



İZMİR KÂTİP ÇELEBİ  
ÜNİVERSİTESİ

---

**Akıllı Sistemlerde Yenilikler ve Uygulamaları  
Sempozyumu**

09-10 Ekim 2014 – zmir

---

**B L D R L E R K T A B I**

**Editör:**

**Yrd. Doç. Dr. Yalçın LER**



# Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU-2014)

09-10 Ekim 2014 – zmir

## B LD R LER K TABI

**Editör:**

**Yrd. Doç. Dr. Yalçın LER**

**Düzenleyen Kurulu**  
zmir Kâtip Çelebi Üniversitesi



**Destekleyen Kurulu**  
Yıldız Teknik Üniversitesi





İzmir Kâtip Çelebi Üniversitesi Yayın No: 2

Bu eser, İzmir Kâtip Çelebi Üniversitesi Yönetim Kurulu'nun 26.03.2015 tarih ve 2015/10 sayılı toplantısında alınan 02 kararı uyarınca üniversitemiz elektronik yayını (e-kitap) olarak yayınlanmasına karar verilmiştir.

Her hakkı saklıdır.

© İzmir Kâtip Çelebi Üniversitesi Yayınları  
2015

**Sertifika No: 23705**

**Editör: Yalçın LER**

**ISBN: 978-605-84722-1-1**

**Adres** İzmir Kâtip Çelebi Üniversitesi Rektörlüğü, Balatçık  
Yerleşkesi, 35620 Çiğli, İzmir, Türkiye  
**Telefon** +90 232 329 3535 / 1255  
**Belge-geçer** +90 232 386 0888  
**E-posta** [ykb@ikc.edu.tr](mailto:ykb@ikc.edu.tr)  
**Web** [ykb.ikc.edu.tr](http://ykb.ikc.edu.tr)

Eserin hukuki ve etik sorumluluğu yazarlara aittir. Tüm hakları saklıdır. Bu kitabın yayım hakkı İzmir Kâtip Çelebi Üniversitesi'ne aittir. İzinsiz kopyalanamaz ve çoğaltılamaz.

## İçindekiler

<b>ÖNSÖZ</b>	<b>iii</b>
<b>ASYU 2014 ORGANİZASYONU</b>	<b>iv</b>
<b>B L M KURULU</b>	<b>v</b>
<b>E T M SEMNER : Doğrusal Olmayan Modeller ile İzleme ve Kontrol: Yapay Sinir Ağlarından Gen Düzeneleyici Ağlara</b>	<b>vi</b>
<b>SEMPOZYUM PROGRAMI</b>	<b>vii</b>
Konjestif Kalp Yetmezliği Telesinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması	1
<b>Nesne Görüntülerinden 3D Modelinın İçin Etkin F-matrisi Hesaplanma Yöntemleri (EN YERLİ ÖDÜLÜ)</b>	<b>6</b>
Güç Sistemleri Arıza Tespitinde Sezgisel Bir Yaklaşım: Renkli Petri Ağları Statiksel Bilgisayarlı Çeviride Paralel Derlemin Büyüklüğünün ve Kalitesinin Etkileri	12
Dalgacık-ANFIS Modeli ile Akarsularda Katı Madde Miktarı Tahmini	18
Heskenilli Mikro İrit Antenin Yabancı Ot Algoritması ile Rezonans Frekansının Belirlenmesi	22
Duygu Tanımadada Farklı Veri Setleri Arasında Bir Çalışma	27
Özdeğer Hesaplaması Ve Yapay Arı Koloni Algoritması Kullanılarak Termal Görüntülerin Bölütlenmesi	31
Biyomedikal Veri Kümeleri Kullanarak Makine Öğrenmesi Sınıflandırma Algoritmalarının Karşılaştırılması	35
EEG Verilerinden Farklı Müzik Türü ve Zihinsel Görevlerin Ayırt Edilmesi	40
Mobil Uygulama ile Görüntü İzleme ve Veri Madenciliği Tekniklerine Dayalı Melanom Tahmin Desteği Sağlanması	44
Destek Vektör Makineleri Kullanılarak Submaksimal Verilerden Maksimum Oksijen Tüketiminin Tahmin Edilmesi	49
Destek Vektör Makineleri ve Nitelik Seçici Algoritma Kullanılarak Maksimum Oksijen Tüketimi Tahmin Modellerinin Geliştirilmesi	54
Uzman Kararımlarında Yeni Bir Yaklaşım: Uzman Kararlarının Yeni Bir Geçiş Fonksiyonuyla Birleştirilmesi	58
İşiksel Verilerin Semantikleştirilmesi	62
Dinamik Optimizasyon Problemleri İçin Uyarlamalı Ate Böceği Algoritması (ÖZET)	67
Üç Kademeli Bir Tedarik Zincirinde Entegre Parti Büyüklüğünün Belirlenmesi (ÖZET)	71
Çok Katmanlı Algılayıcı Ağının Eritim Parametrelerinin Yapay Arı Kolonisi ve Genetik Algoritma ile Optimizasyonu	72
Metin Sınıflandırma İçin Yeni Bir Eritimli Anlamsal Özellik Seçimi Yöntemi	73
Sınıflandırma Tabanlı Türkçe Soru Algılama	77
Nitelik Seçme Problemi İçin Diferansiyel Gelişim Algoritması ve Yapay Arı Kolonisi Optimizasyon Tekniğini Kullanan Melez Yöntem	81
Kril Sürüşü Algoritmasının Atölye Çizelgeleme Problemlerine Uygulanması(ÖZET)	86
Akıllı İbeğe Güvenli İrit için Veri Enjeksiyon Saldırılarının Tespiti	91
Konjestif Kalp Yetmezliği Rahatsızlığının Yapay Sinir Ağları ve Bulanık Yapay Sinir Ağları Yöntemleri ile Telesini	92
Parça-Makine Gruplama Problemi İçin Kısıt Programlama Yaklaşımı (ÖZET)	97
En Yakın Komşuluk Algoritmasında Örneklere Bağılı Dinamik Seçimi	102
Adaptif Sinirsel Bulanık Tahmin Yöntemi ile Esnek Üstyapı Performans Tahmin Modeli Geliştirilmesi	103
Mobilya Üretim Tesisinde Genetik Algoritma ile Makine Düzeneleme	107
Yapay Sinir Ağları ile Doğru Meslek Seçimi	113
	117



Kognitif EEG ıretleri ın Öznitelik Seçimi Tabanlı Kanal Seçimi ve Sınıflandırma	122
Laguerre Fonksiyonları Kullanılarak DA Motor Hızının Sürekli Zamanlı Model Öngörülü Kontrolü	128
Hipertiroidili Hastalarda Kognitif Fonksiyonların ıncelenmesi	132
Bilgisayar Görmesi Ve Gradyan ını Algoritması Kullanılarak Robot Kol Uygulaması	136
Klasik Türk Müzi ını Makamlarının Tanınması	141
Rüzgâr Enerjili Ekonomik Yük Da ıtım Probleminin Yer Çekimsel Arama Algoritması ile Çözülmesi	146
Destek Vektör Makinelerinde Parametre Seçiminin Duygu Analizi Üzerindeki Etkisi	151
Otomatik Tanımlanmış Hedef Takip Sistemi	155
Konjektif Kalp Yetmezli ının Hilbert-Huang Dönü üm ile Analizi	159
Sürü Simülasyon Programı Geli tirilmesi Ve Performansının ıncelenmesi	163
FPGA Tabanlı Gerçek Zamanlı Bir Görüntü ıleme Sisteminin Gerçeklenmesi	167
Açgözlü Rastsalla tırılmış Uyarlamalı Arama Algoritmasının Farklı Yerel Arama Yapılarıyla Akı Tipi Çizelgeleme Problemlerine Uygulanması (ÖZET)	171
ıkın Kip ılevlerinin Kaynak Sayılarına Göre Da ıtımı	172
Çevresel Ekonomik Yük Da ıtım Probleminin ıyile tirilmiş Yerçekimsel Arama Algoritması ile Çözümü	176
Parçacık Sürü Optimizasyonu ve Hücresel Otomata Tabanlı Sayısal Görüntü Karı tırma Yöntemi	182
Çok Hedefli Parçacık Sürü Optimizasyonu için Smith Aba ını Yakla ıtım	187
El Geometrisi Tabanlı Kısıtlamasız ve Temassız Bir Kimliklendirme Sistemi	192
Zaman Bölgesi Saçılım Sinyallerinin Yapısal Öznitelikleri ve Yapay Sinir A ıları Kullanılarak Dielektrik Küresel Hedeflerin Sınıflanması	196
Kolektif Ö renme Algoritmalarıyla Çocuklarda Obezite Hastalı ına Yakalanma Olasılıklarının Hesaplanması	200
Bulanık Analitik Hiyerar ı Prosesi Yöntemi Kullanılarak Ye il Tedarikçi Firma Seçimi: Enerji Sektöründe Bir Uygulama	206
PSO Algoritması ile Çok Katmanlı Algılayıcı A ımın Belirlenmesi	210
Görüntü ıleme Teknikleri Kullanarak Ozonlanmış Kayısların Morfolojik Özelliklerinin ıncelenmesi	214
Genetik Algoritma Kullanarak Çift Rotorlu Sistemin Gürbüz Denetleyicisinin Kazançlarının Ayarlanması (ÖZET)	218
CUDA Platformunda ıkı Boyutlu Ayırık Haar Dalgacık Dönü ümü	219
<b>YAZAR L İSTES</b>	<b>223</b>

## ÖNSÖZ

Akıllı Sistemlerde Yenilikler ve Uygulamaları (ASYU) Sempozyumu, 9-10 Ekim 2014 tarihleri arasında zmir'in yeni kurulan devlet üniversitesi olan zmir Kâtip Çelebi Üniversitesi ( KÇÜ) tarafından Yıldız Teknik Üniversitesi (YTÜ) deste iyle zmir'de düzenlenmiştir.

Sempozyum, disiplinler arası bir konu olan akıllı sistemler alanında çalı an ara tırmacıları bir araya getirmeyi ve aralarında etkin bir iletişim platformu oluşturmaya hedeflemektedir. Sempozyumda Yapay Sinir Ağları, Bulanık Mantık, Karma Akıllı Sistemler, Bilgi Tabanlı Sistemler, Evrimsel Hesaplama, Uzman Sistemler, Evrimsel Algoritmalar, Makine Öğrenmesi, Örüntü Tanıma, Akıllı Elektronik Sistemler gibi yöntemler ve bu yöntemlerin liste ile sınırlı olmamak üzere a a ıdaki örnek alanlardaki uygulamaları konu alınmıştır:

- Akıllı Ajanlar
- Akıllı Kontrol Sistemleri
- Akıllı Savunma / Güvenlik Sistemleri
- Akıllı Sensörler ve Malzemeler
- Akıllı Sistemler için Donanım Gerçeklemeleri
- Akıllı Ya am
- Biyoinformatik
- Biyomedikal Mühendisliğinde Akıllı Uygulamalar
- Doğal Dil İleme
- Genetik Algoritma
- İnsan-Bilgisayar Etkileşimi
- Memetik Hesaplama
- Parçacık Sürüleri
- Robotik ve Otomasyonda Akıllı Yaklaşımlar
- Sinyal ve İletimde Akıllı Yaklaşımlar
- Sistem Kimliklendirme/Modellemede Akıllı Yaklaşımlar
- Sürü Zekası
- Sosyal Sinyal İleme
- Veri Madenciliği
- Yapay Zeka
- Akıllı Sistemler ile ilgili diğer konular

Sempozyum dili Türkçe olup güncel konulardaki sempozyumda yayınlanmak üzere gönderilen tüm bildiriler en az iki hakem tarafından körlene değerlendirme yöntemi ile değerlendirilmiştir. Sempozyum çağrısına gönderilen 70 adet bildiri içerisinde hakem değerlendirmelerine göre 39 farklı kurumdan 128 farklı yazarın katkı koyduğu 54 adet bildiri yayınlanmak üzere kabul edilmiştir. Sempozyuma ilgi gösteren tüm ara tırmacılara teşekkür ederiz.

## **ASYU 2014 ORGAN ZASYONU**

ASYU 2014, zmir Kâtip Çelebi Üniversitesi ( KÇÜ) tarafından  
Yıldız Teknik Üniversitesi (YTÜ) deste iyle düzenlenmiştir.

### **ASYU 2014 Genel Ba kan**

Tülay YILDIRIM (YTÜ)

### **ASYU 2014 Sempozyum Ba kanı**

Yalçın İLER ( KÇÜ)

### **Düzenleme Kurulu**

Adnan KAYA ( KÇÜ)

Ay egül ALAYBEYO LU ( KÇÜ)

Banu D R (YTÜ)

Bülent BOLAT (YTÜ)

Erkin GEZG N ( KÇÜ)

Fatih Cemal CAN ( KÇÜ)

Hakan OFLAZ ( KÇÜ)

Mehmet M EK ( KÇÜ)

Mustafa Alper SELVER (DEÜ)

Mustafa Berkant SELEK (Ege Üniv.)

Özgün BA ER ( KÇÜ)

Sava AH N ( KÇÜ)

Utku Kür at ERCAN ( KÇÜ)

**ASYU 2014, zmir Kâtip Çelebi Üniversitesi Teknoloji Transfer Ofisi ve Bilimsel Ara tırma Projeleri  
Koordinatörlü ü tarafından desteklenmi tir.**

**B L M KURULU**

Aydın Akan ( Ü)	Rembiye Kandemir (Trakya Ü.)
Mehmet Fatih Amasyalı (YTÜ)	Özkan Karabacak ( TÜ)
Ayten Atasoy (KTÜ)	Sedef Kent ( TÜ)
Umut Engin Ayten (YTÜ)	Yakup Kutlu (MKÜ)
Derya Birant (DEÜ)	Fatma Latifo lu (Erciyes Ü.)
Bülent Bolat (YTÜ)	Onur Osman (Arel Ü.)
Suna Bolat (DAÜ)	Haldun M. Özakta (Bilkent Ü.)
Banu Diri (YTÜ)	Ender Özcan (University of Nottingham)
Tolga Ensari ( Ü)	Övünç Polat (Akdeniz Ü.)
Gönenç Ercan (Çankaya Ü.)	Sava ahin ( KÇÜ)
Burcu Erkmen (YTÜ)	Altu Uzunali (Tubitak)
Gülây Öke Günel ( TÜ)	Cem Ünsalan (Yeditepe Ü.)
Alev Gümü (YTÜ)	Revna Acar Vural (YTÜ)
Tunga Güngör (BÜ)	A. Ye im Yayla (Marmara Ü.)
Fikret Gürgen (BÜ)	Erdem Yazgan (HÜ)
Yalçın ler ( KÇÜ)	Engin Ye il ( TÜ)
Nihan Kahraman (YTÜ)	Tülay Yıldırım (YTÜ)
Salim Kahveci (KTÜ)	Nerhun Yıldız (YTÜ)

## **E T M SEM NER : Do rusal Olmayan Modeller ile İret İleme ve Kontrol: Yapay Sinir A larından Gen Düzenleyici A lara**

**9 Ekim 2014**

*Prof. Dr. Cüneyt GÜZEL ,*

*Elektrik Elektronik Mühendisliği, İzmir Ekonomi Üniversitesi*

Kapalı biçimde çözümlerin elde edilebilmesi ve kuramsal çıkarımlarda sağladığı inceleme kolaylıkları açısından iaret ileme, kontrol ve diğer alanlarda çokunlukla do rusal modelleri ye leriz. Yüksek genlikli giri ve bozucular dolayısıyla çalı ma noktasından büyük sapmalar oldu u sistemlerde, elektrik devrelerinde iaretlerin dalga biçimlerinde önemli de i iklikler yapmakta kullanılan diyot vb devrelerde, do rusal dinamiklerle açıklamanın olanaksız oldu u kararlı periyodik, sanki-periyodik ve kaotik titre imlerin modellenmesinde oldu u gibi, do rusal olmayan modellerin geli tirilmesi ve kullanılmasına gereksinim vardır. Bu gereksinimi kar ılamak için do rusal olmayan modellerden hangilerini kullanmalıyız sorusu sürmekte olan ve biçim de i tirerek sürece i öngörülebilecek bir soru olarak durmaktadır. Sırasıyla, polinomsal, sinüzoidal, dalgacık, tanjant-hiperbolik, Gauss gibi taban fonksiyonlarının do rusal birlemi biçiminde do rusal olmayan fonksiyonlar tanımlayan Taylor, Fourier ve Dalgacık serileriyle çok-katmanlı algılayıcı ve radyal-taban fonksiyonlu yapay sinir a modellerinin, fonksiyonlara dolayısıyla fonksiyon olarak tanımlanan iaret ileme, kontrol vb problemlerin çözümüne, istenildi i kadar yakla abilme özellikleri bulunmaktadır. 1940'lı yıllarda sinir hücrelerinin uyarılma ve bastırılma olarak ikili çalı ma ilkesinden esinlenerek ortaya konulan ayrık algılayıcı modelinden günümüze kadar geli tirilen cebrik ve dinamik yapay sinir a modelleri, her türlü fonksiyona yakla abilme yapıları ve örneklerden ö renme özellikleriyle, ö renen evrensel makine modelleri olarak artan bir ilgi oda ı olu turmu lardır. Bu konu mada, do ada gözlemlenen karma ık davranı lar ile do adan esinlenerek geli tirilen do rusal olmayan modeller ve ö renme algoritmaları üzerine, cebrik ve dinamik yapay sinir a modelleri ile parçacık sürüsü optimizasyonu ve genetik algoritmaları da kapsayan ö renme algoritmalarından gen düzenleyici a lara do ru, do rusal olmayan modeller ve onların iaret ileme ile kontrol uygulamaları üzerine genel bir de erlendirme sunulacaktır.

**SEMPOZYUM PROGRAMI****PER EMBE, 9 EK M 2014**

09:00-10:00	<b>KAYIT-</b> zmir Kâtip Çelebi Üniversitesi Konferans Salonu	
10:00-10:45	<b>AÇILI KONU MASI ve Müzik Dinletisi</b>	
10:45-12:00	<b>E itim Semineri: Do rusal Olmayan Modeller ile aret leme ve Kontrol: Yapay Sinir A larından Gen Düzenleyici A lara</b>  Prof. Dr. Cüneyt GÜZEL Elektrik Elektronik Mühendisli i zmir Ekonomi Üniversitesi  zmir Kâtip Çelebi Üniversitesi Konferans Salonu	
12:00-13:30	<b>Ö LE YEME</b>	
13:30-15:00	<b>Paralel Oturumlar</b>	
	<b>Salon 1 : Do al Dil leme ve Veri Madencili i</b> (4, 13, 27, 28, 34, 46)	<b>Salon 2 : Akıllı Kontrol Sistemleri</b> (3, 24, 37, 41, 57, 70)
15:00-19:00	<b>Sosyal Program: irince Gezisi</b>	
20:00-22:00	<b>Gala Yeme i</b>	

**CUMA, 10 EK M 2014**

09:00-10:15	<b>Paralel Oturumlar</b>	
	<b>Salon 1 : Akıllı Ajanlar</b> (19, 32, 33, 48, 66)	<b>Salon 2 : Savunma ve Güvenlik Sistemleri</b> (31, 36, 47, 55, 58)
10:15-10:30	<b>Çay-Kahve Molası</b>	
10:30-12:00	<b>Paralel Oturumlar</b>	
	<b>Salon 1 : Akıllı Sistemler ile lgili Di er Konular</b> (8, 38, 45, 52, 54, 62)	<b>Salon 2 : Sürü Zekası</b> (23, 25, 30, 49, 56, 65)
12:00-13:30	<b>Ö LE YEME</b>	
14:00-15:30	<b>Paralel Oturumlar</b>	
	<b>Salon 1 : nsan Bilgisayar Etkile imi</b> (1, 9, 12, 39, 43, 51)	<b>Salon 2 : Sinyal ve aret leme Uygulamaları</b> (2, 10, 42, 44, 53, 69)
15:30-15:45	<b>Çay-Kahve Molası</b>	
15:45-16:45	<b>Paralel Oturumlar</b>	
	<b>Salon 1: Yapay Zeka</b> (6, 15, 16, 35)	<b>Salon 2 : Veri Madencili i</b> (11, 22, 29, 61)
16:45	<b>KAPANI</b>	

# Konjestif Kalp Yetmezliđi Teşhisinde Kullanılan Çapraz Doğrulama Yöntemlerinin Sınıflandırıcı Performanslarının Belirlenmesine Olan Etkilerinin Karşılaştırılması

Ali NARİN<sup>1</sup> Yalçın İŞLER<sup>2</sup> Mahmut ÖZER<sup>3</sup>

<sup>1,3</sup>Elektrik-Elektronik Mühendisliđi Bölümü  
Mühendislik Fakültesi

Bülent Ecevit Üniversitesi, ZONGULDAK

<sup>2</sup>Biyomedikal Mühendisliđi Bölümü

Mühendislik-Mimarlık Fakültesi

İzmir Katip Çelebi Üniversitesi, İZMİR

alinarin45@gmail.com

islerya@yahoo.com

mahmutozer2002@yahoo.com

## Özet

*Konjestif kalp yetmezliđi (KKY) vücudun ihtiyaç duyduđu miktarda kanın pompalanamaması durumudur. Bu taniya sahip hastaların ölüm oranı çok yüksek olduğundan erken teşhis önemlidir. Bu amaçla gerçekleştirilen sınıflandırma algoritmalarının performanslarının ölçümü için farklı doğrulama yöntemleri vardır. Bu çalışmada, KKY hastalarının teşhisinde sık kullanılan 5 farklı sınıflandırıcının performans ölçümleri için k-parçalı ve birisi-dışarıda çapraz doğrulama yöntemleri denenmiştir. Her algoritma 100 defa denenerek ortalama başarımları ve standart sapmaları kayıt edilmiştir. Sonuç olarak, çapraz doğrulamada kullanılan veri parçası sayısı arttıkça ortalama başarımların arttığı ve başarımların değişkenliğinin azaldığı tespit edilmiştir.*

## 1. Giriş

Doku ve hücrelerin ihtiyaç duydukları oksijen ve besin maddelerinin vücuda yeterli miktarda pompalanması kalbin en önemli görevidir. Kalbin yeterli miktarda kanı pompalayamaması durumunda kalp yetmezliđi ortaya çıkar [1]. Kalp yetmezliđi durumunda kalp çalışır ancak yeterli ve ihtiyaç duyulan miktarda kanı pompalayamaz. Kan dolaşımının yetersizliğinden dolayı bazı doku ve damarlarda kan birikir. Buna konjestiflik denir ve kalp yetmezliđi hastalarının çoğunluğunda meydana geldiğinden dolayı bu rahatsızlığa genellikle konjestif kalp yetmezliđi (KKY) denir [2].

KKY hastalarının teşhis konulduktan sonraki beş yıl içinde %50 sinin öldüğü ortaya konmuştur [3]. Bu nedenle KKY rahatsızlığına erken teşhis konulabilirse hem ölüm oranı azaltılmış hem de kişilerin daha iyi yaşam sürmesi sağlanmış olur. KKY'nin teşhis edilmesinde standart olarak kullanılan elektrokardiyografi, ekokardiyografi ve göğüs röntgeni başta olmak üzere birçok klinik inceleme testleri ve yöntemlerinin yansira kalp hızı değişkenliđi (KHD) analizi de kullanılmaktadır [4-10]. KHD analizi sonucunda elde edilen ölçümlerden oluşturulan öznitelikler çeşitli sınıflandırıcı ve kümeleme algoritmalarına uygulanmaktadır [5]. Bu sınıflandırma algoritmalarının başarımları elde edilen özniteliklerin seçilmesi [4,5,9], normalleştirme işlemlerine [11] ve diğer ön işlem uygulamalarına [12] göre değişiklik göstermektedir. Bu algoritmaların başarımlarının ölçümüyle ilgili literatürde çeşitli çapraz doğrulama yöntemleri verilmiştir [13]. Bu çalışmanın amacı, KHD ölçümleri kullanılarak KKY olan hastaların teşhis edilmesinde kullanılan k-parçalı (k=2,3,5,10) çapraz doğrulama yöntemi ve birisi dışarıda çapraz doğrulama yöntemlerinin literatürde biyomedikal sinyallerin sınıflandırılmasında sık kullanılan LDA, KNN, MLP, RBF ve SVM sınıflandırıcılarının başarımlarına olan etkilerinin araştırılmasıdır.

## 2.Yöntem

### 2.1 Verilerin Elde Edilmesi

Yapılan çalışmada kullanılan KHD verileri MIT/BIH veri setleri <http://www.physionet.org> internet

adresinden ücretsiz olarak elde edilmiştir [14]. Kullanılan bu KHD veriler şu şekildedir:

- “Congestive Heart Failure RR Interval Database” (chf2db) veri tabanı: yaşları 34 ile 79 arasında değişen 29 adet hastadan elde edilmiş EKG kaydı.
- “Normal Sinus Rhythm RR Interval Database” (nsr2db) veri tabanı: yaşları 24 ile 76 arasında değişen 54 adet normal EKG kaydı.

Her ne kadar veri tabanları 24 saatlik KHD verilerinden oluşsa da, sonuca daha hızlı ulaşabilmek ve klinik ortamda hastaları en az şekilde rahatsız etmek için sadece 5 dakikalık (300 saniyelik) KHD verileri kullanılmıştır [4].

## 2.2. Kalp Hızı Değişkenliği Analizi Ölçümleri

KHD verileri EKG işaretindeki QRS dalga yapısının belirlenmesi sonucunda elde edilir. Çünkü QRS dalga yapısı EKG işareti içerisinde en belirgin genlik değerine sahip bileşendir. QRS tespit edildikten sonra peş peşe gelen RR zaman aralıkları arasındaki zaman farkı (Yani  $T_n = t_n - t_{n-1}$ ) olarak tanımlanır [15]. KHD çalışmalarında, hasta bilgisi (yaş), zaman dizisi analizi (ortalama, standart sapma, vb.), frekans alanı analizi (çeşitli frekans bölgelerindeki spektral güç miktarları) ve doğrusal olmayan yöntemlerle elde edilen ölçümlerin (Poincare haritası, sembolik, yaklaşık ve örnek entropileri) kullanılmaktadır. Ayrıntılı bilgi için kaynakçada verilen referanslara bakılabilir [1,5].

Frekans alanı ölçümleri için genellikle hızlı Fourier dönüşümü (FFT) yöntemini kullanan Welch periyodogram yöntemi kullanılmaktadır [4]. Bu yöntem kullanılarak sadece zamanda eşit aralıklarla örneklenmiş veriler üzerinden güç spektral yoğunluğu (GSY) hesaplanabilir. Bu çalışmada FFT kullanımından önce KHD verileri 4 Hz örnekleme hızında kübik spline ara değerlendirme metodu ile yeniden örneklenmiş [15] ve analizde durağanlığı sağlamak için eğilim yok edilmiştir [12].

Frekans alanı ölçümlerinde, GSY üzerindeki farklı frekans bölgelerindeki güçler ve tepe frekansları hesaplanarak incelenir. KHD analizinde yaygın olarak üç frekans bandı kullanılmaktadır: VLF(0,033 Hz), LF(0,033– 0,15 Hz) ve HF(0,15–0,4 Hz) [15]. Bu çalışmada, klasik GSY yöntemlerine alternatif olarak geliştirilen Lomb periyodogram yöntemi ile elde edilen frekans alanı ölçümleri de kullanılmaktadır. Bu yöntem ile zaman alanında yeniden örneklmeye ihtiyaç duyulmadan, doğrudan KHD verileri üzerinden, GSY hesaplanabilmektedir [16].

5 dakikalık zaman aralığı için tanımlanan standart frekans alanı KHD ölçümleri [15] nolu referansta ayrıntılı olarak tanımlanmış ve standart olarak kullanımları önerilmiştir (Tablo 1). Frekans alanı ölçümleri Welch periyodogram ve Lomb periyodogram yöntemleri kullanılarak her ikisi için de ayrı ayrı hesaplanmıştır.

Tablo 1. Frekans alanı standart KHD ölçümleri.

VLF	VLF frekans bandı toplam gücü
LF	LF frekans bandı toplam gücü
HF	HF frekans bandı toplam gücü
LFHF	LF/HF frekans bantları güçleri oranı
NLF	$LF / (LF + HF) = (\text{Normalize LF gücü})$
NHF	$HF / (LF + HF) = (\text{Normalize HF gücü})$

Dalgacık analizi bir sinyalin zaman ve ölçek boyutlarının birlikte incelenmesine olanak tanıdığı gibi yapısından dolayı polinomsal durağansızlıkları da ortadan kaldırır [17]. Bu yönüyle, dalgacıkların RR aralıklarının analizinde çok kullanışlı olduğu rapor edilmiştir [8]. Bu analiz yönteminde de 4 Hz ile yeniden örneklenmiş KHD verisi üzerinden sık kullanılan Daubechies-4 ana dalgacığı ile 7 seviyeli [4] dalgacık dönüşümü metodu kullanılmıştır.

Bu çalışmada ayrıca doğrusal olmayan yöntemlerle elde edilen Poincare haritası, yaklaşık entropi, örnekleme entropi, eğilim yok edilmiş dalgalanma analizi ve sembolik analiz ölçümleri kullanılmıştır.

Bu şekilde hasta bilgisi 1 adet, zaman alanı ölçümleriyle elde edilen 4 adet ölçüm, frekans alanı ölçümleriyle elde edilen 38 adet ölçüm ve doğrusal olmayan yöntemlerle elde edilen 16 adet ölçüm ile toplam 59 adet öznitelik kullanılmıştır.

## 2.3 Özniteliklerin Ölçeklenmesi

Sınıflandırma ve kümeleme algoritmalarında kullanılan özniteliklerin birimlerinin birbirlerine göre büyüklüklerinin çok farklılıklar göstermesi nedeniyle, kullanılan özniteliklerin aynı ölçeğe indirgenmesi gerekmektedir. Bu işleme normalleştirme adı verilir [13]. Bu çalışmada kullanılan tüm öznitelikler [0,1] aralığına ölçekleme olan (Min-Max) yöntemi kullanılmıştır.

## 2.4 Sınıflandırma Algoritmaları

### 2.4.1. Doğrusal Ayraç Analizi (LDA)

Doğrusal ayraç analizi (LDA) iki ya da daha fazla guruba ait özniteliklere göre ayırım yapabilen istatistiksel bir analiz yöntemidir. Matematiksel olarak ayraç fonksiyonları kullanılmaktadır. LDA



sınıflandırma ve boyut azaltma yöntemlerinde oldukça yaygın kullanıma sahiptir [13].

#### 2.4.2. K-En Yakın Komşu (KNN) Sınıflandırıcı

K en yakın komşu (KNN) sınıflandırıcısı örnek tabanlı bir sınıflandırıcı olup doğrudan sınıfı bilenen eğitim kümesindeki örneklerle kıyaslama yapar. Eğitim aşaması giriş verilerinin ait oldukları sınıf bilgisinin saklanmasıyla ibarettir. Bu algoritmada sınıflandırılmak istenen örnek ile eğitim kümesindeki en yakın k adet örneğin ait olduğu sınıfların çoğunluğuna bakılarak sınıflandırma işlemi yapılır. İki örnek arasındaki uzaklığın ölçülmesinde ise Öklid uzaklık ifadesi kullanılmıştır.

#### 2.4.3 Çok Katmanlı Algılayıcı (MLP)

Yapay sinir ağı uygulamalarında çok kullanılan ağ yapısıdır [13]. Hem doğrusal uygulamalarda hem de doğrusal olmayan uygulamalar için kullanılabilir. MLP giriş katmanı, bir veya birden çok saklı katman ve çıkış katmanından oluşmaktadır. MLP'nin her bir katmanında birçok sinir hücresi bulunmaktadır. Bu sinir hücreleri birbirlerine ağırlıklarla bağlıdır. Bu ağırlıklar beklenen çıktı ile ağı çıktısı arasındaki hata minimum olana kadar ağı eğitimi gerçekleştirilir. Ağı çıktı fonksiyonu ve hata fonksiyonu:

$$y_{c,i} = f\left(\sum_{i=1}^N w_{ji}x_i\right) \quad (1)$$

$$E = \frac{1}{2} \sum_i (y_{bc,i} - y_{c,i})^2 \quad (2)$$

Burada  $x_i$  girdi verisi,  $w_{ji}$  ağırlık,  $f(\cdot)$  aktivasyon fonksiyonu,  $y_{c,i}$  i. ağı çıktısı,  $y_{bc,i}$  i. beklenen çıktıdır.

#### 2.4.4. Radyal Tabanlı Fonksiyon (RBF)

Radyal tabanlı fonksiyon (RBF) yapay sinir ağları da girdi katmanı, saklı katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. MLP ağlarına oranla daha hızlı çalışırlar [13]. RBF diğer bir ifadeyle yapay sinir ağlarının çok boyutlu bir uzayda eğri uydurma yaklaşımıdır. Bu ağ türünün saklı katmanında aktivasyon fonksiyonu olarak Gauss fonksiyonu kullanılmaktadır. Gauss aktivasyon fonksiyonu ifadesi:

$$y_i(x) = \sum_{j=1}^k w_{ji} \exp\left(-\frac{\|x - \mu_j\|}{2\sigma_j^2}\right) \quad (3)$$

Burada  $w_{ji}$  ağırlıkları,  $k$  gizli katman nöron sayısı,  $x$  girdi verisi,  $\mu_j$  j'inci nöron merkezi,  $\sigma_j$  j. dağılım parametresi olmak üzere  $y_i$  ağı çıktısını vermektedir.

Ağı çıktısı saklı katman çıkışlarının  $w_{ji}$  ağırlıkla çarpımı sonucu elde edilir ve amaç optimum ağırlık değerlerinin bulunmasıdır.

#### 2.4.5. Destek Vektör Makineleri (SVM)

Destek vektör makineleri istatistiksel öğrenme teorisine dayalı bir yöntemdir. SVM, hem doğrusal hem de doğrusal olmayan veri gruplarında kullanılmaktadır. Bu yöntemde amaç iki gruba birinden ayıran düzlemin bulunmasıdır. Bunun için iki gruba da yakın ve birbirine paralel iki sınır çizgisi belirlenir. Bu sınır çizgilerine destek vektörleri denmektedir. Bu sınıflandırıcı iki sınır çizgisinden yola çıkarak ortak bir düzlemin belirlenmesi işlemine dayanmaktadır [13].

SVM' de bazı veriler doğrusal bir şekilde ayıramamaktadır. Bu durumda ise çekirdek fonksiyonları kullanılarak veriler başka bir boyuta taşınıp doğrusal olmayan dönüşümler de kullanılabilir.

### 2.5 Çapraz Doğrulama Yöntemleri

Çapraz doğrulama yönteminde veri seti, iki gruba ayrılır. Bunlardan birincisi (eğitim seti) sınıflandırıcının model parametrelerinin belirlenmesinde kullanılırken diğeri (test seti) ise eğitilen sınıflandırıcının başarı performansını ölçmek için kullanılır [13].

#### 2.5.1 k-Parçalı Çapraz Doğrulama Yöntemi

k-parçalı doğrulama yöntemi, toplam  $n$  örneğin bulunduğu bir veri setinde, her birinde  $\frac{n}{k}$  örneğin bulunduğu  $k$  adet ayrı parçaya ayrılır. Her seferinde farklı bir veri seti kümesi test için ayrılarak kalan diğer  $k-1$  veri seti eğitim için kullanılır. Her defasında test kümesi değiştirilerek sınıflandırıcı  $k$  defa eğitilir. Bu şekilde elde edilen  $k$  adet hatanın ortalaması ile sınıflandırıcı performansı tahmin edilmiş olur.

#### 2.5.2 Birisi Dışarıda Çapraz Doğrulama Yöntemi

Birisi dışarıda çapraz doğrulama yönteminde,  $n$  adet örneğin bulunduğu veri setinde, veri seti  $n$  parçaya bölünür.  $n$  parçaya bölünmüş veri setinde her seferinde sadece bir örnek dışarıda kalacak şekilde kalan tüm veri seti ( $n-1$ ) ile sınıflandırıcı eğitilir ve bu işlem tüm örnekler için tekrarlanır. Bu şekilde elde edilen  $n$  adet hatanın ortalaması ile sınıflandırıcı performansı tahmin edilmiş olur. Gerçekte örnek sayısı kadar  $k$  parçaya ayrılan k-Parçalı Çapraz Doğrulama Yöntemi gibi düşünülebilir.

## 2.6. Sınıflandırıcı Başarımlarının Belirlemesi

Sınıflandırıcıların başarımlarında kullanılan ölçütler şu şekilde verilmektedir [11]:

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (4)$$

$$SEN = \frac{TP}{TP + FN} \quad (5)$$

$$SPE = \frac{TN}{TN + FP} \quad (6)$$

Burada gerçekten hasta olup sınıflandırıcı tarafından hasta olarak bulunanların sayısını TP ve yanlışlıkla sağlam olarak bulunanların sayısını FN ile gerçekten sağlam olup sınıflandırıcı tarafından sağlam olarak bulunanların sayısını TN ve yanlışlıkla hasta olarak bulunanların sayısını FP verir.

## 3. Sonuçlar

Bu çalışmada kullanılan KHD ölçümleri, sınıflandırıcı algoritmaları ve çapraz doğrulama yöntemlerinin hesaplanması için MATLAB 2013a yazılımı kullanılmıştır. Çalışmada toplam 83 kişiden elde edilmiş 59 adet KHD ölçümü kullanılmış ve her algoritma 100 defa çalıştırılmış ortalama ve standart sapmaları kayıt edilmiştir. Yapılan çalışmada kullanılan sınıflandırıcılar: MLP sınıflandırıcısı 1-50 arasındaki saklı katman nöron sayıları, RBF sınıflandırıcısı 0,1-3,0 arasındaki 0,1 aralıklı yayılım parametre değerleri, SVM sınıflandırıcısı doğrusal çekirdek fonksiyonu, KNN sınıflandırıcısı 1-19 arasındaki tek değerlerdeki komşuluk değerleri ve LDA sınıflandırıcısı ise hem doğrusal hem de ikinci dereceden fonksiyonlar için çalıştırılmıştır. Her bir sınıflandırıcı başarımları literatürde sık kullanılan 2, 3, 5 ve 10 parçalı çapraz doğrulama yöntemi ile birisi dışarda çapraz doğrulama yöntemi kullanılarak tespit edilmiştir. Elde edilen SEN, SPE ve ACC başarımları ortalama±standart sapma olarak düzenlenmiştir (Tablo 2). Elde edilen sonuçlara göre birisi dışarda çapraz doğrulama yöntemi ile hesaplanan ortalama sınıflandırıcı başarımları en yüksek değerlere ve en düşük standart sapma değerlerine sahip olduğu görülmektedir. Ayrıca çapraz doğrulama yöntemindeki parça sayısı arttıkça sınıflandırıcı performanslarına ait standart sapmaların da sürekli azaldığı da görülmektedir. Bu tabloya göre en yüksek sınıflandırıcı başarımları KNN algoritmasının birisi dışarda çapraz doğrulama yöntemiyle doğrulanması halinde elde edildiği görülmektedir.

## 4. Tartışma

Elde edilen sonuçlara göre, sınıflandırıcı performanslarının belirlenmesinde seçilen çapraz

doğrulama yönteminin KKY hastalarının normal kontrol grubundan ayırt edilmesi için tasarlanan teşhis sisteminin değerlendirilmesine etki ettiği görülmüştür. Tablo 2'ye göre çapraz doğrulama sisteminde kullanılan parça sayısı arttıkça ortalama sınıflandırıcı başarımları artmakta ve değişkenliği azalmaktadır. Sonuçlarda tekrarlanabilirlik tercih edilecekse birisi dışarıda yönteminin kullanılması daha etkili olabilir. Genel bir kanıya ulaşmak için diğer doğrulama yöntemlerinin ve daha fazla parça sayısının incelemeye dâhil edilmesi gerekmektedir. Üstelik bir öznitelik seçimi yönteminin de çalışmaya dahil edilmesiyle daha doğru bir yargıya ulaşılabileceği düşünülmektedir.

Tablo 2: Çapraz Doğrulama Yöntemine Göre Sınıflandırıcı Başarımları

		ÇAPRAZ DOĞRULAMA YÖNTEMİ	SEN	SPE	ACC
LDA	k-parçalı	k=2	76.27±3.89	79.07±4.96	78.09±3.68
		k=3	78.20±3.59	78.72±4.15	78.54±3.13
		k=5	67.72±3.93	80.16±4.15	75.81±3.28
		k=10	79.55±2.03	79.18±2.32	79.31±1.69
	birisi-dışarda	79.31±1.23	79.27±0.90	79.35±0.58	
KNN	k-parçalı	k=2	50.62±6.70	90.68±3.29	76.68±3.09
		k=3	49.51±4.73	95.75±1.15	79.60±1.70
		k=5	49.79±3.77	96.12±0.95	79.94±1.53
		k=10	50.79±4.15	94.75±1.08	79.39±1.70
	birisi-dışarda	52.10±1.12	96.29±0.47	80.85±0.44	
MLP	k-parçalı	k=2	53.86±17.31	81.42±14.66	71.75±8.84
		k=3	57.41±13.88	83.12±10.70	74.14±6.31
		k=5	59.10±10.53	85.46±8.73	76.25±5.28
		k=10	56.72±9.47	87.44±5.33	76.71±4.42
	birisi-dışarda	60.93±6.70	85.44±4.03	76.87±3.56	
RBF	k-parçalı	k=2	60.24±11.47	78.40±9.07	72.06±5.38
		k=3	59.31±9.09	78.14±7.42	71.56±4.51
		k=5	53.79±8.14	84.85±4.80	74.00±3.20
		k=10	54.44±4.95	87.33±3.34	75.84±2.75
	birisi-dışarda	60.34±1.03	85.46±2.66	76.68±1.11	
SVM	k-parçalı	k=2	64.24±8.34	80.38±5.96	74.74±4.35
		k=3	66.75±5.95	80.37±4.80	75.61±3.38
		k=5	69.41±5.47	80.40±4.19	76.56±3.43
		k=10	71.27±3.53	80.12±3.41	77.03±2.54
	birisi-dışarda	75.10±1.59	81.61±1.15	79.33±0.91	

## 5. Kaynaklar

- [1] C. Flavell and L. W. Stevenson, "Take Heart with Heart Failure" , *Circulation*, 104: 89, 2001.
- [2] J. Wilbur and P. James, "Diagnosis and management of heart failure in the outpatient setting" , *Primary Care*, 32: 1115-1129, 2005.
- [3] American Heart Association, "Heart Disease and Stroke Statistics-2006 Update: A Report From the American Heart Association Statistics Committee and Stroke Statistics Subcommittee." *Circulation*, 113: 85-151, 2006.
- [4] Y. Isler and M. Kuntalp, "Combining Classical HRV Indices with Wavelet Entropy Measures Improves to Performance in Diagnosing Congestive Heart Failure" , *Comput Biol Med*, 37(10): 1502-1510, 2007.
- [5] A. Narin, Y. Isler and M. Ozer, "Investigating the performance improvement of HRV Indices in CHF using feature selection methods based on backward elimination and statistical significance" , *Comput Biol Med*, 45: 72-79, 2014.
- [6] R.G. Lee, C.C. Hsiao and C.Y. Kao, "Using different entropies to analyze the heart rate variability of congestive heart failure patients" , *Biomed Eng-App Bas C*, 23: 253, 2011.
- [7] L. Pecchia, P. Melillo, M. Sansone and M. Bracale, "Discrimination Power of Short-Term Heart Rate Variability Measures for Chf Assessment" , *IEEE T Inf Technol B*, 15(1): 40-46, 2011.
- [8] U. Wiklund, M. Akay and U. Niklasson, "Short-Term Analysis of Heart-Rate Variability by Adapted Wavelet Transforms" , *IEEE Eng Med Biol*, 16(5): 113-118 and 138, 1997.
- [9] A. Narin ve Y. Isler, "Konjestif Kalp Yetmezliđi Hastalarının Kalp Hızı Verileri Kullanılarak Teşhisi Üzerine Temel Bileşen Analizinin Etkisi" , *IEEE 20. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU2012)*, Fethiye / Muđla, 18-20 April 2012.
- [10] A. Narin ve Y. Isler ve M. Ozer, "Konjestif Kalp Yetmezliđinin Kalp Hızı Deđişkenliđi Analizi ile Teşhisinde Sınıflandırıcı Başarımlarının Karşılaştırılması" , *IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU2013)*, Girne / KKTC, 24-26 April 2013.
- [11] Y. Isler and M. Kuntalp, "Heart Rate Normalization in the Analysis of Heart Rate Variability in Congestive Heart Failure" , *P I Mech Eng H*, 224(3): 453-463, 2010.
- [12] Y. Isler, M.A. Selver ve M. Kuntalp, "Kalp Hızı Deđişkenliđi Analizinde Eğilim Yok Etmenin Etkileri" , *II. M.hendislik Bilimleri Gen. Araştırmacılar Kongresi MBGAK'2005*, İstanbul, 213-219, 17-19 October 2005.
- [13] R.O. Duda, P.E. Hart and D.G. Stork, *Pattern Classification*, 2nd edition, New York: Wiley, 2000.
- [14] A.L. Goldberger and Colleagues, *PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals* , *Circulation*, 101(23): e215-e220, 2000.
- [15] Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology, *Circulation*, 93: 1043, 1996.
- [16] N.R. Lomb, "Least-squares frequency analysis of unequally spaced data" , *Astrophys Space Sci*, 39: 447- 462, 1976.
- [17] R. Quian Quiraga, O.A. Rosso, E. Başar, and M. Schurmann, "Wavelet entropy in event-related potentials: a new method shows ordering of EEG oscillations" , *Biol Cybern*, 84(4): 291-299, 2001.

## Nesne Görüntülerinden 3D Model İnşası İçin Etkin F-matrisi Hesaplanma Yöntemleri

Abdullah Erhan AKKAYA<sup>1</sup> Muhammed Fatih TALU<sup>2</sup>

<sup>1,2</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
İnönü Üniversitesi, MALATYA

abdullahakkaya@gmail.com fatihtalu@gmail.com

### Özet

*Epipolar geometri, farklı iki açıdan çekilmiş görüntü çiftleri arasındaki geometrik ilişkiyi tanımlamaktadır. Bunun için iki görüntüdeki benzer noktaların yakalanması, eşleştirilmesi ve epipolar geometriyi temsil eden temel matrisin (F – fundamental matrix) hesaplanması gerekmektedir. F matrisinin hesaplanması, sonraki aşamalar (3D modelleme, hareket segmentasyonu, stereo görme, kamera kalibrasyonu) için hayati derecede önem arz etmektedir. Bu çalışmada, farklı konseptlerdeki etkin F-matrisi hesaplama yöntemleri (LS, LMedS ve CFNS) incelenmiş, algoritmaların zaman ve doğruluk kıstaslarına göre karşılaştırmaları yapılmıştır. Elde edilen sayısal sonuçlar tablolar halinde sunulmuştur.*

### 1. Giriş

Temel matris (F – fundamental matrix), bir videonun ardışıl iki imgesinde bulunan önemli noktalar arasındaki ilişkiyi tanımlar. Hareket segmentasyonu, 3D model oluşturma, kamera kalibrasyonu, stereo görme gibi birçok uygulama alanında F matrisi kullanılmaktadır. F matrisinin etkin ve doğru olarak hesaplanması, çoklu görüntü analizinde önemli bir problemdir [1]. Analizi yapılacak görüntü sayısı iki olduğunda, bu iki görüntü arasında oluşan, sahne yapısından bağımsız, sadece kameranın içyapısı ile göreceli pozisyona bağlı olarak oluşan izdüşümsel geometriye *epipolar geometri* adı verilmektedir [1]. F matrisi epipolar geometriyi temsil eden temel matristir [1]. Aynı sahnenin birbirine yakın olan farklı açılardan çekilen imgelerinin içerisinde barındırdığı tüm geometrik bilgi F matrisi ile hesaplanmaktadır. Sahne üzerindeki X noktasının birinci ve ikinci görüntüdeki eş noktaları  $x$  ve  $x'$  ile temsil edilirse, F matrisi kullanılarak, bu iki eş nokta arasında bir

denklem kurulabilir (1). F matrisi 3x3 boyutunda rankı 2 olan bir matristir [2].

$$x'^T F x = 0 \quad (1)$$

İki imgedeki nokta eşleştirmelerinden yola çıkarak epipolar geometriyi hesaplamaya çalışan ilk metod Hesse tarafından 1863 yılında ortaya atılmış, aynı yöntem Sturm tarafından 1869 yılında tekrar düzenlenmiştir [3]. Sturm tarafından düzenlenen algoritma teoride iyi olarak çalışan fakat gerçek ortamda gürültüden çok fazla etkilenen ve 7 eş nokta ile epipolar dönüşümü hesaplayan bir yöntemdir [3]. 1981 yılında Longuet-Higgins'in [4] çalışmaları ile hız kazanan F matrisini hesaplama metodlarına zamanla rank-2 şartını sağlamayı hedefleyen, doğrusal, iteratif ve sağlam gruplara ayrılan [5–7] metodlar eklenmiştir.

Doğrusal metodlar F matris hesaplama zamanını oldukça kısa sürede gerçekleştirmesine rağmen optimal olmayan çözümler üretmektedir. Bu nedenle aranan optimal çözümün hızlandırılması için iteratif ve sağlam metodlar ile işbirliği içinde kullanılmaktadırlar [8]. Doğrusal metodlardan bazıları, yedi nokta (7 points) metodu [5], en küçük kareler (least squares- LS) yöntemi [2], ortogonal en küçük kareler yöntemi [7], rank-2 [5] metodlarıdır. İteratif metodlar, doğrusal metodların özyinelemesi sonucu oluşturulmuş metodlardır. Oldukça iyi sonuçlar vermekle beraber doğrusal metodlara göre daha fazla zaman almaktadırlar. İteratif metodlara, Newton Raphson veya Levenberg–Marquardt [9], gradyant tabanlı metod [1], FNS (Fundamental Numerical Scheme), CFNS (Constrained FNS) [10] ve iteratif doğrusal metod [5] örnek olarak verilebilir. Sağlam metodlar, hatalı eşleşen noktaları elemeye çalıştıktan sonra epipolar merkeze olan uzaklığı minimize etmeye dayalı, doğrusal yöntemlerin tekrarından

oluşan yöntemlerdir. Doğrusal yöntemlerden daha fazla zaman almakta fakat sağlam ve etkin sonuçlar vermektedirler. M-Estimator [1], L-Meds [5], RANSAC [7], MLESAC [11] ve MAPSAC [12] sağlam metotlardandır. Hem iteratif hem de sağlam metotlarda tekrarlı olarak kullanımından dolayı, doğrusal yöntemler  $F$  matris hesabında temel yöntemdir, diyebiliriz.


$F$  matrisini hesaplamadan önce eş nokta koordinatları normalize edilmektedir. Hartley normalizasyon [13] metodu başarıyı yüksek olan ve sık kullanılan bir metottur.  $F$  temel matrisi hesaplandıktan sonra epipolar merkeze olan Sampson [14] uzaklığı minimum olan yöntem, başarıyı en yüksek olan yöntem kabul edilmektedir.

Bu çalışmada, altı görüntü çifti üzerinde, doğrusal yöntemlerden LS, iteratif yöntemlerden CFNS ve sağlam yöntemlerden LMedS kullanılarak  $F$  matrisi hesaplanmış, normalize edilen ve edilmeyen sonuçlar karşılaştırılarak verilen yöntemler içerisinde hız ve doğruluk bakımından uygun olanı, saptanmaya çalışılmıştır.

## 2. Epipolar Geometri

Epipolar geometri, bir sahnenin veya objenin iki farklı görüntüsü arasındaki geometrik ilişkiyi kurmaktadır. Şekil 1'de  $C$  ve  $C'$  kamera merkezleridir. Sahneye ait  $X$  noktasının birinci ve ikinci görüntüye düşen imge noktaları sırasıyla  $x = (x, y, 1)^T$  ve  $x' = (x', y', 1)^T$  homojen vektörleri ile temsil edilmektedir. Bu iki eş nokta arasındaki ilişkiyi  $F$  matrisi kurmaktadır (1). Kamera merkezlerinden başlayarak  $x$  ve  $x'$  noktalarından geçecek şekilde ışınlar çizildiğinde bu ışınlar  $X$  noktasında kesişmektedir.  $X$ ,  $x$ ,  $x'$ ,  $C$  ve  $C'$  noktalarını içerecek şekilde oluşturulan düzleme *epipolar düzlem* adı verilmektedir [1]. İki kamera merkezi *taban çizgisi* tarafından birleştirilmektedir. Kamera merkezlerini birleştiren taban çizgisi ile görüntü düzlemlerinin kesiştiği noktalar *epipol* ( $e$ ,  $e'$ ) adını almaktadır [15]. Epipol ve  $F$  matrisinin çarpımı (2) sıfıra eşittir [1]. Epipol noktalardan imge noktasından geçecek şekilde çizilen doğruya ise *epipolar çizgi* denilmektedir [15]. Epipolar düzlem ile görüntü düzleminin kesişimi sonucu da epipolar çizgiler oluşmaktadır. Eş noktalar eş epipolar çizgiler üzerinde yer almaktadırlar. Bu nedenle  $x$  noktasının eşdeğer noktası olan  $x'$  noktası,  $x$  noktası kullanılarak hesaplanan  $l'$  epipolar çizgisi üzerinde (3) olmalıdır [1].  $l'$ ,  $x'$  noktasının aranacağı epipolar çizgidir. Bu

nedenle  $x'$  noktası, ikinci görüntünün tamamı içerisinde değil, sadece  $l'$  epipolar çizgisi üzerinde aranacağından pencere boyutu düşürülmekte ve arama maliyeti azaltılmaktadır.



Şekil 1. Epipolar geometri.

$$Fe = 0, F^T e' = 0 \quad (2)$$

$$l' = Fx, l = F^T x' \quad (3)$$

## 3. F Matrisi Hesaplama

Bu bölümde, farklı konseptlerde yer alan  $F$  matrisi hesaplama yöntemlerinden bahsedilen yöntemler içerisinde en iyi sonuç verenler seçilerek, bu yöntemlerin kıyaslamalı bir sunumu yapılmaktadır. Seçilen yöntemler doğrusal LS, iteratif CFNS ve sağlam LMedS yöntemleridir ve üç yönteminde ilk aşaması görüntü normalizasyonudur.

### 3.1. Normalizasyon Aşaması

Aynı nesneye ait farklı görüntülerin farklı çözünürlüklerde olması, verinin normalize edilmesini gerektirmektedir. Normalizasyon işlemi ölçekleme ve dönüşüm aşamalarından oluşmaktadır [6]. Birinci ve ikinci görüntü düzlemine düşen  $X$  noktasına ait imge noktaları sırasıyla  $x = (x, y, 1)^T$  ve  $x' = (x', y', 1)^T$  olsun.  $T$  ve  $T'$  dönüşüm matrisleri kullanılarak normalize edilmiş noktalar elde edilmektedir (4), (5).

$$\hat{x}_i = Tx_i \quad (4)$$

$$\hat{x}'_i = T'x'_i \quad (5)$$

Daha sonra normalize edilmiş noktalar kullanılarak, farklı metotlarla  $\hat{F}$  matrisi hesaplandıktan sonra,  $F$  matrisinin gerçek değeri:

$$F = T^T \hat{F} T' \quad (6)$$

formülü ile hesaplanmaktadır.

Normalizasyon sürecinde her bir imgenin normalizasyonu diğer imgelerden bağımsız olarak gerçekleştirilmektedir.

Hartley Normalizasyon [13] metodu çoğu uygulamada kullanılmaktadır. Bu metotta ilk olarak imgeye ait tüm eş noktaların merkezi olan Centroid  $(C_x, C_y)$  noktanın koordinatı hesaplanmaktadır. Merkez nokta koordinatı hesaplandıktan sonra, her bir eş noktanın bu merkez noktaya olan  $dx_i$ ,  $dy_i$  uzaklıkları ile  $de_i$  öklid uzaklıkları hesaplanmaktadır. Öklid uzaklıklarının ortalaması  $d_{mean}$  hesaplandıktan sonra, bu noktaların merkeze olan  $dx_i$  ve  $dy_i$  uzaklıkları ayrı ayrı  $\sqrt{2}$  ile çarpılarak  $d_{mean}$  değerine bölünmekte ve normalize edilmiş  $hx_i$  ve  $hy_i$  değerleri elde edilmektedir.  $n$ , toplam eş nokta sayısını temsil edecek şekilde, Hartley normalizasyon adımları aşağıdaki şekilde formüle edilmektedir:

- i.  $C_x = (\sum_{i=1}^n x_i)/n$ ,  $C_y = (\sum_{i=1}^n y_i)/n$
- ii.  $dx_i = x_i - C_x$ ,  $dy_i = y_i - C_y$
- iii.  $de_i = \sqrt{(dx_i)^2 + (dy_i)^2}$
- iv.  $d_{mean} = (\sum_{i=1}^n de_i)/n$
- v.  $hx_i = dx_i \sqrt{2}/d_{mean}$ ,  $hy_i = dy_i \sqrt{2}/d_{mean}$

Tüm bu adımlar gerçekleştirildikten sonra normalize edilmiş noktaların orijine olan öklid uzaklıkları ortalaması  $\sqrt{2}$  olmaktadır.

### 3.2. Epipolar Düzleminin Belirlenme Aşaması

Normalize edilmiş nokta koordinatları hesaplandıktan sonra denklem (1) kullanılarak 9 bilinmeyenli  $F$  matrisine ait Epipolar denklemi:

$$u_i^T f = 0 \quad (7)$$

$$u_i = [x_i x'_i, y_i x'_i, x'_i, x_i y'_i, y_i y'_i, y'_i, x_i, y_i, 1]^T \quad (8)$$

$$f = [F_{11}, F_{12}, F_{13}, F_{21}, F_{22}, F_{23}, F_{31}, F_{32}, F_{33}]^T \quad (9)$$

şeklinde ifade edilebilir. Eğer eşleşen  $n$  nokta varsa denklem (7), (11) nolu denkleme dönüşmektedir:

$$U = [u_1, \dots, u_n]^T \quad (10)$$

$$U f = 0 \quad (11)$$

### 3.3. Doğrusal LS Yöntemi

$F$  matrisini hesaplamak için geliştirilen doğrusal metotlardan ortogonal en küçük kareler yöntemi, en az sekiz eş nokta üzerinden işlem yapmaktadır. Denklem (10)  $U$  matrisi hesaplandıktan sonra  $U^T U$  çarpımına ait en küçük öz değerli vektör hesabını göstermektedir. Hesaplanan en küçük öz değerli vektör  $F$  matrisini vermektedir.

$$[V, D] = eig(U^T U) \quad (12)$$

### 3.4. İteratif CFNS Yöntemi

İteratif FNS metodu Newton-Raphson minimizasyon yöntemini kullanmaktadır. FNS yönteminin iyileştirilmiş hali olan CFNS metodu ise minimizasyon fonksiyonundan elde edilen yardımcı kısıtın FNS metoduna eklenmesi ile oluşturulmaktadır.

### 3.5. Sağlam LMedS Yöntemi

Sağlam LMedS metodunda ise epipolar çizgiye olan uzaklıkların kareleri hesaplanarak bu uzaklık değerlerinin en küçük medyan değeri aranmaktadır. LMedS yönteminde hatalı olan nokta eşleştirmeleri elenerek  $F$  matrisi daha etkin bir şekilde hesaplanmaktadır [6].

### 3.6. Kıyaslama Ölçeği

Yöntemlerden hangisinin daha etkin olarak çalıştığının saptanabilmesi için epipolar çizgiye olan ortalama uzaklık hatasının hesaplanması gerekmektedir. En düşük ortalama uzaklığa sahip olan

yöntem en iyi sonucu vermektedir. Sampson [14] uzaklığı sık kullanılan hata hesaplama yöntemlerindedir. Her bir nokta çiftinin epipolar çizgiye olan uzaklığı

$$r = x'^T F x \quad (13)$$

olacaktır.  $r$  değerinin giderek sıfıra yaklaşması matrisin daha doğru hesaplandığının göstergesidir. Fakat  $r$  değerinin tek başına geometrik bir anlamı yoktur.  $F$  temel matrisi denklem (14) ile ifade edilirse

$$F = \begin{pmatrix} f_1 & f_2 & f_3 \\ f_4 & f_5 & f_6 \\ f_7 & f_8 & f_9 \end{pmatrix} \quad (14)$$

$$r_x = f_1 x' + f_4 y' + f_7, r_y = f_2 x' + f_5 y' + f_8 \quad (15)$$

$$r_{x'} = f_1 x + f_2 y + f_3, r_{y'} = f_4 x + f_5 y + f_6 \quad (16)$$

olmak üzere her bir eş nokta çifti için Sampson uzaklığı

$$d_s = r \frac{1}{\sqrt{r}} = r \left( \frac{1}{r_x^2 + r_y^2 + r_{x'}^2 + r_{y'}^2} \right)^{\frac{1}{2}} \quad (17)$$

formülü ile hesaplanmaktadır. Tüm eş noktaların Sampson uzaklıklarının aritmetik ortalaması alınarak her bir metodun etkinliği hesaplanmaktadır.

#### 4. Simülasyon Sonuçları

Simülasyon sonuçları, Matlab programı i7-4770 3.4GHz işlemci ve 8 GB belleğe sahip bilgisayar kullanılarak elde edilmiştir. Görüntü çiftleri üzerinde 100 adet eş nokta saptanmaya çalışılmıştır. Eş noktalar Lowe [16] tarafından bulunan SIFT algoritmasının A.Vedaldi [17] tarafından geliştirilen Matlab programı kullanılarak bulunmuştur. Bulunan eş noktalar Hartley [13] metodu ile normalize edilmiştir. Elde edilen eş noktalara LS, LMedS ve CFNS algoritmaları uygulanarak  $F$  matrisi hesaplanmıştır.

Tablo 1 Hartley ile normalize edilmiş, Tablo 2 ise normalize edilmemiş eş noktalara uygulanan metotlar sonucunda elde edilen noktalarla epipolar çizgiler arasındaki Sampson uzaklıklarının ortalamasını göstermektedir. Kullanılan 6 imge çifti için en iyi değer LMedS yöntemine ait olduğu görülmektedir.

LMedS yöntemi, hatalı eş nokta eşleştirmelerini eleyerek (outliers removing), doğru olarak eşleşen

nokta çiftleri üzerinden işlem yapmaktadır. Bundan dolayı, yanlış eşleştirmeden kaynaklanabilecek hesaplama hatalarının önüne geçmekte ve en iyi sonucu vermektedir. Hartley normalizasyonu yapılmış verilerin Sampson uzaklık değerlerinin daha küçük olduğu gözlemlenmiştir. Ayrıca normalizasyon yapılan ve yapılmayan imgeler üzerinde CFNS metodunun aynı sonuçları verdiği gözlemlenmiştir.

Tablo 3 uygulanan metotların Hartley normalizasyonu ve Sampson uzaklığı kullanılarak  $F$  matrisini hesaplamak için ne kadar zaman harcadığını göstermektedir. Eğer uygulama offline olarak yapılacaksa ve zaman kısıtı yoksa LMedS metodu kullanılmalıdır. Uygulama online ise kullanılacak eş nokta sayısının artması durumunda harcanan zaman da artacağından LMedS metodu kullanımından kaçınılmalıdır.


#### 5. Sonuç

Bu çalışmada ardışıl video imgeleri arasındaki hareketin anlamlandırılmasında önemli aşamalarından biri olan  $F$  matrisinin hesaplanması incelenmiştir. Birçok farklı konsepte sahip yöntemlerin avantaj ve dezavantajları sunulmuştur. Buna göre 6 farklı görüntü çifti üzerinde  $F$  matrisinin hesabı gerçekleştirilmiş ve bunun için 3 farklı yöntem kullanılmıştır. Sonuç olarak,  $F$  matrisinin hesabı için LS yönteminin kullanılması düşük maliyet sağlamak fakat yüksek hataya sebep olmaktadır. Bunun aksine, LMedS yöntemi yavaş fakat yüksek doğruluğa sahiptir. Offline uygulamalar için LMedS yönteminin tercihi ideal bir çözüm sunmaktadır.

#### 6. Gelecek Çalışmalar

Gerçek 3D yapıların veya nesnelerin bilgisayar ortamında yeniden modellenmesine SFM (structure of motion) adı verilmektedir. Bundan sonraki çalışmada ise iki anahtar imgeye adım adım yeni bir imge eklenerek imge kümesi oluşturulması sonucu oluşan üçlü (trifocal) ve dördü (quadrifocal) yapılar kullanılarak 3D nesneye ait izdüşümsel inşa aşamasına geçilmesi planlanmaktadır.





Şekil 2.  $F$  matrisinin hesaplanacağı eş noktaları bulunmuş görüntüler. Soldan sağa ve yukarıdan aşağıya doğru: Pisa Katedrali (imge 1); Trevi Çeşmesi (imge 2); Kasuga feneri (imge 3); Heykel (imge 4); Emanuele Anıtı (imge 5); Mide laparoskopisi (imge 6).

Tablo 1. Sampson uzaklıkları (Hartley normalizasyon).

Yöntem	İmge 1	İmge 2	İmge 3	İmge 4	İmge 5	İmge 6
LS	6.257853	23.140691	2.267595	4.056772	3.527261	7.720820
LMedS	<b>0.248110</b>	<b>0.446424</b>	<b>0.151231</b>	<b>0.235827</b>	<b>0.569709</b>	<b>0.363649</b>
CFNS	4.736782	28.405349	1.425712	3.608114	2.782481	17.581394

Tablo 2. Sampson uzaklıkları (Normalizasyon yok).

Yöntem	Hata Büyüklüğü					
	İmge 1	İmge 2	İmge 3	İmge 4	İmge 5	İmge 6
LS	23.787348	44.382813	8.023689	7.384078	6.059624	20.633057
LMedS	<b>0.321937</b>	<b>0.468686</b>	<b>0.275656</b>	<b>0.290252</b>	<b>0.190641</b>	<b>0.231836</b>
CFNS	4.736782	28.405349	1.425712	3.608114	2.782481	17.581394

Tablo 3. Harcanan süre (sn).

Yöntem	İmge 1	İmge 2	İmge 3	İmge 4	İmge 5	İmge 6
LS	0.008103	0.008432	0.008433	0.012126	0.008252	0.008248
LMedS	<b>0.164673</b>	<b>0.183504</b>	<b>0.162516</b>	<b>0.150408</b>	<b>0.174300</b>	<b>0.165895</b>
CFNS	0.091506	0.090935	0.103341	0.090556	0.084295	0.091899



## 7. Kaynaklar

- [1] R. Hartley and A. Zisserman, *Multiple view geometry in computer vision*. Cambridge, UK; New York: Cambridge University Press, 2003.
- [2] Q.-T. Luong and O. D. Faugeras, "The fundamental matrix: Theory, algorithms, and stability analysis," *Int. J. Comput. Vis.*, vol. 17, no. 1, pp. 43–75, Jan. 1996.
- [3] B. Boufama and R. Mohr, "Epipole and fundamental matrix estimation using virtual parallax," in *Fifth International Conference on Computer Vision, 1995. Proceedings, 1995*, pp. 1030–1036.
- [4] H. C. Longuet-Higgins, "A computer algorithm for reconstructing a scene from two projections," *Nature*, vol. 293, no. 5828, pp. 133–135, Sep. 1981.
- [5] Z. Zhang, "Determining the Epipolar Geometry and its Uncertainty: A Review," *Int. J. Comput. Vis.*, vol. 27, no. 2, pp. 161–195, Mar. 1998.
- [6] X. Armangué and J. Salvi, "Overall view regarding fundamental matrix estimation," *Image Vis. Comput.*, vol. 21, no. 2, pp. 205–220, Feb. 2003.
- [7] P. H. S. Torr and D. W. Murray, "The development and comparison of robust methods for estimating the fundamental matrix," *Int. J. Comput. Vis.*, vol. 24, pp. 271–300, 1997.
- [8] Y. Zheng, S. Sugimoto, and M. Okutomi, "A branch and contract algorithm for globally optimal fundamental matrix estimation," in *2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2011*, pp. 2953–2960.
- [9] Salvi, "An approach to coded structured light to obtain three dimensional information," PhD Thesis, Universitat de Girona, Departament d'Electrònica, Informàtica i Automàtica, 1997.
- [10] W. Chojnacki, M. J. Brooks, A. van den Hengel, and D. Gawley, "A new constrained parameter estimator for computer vision applications," *Image Vis. Comput.*, vol. 22, no. 2, pp. 85–91, Feb. 2004.
- [11] P. H. S. Torr and A. Zisserman, "MLESAC: A New Robust Estimator with Application to Estimating Image Geometry," *Comput. Vis. Image Underst.*, vol. 78, no. 1, pp. 138–156, Apr. 2000.
- [12] P. H. S. Torr, "Bayesian Model Estimation and Selection for Epipolar Geometry and Generic Manifold Fitting," *Int. J. Comput. Vis.*, vol. 50, no. 1, pp. 35–61, Oct. 2002.
- [13] R. I. Hartley, "In defence of the 8-point algorithm," in *Fifth International Conference on Computer Vision, 1995. Proceedings, 1995*, pp. 1064–1070.
- [14] P. D. Sampson, "Fitting conic sections to 'very scattered' data: An iterative refinement of the bookstein algorithm," *Comput. Graph. Image Process.*, vol. 18, no. 1, pp. 97–108, Jan. 1982.
- [15] Y. Li, S. Velipasalar, and M. C. Gursoy, "An improved evolutionary algorithm for fundamental matrix estimation," in *2013 10th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), 2013*, pp. 226–231.
- [16] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," *Int. J. Comput. Vis.*, vol. 60, no. 2, pp. 91–110, Nov. 2004.
- [17] A. Vedaldi, *SIFT for MATLAB*. University of California, 2006.

## Güç Sistemleri Arıza Tespitinde Sezgisel Bir Yaklaşım: Renkli Petri Ağları

Nihat PAMUK

Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ)  
5. İletim Tesis ve İşletme Grup Müdürlüğü  
Orhangazi Cad. No:74, 54100, Maltepe, SAKARYA

Email: nihatpamuk@gmail.com

### Özet

*Bu çalışmada, güç sistemlerindeki transformatör merkezlerinin arıza karakteristikleri, uzman sistemlerden daha başarılı sonuçlar veren sezgisel ve matematiksel bir model olan Renkli Petri Ağları (RPA) kullanılarak elde edilmiştir. Benzetim aşamasında Platform Independent Petri Net Editor 2 (PIPE2) petri ağı yazılımı kullanılmıştır. RPA paralel işlem yapması nedeniyle, daha büyük ve daha karmaşık güç sistemlerinde rahatlıkla uygulanabilmektedir. Güç sistemindeki arızalı bölgelerin önceden analiz edilmesi, trafo merkezlerinde çalışan operatörün arızaya müdahalesini hızlandırmakta, arızalı bölgenin sistemden hızla izole edilmesine neden olmakta ve sistem güvenilirliğini arttırmaktadır. Bu çalışma ile güç sistemindeki muhtemel arıza bölgelerinin güvenilirlik derecesi değerleri önceden analiz edilerek personel müdahalesinin en aza indirgenmesi amaçlanmıştır.*

### 1. Giriş

Elektrik enerjisi, bir ülkenin sosyal ve ekonomik olarak kalkınmasında en önemli destek unsurlarından birisidir [1]. Farklı enerji çeşitlerinin kullanılması, gelişen ülkelerin sosyal ve ekonomik alanda kalkınmasında büyük katkı sağlamıştır. Bu ülkeler gelişmişliklerini, kaynaklarını verimli ve doğru kullanarak ürettikleri bol ve ucuz elektrik enerjisinden faydalanmalarına da borçludurlar. Üretim, iletim ve dağıtım tesislerinin kurulması, işletilmesi, kumandası, izlenmesi ve kontrol edilmesindeki kolaylıkların yanında temiz oluşu ve istenen enerji şekline istenilen yerde, istenilen miktarda dönüştürülebilir olması nedeniyle elektrik enerjisi her zaman tercih edilir olmuştur ve rahatlıkla söylenebilir ki gelecekte de tercih edilir olacaktır. Bu özelliklerinin yanında elektrik enerjisinden faydalanmak için geliştirilen

elektrikli makine, alet ve cihazların ucuz, işletilmelerinin kolay ve pratik olması da elektrik enerjisinin önemini bir kat daha artırmıştır.

Ülkemizdeki elektrik enerjisi ihtiyacı kömür, petrol, doğal gaz, hidrolik ve nükleer enerji kaynaklarından, az miktarlarda ise rüzgâr, atıklar, güneş ve denizlerdeki dalgalardan yararlanılarak karşılanmaktadır [2]. Fakat ülkemizin coğrafi yapısı ve enerji kaynaklarının konumu itibarı ile üretilen elektrik enerjisi, enerji iletim hatları ile uzak mesafelere taşınmaktadır [3]. Bu sebeple elektrik iletim sistemlerinin, enerji kesintisinin ve kısıtlamasının olmayacağı şekilde planlanması ve işletilmesi gerekmektedir. Elektrik enerjisi iletiminin devamlılığı, elektrik tesislerinin arızalardan etkilenme oranının azaltılması, yedek üretim kaynaklarının tesisi ve aynı yükün alternatif noktalardan beslenmesi gibi hususların geliştirilmesi ile sağlanmaktadır.

Güç sistemlerinde istasyon, transformatör, enerji iletim hattı, kesici ve benzeri elemanların hızla çoğalması sistemin karmaşasını arttırmakta ve tüm sistemin bir merkezden kontrolünü gerektirmektedir. Böyle bir merkeze ihtiyaç duyulmasının güvenilirlik ve ekonomik üretim yapma gibi iki önemli nedeni vardır [4]. Kontrol merkezi, hem normal çalışma hem de acil çalışma durumlarında sistem elemanlarından gelen durum bilgilerini inceleyerek değerlendirme yapar. Bu bilgiler; uç birimlerden elde edilen akım, gerilim ve güç bilgileri olup, uç birimler tarafından algılanır ve sayısal değerlere dönüştürülür. Daha sonra modemler aracılığı ile kontrol merkezine iletilir. Kontrol merkezi gelen verileri analiz eder [5].

Normal durumda güç sisteminde meydana gelen hataların belirlenmesi ve operatörün uyarılması kullanılan kontrol yazılımı ile sağlanır [6]. Acil durumlarda ise kontrol merkezine ulaşan veriler operatör tarafından analiz edilir ve hata belirlenerek giderilmeye çalışılır. Güç sistemlerindeki merkezi



Basit bir PA yapısı beş bileşenden oluşan bir kümedir. Bu bileşenler;  $PA = (P, T, Pre, Post, M_0)$ 'dir. Burada:

- $P: \{p_1, p_2, \dots, p_n\}$  sonlu sayıda boş olmayan konum kümesini ifade etmektedir.
- $T: \{t_1, t_2, \dots, t_n\}$  sonlu sayıda boş olmayan geçişler kümesini ifade etmektedir. (N negatif olmayan tamsayılar kümesini göstermektedir).
- $Pre: (P \times T) \rightarrow N$  yerlerden geçişlere olan yönlendirilmiş sıradan okları tanımlayan giriş fonksiyonudur.
- $Post: (T \times P) \rightarrow N$  geçişlerden yerlere olan yönlendirilmiş sıradan okları tanımlayan çıkış fonksiyonudur.
- $M_0: P \rightarrow N$  Başlangıç işaretlemesini ifade etmektedir [12].

### 3.1. Bulanık petri ağları (BPA)

Karmaşık sistemlerin modellenmesinde ve analizinde genellikle iki çeşit belirsizlik bulunmaktadır. Bu belirsizlikler rassallık ve bulanıklıktır. Rassal modelleme stokastik değişkenliği ifade etmektedir. Bulanık modelleme ise kesin olmayan bilgiden kaynaklı ölçümleri ifade etmektedir. Sistem modellemede karşılaşılan kesin olmama durumunun olası kaynakları; sistem girdi ve çıktıları ile kesin olmayan iç operasyonlardır. BPA dört bileşenden oluşmaktadır [13]. Bu bileşenler:


- **Bulanık Jeton:** Bir konumuna ait olan veya olmayan standart PA'daki jetonun genelleşmesidir. Bu şekilde bir jeton gerçeklik değeri olarak 0 veya 1'e sahip bir eleman olarak görülebilir. Gerçeklik değerinin  $[0,1]$  birim aralığında bir değer almasına izin verilerek bulanık jeton oluşturulur.
- **Bulanık Konum:** Kendisiyle ilişkilendirilmiş bir özelliğe sahiptir. Bu konumda yer alan bir jeton bu özelliğe sahip olma derecesi veya bu konuma ait olması ile karakterize edilir. Bu konumda hız düşüktür.
- **Bulanık Geçiş:** Bulanık bir geçiş eğer - o zaman gibi bulanık tabanlı bir kural kullanmakta ve bulanık çıkarım algoritmaları ile gerçeklik değerleri elde edilmektedir.
- **Bulanık Ok:** Bulanık ok, girdi jetonunun değerini belirtmektedir. Eğer jeton değeri karşılamıyorsa, jeton ile değer arasındaki mesafenin ölçümü gerekir. Eğer mesafe önceden tespit edilen maksimum değerden büyük ise geçiş ateşlenemez. Bu durumda minimum mesafeli jeton seçilmektedir.

### 3.2. Renkli petri ağları (RPA)

RPA, jetonlara ve geçişlere renk bilgisi atanarak klasik PA ile tanımlanması daha karmaşık olan sistemleri daha basit ve anlaşılır bir biçimde modellemek amacıyla geliştirilmiştir. Birbirinin benzeri iki işi yapan bir PA, RPA ile modellendiği takdirde sistemdeki geçiş ve konum kümesi sayıları yarıya düşmektedir. RPA yapısı yedi bileşenden oluşan bir kümedir. Bu bileşenler;  $RPA = (P, T, N, O, C, \Omega, M_0)$ 'dir. Burada:

- $P: \{p_1, p_2, \dots, p_n\}$  sonlu sayıdaki konum kümesini,
- $T: \{t_1, t_2, \dots, t_n\}$  sonlu sayıdaki geçişler kümesini,
- $N: (P \times T) \rightarrow N$  yerlerden geçişlere olan yönlendirilmiş sıradan okları tanımlayan giriş fonksiyonunu,
- $O: (T \times P) \rightarrow N$  geçişlerden yerlere olan yönlendirilmiş sıradan okları tanımlayan çıkış fonksiyonunu,
- $C: \text{Renk kümesini, } C(P) \rightarrow \text{Konumların renk kümesini, } C(T) \rightarrow \text{Geçişlerin renk kümesini,}$
- $\Omega: C(P) \cup C(T) \rightarrow \text{Sonlu sayıda renk kümesini,}$
- $M_0: P \rightarrow N$  Başlangıç işaretlemesini ifade etmektedir [14].

Şekil 2'de basit bir RPA örneği gösterilmiştir.



Şekil 2. RPA örneği

Şekil 2 incelenecek olursa;

$$\begin{aligned}
 P &= \{P_1, P_2, P_3\}, \\
 T &= \{T_1, T_2, T_3\}, \\
 N &= \{(P_1, T_2, a) (P_1, T_2, b) (P_1, T_2, c) (P_2, T_3, a) (P_2, T_3, b) \\
 &\quad (P_3, T_1, a) (P_3, T_1, b) (P_3, T_2, a) (P_3, T_2, b) (P_3, T_2, c)\}, \\
 O &= \{(T_1, P_1, a) (T_1, P_1, b) (T_2, P_2, a) (T_2, P_2, b) (T_2, P_2, c) \\
 &\quad (T_2, P_3, a) (T_2, P_3, b) (T_2, P_3, c) (T_3, P_3, a) (T_3, P_3, b)\}, \\
 W_1 &= (P_1, T_2, a, c_1) = 0, W_1 = (P_1, T_2, a, c_2) = 2, \\
 W_1 &= (P_1, T_2, a, c_3) = 1, W_1 = (P_1, T_2, b, c_1) = 0,
 \end{aligned}$$

$$\begin{aligned} W_2 &= (P_1, T_2, b, c_2) = 1, W_2 = (P_1, T_2, b, c_3) = 2, \\ W_2 &= (T_2, P_2, a, c_1) = 1, W_2 = (T_2, P_2, a, c_2) = 0, \\ W_3 &= (T_2, P_2, a, c_3) = 1, W_3 = (T_2, P_2, b, c_1) = 0, \\ W_3 &= (T_2, P_2, b, c_2) = 2, W_3 = (T_2, P_2, b, c_3) = 0, \end{aligned}$$

şeklinde yazılır. Sistemin ilk işaretlemesi iki boyutlu matristir. Satırları konum kümelerini belirtirken, sütunları ise jeton renklerini belirtmektedir. Değerleri ise o konumdaki jeton sayısını vermektedir.  $P_1$  konumunda 2 tane  $c_2$  renkli jeton (kırmızı) ve 3 tane  $c_3$  renkli jeton (mavi) bulunmaktadır. Bu durumda;  $M(P_1, c_1) = 0$ ,  $M(P_1, c_2) = 2$ ,  $M(P_1, c_3) = 3$  olduğundan  $M_0$  işaretleme matrisinin ilk satırı  $[0 \ 2 \ 3]$  şeklinde olur. İlk işaretleme matrisi denklem 1'deki gibi olur.

$$M_0 = \begin{pmatrix} 0 & 2 & 3 \\ 9 & 9 & 1 \\ 7 & 5 & 6 \end{pmatrix} \quad (1)$$

RPA' da geçişin izinli olması klasik PA' da olduğu gibidir. Geçiş durumunun herhangi bir geçiş rengi için izinli olabilmesi için o geçiş rengi için tanımlanmış geçiş koşulunu sağlayacak kadar uygun renkteki jetonların giriş yerlerinde bulunması gereklidir. RPA örneğinde ilk işaretlemeye göre  $T_2$  geçişi a,b,c geçiş renkleri için ateşlenebilir,  $T_3$  geçişi a,b geçiş renkleri için ateşlenebilir iken  $T_1$  geçişi  $P_3$  konumunda yeterli sayıda  $c_2$  renkli jeton olmadığı için ateşlenememektedir.  $P_1$  konumundaki jetonların hangi geçiş rengi için kullanılacağı bir problemdir. Bu problemin giderilebilmesi için geçiş renklerine de öncelik ataması yapılmaktadır. RPA incelenirken çelişki durumlarında önce geçişler arası önceliğe bakılmaktadır. Eğer geçiş durumunda kendi geçiş renkleri arasında çelişki durumu söz konusu ise, geçiş renkleri arasındaki öncelik atamasına bakılmaktadır.

### 3.3. Modelleme ve benzetim

Var olan bir sistemin ya da geliştirilen bir ürünün yapısal ve işlevsel durumlarını belirlemek amacıyla modelleme ve benzetim işlemleri yapılmaktadır. Sistemin dinamik davranışı elde edilen model benzetimi ve çeşitli durum seçenekleri ile gözlenebilmektedir. Son yıllarda çeşitli tasarımların geliştirilmesinde, otomasyon dünyası mühendis ve tasarımcıların en büyük yardımcıları haline gelmiştir. Bu amaçla tasarımın çeşitli kademelerinde kullanılmak üzere hazırlanmış değişik benzetim programları bulunmaktadır. Tasarım ve geliştirme süreçlerindeki alt süreçler sırasıyla [15];

- Sorunun tanımlanması,
- Ürün gelişimi için seçeneklerin oluşturulması,
- Seçeneklerin değerlendirilmesi ve geliştirilecek tasarıma karar verilmesi,
- Ön tasarım yapılması,
- Ayrıntılı tasarım ve dokümantasyonun sağlanması.


İkinci ve üçüncü alt süreçler, kavramsal tasarım olarak adlandırılmaktadır [16]. Kavramsal tasarım, belirtilen sorunu çözecek bir ürünün ayrıntılı hesaplara girmeden, yapısal ve işlevsel olarak ortaya konmasıdır. Seçeneklerin belirlenmesi, mühendislik yeteneği ile insan zekasına muhtaç bir aşamadır. Bu nedenle ki, tasarım sürecinin bu aşamasında fazlaca bir otomasyon sistemine ihtiyaç duyulmamaktadır.

### 4. Kısa devre arızalarının RPA ile modellenmesi ve analizi

RPA sistem modellemenin temelini oluşturmaktadır. Bir sistemin RPA modeli oluşturulurken etken ve edilgen elemanların RPA elemanlarından hangisi ile temsil edileceğine karar verilmelidir. Bu sayede geliştirilme aşamasındaki sistemlerin senkron veya asenkron olaylarında sistemin kontrolü sağlanmakta, bilgi akışının analiz ve tanımlanması için basit ve etkili metotlar geliştirilmektedir. PA, hızla gelişmiştir. Uygulama şekillerine göre RPA ve BPA gibi çeşitli tipleri ortaya çıkmıştır. PA modellemelerindeki renk; aralarında çeşitli etkileşimin olduğu ayrık olayların başlama ve bitiş durumlarını temsil etmektedir. Dört ayrı eleman üzerinde renk belirtilebilir:

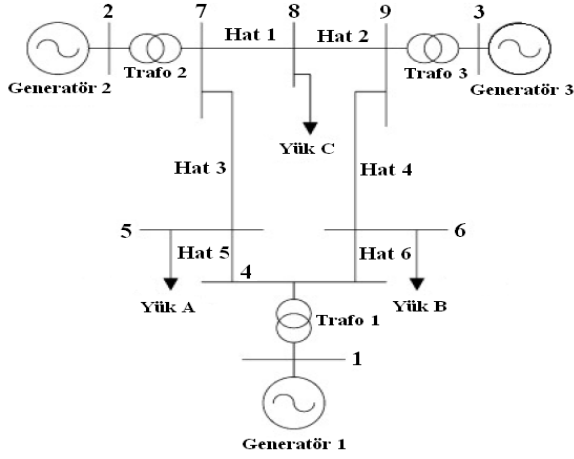
- Konum rengi
- Jeton rengi
- Geçiş rengi
- Ok rengi

Bu elemanlardan, bir tanesi ya da birkaç tanesi ortak kullanılarak sistemin RPA modeli elde edilmektedir. Jeton rengi sadece belirli geçişleri tetiklemek için kullanılmaktadır. Simetrik olmayan kısa devre arızalarında sisteme ilişkin empedansların pozitif, negatif ve sıfır bileşen değerleri kullanılmaktadır [17]. Şekil 3'de güç sistemine ait simetrik bileşen devreleri ve Thevenin eşdeğer devreleri gösterilmiştir. Şekil 3 incelendiğinde sadece doğru bileşen devresindeki kaynak geriliminin değeri bulunmaktadır. Sistemde bir kısa devre arızası meydana geldiği durumda eşdeğer devreler birbirine bağlanmaktadır. Bu bağlama biçimi oluşacak olan arıza tipine göre değişmektedir.

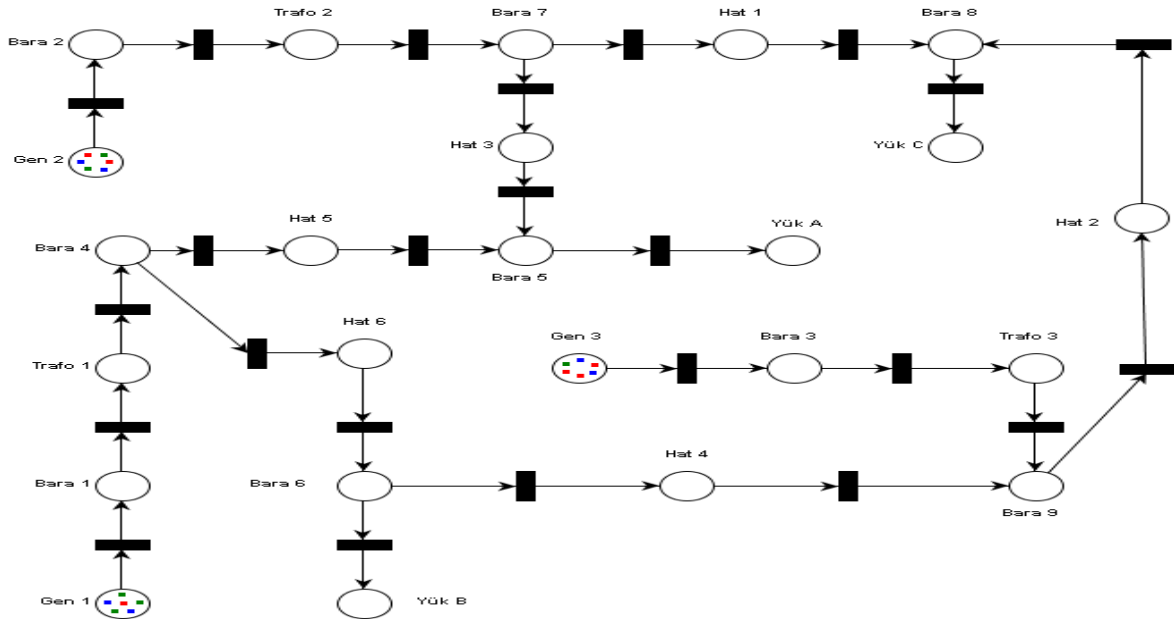


Şekil 3. Simetrik bileşenler ve Thevenin devreleri

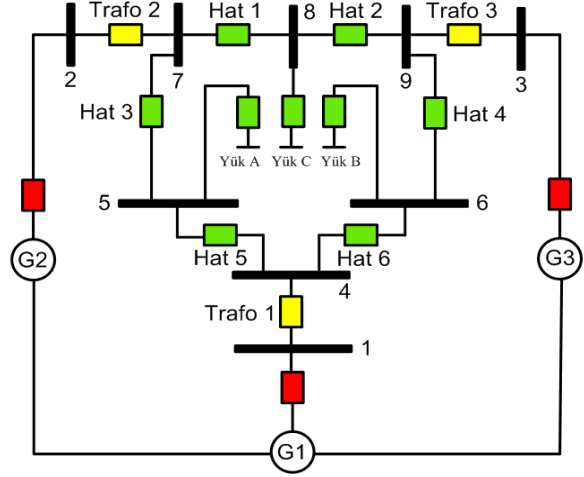
Şekil 4'de üç generatörlü, üç transformatörlü ve dokuz baralı örnek bir güç sistemi gösterilmiştir. Şekil 5'de ise dokuz baralı güç sistemine ait doğru bileşen devresi gösterilmiştir.



Şekil 4. Dokuz baralı örnek bir güç sistemi



Şekil 6. Dokuz baralı örnek güç sistemine ait doğru bileşen devresinin RPA modeli



Şekil 5. Dokuz baralı örnek güç sistemine ait doğru bileşen devresi

Güç sisteminde yer alan transformatör ve generatör gibi elektriksel teçhizatlar konumlar ile diğer durumlar ise geçişler ile gösterilmiştir. Generatörlerden çıkan oklar test tipi oklardır. Bu oklar sayesinde generatörler güç sistemini beslerken generatörlere ait durum kapasitelerinde herhangi bir değişiklik olmamaktadır. Transformatörlerin yük altında kademe değiştirme ve dönüştürme oranları ile hat kayıpları okların ağırlık renkleri ile belirlenmiştir. Şekil 6'da ise doğru bileşen devresinin RPA modeli gösterilmiştir. Sıfır ve ters bileşen devreleri de benzer şekilde modellenebilmekte, akış denklemleri renkli jetonlara aktarılarak kısa devre arıza hesaplamaları yapılabilmektedir.

## 5. Sonuçlar

Bu çalışmada güç sistemlerindeki kısa devre arızalarının tespit edilmesi ve oluşan kısa devre arıza tipinin belirlenmesi için güç sisteminin RPA modelinin oluşturulması amaçlanmıştır. Güç sistemlerinde üç fazlı simetrik olmayan kısa devre arıza durumlarında sisteme ait doğru bileşen devresi RPA ile modellenmiştir. Elde edilen modelin trafo merkezlerindeki operatörlere yardımcı olması amaçlanmıştır. Söz konusu model ile güç sistemlerindeki kısa devre arıza yeri tespiti daha hızlı ve kesin bir şekilde yapılabilmektedir. RPA ile modellenen sistemin çözüm kümesi sınırlı alanlar içerisinde kalmaktadır. Bu nedenle geniş çözüm uzayında hipotez testi yada örüntü tanıma gibi yöntemler ile çözüm aramaya gerek kalmamaktadır. PA'nın ikili sisteme dayalı çalışma özelliğinden dolayı sistemde oluşan belirsizlikler azalmaktadır. Daha sonraki çalışmalarda uç birimlerden alınan sinyaller PA modeline arabirim aracılığı ile uygulanarak sistemde oluşan arızaların tespiti eşzamanlı hale getirilebilir. Model daha da geliştirilerek enerji iletim hatları ve dağıtımı da modele dahil edilebilir. Bu tür oluşturulan modeller trafo merkezindeki operatörün işini kolaylaştıracak ve yol gösterici klavuz olacaktır.

## 6. Kaynaklar

- [1] Türkiye Elektrik Kurumu (TEK), Elektrik Tesislerinde Koruma ve Kontrol, Elektrik Üretim İletim Müessesesi Röle ve Ölçü Aletleri Grup Müdürlüğü, Ankara 1990.
- [2] Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ), Elektrik Piyasası Şebeke Yönetmeliği, 27418 Sayılı Resmi Gazete, 26 Kasım 2009.
- [3] B. Demirkurt, Elektrikle Enerji Taşınması, İstanbul Devlet Mühendislik Mimarlık Akademisi, 1971.
- [4] S. Massoud Amin, B.F. Wollenberg, "Toward a Smart Grid: Power Delivery for the 21<sup>st</sup> Century", IEEE Power and Energy Magazine, 2005.
- [5] C.H. Hauser, D.E. Bakken, A. Bose, "A Failure to Communicate: Next Generation Communication Requirements, Technologies and Architecture for the Electric Power Grid", IEEE Power and Energy Magazine, School of Electrical Engineering & Computer Science, Washington State University DC, USA, 2005.
- [6] J.S. Lee, M.C. Zhou, P.L. Hsu, "An Application of Petri Nets to Supervisory Control for Human Computer Interactive Systems", IEEE Transactions Industrial Electronics, vol. 52, no. 5, 2005, s. 1220-1226.
- [7] U. Arifoğlu, Güç Sistemlerinin Bilgisayar Destekli Analizi, Alfa Yayınevi, İstanbul, 2002.
- [8] Y. Saner, Güç Dağıtımı Kısa Devre Hesapları, Birsen Yayınevi, İstanbul, 2000.
- [9] N. Pamuk, "Sakarya İli Elektrik İletim Şebekesinin Matlab/Simulink Programı Kullanılarak Modellenmesi ve Analiz Edilmesi", Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, vol. 27, no. 1, 2011, s. 19-39.
- [10] C.A. Petri, Kommunikation Mit Automaten, PhD Thesis, University of Bonn, West Germany, 1962.
- [11] Z. Erden, A.M. Erkmen, A. Erden, "Kavramsal Tasarım Otomasyonu: Mekatronik Tasarımda Petri Net Uygulaması-1" Endüstri & Otomasyon Dergisi, 1998, s. 16-17.
- [12] N. Pamuk, Y. Uyaroğlu, "Modeling of Fault Diagnosis in Power Systems Using Petri Nets", Elektronika Ir Elektrotechnika, vol. 2, no. 118, 2012, s. 63-66.
- [13] N. Pamuk, Y. Uyaroğlu, "The Fault Diagnosis for Power System Using Fuzzy Petri Nets," Przeglad Elektrotechniczny (Electrical Review), vol. 88, no. 7a, 2012, s. 99-102.
- [14] M. Uzam, Petri-Net-Based Supervisory Control of Discrete Event Systems and Their Ladder Logic Diagram Implementations, PhD Thesis, Telford Research Institute University of Salford, Salford UK, 1998.
- [15] N. Pamuk, "Genetik Algoritma Kullanılarak Orta ve Yüksek Gerilim Şalt Cihazları Üretimine Tasarlanması", Bilimde Modern Yöntemler Sempozyumu, Diyarbakır, 14-16 Ekim 2010, s. 1494-1509.
- [16] D. Hanbay, İ. Türkoğlu, Y. Demir, "Güç Sistemlerinin Zamanlanmış Petri Ağı Kullanılarak Modellenmesi," 4<sup>th</sup> Uluslararası İleri Teknolojiler Sempozyumu, Konya, 28-30 Eylül 2005, s. 264-267.
- [17] L.G. Hewitson, M. Brown, R. Balakrishnan, "Simple Calculation of Short Circuit Currents", Practical Power System Protection, vol. 4, no. 1, 2005, s. 11-25.

## İstatiksel Bilgisayarlı Çeviride Paralel Derlemin Büyüklüğünün ve Kalitesinin Etkileri

Eray YILDIZ<sup>1</sup> A. Cüneyd TANTUĞ<sup>2</sup> Banu DİRİ<sup>3</sup>

<sup>1,3</sup> Bilgisayar Mühendisliği Bölümü  
Elektrik-Elektronik Fakültesi  
Yıldız Teknik Üniversitesi, İSTANBUL  
<sup>2</sup> Bilgisayar Mühendisliği Bölümü  
Bilgisayar ve Bilişim Fakültesi  
İstanbul Teknik Üniversitesi, İSTANBUL

Email: yildizeray@hotmail.com.tr

tantug@itu.edu.tr

banu@ce.yildiz.edu.tr

### Özet

*Paralel derlemler İstatiksel Bilgisayarlı Çeviri (İBÇ) sistemlerinde önemli bir rol oynamaktadır. Bu çalışma paralel derlem büyüklüğünün ve kalitesinin İBÇ sisteminin başarısına olan etkilerini incelemeyi amaçlamıştır. Paralel derlemlerde yer alan paralel cümle çiftlerini kaliteli veya kalitesiz olarak sınıflandırmak için geliştirilen makine öğrenmesi tabanlı bir sınıflandırıcı, 1 milyon paralel cümle içeren bir paralel derleme uygulanmış ve 600 bin kaliteli paralel cümle elde edilmiştir. Tüm paralel derlem ve filtrelenmiş kaliteli derlem içerisinden seçilmiş farklı büyüklüklerdeki eğitim verileriyle İBÇ sistemleri eğitilip başarıları karşılaştırılmıştır.*

### 1. Giriş

Birbirinin çevirisi olan metinlerden oluşan ve cümle seviyesinde hizalanmış olan paralel derlemler İstatiksel Bilgisayarlı Çeviri (İBÇ) için temel eğitim verisi görevini görmektedir [1]. Paralel derlemler İBÇ'nin yanı sıra sözcük belirsizliği giderme, bilgi erişimi gibi diğer doğal dil işleme alanlarında da kullanılmaktadır. Yüksek başarılı bir İBÇ sistemi için en çok zaman alan işlem, paralel cümle çiftlerini içeren bir paralel derlem oluşturmaktır. İBÇ'nin bileşenlerinden olan çeviri modeli parametrelerin kestirimi için büyük boyutlarda eğitim verisine ihtiyaç duymaktadır [2]. Bu sebepten yüksek başarılı çeviriler yüksek sayıda örnek içeren eğitim verileri ile mümkün olmaktadır [3]. İBÇ sisteminin çıktılarının kalitesi cümle çiftlerinin kalitesiyle doğrudan alakalıdır. Erişilebilir paralel metin derlemlerinin bir kısmı sınırlı sayıda dil için Birleşmiş Milletler, Avrupa Parlamentosu, Kanada Parlamentosu gibi çok dilli organizasyonlar ve devletler tarafından üretilmektedir. İnsan emeğiyle paralel derlem oluşturmak oldukça maliyetli ve zaman gerektirdiği için paralel derlemler genellikle otomatik yöntemlerle üretilirler. Otomatik üretilen paralel derlemler hatalar ve

belirsizlikler içerebilirler. Paralel olmayan cümleler içeren, düşük kalitede bir eğitim derlemi düşük kalitede çevirilere sebep olmaktadır [2]. Otomatik üretilmiş bir derlemdeki gürültü, kaynak ve hedef dokümanlardaki farklılıklardan, aslına uygun olmayan çevirilerden veya cümle hizalama hatalarından meydana gelebilir. Büyük bir paralel derlemlerdeki hataları elle gidermek pek mümkün olmadığından, paralel bir cümle çiftinin doğru olup olmadığını belirlemek için otomatik bir değerlendirme yöntemi gerekmektedir [4]. Otomatik değerlendirme yöntemi eşleşen sözcükler, cümle uzunluk ilişkisi, dilbilgisel doğruluk, akıcılık gibi etkenlerden faydalanabilir.

Bu çalışma, büyük ve gürültülü bir paralel derlemin veya filtrelenmiş kaliteli bir derlemin eğitim verisi olarak da kullanımının etkilerini gözlemlemek amacıyla yapılmıştır. Deneysel İngilizce ve Türkçe dilleri arasında çalışan İBÇ sistemlerinde gerçekleştirilmiştir. Bölüm 2'de mevcut çalışmalardan Bölüm 3'te kullanılan eğitim verisinden, Bölüm 4'te de paralel derlem filtreleme yönteminden ve deneysel sonuçlardan bahsedilmektedir.

### 2. İlgili Çalışmalar

Paralel olmayan cümle çiftlerinin filtrelenmesi işlemi paralel metin madenciliğinin son işleme adımlarından biri olarak düşünülmektedir. Resnik ve Smith'in [5] geliştirdiği paralel metin elde etmek için Web'i tarayan sistemde çeviri benzerliği ölçüsü adını verdikleri bir özellik, toplanan verileri temizleme işleminde kullanılmıştır. Çeviri benzerliği ölçüsü kaynak metinde yer alan sözcüklerin çevirilerinin hedef dildeki metinde yer almadığına bakılarak elde edilen bir ölçüttür.

Khadivi ve Ney [6] cümle uzunluklarını ve çeviri olasılığı ölçüsünü kullanan kural tabanlı bir model geliştirmiştir ve Avrupa Birliği sitesinden elde edilen bir paralel derlemi bu modelin ürettiği sonuçlara göre sıralayarak üstteki



%97,5'lik kısımla BLEU puanını 46,8'den 47,2'ye çıkarmayı başarmışlardır. Yasuda ve diğerleri [7] İngilizce-Çince dilleri arasında her cümle için dil modelleriyle hesaplanan karmaşıklık skoru ile eğitim verisindeki olumsuz örnekleri eleyerek %1,76 BLEU puanı civarında ilerleme kat etmiştir. Liu ve Zhou'nun [4] çalışmasında paralel cümlelerden çeşitli dilsel özellikler çıkartılarak bir özellik vektörü elde edilmiş ve Destek Vektör Makineleri (DVM) yardımıyla problem, bir sınıflandırma problemi olarak ele alınmıştır. Yapılan testler sonucunda 40 binlik bir derlemde 0,88 tutturma ve bulma sonuçlarını elde etmişlerdir. Taghipour [2] ise dil modeline ve IBM çeviri modeline dayalı özellikleri kullanarak geliştirdikleri yöntemde sınıflandırma işlemi için maksimum entropi modelini kullanmışlardır. 48 binlik Farsça-İngilizce paralel derlem üzerinde yapılan deneyler sonucu sistemlerinin %98,3 doğruluk düzeyinde çalıştığı gösterilmiştir. Munteanu ve Marcu tarafından [8] yapılan çalışmada paralel olmayan haber kaynaklarından Çince, Arapça, İngilizce paralel cümleleri bulan bir sistem geliştirilmiştir. Maksimum entropi sınıflandırıcısı ile cümleleri uzunluk, eşleşme ve sözcük hizalama sonucu elde edilen özellikleri kullanarak sınıflandıran bu sistem ile Arapça-İngilizce bir derlemde 0,94 tutturma ve 0,67 duyarlılık sonuçları elde edilmiştir.

Yine bu çalışmayla ilişkili olarak Schwenk'in [9] tek dilli metinleri çeviren ve sonrasında filtreleyerek eğitim verisine ilave eden yaklaşımı, Matsoukas'ın [10] eğitim verisindeki cümlelere farklı ağırlıklar veren yöntemi ve Axelrod'm [11] özel bir konuya göre eğitim verisinden örnek seçen yöntemi gösterilebilir.

### 3. Eğitim Verisi

Bu çalışmada haber metinleri [12], yazınsal metinler [13], film altyazıları [14] ve çok dilli Web sayfaları [15] gibi farklı kaynaklardan alınan 1 milyon paralel cümle çifti içeren bir derlemden faydalanılmıştır. Bu kaynaklar cümle seviyesinde hizalanmış olsa da, önemli hizalama hataları içermektedir. Dolayısıyla, hizalama problemlerini gidermek ve belirli bir kalite seviyesini korumak için her bir derlemdeki paralel cümle çifti ön elemeyen geçirilmiştir. Sözlük tabanlı bir cümle hizalama aracı olan Champollion [16] aracı bu ön eleme işlemi için kullanılmış ve bu işlemden sonra deneylerde kullanılan eğitim verisi oluşturulmuştur. Derlemlerin içerdiği cümle sayıları Tablo 1'de gösterilmiştir.

Tablo 1. Ön-eleme işlemi sonrası eğitim kümesi

EğitimKümesi	CümleSayısı (Bin)
Haber	200
Altyazı	1.200
Web	150
Yazınsal	680
<b>Total</b>	<b>2,230K</b>

## 4. Deneyler

Yapılan ilk araştırma, paralel veriyi oluşturan kaynakların kalitesini gözlemek için yapılmıştır. Adil bir karşılaştırma yapabilmek için eğitim verisinin büyüklüğünün çeviri kalitesine olan etkisinden kaçınmak gerekmektedir. Bu sebeple paralel verilerden eşit büyüklükte (150K cümlelik) parçalar alınarak İBÇ sistemleri eğitilmiş ve sistemlerin performansları yine her bir kaynaktan eşit sayıda örnek alınarak oluşturulan 4K cümlelik bir test kümesi üzerinde ölçülmüştür. İBÇ sistemlerinin eğitimi için MOSES aracı [17]; başarı ölçüsü olarak sistem çıktuları ile referans çeviriler arasındaki benzerliği ölçerek elde edilen BLEU puanı [18] kullanılmıştır. Tablo 2'de her derlemin cümle başına düşen ortalama sözcük sayısı ve çeviri başarıları verilmektedir.

Tablo 2. Her bir derlemden eşit sayıda örnekle eğitilmiş İBÇ sistemlerinin çeviri başarıları

EğitimVerisi	EğitimVerisi Büyüklüğü (Bin Cümle)	OrtalamaCümleUzunluğu (Sözcük)	BLEU(%)
Haber <sub>150K</sub>	150	17,25	16,59
Altyazı <sub>150K</sub>	150	10,41	4,72
Web <sub>150K</sub>	150	23,1	19,56
Yazınsal <sub>150K</sub>	150	17,71	9,49

Tablo 2'deki sonuçlar yorumlandığında, çeviri kalitesinde önemli farklılıkların olduğu görülmektedir. Bu duruma yol açan etkenler içerdikleri sözcük sayısının yanı sıra çeviri kaliteleri ve hizalama hatalarıdır. Dolayısıyla, kaliteli cümle çiftlerini kalitesiz olanlardan ayıracak bir sınıflandırıcı faydalı bir ön işleme adımı olarak düşünülebilir.

### 4.1. Kalite Sınıflandırıcısı

Derlemdeki her bir paralel cümle çifti için birbirlerinin uygun çevirileri olup olmadığını denetleyen bir yöntem ihtiyacı duyulduğu için; çeviri kalitesi ile ilişkili olduğu düşünülen özelliklerden faydalanarak otomatik bir sınıflandırıcı geliştirilmiştir. Çeviri kalitesi sadece hizalamanın doğruluğuna bağlı değildir, aynı zamanda dilbilgisel doğruluk, akıcılık ve doğru sözcük kullanımı da kaliteyi değerlendirmede etkilidir [4].

Dilbilgisi kurallarına aykırı olan bir cümle, çeviri modelinde bozulmalara yol açabilmektedir. Dilbilgisi ile ilişkili olarak kullanılan özellikler: bir yazım denetleyicisi [19] kullanılarak elde edilen İngilizce cümledeki hatalı yazılan sözcük sayısı ve akıcılığı, doğru sıralamayı ölçen dil modeli puanıdır. Uzun cümlelerin dil modeli olasılıklarının düşük olması da dikkate alınarak cümle uzunlukları da özellik olarak kullanılmıştır. İngilizce dil

modelini üretmek için BerkeleyLM aracı [20] ve Web 1T<sup>1</sup> derleminden faydalanılmıştır. Filtreleme işleminde kullanılan özelliklere cümlelerin uzunluklarının yanı sıra farkları ve oranları da eklenmiştir. Kullanılan son özellik ise sözlüğe göre karşı tarafta çevirileri bulunan sözcüklerin oranıdır. Bu özellik cümlelerin içerikleriyle ilgili bir özellik olup, 88.824 İngilizce sözcük ve Türkçe karşılıklarını içeren elektronik bir sözlükten ve sözcüğün ilk 5 harfini baş kelime (lemma) olarak ele alan basit kök eşleştirme yönteminden yararlanılmıştır [21].

Sınıflandırıcının eğitimi için gereken eğitim verisi paralel derlemlerden rasgele seçilen örneklerin insan emeğiyle 'kaliteli' ve 'kalitesiz' olarak etiketlenmesiyle oluşturulmuştur. 983 cümle çifti 'kaliteli', 160 cümle çifti 'kalitesiz' olarak işaretlenmiştir. 'kalitesiz' olarak işaretlenen bu 160 örneğin kalitelerinin düşük olmasının sebebi dilbilgisel ve yazınsal hatalardan, aslına uygun olmayan çevirilerden kaynaklanmaktadır. Ayrıca, yanlış rasgele hizalamalar sonucu üretilen 674 örnek de 'kalitesiz' olarak işaretlenmiş ve eğitim verisine yapay gürültü olarak eklenmiştir. Tablo 3'te sınıflandırıcının eğitimi için kullanılan eğitim verisi gösterilmektedir.

Tablo 3. Sınıflandırıcı için Eğitim Verisi

Cümle Çifti Kalitesi	Adet
Kaliteli	983
Kalitesiz	
YapayGürültü	674
DerlemlerdenSeçilen	160
<b>Total</b>	<b>1817</b>

Tablo 4. Sınıflandırma algoritmalarının başarıları

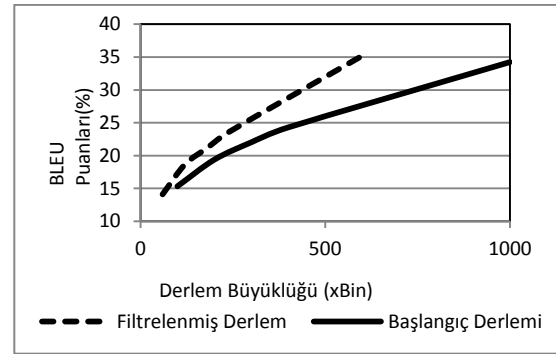
Sınıflandırıcı	Tutturma	Duyarlılık	F1
RTF	0.903	<b>0.964</b>	0.933
RKO	<b>0.969</b>	0.960	<b>0.965</b>
YSA	0.938	0.953	0.946
DVM	0.932	0.963	0.947
NB	0.736	0.930	0.822

Sınıflandırıcıyı eğitirken en uygun yöntemi belirlemek amacıyla farklı makine öğrenmesi yöntemleri olarak Radyal Tabanlı Ağlar (RTF), Rassel Karar Ormanı (RKO), Çok katmanlı Yapay Sinir Ağı (YSA), Destek Vektör Makineleri (DVM) ve Naive Bayes (NB) tabanlı sınıflandırıcılar ile WEKA aracı [25] kullanılarak deneyler yapılmış ve Tablo 4'de yer alan sonuçlar elde edilmiştir. Tüm deneyler onlu çapraz doğrulama ile yapılmıştır. Tutturma ölçütüyle sınıflandırıcının yaptığı sınıflandırmaların ne kadarının doğru olduğu ifade edilirken, bulma ölçütüyle gerçekten kaliteli olan örnek cümle çiftlerinin ne kadarının sınıflandırıcı tarafından bulunduğu gösterilmektedir. Sonuçlara bakıldığında; RKO algoritmasının filtreleme görevi için en uygun sınıflandırıcı olduğu görülmektedir.

Derlemlerden seçilerek elle etiketlenen kalitesiz örneklerin sınıflandırılması işleminin yapay üretilen kalitesiz örneklerin sınıflandırılması işlemine göre daha güç olduğu söylenebilir. Derlemlerden seçilen bu 160 kalitesiz örnek üzerinde RKO algoritmasının verimliliğini görmek için derlemlerden seçilen 80 kalitesiz örnek eğitim verisinden çıkartılıp test kümesi olarak kullanılmıştır. RKO algoritması ile 76 örneğin doğru etiketlendiği görülmüştür (0,95 doğruluk).

## 4.2. Deneysel Sonuçlar


Derlem büyüklüğünün etkilerini gözlemleyebilmek için Tablo 1'de gösterilen veri kümelerinden alınan örneklerden oluşturulan 1 milyon cümle çiftine kadar farklı büyüklüklerde eğitim verileri kullanılarak deneyler yapılmıştır. Eğitim verisinin %10'luk kısmı test kümesi olarak kullanılırken, Türkçe kısmı ile dil modelinin eğitimi gerçekleştirilmiştir. İngilizce-Türkçe ve Türkçe-İngilizce yönlerinde yapılan deneylerde elde edilen çeviri başarıları BLEU puanı olarak Şekil 1 ve Şekil 2'de görselleştirilmiştir.



Şekil 1. İBÇ sistemlerinin eğitim verisi büyüklüğü ve kalitesine göre sonuçları (İngilizce'den Türkçe'ye)

Beklenildiği gibi, daha çok verinin daha yüksek başarı sağlayacağı tezi doğrulanmıştır. İngilizce'den Türkçe'ye yapılan deneylerde, işlenmemiş başlangıç derlemindeki paralel cümlelerin sayısı 100 binden 1 milyona çıktığında BLEU puanı 15,33'den 34,24'e çıkmıştır (Şekil 1). Grafikteki eğilim dikkate alındığında 1 milyon cümleden daha fazla eğitim kümesiyle daha yüksek başarılar elde edilebileceği söylenebilir. Çıkarılan bir diğer sonuç, yüksek başarıya daha küçük ve kaliteli paralel bir derlem ile ulaşılabileceğidir. Kalite sınıflandırıcısı ile filtrelenerek elde edilen başlangıç derleminin %60'ı kullanılarak BLEU puanı 35,19'a çıkmış, yani %2,77 göreceli ilerleme sağlanmıştır. Eğitim verisinin büyüklüğünün azalması günler ve haftalar süren eğitim zamanında %40 civarında bir azalma sağlamaktadır.

<sup>1</sup> <http://get1t.sourceforge.net/>



Şekil 2. İBÇ sistemlerinin eğitim verisi büyüklüğü ve kalitesine göre sonuçları (Türkçe'den İngilizce'ye)

## 5. Sonuçlar

Paralel derlemin kalitesinin İBÇ sistemlerinin başarısına olan etkilerini gözlemlemeyi amaçlayan bu çalışma da çeviri benzerliği ve dilbilgisel özellikleri kullanarak paralel cümle çiftlerini kaliteli veya kalitesiz olarak sınıflandıran RKO sınıflandırıcısının kullanılması önerilmektedir. Geliştirilen kalite filtresi sayesinde gürültülü bir paralel derlemden elverişsiz örneklerin ayıklanması ile elde edilen daha küçük ve kaliteli bir derlem ile daha başarılı İBÇ sistemlerinin geliştirilebilmesi mümkün olmaktadır. Geliştirilen paralel derlem filtreleme yönteminin ortak bir test kümesinin olmayışı ve farklı diller üzerinde çalışmaları sebebiyle her ne kadar adil bir kıyaslama yapmak mümkün olmasa da filtreleme üzerine yapılan diğer çalışmalarla karşılaştırıldığında tutturma-bulma değerleri ve Bleu puanlarındaki iyileşme dikkate alındığında benzer başarılar gösterdiği gözlemlenmektedir.

Deneyler Türkçe ve İngilizce dilleri arasında yapılmış olsa da, diğer dillere uyarlanması oldukça kolaydır.

Geliştirilen filtreleme metodunun, Türkçe-İngilizce dilleri arasında geniş kapsamlı ve kaliteli bir paralel derlem oluşturma işleminde kullanılması planlanmaktadır.

## 6. Kaynaklar

[1] Brown, Peter F., John Cocke, Stephen A. Della Pietra, Vincent J. Della Pietra, Fredrick Jelinek, John D. Lafferty, Robert L. Mercer ve Paul S. Roossin. (1990) "A statistical approach to machine translation", Computational Linguistics, 16 (2):79-85.

[2] Taghipour, Kaveh, Nasim Afhami, Shahram Khadivi ve Saeed Shiry. (2010) "A discriminative approach to filter out noisy sentence pairs from bilingual corpora", Telecommunications (IST), 5th International Symposium : 537-541.

[3] Koehn, Philipp. (2002) "Europarl: A multilingual corpus for evaluation of machine translation", Information Sciences Institute, University of Southern California.

[4] Liu, Xiaohua ve Ming Zhou. (2010) "Evaluating the quality of web-mined bilingual sentences using multiple linguistic features", Asian Language Processing (IALP)

[5] Resnik, Philip, ve Noah A. Smith. (2003) "The web as a parallel corpus", Computational Linguistics 29.3 (2003): 349-380.

[6] Khadivi, Shahram, ve Hermann Ney. (2005) "Automatic filtering of bilingual corpora for statistical machine translation." Natural Language Processing and Information Systems. Springer Berlin Heidelberg : 263-274.

[7] Yasuda, Keiji, Ruiqiang Zhang, Hirofumi Yamamoto and Eiichiro Sumita. (2008) "Method of Selecting Training Data to Build a Compact and Efficient Translation Model" IJCNLP, Hyderabad, India

[8] Munteanu, Dragos Stefan, ve Daniel Marcu. (2005) "Improving machine translation performance by exploiting non-parallel corpora", Computational Linguistics 31.4 : 477-504.

[9] Schwenk, Holger. (2008) "Investigations on Large-Scale Lightly-Supervised Training for Statistical Machine Translation". International Workshop on Spoken Language Translation

[10] Matsoukas, Spyros, Antti-Veikko I. Rosti, and Bing Zhang. (2009) "Discriminative Corpus Weight Estimation for Machine Translation". EMNLP, Singapore : 708-717

[11] Axelrod, Amittai, Xiaodong He, ve Jianfeng Gao. (2011) "Domain adaptation via pseudo in-domain data selection." EMNLP

[12] Tyers, Francis M., and Murat Serdar Alperen. (2010) "SETimes: a parallel corpus of Balkan languages", LREC2010, Malta, pp 49-53

[13] Taşçı, Şerafettin, A. Mustafa Güngör, and Tunga Güngör. (2006) "Compiling a Turkish-English Bilingual Corpus and Developing an Algorithm for Sentence Alignment", International Scientific Conference Computer Science

[14] Tiedemann, Jörg. (2009) "News from opus - a collection of multilingual parallel corpora with tools and inter-faces", Natural Language Processing, volume V, Amsterdam/Philadelphia

[15] Yıldız, Eray ve Tantuğ, A.Cüneyd. (2012) "Evaluation of Sentence Alignment Methods for English-Turkish Par-allel Texts", LREC 2012. Istanbul

[16] Ma, Xiaoyi. (2006) "Champollion: A Robust Parallel Text Sentence Aligner", LREC 2006.

[17] Koehn, Philipp, Hieu Hoang, Alexandra Birch, Chris Callison-Burch, Marcello Federico, Nicola Bertoldi, ... and Evan Herbst . (2007) "Moses: Open source toolkit for statistical machine translation", ACL 2007 : 177-180.

[18] Papineni, Kishore, Salim Roukos, Todd Ward ve Wei-Jing Zhu. (2002) "BLEU: A Method for Automatic Evaluation of Machine Translation", Computational Linguistics :311-318

[19] Idzelis Mindaugas. (2005) "Jazzy: The java open source spell checker", <http://jazzy.sourceforge.net/>

[20] Pauls, Adam, ve Dan Klein. (2011) "Faster and smaller n-gram language models", Association for Computational Linguistics., Portland, Oregon.

[21] Hall, Mark, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann ve Ian H. Witten.(2009) "The weka data mining software: An update", ACM SIGKDD explorations newsletter 11.1 : 10-18.

## Dalgacık-ANFIS Modeli ile Akarsularda Katı Madde Miktarı Tahmini

Özlem TERZİ<sup>1</sup> Tahsin BAYKAL<sup>2</sup> Demet YILMAZ<sup>3</sup>

<sup>1</sup>Yapı Eğitimi Bölümü  
Teknik Eğitim Fakültesi  
Süleyman Demirel Üniversitesi, ISPARTA  
<sup>2,3</sup>Yapı Eğitimi Anabilim Dalı  
Fen Bilimleri Enstitüsü  
Süleyman Demirel Üniversitesi, ISPARTA

Email: ozlemterzi@sdu.edu.tr tahsinbaykal@hotmail.com demetyilmaz2836@gmail.com

### Özet

*Çalışmada, dalgacık dönüşümü (D) ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) kullanılarak Kızılırmak Nehri'nin askıda katı madde miktarı tahmin modelleri geliştirilmiştir. Öncelikle, ANFIS modeli geliştirilirken, nehir akım verileri kullanılmıştır. Daha sonra, akım verileri dalgacık dönüşümü ile alt serilere ayrılarak, etkili olan bileşenler belirlenmiştir. D-ANFIS modelinde ise bu etkili alt seriler kullanılarak askıda katı madde tahmin modelleri oluşturulmuştur. ANFIS ve D-ANFIS modelleri kıyaslandığında, dalgacık dönüşümünün ANFIS modelinin performansını arttırdığı görülmüştür.*

### 1. Giriş

Katı madde, rezervuarların dolmasına neden olarak hizmet sürelerini kısaltmaktadır. Su kaynaklarının kullanılması için gerekli her türlü depolama tesislerinin projelendirilmesinde birikecek katı madde miktarının dikkate alınması gerekmektedir. Aynı zamanda, katı madde tarım alanlarını verimsizleştirmektedir. Öte yandan sulama ve drenaj hendeklerinin katı madde malzemeden temizlenmesi büyük masrafları gerektirmektedir. Hepsinden önemlisi de toprağın kaybolmasıdır [1].

1950'li yıllardan beri katı madde miktarı tahmini için amprik çalışmalar yapılmaktadır. Amprik çalışmalar, katı madde taşınımı, erozyon ve çökelti gibi karmaşık süreçler nedeniyle kolay olmamıştır [2]. Karmaşık hidrolojik süreçlerin modellenmesinde uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) gibi yapay zeka yöntemleri etkili olabilmektedir. Hidroloji alanında ANFIS ile ilgili birçok çalışma mevcuttur [3-

6]. Wieprecht vd. (2013) Rhine Nehri boyunca yatak yükü ve toplam yatak malzeme yükü tahmini için nöro-bulanık modeller geliştirmişlerdir. Yatak yükü ve toplam yatak malzemesi yükü tahmini için katı madde taşınımını etkileyen dört parametre kullanmışlardır. Yatak yükü ve toplam yatak malzeme yükü tahmini için nöro-bulanık modellerinin doğru sonuçlar verdiğini göstermişlerdir [7]. ANFIS yönteminin de başarısının artırılması gerektiği durumlarda dalgacık dönüşümü gibi veri ön işleme tekniklerine ihtiyaç duyulmaktadır. Dalgacık dönüşüm tekniğinin hidrometeoroloji ve su kaynakları alanlarında uygulandığı yenidir [8-10]. İlk çalışmalardan biri olan Kumar ve Foufoula-Georgiou (1993) tarafından yapılan çalışmada, yağış verileri çok çözünürlüklü analiz ile bileşenlerine ayrılıp her bileşen analiz edilmiştir [11]. Mirbagheri vd. (2010) askıda katı madde konsantrasyonu tahmininde, yapay sinir ağları (YSA), ANFIS, dalgacık-ANFIS ve konvansiyonel katı madde anahtar eğrilerini (SRC) kullanmışlardır. Dalgacık-ANFIS yönteminin diğer yöntemlere göre, uç değerlerin tahmininde daha iyi sonuçlar verdiğini belirtmişlerdir. Ayrıca ANFIS modelinin YSA ve SRC modellerinden daha iyi performans gösterdiğini söylemişlerdir [12].

Bu çalışmada, askıda katı madde miktarı tahmininde D-ANFIS modelinin uygulanabilirliği araştırılmıştır. Dalgacık dönüşümü tekniğinden yararlanarak model geliştirebilmek için Kızılırmak Nehri'ne ait akım verileri alt serilere ayrılmış ve etkili alt serilerin girdi olarak kullanıldığı D-ANFIS modelleri ANFIS modelleri ile kıyaslanmıştır.

## 2. Materyal ve Yöntem

### 2.1. Araştırma Bölgesi ve Veriler

1182 km uzunluğu ile Türkiye'nin kendi sınırları içinde denize ulaşan en uzun nehri olan Kızılırmak Nehri, Sivas'ın İmranlı İlçesinin doğusundaki Kızıldağ'dan doğmaktadır. Kızılırmak Orta Anadolu Bölgesi'nde geniş bir yay çizdikten sonra sırasıyla Sivas, Kayseri, Nevşehir, Kırşehir, Ankara, Çankırı ve Çorum illerinden geçerek Samsun'un Bafra Burnu'ndan Karadeniz'e dökülür [13]. Çalışmada, Elektrik İşleri Etüt İdaresi'nden alınan Salur Köprüsü (1528) istasyonuna ait 1972–1997 yılları arasında bulunan akım ve katı madde miktarı değerleri ile modeller geliştirilmiştir. 1528 numaralı istasyonun katı madde miktarını tahmin etmek için aynı istasyona ait akım değerleri dalgacık dönüşümü ile alt serilere ayrılmış ve bu alt seriler girdi olarak kullanılmıştır. Verilerin ilk % 80'lik kısmını modellerin eğitimi için, kalan % 20'lik kısmı ise modellerin geçerliliğini test etmek için kullanılmıştır.

### 2.2. Yöntem

#### 2.2.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

Bulanık sistemler, genel anlamda, girdi değişkenlerinden çıktı değişkenlerine dönüşümü sağlamak amacıyla bulanık kümeleri kullanan sistemlerdir [14]. Bulanık mantık ile direkt olarak sayısal karşılığı bulunmayan değişkenler uzman kişilerin görüş ve tecrübeleriyle modele aktarılabilir, anlaşılması kolaydır ve eksik ya da yetersiz verilerle işlem yapılabilir. Bulanık mantık insanların günlük hayatlarında kullandığı dili kullanır, ayrıca ANFIS gibi uyarlanabilir teknikler yardımı ile girdi ve çıktı veri kümelerini kullanarak modellerin oluşturulmasında kolaylık sağlar. ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur [15].

Bulanık çıkarım sistemleri için çok sayıda ve değişik modeller bulunmaktadır. Bu modellerden bazıları Mamdani, Tsukamoto ve Sugeno tipi çıkarım sistemleridir. Sugeno tipi çıkarım sistemi, girdi ve çıktı veri setlerine göre bulanık kuralların

oluşturulması için sistematik bir yaklaşım sağlar. Parametrelerinin optimize edilebilmesinin kolaylığı bakımından diğer sistemlerden avantajlıdır. Sugeno tipi bulanık çıkarım sisteminde soncul kısımdaki çıktı değişkeni, girdi değişkenlerinin lineer bir fonksiyonu ya da sabit bir fonksiyon şeklindeki üyelik fonksiyonuna sahiptir. Parametreleri optimize edilen Sugeno tipi çıkarım sistemlerine “Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi” adı verilir [16].

ANFIS parametrelerinin optimizasyonunda, geriye yayma, en küçük kareler kestirimi, kalman filtresi ya da birden fazla matematiksel optimizasyon yönteminin birleşmesinden oluşan hybrid öğrenme algoritmaları gibi değişik yöntemler kullanılabilir. Sugeno tipi bulanık çıkarım sistemlerinde kurallar,

$$\text{Eğer } x \in A \text{ ve } y \in B \text{ ise } f = f(x, y) \quad (1)$$

şeklinindedir. Burada A ve B sırasıyla öncül kısımdaki X ve Y değişken uzayını bulanık alt uzaylara ayıran kümelerin etiketidir. f ise o kurala ait çıkış değeridir ve bu, girdi değişkenlerinin bir fonksiyonudur. Herhangi bir x, y girdi çifti için sonuç çıktı değeri f ise tüm kuralların çıktı değeri f'lerin ağırlıklı ortalamasıdır [16].

#### 2.2.2. Dalgacık Dönüşümü

Dalgacık, dalganın küçük bir parçası olarak tanımlanabilir. Bu anlamda dalgacık, süresi sınırlı bir titreşim işaretidir [17]. Dalgacık analizinde en çok kullanılan ana dalgacıklar Morlet, Haar, Meksika şapka tipi, Daubechies dalgacıklarıdır. Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır. Dalgacık algoritmaları, veriyi farklı ölçek veya çözünürlüklerde işler. Eğer geniş bir pencereden bir işarete bakılırsa, büyük özellikleri fark edilir. Benzer şekilde, küçük bir pencereden bir işarete bakılırsa, küçük özellikleri fark edilir. Dalgacıkları ilginç ve aynı zamanda yararlı kılan bu özelliğidir.

Dalgacık katsayılarının ölçek değerinde hesaplanması çok miktarda katsayının oluşmasına ve işlem yüküne neden olduğundan dolayı, katsayıların yalnızca seçilen ölçekler ve zaman diliminde hesaplanması birçok avantaj sağlar. Bu sayede daha az sayıda ancak yine de işaretin frekans-ölçek bilgisinin zaman boyunca değişimini veren katsayılar elde edilmiş olur.

Bu katsayılar bir zaman serisi meydana getirirler ve bu zaman serileri çeşitli amaçlar için kullanılabilir.

Ayrık dalgacık dönüşümünde (ADD) kullanılan ikili ölçek ve zaman adıdır. Bu şekilde elde edilen her bir bileşen iki ve ikinin katları olacak şekilde ölçek değerlerine ait zaman serilerini ya da dalgacık katsayılarını verirler. Ayrık dalgacık dönüşümü için kullanılan dalgacık fonksiyonu aşağıda verilmiştir.

$$\Psi_{m,n}\left(\frac{t-\tau}{s}\right)=S_0^{-m/2}\Psi\left(\frac{t-n\tau_0s_0}{s_0^m}\right) \quad (1)$$

Burada m ve n tamsayı olarak dalgacığın sırası ile ölçek ve zaman eksenindeki öteleme parametreleridir.  $S_0$  sabit bir öteleme adımını ifade eder ve bu çalışma da 2 olarak alınmıştır.  $\tau_0$  zaman eksenindeki öteleme aralığı değerini verir ve değeri 1 olarak alınmıştır. Bu değerler literatürde en çok kullanılan değerlerine göre alınmıştır. İkinci katları kullanılarak oluşturulan dalgacık fonksiyonu aşağıdaki şekilde tanımlanabilir.


$$\Psi_{m,n}(t)=2^{-m/2}\Psi(2^m t-n) \quad (2)$$

Bir i ayrık adımına sahip x(t) zaman serisi için ayrık dalgacık dönüşümü aşağıdaki şekilde tanımlanabilir.

$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} x_i \Psi(2^m i - n) \quad (3)$$

Burada  $W_{m,n}$ ,  $s=2^m$  ölçek ve  $t=2^m n$  zaman değerlerine sahip dalgacık dönüşümü katsayılarıdır. Denklemde  $x_i$ ,  $i=1, \dots, N-1$ ; sonlu değerlere sahip bir zaman serisi ve N,  $N=2M$  şeklinde ifade edilen ikinin katı bir tamsayıdır.  $1 < m < M$  olmak üzere 2m ölçeğinde,  $m=M$  olduğu en geniş ölçekte, tüm zaman serisini kaplayacak yalnızca bir tane dalgacık gerekir. Bir sonraki ölçekte ise (2M-1) iki adet dalgacık tüm zaman aralığını kapsar ve iki adet katsayı üretilmiş olur. Bu işleme  $m=1$ 'e kadar devam edilir. Bu işlemlerden sonra boyutu  $N=2M$  olan bir ayrık zaman serisini ifade edecek toplam katsayı sayısı  $1+2+4+\dots+2M-1$  adettir. Böylece ayrık dalgacık dönüşümü bize farklı zaman ve ölçeklerdeki bir zaman serisinin değişimi hakkında bilgi sağlar.

ADD'nin bu şekli ile her seferinde veri sayısı yarı oranda azalmaktadır. Ayrık dalgacık dönüşümünün çok çözünürlüklü analiz adlı başka bir şekli daha vardır. Mallat (1989) tarafından önerilen ADD'nin genel çalışma prensibi Şekil 1'de gösterilmiştir [18].



Şekil 1. İşaretin ADD ile bileşenlerine ayrılıp tekrar oluşturulması (S, orijinal işaret: Y, yaklaşık bileşen; AD, Detay bileşen)

Detay bileşenlerinin her birisi ayrı bir zaman serisi olup ait olduğu ölçekte orijinal seri hakkında önemli bilgiler içerir. Bu sayede orijinal serinin yapısının gizli özellikleri, detay bileşenlerinden incelenebilir. Detay bileşenlerinin bazıları orijinal serinin özelliklerinin büyük kısmını barındırabilir [17].

### 3. Araştırma ve Bulgular

Çalışma iki aşamadan oluşmaktadır. Birinci aşamada, 1528 numaralı istasyonun katı madde miktarını tahmin etmek için aynı istasyonun akım değerleri kullanılarak ANFIS ile modeller geliştirilmiştir. ANFIS modelleri geliştirilirken farklı alt küme sayıları, geriye yayma ve hybrid ağ yapıları denenmiştir. Geliştirilen modeller içinden en uygun modelin eğitim ve test setleri için determinasyon katsayısı ( $R^2$ ) 0,55 olarak belirlenmiştir. Çalışmanın ikinci aşamasında ise, dalgacık-ANFIS modelleri geliştirilmiştir. Bu modelleri geliştirmek için akım değerlerine ayrık dalgacık dönüşümü uygulanmış ve bu akım değerleri sekiz adet detay (2-4-8-16-32-64-128-256) ve bir adet yaklaşıklık bileşenine ayrılmıştır. Alt serilerin oluşturulmasında, ayrık dalgacık dönüşüm tekniğinde en çok kullanılan Haar, DMeyer (Dmey) ve Daubechies (db) dalgacıkları kullanılmış ve bu dalgacıklardan en iyi model sonuçlarını db dalgacığı vermiştir.

Db dalgacığı ile elde edilen alt seriler ve katı madde miktarı arasında korelasyon katsayıları hesaplanmış ve Tablo 1'de verilmiştir. Tablo 1 incelendiğinde,  $D_1$ ,  $D_2$ ,  $D_3$  ve  $D_5$  bileşenlerinin diğerlerinden daha yüksek korelasyon değerlerine sahip olduğu görülmüştür. Katı madde miktarı üzerinde etkili olan bu bileşenler, dalgacık-ANFIS modelinin girdi parametreleri olarak kullanılmıştır.

Modellerin performanslarını değerlendirmek için, karekök ortalama hata (KOH) değerleri (denklem 4) ve belirginlik katsayıları ( $R^2$ ) (denklem 5) hesaplanmıştır.

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{i(gerçek)} - R_{i(model)})^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (R_{i(gerçek)} - R_{i(model)})^2}{\sum_{i=1}^n (R_{i(gerçek)} - R_{ort})^2} \quad (5)$$

Burada, n toplam veri sayısı,  $R_i(gerçek)$  ve  $R_i(model)$  sırasıyla ölçülen katı madde miktarı ve geliştirilen modelin sonuçlarıdır.  $R_{ort}$  ise ortalama katı madde miktarıdır.

Tablo 1. Akım alt serileri ile katı madde miktarı arasındaki korelasyon katsayıları

Alt bileşenler	Korelasyon	Alt bileşenler	Korelasyon
D <sub>1</sub>	0,427	D <sub>5</sub>	0,250
D <sub>2</sub>	0,321	D <sub>6</sub>	0,135
D <sub>3</sub>	0,327	D <sub>7</sub>	0,078
D <sub>4</sub>	0,145	D <sub>8</sub>	-0,003
Yaklaşıklık (A <sub>8</sub> )			-0,048

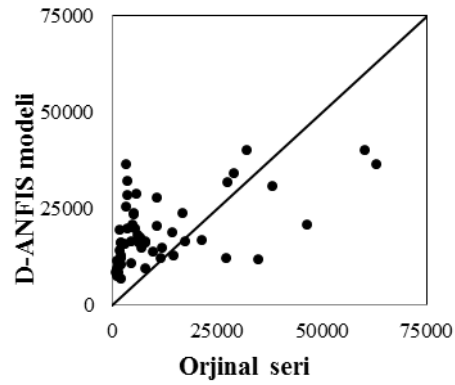

D<sub>1</sub>, D<sub>2</sub>, D<sub>3</sub> ve D<sub>5</sub> alt bileşenleri tek tek ve toplanarak girdi parametresi olarak kullanılmasıyla çeşitli kombinasyonlar oluşturulmuştur. Bu girdi kombinasyonları ile geliştirilen dalgacık-ANFIS modellerine ait eğitim ve test setleri için kareköt ortalama hata (KOH) ve R<sup>2</sup> değerleri Tablo 2'de verilmiştir. Bu modeller içerisinde en uygun sonucu veren modelin girdi parametresi D<sub>1</sub>+D<sub>3</sub>+D<sub>5</sub> alt serilerinin toplanması ile elde edilmiştir. Bu modelin test seti için R<sup>2</sup> değeri 0,73 olarak belirlenmiştir.

Tablo 2. Geliştirilen modellere ait parametreler

İstatistiksel parametreler	Eğitim Seti		Test Seti	
	KOH	R <sup>2</sup>	KOH	R <sup>2</sup>
ANFIS	29823	0,58	35947	0,55
D-ANFIS (D <sub>1</sub> -D <sub>2</sub> -D <sub>3</sub> )	24970	0,71	33533	0,68
D-ANFIS (D <sub>1</sub> +D <sub>3</sub> +D <sub>5</sub> )	27472	0,65	32140	0,73

Orijinal seri ile elde edilen ANFIS modelinin test seti için R<sup>2</sup> 0,553 iken, dalgacık dönüşümünden sonra elde edilen D-ANFIS modellerinin R<sup>2</sup> değerleri 0,68 ve 0,73'e yükselmiştir. Akım alt serilerinin toplanması ile elde edilen modelin (D<sub>1</sub>+D<sub>3</sub>+D<sub>5</sub>) performansının en yüksek olduğu görülmüştür.

ANFIS ve dalgacık-ANFIS (D<sub>1</sub>+D<sub>3</sub>+D<sub>5</sub>) modelleri için test setine ait saçılma diyagramları Şekil 2'de verilmiştir. Elde edilen D-ANFIS modelinin ANFIS modeline göre daha iyi performans gösterdiği görülmüştür.



Şekil 2. ANFIS ve dalgacık-ANFIS modellerine ait saçılma diyagramları

#### 4. Sonuçlar

Bu çalışmada, dalgacık dönüşümü ve ANFIS yöntemi birlikte kullanılarak Kızılırmak Nehri'nin askıda katı madde tahmini için modeller geliştirilmiştir. Burada, farklı bir yaklaşım oluşturarak dalgacık dönüşümü ile ANFIS'in başarısını artırmak hedeflenmiştir. Bunun için Haar ve Dmey dalgacıları kullanılarak alt seriler elde edilmiştir. Bu alt serilerden etkili olanlar seçilerek ANFIS'de girdi olarak kullanılmış ve D-ANFIS modelleri geliştirilmiştir. Orijinal akım değerleri kullanılarak geliştirilen ANFIS modeli ve D-ANFIS modeli kıyaslandığında, dalgacık dönüşümünün ANFIS'in performansını arttırdığı ve D-ANFIS modelinin ANFIS modeline göre daha başarılı olduğu görülmüştür.

## 5. Kaynaklar

- [1] M. Berkün, Su Kaynakları Mühendisliği, Birsen Yayınevi, İstanbul, 2005.
- [2] V. Jothiprakash, V. Garg, “Reservoir sedimentation estimation using artificial neural networks”, *Journal of Hydrologic Engineering*, 2009, 14(9), s.1035-1040.
- [3] R. Bakhtyar, A. Ghaberi, A. Yeganeh-Bakhtiary ve D.-S. Jeng, “Cross-shore sediment transport estimation using fuzzy inference system in the swash zone”, *Journal of the Franklin Institute* 2011, 348, s. 2005-2025.
- [4] Ö. Kişi and J. Shiri, ”River suspended sediment estimation by climatic variable simplification: Comparative study among soft computing techniques”, *Computers&Geosciences*, 2012,43, s.73–82.
- [5] M. Rezaeianzadeh, H. Tabari, A. Arabi Yazdi “Flood flow forecasting using ANN, ANFIS and regression models” *Neural Comput&Applic*, 2014,25, s.25–37.
- [6] Ö. Kişi, A.H. Dailr, M. Çimen, J. Shiri, “Suspended sediment modeling using genetic programming and soft computing techniques”, *Journal of Hydrology*, 2013, s.450–451 48–58.
- [7] S. Wieprecht, H.G. Tolossa, C.T. Yang, “A neuro-fuzzy-based modelling approach for sediment transport computation”, *Hydrological Sciences Journal*, 2013, 58 (3), s.587–599.
- [8] T. Partal ve H.K. Cığızoğlu, “Estimation and forecasting of daily suspended sediment data using wavelet–neural networks”, *Journal of Hydrology*, 2008, 358, s.317– 331.
- [9] U. Okkan, ”Wavelet neural network model for reservoir inflow prediction”, *Scientia Iranica Transactions A: Civil Engineering*, 2012, 19(6), 1445-1455.
- [10] T. Partal ve Ö. Kişi, “Wavelet and neuro-fuzzy conjunction model for precipitation forecasting”, *Journal of Hydrology*, 2007, 342, s.199– 212.
- [11] P. Kumar, E. Foufoula-Georgiou, “A multi component de composition of spatial rain fall fields 2. self-similarity in fluctuations” *Water Resources Research*, 1993, 29(8), s.2533- 2544.
- [12] S. A. Mirbagheri, V. Nourani., T.Rajaei, A. Alikhani, ”Neuro-fuzzy models employing wavelet analysis for suspended sediment concentration prediction in rivers”, *Hydrological Sciences Journal – Journal des Sciences Hydrologiques*, 2010, 55(7), 1175-1189.
- [13] Anonim. <http://www.samsun.gov.tr/samsun-sehri.asp?ContentId=21#5>, 2012.
- [14] L.A. Zadeh, “Fuzzy Sets”, *Information and Control*, 1995, 8, s.338–53.
- [15] A. Ülke ve M. Doğan, “ANFIS ve Çoklu Regresyon Teknikleri İle Eksik Yağış Gözlemlerinin Tamamlanması, Gediz Örneği”, *Bilimde Modern Yöntemler Sempozyumu*, Eskişehir, 2008.
- [16] J.S.R. Jang, ve C.T. Sun, “Neuro-Fuzzy Modeling and Control”, *The Proceedings of the IEEE*, 1995, 83(3), s. 378-406.
- [17] T. Partal, *Türkiye Yağış Miktarlarının Yapay Sinir Ağları ve Dalgacık Dönüşümü ile Tahmini*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 2007.
- [18] S.G. Mallat, “A Theory For Multiresolution Signal Decomposition: The Wavelet Representation”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989, 11(7), s.674–693.



## H ŞEKİLLİ MİKROŞERİT ANTENİN YABANI OT ALGORİTMASI İLE REZONANS FREKANSININ BELİRLENMESİ

Bülent URUL<sup>1</sup>Yavuz Cengiz<sup>2</sup>

<sup>1,2</sup>Elektronik ve Haberleşme Mühendisliği Bölümü  
Mühendislik Fakültesi  
Süleyman Demirel Üniversitesi, Isparta

[bulenturul@sdu.edu.tr](mailto:bulenturul@sdu.edu.tr)[yavuzcengiz@sdu.edu.tr](mailto:yavuzcengiz@sdu.edu.tr)

### Özet

Bu çalışmada, 1-3GHz frekans bandında, H şekilli mikroşerit antenin (HMA) rezonans frekansı, Yabani Ot Algoritması (YOA) ile optimize edilerek belirlenmiştir. YOA, yabancı otların istilacı ve dirençli yapılarından esinlenerek geliştirilmiş bir optimizasyon algoritmasıdır. YOA, iterasyon sayısı 100 olmak şartıyla, 1GHz'den 3GHz'e kadar 0.1GHz aralıklı frekans değerleri için 10x19 defa çalıştırılmış ve anten boyutları ve rezonans frekansı tablo halinde verilmiştir. HMA'nin istenilen rezonans frekansında çalışması için boyutlarının ne olacağı YOA yardımı ile %0.4'lük yanılma payı ile elde edilmiş ve YOA'nın HMA'nin rezonans frekansının belirlenmesindeki etkisi ortaya konulmuştur.

### Abstract

In this study, at 1-3GHz frequency band, resonance frequency of H type microstrip antenna (HMA) has been determined by optimizing Invasive Weed Algorithm(IWO). IWO is a optimization algorithm which has been developed inspired by invasive and resistant structures of invasive weeds. IWO, provided that the number of iterations 100, for frequency values with 0.1GHz range from 1GHz to 3GHz, was run 10x19 time and antenna sizes and resonance frequency are tabulated. To work in the desired resonant frequency of the HMA, what would be the size by the help of YOA, have been obtained with 0.4% margin of error and the effect of IWO in determining the resonant frequency of HMA has been demonstrated.

### 1.Giriş

Mikroşerit antenler, küçük boyutları ve baskı devre teknolojisi ile üretilebilmeleri sebebiyle, çok sayıda uygulamada kullanılmaktadır. Çok farklı geometrilere üretilebilen mikroşerit antenlerin literatürde dikdörtgen, kare, çember ve üçgen gibi geleneksel şekilli yapılar için rezonans frekansını belirleyen formüller mevcuttur[1-3]. Geleneksel şekiller dışında herhangi bir geometrideki mikroşerit antenin rezonans frekansı çok uzun nümerik yöntemler ile bulunabilmektedir. Bu çalışmada referans[4] baz alınarak, YOA ile H şekilli bir

mikroşerit antenin rezonans frekansı, boyutlara bağlı olarak belirlenmeye çalışılmıştır.

Çok sayıda değişkene sahip problemlerin optimum çözümünü bulmak için geliştirilen yöntemlerdeki aşırı hesaplamadan kaynaklı zaman ve iş gücü kaybı, tasarımcılar için bir handicap oluşturmaktadır. Geleneksel türeve dayalı optimizasyon algoritmaları, çok modlu ve doğrusal olmayan problemlerin çözümünde veya türevi alınamayan fonksiyonların optimizasyonlarında istenilen başarıyı gösteremediğinden, sezgisel algoritmalar genel olarak deneme yanılma yöntemine dayanmasına rağmen türevsel algoritmalarla göre oldukça başarılı sonuçlar üretmektedir.


H şekilli bir mikroşerit antenin rezonans frekansı antenin boyutlarına bağlıdır. Bu çalışmada toplam 6 farklı parametreye bağlı olarak H şekilli bir mikroşerit antenin rezonans frekansı, yabancı otların istilacı ve dirençli yapılarından etkilenilerek ortaya konulmuş olan YOA ile optimize edilmiştir.

### 2. H şekilli mikroşerit anten yapısı


HMA, Şekil 1 ve Şekil 2'de görüldüğü üzere bir dikdörtgen mikroşerit antenden 2 dikdörtgen parçanın çıkartılmasıyla elde edilmiş bir antendir. Basit yapıları ve parametrelerinin diğer antenlere nispeten daha kolay hesaplanabilmesi nedeniyle bu dikdörtgen şekilli mikroşerit antenler, tasarımcılar tarafından çok tercih edilmektedir[4-6]. Antenin rezonans frekansı, anten boyutları olan W, L, s, d, yama yüksekliği, alttaş yüksekliği ve dielektrik katsayısı  $\epsilon$ 'a bağlıdır. Bu çalışmada tüm denemeler için yama yüksekliği pratik uygulamalarda yaygın olarak kullanılan 0.1cm kabul edilmiştir. Anten boyutlarının sınır değerleri Tablo 1'de verildiği şekilde seçilmiştir.

Tablo 1. HMA boyutlarının sınır değerleri

a	b	s	d	e	h
28	28	6	6	2.5	2
36	36	22	22	5	5



Şekil 1. Dikdörtgen şekilli mikroşerit anten[4]



Şekil 2. HMA[5]

HMA'nın rezonans frekans formülü, dikdörtgen mikroşerit antenin hesaplama denklemlerinden elde edilmiştir. Dikdörtgen şekilli antendeki W boyutu H tipi anten denklemlerinde b parametresiyle ifade edilmiştir. HMA'yı elde etmek için dikdörtgen mikroşerit antende oluşturulan boşluklar nedeniyle rezonans frekans formülünde L yerine  $L_e$  kullanılmıştır. Dikdörtgen mikroşerit antene, iletim hattı modeli uygulanarak elde edilen denklemlere, HMA için üretilen yeni parametreler yerleştirilmiş ve aşağıdaki denklemler elde edilmiştir[7-8].

$$\epsilon_{reff} = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left[ 1 + 10 \frac{h}{b} \right]^{-1/2} \quad (1)$$

$$\Delta L = 0.412 \times h \frac{(\epsilon_{reff} + 0.3) \left( \frac{b}{h} + 0.264 \right)}{(\epsilon_{reff} - 0.258) \left( \frac{b}{h} + 0.8 \right)} \quad (2)$$

Burada  $\epsilon_{reff}$  değeri, içinde alttaş ve havanın dielektrik sabitini bulunduran dielektrik sabitidir. Ayrıca yamanın uzunluğunun  $\epsilon_{reff}$  ve  $b/h \gg 1$  oranına bağlı bir fonksiyon olarak her iki uçta  $\Delta L$  kadar uzadığı varsayılmaktadır [4]. (1) ve (2) nolu denklemlerde elde edilen  $\epsilon_{reff}$  ve  $\Delta L$  değerleri kullanılarak eşitlik (3)'teki H şekilli antenin rezonans denklemi oluşturulmuştur.

$$f_r = \frac{c}{2(L_e + 2\Delta L)\sqrt{\epsilon_{reff}}} \quad (3)$$

Referans [4] de çok sayıda deneme ile elde edilmiş olan  $L_e$  değeri, (4) ve (5) nolu eşitliklerde verilmiştir.

$$L_e = (\alpha_1 \cdot a + \alpha_2 \cdot d) \left( \frac{a}{b} \right)^{\alpha_3} + (\alpha_4 \cdot a + \alpha_5 \cdot s) \left( \frac{s}{d} \right)^{\alpha_6} + (\alpha_7 \cdot d) \left( \frac{d}{b} \right)^{\alpha_8} \quad (4)$$

$$\alpha_1 = 0.893 \quad \alpha_2 = -0.317 \quad \alpha_3 = -0.561 \quad \alpha_4 = 0.721 \\ \alpha_5 = -0.634 \quad \alpha_6 = 0.644 \quad \alpha_7 = 0.147 \quad \alpha_8 = -1.586 \quad (5)$$


### 3.Yabani ot algoritması

Yabani ot algoritması ilk olarak Mehrabian tarafından 2006 yılında ortaya konulmuş bir sezgisel optimizasyon algoritmasıdır[9]. Bu algoritma, doğadaki yabani otların, tüm zirai mücadelelere rağmen ayakta kalıp, soyunu sürekli güçlendirerek devam etmesinden esinlenilerek ortaya konulmuştur. Yabani ot ekolojisinde, iyilerin daima ayakta kalabildiği bir mekanizma vardır. Yabani otların bu özellikleri YOA'nın temelini oluşturmaktadır.


Algoritmanın işleyişi 4 kısımda özetlenebilir:

**3.1. Başlangıç popülasyonu:** Belirli sayıda birey problem uzayında rasgele dağıtılarak başlangıç popülasyonu oluşturulur.

**3.2. Üreme:** Her bir bireyden kendi sağlık durumuyla orantılı olarak belirli sayıda yeni bireyler türetilmesi gerekmektedir. Şekil 1 ve 2'de gösterildiği üzere lineer olarak en iyi bireyden en fazla, en kötü bireyden en az olacak şekilde yeni bireyler üretilir. Bu aşamada kaç tane yeni oluşturulacağı belirlenir.



Şekil 3. Üretilecek Birey Sayısı Grafiği (Maksimum İçin)[9]



Şekil 4. Üretilecek Birey Sayısı Grafiği (Minimum İçin)

**3.3.Konumsal Dağıtma:** Bir önceki adımdaki belirlenen sayıda birey, zamanla azalan değişim parametresine bağlı olarak eşitlik (6) ve (7)'ye göre rasgele olacak şekilde problem uzayına dağıtılır.

$$\sigma_{iter} = \frac{(iter_{max} - iter)^n}{iter_{max}^n} * (\sigma_{baş} - \sigma_{son}) + \sigma_{son} \quad (6)$$

$$x_{yeni} = x_i + \sigma_{iter} * randn(0,1) \quad (7)$$

Burada,  $\sigma_{iter}$  her bir iterasyon için standart sapma değeri,  $\sigma_{baş}$  başlangıç standart sapma değeri,  $\sigma_{son}$  ulaşılabilecek son standart sapma değeri, n modülasyon indeksi,  $x_i$  bir önceki iterasyonda bulunan değer ve  $x_{yeni}$  standart sapmaya bağlı olarak rastgele bir şekilde bulunan yeni birey değeridir.

Bu aşamada iyi bireyler bir yere doğru toparlanır ve kötü bireyler zamanla elenir.

**3.4. Rekabetçi Eleme:** Birkaç iterasyon sonrası yeni üretilen bireyler nedeniyle maksimum popülasyon sayısı geçileceğinden, en kötü bireyler elenerek birey sayısı başlangıçta belirlenen popülasyonun maksimum birey sayısına geri çekilir. Bu şekilde zayıfın elenip kuvvetlilerin devam ettiği bir popülasyon elde edilir. Bu işlem tüm iterasyonlar bitene veya diğer durdurucu kriterler limit değerine ulaşana kadar devam eder.

Bu işlemler neticesinde, hayatta kalan en iyi birey, optimizasyon probleminin aranan en iyi çözüm noktasını verir.

#### 4. YOA ile H şekilli mikroşerit antenin rezonans frekans formülünün optimizasyonu

Düzgün bir geometriye sahip bir antenin analizi, bazı analitik yöntemlerle yapılabilmektedir. Kompleks geometrilere sahip antenlerin analizleri, çok sayıda

hesaplama gerektirdiğinden, bazı elektromanyetik simülasyon programları kullanılarak bu işlemler yapılabilmektedir. Fakat istenen frekans bandında çalışacak bir antenin boyutları çok sayıda deneme yapılarak belirlenebilmektedir. Denemeler zaman ve iş gücü kaybına neden olduğundan, bu yöntem tasarımcılar için bir dezavantaj oluşturmaktadır.


Bu çalışmada istenilen frekans bandında çalışacak bir antenin boyutları, yukarıda bahsedildiği üzere zaman ve iş gücü kaybı olmaksızın YOA ile yaklaşık % 0.4'lük hata payı ile hesaplanmıştır.

Referans [4]'de belirlenen, antenin boyutları (a,b,s,d,h) ve elektriksel geçirgenliğine bağlı rezonans frekans ifadesi, YOA'da hedef fonksiyonu olarak kullanılmıştır. Bu parametrelerin sınır değerleri, Tablo 1'de verilmiştir.

1-3GHz frekans bandında 0.1GHz aralıklarla toplam 19 farklı mikroşerit anten tasarımı yapılmıştır. İterasyon sayısı 100 olarak belirlenen YOA algoritması ile her bir anten konfigürasyonu 10 kez denenmiş, en optimum çözümler seçilmiştir. Bulunan anten boyutları, bir elektromanyetik simülasyon programı ile test edilmiş ve sonuçlar karşılaştırmalı bir şekilde Tablo 2'de verilmiştir. Ayrıca bazı frekans değerleri için YOA ile bulunan parametrelere göre antenin S11 grafiği Şekil 5'de gösterilmiştir.  $f_{gerçek}$  değeri antenin çalışması istenilen rezonans frekansı ve  $f_{yoa}$  değeri ise YOA tarafından elde edilen a, b, s, d, e, h parametrelerine bağlı simülasyon programından elde edilen rezonans frekansdır.

YOA algoritması için;

Maksimum iterasyon sayısı 100, modülasyon indeksi 3, başlangıç standart sapma değeri 3, son standart sapma değeri 0.000001, maksimum birey sayısı 5, minimum birey sayısı 1 olarak seçilmiştir.



Şekil 5. HMA'nın YOA ile bulunmuş değerlere göre bazı değerler için S11 grafiği

Tablo 2. YOA ve simülasyon programı ile elde edilen parametreler ve rezonans frekansı

a	b	s	d	e	h	fr <sub>voa</sub>	fr <sub>gerçek</sub>
35.7418	32.8228	17.7905	6.792	4.8652	2.182	1.053	1
35.3708	34.411	14.1492	9.0027	4.7838	3.064	1.166	1.1
34.6593	33.4062	18.9729	10.5213	4.9292	2.2482	1.224	1.2
33.3142	32.3715	12.9754	9.5083	4.2504	2.059	1.328	1.3
33.0632	29.7589	20.2706	11.9819	4.9942	2.8647	1.432	1.4
35.5449	32.7092	6.1419	16.6637	4.9004	4.4306	1.504	1.5
35.4766	31.097	18.659	20.6985	4.7994	2.5462	1.614	1.6
34.2592	30.6826	10.3764	21.6549	4.7134	4.8942	1.698	1.7
35.439	28.4421	19.3925	20.1445	4.0731	2.8326	1.804	1.8
30.3214	30.3181	7.0547	16.5877	4.0701	2.8025	1.906	1.9
33.5242	32.5089	9.3617	20.4634	3.3032	2.5528	1.992	2
34.8984	28.2792	12.2754	18.4945	2.8597	2.9682	2.1	2.1
31.566	29.1367	13.0546	20.6853	3.2596	3.0098	2.206	2.2
31.6673	29.1236	11.5272	20.0869	2.8845	3.5415	2.3	2.3
30.91	30.6018	14.6518	21.4963	2.7818	2.8696	2.4	2.4
30.1281	28.0924	15.9126	21.0725	2.8738	3.5997	2.5	2.5
29.4262	28.3772	19.2921	18.7892	2.6046	3.5444	2.598	2.6
29.1553	28.6748	11.8765	21.7208	2.5554	4.2581	2.672	2.7
28.6752	28.404	19.7568	20.6594	2.5705	3.7937	2.778	2.8

## 5. Sonuç

Mikroşerit anten tasarımında rezonans frekansının belirlenmesi, en önemli kriterlerden birisidir. Antenin istenilen rezonans frekansında çalışmasını deneme yanılma yöntemi yerine kolay ve hızlı bir şekilde belirlemek iş gücü kaybını minimum seviyeye indirecektir. Bu amaçla yapılan bu çalışmada HMA'nın rezonans frekansının belirlenmesi için YOA algoritması kullanılmış ve yaklaşık %0.4 hata ile tasarımlar gerçekleştirilmiştir. Bu çalışma ile YOA algoritmasının, H şekilli mikroşerit antenin rezonans frekansının belirlenmesinde etkili bir yöntem olduğu ortaya konulmuştur.

## 6. Kaynaklar

- [1] Balanis, C. A. "Antenna Theory: Analysis and Design", John Wiley & Sons, New York, 941p., (1997).
- [2] Garg, R., Bhartia, P., Bahl, I. and Ittipiboon, A. "Microstrip Antenna Design Handbook", Artech House, London, 845p., (2001).
- [3] Bhattacharyya, A. K., Shafai, L. and Gary, R. "Microstrip Antenna – A Generalized Transmission Line", Progress In Electromagnetics Research, 4: 45-84, (1991).
- [4] TOKTAŞ, A., "Farksal Gelişim Algoritması Kullanarak H Şekilli Mikroşerit Antenlerin Rezonans Frekansının Hesaplanması", Yüksek Lisans Tezi, Mersin Üniversitesi Fen Bilimleri

Enstitüsü, Elektrik-Elektronik Ana bilim dalı, 2009, Mersin.

- [5] Gao, S.C., Li, L. W., Leong, M. S. and Yeo, T. S. "Analysis of An H-Shaped Patch Antenna by Using FDTD Method", Progress In
- [6] Pierantoni, L., Farina, M., Rozzi, T. "Accurate analysis of H-shaped antenna coupled to microstripfeed-line", Electronics Letters, 38(14): 676 – 677 , ( 4 Jul 2002) Electromagnetics Research, 34: 165-187, (2001)
- [7] Sağiroğlu, S., Güney, K., Erler, M. "Resonant Frequency Calculation for Circular Microstrip Antennas Using Artificial Neural Networks" John Wiley & Sons, 8: 270-277, (1998).
- [8] Deshmukh, A. A. and Kumar, G. "Formulation of Resonant frequency for Compact Rectangular Microstrip Antennas", Microwave and Optical Technology Letters, 49(2): 498-501, (July 2006).
- [9] R.Mehrabian, C. Lucas, and S. Mohagheghi, "A Novel Numerical Optimization Algorithm Inspired from Weed Colonization". Ecological Informatics, vol. 1, no. 4, December 2006,pp. 355-366.

## Duygu Tanımada Farklı Veri Setleri Arasında Bir Çalışma

Cevahir PARLAK<sup>1</sup> Banu DIRİ<sup>2</sup>

<sup>1,2</sup>Bilgisayar Mühendisliği Bölümü  
Elektrik-Elektronik Fakültesi  
Yıldız Teknik Üniversitesi, Beşiktaş, İSTANBUL

Eposta: cevahir.parlak@boun.edu.tr banu@ce.yildiz.edu.tr

### Özet

*Bu çalışmamızda EmoSTAR adlı yeni bir duygu veri seti sunulmuş ve Berlin Duygu Veri seti ile çapraz testler yapılmıştır. Çapraz testlerde setlerden biri eğitim diğeri test seti olarak kullanılmıştır. Özellik seçicilerin performansı da incelenmiştir. Özellik çıkarma openSMILE Emobase ve Emo\_large konfigürasyonlarında MFCC sayısı 12'den 24'e çıkartılarak ve Harmonic-to-Noise-Ratio (HNR) özellikleri eklenerek gerçekleştirilmiştir. Özellik seçme ve sınıflandırma ise Weka aracıyla yapılmıştır. EmoSTAR halen daha fazla duygu türü ve örnek için geliştirilme aşamasındadır.*

### 1. Giriş

Duygu insanları diğer canlılar ile makinelerden ayıran ve insanlar arasındaki iletişimde çok önemli rol oynayan bir faktördür. Son yıllarda insan makine etkileşiminde duygu tanıma çalışmaları oldukça ilerleme kaydetmiştir. Makinelerin ürettiği mekanik sesli cevaplar insanlar üzerinde itici bir etki oluşturmaktadır. Bu nedenle insan-makine etkileşiminde makinelere duygu yüklü konuşmalar yapabilmek ve karşısındakinin duygusunu anlayabilmek özelliği kazandırılmaya çalışılmaktadır. Böylece insan-makine etkileşimi daha çekici olabilmektedir. Duygu tanıma çalışmalarının temel öğelerinden birisi de hiç kuşkusuz duygu veritabanlarıdır. Ne var ki bu konuda üstünde çalışılacak veri setlerini hazırlamak oldukça zahmetli ve zorlu bir çalışma gerektirmektedir. Pek çok duygu türü bulunmakta ve bu duygu türlerini gerçek ortamlarda elde edebilmek çok ciddi problemleri beraberinde getirmektedir. Bu konudaki ilk çalışmalarda daha az duygu türleri üstünde veya konuşmanın sadece olumlu veya olumsuz olması ile ilgilenilmekte iken gelişen teknolojiyle birlikte daha fazla duygu türü üstünde çalışılmaya başlanmıştır.

Duygu tanımının uygulama alanları arasında çağrı merkezi uygulamaları, bilgisayar destekli öğrenme sistemleri, yalan makineleri, sesli eposta sistemleri ve oyunlar sayılabilir. Son yıllarda otomobillerde de sürücünün performansı ile duygu hali arasındaki ilişkiye gözlemlemek amacıyla duygu tanımadan yararlanılmaktadır [1]. Duygusal konuşma sentezi alanında çalışmalar da gün geçtikçe artmaktadır [2], [3].

### 2. İlgili Çalışmalar

Son yirmi yıl içinde duygu tanımadaki çalışmalar büyük ivme kazanmıştır. Pek çok veritabanı geliştirilmiş ve veritabanları üstünde sayısız çalışma gerçekleştirilmiştir [4], [5], [6]. Teknolojinin gelişmesiyle üstünde çalışılan duygu sayısı artmış ve çok yüksek başarı oranlarına ulaşılmıştır. Ancak bu çalışmalarda önemli sorunlardan biri veri setleri arasında uygulanan testlerde karşılaşılan düşük başarı oranlarıdır. Setler arası, karma setli ve çok setli çalışmalara [7-10] literatürde nispeten daha az rastlanılmaktadır ve bu alanda çözülmeyi bekleyen sorunlar bulunmaktadır.

Oflazoğlu ve Yıldırım [8] TURES (Turkish Emotional Speech Database) ve VAM (Vera am Mittag) veri setlerinde setler arası bir çalışma gerçekleştirmiş ve 3 boyutlu duygu uzayında %41.3 başarı oranı elde etmişlerdir.

Zhang vd. [9] ABC, AVIC, DES, eINTERFACE, SAL ve VAM setlerinde yaptıkları çapraz testlerde iki boyutlu duygu uzayında aktivitede %62.6 ve pozitiflikte ise %55.6 başarı oranı elde etmişlerdir.

Schüller vd. [11] EmoDB'nin test seti, AVIC, DES, eINTERFACE, SmartKOM ve SUSAS'ın eğitim seti olarak kullanıldığı çalışmalarında %35 ile %45 arasında başarı oranları elde etmişlerdir.

ABC, AVIC, DES, EmoDB, eNTERFACE, SAL, SUSAS ve VAM olmak üzere 8 veri setinin kullanıldığı bir çalışmada [12], VAM üstünde eğitim diğer 7 veri seti üstünde de test yapılarak iki boyutlu duygu uzayında aktivitede %67.7 başarı oranı yakalanmıştır. DES üstünde eğitim diğer 7 veri seti üstünde test yapılarak pozitiflik boyutunda %54.8 başarı oranı yakalanmıştır.

### 3. EmoSTAR

Bu çalışmamızda EmoSTAR adlı yeni bir duygu veritabanını tanıtacağız. EmoSTAR televizyon ve internetteki kaynaklardan derlenerek hazırlanmış bir veri setidir. Nötr duygu içeren örnekleri bulmak (haber kanalları gibi) kolay olsa da diğer duyguların toplanmasında büyük zorluklar ortaya çıkmaktadır. Bazı durumlarda arka plandaki sesler ve müzik de sorun oluşturmaktadır. Yapay duygu elde etmek amacıyla katılımcıların doğal halleriyle konuşmaları kolay olmamaktadır.

EmoSTAR 393 kızgın, nötr, mutlu ve üzgün Türkçe ve İngilizce örnekten oluşmaktadır. Nötr örnekler haber kanallarından, kızgın örnekler sinema ve dizilerden, üzgün örnekler internetteki videolardan, mutlu örnekler ise Oscar, Golden Globe gibi ödül törenlerinde ödül alan sanatçıların yaptığı konuşmalardan derlenmiştir. Nötr ve mutlu örnekler doğal konuşma içermektedir. Kızgın örnekler yapay duyguludurlar ve üzgün örnekler çok azı hariç doğal konuşmalardan oluşmaktadır. Örneklerin hepsi farklı cümleler içermektedir ve uzunlukları 2.2 ile 14.5 saniye arasında değişmektedir. Konuşmacı başına örnek sayısı ise 1 ile 29 arasındadır. Kategorik duygu etiketleme yazar tarafından sesli ve görsel değerlendirmeye videoların sahibi tarafından atanan üzgün ve kızgın etiketlerde göz önüne alınarak yapılmıştır. Ayrıntılı sayılar Tablo 1. de verilmiştir.

Üzerinde çalışacağımız diğer veritabanı ise Berlin Duygu Veritabanıdır (EmoDB). EmoDB Tablo 2'de gösterildiği üzere 7 duygu içeren 535 Almanca örnekten oluşmaktadır. Bu örneklerde 5 kısa ve 5 uzun cümle 5 erkek ve 5 kadın tarafından seslendirilmektedir. Pan [5] EmoDB üstünde mutlu, nötr, üzgün sınıflandırmada %95.1 başarı elde etmiştir. Mutlu, nötr, üzgün, sıkın ve tiksinti sınıflandırmasında ise enerji ve prozodi özellikleri %66, LPCMCC (Linear Prediction Coding Mel Cepstrum Coefficients) 70%, her ikisi birlikte %82 başarı sağlamıştır. Wu vd. [6] EmoDB'de çok-sınıflı

SVM ve 10-kat çapraz geçirme ile 7 duygu üstünde %85.4 başarı oranına ulaşmışlardır.

Tablo 1. EmoSTAR'da duygu sayıları (İ=İngilizce, T=Türkçe).

	Kızgın	Nötr	Mutlu	Üzgün
<b>Erkek</b>	33 İ 30 T	35 İ 34 T	45 İ	12 İ
<b>Kadın</b>	40 E	37 İ 20 T	37 İ	51 İ 19 T
<b>Toplam=393</b>	103	126	82	82

Tablo 2. EmoDB'de duygu sayıları.

	K	N	M	Ü	S	T	Ko
<b>Erkek</b>	60	39	27	25	35	11	36
<b>Kadın</b>	67	40	44	37	46	35	33
<b>Toplam=535</b>	127	79	71	62	81	46	69

### 4. Deneysel Kurulum

Deneyler openSMILE [11] ve Weka [12] araçlarıyla gerçekleştirilmiştir. Özellik çıkarma işleminde openSMILE ile beraber gelen Emobase ve Emo\_large konfigürasyonlarında MFCC sayısı 12'den 24'e çıkarılmış ayrıca Harmonic-to-Noise-Ratio özelliği eklenmiştir. Bu dosyalardaki özellik sayıları Tablo3'te gösterilmektedir.

Tablo 3. Konfigürasyonlardaki özellik sayıları.

Konfigürasyon	Özellik Sayısı
<b>Emobase.conf</b>	1482 (39 LLD + 39 delta)*19 fonksiyon
<b>Emo_large.conf</b>	8190 (70 LLD + 70 delta+ 70 delta-delta)*39 fonksiyon

Deneylerin tamamı 10-kat çapraz geçirmeyle Weka'nın Naive Bayes (NB) ve SMO sınıflandırıcılarıyla gerçekleştirilmiştir. EmoDB ve EmoSTAR için ağırlıklı ortalama doğruluk oranları Tablo 4, 5 ve 6'da verilmektedir.

Tablo 4. EmoDB'de 7 duygu için sınıflandırma sonuçları.

EmoDB	Emobase (988)	Emo_large (6669)
<b>NB</b>	57.00	70.46
<b>SMO</b>	<b>87.85</b>	87.28



Tablo 5. EmoDB'de 4 duygu (Kızgın, Nötr, Mutlu, Üzgün) için sınıflandırma sonuçları.

EmoDB	Emobase (1482)	Emo_large (8190)
NB	80.82	84.36
SMO	<b>91.44</b>	91.15

Tablo 6. EmoSTAR'da 4 duygu (Kızgın, Nötr, Mutlu, Üzgün) için sınıflandırma sonuçları.

EmoSTAR	Emobase (1482)	Emo_large (8190)
NB	83.20	86.00
SMO	95.92	<b>96.69</b>

## 5. Veri Setleri Arası Çapraz Testler

Duygu çıkarmadaki 20 yılın ardından tek veri setli çalışmalarda başarı oranı yönünden limitlere ulaşılmış gibi gözükmektedir. Setler arası çapraz testler araştırmacılar için üstesinden gelinmesi gereken yeni bir konu olarak karşımıza çıkmaktadır. Bu tür uygulamalarda tek veri setli uygulamalara göre başarı oranları oldukça düşmektedir. Çapraz testleri veri setlerimizden birini eğitim seti diğerini de test seti olarak kullanarak gerçekleştirdik. EmoSTAR 4 duygu içerdiği için testlerde EmoDB'den de Tablo 7'de gösterildiği gibi 4 duygu kullanılmıştır.

Tablo 7. EmoSTAR ve EmoDB eğitim ve test seti olarak çapraz test sonuçları.

	EmoSTAR Eğitim		EmoDB Eğitim	
	EmoDB Test		EmoSTAR Test	
	NB	SMO	NB	SMO
Emobase	43.65	<b>52.80</b>	41.73	43.00
Emo_large	45.13	<b>64.30</b>	41.98	43.25

## 6. Özellik Seçme

Bir veri setinde en iyi sonucu üreten optimal özellikleri bulmak araştırmacıların en fazla gayret sarf ettikleri konulardan birisidir. Gereğinden fazla özellik kullanmak sınıflandırıcıların başarı oranlarında negatif etki oluşturmaktadır. Bu çalışmada da Tablo 4, 5 ve 6'da bu sorun kendini göstermiştir. Tablo 5'te görüldüğü gibi özellik sayısının 1482'den 8190'a çıkmasına rağmen en başarılı sınıflandırıcı SMO'nun başarı oranında bir düşüş meydana gelmiştir. Bu sorunu çözmek amacıyla özellik seçicilerden yararlanılmaktadır. Özellik seçme için Information

Gain, ChiSquared, Principal Components özellik seçiciler Ranker arama yöntemiyle, CfsSubSet özellik seçici ise Linear Forward Selection arama yöntemiyle kullanılmış ve sonuçlar EmoDB için Tablo 8 ve 9'da, EmoSTAR için Tablo 10 ve 11'de verilmiştir. EmoDB'de InfoG+Rank ve Chi+Rank %88.41 başarı oranına 1074 özellekle ulaşmıştır. Bu oran 1482 ve 8190 özellekle elde edilen oranın üstündedir.

Tablo 8. EmoDB'de özellik seçme (Emobase).

EmoDB	Emobase (1482) ‡	
	NB (57.00)*	SMO (87.85)*
CfsSub+LFS (55) †	76.44	81.68
InfoG+Rank (1074)	69.90	<b>88.41</b>
Chi+Rank (1074) †	69.90	<b>88.41</b>
PCA (145) †	46.91	74.01

\* Özelliklerin tamamıyla elde edilen sonuçlar

† Seçilen özellik sayıları

‡ Tüm özellik sayısı

Aynı özellik seçici Emo\_large konfigürasyonunda da daha az özellekle tüm özellik setinden daha iyi bir başarı oranı elde etmiştir. Emobase konfigürasyonunda Naive Bayes sınıflandırıcının performansında büyük artış meydana gelmiştir. Bu sonuç aşırı özellik sayısının performans üstündeki negatif etkisinin bir kanıtıdır.

Tablo 9. EmoDB'de özellik seçme (Emo\_large).

EmoDB	Emo_large (8190)	
	NB (70.46)*	SMO (87.28)*
CfsSub+LFS (102) †	77.75	83.55
InfoG+Rank (6512) †	70.09	87.28
Chi+Rank (6512) †	69.90	<b>87.47</b>

EmoSTAR'da ise InfoG+Rank ve Chi+Rank %97.20 başarı oranı ile en başarılı seçici olmuş ve Tablo 10 ve Tablo 11'de görüldüğü gibi tüm özelliklerden daha iyi sonuç elde etmiştir. PCA diğerlerine göre zayıf bir performans sergilemiştir. PCA, Emobase konfigürasyonunda 145 özellik seçmesine rağmen en az özellik seçen CfsSubSet seçicinin altında kalmıştır. PCA genellikle 150-200 özellik grubu önermekte ve bunları belli bir sıraya koymamaktadır. En iyi sonucu üreten özellik grubunu bulmak oldukça zor ve zahmetli bir iş olmaktadır. Bu çalışmada ilk önerilen

grup seçilmiş ve en iyi grubu bulmak için bir çalışma yapılmamıştır.

Tablo 10. EmoSTAR'da özellik seçme (Emobase).

EmoSTAR	Emobase (1482)	
	NB (83.20)*	SMO (95.92)*
<b>CfsSub+LFS</b> (75) †	87.27	94.65
<b>InfoG+Rank</b> (1236) †	83.96	<b>96.18</b>
<b>Chi+Rank</b> (1236) †	83.96	<b>96.18</b>
<b>PCA</b> (105) †	72.26	81.67

Tablo 11. EmoSTAR'da özellik seçme (Emo\_large).

EmoSTAR	Emo_large (8192)	
	NB (86.00)*	SMO (96.69)*
<b>CfsSub+LFS</b> (95) †	89.05	94.14
<b>InfoG+Rank</b> (6755) †	85.49	<b>97.20</b>
<b>Chi+Rank</b> (6755) †	84.98	<b>97.20</b>

## 7. Sonuçlar

Makalenin en önemli sonuçlarından biri setler arası çalışmalarda orta düzey başarı oranlarıdır.

8190 özellik kullanan Emo\_large özellik seti EmoSTAR veri setinin eğitim seti olarak kullanıldığı çapraz testlerde güçlü bir performans sergilemiştir. Ancak EmoDB'de tek veri setli çalışmalarda Emobase özellik setinin gerisinde kalmıştır.

Ümit verici bir diğer sonuç ise özellik seçme algoritmalarının çarpıcı performanslarıdır. Özellik seçiciler çok büyük özellik sayılarına rağmen orijinal özellik setlerinden daha iyi başarı oranlarını yakalayabilmiştir.

İleriki çalışmalarda EmoSTAR veri seti daha fazla duygu ve daha fazla örnekle geliştirilecektir. Veri setleri arası çapraz testler de daha fazla veri seti ile gerçekleştirilebilir.

## 8. Kaynaklar

[1] Ramakrishnan, S., "Recognition of Emotion from Speech: A Review", International Journal of Speech Technology, v:15, Issue 2, pp 99-117, 2012.

[2] Black, A. W., Bunnell, H.T., Dou, Y., Kumar, P., Metzger, F., Perry, D., Polzehl, T., Prahallad, K., Steidl, S. ve Vaughn, C., "New Parameterization for Emotional Speech Synthesis", CSLP Proc., Johns Hopkins Summer Workshop, Baltimore, 2011.

[3] Iida, A., Campbell, N., Higuchi, F. ve Yasumura M., "A corpus-based speech synthesis system with emotion", Speech Communication 40 161–187, 2003.

[4] Pan, Y., Shen, P. ve Shen, L., "Speech Emotion Recognition Using Support Vector Machine", International Journal of Smart Home, v:6, no. 2, Apr. 2012.

[5] Schuller, B., Vlasenko, B., Eyben, F., Rigoll, G. ve Wendemuth, A., "Acoustic Emotion Recognition: A Benchmark Comparison of Performances", IEEE Workshop on Automatic Speech Recognition & Understanding, ASRU 2009 Proc., Merano, Dec. 2009.

[6] Wu, S., Falk T.H. ve Chan W., "Automatic speech emotion recognition using modulation spectral features", Speech Communication 2010, doi:10.1016/j.specom.2010.08.013.

[7] Oflazoglu C. ve Yildirim S., "Recognizing emotion from Turkish speech using acoustic features", EURASIP Journal on Audio, Speech, and Music Processing, 2013.

[8] Zhang, Z., Wenginger, F., Wöllmer, M. ve Schuller, B., "Unsupervised Learning in Cross-Corpus Acoustic Emotion Recognition", IEEE Workshop on Automatic Speech Recognition & Understanding, ASRU Proc., Waikoloa, Hawaii, Dec. 2011.

[9] Schuller, B., Vlasenko, B., Eyben, F., Wollmer, M., Stuhlsatz, A., Wendemuth, A. ve Rigoll, G., "Cross-corpus acoustic emotion recognition: variances and strategies", IEEE Transactions on Affective Computing 1(2), 119–131, July-December 2010.

[10] Schuller, B., Zhang, Z., Wenginger, F. ve Rigoll, G., "Selecting Training Data for Cross-Corpus Speech Emotion Recognition: Prototypicality vs. Generalization", 2011 Speech Processing Conference, AVIOS Proc., Telaviv, June 2011.

[11] Eyben, F., Wöllmer, M. ve Schuller, S., (2009). "openSMILE - The Munich Versatile and Fast Open-Source Audio Feature Extractor", In Proc. ACM Multimedia (MM), ACM, Florence, Italy, ACM, ISBN 978-1-60558-933-6, pp. 1459-1462, October 2010. doi:10.1145/1873951.1874246

[12] Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I.H., (2009). "The WEKA data mining software: an update". SIGKDD Explor. Newsl. 11, 10–18 (2009).



# ÖZDEĞER HESAPLAMASI VE YAPAY ARI KOLONİ ALGORİTMASI KULLANILARAK TERMAL GÖRÜNTÜLERİN BÖLÜTLENMESİ

MücahitÇALIŞAN<sup>1</sup>, Kazım HANBAY<sup>2</sup>, İbrahim TÜRKOĞLU<sup>3</sup>

<sup>1</sup>Bilgisayar Programcılığı Bölümü, Teknik Bilimler MYO, BİNGÖL Üniversitesi, BİNGÖL

<sup>2</sup>Bilgisayar Programcılığı Bölümü, Teknik Bilimler MYO, BİNGÖL Üniversitesi, BİNGÖL

<sup>3</sup>Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, FIRAT Üniversitesi, ELAZIĞ

Email: [mcalisan@bingol.edu.tr](mailto:mcalisan@bingol.edu.tr) [khanbay@bingol.edu.tr](mailto:khanbay@bingol.edu.tr) [iturkoglu@firat.edu.tr](mailto:iturkoglu@firat.edu.tr)

## Özet

*Termal görüntülerin bölütlenmesi bu görüntülerin analizinde önemli bir aşamadır. Çünkü görüntüdeki termal nesnelere ayırt edilmesi için arka planda bulunan diğer nesnelere yok edilmesi gerekmektedir. Ayrıca termal görüntülerde çoklukla bulunan gürültü nedeniyle bölütleme işleminin önemi artmaktadır. Bu çalışmada Hessian matrisi ve bu matrisin özdeğerleri kullanılarak etkili ve hızlı bir bölütleme metodu önerilmiştir. Öz değer bilgileri kullanılarak 256 × 256 boyutunda gri seviye eş oluşum matrisi oluşturulmuş ve entropi hesaplamasında kullanılmıştır. Eşik değeri hesaplamak için Shannon entropi fonksiyonu kullanılmıştır. Bu fonksiyonu optimize etmek için Yapay Arı Koloni algoritmasından faydalanılmıştır. Geliştirilen metod güncel iki metod ile bölütleme kalitesi açısından karşılaştırılmıştır. Elde edilen sonuçlar önerilen metodun etkili ve hızlı bölütleme yaptığını göstermiştir.*

**Anahtar Kelimeler:** Görüntü İşleme, Hessian matrisi, Termografî, Yapay Arı Koloni, Bölütleme

## 1. Giriş

Termal kameralar insan gözünün göremediği bantlarda ki görüntüyü alarak bu görüntünün görülebilir hale getirilmesini sağlayan sistemlerdir. Termal görüntü genelde gözlemlenen nesne ve arka planı tarafından yayılan kızılötesi radyasyonu görselleştirmek olduğundan termal kameradan çıkan görüntü önemli ölçüde farklıdır. Görselleştirilen bu ısı sahnenin bir insan tarafından anlaşılması çoğu zaman güçleşir. IR görüntü yorumlamada ölçü, gözlenen nesne ve çevresinin özellikleri tarafından etkilenir. Kameranın odak sıcaklık ayarları, ölçümleme ayarları gibi özellikler optimum olmalıdır [1]. Termal görüntü insan gözü tarafından algılanan alanın içerisine kızılötesi dedektörlerin ulaşip termal radyasyonu dönüştürmesi ile oluşturulur. Dedektörde olay başta emisyon olmak

üzere kızılötesi radyasyon seviyesinin bir çok faktöre bağlı olmasıdır [2]. Termografik görüntüleri alma ve aktarmada sayısal görüntüleme işlemindeki olumsuz şartlar nedeniyle görüntülerde bozulmalar oluşabilmektedir. Bu olumsuzluklar hem ortamdaki hem de kameranın yapısından kaynaklanmaktadır. Bilgisayarlı görme teknikleri sürekli iyileştirmeler ile otomatik düşük maliyetli video izlemelerini mümkün hale getirebilmektedir. Dış mekân çekimlerinde yayaların tespitini doğru modellemek için önemli bir sorun olan bölütlemenin iyi yapılması gerekir. Böylece akıllı otomatik video gözetim sistemleri daha başarılı çalışır. Son yıllarda çokça çalışma, insan etkinliğini tespit ederek, izlemek ve tanımak amacıyla gerçekleştirilmiştir. Gauss karışım modelini (GMM) kullanan çalışmada yayalar kısmi olarak belirtilmektedir [3]. Yapılan diğer bir çalışmada ise kentsel ortamlarda kalıcı nesne tespiti için termal ve görünür görüntülerin hatlarını kaynaştırarak Sonsuz Gauss Karışım Modeli (IGMM) kullanılarak arka plan çıkarma tekniği sunulmuştur [4].


## 2. Termal Görüntüleyiciler

Termografik görüntülerin elde edilmesine yarayan termal kameralar cisimlerden yayılan ışınının uzaktan algılanmasını sağlar. -273°C'nin üzerindeki tüm cisimler belli bir sıcaklığa sahip olmalarından dolayı kızılötesi ışınım yayarlar. Stefan-Boltzmann (1) kanununa göre cisimlerin sıcaklığı arttıkça, salınan ışınım miktarı da sıcaklığın 4. kuvveti ile artmaktadır.

$$J = \sigma T^4 \quad (1)$$

Burada  $J$  yüzeyden ışınan enerji,  $\sigma$  Stefan-Boltzmann sabiti,  $T$  ise cisim yüzey sıcaklığıdır.

Termal kameralar nesne ile temas gerçekleştirilmeden sıcaklık modellerini esas alan ve görüntünün genel yapısını bu sıcaklığa göre oluşmuş renklerin belirlediği görüntüleme sistemidir. Şekil 1'de termal kameranın şematik görünümü verilmiştir.




Şekil 1. Termal kameranın şematik görünümü [5].

Termal kameralar elde ettikleri görüntüleri kızılötesi ışınmayı tespit eden lensler kullanarak elde edebilmektedirler. Lenslerden elde edilen IR ışınma değerleri sayısal değerlere çevrilir ve Şekil 2 ve 3'te görüldüğü üzere yüzey sıcaklık değerlerine karşılık gelecek şekilde farklı renklerle belirtilerek siyah-beyaz veya renkli termografik görüntü elde edilir.



Şekil 2. Termal kameranın siyah-beyaz görüntüsü



Şekil 3. Termal kameranın renkli görüntüsü

### 3. Termal Görüntülerin Analizi

Çevremizdeki tüm nesnelere sahip oldukları sıcaklığa bağlı olarak farklı dalga boylarında yoğunluk değişimi gösteren termal radyasyon olarak da adlandırılan elektromanyetik enerji yayırlar. Termal sistemlerin temeli de kızılötesi ışımaya dayanır. Yani bir cisim tarafından yayılan ısıdan yararlanarak onun görüntüsü üretilmektedir. Bu yayılan enerji nesnenin gerçek karakterize özelliği olan nesnenin ışık yayılım gücü ( $\epsilon$ ) düzeyindedir. Yayıma yüzeyi parametrelerin kimyasal özelliklerinin bir fonksiyonu olan sıcaklık ve dalga boyuna bağlıdır ( $\lambda$ ). Opak nesnelere için, Kirchhoff yasasına göre aşağıdaki ilişki yazılabilir [2]:

$$\epsilon_\lambda + \rho_\lambda = 1 \quad (2)$$

Bu ifade ışık yayılım gücü ( $\epsilon$ ) ve yansıtma ( $\rho$ ) arasındaki ilişkiyi açıklar. Yüksek emisyonlu bir nesne çevre radyasyonunu çok az yansıtan anlamına gelir. Her pikselin parlaklığı emisyonu ile sıkı sıkıya bağlantılıdır. Bu bakış açısı imaj oluşturulması açısından son derece önemlidir [6].

Termal görüntülerin seçilmesinde aşağıdaki özellikler etkindir:

- Düşük çözünürlüklü ve düşük kontrastlıdır.
- Açıkça görülebilir kenarları yoktur.
- Düşük görüntü netliği.
- Dizi dedektör nedeniyle net görünür gürültü.

Yukarıda açıklanan termal görüntülerin özellikleri bazen etkili gözlemi zorlaştırmakta hatta bazen imkânsız hale getirmektedir. Görüntü analizi yapılırken her adımda amaca uygun bir takım işlemler gerçekleştirilmektedir. Görüntüye uygulanacak işlemler sonrasında sistemin çıkışı yeni bir görüntü, giriş görüntüsünün bir kısmı veya giriş görüntüsündeki nesnelere olabilir.

Termal görüntüleyicide öncelikle dizi kamera görüntüsünden iki boyutlu imge elde edilir, sonraki aşamada ise bu görüntüdeki dedektör farklılıkları giderilir. Sonrasında histogram eşleme algoritmalarından biri kullanılarak görüntü ekrana verilir. Alınan termal görüntünün anlaşılabilir olması için görüntüdeki gürültünün azaltılması, kenarların belirginleştirilmesi, görüntünün göz ile fark edilebilir şekle dönüştürülmesi için genel teknikler kullanılır. Genelde karşıtlık, histogram, filtreleme, keskinleştirme, sahte renklendirme ve değişiklikleri büyütme gibi teknikler kullanılmaktadır. İşlenecek görüntünün özelliklerine ve amaca uygun görüntü işleme tekniklerinin belirlenmesi çok önemlidir.

Görüntülerinin analiz edilmelerinde öncelikli olan durum görüntü üzerinde ilgilenilen kısım ve geri kalanı arasındaki farkı ayırt etmektir. Bu da görüntü detayının ölçülerek, sayılarak ve boyutlandırılarak nesnelere tanınması işlemidir. Görüntü analizinde giriş görüntü iken, görüntü geliştirme süreci sonunda çıkışta görüntüden elde edilen özellikler vardır. Görüntü geliştirme süreci tabii ki görüntü bilgi miktarını arttırmaz. Tüm bilgiler zaten var ama görüntü artırılması suretiyle belirli özellikleri yorumlamak, dolayısıyla daha kolay anlaşılır bazı ayrıntıları fark edebilir hale gelir.

### 4. Önerilen Yöntem

Bu çalışmada Hessian matrisinin öz değerleri, Shannon entropi fonksiyonu ve yapay arı koloni algoritması kullanılarak termal görüntülerin bölütlemesi gerçekleştirilmiştir. Genellikle gradient hesaplaması ile elde edilen türev bilgisinin yerine, bu çalışmada orijinal termal görüntünün Hessian matrisi ve bu matrisin Öz değer analizi yapılmıştır. Geleneksel gradient hesaplamasında görüntü ve arka plan arasındaki değişimleri tespit etmek için basit piksel farkına dayanan bir türev hesaplama yöntemi kullanılmaktadır. Gradient iki boyutlu bir vektör niceliği olup pikseller hakkında hem yön hem de büyüklük bilgisi içerir [7]. Bir  $I(x, y)$  görüntüsünün gradient'i aşağıdaki gibi hesaplanır:

$$\nabla I(x, y) = \begin{bmatrix} I_x(x, y) \\ I_y(x, y) \end{bmatrix} \quad (3)$$

$$\begin{aligned} I_x &\cong I(x + 1, y) - I(x, y), \\ I_y &\cong I(x, y + 1) - I(x, y) \end{aligned} \quad (4)$$

Burada  $I_x$  ve  $I_y$  görüntünün sırasıyla yatay ve dikey gradient bilgileridir. Denklem 3 ve 4'de görüleceği gibi yapılan işlem basit bir fark alma işlemidir. Ancak, bir  $I_x$  görüntüsünün lokal davranışlarını daha detaylı analiz etmek için, görüntünün ikinci mertebeden türev bilgisinden oluşan Hessian matrisi kullanılabilir. Hessian matrisi karesel ve simetrik bir matris olup bir fonksiyonun ikinci mertebeden kısmi türevlerinden oluşur [6]. Gri seviye bir görüntüdeki bir noktanın  $\sigma$  ölçeğinde Hessian matrisi aşağıdaki gibi ifade edilir:

$$H\sigma(x, y) = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{yx} & I_{yy} \end{bmatrix} \quad (5)$$

Burada  $I_{xx}$ ,  $I_{yy}$ ,  $I_{yx}$  görüntünün sırası ile  $x$ ,  $y$ ,  $xy$  yönlerindeki ikinci mertebeden türev bilgileridir. Klasik gradient hesaplaması ile karşılaştırıldığında, Hessian matrisi görüntüdeki temel yönlerin elde edilmesinde gradient'e göre daha uygundur. Çünkü Hessian matrisindeki ikinci mertebeden türev bilgisi görüntülerde doku bilgilerinin değişimlerini elde etmede gradient'e göre daha ayırt edici bilgi sunmaktadır [6]. Hessian matrisinin öz değer-öz vektör analizinin arkasındaki temel neden ise, görüntü yüzeyindeki temel yönleri ve temel eğrilikleri tespit etmektir. Bu nedenle, görüntünün ikinci mertebeden yapısının detaylı bir biçimde analiz edilmesi gerekir. Hessian matrisinin öz değerleri aşağıdaki gibi elde edilebilir [8]:

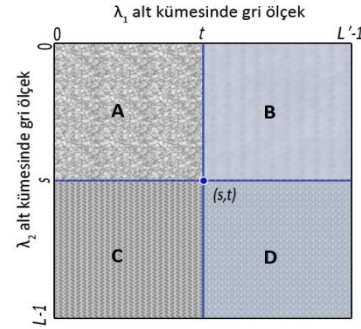
$$\lambda = \pm \sqrt{\frac{(I_{xx} - I_{yy})^2}{4} + (I_{xy})^2} + \frac{I_{xx} + I_{yy}}{2} \quad (6)$$

Buradan elde edilecek  $\lambda_1$  ve  $\lambda_2$  öz değer matrisleri görüntü hakkında kıymetli bilgiler içermektedir. Bu çalışmada hesaplanan iki öz değer bilgisi kullanılarak  $L \times L'$  boyutunda  $\lambda_1 - \lambda_2$  eş oluşum matrisi  $C = [c_{ij}]_{L \times L'}$  inşa edilmiştir. Burada  $L = L' = 256$ 'dır ve görüntüdeki gri seviye sayısını ifade eder. Gri seviye oluşum matrisi termal görüntünün tüm karakteristiğini içermekte olup, sonraki adımda entropi fonksiyonunda kullanılmıştır. Oluşturulan bu matriste  $c_{ij}$  ifadesi  $\lambda_1(m, n) = i$  ve  $\lambda_2(m, n) = j$  şartını sağlayan piksel çiftlerinin sayısını ifade etmektedir. Bu yüzden eş oluşum matrisindeki  $c_{ij}$  olasılığını ifade eden  $p_{ij}$  ifadesi aşağıdaki gibi hesaplanmıştır:

$$p_{ij} = \frac{c_{ij}}{\sum_{i=0}^{L-1} \sum_{j=0}^{L'-1} c_{ij}} \quad (7)$$

Oluşturulan iki boyutlu eş-oluşum matrisinde görüntüyü eşikleyecek piksel değerinin koordinatları  $(s, t)$  ile ifade edilirse, bu  $(s, t)$  değerleri eş oluşum matrisini Şekil 4'de görüldüğü gibi dört alt bölgeye

ayırır. Burada  $s$  değeri  $\lambda_1$  görüntüsünün eşik değeri,  $t$  ise  $\lambda_2$  görüntüsünün eşik değerini ifade etmektedir.



Şekil 4.  $\lambda_1$  ve  $\lambda_2$  bilgileri ile elde edilen gri seviye eş oluşum matrisi

Şekil 4'de A, B, C, D bölgeleri dört alt bölgeyi ifade etmektedir. Eğer A ve C bölgeleri sırasıyla termal nesne ve arka planı, B ve D bölgelerinin ise sırasıyla termal nesnelere kenar ve doku bilgileri ile arka plandaki kenar ve doku bilgilerini temsil ettiği varsayıldığında, bu bölgelerin Shannon entropisi aşağıdaki gibi hesaplanır [9]:

$$H_{grey}(s, t) = \frac{1}{2} \left[ \left( -\sum_{i=0}^s \sum_{j=t+1}^{L'-1} p_{ij}^B \log_2 p_{ij}^B \right) + \left( -\sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L'-1} p_{ij}^D \log_2 p_{ij}^D \right) \right] \quad (8)$$

Bu bölgelerin optimum entropi değerleri yukarıdaki gibi hesaplanarak termal görüntüyü bölütleyecek en uygun eşik değeri tespit edilir. Elde edilen  $(s, t)$  değerlerinden maksimum olanı bölütlemeye eşik değeri olarak kullanılır.

Geliştirdiğimiz yöntemde Shannon entropi fonksiyonunu optimize etmek için Yapay Arı Koloni algoritması kullanılmıştır. Yani Shannon fonksiyonu Yapay Arı Koloni algoritmasının uygunluk fonksiyonu olarak kullanılmıştır. Yapay arı koloni algoritması 2005 yılında Derviş Karaboğa tarafından geliştirilmiştir [10]. Nümerik fonksiyon optimizasyonu için önerilen yapay arı koloni algoritması, doğal arı kolonilerinin davranışlarını temel alıp matematiksel olarak modelleyen bir optimizasyon algoritmasıdır. Kaynağını gerçek doğadan alan algoritmaların yeni bir dalı olan bu algoritma, arıların içgüdülerinden gelen problem çözme becerilerini kullanan etkili metasezgisel yöntemler geliştirebilmek için arı davranışlarının modellenmesine odaklanmıştır. Görüntü işleme alanında çok fazla kullanılmayan bu algoritma bazı bölütleme çalışmalarında kullanılmıştır [11]. Bu çalışmada kullanılan Yapay Arı Koloni algoritmasının parametreleri Tablo 1'de görüldüğü gibi ayarlanmıştır.

Tablo 1. Bu çalışmada kullanılan Yapay Arı Koloni algoritmasının parametre değerleri.


Parametre	Değeri
Arı sayısı (işçi+gözcü)	20
Maksimum çevrim sayısı	30
Limit	10
Çalıştırma sayısı	1
Amaç fonksiyonu	Shannon

## 5. Deneysel Sonuçlar

Bu bölümde önerilen termal görüntü bölütleme metodunun uygulama sonuçları sunulmuştur. Geliştirilen metot, GMM ve MaG metotları ile bölütleme doğruluğu açısından karşılaştırılmıştır. Karşılaştırma yapılan metotların sonuçları orijinal makalelerinden alınmıştır. Uygulamalarda kullanılan sonuçlar OTCBVS termal görüntü veri tabanından alınmıştır [12]. Görüntü bölütleme çalışmalarının doğruluğunu ölçmede kullanılan birçok kriter vardır. Bu çalışmada bölütleme doğruluğunu ölçmek için Pratt'ın FOM (Figure Of Merit) kriteri kullanılmıştır [13]. FOM kriteri aşağıdaki gibi ifade edilmektedir:


$$FOM = \frac{1}{\max\{E_D, E_I\}} \sum_{i=1}^{E_D} \frac{1}{1+\alpha(d_i)} \quad (9)$$

Burada  $E_D$  ve  $E_I$  sırasıyla tespit edilen ve ideal obje kenarları göstermektedir.  $d_i$  tespit edilen kenar noktasının ideal kenar noktasına uzaklığını,  $\alpha$  ise 1 olarak aldığımız ölçekleme sabitidir. FOM değerinin 1 olması mükemmel bölütlemeyi ifade etmektedir. Şekil 5'de üç görüntü üzerinde elde edilen sonuçlar görülmektedir. Şekil 5-b'de görüleceği gibi GMM metodu termal nesnelere gürültülü bir biçimde bölütlemiştir. Dolayısıyla arka plan ve nesnelere arasında yeteri ölçüde ayırım yapılamamıştır. Ayrıca görüntüdeki termal nesnelere sınırları yeteri kadar doğru elde edilememiştir. Önerilen metot ise (Şekil 5-c) gürültüye karşı oldukça keskin ve daha doğru nesne sınırları elde edebilmiştir.



Şekil 5. Önerilen metot ile GMM metodunun bölütleme sonuçları.

Tablo 2'de Şekil 5'deki bölütleme sonuçlarına ait FOM kriteri sonuçları görülmektedir. FOM sonuçlarından da görüleceği gibi ikinci mertebeden analiz sayesinde daha ayırt edici öznelikler elde edildiği için önerilen metot daha yüksek FOM değerlerine sahiptir. Termal görüntülerin ikinci mertebeden analizleri bize kenar bilgisinin yanında nesnelere köşe bilgilerini de kullanma imkânı sağlamıştır.



Şekil 6. Önerilen metot ile IGMM metodunun bölütleme sonuçları.

Şekil 6'da ise IGMM metodu ile önerilen yöntemle ait sonuçlar verilmiştir. Şekil 6-a'da görüldüğü gibi orijinal termal sokak görüntülerinde insan ve diğer nesnelere çoklukla bulunmaktadır. Ayrıca insan ve diğer nesnelere parlaklık değerleri birbirine çok yakın olduğu için istenen ölçüde bölütleme yapmak zordur. Ancak önerilen yöntem IGMM yöntemine göre arzu edilen insan bölütlemesini daha doğru olarak gerçekleştirmiştir (Şekil 6-c). Bölütleme sonuçlarına ait FOM sonuçları da bunu göstermektedir. Geliştirdiğimiz metot sayesinde görüntünün her bir pikseline ait öz değer bilgileri hesaplandığı için piksellerin davranışları en ayrıntılı olarak analiz edilebilmiştir.

Tablo 2. Şekil 5'deki bölütlemelere ait FOM sonuçları.

İmge	Önerilen metot	GMM metodu
Birinci satır	0.5412	0.3895
İkinci satır	0.4862	0.3248
Üçüncü satır	0.5246	0.4765

Geliştirilen metotta bir boyutlu Gaussian filtreleri kullanılarak iki boyutlu konvolüsyon işlemine dayanarak türev hesaplaması yapılmıştır. Bu nedenle Hessian matrisinin hesaplanması daha hızlı yapılmıştır. Bu nedenle önerilen metot hızlı çalışmaktadır. Ayrıca Yapay Arı Koloni algoritmasının optimum entropi değerine hızlı yakınsaması nedeniyle önerilen metodun zaman hesaplama maliyeti oldukça düşüktür. Karşılaştırmada kullanılan metotların çalışma zamanları hakkında herhangi bir bilgi verilmediği için herhangi bir zaman karşılaştırması yapılamamıştır. Ancak Yapay Arı Koloni

algoritması neredeyse ilk iterasyonlarda optimum eşik değeri hesaplamaktadır.

Tablo 3. Şekil 6'daki bölütlemelere ait FOM sonuçları.

İmge	Önerilen metot	IGMM metodu
Birinci satır	0.4512	0.4012
İkinci satır	0.4378	0.3168

## 6. Sonuçlar

Bu çalışmada Hessian matrisi ve onun öz değerleri kullanılarak termal görüntülerin bölütlemesi gerçekleştirilmiştir. Termal görüntülerin bölütlenmesinde literatürde pek sık rastlanmayan Hessian matrisi, öz değerler ve Yapay Arı Koloni Algoritması birlikte kullanılarak optimum entropi değerinin hesaplanması gerçekleştirilmiştir. Termal görüntülerin detaylı karakterizasyonlarını sağlamak için gradient gibi birinci mertebeden yöntemler yerine Hessian matrisi gibi ikinci mertebeden diferansiyel analiz metotları kullanılmıştır. Elde edilen bölütleme sonuçları önerilen metodun genel olarak hızlı ve etkili bir bölütleme gerçekleştirdiğini göstermiştir. Bazı görüntülerde termal nesnelerin tüm noktaları tam olarak elde edilemese de, yapacağımız daha sonraki çalışmalarda önerilen metodun daha kesin ve etkili sonuçlar vermesini sağlayacağız.

## 7. Kaynakça

- [1] M. Vollmer, K.-P. Möllmann, "Infrared Thermal Imaging," Wiley-VCH VerlagGmbH, Weinheim, 2010.
- [2] JS ACCET, the DL Shumaker, "Infrared and Electro-Optical Systems Handbook," AnnArbor, MI, and SPIE Press' Bellingham, WA, 1993.
- [3] T. Elguebaly, N. Bouguila, Finite asymmetric generalized Gaussian mixture models learning for infrared object detection, Computer Vision and Image Understanding, 117 (2013) 1659–1671.
- [4] J. Davis, V. Sharma, Background-subtraction using contour-based fusion of thermal and visible imagery, Computer Vision and Image Understanding 106(2–3) (2007) 162–182.
- [5] Çalışan, M., 2013, Termal Kamera Görüntülerinin İyileştirilmesi, Yüksek Lisans Tezi, F.Ü. Fen Bilimler Enstitüsü, Elazığ.
- [6] R. Dulski, T. Piatkowski, P. Trzaskawka, M. Kastek, Testing of IR Image Enhancement Algorithm on Maritime Objects, Photonics and Optoelectronics (SOPO) Symposium, 2012.
- [7] M.P. DocARMO, Differential Geometry of Curves and Surfaces, Prentice-Hall, 1976.
- [8] JunZhang, HengZhao, JiminLiang, Continuous rotation invariant local descriptors for texture dictionary-based texture classification, Computer Vision and Image Understanding, Volume 117, Issue 1, January 2013, Pages 56-75.

- [9] MiaoMa, JianhuiLiang, MinGuo, Yi Fan, YilongYin, SAR image segmentation based on Artificial Bee Colony algorithm, AppliedSoft Computing 11 (8) (2011) 5205-5214.
- [10] D. Karaboga, B. Basturk, A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, Journal of Global Optimization 39 (3) (2007) 459–471.
- [11] Hanbay, K., Talu, M.F., Karci, A., Segmentation of color texture images with artificial bee colony algorithm and wavelet transform, Signal Processing and Communications Applications Conference (SIU), 2012 20th, pp.1,4, 18-20 April 2012.
- [12] <http://www.cse.ohio-state.edu/otcbvs-bench/>, (14.11.2013)
- [13] I.E. Abdou, W.K. Pratt, Quantitative design and evaluation of enhancement / thresholding edge detectors, Proceedings of the IEEE 67 (5) (1979) 753–763.

# Biyomedikal Veri Kümeleri Kullanarak Makine Öğrenmesi Sınıflandırma Algoritmalarının Karşılaştırılması

Murat KARAKOYUN<sup>1</sup> Mehmet HACIBEYOĞLU<sup>2</sup>

<sup>1,2</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik ve Mimarlık Fakültesi  
Necmettin Erbakan Üniversitesi, Meram, KONYA

mkarakoyun@konya.edu.tr

hacibeyoglu@konya.edu.tr

## Özet

Günümüzde bilişim teknolojileri hemen hemen her alanda kullanılmaktadır. En çok kullanılan alanlardan bir tanesi de sağlık sektörüdür. Dijital hastane sistemlerinin kullanılmasıyla birlikte hasta verileri artık bilgisayar ortamında saklanmakta ve böylelikle biyomedikal veri kümeleri oluşmaktadır. Boyut olarak çok büyük olan bu veri kümelerinin bir insan tarafından analiz edilmesi ve yorumlanması çok zordur. Bunun için bilgisayar mühendisliği çalışma alanlarından biri olan makine öğrenmesi algoritmaları kullanılır. Bu çalışmada K-en Yakın Komşu, Naive Bayes, Destek Vektör Makineleri ve CN2 makine öğrenmesi algoritmalarının başarımları biyomedikal veri kümeleri üzerinde test edilmiştir. Elde edilen deney sonuçlarına göre Destek Vektör Makineleri algoritmasının ortalama en az %0.66 oranında diğer algoritmalarından daha başarılı sonuçlar verdiği görülmüştür.

## 1. Giriş

Günümüzde sağlık alanındaki problemlerin çözümü için, özellikle hastalıkların teşhisi konusunda, doktorların kararına destek olabilecek yapay zekâ temelli önemli çalışmalar yapılmaktadır. Yapay zekânın bir alt dalı olan sınıflandırma algoritmaları da bu alanda kullanılabilir. Öncelikle sınıflandırma algoritmaları hastalıklar ile ilgili geçmişe yönelik hasta verilerini kullanarak kendisini eğitir. Eğitimi tamamlandıktan sonra algoritma olası hastalar ve hastalıklar için hastalık teşhisinde kullanılabilir.

Jin Huang ve arkadaşları Naive Bayes (NB), Karar Ağaçları (KA) ve Destek Vektör Makinelerini (DVM) kullanarak çeşitli veri kümeleri üzerinde veri sınıflandırma yapmışlardır [1].

E. Kaya ve arkadaşları, NB, k-En Yakın Komşu (k-EYK) , C4.5 Karar Ağaçları Algoritması ve DVM algoritmalarını kullanarak Parkinson veri kümesi üzerinde sınıflandırma yapmışlardır [2].

Kai Fu ve arkadaşları, Hilbert -Huang dönüşüm metodu ile beraber DVM algoritmasını kullanarak EEG veri kümesi üzerinde sınıflandırma işlemi gerçekleştirmiştir [3].

Bu çalışmada 4 adet biyomedikal veri seti üzerinde deneyler yapılmıştır. Kullanılan sınıflandırma algoritmaları ise literatürde sıklıkla kullanılan k-EYK [4], NB [5], CN2 [6] ve DVM [7] algoritmalarıdır.

## 2. Materyal ve Metot

### 2.1. Materyal

Bu çalışmada kullandığımız, UCI [8] veri ambarından alınan veri kümelerinin sınıf sayısı, özellik sayısı ve örnek sayısı özellikleri Tablo 1' de gösterilmektedir.

Tablo 1. Kullanılan veri kümelerinin özellikleri

Veri Seti	Sınıf sayısı	Özellik sayısı	Örnek sayısı
Dermatology	6	34	366
Echocardio	2	12	132
EEG Eye	2	14	14980
Breast cancer	2	10	699

Dermatology: Ciltte oluşan kızarıklık, sertleşme, kaşıntı, yumuşama, kepeklenme, çatlama; kafa derisi, diz ve el dirseklerinde hastalığın görülme düzeyi gibi medikal özellikler kullanılarak hastanın hastalık sınıfı tahmin edilmektedir. Hastalık sınıfları: Sedef Hastalığı, Seboreik Egzama, Liken Planus, Pitriyazis Rozea, Kronik Deri İltihabı, Pitriyazis Rubra Pilar.



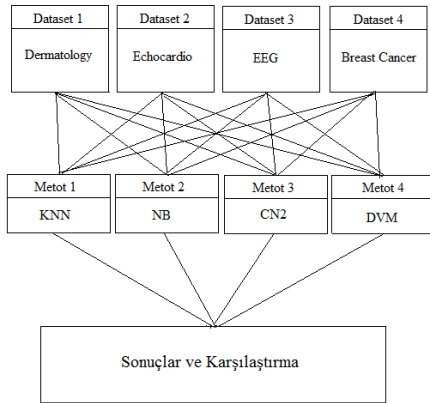
Echocardio: Kalp krizi yaşandıktan sonra hastanın kalp hareketlerinden oluşan nitelikler kullanılmaktadır. Örnek olarak kalp kesesinde sıvı toplanıp toplanmadığı, kalpte kısmı yağlanma oranı, kalbin kasılma durumu, kalbin sol karıncıklarındaki hareket durumu gibi değerler göz önünde bulundurulur. Bu özelliklerin yanında hastanın krizden sonra hayatta olup olmadığı, değilse hayatta kaldığı süre dikkate alınmaktadır. Tüm bu özelliklerin kullanılması ile hastanın 1 yıla yakın bir süre içinde hayatta kalıp kalmadığı sonucu elde edilmektedir.

EEG Eye State: Kafatasının belli bölgelerinden elektrotlar vasıtasıyla alınan elektriksel işaretler özellik olarak kullanılmaktadır. Sınıflandırma işlemi gözün açık veya kapalı olmasına göre belirlenir.

Breast Cancer: Hastalık bölgesindeki tümörlü alanın özellikleri sınıflandırmada nitelik olarak kullanılmaktadır. Örneğin: tümörlü bölgenin kalınlığı, tümörlü hücrelerin şekil ve büyüklük olarak birbirine benzemesi oranı, tümörün vücuda yapışma oranı gibi özellikler. Bu özelliklerin kullanılması ile tümörün iyi huylu veya kötü huylu olması sonucu elde edilir.

## 2.2. Metod

Bu çalışmada kullanılan metodlar ve çalışmanın akış diyagramı Şekil 1'de gösterilmektedir.



Şekil 1. Yapılan çalışmanın akış diyagramı

### 2.2.1. K-En Yakın Komşu Algoritması

K-En Yakın Komşu algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesnelere sınıflandıran, en basit örüntü tanıma yöntemlerinden birisidir. Bu algoritma verilen  $k$  değeri kadar en yakın komşunun sınıfına göre sınıflandırma işlemi yapmaktadır.  $k$ -EYK algoritmasında bir vektörün sınıflandırılması, sınıfı bilinen vektörler kullanılarak yapılmaktadır. Test edilecek örnek, eğitim

kümesindeki her bir örnek ile tek tek işleme alınır. Test edilecek örneğin sınıfını belirlemek için eğitim kümesindeki o örneğe en yakın  $k$  adet örnek seçilir. Seçilen örneklerden oluşan küme içerisinde hangi sınıfa ait en çok örnek varsa test edilecek olan örnek bu sınıfa aittir denilir. Örnekler arası uzaklıklar *Öklid (Euclidean)* uzaklığı ile bulunur [9]. (1) numara ile gösterilen formül,  $n$  boyutlu 2 nokta arasındaki uzaklığı veren Öklid uzaklık formülüdür.

$$d(x, y) = \sqrt{\sum_i^n (X_i - Y_i)^2} \quad (1)$$

### 2.2.2. Naive Bayes Algoritması

Naive Bayes Sınıflandırıcısı Bayes teoremine dayanan basit bir olasılıksal sınıflandırma yöntemidir. Mevcut sınıflanmış durumdaki örnek verileri kullanarak yeni bir verinin mevcut sınıflardan herhangi birine ait olma olasılığını hesaplayan bir yaklaşımdır. Bu sınıflandırıcıda nitelikler birbirinden bağımsız olarak kabul edilir. Örneklerin hepsi aynı derecede öneme sahiptir. Bir özelliğin değeri başka bir özellik değeri hakkında bilgi içermez.

Her biri  $n$  adet nitelikten oluşan ve  $m$  adet sınıftan herhangi birine dâhil olan bir veri seti üzerinde çalıştığımızı düşünelim. Bu durumda hangi sınıfa ait olduğu bilinmeyen yeni bir  $X$  örneği sınıflandırılmak istendiğinde, (2) numaralı formül kullanılarak örneğin her sınıf için, o sınıfa ait olma olasılığı hesaplanır. Bu değerler içerisinde en yüksek olasılığa sahip olan sınıf örneğin ait olduğu sınıf olarak kabul edilir.

$$P(S_i|X) = \frac{P(X|S_i) * P(S_i)}{P(X)} \quad (2)$$

$P(S_i|X)$ :  $X$  olayı gerçekleştiğinde  $S_i$  olayının gerçekleşme olasılığı,

$P(X|S_i)$  :  $S_i$  olayı gerçekleştiğinde  $X$  olayının gerçekleşme olasılığı,

$P(S_i), P(X)$  :  $S_i$  ve  $X$  olaylarının önsel olasılığıdır.

Her bir  $X$  örneğinin aynı derecede öneme sahip olması sebebiyle  $P(X)$  değeri her örnek veri için aynıdır. Bu durumda (2) numaralı formülümüzü, (3) numaralı formül biçimine sadeleştirebiliriz.

$$P(S_i|X) = P(X|S_i) * P(S_i) \quad (3)$$

Her bir sınıf için (3) numaralı formül uygulanıp olasılıklar hesaplandıktan sonra örneğin ait olduğu sınıf bulunur [10].

### 2.2.3. CN2 Algoritması


CN2 bir öğrenme algoritmasıdır ve üzerinde çalışılacak veri kümesinde kurallar oluşturmaya yönelik geliştirilmiştir. Veri kümesindeki gürültülü örneklerden kaynaklanan problemlerle ilgilenir. Bunun için bir dizi kural oluşturur ve karar ağacında budama yapabilecek istatistiksel teknikler sunar [11].

### 2.2.4. Destek Vektör Makineleri

Destek Vektör Makineleri Vapnik tarafından geliştirilmiş ve istatistiksel öğrenme teorisi alanında ortaya çıkmış bir öğrenme metodudur [12]. Sınıflandırma için, bir düzlemde bulunan örnekler arasına bir sınır çizerek iki gruba ayırır. Bu sınırın çizileceği yer ise iki grubun da üyelerine en uzak olan yer olmalıdır. Sınırın çizilmesi için iki gruba da yakın ve birbirine paralel iki çizgi çizilir ve bu çizgiler birbirine yaklaştırılarak sınır çizgisi üretilir. DVM yöntemi, veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır.


DVM, basit bir yapısı olması ve pratik uygulamalarda yüksek performans göstermesi bakımından oldukça kullanışlıdır. DVM'lerde kullanılacak örnek sayısı önemli değildir. DVM eğitim esnasında görülmemiş verileri de sorunsuz olarak sınıflandırır. Bu DVM' nin genelleştirebilme yeteneğini gösterir. Genelleştirebilme özelliği DVM' yi diğer tekniklere göre iyi bir alternatif yapmaktadır [13].

Sınıflandırılacak örnekler Şekil 2' deki gibi doğrusal bir düzlemle ayrıştırılabilecek seviyede olabilir. DVM analizi, olayları ayıran 1-boyutlu düzlemi, hedef kategorilerini temel alarak bulmaya çalışır. Mümkün çizgilerin sınırsız sayısı vardır. Hangi çizginin, daha iyi olduğunu bulmak ve optimal çizgiyi nasıl bulacağımız önemlidir. Noktalı gösterilen çizgiler en yakın vektörler arasında mesafeyi ayıran çizgiye paralel olarak çekilir. Noktalı çizgilerin arasındaki mesafe kenarı çağırır. Kenarın genişliğini zorlayan vektörler, destek vektörleridir [14].




Şekil 2. Destek vektörlerinin gösterimi

Sınıflandırılacak örnekler Şekil 3' deki gibi doğrusal bir çizgi ile ayıramayacak durumda olabilir.



Şekil 3. DVM doğrusal olmayan sınıflandırma örneği

Bu durumda doğrusal olmayan bir çizgiye ihtiyaç duyulur. Veriye doğrusal olmayan eğrilerle uymaktansa DVM' yi çekirdek fonksiyonu ile başka bir uzaya taşıyarak daha tutarlı bir ayırım sağlanmış olunur. Şekil 4' de çekirdek fonksiyonlarının üst boyuta taşınması gösterilmektedir [13].



Şekil 4. Çekirdek fonksiyonunun üst boyuta taşınması

## 3. Deneysel Sonuçları

Bu çalışmada makine öğrenmesinin sınıflandırma algoritmalarından NB, k-EYK, CN2 ve DVM algoritmaları kullanılarak; Dermatology, Echocardio, EEG Eye ve Breast Cancer biyomedikal veri kümeleri üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Deneyler, Intel i7 2.4 GHz işlemci, 8 GB RAM özelliklerine sahip Windows 7 64 bit işletim sistemi kurulu bilgisayarda yapılmıştır.

NB algoritmasında olasılığı 0 olan durumlarda Laplace Doğrulama yöntemi kullanılmıştır. k-EYK algoritmasında sınıflandırma sırasında  $k$  komşu değeri olarak 7 seçilmiştir. DVM algoritmasında kullanılan kernel fonksiyonlarından Sigmoid fonksiyonu kullanılmıştır. Bütün algoritmalarda çapraz doğrulama sayısı 10 olarak ayarlanmıştır. Ayrıca k-EYK ve DVM algoritmaları için veriler üzerinde normalizasyon işlemi uygulanmıştır. EEG Eye veri kümesindeki tüm özellikler sürekli değerler olduğu için veriler üzerinde ayrıştırma işlemi yapılarak kategorik hale dönüştürülmüştür. Yapılan deneylere başarımlar açısından bakarsak kullanılan bütün algoritmaların birbirine yakın sonuçlar verdiği görülür. Fakat DVM algoritması ortalama en az %0.66 oranında daha yüksek başarımlı sonuçlar vermiştir. Çalışma süreleri açısından bakarsak NB algoritmasının çok daha hızlı çalıştığı görülür. Bu çalışmada elde edilen sonuçlar Tablo 2' de gösterilmektedir.



Tablo 2. Biyomedikal veri kümeleri için sınıflandırma algoritmalarının başarımları ve çalışma süreleri

	NB		k-EYK		CN2		DVM	
	Süre (sn)	Başarım (%)	Süre (sn)	Başarım (%)	Süre (sn)	Başarım (%)	Süre (sn)	Başarım (%)
Dermatology	<b>0.11</b>	<b>97.82</b>	0.31	96.43	5.80	88.79	1.98	97.55
Echocardio	0.09	90.36	<b>0.04</b>	84.82	0.22	<b>95.89</b>	0.07	93.04
EEG Eye	<b>2</b>	69.06	163	<b>79.81</b>	84	73.68	371	72.98
Breast Cancer	<b>0.36</b>	<b>97.42</b>	0.45	96.57	1.82	94.99	0.99	96.71
Ortalama	<b>0.64</b>	88.67	40.95	89.41	22.96	88.34	93.51	<b>90.07</b>

#### 4. Sonuç ve Öneriler

Makine öğrenmesi algoritmalarının sağlık sektörü alanındaki uygulamaları her geçen gün biraz daha artmaktadır. Sağlık sektöründe doktorlar tarafından yapılan teşhis ve tedavilerde daha doğru sonuçlar elde etmek, insan kaynaklı hataları engellemek ve doktorun kararına yardımcı olmak amacıyla makine öğrenmesi tabanlı karar destek sistemleri kullanılmaktadır. Bunun yanı sıra çok sayıda hastanın bilgilerini barındıran biyomedikal veri kümelerinin analizi, istatistiki bilgilerin çıkarılması ve bilimsel çalışmalarda kullanılabilirliği için hızlı bir şekilde yorumlanması gerekmektedir. Bu yorumlama işleminde sadece ve sadece bilgisayar ortamındaki makine öğrenmesi tabanlı yazılımlar tarafından gerçekleştirilebilir. Bu çalışmada makine öğrenmesi algoritmalarından k-EYK, NB, CN2 ve DVM kullanılmıştır. Saf halleriyle çalıştırılan bu algoritmalar içerisinde en iyi başarı DVM tarafından elde edilmiştir.

Bu çalışma ileride yapılacak bir çalışmanın başlangıç aşamasıdır. Daha sonraki çalışmalarda kullanılan makine öğrenmesi algoritmalarının iyileştirilmesi veya hibrit kullanımları gerçekleştirilecektir. Böylelikle de sınıflandırma başarımlarının artırılabilirliği düşünülmektedir.

#### 5. Kaynaklar

- [1] J. Huang, J. Lu, and C. X. Ling, "Comparing naive Bayes, decision trees, and SVM with AUC and accuracy," *Third IEEE Int. Conf. Data Min.*, pp. 553–556, 2003.
- [2] O. F. P. S. Disease, "Effect of discretization method on the diagnosis of parkinson's disease," vol. 7, no. 8, pp. 4669–4678, 2011.
- [3] K. Fu, J. Qu, Y. Chai, and Y. Dong, "Classification of seizure based on the time-frequency image of EEG signals using HHT and SVM," *Biomed. Signal Process. Control*, vol. 13, pp. 15–22, Sep. 2014.
- [4] N. S. Altman, "An Introduction to Kernel and Nearest-Neighbor Nonparametric

- Regression," vol. 46, no. 3, pp. 175–185, 2007.
- [5] D. M. Farid, L. Zhang, C. M. Rahman, M. A. Hossain, and R. Strachan, "Hybrid decision tree and naïve Bayes classifiers for multi-class classification tasks," *Expert Syst. Appl.*, vol. 41, no. 4, pp. 1937–1946, Mar. 2014.
- [6] P. Clark and T. Niblett, "The CN2 Induction Algorithm," *Mach. Learn.*, vol. 3, no. 4, pp. 261–283, Mar. 1989.
- [7] B. He, Y. Shi, Q. Wan, and X. Zhao, "Prediction of Customer Attrition of Commercial Banks based on SVM Model," *Procedia Comput. Sci.*, vol. 31, pp. 423–430, 2014.
- [8] "UCI Machine Learning Repository." [Online]. Available: <http://archive.ics.uci.edu/ml/>. [Accessed: 18-Jun-2014].
- [9] H. Kucuk, C. Tepe, and I. Eminoglu, "Classification of EMG signals by k-Nearest Neighbor algorithm and Support vector machine methods," in *2013 21st Signal Processing and Communications Applications Conference (SIU)*, 2013, pp. 1–4.
- [10] P. Bermejo, J. A. Gámez, and J. M. Puerta, "Improving the performance of Naive Bayes multinomial in e-mail foldering by introducing distribution-based balance of datasets," *Expert Syst. Appl.*, vol. 38, no. 3, pp. 2072–2080, Mar. 2011.
- [11] M. Hacibeyoglu, A. Arslan, and S. Kahramanli, "Improving Classification Accuracy with Discretization on Datasets Including Continuous Valued Features," pp. 337–340, 2011.
- [12] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, p. 273, 1995.
- [13] V. Kecman, *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models*. A Bradford Book; 1 edition, 2001, p. 608.
- [14] "SVM - Support Vector Machines." [Online]. Available: <http://www.dtrek.com/svm.htm>. [Accessed: 18-Jun-2014].

## EEG Verilerinden Farklı Müzik Türü ve Zihinsel Görevlerin Ayırt Edilmesi

Zhaleh SADREDDİNİ<sup>1</sup> Ebru DURMUŞ<sup>2</sup> Nurhan GÜRSEL ÖZMEN<sup>3</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü

<sup>2,3</sup>Makine Mühendisliği Bölümü

Mühendislik-Mimarlık Fakültesi

Karadeniz Teknik Üniversitesi, TRABZON

Zh.sadreddini@ktu.edu.tr

ebru.drms@ktu.edu.tr

gnurhan@ktu.edu.tr

### Özet

*Bu çalışmanın amacı, insan beyninin farklı durumlardaki değişimini gözlemlemek ve bu değişimin bir beyin bilgisayar arayüzü sisteminde kullanılabilirliğini araştırmaktır. Üç farklı kişi ile müzik dinleme, zihinsel ve motor hareket hayal etme görevleri gerçekleştirilmiş ve farklı öznitelik yöntemleri ve sınıflandırıcılar açısından performansları değerlendirilmiştir. Deneysel sonuçlara göre, müzik dinlerken beynin artkafa (occipital) ve merkez (central) bölgelerinin daha aktif olduğu belirlenmiştir. Öznitelikler arasından seçilen özbağlanım katsayıları (AR) özniteliğinin sonuçları ve sınıflandırıcılar arasından seçilen yapay sinir ağları (NN) ile sınıflandırma sonuçlarının daha başarılı olduğu gözlenmiştir. Elde edilen sonuçlara göre, bu çalışmada kullanılan müzik dinleme yöntemi bir beyin bilgisayar arayüzü sistemi için denenebilir.*

*Anahtar Kelimeler — BBA, EEG, müzik dinleme zihinsel görevi, öznitelik çıkarma, sınıflandırma.*

### 1. Giriş

İnsanların bilinen en eski ve temel sosyo-bilişsel alanlarından biri müziktir. Düzenli olarak müzik dinlemek nöron ve sinapsları daha aktif hale getirdiği gibi, sevilen müzikleri dinlemek zihinsel yorgunluğu azaltmaya yardımcı olur. Ses dalgaları incelendiğinde, ses dalgalarının insanların nörolojik (beyin ve sinir) sisteminde büyük etkisi olduğu saptanmıştır. Dolayısıyla yapılan nörolojik çalışmalar müziğin beyin sistemini değerlendirmek için önemli bir araç olduğunu göstermektedir [1].

Müzik türlerinin her birinin insan vücudunda oluşturduğu kendi frekansları vardır ve beyin ile ilişkili olan frekans bandlarını da Elektroansefalogram

(EEG) ile ölçüp incelemek mümkündür [2]. EEG tabanlı Beyin Bilgisayar Arayüzü (BBA) literatüründe müzik dinletilerek kişilerin farklı görevler yerine getirdikleri çalışmalar mevcuttur. Bu çalışmalar iki açıdan ele alınmıştır. Birincisinde, müzik dinletilerek ve müzik dinletilmeden zihinsel görevleri yerine getirenler incelenmiş, ikincisinde ise müzisyen ve müzisyen olmayan insanlar arasında müzik türlerine göre farklılıklar EEG sinyallerinden ayırt edilmeye çalışılmıştır [3,4].

Bu çalışmada ise, müzik dinleme görevi ayrı bir görev olarak ele alınmış, hem farklı müzik türleri (klasik, rock) kendi aralarında karşılaştırılmış hem de diğer zihinsel görevlerle karşılaştırılmıştır. Bu çalışmada kullanılan EEG verilerinin tamamı Karadeniz Teknik Üniversitesi Makine Mühendisliği Bölümü'nde Bilimsel Araştırma Projeleri kapsamında satın alınan Biosemi Active Two EEG Sistemi ile gerçekleştirilen ölçümlerden elde edilmiştir.

### 2. Materyal ve Yöntem

#### 2.1. Katılımcılar ve İşlem Adımları

Çalışmamız üç farklı kişi ile gerçekleştirilmiştir. Bu denekler, Karadeniz Teknik Üniversitesi Makine Mühendisliği öğrencileri olup, yaşları 20 ile 25 arasında değişen ve herhangi bir nörolojik, psikolojik, kronik hastalık tanısı olmayan gönüllü ve sağ elini kullanan kişilerdir. EEG kayıtları sessiz, sakin, gün ışığı ile aydınlatılmış bir odada gerçekleştirilmiştir. Denekler rahat bir sandalyede oturmaktadırlar ve deney esnasında gözlerini açık tutmaları ve hareket etmemeleri söylenmektedir. Deneyden önce deneklere işlem adımları araştırmacı tarafından anlatılır. Her ölçüm öncesinde denekler bir

araştırmacı tarafından hangi görevin yapılacağı, başlama ve bitiş zamanları konusunda bilgilendirilirler [2,5]. Her bir deneme 10 saniyelik bir kaydı içermektedir ve ardışık deneyler arasında 2-3 saniyelik ara verilmektedir. Yedi farklı görev için toplamda 100 farklı kayıt gerçekleştirilmiştir. Görev tanımları aşağıdaki şekildedir:

**Rahat durum:** Temel görev olarak adlandırılan bu görev esnasında deneklerin rahat bir şekilde hiçbir şey düşünmeden beklemeleri istenmektedir.

**Matematiksel işlem:** Bu görevde deneklerden zihinden iki basamaklı bir çarpma problemini çözmeleri istenir. İşlemler her defasında değişkendir ve 10 saniye sonunda denegın sonucu bulup bulamadığı kontrol edilir.

**Sağ el hareketi hayali:** Bu esnada deneklerin sağ ellerini ardışık hareket ettirdiklerini hayal etmeleri istenir. Bu hareketlerin seçilme nedeni, motor görevlerle sezgisel görevler arasındaki ayrımları fark etmek amaçlıdır.

**Sol el hareketi hayali:** Bu görev sağ el hareketi hayali ile aynıdır.

**A harfi hayali:** Bu görev esnasında deneklerin gözleri açık bir şekilde zihinlerinde yanıp sönen veya bir ekrana yazılmış şekilde A harfini canlandırmaları istenir.

**Klasik müzik dinleme:** Bu görev esnasında denek gözleri açık bir pozisyonda kulaklık ile sözsüz klasik müzik dinlemektedir.


**Rock müzik dinleme:** Bu görev de klasik müzik dinleme görevine benzer şekilde uygulanır.

Bu yedi görev çalışmanın devamında birbirleriyle karşılaştırılırken kullanım kolaylığı sağlaması için sırasıyla Görev1, Görev2, Görev3, Görev4, Görev5, Görev6 ve Görev7 olarak adlandırılmıştır [5, 6, 7].

## 2.2. EEG Veri Kaydı ve Ön İşleme

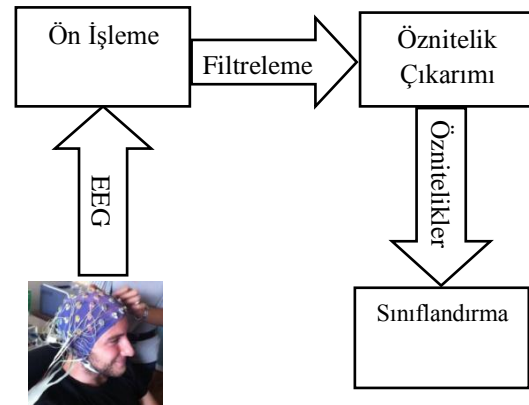
Çalışmada kullanılan veriler Karadeniz Teknik Üniversitesi Makine Mühendisliği Bölümü'nde bulunan 64 kanallı Biosemi ActiveTwo EEG kuvvetlendiricisi ile kaydedilmiş ve sayısal ortama aktarılmıştır. Kaydedilen veri sayısal ortama 512 Hz ile aktarılmıştır. Verilerin analizi MATLAB programı ile yapılmıştır.

Sinyal analizi için 64 kanal arasından seçilen belirli 6 elektrot kanalına ait EEG verileri kullanılmıştır. Farklı görevler için beynin farklı bölümlerinin sorumlu olduğu ve farklı zihinsel aktiviteler esnasında farklı türden işaretler üretildiği bilindiğinden, o alanları içerecek şekilde Şekil1'de sarı ve kırmızı renkte belirtilen C3, C4, P3, P4, O1 ve O2 kanalları seçilmiştir. Seçilen her bir elektrot kanalının sınıflandırmadaki etkilerini görebilmek amacıyla, sınıflandırma başarımları elektrot bazında incelenmiştir [6].



Şekil1. Uluslararası 10-20 elektrot yerleşim düzeni ve seçilen elektrotlar (sarı-kırmızı), en yüksek başarımın gözlemlendiği elektrotlar (kırmızı)

EEG sinyal analizi adımları Şekil2'de gösterilmektedir. Öncelikle, kaydedilen EEG sinyallerinden doğru ve yüksek performanslı bir sınıflandırma sonucu elde edebilmek için EEG işaretine dahil olan bozucuların ayıklanması gerekir. Bu nedenle bu çalışmada bozucuların etkisini azaltabilmek için deneklerden gözlerinin açık fakat deney esnasında (her bir 10 saniyelik periyotta) gözlerini hareket ettirmemeleri istenmektedir. Daha sonra elde edilen veriler, bozucu ve gürültülerden ayıklamak için 1-30 Hz aralığını geçiren Elliptik bant geçiren süzgeçten geçirilerek sinyal filtreleme işlemine tabi tutulmuştur.



Şekil 2. EEG analiz şeması

### 2.3. Öznitelik Çıkarımı

Öznitelik çıkarmanın temel amacı kaydedilen EEG verilerinin ayırt edici özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Bu çalışmada, öznitelik vektörleri olarak, özbağlanım katsayıları(AR), Hjorth parametreleri, güç spektrum yoğunluğu (PSD) ve zihinsel ve motor hareketlerin ayırt edilmesinde frekans karakteristikleri çok önemli olduğu için bu çalışmada kullanılan diğer bir öznitelik çıkarma yöntemi de [7]'deki çalışmada yapılan EEG işaretlerinin güç spektral yoğunluğundan elde edilen frekans dağılımlarını esas alarak çıkarılan özniteliktir. Bu dört öznitelik çıkarma yöntemleri, sınıflandırma performansları açısından karşılaştırılmıştır.

Mertebesi  $p$  olan özbağlanım modeli (AR), Eşitlik 1 denklemi ile hesaplanmaktadır. Bu eşitlikte  $x(n)$  çıkış dizini,  $e(n)$  varyansı  $\sigma^2$  olan beyaz gürültü dizini,  $a(k)$  ise özbağlanım (AR) parametrelerini ve/veya öznitelikliğini belirtmektedir.  $AR(p)$  modeli,  $\{a[1], a[2], \dots, a[p], \sigma^2\}$  AR model parametreleri ile karakterize edilir.

$$x[n] = -\sum_{k=1}^p a[k]x[n-k] + e[n] \quad (1)$$

Hjorth tanımlayıcıları, üç alt parametrenin birleşmesiyle oluşturulmuştur. Bu parametreler şu şekildedir: işleklik, taşınırılık ve karmaşıklık. İşleklik en sade haliyle sinyalin enerjisi ( $\sigma_x$ ) olarak tanımlanır. Taşınırılık ise Eşitlik 2'de verilen denklem ile ifade edersek  $x$  sinyalinin birinci türevinin standart sapmasının sinyalin standart sapmasına oranı şeklindedir.

$$T = \frac{\sigma_{x'}}{\sigma_x} \quad (2)$$

Karmaşıklık diğer adıyla biçim faktörü (BF) sinyalin formu ile ilgili hesaplanabilir bir değer verir.

$$BF = \frac{Tx'}{Tx} = \frac{\sigma_{x''} / \sigma_{x'}}{\sigma_{x'} / \sigma_x} \quad (3)$$

Öznitelik olarak literatürde de yaygın olarak kullanılan güç spektral yoğunluğu ise Welch periodogramı ile [7,8,9,10] ve [7]'deki yöntemle hesaplanmıştır.

### 2.4. Sınıflandırma

Sinyal işleme sistemlerinin son aşaması olan sınıflandırmada, kullanılan algoritmaya bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflandırma sonucu belirlenir [7,11].

Bilinmeyen bir sinyali tanıyabilmek için öznitelik çıkarımı ve öznitelik seçimi işlemlerinin ardından sınıflandırma işlemi gerçekleştirilir. Sınıflandırma işlemi için, hangi sınıfa ait olduğu önceden bilinen belirli sayıda öznitelik vektörünün oluşturduğu "veri kümeleri" bir eğitim sürecinden geçirilir. Bu eğitim sonucunda, bilinmeyen sinyali uygun sınıfa atamakta kullanılan bir karar mekanizması oluşturulur [12,13]. Bu çalışmada sınıflandırma performansları yedi farklı görev için üç farklı sınıflandırıcının kendi aralarında ikili sınıflandırma yöntemleri ile değerlendirilmiştir. Sınıflandırıcı olarak seçilen yöntemler Destek Vektör Makinesi, k-En Yakın Komşuluğu ve Yapay Sinir Ağları'dır.

#### 2.4.1. Destek Vektör Makinesi (SVM) İle Sınıflandırma

Destek vektör makineleri (SVM), istatistiksel öğrenme teorisine dayalı öğrenme algoritmasıdır [14]. Genellikle SVM' de ikili sınıflandırmada etiketlenmiş eğitim verisi (4) ifadesindeki gibi belirtilir. Burada  $l$ ; örnek sayısı  $x_i$ ; örnekler,  $y_i$ ; bu örneklere ait etiketleri temsil etmektedir.

$$\{x_i, y_i\}^l \quad i=1 \quad x_i \in R, \quad y_i \in \{-1, +1\} \quad (4)$$

İkili sınıflandırma probleminde doğrusal olarak ayrılabilen bir veri setinin olduğu düşünülürse, bu veri setini ayırabilen sonsuz sayıda hiper-düzlem vardır. SVM karar yüzeyini oluştururken iki sınıfa olan uzaklığı maksimum yapmaya çalışır. Bu düzlemler arasındamaksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır. Sınır genişliğini sınırlandıran noktalara ise destek vektörleri adı verilir. Destek vektör algoritması en büyük sınır genişliğine sahip ayırıcı hiper-düzlem ile sınıflandırma yaparak eğitim hatasını minimize etmeye çalışır. Sınıfları birbirinden ayıran marjini en büyük, doğrusal bir ayırt edici fonksiyon bulunmasını amaçlar. Doğrusal olarak ayrılabilen örnekler için, örnekler doğrusal olarak ayrılabilirdikleri daha yüksek boyutlu başka bir uzaya taşınır ve sınıflandırma o uzayda yapılır.

### 2.4.2. K-En Yakın Komşuluk Algoritması ile Sınıflandırma

k-En Yakın Komşu (k-NN) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesnelere sınıflandıran, en basit örüntü tanıma yöntemlerinden birisidir [15]. Bu algoritma verilen k değeri kadar en yakın komşunun sınıfına göre sınıflandırma işlemi yapmaktadır. Bu çalışmada optimum k değeri denemeler sonucunda üç olarak belirlenmiştir.

k-En Yakın Komşu algoritmasında bir vektörün sınıflandırılması, sınıfı bilinen vektörler kullanılarak yapılmaktadır. Test edilecek örnek, eğitim kümesindeki her bir örnek ile tek tek işleme alınmıştır. Test edilecek örneğin sınıfını belirlemek için eğitim kümesindeki o örneğe en yakın k adet örnek seçildi (k=3). Seçilen örneklerden oluşan küme içerisinde hangi sınıfa ait en çok örnek varsa test edilecek olan örnek bu sınıfa aittir denildi. Örnekler arası uzaklıklar Öklid (Euclidean) uzaklığı ile hesaplanmıştır.

### 2.4.3. Yapay Sinir Ağları İle Sınıflandırma

Yapay sinir ağları (NN) ile sınıflandırmada tek katmanlı bir YSA modeli Matlab ortamında oluşturulmuştur. Oluşturulan modelde öğrenme kuralı olarak geri yayılım algoritması (traingdx) kullanılmış ve bu öğrenme kuralındaki parametrelerden öğrenme oranı (learning rate, lr), maksimum iterasyon sayısı (itnum) parametreleri için en uygun değerler araştırılmıştır. Bunun yanı sıra ara katmandaki gizli nöron sayısı için de benzer bir araştırma işlemi gerçekleştirilerek, optimum gizli nöron sayısı belirlenmiştir. Sınıflandırma işlemi esnasında toplam veri seti, eğitim, doğrulama ve test verileri olmak üzere üçe ayrılmıştır. Her bir denemeye ait verilerin %70'i eğitime, %5'i doğrulamaya ve %25'i ise test kümesine yerleştirilerek bir çözüm yapılmıştır. Sınıflandırma performansı ise toplam verilerinden elde edilen yüzdesel ikili sınıflandırma doğruluğu olarak ele alınmış ve yedi farklı görevden her bir elektrot için kaydedilen her yüz veriden kaç tanesinin doğru sınıflandırıldığı bulunmuştur.

### 3. Tartışma

Bu çalışma kapsamında üç farklı kişiden elde edilen EEG verileri hem seçilen görevler, hem öznitelik

yöntemleri, hem de sınıflandırıcı performansları açısından değerlendirilmiştir. Sayfa sayısının sınırlı olması nedeniyle, Tablo1' de yalnızca en yüksek başarımın elde edildiği deneğe ait sonuçlar seçilen elektrotlar bazında verilmiştir. Genel olarak 3 kişi için değerlendirdiğimizde, görevlerdeki başarılar ve sınıflandırıcı başarımları Tablo1'deki denek sonuçları ile benzerdir. Sadece öznitelikler arasında farklılıklar gözlenmiştir. Hjorth tanımlayıcısı için sınıflandırma başarımları ortalama olarak %60-70, AR için %90-100 ve PSD değerleride %90-98 civarındadır. AR başarımları biraz daha yüksek olduğu için Tablo 1'e konulmuştur. Sınıflandırıcılar arasında en yüksek başarımlar, sırasıyla NN, SVM ve k-NN sınıflandırıcısıdır. Elektrotlar açısından değerlendirildiğinde, C3 ve O2 elektrolarında 3 kişi için bütün görevlerdeki başarılarının ortalamasının yüksek olduğu gözlenmiştir (Şekil 2'de kırmızı elektrotlar). Tüm görevlerin ikili sınıflandırma sonuçları değerlendirildiğinde, 3 sınıflandırıcı ve 3 kişi içinde en iyi sonuçlar Görev3-Görev6 (sağ el-klasik müzik), Görev3-Görev7(sağ el-rock müzik), Görev5-Görev6 (A harfi-klasik müzik), Görev5-Görev7( A harfi-Rock müzik) ve Görev 6-Görev7 'de (Klasik-rock müzik ) görevlerinde elde edilmiştir. Bu sonuçlara göre, BBA sistemleri için, görev tanımlaması yaparken müzik dinleme görevinin de uygun bir seçim olacağı düşünülmektedir. Klasik ve rock müzik dinleme esnasında, EEG sinyallerinde farklılık oluştuğu ve bu farklılığın sınıflandırma başarımlarına yansıdığı görülmüştür.

### 4. Sonuçlar

Bu çalışmada üç farklı kişi ile müzik dinleme, zihinsel ve motor hareket hayal etme görevleri gerçekleştirilmiş ve farklı öznitelik yöntemleri ve sınıflandırıcılar açısından performansları değerlendirilmiştir. Özbağlanım katsayıları (AR), Hjorth parametreleri, güç spektrum yoğunluğu (PSD) ve zihinsel ve motor hareketlerin ayırt edilmesinde frekans karakteristikleri gibi öznitelik yöntemleri arasında, AR parametreleri ile SVM ve NN sınıflandırıcı performanslarının yüksek olduğu görülmüştür. En başarılı elektrot kanalları ise C3 ve O2 olarak gözlenmiştir. Elde edilen sonuçlar ışığında, müzik dinleme görevinin BBA sistemleri için denenebileceği söylenebilir.

Tablo1. EEG müzik görevleri verilerinin çalışılan diğer görevlerle ikili sınıflandırma sonuçları

Deneme Seti (Görev)	Sınıflandırıcıların (%) Başarı Değerleri																	
	k-NN				NN				SVM									
	C3	C4	P3	P4	O1	O2	C3	C4	P3	P4	O1	O2	C3	C4	P3	P4		
1 - 6	40	27	63	67	57	77	95	83	80	85	61	76	60	37	47	60	70	50
2 - 6	100	100	90	93	100	100	96	95	95	92	96	93	100	97	47	70	94	94
3 - 6	93	93	90	100	90	93	90	96	96	94	98	94	97	97	80	100	80	94
4 - 6	93	93	77	90	93	90	95	93	96	100	95	96	80	67	84	97	80	94
5 - 6	93	93	93	93	93	93	72	77	77	89	86	80	97	94	94	94	94	94
1 - 7	97	60	60	80	60	87	100	94	84	93	90	86	97	90	50	94	74	97
2 - 7	100	63	63	73	80	87	92	82	85	80	85	84	100	74	24	57	84	84
3 - 7	83	93	80	80	80	77	98	100	98	98	91	98	100	100	87	94	87	84
4 - 7	87	70	67	77	67	83	91	75	83	82	81	74	90	97	97	90	77	90
5 - 7	100	100	100	100	100	100	93	91	92	95	87	95	100	100	100	100	100	100
6 - 7	77	90	90	90	90	90	90	96	95	94	95	96	100	100	100	100	100	100

## 5. Kaynaklar

- [1] Peretz I, Zatorre R. Brain Organization for Music Processing. Annual Review of Psychology, pp: 89 – 114, 2005 (56).
- [2] Asada H, Fukuda Y, Tsunoda S, Yamaguchi M, Tonoike M. “ Frontal midline theta rhythms reflect alternative activation of prefrontal cortex and anterior cingulate cortex in humans.” J Neurophysiology (50), pp: 324 – 328, 1999.
- [3] A. Dey, S.K. Palit, D.K. Bhattacharya, D.N. Tibarewala, Debraj Das, “Study of the effect of music on central nervous system through long term analysis of eeg signal in time domain” International Journal of Engineering Sciences & Emerging Technologies, Volume 5, Issue 1, pp: 59-67, Apr. 2013.
- [4] J. Bhattacharya, H. Petsche, E. Pereda, “Interdependencies in the spontaneous EEG while listening to music” Elsevier Science B.V. All rights reserved, 2001.
- [5] N.G. Ozmen, L. Gumusel, “Discrimination between Mental and Motor Tasks of EEG Signals Using Different Classification Methods”, INISTA ,15-18 June, Istanbul, Turkey, 2011.
- [6] N.,Gürsel Özmen, L., Gümüşel,” Mental and Motor Task Classification by LDA”, MEDICON 2010, IFMBE Proceedings29, pp. 172-175, Chalkidiki, Greece. , 28-29 May 2010.
- [7] N.,Gürsel Özmen, L., Gümüşel, Classification of Real and Imaginary Hand Movements for a BCI Design, 978-1-4799-0404-4/13/\$31.00 IEEE, TSP 2013.
- [8] C.W. Anderson ve Z. Sijercic, Classification of EEG signals from four subjects during five mental tasks. Solving Engineering Problems with Neural Networks Proc. Int.Conf. on Engineering Applications of Neural Networks (EANN'96), 1996.
- [9] C.W Anderson., S.V. Devulapalli, A.Stolze Determining mental state from EEG signals using parallel implementations of neural networks. Scientific Programming IOS Press, 4, 3: 171-183, 1995.
- [10] N.,Gürsel Özmen, L., Gümüşel, Mental and Motor Task Classification by LDA, MEDICON 2010, IFMBE Proceedings29, pp. 172-175, Chalkidiki, Greece. , 28-29 May 2010.
- [11] Kwak, N., Choi, C.-H., “Input feature selection for classification problems,” IEEE Transactions on Neural Networks, Vol. 13, No. 1, pp. 143-159, 2002.
- [12] Gunal S., Örüntü tanıma uygulamalarında alt uzay analiziyle öznelik seçimi ve sınıflandırma, Doktora tezi, Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2001.
- [13] Duda, R. O., Hart, P. E. and Stork, D. G., Pattern classification, John Wiley & Sons Inc., USA, 654 p, 2001.
- [14] Burges, J.C., “A Tutorial on Support Vector Machines for Pattern Recognition”, Data Mining and Knowledge Discovery 2, 121-167,1998.
- [15] Alpaydin, E., “Introduction to Machine Learning”, MIT Press, 2004.

## Mobil Uygulama ile Görüntü İşleme ve Veri Madenciliği Tekniklerine Dayalı Melanom Tahmin Desteği Sağlanması

Melike ÇAĞLAYAN<sup>1</sup> Begüm ÇEKİRGE<sup>2</sup> Derya BİRANT<sup>3</sup> Pelin YILDIRIM<sup>4</sup>

<sup>1,2,3</sup>Bilgisayar Mühendisliği Bölümü  
Dokuz Eylül Üniversitesi, İZMİR  
<sup>4</sup>Yazılım Mühendisliği Bölümü  
Celal Bayar Üniversitesi, MANİSA

Email: melike.caglayan@st.cs.deu.edu.tr begum.cekirge@st.cs.deu.edu.tr derya@cs.deu.edu.tr  
pelin.yildirim@cbu.edu.tr

### Özet

*Son yıllarda, cilt kanserine yakalanan hasta sayısında artış gözlemlenmektedir. Cilt kanseri türlerinden biri olan melanom, en fazla ölüme neden olan cilt kanseridir ve erken tanısı hayati önem taşımaktadır. Bu çalışmada; melanom riskinin tahmin edilebilmesi amacıyla yönelik olarak geliştirilen, mobil teknolojisi içeren, görüntü işleme ve veri madenciliği tekniklerine dayalı yeni bir akıllı sistem (Analiz@) önerilmektedir. Deneysel çalışmalarda, altı farklı sınıflandırma algoritması (C4.5, Çok Katmanlı Algılayıcı, k-En Yakın Komşu, Destek Vektör Makineleri, KStar, Adaboost) karşılaştırılmakta ve başarılı sonuçların elde edildiği gösterilmektedir.*

### 1. Giriş

Cilt kanserine bağlı ölümlerin büyük bir çoğunluğu melanom nedeniyle. Dünya genelinde artan oranda melanom vakaları tespit edilmektedir. Melanom tedavisi için harcanacak giderleri ve melanom kaynaklı ölümleri azaltmak için erken teşhis son derece önemlidir.

Bu bildiride; doktorla erken iletişimin sağlanabilmesi, melanom olma olasılığının tahmin edilerek doktora başvurma tavsiyesi verilebilmesi amacıyla, yapay zeka içeren akıllı bir sistem önerilmektedir. Önerilen yeni sistem, Analiz@ olarak adlandırılmıştır; mobil teknolojisini, görüntü işleme tekniklerini ve veri madenciliği yöntemlerini içermektedir.

Bu çalışmada önerilen yeni sistem üç ana bölümden oluşmaktadır: (i) geçmiş hasta verilerinden veri madenciliği teknikleri kullanılarak karar modelinin oluşturulması ve test edilmesi, (ii) kişinin mobil

cihazı ile çektiği ben fotoğrafından görüntü işleme teknikleri ile şekil özelliklerinin çıkartılması, (iii) belirlenen nitelik bilgileri kullanılarak sınıflandırma yapılması, böylece melanom tahmin desteği sağlanabilmesi.

Çalışmanın başlıca yenilikçi yönü; melanom konusuna odaklanan, kişilerin mobil cihazları ile çektikleri fotoğrafları mobil uygulama ile sınıflandıran, görüntü işleme ve veri madenciliği tekniklerini birlikte içeren, ülkemizde ve Türkçe dilinde geliştirilen, ekstra özellikler planlanan, altı farklı algoritmayı karşılaştıran; tüm bunları bir arada içeren bir çalışma olmasıdır.

Çalışmada önerilen çözüm, cilt kanseri teşhisi amaçlı değil, risk belirtileri varlığında uyararak, bu konu hakkında farkındalık oluşturmak ve mobil uygulama kullanıcısının doktorla erken iletişimini sağlamak amaçlı geliştirilmiştir.

Bildiride son olarak, melanom veri seti üzerinde gerçekleştirilen veri madenciliği çalışmalarında elde edilen yüksek doğruluk oranları da sunulmaktadır.

### 2. Mevcut Çalışmalar

Bilişim teknolojisinin ilerlemesi ile birlikte, medikal alanda veri madenciliği tekniklerini uygulayan otomasyon sistemlerinin kullanılması yaygınlaşmaya başlamıştır. Özellikle cilt hastalığı ve kanser olasılıklarının tahmin edilebilmesinde sınıflandırma, kümeleme, birliktelik kuralları analizi teknikleri ile başarılı sonuçlar elde edilebilmektedir [1].

Geçmiş çalışmalarda, veri madenciliği teknikleri melanom dışında da çeşitli cilt hastalıkları için

kullanılmıştır [2]. Cilt kanserini veri madenciliği ile erken teşhis edebilmenin önemi belirtilmiş [3] ve cilt hastalıklarında yazılım ile sağlanabilecek başarı oranları verilmiştir [4]. Mevcut çalışmaların bir kısmında farklı dermatoloji verileri kullanılmaktadır ve bazı çalışmalar direk melanom konusu üzerine değildir [5]. Çalışmaların bir kısmı ise cilt kanserinin bir türü olan melanom ile de ilgilidir [6]. Ama bu çalışmalar, bu bildiriye önerilen çalışmadan farklı olarak ABCD (A: asimetri, B: sınır (border), C: renk (color), D: çap (diameter)) formülüne ve Toplam Dermatoskopik Puan (TDS) hesabına dayanmaktadır.

Melanom verisinin ön-ışlemden geçirilmesi aşamasında kümeleme yönteminin kullanıldığı bir çalışma bulunmaktadır [7]. Ama bu bildiriye sunulan çalışmada hem veri madenciliği ön-ışlem amaçlı kullanılmamakta, hem de kümeleme yerine sınıflandırma yapılmaktadır. Gen verisine dayalı olarak melanom sınıflandırması yapan veri madenciliği çalışmaları da mevcuttur [8]. Farklı bir melanom verisi üzerinde Durum Tabanlı Çıkarsama algoritması ile çok-etiketli sınıflandırma yapan bir çalışma bulunmaktadır [9]. Ama bu çalışmadan farklı olarak, önerilen çalışmada tek-etiketli sınıflandırma yapılmakta ve farklı algoritmalar kullanılmaktadır.

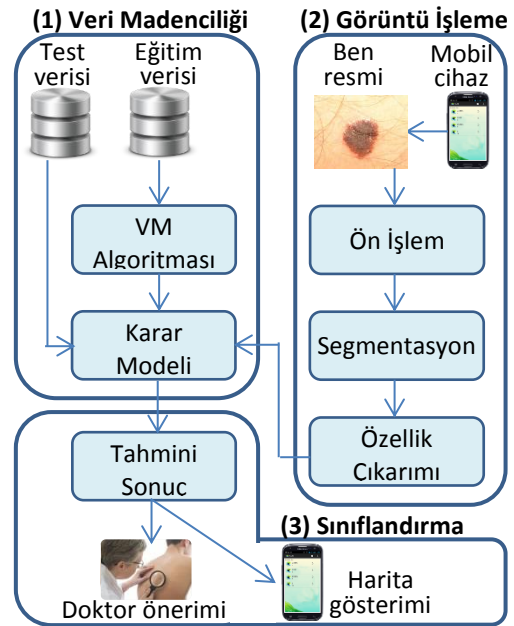
Çalışmaların bir kısmı görüntü işleme içermemekte, toplanan dermatoloji verisi üzerinde analiz yapmaktadır. Görüntü işleme içeren bazı çalışmalarda ise birliktelik kuralları analizi gibi farklı veri madenciliği yöntemleri kullanılmıştır [10]. Görüntü işleme içeren diğer bir çalışmada ise standart kamera ile çekilen resimlerden elde edilen verilerin renk ve doku özelliklerine bakılarak sınıflandırma yapılmıştır [11]. Ancak bu çalışma, bu bildiriye önerilen çalışmadan farklı olarak, melanom olmayan lezyonları 5 farklı türe göre sınıflandırmaktadır.

Kısaca özetlemek gerekirse; bu çalışmanın, mevcut çalışmalardan en temel farkları; mobil uygulama olması, ekstra işlevlerin hedeflenmesi, ülkemizde ve Türkçe olarak geliştirilmesi, hem görüntü işleme hem veri madenciliği içermesi, ABCD formülüne dayanmaması, gen bilgisi içermemesi, tek-etiketli olması, melanom konusu üzerine özelleşmiş olması, altı farklı algoritmanın karşılaştırılması; tüm bunları bir arada içermesidir.

### 3. Yöntem

Şekil 1'de, Analiz@ olarak adlandırılan sistemin mimari yapısı gösterilmektedir. Sistem üç ana

bölümden oluşmaktadır. Birinci bölüm olan *Veri Madenciliği*; veri tabanında tutulan eğitim verilerine veri madenciliği algoritmaları uygulanmakta ve karar modeli (kurallar, örüntüler, ilişkiler vb.) oluşturulmaktadır. Ayrıca test verileri ile modelin doğruluk oranı hesaplanmaktadır. İkinci bölüm olan *Görüntü İşleme*; mobil cihaz ile çekilen ben fotoğrafı işlenmekte ve bene ilişkin özellikler (renk, alan, düzgünlük, eşdeğer çap vb.) çıkartılmaktadır. Üçüncü bölüm olan *Sınıflandırmada* ise, işlenmiş görüntü verileri karar modelinden geçirilerek melanom olma olasılığı konusunda tahmin desteği sağlanmakta, doktora başvurma tavsiyesi verilmekte ve en yakın hastaneler harita üzerinde gösterilmektedir.



Şekil 1. Sistem mimarisi

### 3.1. Görüntü İşleme

En önemli melanom belirtileri; bendeki asimetri, sınır düzensizliği, birçok renk içermesi, çapta büyüme olması ve son birkaç ayda değişme göstermesidir. Görüntü işleme teknikleri ile şekillerin; simetrik olup olmadığı, kenar düzensizliği, renk değişimleri, delik sayıları, alan ve çevre değerleri gibi birçok özelliğini belirleyebilmek mümkündür.

Çalışmada gerçekleştirilen görüntü işleme üç alt aşamadan oluşmaktadır:

**Ön-ışlem:** Görüntü elde edildikten sonra gerçekleştirilen bu aşama genel olarak aşındırma (erosion), yayma (dilation), filtreleme gibi sıralı bir dizi işlem içermektedir. İleriki aşamalar için ihtiyaç



duyulan verinin daha uygun hale getirilmesi sağlanmaktadır.

**Segmentasyon:** Görüntü piksellerini anlamsal olarak gruplandırma işlemidir. Bu aşamada, ön işlemden geçmiş görüntünün segmentasyon işlemi, RGB değerlerinde eşik değerlerin kullanılmasıyla gerçekleştirilir. Bu yaklaşıma göre, pikselin normal cilt sınıfında mı yoksa ben sınıfında mı olduğuna karar verilir ve kenar tespiti yapılır.

**Özellik Çıkarımı:** Ön-işlem ve segmentasyon aşamasından sonra elde edilen görüntü üzerinde önceden tanımlanmış hesaplamaların yapılmasını içermektedir. Bu çalışmada, özellikler şekil ve renk olmak üzere iki kategoriye ayrılmıştır.

- **Şekil ölçümleri:** Şekil, ben görüntüsü analizinde önemli bir özelliktir. Şekil ölçümleri olarak; alan, çevre, düzgünlük, eşdeğer çap gibi özellikler çıkarılmıştır.
  - **Alan:** Bölgedeki piksel sayıları ile hesaplanır.
  - **Çevre:** Sınır pikselleri belirlenerek hesaplanır.
  - **Eşdeğer çap:** Ben ile aynı alana sahip bir dairenin çapıdır.
  - **Düzgünlük:** Nesne alanı ve dışbükey kabuk alanı arasındaki oran olarak tanımlanan sınır düzensizliği ölçüsüdür. Değeri bire yakınsa düzgün nesneyi, sıfıra yakınsa düzensiz nesneyi ya da boşlukları ifade etmektedir.
- **Renk ölçümleri:** Renk ölçümleri ben görüntüsünü sınıflandırabilmek için önemlidir. RGB renk uzayı kullanılarak, maksimum ve ortalama kırmızı, yeşil ve mavi renk değerleri hesaplanmaktadır.

Çalışmada kullanılan düzgünlük (solidity), eşdeğer çap (equivdiameter), eksantriklik (eccentricity), Euler sayısı (Euler number) hesaplamaları formül (1) - (4) ile gösterilmektedir.

$$Düzgünlük = \frac{Alan}{Dışbükey Kabuk Alanı} \quad (1)$$

$$Eşdeğer Çap = \sqrt{\frac{4 * Alan}{\pi}} \quad (2)$$

$$Eksantriklik = \frac{(m_{20} - m_{02})^2 + 4m_{11}^2}{(m_{20} + m_{02})^2} \quad (3)$$

Benin eni ve boyu arasındaki ilişki, benin eksantrikliği ile tanımlanmaktadır. Eksantriklik resim momentlerinin (m) elde edilmesiyle hesaplanır. Bu değer, sıfıra yakınsa şekil daireseldir, bire yakınsa düz çizgi şeklindedir.

$$E = B - H \quad (4)$$

Formüldeki  $E$  Euler sayısını,  $B$  bağlı bileşenlerin sayısını,  $H$  ise delik sayısını ifade etmektedir.

Görüntü işlemenin daha sağlıklı yapılabilmesi için fotoğrafın belirli bir uzaklıktan ve gündüz ışıklı bir ortamda çekilmesi, mobil cihazın kaliteli fotoğraf çekmesi, bene iyi odaklanması, elin titretilmemesi, fotoğrafa gölge düşmemesi gibi kriterler önemlidir.

### 3.2. Veri Madenciliği

Veri madenciliği ile geçmiş hasta kayıtlarında bulunan gizli örüntüler, ilişkiler ve kurallar keşfedilebilmektedir. Başlıca veri madenciliği yöntemleri: sınıflandırma, kümeleme ve birliktelik kuralları analizidir. Bu çalışmada, melanom veri setine farklı sınıflandırma algoritmaları uygulanmıştır.

### 3.3. Mobil Uygulama

Her insanın cildinde benler bulunmaktadır ve bu benler güneşle etkileşim halindedir. Bu durum herkeste az ya da çok melanom riski yaratmaktadır ve bireylerin ciltlerindeki benleri takibe alması, belirli kriterlere uyan özellikler görüldüğünde hiç zaman kaybetmeden doktorlara göstermesi gerekmektedir. Bu çalışmada, benlerin riskini geçmiş verilere göre analiz edebilen bir mobil uygulama geliştirilmiştir.

Şekil 2'de, Android işletim sistemine uygun geliştirilen mobil uygulamaya ilişkin ekran görüntüleri verilmektedir.



Şekil 2. Mobil uygulama ekran görüntüleri

Mobil uygulamada, kişinin mobil cihazı ile çektiği ben fotoğrafından OpenCV açık kaynaklı görüntü işleme kütüphanesi ile şekil özellikleri çıkartılmakta ve bunlara uygun olarak veri madenciliği teknikleri ile sınıflandırma yapılmaktadır. Görüntü işleme ile şekil özelliklerinin çıkartılması mobil cihaz üzerinde, C++ kodlarının JNI ile Java kodlarından çağırılmasıyla

gerçekleştirilmektedir. Sınıflandırma için oluşturulmuş olan modellere, Restful web servisleri ile JSON veri değişim formatında erişilmektedir. Uygulamanın ayrıca kullanıcı girişi yapma, eski resimleri arşivleme, en yakın hastane bulma ve haritada gösterme gibi özellikleri de bulunmaktadır.

#### 4. Deneysel Çalışmalar ve Tartışma

Melanom veri setine, WEKA açık kaynaklı kodlardan yararlanılarak altı farklı sınıflandırma algoritması uygulanmış, doğruluk oranları ve F-ölçüm değerleri hesaplanarak elde edilen sonuçlar karşılaştırılmıştır.

##### 4.1. Veri Seti

Sınıflandırmada, eğitim ve test verileri olarak IEEE CIBCB sempozyumu için yayınlanan melanom veri seti kullanılmıştır. Veri seti 18 nitelikten oluşmaktadır ve içerisinde toplam 298 kayıt bulunmaktadır. Niteliklerin 17 tanesi ben özelliklerini, 1 tanesi ise melanom tanısını (sınıfını) belirtmektedir. Sınıf niteliği “0 (negatif)” ve “1 (pozitif)” olmak üzere iki değer içermektedir ve toplam kayıt sayısının yarısı “0” sınıfına, diğer yarısı ise “1” sınıfına aittir. Tablo 1’de melanom veri setinin nitelik açıklamaları ve değer aralıkları gösterilmektedir.

Tablo 1. Melanom veri seti

Nitelik Adı	Değer Aralığı	Açıklama
Entropy	1,01 ... 4,59	Entropi değeri
Max_Red	67 ... 255	Maksimum kırmızı renk
Max_Green	64 ... 217	Maksimum yeşil renk
Max_Blue	45 ... 229	Maksimum mavi renk
Mean_Red	58,53 ... 229,59	Ortalama kırmızı renk
Mean_Green	52,73 ... 175,66	Ortalama yeşil renk
Mean_Blue	38,82 ... 172,17	Ortalama mavi renk
MeanSrnd Red	68,43 ... 248,07	Beni çevreleyen ortalama kırmızı renk
MeanSrnd Green	65,54 ... 214,72	Beni çevreleyen ortalama yeşil renk
MeanSrnd Blue	47,06 ... 216,52	Beni çevreleyen ortalama mavi renk
Solidity	0,21 ... 1	Şekil alanının, dışbükey kabuk alanına oranı
Euler Number	-2 ... 1	Bağlı bileşenlerin sayısından delik sayısının çıkartılması
Eccentricity	0,299 ... 0,99	Elipsin odakları ile ana eksen uzunluğu arasındaki uzaklığın oranı
AreaOver Perimeter	0,397 ... 8,25	Çevre ile alan arasındaki ilişki
Perimeter	12,83 ... 393,63	Çevre değeri
Equiv Diameter	4,51 ... 24,72	Aynı alana sahip bir dairenin çapı
FilledArea	16 ... 480	Dolu şeklin alanı
Class	0 (negatif) 1 (pozitif)	Melanom olup olmadığı

##### 4.2. Sınıflandırma

Çalışmada, altı farklı sınıflandırma algoritması (k-En Yakın Komşu (KNN), C4.5 Karar Ağacı, Çok Katmanlı Algılayıcı - Yapay Sinir Ağları (NN), KStar, Destek Vektör Makineleri (SVM) ve Adaboost) kullanılmıştır. Test verileri ile elde edilen sınıflandırma sonuçlarına göre doğruluk oranları ve F-ölçümleri hesaplanmıştır.

Sınıflandırma sonuçları *n-Katlı Çapraz Geçerlilik* ve *%33 test verisi* teknikleri ile değerlendirilmiştir. *Doğruluk* oranı denklem (5)’te belirtilen eşitliğe göre hesaplanmıştır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (5)$$

Formülde, doğru pozitif *DP*, doğru negatif *DN*, yanlış pozitif *YP* ve yanlış negatif *YN* olarak ifade edilmektedir.

Denklem (6)’da gösterilen *F-ölçüm* değerinin hesaplanması için, *kesinlik* (precision) ve *çağrı* (recall) değerlerinin belirlenmesi gerekmektedir.

$$F - \text{ölçüm} = \frac{2 * \text{Kesinlik} * \text{Çağrı}}{\text{Kesinlik} + \text{Çağrı}} \quad (6)$$

*Kesinlik* değeri, doğru sınıflandırılmış pozitif değerlerin tüm pozitif değerlere oranı ile bulunmaktadır ve denklem (7)’de gösterilmektedir.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (7)$$

*Çağrı* değeri, Denklem (8)’de gösterildiği üzere, doğru sınıflandırılmış pozitif değerlerin, doğru sınıflandırılmış pozitif değerler ve yanlış sınıflandırılmış negatif değerlerin toplamına oranı ile hesaplanmaktadır.

$$\text{Çağrı} = \frac{DP}{DP + YN} \quad (8)$$

Uygulanan test metodlarına göre, algoritmalarından elde edilen doğruluk oranları ve F-ölçümleri Tablo 2’de gösterilmektedir. Kullanılan tüm algoritmalar içerisinde Yapay Sinir Ağlarının en yüksek doğruluk oranına sahip olduğu gözlemlenmektedir. Tüm algoritmaların doğruluk oranlarının %87’nin üzerinde olması ve %95’e kadar çıkabilmesi başarılı sonuçlar elde edilebildiğini göstermektedir.

Tablo2. Melanom veri seti için sınıflandırma algoritmalarının karşılaştırılması

Test Metotları ⇨	10-Katlı Çapraz Geçerlilik		Test Verisi (%33)	
	Doğruluk (%)	F-Ölçüm	Doğruluk (%)	F-Ölçüm
Algoritma ⇩				
NN	95,64	0,96	92,86	0,93
SVM	91,95	0,92	91,84	0,92
KNN	91,28	0,91	90,82	0,91
KStar	89,60	0,90	89,80	0,90
C4.5	88,93	0,89	91,84	0,92
Adaboost	87,25	0,87	91,84	0,92

## 5. Sonuçlar

Cilt kanseri olarak bilinen melanomun genellikle hastalığın son evrelerinde teşhis edilebildiği ve bu evrede mevcut tedavi yöntemlerinin başarısız kalabildiği bilinmektedir. Bu çalışmada, yeni bir sistem (Analiz@) önerilmekte, bu sistem ile melanom konusunda farkındalık yaratılması, olası geç teşhislerin önüne geçilmesi hedeflenmektedir. Önerilen sistem, mobil teknolojisini, görüntü işleme tekniklerini ve veri madenciliği yöntemlerini içermektedir. Vücuttaki bir benin mobil uygulama ile fotoğrafının çekilmesi, görüntü işleme ile analiz edilmesi, veri madenciliği ile melanom risk ihtimalinin tahmin edilmesi ve sonuca göre de doktora gitme tavsiyesinde bulunulması söz konusudur. Deneysel çalışmalarda %95'lere kadar çıkabilen başarı oranları elde edilebilmiştir.

Gelecek çalışma olarak; melanom riski olan hastalara belirli aralıklarla hatırlatıcı uyarılar verilmesi ve böylece benin düzenli takibinin sağlanabilmesi gibi yeni özelliklerin mobil uygulamaya eklenmesi planlanmaktadır.

## 6. Kaynaklar

- [1] E. Barati, M. Saraee, A. Mohammadi, N. Adibi ve M.R. Ahamadzadeh, "A survey on utilization of data mining approaches for dermatological (skin) diseases prediction", Journal of Selected Areas in Health Informatics, 2 (3), 2011, s. 1-11.
- [2] P.K. Srimani ve M.S. Koti, "Performance of the DM technique on dermatology data through factor analysis", International Journal Of Concepts on Electrical and Electronics Engineering, vol. 1, Oct 2013, s. 45-48.
- [3] K. Ahmed, T. Jesmin ve Md.Z. Rahman, "Early prevention and detection of skin cancer risk

using data mining", International Journal of Computer Applications, 62 (4), 2013, s. 1-6.

- [4] H. Çataloluk ve M. Kesler, "A diagnostic software tool for skin diseases with basic and weighted K-NN", International Symposium on Innovations in Intelligent Systems and Applications (INISTA), 2012, s. 1-4.
- [5] B.F. Chimieski ve R.D.R. Fagundes, "Association and classification data mining algorithms comparison over medical datasets", J. Health Inform., 5 (2), 2013, s. 44-51.
- [6] R. Andrews, S. Bajcar, J.W. Grzymala-Busse, Z.S. Hippe ve C. Whiteley, "Optimization of the ABCD formula for melanoma diagnosis using C4.5, a data mining system", Lecture Notes in Computer Science, vol. 3066, 2004, s. 630-636.
- [7] S. Bajcar, J.W. Grzymala-Busse ve Z.S. Hippe, "A comparison of six discretization algorithms used for prediction of melanoma, Advances in Soft Computing, vol. 17, 2002, s. 3-12.
- [8] A. Bellaachia, D. Portnoy, Y. Chen, ve A.G. Elkahloun, "E-CAST: A data mining algorithm for gene expression data", Proceedings of Workshop on Data Mining in Bioinformatics, 2002, s. 49-54.
- [9] R. Nicolas, A. Fornells, E. Golobardes, G. Corral, S. Puig, ve J. Malveyh, "DERMA: A melanoma diagnosis platform based on collaborative multi-label analog reasoning", The Scientific World Journal, vol. 2014, 2014, s. 1-11.
- [10] S.M. Chung ve Q. Wang, "Content-based retrieval and data mining of a skin cancer image database", International Conference on Information Technology, USA, 2001, s. 611-615
- [11] L. Ballerini, R.B. Fisher, B. Aldridge ve J. Reesy, "Non-melanoma skin lesion classification using colour image data in a hierarchical K-NN classifier", 9th IEEE International Symposium on Biomedical Imaging, Barcelona, 2012, s. 358 - 361.

## Destek Vektör Makineleri Kullanılarak Submaksimal Verilerden Maksimum Oksijen Tüketiminin Tahmin Edilmesi

M. Fatih AKAY<sup>1</sup>, Gözde ÖZSERT<sup>2</sup>, Mustafa AÇIKKAR<sup>3</sup> ve James GEORGE<sup>4</sup>

<sup>1,2</sup>Bilgisayar Müh. Böl., Çukurova Üniversitesi, TÜRKİYE

<sup>3</sup>BESYO, Çukurova Üniversitesi, TÜRKİYE

<sup>4</sup>Egzersiz Bilimleri Böl., Brigham Young Üniversitesi, UT, USA

Email: mfakay@cu.edu.tr      ozsertg@gmail.com

### Özet.

*Maksimum oksijen tüketimi ( $VO_2max$ ), kardiyο respiratuar uygunluğu belirleyen en önemli bileşendir. Bu çalışmada, submaksimal koşu bandı egzersizi uygulanan sağlıklı yetişkinlerin  $VO_2max$ 'ını tahmin etmek için Destek Vektör Makinesi (Support Vector Machines: SVM) tabanlı modeller geliştirilmiştir.  $VO_2max$  regresyon denklemini oluşturabilmek için 185 denek içeren veri kümesi kullanılmıştır. 10 katlı çapraz doğrulama kullanılarak, modellerin standart tahmin hatası (SEE) ve çoklu korelasyon katsayısı (R) hesaplanmıştır. Karşılaştırma yapabilmek amacı ile Çoklu Doğrusal Regresyon (Multiple Linear Regression: MLR) yöntemi kullanılarak  $VO_2max$  tahmin modelleri de geliştirilmiştir. Sonuç olarak, SVM tabanlı modellere ait SEE değerlerinin MLR tabanlı modellerin SEE değerlerinden daha düşük olduğu gözlemlenmiştir.*

### 1. Giriş

$VO_2max$ , kardiyο respiratuar uygunluğu belirleyen en önemli bileşendir.  $VO_2max$ , egzersiz için çalışma süresini belirlemek, aerobik egzersiz programlarının etkilerini değerlendirmek ve bireylerin sağlık açısından risklerini sınıflandırmak için kullanılır.  $VO_2max$ 'ı belirlemenin standart yolu, koşu bandı veya siklet ergometresi üzerinde bireyin yorulana kadar egzersiz yaptığı süre sonunda  $VO_2max$ 'ın doğrudan ölçülmesidir (maksimal test). Bireye uygulanan egzersiz derecesinde artış olmasına rağmen, oksijen alımında artış gözlenmiyorsa,  $VO_2max$  değerine ulaşılmıştır [1].

Maksimal testler, yönetilmek için riskli olabilir çünkü kişi aşırı yorulduğunda kalp hızı maksimum seviyeye ulaşır. Maksimal testlerin dezavantajlarından dolayı,  $VO_2max$ 'ı belirlemek için maksimum çaba gerektirmeyen diğer yöntemler geliştirilmiştir. Bu yöntemler,  $VO_2max$ 'ı tahmin etmek için egzersize

dayalı olmayan ve submaksimal egzersize dayalı verileri içerir. Egzersize dayalı olmayan modeller, maksimal ve submaksimal egzersiz testlerine ihtiyaç duyulmadan  $VO_2max$  tahmini sağlar [2].

Submaksimal test,  $VO_2max$ 'ı dolaylı olarak belirler ve genelde koşu bandı, ergometre veya pist üzerinde gerçekleştirilir. Submaksimal egzersiz testini gerçekleştirmek için koşu bandı kullanımı daha yaygındır, çünkü a) Koşu bantları fitness salonları ve laboratuvarlarda hazır bir şekilde mevcuttur. b) Yavaş bir tempoda koşu, egzersizin popüler bir şekli ve koşu bantları bir eğitim şeklidir. c) Koşu bandı protokolleri, yönetmede ve kontrol etmede kolaydır. Submaksimal testler maksimal testleri yönetmekten daha ucuz, hızlı ve güvenilirdir. Tablo 1'de  $VO_2max$ 'ı belirlemek için submaksimal modelleri kullanan bazı önemli çalışmalar özetlenmiştir.

$VO_2max$  tahmin modelinin doğruluğunu etkileyen en önemli faktör uygun araştırma tekniklerinin kullanılmasıdır. Literatürde verilen birçok submaksimal  $VO_2max$  tahmin modeli için akıllı veri analizleri için önemli araçlar sunan makine öğrenme yöntemlerinin kullanılmadığı görülmektedir (Akay ve ark. hariç). Ayrıca, yine bir çok çalışmada çapraz doğrulama yapılmadığı için verilen sonuçların güvenilir olması tartışmalıdır.

Bu çalışmada, submaksimal koşu bandı egzersizi uygulanan sağlıklı yetişkinlerin  $VO_2max$ 'ını tahmin etmek için cinsiyet, yaş, boy, vücut ağırlığı, egzersiz süreleri ve kalp atım hızları değişkenlerinin kombinasyonlarından oluşan SVM tabanlı 21 farklı model geliştirilmiştir. Veri kümesi, 185 deneye ait bilgileri içermektedir. 10 katlı çapraz doğrulama kullanılarak, modellerin standart tahmin hatası (SEE) ve çoklu korelasyon katsayısı (R) hesaplanmıştır. Karşılaştırma yapabilmek amacı ile MLR yöntemi kullanılarak  $VO_2max$  tahmin modelleri de geliştirilmiştir.

Tablo 1. Literatürde  $VO_2max$  tahmini için kullanılan bazı submaksimal regresyon modelleri.

Çalışma	Tahmin Değişkenleri	R	SEE
Larsen ve ark. [3]	G, BM, Egzersiz Süresi, HR	0.90	2.87
Dalleck ve ark. [4]	G, Yaş, HR, BM	0.86	3.91
McComb ve ark. [5]	G, Boy, BM, BF, HR	0.89	3.31
Vehrs. ve ark. [6]	G, Yaş, BM, MPH, HR	0.91	2.52
Nielson ve ark. [7]	G, BM, PFA, HR	0.91	3.36
Akay ve ark. [8]	Yaş, BM, MPH, HR	0.95	1.80

G, Cinsiyet; BM, vücut ağırlığı; BMI, vücut kütle indeksi; HR, kalp atış hızı; PFA, algılanan fonksiyonel yetenek; MPH, hız

## 2. Egzersiz Protokolü ve Veri Seti Oluşturulması

18-26 yaş arası 185 (115 erkek ve 70 kadın) sağlıklı üniversite öğrencisi bu çalışmada yer almaktadır. Egzersiz testinden önce bütün katılımcılara bu araştırmanın klinik önemi ve amacıyla ilgili detaylı bir açıklama verilmiştir.

1.5 mil submaksimal testi kapalı alan pistinde 229.7 metrede tamamlanmıştır. 1.5 mil testi 10.5 (onbuçuk) turun tamamlanmasını gerektirir. Her katılımcının kalp atım hızı sürekli ölçülmüş ve elektronik bir ölçüm cihazı kullanılarak 0.5 mil, 1 mil ve 1.5 mil için değerler kaydedilmiştir. En az 24 saat sonra (fakat 7 günü geçmemek kaydı ile) 1.5 mil test katılımcıları, laboratuardaki maksimal egzersizlerini tamamlamışlardır.

Bütün katılımcılara maksimal testin yapılacağı gecedan önce yeterli uyku (6-8 saat) almaları, testten 3 saat önce ise yemek, kafein, tütün ürünleri ve alkol almamaları konusunda bilgi verilmiştir. Katılımcılardan maksimal test sırasındaki metabolik gaz ölçümünün yapılabilmesi için başlık, ağızlık ve burun klipsi giyinmeleri istenmiştir. Maksimal teste ısınmaları için katılımcılara 2-3 dakikalık bir süre kadar koşu bandı üzerinde yürümeleri ve daha sonra tempolu ve yavaşça koşmaları söylenmiştir. Isınma süresini takiben ise koşu bandının eğimi dakikada %1.5 artırılmıştır. Bu işlem, katılımcılar maksimum zorlama seviyesine ulaşana ve sözlü cesaretle bile egzersize devam edemeyecek seviyeye gelene kadar devam etmiştir.

$VO_2$  ve solunum değişim oranı her 15 saniyede hesaplanmış, ortalaması bulunmuş ve online bir bilgisayar sisteminden çıktı alınmıştır. Maksimal test sırasında katılımcıların kalp atışları ve maksimum zorlama seviyeleri her bir bölüm sonunda kayıt edilmiş ve metabolik gaz TrueMax 2400 gaz ölçüm sistemi kullanılarak toplanmıştır.  $VO_2max$  en yüksek

ardışık 15 saniye skorlarının ortalaması alınarak hesaplanmıştır.

$VO_2max$ 'ın geçerli olması için, aşağıdakilerden en az ikisinin sağlanması gerekmektedir:

- $HR_{max}$  (220 – yaş formülü ile verilen tahmini kalp atım hızı)'ın 15 yakınında olması.
- Maksimum solunum oranının (Verilen karbondioksit / Alınan oksijen oranı) 1.1 veya daha fazla olması.
- İş yükündeki artışa rağmen  $VO_2$ 'de artış olmaması.

Çalışmada kullanılan; yaş, cinsiyet, vücut ağırlığı, boy, MIN1, HR1, MIN2, HR2, MIN3 ve HR3 bağımsız değişkenleri içermektedir.

## 3. SVM Modeli

SVM modelinin kalitesini ve performansını etkileyen en önemli bileşenler çekirdek fonksiyonunun tipi, parametreleri, C değeri ve  $\epsilon$  değeridir. C parametresi hata ve karmaşıklık arasındaki ilişkiyi belirler. C'nin büyük değerleri için SVM oldukça az hata yapmaya çalışırken, karmaşıklık artar. C'nin küçük değerlerinde SVM daha çok hata yapabilirken daha basit bir model ortaya çıkarır.

$\epsilon$  parametresi,  $\epsilon$ -duyarsız bölgenin büyüklüğünü kontrol eder. Buna ek olarak destek vektörlerinin sayısını belirler.  $\epsilon$ 'nin küçük değerleri daha fazla destek vektörlerine neden olur. Hangi C,  $\epsilon$  ve gamma ( $\gamma$ ) değerlerinin verilen problem için en iyi olacağı önceden bilinemez. Temel amaç bu parametrelerin değerlerini optimize ederek regresyon modelinin en az hatayı bulmasını sağlamaktır. Bu optimal parametrelerin seçimi için bir çok yöntem önerilmiştir. Örneğin; çapraz doğrulama, ızgara arama [9], genetik algoritmalar [10] vb. parametrelerin optimal değerlerini bulmaya çalışır. k sayıdaki bir çapraz-doğrulama orijinal veri seti k tane alt kümeye bölünür. İşlem k defa tekrarlanır ve daha sonra elde edilen performans değerlerinin ortalaması alınır.

Bu çalışmada, SVM tabanlı modellerin geliştirilmesinde kernel olarak radial tabanlı fonksiyon (Radial Basis Function : RBF) seçilmiştir. Modellerin  $C$ ,  $\varepsilon$  and  $\gamma$  değerlerini belirlemek için 5 katlı çapraz doğrulama kullanılmıştır.

$$R = \sqrt{1 - \frac{\sum (Y - Y')^2}{\sum (Y - \bar{Y})^2}} \quad (2)$$

#### 4. Bulgular ve Tartışma

SVM ve MLR modellerinin performansı, 10-katlı çapraz doğrulama kullanılarak,  $SEE$  ve  $R$  hesaplanarak değerlendirilmiştir.  $SEE$  ve  $R$ 'nin formülleri sırasıyla (1) ve (2) de verilmiştir.

$$SEE = \sigma_{Y'} \sqrt{1 - r^2} \quad (1)$$

(1) ve (2)'de,  $Y$  ölçülen  $VO_{2max}$  'ın değeri,  $Y'$  tahmin edilen  $VO_{2max}$ 'ın değeri,  $\bar{Y}$  ölçülen  $VO_{2max}$  'ın ortalaması,  $\bar{Y}'$  tahmin edilen  $VO_{2max}$ 'ın ortalaması,  $\sigma_{Y'}$   $VO_{2max}$  'ın tahmin edilen değerlerinin sapması ve  $r$  Pearson korelasyon katsayıdır.

SVM ve MLR tabanlı  $VO_{2max}$  tahmin modellerinin her bir katı için  $SEE$  ve  $R$  değeri hesaplanmıştır ve her bir model için ortalama değerler Tablo 2, Tablo 3 ve Tablo 4' te gösterilmiştir.

Tablo 2. MIN Değişkenleri İçeren Modellere Ait Sonuçlar.

No	Model Değişkenleri	MLR		SVM	
		R	SEE	R	SEE
1	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1	0.77	3.89	0.81	3.46
2	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN2	0.78	3.81	0.83	3.31
3	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN3	0.80	3.62	0.83	3.28
4	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, MIN2	0.77	3.97	0.81	3.46
5	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, MIN3	0.78	3.83	0.83	3.32
6	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN2, MIN3	0.77	3.88	0.83	3.33
7	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, MIN2, MIN3	0.75	4.11	0.81	3.49

Tablo 3. HR Değişkenlerini İçeren Modellere Ait Sonuçlar.

No	Model Değişkenleri	MLR		SVM	
		R	SEE	R	SEE
8	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR1	0.66	4.55	0.73	4.03
9	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR2	0.68	4.47	0.73	4.03
10	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR3	0.66	4.55	0.73	4.07
11	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR1, HR2	0.66	4.57	0.72	4.08
12	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR1, HR3	0.63	4.79	0.71	4.13
13	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR2, HR3	0.64	4.78	0.72	4.13
14	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, HR1, HR2, HR3	0.60	5.09	0.72	4.15

Tablo 4. MIN ve HR Değişkenlerini İçeren Modellere Ait Sonuçlar.

No	Model Değişkenleri	MLR		SVM	
		R	SEE	R	SEE
15	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, HR1	0.75	4.08	0.81	3.46
16	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN2, HR2	0.80	3.62	0.83	3.29
17	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN3, HR3	0.84	3.25	0.87	2.90
18	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, HR1, MIN2, HR2	0.86	4.12	0.80	3.49
19	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, HR1, MIN3, HR3	0.80	3.84	0.83	3.32
20	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN2, HR2, MIN3, HR3	0.82	3.52	0.87	2.96
21	Yaş, Cinsiyet, Boy, Vücut Ağırlığı, MIN1, HR1, MIN2, HR2, MIN3, HR3	0.75	4.30	0.80	3.57

Elde edilen sonuçlara göre ulaşılan noktalar aşağıda maddeler halinde listelenmiştir.

1. SVM tabanlı modeller MLR tabanlı modellere göre daha düşük *SEE* değerleri üretmiştir.
2. MIN değişkenlerini içeren VO<sub>2</sub>max tahmin modellerinin HR değişkenlerini içeren modellere göre daha düşük *SEE* ürettiği gözlemlenmiştir.
3. Yalnızca MIN değişkenlerini içeren modeller arasında, MIN3 değişkenini içeren modelin (model no: 3) en düşük *SEE* değerini ürettiği gözlemlenmiştir.
4. Yalnızca HR değişkenlerini içeren modeller arasında, HR2 değişkenini içeren modelin (model no: 9) en düşük *SEE* değerini ürettiği gözlemlenmiştir.
5. MIN ve HR değişkenlerinin ikili kombinasyonlarından oluşan modellerde, 20. modelin (yaş, cinsiyet, boy, vücut ağırlığı, MIN2, HR2, MIN3, HR3) en düşük *SEE* değerini ürettiği gözlemlenmiştir.
6. En düşük *SEE* değerini üreten modelin (17.model - yaş, cinsiyet, boy, vücut ağırlığı, MIN3, HR3) olduğu gözlemlenmiştir.
7. En yüksek *SEE* değerini üreten modelin ise (14. Model - yaş, cinsiyet, boy, vücut ağırlığı, HR1, HR2, HR3) olduğu gözlemlenmiştir.

## 5. Sonuç

Bu çalışmada submaksimal değişkenler aracılığı ile VO<sub>2</sub>max tahmini yapabilmek için SVM ve MLR yöntemleri kullanılmıştır. Veri kümesinde bulunan değişkenlerin (cinsiyet, yaş, boy, vücut ağırlığı, MIN1, HR1, MIN2, HR2, MIN3 ve HR3) kombinasyonlarından oluşan 21 farklı tahmin modelinin performansı *R* ve *SEE* hesaplanarak karşılaştırılmıştır. En iyi VO<sub>2</sub>max tahmin modeli yaş, cinsiyet, boy, vücut ağırlığı, MIN3 ve HR3 değişkenlerinin bulunduğu modeldir. SVM tabanlı tahmin modellerinin MLR tabanlı tahmin modellerine göre daha az hatalı sonuçlar verdiği gösterilmiştir. Bu nedenle SVM tabanlı modeller VO<sub>2</sub>max'ın tahminin de geçerli bir yöntem olabilmektedir.

## Teşekkür

Bu çalışma Çukurova Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir (Proje No: MMF2013D17 ve Proje No: MMF2013BAP20).

## Referanslar

- [1] George, J. D., Paul, S. L., Hyde, A., Bradshaw, D. I., Vehrs, P. R., & Hager, R. L. "Prediction of maximum oxygen uptake using both exercise and non-exercise data.", *Measurement in Physical Education and Exercise Science*, Vol. 13, No. 1, 2009, pp. 1–12.
- [2] American College of Sports Medicine. "ACSM's guideline for exercise testing and prescription (6<sup>th</sup> ed.)", *Philadelphia: Lippincott William & Wilkins*, 2000.
- [3] Larsen, G. E., George, J. D., Alexander, J. L., Fellingham, G. W., Aldana, S. G., & Parcell, A. C. (2002). Prediction of maximum oxygen consumption from walking, jogging, or running. *Research Quarterly for Exercise and Sport*, 73(1), 66–72
- [4] Dalleck, L. C., Kravitz, L., & Robergs, R. A. (2006). Development of a submaximal test to predict elliptical cross-trainer VO<sub>2</sub>max. *National Strength & Conditioning Association*, 20(2), 278-283
- [5] McComb, J. J. R., Roh, D., & Williams, J. S. (2006). Explanatory variance in maximal oxygen uptake. *Journal of Sports Science and Medicine*, 5(2), 296–303.
- [6] Vehrs, P. R., George, J. D., Fellingham, G. W., Plowman, S. A., & Dustman-Allen, K. (2007). Submaximal treadmill exercise test to predict VO<sub>2</sub>max in fit adults. *Measurement in Physical Education and Exercise Science*, 11(2), 61–72.
- [7] Nielson E. David., "Predicting VO<sub>2</sub>max in College-Aged Participants Using Cycle Ergometry and Nonexercise Measures", Department of Exercise Sciences Brigham Young University, Master of Science, December 2009.
- [8] Kale , G., Akay, M.F., Aktürk , E., Tunçdemir, A.E. "Yapay Sinir Ağları Kullanılarak Egzersiz ve Egzersize Dayalı Olmayan Verilerden VO<sub>2</sub>max tahmini" 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SİU2013, 24-26 Nisan 2013, KKTC.
- [9] Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification. <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.
- [10] Friedrichs, F., & Igel, C. (2005). Evolutionary tuning of multiple SVM parameters. *Neurocomputing*, 64, 107–117.

## Destek Vektör Makineleri ve Nitelik Seçici Algoritma Kullanılarak Maksimum Oksijen Tüketimi Tahmin Modellerinin Geliştirilmesi

M. Fatih AKAY<sup>1</sup>, Derman AKGÖL<sup>2</sup>, Erman AKTÜRK<sup>3</sup> ve James GEORGE<sup>4</sup>

<sup>1,3</sup>Bilgisayar Müh. Böl., Çukurova Üniversitesi, TÜRKİYE

<sup>2</sup>Bilgisayar Müh. Böl., Osmaniye Korkut Ata Üniversitesi, TÜRKİYE

<sup>3</sup>Egzersiz Bilimleri Böl., Brigham Young Üniversitesi, UT, USA

Email: mfakay@cu.edu.tr

dermanakgol@osmaniye.edu.tr

### Özet.

Bu çalışmada Destek Vektör Makineleri (Support Vector Machines - SVM) ile Relief-F nitelik seçici algoritması birleştirilerek maksimum oksijen tüketimi ( $VO_2max$ ) tahmin modelleri geliştirilmiştir. Modellerde giriş değişkenleri olarak; cinsiyet (gender), yaş (age), vücut kitle indeksi (Body Mass Index - BMI), kalp atış hızı (Heart Rate - HR), koşu bandı eğimi (grade - GRD), maksimum solunum oranı (Respiratory Exchange Ratio - RER) ve algılanan zorluk derecesi (Rating of Perceived Exertion - RPE) kullanılmıştır. Relief-F kullanılarak veri setindeki her değişken için bir skor hesaplanmıştır. Tahmin modellerinin performansı, 10 katlı çapraz doğrulama kullanılarak standart tahmin hatası (Standard Error of Estimate - *SEE*) ve çoklu korelasyon katsayısı (Multiple Correlation Coefficient - *R*) hesaplanarak değerlendirilmiştir.

### 1. Giriş

Bir çok kas grubunu kullanarak, orta yoğunluktan yüksek yoğunluğa kadar uzun periyotlar boyunca dinamik olarak egzersiz yapabilme yeteneğine kalp-solunum (kardiyorespiratuvar) uygunluğu adı verilir. Kalp-solunum uygunluk seviyesi solunum, kardiyovasküler ve iskelet kas sistemlerinin durumuna bağlıdır. Düşük seviyedeki kalp-solunum uygunluğu, kardiyovasküler hastalıklardan dolayı erken ölüm riskini ortaya çıkarmaktadır [1]. Kardiyorespiratuvar uygunluğunu tespit etmek için kullanılan standart yöntem, maksimal egzersiz testi (koşu bandı veya bisiklet ergometresi testleri) sırasında  $VO_2max$ 'ın direk olarak ölçülmesidir.

$VO_2max$ 'ın ölçülmesinde maksimal egzersiz testi yüksek düzeyde doğruluğa sahip olmasına karşın, bu testin bazı sınırlamaları da bulunmaktadır [2]. Maksimal  $VO_2max$  testi pahalı laboratuvar malzemesi, eğitilmiş teknisyenler, yüksek motivasyonlu bireyler, hatta bazı durumlarda bir doktorun desteğini gerektiren ve zaman alıcı bir testtir. Bunlara ilaveten, maksimal egzersiz testi bazı bireyler için uygun değildir, çünkü bu test bireyin fiziksel olarak dayanabileceği son noktaya kadar egzersiz yapmasını gerektirir. Bundan dolayı, bazı yaşlı ve risk altındaki

kişilerin tıbbi destek olmadan bu testi yapması sakıncalıdır. Ayrıca, denek sayısının fazla olduğu durumlarda tüm denekler için maksimal  $VO_2max$  testinin gerçekleştirilmesi pratik olarak mümkün değildir [3].

Maksimal egzersiz testinin dezavantajlarından dolayı,  $VO_2max$ 'ı tahmin etmek için alternatif yöntemler önerilmiştir. Literatürde maksimal test değişkenlerini kullanarak  $VO_2max$  tahmini üzerine yapılmış bazı önemli çalışmalar Tablo 1'de verilmiştir.

Literatürde, maksimal değişkenleri kullanarak yapılan  $VO_2max$  tahmin çalışmalarında çeşitli sınırlamalar vardır. İlk olarak, [4] ve Akay ve ark. haricinde yapılan çalışmalarda  $VO_2max$  tahmin denklemleri geliştirmek için sadece Çoklu Doğrusal Regresyon (Multi Linear Regression - MLR) yöntemi kullanılmıştır. İkinci olarak, yine [4] ve Akay ve ark. haricindeki diğer çalışmaların çoğunda elde edilen sonuçların güvenilirliğini sağlamak için çapraz doğrulama yöntemi kullanılmamıştır. Üçüncü olarak, çalışmaların hiç birinde  $VO_2max$  tahmini için gerekli değişkenlerin nitelik seçici algoritmalar ile değerlendirilmesi yapılmamıştır.

Pek çok örüntü tanıma tekniği veri kümesinde ilgisiz nitelikleri temizlemek için nitelik seçme işlemlerine ihtiyaç duyar [5]. Nitelik seçme hem sınıflandırma, hem de regresyon başarısını ve performansını doğrudan etkiler, ayrıca ezberleme riskini de azaltır [5-7]. Nitelik seçme ile aşırı eğitim problemi aşılarda model performansı arttırılabilir, düşük maliyetli, etkin ve hızlı modeller sunulabilir, ayrıca veri elde etme süreci daha iyi detaylandırılabilir [7, 8].

Bu çalışmada SVM ile Relief-F nitelik seçme algoritması birleştirilerek  $VO_2max$  tahmin modelleri geliştirilmiştir. Modellerde kullanılan değişkenler; cinsiyet, yaş, BMI, HR, GRD, RER ve RPE'dir. Tahmin modellerinin performansı, 10 katlı çapraz doğrulama kullanılarak, *SEE* ve *R* hesaplanarak değerlendirilmiştir. Elde edilen değerlerden 4



Tablo 1. VO<sub>2</sub>max tahmini için kullanılan maksimal regresyon modelleri

Çalışma	Tahmin Değişkenleri	R	SEE
Akay ve ark. (2009) [9]	Cinsiyet, Yaş, BMI, PFA, PA-R	0.91	3.23
Mahar ve ark. (2011) [10]	Cinsiyet, Yaş, BMI, PACER	0.75	6.17
Daros ve ark. (2012) [11]	Hız	0.73	4.53
Silva ve ark. (2012) [12]	Cinsiyet, Yaş, BM, Boy, BMI, SR	0.86	5.00
Costa ve ark. (2013) [13]	NLP	0.74	7.91
Machado ve ark. (2013) [14]	BM, Hız	0.93	4.10

**BM**, vücut kitlesi (body mass); **BMI**, vücut kitle indeksi (body mass index); **PACER**, aerobik kardiyovasküler dayanıklılık koşusu; **PA-R**, fiziksel aktivite değerlendirme (physical activity rating); **PFA**, algılanan fonksiyonel aktivite (perceived functional ability); **SR**, koşu (shuttle run); **NLP**, tamamlanan etap sayısı (number of laps performed)

değişken içeren (yaş, cinsiyet, BMI ve HR) SVM-tabanlı modelin en düşük SEE (6.10) ve en yüksek R (0.74) değerine sahip olduğu görülmüştür.

## 2. Maksimal Egzersiz Testi Protokolü ve Veri Seti Oluşturma

Testler, yaşları 18 ile 65 arasında değişen 100 (50 kadın ve 50 erkek) sağlıklı gönüllü üzerinde yapılmıştır. Denekler Brigham Young Üniversitesi (BYU) Y-Be-Fit Sağlıklı Yaşam Programından ve Utah LDS Hastanesi çalışanlarından oluşmaktadır.

Denekler, Arizona Devlet Üniversitesi Maksimal Egzersiz Testi Protokolünün ısınma aşamasında küçük bir değişiklik yapılarak maksimal egzersiz testini yapmışlardır.

VO<sub>2</sub>max'ın geçerli olması için, aşağıdakilerden en az ikisinin sağlanması gerekmektedir [1]:

- HR<sub>max</sub>(220 – yaş formülü ile verilen tahmini kalp atım hızı)'ın 15 yakınında olması.
- Maksimum solunum oranının (Verilen karbondioksit / Alınan oksijen oranı) 1.1 veya daha fazla olması.
- İş yükündeki artışa rağmen VO<sub>2</sub>'de artış olmaması.

Bu kriterlerden en azından ikisini sağlayamayan deneklerin sonuçları çalışmadan çıkarılmışlardır. Veri setinin betimsel istatistiği Tablo 2'de verilmiştir.

Tablo 2. Veri kümesinin betimsel istatistiği

Değişken	Ortalama ± Standart Sapma
Cinsiyet	0.5 ± 0.5
Yaş	36.23 ± 13.16
HR	185.16 ± 13.12
RPE	19.01 ± 0.78
GRD	9.39 ± 2.7
RER	1.17 ± 0.05
BMI	24.0 ± 4.71
VO <sub>2</sub> max (ml.kg <sup>-1</sup> .min <sup>-1</sup> )	41.39 ± 9.1

**BMI**, vücut kitle indeksi (body mass index); **GRD**, Eğitim (Grade); **HR**, kalp atış hızı (Heart Rate); **RER**, maksimum solunum oranı (Respiratory Exchange Ratio); **PRE**, algılanan zorluk derecesi (Rating of Perceived Exertion).

## 3. SVM ve Relief-F Tabanlı Algoritma

Şekil 1'de verilen SVM ve Relief-F tabanlı tahmin modelinin akış şeması kullanılmıştır. Şekil 1'den görüleceği üzere veri seti ilk olarak nitelik seçme algoritmasından geçirilmiştir. Nitelik seçme algoritması olarak Relief-F kullanılmıştır. Relief-F ile tüm giriş değişkenlerinin skorları hesaplanmıştır ve bu skorlar Tablo 3'de verilmektedir. Her aşamada en düşük skora sahip değişken elenerek 7 farklı VO<sub>2</sub>max tahmin modeli oluşturulmuştur. Veri kümesi öğrenme ve test kümesi olarak ikiye ayrılmıştır. Bu işlem 10 katlı çapraz doğrulama kullanılarak yapılmıştır. Eğitim kümesi ortalaması sıfır ve varyansı bir olan ön işlemeden geçirilmiştir. SVM'nin performansını belirleyen en önemli parametreler cost (C), epsilon (ε), gamma (γ) ve loss parametreleridir. En iyi VO<sub>2</sub>max tahmini yapabilmek için modellerde C, ε, γ ve loss parametrelerinin her biri için belirtilen arama aralığı boyunca geometrik değerler verilip deneme-yanılma yöntemi kullanılır ve böylece en uygun parametre değerleri bulunur. En uygun parametre değerleri belirlendikten sonra, parametre değerleri eğitim amacıyla kullanılan veri kümesine uygulanır ve VO<sub>2</sub>max tahmin modeli oluşturulur. Modele ait test verileri ile işlem yapılarak SEE ve R değerleri hesaplanır.

Tablo 3. Relief-F ile sıralanmış nitelikler

Nitelikler	Değerler
Cinsiyet	0.05427
Yaş	0.03435
BMI	0.01470
HR	0.01075
GRD	0.00725
RER	-0.00907

#### 4. Bulgular ve Tartışma

Relief-F kullanılarak indirgenen veri kümesinden SVM tabanlı 7 farklı VO<sub>2</sub>max tahmin modeli oluşturulmuştur. 10 katlı çapraz doğrulama kullanılarak, modellerin performansı SEE ve R hesaplanarak değerlendirilmiştir. SEE ve R'nin formülleri aşağıda verilmiştir:

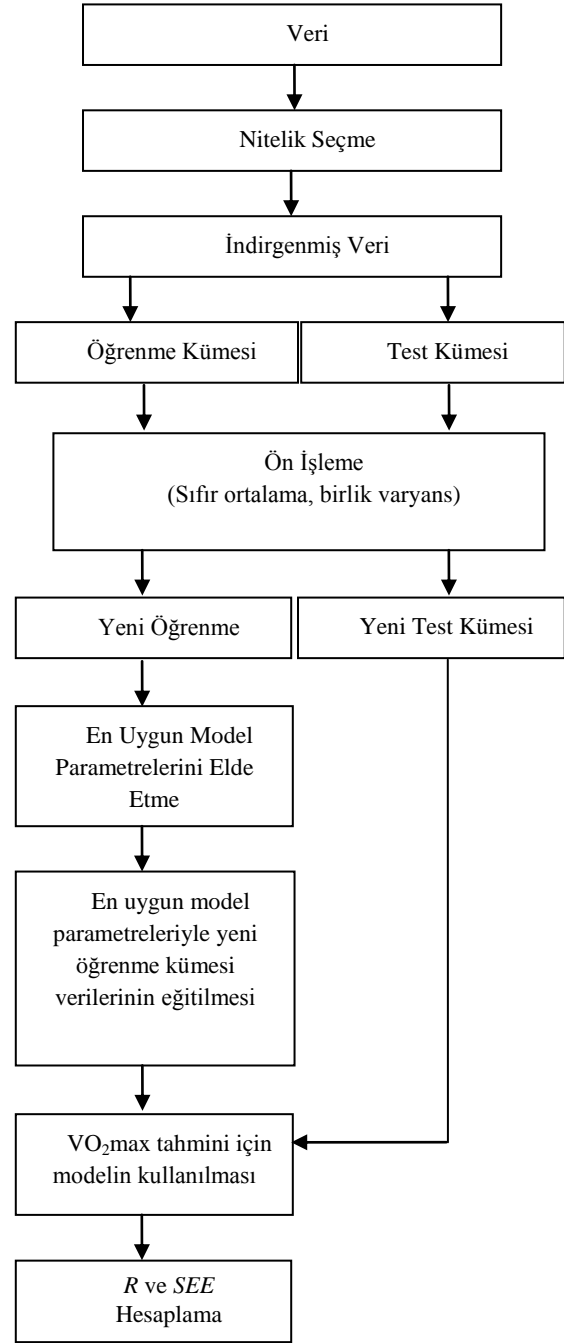
$$R = \sqrt{1 - \frac{\sum(Y - Y')^2}{\sum(Y - \bar{Y})^2}} \quad (1)$$

$$SEE = \sqrt{1 - \frac{\sum(Y - Y')^2}{N}} \quad (2)$$

Denklem 1 ve 2'de, Y ölçülen VO<sub>2</sub>max değerini, Y' tahmin edilen VO<sub>2</sub>max değerini,  $\bar{Y}$  ölçülen VO<sub>2</sub>max değerlerinin ortalamasını, N ise test edilen alt küme örneklerinin sayısını göstermektedir. Tablo 4, SVM'de oluşturulan VO<sub>2</sub>max tahmin modellerine ait R ve SEE değerlerini ve Relief-F ile seçilen nitelikleri göstermektedir.

Elde edilen sonuçlara göre aşağıdaki tartışmalar yapılabilir:

- Relief-F ile sıralanan niteliklerin sıralamasına bakıldığında en yüksek değerli niteliğin cinsiyet, en düşük ise RPE olduğu görülmektedir.
- SEE değerlerine göre en iyi sonucu Model 4'ün ürettiği ve bu modelin yaş, cinsiyet, BMI ve HR niteliklerini içerdiği gözlemlenmektedir.
- Tüm değişkenleri içeren Model 1 ile en düşük SEE değerini veren Model 4 arasında %10,4'luk fark olduğu görülmektedir. Aynı zamanda, en yüksek SEE değerine sahip olan Model 7 ile Model 4 arasında %24,47'lik fark görülmüştür.
- Maksimal değişkenlerin seçildiği Model 1, 2, 3 ve 4 incelendiğinde, HR niteliğinin en düşük hatayı verdiği görülmüştür.
- Egzersize bağlı olmayan değişkenlere (cinsiyet, yaş ve BMI) bakıldığında her üçünün seçildiği Model 5'in sadece cinsiyetin seçildiği Model 7'ye göre %17,08'lik daha iyi sonuç ürettiği görülmüştür.
- RER, RPE ve GRD değişkenlerinin olmadığı VO<sub>2</sub>max tahmin modellerinin daha düşük hataya sahip olduğu ve bunların Tablo 3'de verildiği üzere en düşük skorlu nitelikler olduğu görülmektedir.



Şekil 1. SVM tabanlı tahmin modelinin akış şeması

#### 5. Sonuçlar

Bu çalışmada, VO<sub>2</sub>max tahmin modelleri elde etmek için SVM ile nitelik seçici algoritma birleştirilmiştir. Bu modellerde giriş değişkenleri olarak koşu bandı testinden elde edilen HR, GRD, RER ve RPE ile egzersize dayalı olmayan cinsiyet, yaş ve BMI kullanılmıştır. Tahmin modellerine bakıldığında

Tablo 4. SVM-tabanlı tahmin modellerinin R ve SEE değerleri ve seçilen nitelikler

Modeller	R	SEE	Seçilen Değişkenler
Model 1	0.68	6.81	Cinsiyet, Yaş, BMI, HR, GRD, RER, RPE
Model 2	0.70	6.80	Cinsiyet, Yaş, BMI, HR, GRD, RER
Model 3	0.74	6.26	Cinsiyet, Yaş, BMI, HR, GRD
Model 4	0.74	6.10	Cinsiyet, Yaş, BMI, HR
Model 5	0.68	6.70	Cinsiyet, Yaş, BMI
Model 6	0.63	7.12	Cinsiyet, Yaş
Model 7	0.46	8.08	Cinsiyet

RER, RPE ve GRD değişkenlerini içermeyen modellerin daha düşük SEE ve daha yüksek R değerine sahip olduğu ve bunların Tablo 3'den görüldüğü üzere en düşük skorlu nitelikler olduğu görülmektedir. En iyi VO<sub>2</sub>max tahmin modeli yaş, cinsiyet, BMI ve HR niteliklerinin seçildiği modeldir.

### Teşekkür

Bu çalışma Çukurova Üniversitesi Bilimsel Araştırmalar Koordinasyon Birimi tarafından desteklenmiştir (Proje No: MMF2013YL13 ve Proje No: MMF2013BAP20).

### Referanslar

- [1] Wilmore, J.H., Costill, D.I., and Kenney, W.L. "Physiology of Sport and Exercise". UA: Human Kinetics. 2008
- [2] Taylor, H., Buskirk, E., & Henschel, A. "Maximal oxygen intake as an objective measure of cardiorespiratory performance.", *J. Appl. Physiol.*, Vol. 8, No. 1, 1995, pp. 73-80.
- [3] Balmer, P.B., & O'Connel, D.G. "Research corner regression analysis for prediction: understanding the process", *Cardiopulmonary Physical Therapy Journal*, Vol. 20, No. 3, 2009, pp. 23-26.
- [4] Ruiz, J.R., Ramirez-Lechuga, J., Ortega, F.B., Castro-Piñero, J., Benitez, J.M., Arauzo-Azofra, A., Sanchez, C., Sjöström, M., Castillo, M.J., Gutierrez, A., and Zabala, M. "Artificial neural network-based equation for estimating VO<sub>2</sub>max from the 20 m shuttle run test in adolescents", *Artificial Intelligence in Medicine*, Vol. 44, No. 3, 2008, pp. 233-245.
- [5] Saeys, Y., Inza, I. ve Larranaga, P., "A Review Of Feature Selection Techniques In Bioinformatics", *Bioinformatics*, Cilt 23, 2507–2517, 2007.
- [6] Peng, Y., Wu, Z., Jiang, J., "A Novel Feature Selection Approach For Biomedical Data Classification", *Journal of Biomedical Informatics*, Cilt 43, 15-23, 2010.
- [7] Maldonado, S., Weber, R., "A Wrapper Method For Feature Selection Using Support Vector Machines", *Information Sciences*, Cilt 179, 2208–2217, 2009.
- [8] Liu, H. ve Motoda, H., "Computational Methods Of Feature Selection", Chapman & Hall/CRC, Taylor & Francis Group 6000 Broken Sound Parkway NW, 2008, 26-27
- [9] Akay, M. F., Inan, C., Bradshaw, D. I., & George, J. D. "Support vector regression and multilayer feed forward neural networks for non-exercise prediction of VO<sub>2</sub>max", *Expert Systems with Applications*, Vol. 36, No.6, 2009, pp. 10112–10119.
- [10] Mahar, M.T., Guerieri, A.M., Hanna, M.S., & Kemble, D. (2011). Estimation of aerobic fitness from 20-m multistage shuttle run test performance. *American Journal of Preventive Medicine*, 41 (4) : 117-123.
- [11] Daros, L.B., Osiecki, R., Dourado, A.C., Stanganelli, L.C.R., Fornaziero, A.M., & Osiecki, A.C.V. (2012). Maximum aerobic power test for soccer players. *Journal of Exercise Physiology*, 15 (2) : 80-89.
- [12] Silva, G., Oliveira, N.L., Aires, L., Mota, J., Oliveira, J., & Riberio, J.C. (2012). Calculation and validation of models for estimating VO<sub>2</sub>max from the 20-m shuttle run test in children and adolescents. *Arch Exerc Health Dis*, 3 (1-2) : 145-152.
- [13] Costa, A.V.D., Costa, M.D.C., Oliveira, S.F.M.D., Albuquerque, F.L.D., Guimarães, F.J.D.S.P., & Barbosa, T.M. (2013). Validation of an equation for estimating maximal oxygen consumption of nonexpert adult swimmers. *Open Access Journal of Sports Medicine*, 4 : 19-25.
- [14] Machado, F.A., & Denadai, B.S. (2013). Prediction of aerobic power (VO<sub>2</sub>max) of children and adolescents during an incremental treadmill test. *Motriz*, Rio Claro, 19 (1) : 126-132.

## Uzman Karışımlarında Yeni Bir Yaklaşım: Uzman Kararlarının Yeni Bir Geçiş Fonksiyonuyla Birleştirmesi

Faruk BULUT<sup>1</sup>M. Fatih AMASYALI<sup>2</sup>A. Coşkun SÖNMEZ<sup>3</sup><sup>1,2</sup>Bilgisayar Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi, Yıldız Teknik Üniversitesi, Davutpaşa, İSTANBUL

<sup>3</sup>Bilgisayar Mühendisliği Bölümü

Bilgisayar ve İletişim Fakültesi, İstanbul Teknik Üniversitesi, Maslak, İSTANBUL

Email: faruk.bulut.501@std.yildiz.edu.tr

mfatih@ce.yildiz.edu.tr

sonmez@itu.edu.tr

### Özet

*Kolektif öğrenme (Ensemble) metodlarından biri olan uzman karışımları, öğrenme başarısını artırmak için kullanılan yöntemlerden biridir. Bu yöntemde veri seti bölümlere ayrılarak her bir bölüm için ayrı bir uzman eğitilir ve geçiş fonksiyonu ile (gating function) ile uzmanların kararları birleştirilir. Literatürde genelde uzman olarak, yüksek performans ve hızlarından dolayı karar ağaçları tercih edilir. Bu çalışmada veri setini kümeleme (clustering) yöntemiyle alt veri setlerine bölerek her bir alt veri seti için ayrı bir karar ağaçları inşa edilmiştir. Geliştirilen geçiş fonksiyonu ile uzmanların kararları birleştirilmiştir. Bu geçiş fonksiyonu sayesinde, her hangi bir test noktası için tüm uzmanların test noktasına olan uzaklıklarına bağlı olarak verdikleri kararlar ağırlıklandırılmış ve ortak komite kararı bulunmuştur. Yapılan denemelerde tekil karar ağaçlarına ve en yakın komşu algoritmasına göre uzman karışımlarının daha başarılı sonuçlar verdiği gözlemlenmiştir.*

### 1. Giriş

Bir veri kümesinin alt bölgeleri birbirinden farklı yapılar içerebilir. Bu farklılıklar, örnek (samples) sayısından, sınıf etiketi sayısından, verilerin tipinden, seyrek veya yoğun oluşundan kaynaklanıyor olabilir. Bahsedilen bu farklılıklar sınıflandırma başarısını olumlu ya da olumsuz etkileyebilmektedir. Sınıflandırma başarısını artırmak amacıyla tüm veri kümesi için tek bir model belirlemek yerine her bir alt bölge için farklı modeller tasarlamak gerekebilir.

Çalışmamızda bu alt bölgeleri ayrı bir veri seti gibi düşünerek bahsedilen bu etkileri en aza indirecek ve genel sınıflandırma başarısını artıracak bir yöntem

geliştirilmiştir. Bu amaçla tüm veri seti için tek bir öğrenici yerine, veri setinin her bir alt bölümü için ayrı ayrı öğrenici inşa edilmiştir. Veri setinin alt bölümlerini belirlemek için kümeleme (clustering) işlemi yapılmıştır.

Uzman Karışımları (Mixture of Experts, UK) algoritması temelde iki soruya cevap arar. Birincisi veri setinin alt bölümlerinin nasıl belirleneceği, diğeri ise test örneklerinin nasıl etiketleneceğidir. Literatürde [1-3] bu sorulara cevap olarak veri setini bölümlenme işlemi için Beklenti Artırımı (Expectation Maximization, BA) algoritması ve etiketleme işlemi için BA yöntemine özgü bir geçiş fonksiyonu (Gating Function) gösterilmektedir. Bilindiği üzere BA yöntemi, yumuşak bir kümeleme (softclustering) yapmaktadır. Test örneğinin etiketlenmesinde ait olduğu alt küme için tasarlanmış uzmanının kararı geçerlidir.

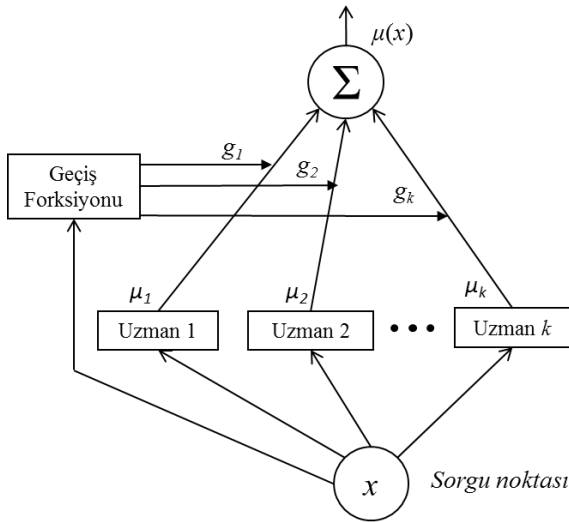
Bu çalışmamızda veri setinin alt bölümleri *k*-means yöntemiyle katı kümeleme (hard clustering) yapılarak belirlenmiştir. Her bir alt bölüm için ayrı bir Karar Ağacı (Decision Tree, KA) ile modellenerek homojen bir kolektif öğrenme yapısı oluşturulmuştur. Bir test örneğinin etiketlenmesi için tüm uzmanların kararlarını birleştiren yeni bir geçiş fonksiyonu (gatingfunction) tasarlanmıştır.

Çalışmamız beş bölümden oluşmaktadır. İkinci bölümde UK'nın çalışma prensibine; üçüncü bölümde uygulama ve deneysel sonuçlara; dördüncü bölümde üzerinde çalıştığımız yöntemin karmaşıklık analizine; beşinci bölümde ise yorumlara yer verilmiştir.

### 2. UK İçin Yeni Bir Geçiş Fonksiyonu

Kolektif öğrenme (*Ensemble Learning*) yöntemlerinden biri olan UK için son 20 yıl içerisinde teorik çalışmalar yapılmış, farklı yaklaşımlar sunulmuştur [2]. UK'da amaç, veri setini böl-yönet mantığıyla daha az karmaşık bir yapıya indirgeyerek sınıflandırma performansını artırmaktır. UK ile veri seti en uygun alt kümelerle bölünür ve her bir alt küme için bir uzman tasarlanarak o bölgede sınıflandırma başarısı artırılmaya çalışılır. Her hangi bir test noktasının sınıflandırılması normalde ait olduğu alt bölgenin uzmanı ile yapılmaktadır. Fakat çalışmamızda test noktasının sınıflandırılması tüm bölgelere ait uzmanların kararlarının birleştirilmesi ile yapılmıştır. Bu işlemi geçiş fonksiyonu (*gate function*) adındaki bir mekanizma yapmaktadır [1,3]. Şekil-1'de görülen UK'nın çalışma mantığı şu basamaklardan oluşur:

1. Veri seti K adet alt kümeye bölünür.
2. Her bir alt küme için bir Uzman (*Expert*) eğitilir.
3. Gelen  $x$  test örneğinin etiketlenmesi için tüm uzmanlara danışılır ve kararları ( $\mu_i$ ) alınır.
4. Geçiş fonksiyonu mekanizması ile kararlar ağırlıklandırılır ( $g_i * \mu_i$ ) ve test noktasının her bir sınıfa ait olma olasılığı belirlenir.
5. En yüksek oranın ait olduğu sınıf ile test noktası etiketlenir (*majority voting*).



Şekil 1. UK'nın çalışma prensibi

Çalışmamızda farklı bir uzman tasarımı ve buna bağlı olarak bir geçiş fonksiyonu geliştirilmiştir. Şekil-1'de görüldüğü gibi  $x$  test noktasının etiketlenmesinde her bir uzmanın verdiği karar geçiş fonksiyonu tarafından ağırlıklandırılır. Geçiş fonksiyonun tasarlanmasında uzakta bulunan uzmanların etkisi az; yakında olanların etkisi fazla olması gerektiği düşüncesinden

yola çıkılarak *Shepard* metodundan [4] yararlanılmıştır.

Bir test örneğinin sadece bir uzmana danışılması durumunda sınıflandırma hatalarının oluşması muhtemeldir. Bu test örneği alt kümelerin karar sınırlarına yakınsa hangi uzmanın kararına danışılacağı problem oluşturmaktadır. Bu çalışmada bu soruna çözüm aranmış ve bahsedildiği üzere yeni bir geçiş fonksiyonu tasarlanmıştır.

Formül 1'de  $w_i$ ,  $i$ . uzmanın hesaplamadaki ağırlığıdır.  $E_j$ ,  $j$ . uzmanın öğrendiği alt kümenin merkez noktasıdır. Merkez noktası küme içindeki eğitim örneklerinin aritmetik ortalaması ile bulunmaktadır ve ilgili uzmanı temsil etmektedir.

$$w_i = \frac{1}{d_i^2} = \frac{1}{d_i(x, E_j)^2} \quad (1)$$

$$d(x, E_j) = \sqrt{\sum_{i=1}^A (a_i(x) - a_i(E_j))^2} \quad (2)$$

$x$  test noktası ve  $E_j$  arasındaki uzaklık Öklid uzaklık formülü (2) ile bulunmaktadır.  $A$ , uzayın boyut (özellik) sayısıdır ve herhangi bir noktanın özellikleri vektör olarak şu şekilde tanımlanmaktadır:  $\langle a_1(x), a_2(x), a_3(x), \dots, a_A(x) \rangle$ . Burada  $a_i(x)$ ,  $x$ 'in  $i$ . özelliğini göstermektedir.

Tom Mitchell tarafından önerilen *Distance-weighted-k-NN* sınıflandırıcının [4],[6] çalışma prensibi buraya uyarlanmış ve geçiş fonksiyonu olarak (3) numaralı formül geliştirilmiştir.  $g_i$ ,  $i$ . uzmanın  $x$  test noktası için hesaplamadaki ağırlığıdır.

$$\text{Geçiş Fonksiyonu} = g_i = \frac{w_i}{\sum_{j=1}^K w_j} \quad (3)$$

$$G = \sum_{i=1}^k g_i = 1 \quad (4)$$

$K$ 'nın alt küme ve aynı zamanda uzman sayısını gösterdiği 4 numaralı formülde her bir uzman için atanan yüzdelik ağırlıklar toplamı yani  $G$ , 1'e eşittir. Görüldüğü üzere  $x$  örneğinin sınıfı belirlenirken uzaklığa bağlı olarak her bir uzmanın (Karar ağaçlarının) verdikleri kararlar ağırlıklandırılmıştır.

$x$ 'in ait olabileceği sınıfların yüzdelik olarak en büyüğü ile etiketleme yapılabilmesi için sınıflandırma fonksiyonu formülümüz (5) ve bu formülün genişletilmiş hali (6) şu şekildedir:

$$\mu(x) = \underset{c \in C}{\operatorname{argmax}} (g_i \cdot \mu_i^c(x)) \quad (5)$$

$$\mu(x) = \underset{c \in C}{\operatorname{argmax}} \left( \frac{\sum_i^K w_i \cdot \mu_i^c(x)}{\sum_j^K w_j} \right) \quad (6)$$

$\mu: R \rightarrow C$  olan  $\mu$  fonksiyonu tüm sınıf etiketleri için ayrı ayrı hesaplama yapıp maksimum argümanı sınıf etiketi olarak  $x$ 'e atamaktadır. Burada  $C$ , veri setindeki tüm sonlu sınıf etiketleri kümesidir ve şu şekilde tanımlanabilir:  $\{c_1, c_2, c_3, \dots, c_s\}$ .  $\mu_i^c(x)$  fonksiyonu ise,  $i$ . uzmana göre  $x$ 'in  $c$  sınıfından olma olasılığını hesaplamaktadır.

### 3. Pratik Uygulama ve Deneysel Sonuçlar

Uygulama alanı olarak 36 adet UCI Benchmark veri seti [5] seçilmiştir. Tüm veri setlerine ait değerler normalize edilmiş, kayıp değerler yer değiştirilmiş, nominal değerler ikili sayısal değerlere dönüştürülerek kullanıma hazır hale getirilmiştir. Tüm algoritmalar MATLAB ortamında, her bir veri seti üzerinde 5x2 çapraz geçişleme ile test edilmiştir.

Yapılan uygulamalarda veri setleri  $k$ -means kümeleme yöntemiyle (iterasyon sayısı=100)  $k$  değerleri sırasıyla 2 ile 50 arasında alınarak kümeleme işlemi yapılmıştır. Veri setlerini daha yüksek sayıda kümelere ayırmak hem hesaplama süresini artırmakta hem de seyrek veri setlerinde çok az elemanlı alt kümeler oluşturmaktadır. Bu durumda  $k$ -means'teki  $k$  parametresi artırıldığında (veri setindeki eleman sayısına yaklaşıldığında) *distance weighted k-NN* sınıflandırmasına benzer bir yapının ortaya çıktığı gözlemlenmiştir. Fazla örnekleri bulunan veri setlerini daha fazla sayıda alt kümelere; az sayıda örnekleri bulunan veri setlerinin de az sayıda kümelere bölmenin sınıflandırma başarısını artırdığı gözlemlenmiştir.

#### 3.1. Temel Uzman seçimi

Bu çalışmada temel uzman seçimini, karar ağaçları ile yapılmıştır.  $k$ -means ile oluşturulan  $k$  tane veri setinin her biri ayrı bir veri seti gibi düşünülüp  $k$  tane KA inşa edilmiştir.

UK uygulamalarında KA kullanımı mantığı ilk olarak Jordan ve Jacobs tarafından anlatılmıştır [7]. Bugüne dek UK yöntemleri üzerinde pek çok çalışma [2] yapılmış ve farklılıkları gösterilmiştir. UK'nın günümüzde olduğu gibi *Radial Basis* fonksiyonlarıyla kullanılmasını Lei Xu önermiştir [8]. KA'ların,

kompakt ve sınıflandırmayı kolaylaştırıcı özelliğinden ötürü *Radial Basis* fonksiyon ağlarında TB-RBF (*Decision Tree based Radial Basis Function*) adıyla kullanıldığı bilinmektedir [9]. Hızlı bir şekilde eğitilebilmeleri, karar verme hızlarının yüksek oluşu ve beyaz kutu (*white box*) özellikleri ile çalışma sistemlerinin kolay analiz edilebilmesi gibi niteliklerinden ötürü KA'lar diğer öğrencilere göre daha avantajlıdır. Kolektif öğrenme metodlarında temel öğrenici olarak genelde KA'lar tercih edildiği de bir gerçektir [9-10].

#### 3.2. Ağırlıklandırma Yöntemi

Uzmanların kararları (1) numaralı formül ile uzaklığa bağlı olarak yapılmaktadır. Buradaki ağırlıklandırma işlemi için kullanılan farklı yöntemler vardır:  $1/d$ ,  $1/d^2$  ve  $1/d^3$ .  $1/d^2$ 'li yöntem,  $1/d$ 'ye göre yakındaki öğelerin etkisini çok fazla; uzaktakinin etkisini çok az almaktadır. Geçiş fonksiyonu için kullanılan  $1/d^2$ 'li formül, yapılan deneysel uygulamalarda diğerinden daha iyi sonuçlar verdiği için tercih edilmiştir.

#### 3.3. Sonuçlar

İki sınıflandırma mekanizması tarafından elde edilen sonuçların istatistiksel anlamlılığını belirleyebilmek için T-Test yöntemi kullanılmıştır. T-Test sonuçları üç farklı değer içermektedir: *win* (başarılı), *loss* (başarısız) ve *tie* (eşit). Bu sayede geliştirilen yöntemin başarılı olup olmadığı tespit edilebilmektedir. Tablo-1'de 36 UCI veri seti ile yapılan uygulamaların sonuçları görülmektedir. Geliştirdiğimiz UK yöntemi 3 ayrı sınıflandırıcı ile kıyaslanmıştır. Bunlar INN (*En Yakındaki Komşu* algoritması), en iyi sonucu veren  $k$ -NN ( $k$  – *En yakın Komşuluk* algoritması) ve KA sınıflandırıcılarıdır. T-Test sonucuna göre elde edilen *win*, *tie* ve *loss* sayıları Tablo-1'de görülmektedir. Görüldüğü üzere UK'nın KA ile kıyaslanmasında 11 adet veri kümesinde performans artışı (*win*) sağlanmış, 23'ünde değişme olmamış, sadece 2 tanesinde başarısız olunmuştur. Bu da üzerinde çalışılan yöntemin başarılı sonuçlar elde ettiğini göstermektedir.

Tablo 1. Sonuçlar

T-Test Sonucu	UK'yı INN ile Karşılaştırma	UK'yı En iyi $k$ -NN ile Karşılaştırma	UK'yı KA ile Karşılaştırma
<i>Win</i>	21	11	11
<i>Tie</i>	11	18	23
<i>Loss</i>	4	7	2

Tüm veri setleri için oluşturulmuş KA sınıflandırıcısı ile bu uygulamada yaptığımız UK sınıflandırıcısının doğruluk oranları Tablo-2'de görülmektedir. Bu tablo ile tekil bir öğrenci olan KA'nın sınıflandırma performansı ile UK'nın performansı T-Test sonuçlarıyla kıyaslanabilmektedir.

Tablo 2. UCI Test Sonuçları

Veri seti Adı	KA Doğruluk Oranı	UK		KA ile UK'yı karşılaştırma	
		k	Doğruluk Oranı	Yüzdellik fark	T-Test Sonucu
abalone	0.2122	50	0.2231	5.11	win
anneal	0.9883	2	0.9879	-0.05	tie
audiology	0.8615	2	0.8166	-5.22	loss
autos	0.6614	2	0.6426	-2.84	tie
balance-scale	0.7811	30	0.8614	10.28	win
breast-cancer	0.6692	20	0.7028	5.02	win
breast-w	0.9465	4	0.9536	0.76	tie
col10	0.7575	3	0.7559	-0.21	tie
colic	0.8092	2	0.8212	1.48	tie
credit-a	0.8197	4	0.8533	4.10	win
credit-g	0.6870	20	0.7140	3.93	win
d159	0.9698	2	0.9610	-0.90	tie
diabetes	0.7036	10	0.7375	4.81	win
glass	0.6527	5	0.6615	1.35	tie
heart-statlog	0.7415	35	0.8015	8.09	win
hepatitis	0.7923	4	0.8103	2.28	tie
hypothyroid	0.9943	2	0.9932	-0.11	tie
ionosphere	0.8547	35	0.8991	5.20	win
iris	0.9333	2	0.9400	0.71	tie
kr-vs-kp	0.9901	2	0.9838	-0.63	tie
labor	0.8596	2	0.8526	-0.82	tie
letter	0.8234	2	0.8203	-0.38	tie
lymph	0.7901	3	0.7775	-1.60	tie
mushroom	1.0000	2	0.9997	-0.03	tie
primary-tumor	0.4265	2	0.4351	2.02	tie
ringnorm	0.8842	10	0.9375	6.03	win
segment	0.9436	2	0.9474	0.39	tie
sick	0.9824	2	0.9846	0.22	tie
sonar	0.7000	5	0.7231	3.30	tie
soybean	0.8824	2	0.8809	-0.17	tie
splice	0.9254	2	0.9066	-2.03	tie
vehicle	0.6849	5	0.6835	-0.21	tie
vote	0.9361	3	0.9549	2.01	tie
vowel	0.6873	9	0.7143	3.94	win

waveform	0.7394	35	0.8051	8.89	win
zoo	0.9762	2	0.9214	-5.61	loss

İlk sütun tekil KA sınıflandırıcısının veri kümeleri üzerinde verdiği doğruluk değerini; ikinci ve üçüncü sütun ise UK sınıflandırıcısının değerlerini göstermektedir. İkinci sütunda UK için oluşturulan alt küme sayısını yani  $k$ -means yöntemindeki  $k$  parametresini; sonraki sütun UK'nın  $k$  değerine bağlı olarak verdiği doğruluk değerini göstermektedir. Son iki sütunda UK ile KA karşılaştırıldığında yüzdellik artış-azalış ile T-Test sonucu verilmektedir. Yaptığımız UK uygulamasında doğruluk oranının bazı veri setlerinde KA doğruluk oranına göre %10.28'e kadar artış sağladığı gözlemlenmiştir.

#### 4. Yöntemin Karmaşıklık Analizi

Uzman olarak inşa edilen bir KA'nın büyük  $O$  notasyonuna göre zaman karmaşıklığı şu formül ile açıklanmaktadır[11]:

$$O(A * n * \log n) \quad (7)$$

$n$  örnek sayısını,  $A$  ise özellik sayısını göstermektedir.

$k$ -means kümeleme yönteminin karmaşıklığı ise şu formül ile analiz edilmektedir[12]:

$$O(n * k * I * A) \quad (8)$$

$k$  küme sayısını,  $I$  iterasyon sayısını simgelemektedir.

Geliştirdiğimiz UK yönteminde  $k$  tane KA oluşturmanın maliyeti ise şu şekildedir:

$$O\left(k * A * \frac{n}{k} * \log \frac{n}{k}\right) = O\left(A * n * \log \frac{n}{k}\right) \quad (9)$$

Bir veri için yalın bir KA inşa etmek ile  $k$  tane KA inşa etmek arasındaki zaman karmaşıklığı oranını şu şekilde bulunabilir:

$$O\left(\frac{A * n * \log n}{A * n * \log \frac{n}{k}}\right) = O\left(\frac{\log n}{\log \frac{n}{k}}\right) \quad (10)$$

$k$  parametresi her zaman için küçük bir tamsayı olarak alındığından dolayı önemsenmeyebilir. Bu durumda  $k$  tane KA oluşturmak zaman karmaşıklığı açısından maliyetli bir durum olmadığı sonucuna varılabilir.

$I$  ve  $A$  sayılarının her bir uzman için aynı olduğu düşünülüp sabitlenirse, UK yönteminin karmaşıklığı şu şekilde dönüşür:

$$O\left(A * n * \log \frac{n}{k}\right) + O(n * k) + O(k) \quad (11)$$

Yukarıdaki zaman karmaşıklığı analizinde ilk iki karmaşıklık  $k$  tane KA ve  $k$  tane küme oluşturmayı göstermektedir. En sonda bulunan  $O(k)$  karmaşıklığı ise geçiş fonksiyonuna aittir ve  $k$  küçük bir tamsayı olduğu için önemsenmeyecek etki düzeyindedir.

Yapılan incelemelerde BA kümeleme yöntemi içeren uzman karışımlarının karmaşıklığı [2-3] ile  $k$ -means yöntemli çalışmamızın karmaşıklığının birbirine benzer olduğu görülmüştür.

## 5. Değerlendirme ve İleri Çalışmalar

Bir veri setinin bazı bölgelerinin diğerlerinden farklı özelliklere sahip olması genel sınıflandırma performansını düşürebilir. Bu nedenle bu bölgeleri diğerlerinden ayırmak amacıyla önce kümeleme yapıldı, sonra her bir bölge için ayrı bir uzman eğitildi, ardından bu uzmanlar bir geçiş fonksiyonuyla birleştirilerek uzman karışımı bir sistem geliştirildi. Bu çalışmamızda tüm veriye tek bir model belirlemek yerine, veriyi alt bölgelere ayırıp her biri için farklı modeller belirlemenin sınıflandırma performansını genel olarak artırdığı görüldü.

Uzman oluşturabilmek için veri seti denetimsiz öğrenme ile kümelere bölünmeye çalışılmaktadır. Bu ise hesaplama süresini tekil öğrencilere göre artırmaktadır.  $k$ -means ile yapılan kümeleme işleminde her defasında başka küme grupları olduğu için sınıflandırma başarısı kümelerin yerleşimine, eleman sayısına ve yapısına bağlı olarak az da olsa değişiklik göstermektedir. Yapılan T-Test analizlerinde hemen hemen aynı sayıda *win*, *tie*, *loss* çıktılarını elde edildiği için bu değişiklik önemsenmeyecek düzeydedir.

Ayrıca  $k$ -means yöntemi iki boyutlu veri kümelerinde dairesel; üç boyutlu ortamda da küresel tarzda kümeleme yaptığı için alt kümelerde bulunan örnekler o kümenin merkez noktası etrafına saçılmış bir şekilde bulunmaktadır. Kısaca  $k$ -means metodunda oluşturulan kümeler iç içe veya sarmal yapıda olmamaktadır. Bu özellik, UK'da uzaklığa bağlı olarak ağırlıklandırma ile sınıflandırma yapan geçiş fonksiyonu için çok uygun olmaktadır ve yüksek başarı elde edilmesini sağlamaktadır.

İleri aşamalarda, uzman olarak KA'nın haricinde farklı sınıflandırıcılar ve farklı kümeleme yöntemleri de kullanılarak performans karşılaştırmaları yapılabilir. Ayrıca BA ile yapılan UK çalışmaları ile

üzerinde çalıştığımız yöntem değişik açılardan kıyaslanabilir.

## 6. Kaynaklar

- [1] Alpaydın E, Yapay Öğrenme Kitabı, Uzman Karışımları, Boğaziçi Üniversitesi Yayınevi, (2010), s. 373-376, 253-257
- [2] Yuksel, S. E. Twenty Years of Mixture of Experts. IEEE Transactions On Neural Networks And Learning Systems, (2012). s. 1177-1193.
- [3] Dempster, A.P., Laird, N.M., Rubin, D.B. "Maximum Likelihood from Incomplete Data via the EM Algorithm". Journal of the Royal Statistical Society, Series B 39, (1977). s.1-38.
- [4] Shepard, D. A two-dimensional interpolation function for irregularly spaced data. Proceedings of the 23rd National Conference of the ACM, (1968). s. 517-523.
- [5] Bache, K. & Lichman, M. UCI Machine Learning Repository <http://archive.ics.uci.edu/ml/Irvine>, CA: University of California, School of Information and Computer Science. (2013).
- [6] Mitchell, T. Machine Learning, Title: 8.2.1 Distance-Weighted-kNN. USA: Mc Grow-Hill, (1997). s. 233-236, s. 156-159.
- [7] Michael I. Jordan, Robert A. Jacobs, "Hierarchical Mixture of Experts and the EM Algorithm" Journal Neural Computation archive, Vol.6, Issue 2, (1994)., s.181-214
- [8] Lei Xu, RBF nets, Mixture Experts, and Bayesian Ying-Yang Learning, Elsevier Neurocomputing 19 (1998) s.223-257.
- [9] M. Kubat, Decision Trees Can Initialize Radial-Basis Function Networks, IEEE Transaction On Neural Networks, VOL.9, NO.5, (1998), s. 813-821
- [10] Zhi-Hua Zhou, *Ensemble Methods: Foundations and Algorithms*, CRC Press, (2012). s. 270-272
- [11] Ian H. Witten, Eibe Frank, *Data Mining: Practical Machine Learning Tools and Techniques*, 2<sup>nd</sup> Edition, Elsevier, (2005). s. 196-198
- [12] Myatt, G.J, *Making Sense of Data: A Practical Guide to Exploratory Data Analysis and Data Mining*, Wiley, (2007). s. 120-129.



## İlişkisel Verilerin Semantikleştirilmesi

Öğr.Gör. Mustafa YENİAD<sup>1</sup> Yrd.Doç.Dr. Yakup KUTLU<sup>2</sup>

<sup>1</sup>Bilgisayar Teknolojisi ve Programlama Bölümü  
Antakya Meslek Yüksekokulu  
Mustafa Kemal Üniversitesi, Antakya, HATAY

<sup>2</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
Mustafa Kemal Üniversitesi, Antakya, HATAY

Email: myeniad@mku.edu.tr

ykutlu@mku.edu.tr

### Özet

*Bu çalışmada, ilişkisel veritabanı yönetim sistemindeki veriler yeni nesil web (Web 3.0) olarak nitelendirilen Semantik (Anlamsal) Web teknolojisine uygun hale dönüştürülerek semantik veri deposuna aktarılmıştır. İlişkisel ve semantik verilerin karşılıklı doğrulanmasıyla dönüşüm işleminin başarılı olduğu anlaşılmıştır. Ayrıca ilişkisel veritabanı üzerinde SQL ve semantik veri deposunda SPARQL sorguları aracılığıyla geri çağırma, ekleme, güncelleme ve silme işlemleri yapılarak sonuçlar performans açısından karşılaştırılmış; semantik veri deposunun ilişkisel veritabanı yönetim sistemine göre daha yüksek performans sunduğu görülmüştür.*

### 1. Giriş

Semantik (Anlamsal) Web (SW), internet ortamındaki kaynakların daha kolay erişilebilir, makineler tarafından anlaşılabilir ve yazılım ajanları tarafından kullanılabilir hale getirilmesi amacıyla yeniden tanımlanması fikridir. SW fikri, 2001 yılında Tim Berners Lee ve arkadaşları tarafından ortaya atılmıştır [1]. Lee, SW'ı mevcut webden ayrı bir oluşum değil, onun uzantısı olarak tanımlar ve SW'in ilk aşamasının, web ortamındaki içerikleri makinelerin işleyip "anlayabilmesi" olacağını belirtmiştir. SW, web teknolojisinin güncel bir sürümü; yazılımlar için yeni bir üstveri (metadata) teknolojisi; açık kaynak teknolojiler lehine bir sosyal hareket veya yeni nesil bir yapay zeka teknolojisi olarak değerlendirilebilir [2].

Mevcut web içeriklerinin çok büyük bir kısmının henüz RDF formatına dönüştürülmemiş olması, SW teknolojisinin yaygınlaşmasının önündeki ciddi problemlerden biri olarak durmaktadır [3]. İlişkisel veritabanlarındaki içeriklerin semantikleştirilmesi

amacıyla araştırmalar sürdürülmektedir ve henüz bir standart oluşturulamamıştır. Erling ve Mikhailov, Virtuoso yazılımının "RDF Views" özelliğini kullanarak ilişkisel verileri bir ontolojiye göre dönüştürmeden RDF üçlüleri şeklinde okutabilmiştir ancak bu durum, diğer popüler ilişkisel veritabanları için sınırlılık oluşturmaktadır [4]. Auer ve ark., Triplify yazılımı aracılığıyla, ontoloji kullanmadan ve manuel yazdıkları SQL sorgularına göre ilişkisel veritabanından RDF üretmişlerdir ancak Triplify'nin SPARQL desteğinin bulunmaması, semantik doğrulama için sınırlılık oluşturmuştur [5]. Bumann, ilişkisel veritabanındaki verilerin basit bir ontolojiye RDF çıktılarını üretecek SQL sorgularını hazırlamış ve RDF üçlüleri elde etmiştir. Ancak herhangi bir eşleme dili (mapping language) kullanmadığından veritabanı şemasının bilinmesi zorunluluk olarak devam etmiş; ayrıca RDF üçlüleri bir semantik depoya aktarılmadığından dolayı veriler üzerinde doğrulayıcı SPARQL sorguları işletilememiştir [6].

Bu çalışmanın amacı, SW için halen problem olarak duran ilişkisel veritabanlarının semantikleştirilmesine otantik bir örnek oluşturmak üzere; ilişkisel veritabanındaki verilerin, okul süreçlerine göre modellenmiş ontoloji bağlamında RDF dönüşümünün gerçekleştirilmesi ve semantik depoya aktarılarak sonuçların doğrulanmasıdır.

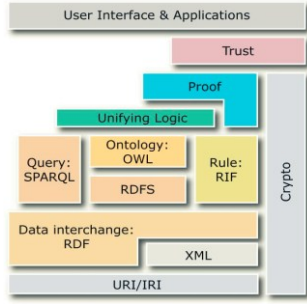
### 2. Materyal ve Metod

#### 2.1. SW Bileşenleri

##### 2.1.1. Ontoloji

SW teknolojisinin bir anlamda kalbini ontolojiler oluşturur. Ontoloji, insanlar veya sistemler arasındaki

iletişimin temel aldığı bir bilgi alanının, ilgili sistemler tarafından tanınan ortak anlamını ifade eder [7]. Bu bağlamda ontolojiler, bir alanla ilgili nesnelere sahip olduğu özelliklerin ve birbirleri arasındaki ilişkilerin tanımlanmasını gerekli kılar. SW'de ontolojilerin modellenmesi, yayımlanması, dokümanlar üzerinde yazılım ajanlarının ileri düzeyde web aramaları yapabilmesi için RDF, RDFS ve OWL semantik tanımlama dilleri kullanılır (Şekil 1). XML sözdizimine dayanan OWL (Web Ontology Language), bilgi yönetimini, yazılım ajanlarını ve ileri düzeyde web aramalarını destekleyen, ontolojilerin yayımlanması ve paylaşımı için kullanılmaktadır.



Şekil 1. Semantik Web Katmanları [8]

### 2.1.2. RDF Üçlüsü (RDF Triples)

SW'de kaynaklar, RDF Üçlüsü (RDF Triples) olarak adlandırılan; özne (subject), özellik / yüklem (property) ve nesne (object) şeklindeki bir yapıyla ifade edilir ve Web tanımlayıcıları ile (Uniform Resource Identifiers ya da kısaca URI şeklinde) tanımlanır [8]. RDF sözdiziminde kullanılan ilişki betimleyici sözcüklerin anlamı konusunda genel bir üstveri (metadata) standardı oluşturmak üzere URI uzayına eşlenmiş çalışmalara Dublin Core Metadata, FOAF (Friend of a Friend) Project ve PURLs (Persistent Uniform Resource Locators) örnek verilebilir.

RDF üçlülerinin yazımında standartlaşmış bir kullanım biçimi henüz yoktur ve RDF birden fazla formatta ifade edilebilir. RDF/XML, N-Triple, Notation 3, Turtle en bilinen RDF formatlarıdır.

Tablo 1. RDF örneği

Özne	Özellik	Nesne
personel99005	givenName	Elif
personel99005	familyName	YENİAD

Tablo'deki "personel99005'in adı Elif" ve "personel99005'in soyadı YENİAD"dır, cümlelerinin RDF karşılığı aşağıdaki gibi olur:

```
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#" xmlns:j.0="http://xmlns.com/foaf/spec/#" >
```

```
<rdf:Description rdf:about=
"http://localhost/otomasyon.owl#personel99005">
<j.0:givenName>Elif</j.0:givenName>
<j.0:familyName>YENİAD</j.0:familyName>
</rdf:Description>
</rdf:RDF>
```

RDF kodlarının başında XML deklarasyonu bulunur. Sonrasında kök eleman olarak RDF başlangıcı ve isim uzayı kısaltmalarının tanımları, ardından da özneye ait alt etiketler gelmektedir.

### 2.1.3. Semantik Depo (Triple Store)

RDF üçlülerinin depolanması, geri çağırılması ve üzerinde birtakım sorguların yapılabilmesi için işlevsel olarak günümüz veritabanlarına benzeyen semantik depolar kullanılır. Literatürde "Triple Store" olarak da anılan semantik depoların, SW teknolojisi yavaşlaştıkça ilişkisel veritabanı yönetim sistemlerinin yerini alacağı düşünülmektedir. RDF üçlülerinin semantik depoya eklenmesi, geri çağırılması, güncellenmesi ve silinmesi gibi işlemler için SPARQL (Sparql Protocol And RDF Query Language) kullanılır. SPARQL, günümüz veritabanı yönetim sistemlerinde kullanılan SQL veritabanı sorgulama diline işlevsel açıdan benzerdir ancak anlamsal çıkarsamalar da yapabilen daha esnek bir yapıya sahiptir.

### 2.2. Verilerin Semantikleştirilmesi

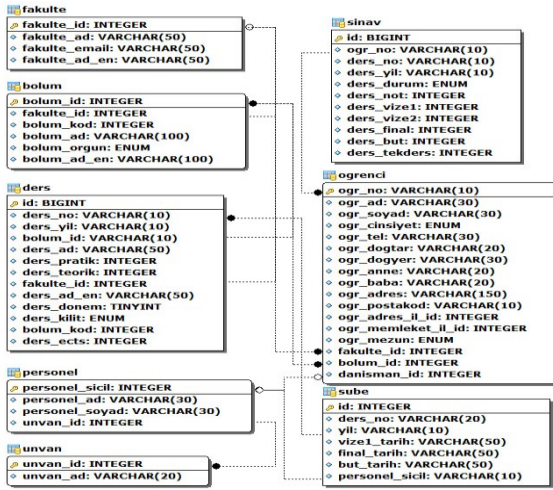
Öğrenci işleri ilişkisel veritabanını semantikleştirmek üzere aşağıdaki adımlar takip edilmiştir:

- Veritabanı şeması oluşturularak tablolar arasındaki ilişkiler çıkarıldı (Şekil 2).
- Gerçek kişilerin temsil edilmesini önlemek amacıyla, veritabanındaki öğrenci ve personel ad soyad alanları kendi aralarında rastgele (random olarak) yer değiştirildi.
- Ontolojide otomasyon verilerini temsil edecek sınıflar (class) tespit edilerek özellikleri tanımlandı.
- Öğrenci İşleri okul süreçlerini betimleyen bir ontoloji, açık kaynak kodlu Protégé editör yazılımı aracılığıyla OWL (Ontology Web Language) dili kullanılarak modellendi (Şekil 3).
- Veritabanındaki alanlar ile ontoloji sınıfları arasında R<sub>2</sub>O (Relational to Ontology) dili aracılığıyla eşleme (mapping) işlemi yapıldı.
- Veritabanından sadece 1 yüksekokuldaki 1186 öğrenci, 2508 ders, 45291 not ve 37 personele ait veriler RDF üçlüsüne


dönüştürülerek RDF yığın dosyası elde edildi.

- RDF yığın dosyası, semantik veri deposuna (Virtuoso) aktarıldı.
- Aynı sonuçları döndürecek ilişkisel veritabanı yönetim sistemindeki (MySQL) SQL sorguları ile semantik veri deposu (Virtuoso) üzerindeki SPARQL sorguları, PHP web programlama dili kullanılarak yazılan betikler aracılığıyla çalıştırılıp veriler karşılıklı olarak doğrulandı ve sorguların sonuç döndürme süreleri karşılaştırıldı.

Söz konusu işlemlerin tümü Linux işletim sistemi üzerinde açık kaynak kod teknolojileri ve Virtuoso semantik depo yazılımının tüm özelliklerinin aktif olduğu 15 günlük deneme sürümü kullanılarak gerçekleştirilmiştir.



Şekil 2. Öğrenci İşleri Veritabanı Şeması



Şekil 3. Öğrenci İşleri Ontoloji Modeli

Şekil 3'deki ontolojinin OWL kodlarından bir kesit aşağıdaki gibidir:

```
<owl:ObjectProperty rdf:ID="LecturedBy">
<rdfs:domain rdf:resource="#ders"/>
<rdfs:range rdf:resource="#personel"/>
<owl:inverseOf>
<owl:ObjectProperty rdf:ID="Teaches"/>
</owl:inverseOf>
</owl:ObjectProperty>
<owl:ObjectProperty rdf:ID="EnrolledBy">
<rdfs:range rdf:resource="#ogrenci"/>
<owl:inverseOf>
...

```

### 2.2.1. Semantik Eşleme (Mapping) İşlemi

Semantik eşleme, bilginin görsel bir sunumu olup kavram veya kelimeler arasındaki ilişkilerin açığa çıkarılmasıdır [9]. Eşleme işlemi, heterojen veritabanları arasında karşılıklı olarak veya farklı ontolojileri eşlemek amacıyla yapılabildiği gibi; veritabanlarındaki alanlarla ontoloji sınıfları arasında da yapılabilir. Her bir eşleme türü için geliştirilmiş özel yöntem ve araçlar mevcuttur.

Bu çalışmada, ilişkisel veritabanındaki alanlar ile ontoloji sınıfları arasında R<sub>2</sub>O (Relational to Ontology) dili aracılığıyla eşleme (mapping) yapılmıştır. R<sub>2</sub>O kodlarından bir kesit aşağıdaki gibidir:

```
<r2o>
<dbschema-desc name="semantic">
<has-table name="personel">
<keycol-desc name="personel_sicil"/>
<nonkeycol-desc name="personel_soyad"/>
<nonkeycol-desc name="personel_ad"/>
<nonkeycol-desc name="unvan_id"/>
</has-table><attributemap-def
name="http://localhost/otomasyon.owl#hasStuffID">
<selector><aftertransform><operation oper-id="constant">
<arg-restriction on-param="const-val">
<has-column>semantic.sube.personel_sicil
</has-column></arg-restriction>
</operation></aftertransform></selector>
</attributemap-def>
...

```

### 2.2.2. Veritabanı Yönetim Sistemi ile Semantik Depo Verilerinin Doğrulanması ve Performans Karşılaştırması

MySQL, altı milyondan fazla sistemde yüklü bulunan çoklu iş parçacıklı (multi-threaded), çok kullanıcı (multi-user), yüksek performanslı, sağlam (robust) ve günümüz web sunucularında en çok tercih edilen ilişkisel bir veritabanı yönetim sistemidir. Virtuoso yazılımı, Openlink firması tarafından geliştirilmiş hibrit bir veritabanı yönetim sistemidir. Geleneksel ilişkisel veritabanı ve SQL desteği bulunmakla birlikte, gelişmiş XML ve RDF veri depolama özellikleri ile birlikte Full SPARQL desteğinden

dolayı rakiplerine göre avantajlı bir semantik depo olarak kullanılabilir. MySQL ve Virtuoso, ODBC sürücü desteğine sahip olduğundan dolayı her ikisi birçok programlama dili ile birlikte rahatlıkla kullanılabilir.

Çalışmanın sonunda, ilişkisel veritabanı yönetim sistemindeki (MySQL) verilerin RDF yapısına dönüştürülmesi ile elde edilen yığın dosyası semantik depoya (Virtuoso) aktarılmış ve semantikleştirme işleminin başarı durumunun tespiti için 17 adet farklı (MySQL üzerinde SQL; Virtusoso üzerinde SPARQL) geri çağırma (SELECT) sorgusu hazırlanarak sonuçlar karşılaştırılmıştır. Ayrıca birer adet ekleme (INSERT), güncelleme (UPDATE) ve silme (DELETE) sorguları da işletilerek doğrulanmış ve tümünün performans sonuçları incelenmiştir. Güvenirliği artırmak amacıyla, her sorgu 5'er kez işletilmiş ve sonuç döndürme sürelerinin ortalaması hesaplanmıştır (Tablo 2).

Tablo 2. İlişkisel veritabanı ile semantik depo sonuç döndürme süreleri (ms)

Sorgu Türü	Ortalama Sonuç Döndürme Süresi (ms)		Oran (a/b)
	İlişkisel Veritabanı (MySQL) (a)	Semantik Depo (Virtuoso) (b)	
Geri Çağırma (17 adet)	3.64	1.48	2.45
Ekleme (1 adet)	5.11	2.9	1.76
Güncelleme (1 adet)	21.7	8.6	2.52
Silme (1 adet)	22.4	3.7	6.05

Tablo 3. Eşdeğer SQL ve SPARQL sorguları

SQL	SPARQL
<pre>SELECT personel_ad AS ad, personel_soyad AS soyad FROM `personel` WHERE `personel_sicil` = '99005'</pre>	<pre>PREFIX myont: &lt;http://localhost/otomasyon.owl#&gt; SELECT ?ad ?soyad FROM &lt;http://127.0.0.1:8890/DAV /home/dba/otomasyon.rdf&gt; WHERE { ?personel myont:hasID "99005" . ?personel myont:givenName ?ad . ?personel myont:familyName ?soyad . }</pre>

'99005' sicil numarasına sahip personelin ad ve soyad bilgisini döndüren eşdeğer SQL ve SPARQL (geri çağırma) sorgu örneği Tablo 3'de sunulmuştur.

### 3. Sonuç

İlişkisel veritabanı yönetim sistemi ile semantik depo yazılımı üzerinde işletilen 17'şer adet SQL ve SPARQL geri çağırma sorgusunun birebir aynı sonuçları döndürdüğü görülmüş ve geliştirilen ontolojiye göre semantikleştirme işleminin başarılı olduğu anlaşılmıştır. Ek olarak 1'er adet ekleme, güncelleme ve silme sorgusu da işletilerek toplam 20 adet sorgunun ortalama sonuç döndürme sürelerinin karşılaştırılması sonucunda, semantik depo yazılımının ilişkisel veritabanına göre daha yüksek performans sunduğu görülmüştür. İlişkisel veritabanındaki (mezunlar dahil toplam 84760 öğrenciye ait) tüm verilerin yeniden semantikleştirilmesi ve daha yüksek sayıdaki sorgularla karşılıklı doğrulanmasından elde edilecek yığın üzerinde anlamsal çıkarsamalar yapmak, bu çalışmanın devamı niteliğindeki bir araştırma konusu olarak düşünülmektedir.

### 4. Teşekkür

Mustafa Kemal Üniversitesi, Bilimsel Araştırma Projeleri Koordinasyon Birimine (proje no:9800) sağladığı maddi destekten dolayı teşekkür ederiz.

### 5. Kaynaklar

- [1] Berners-Lee, T., Hendler, J & Lassila, O. The Semantic Web, Scientific American, 284(5), 2001, p. 34-43.
- [2] Pollock J.T. "Semantic Web for Dummies", Wiley Publishing, NJ, USA, 2009, p. 10-11.
- [3] Pandey, G. "The Semantic Web: An Introduction and Issues", International Journal of Engineering Research and Applications, 2012, p.780-786.
- [4] Erling, O. & Mikhailov, I. "RDF Support in the Virtuoso DBMS", In Proceedings of 1st Conference on Social Semantic Web, 2007, Leipzig, Germany.
- [5] Auer S. & Dietzold S., et al. "Triplify: Light-Weight Linked Data Publication From Relational Databases", 18th International Conference on World Wide Web, Madrid, Spain, 2009, p. 621-630.
- [6] Bumans, G. Mapping between Relational Databases and OWL Ontologies: an Example, Computer Science and Information Technologies, 2010, p.99-117.
- [7] Ullrich, C. "Description of an Instructional Ontology and its Application in Web Services for Education". Applications of Semantic Web Technologies for E-learning, (SW-EL'04), 2004, p. 17-23.
- [8] [http://en.wikipedia.org/wiki/Semantic\\_Web](http://en.wikipedia.org/wiki/Semantic_Web), Erişim: Şubat 2014.
- [9] Johnson, D. D.& Pearson, P. D. "Teaching reading vocabulary (2nd ed.)", New York: Holt, Rinehart and Winston, 1984.

## **Dinamik Optimizasyon Problemleri için Uyarlamalı Ate Böce i Algoritması**

Fehmi Burçin ÖZSOYDAN<sup>1</sup>, Adil BAYKASO LU<sup>2</sup>

<sup>1,2</sup>Endüstri Mühendisli i Bölümü, Mühendislik Fakültesi, Dokuz Eylül Üniversitesi, ZM R

Literatürde yer alan optimizasyon problemlerinin çok büyük bir kısmında sistemi etkileyen parametre, kısıt ya da de i kelerin problemin çözümü süresince sabit kaldı ı varsayılmaktadır. Oysa gerçek hayattaki uygulamalarda durum farklıdır. Gerçek hayat ko ullarında problemin çözümünde kullanılacak parametre, de i ken ya da kısıtlar elimizde olmayan zamana ya da olaya ba lı sebeplerle de i kenlik gösterebilmekte, problem henüz çözüme ula tırlanamı ken yeni bir problem ortaya çıkmaktadır. Bu problemler literatürde dinamik optimizasyon problemleri olarak isimlendirilmektedir. Burada amaç en iyi çözümü bulmak yerine, bulunan iyi ya da en iyi çözümlerin de i en ko ullar altında takip edilebilmesidir. Bu çalı mada bu amaçla tasarlanmı bir algoritma ve çe itli test problemlerinde uygulanı ı sunulmaktadır.

### **Üç Kademeli Bir Tedarik Zincirinde Entegre Parti Büyüklü ünün Belirlenmesi**

Nurhan DUDAKLI<sup>1</sup>, M. Mine ENYÜZ<sup>1</sup>, A. Serdar TA AN<sup>1</sup>, Adil BAYKASO LU<sup>1</sup>, Burcu FELEKO LU<sup>1</sup>

<sup>1</sup> Endüstri Mühendisli i Bölümü, Mühendislik Fakültesi Dokuz Eylül Üniversitesi, Buca, ZM R

Günümüzde artan rekabet ko ullarında firmaların maliyetlerini dü ürmesi onlara büyük avantajlar sa layacaktır. Envanter maiyetleri tedarik zincirinin en önemli maliyet kalemlerinden biriyken tüm tedarik zincirini dikkate alarak yapılacak bir envanter yönetimi daha da önemli hale gelecektir. Bu durumda söz konusu bütünle ik envanter modelleri çok de i kenli karar verme problemlerine dönü ecektir. Klasik envanter problemlerinin çözümünde daha çok diferansiyel çözüm teknikleri kullanılmaktayken bahsedilen envanter modellerinin çözümü için akıllı sistemlere ihtiyaç duyulmaktadır. Bu çalı mada üç kademeli bütünle ik bir tedarik zincirinde, optimum üretim ve da ıtım miktarını bulmak için bir model önerilmi ve problemin çözümü için yeni bir algoritma olan borsa piyasası algoritması kullanılmı tır.

## Çok Katmanlı Algılayıcı Ağının Eğitim Parametrelerinin Yapay Arı Kolonisi ve Genetik Algoritma ile Optimizasyonu

Zehra Gülru ÇAM<sup>1</sup> Aslıhan KARTCI<sup>2</sup> Tülay YILDIRIM<sup>3</sup>

<sup>1,2,3</sup>Elektronik ve Haberleşme Mühendisliği Bölümü  
Elektrik-Elektronik Fakültesi  
Yıldız Teknik Üniversitesi, Beşiktaş, İSTANBUL

Email: zgcam@yildiz.edu.tr

f0413013@std.yildiz.edu.tr

tulay@yildiz.edu.tr

### Özet

*Bu çalışmada, yapay arı kolonisi (YAK) ve genetik algoritma (GA) kullanılarak çok katmanlı algılayıcı ağının en iyi çalıştığı momentum katsayısı, öğrenme oranı ve gizli nöron sayısı belirlenmeye çalışılmıştır. Kullanılan ağ ve optimizasyon algoritmaları MATLAB kullanılarak yazılmış ve sonuçlar elde edilmiştir. Sonuçlar elde edilirken IRIS, new\_thyroid ve mammographic\_mass veri kümeleri kullanılmıştır. Bu sonuç, bu parametrelerin sinirsel öğrenme süreci üzerinde belirleyici etkisinin yüksek ölçüde olduğunu gösteren literatürdeki diğer yaklaşımlar ile uyumludur. İki algoritma da yüksek başarımla elde edilen değerleri bulmada başarılı olurken popülasyon sayılarının başarımlar üzerindeki etkisi de gözlenmiştir.*

### 1. Giriş

Yapay Sinir Ağlarında (YSA) sinirsel öğrenimin optimize edilmesi problemi literatürde oldukça yaygın olarak incelenmiştir. Özellikle yaygın bir kullanım alanı bulan Çok Katmanlı İleri Beslemeli YSA'larının yapay arı kolonisi ile optimizasyonu noktasında oldukça geniş bir literatür oluşturulmuştur. Bu tip sinir ağlarında diğer parametreler sabit tutulurken başlangıç ağırlıklarının belirlenmesi konusunda çok sayıda çalışma yapılmıştır [1,2,3]. Garro, Sossa ve Vazquez 2011 yılında belirli bir topolojide bağlantı sayısının azaltılması için aynı algoritmayı kullanmışlardır [4]. 2012 yılında Nourani, Rahmani ve Navin'in yaptığı çalışmada sinaptik ağırlıklar ve kutuplama sabitlerinin optimizasyonu yapılmıştır [5]. Bu çalışmada ise öğrenme parametrelerinin optimize edilmesi amaçlanmıştır. Bu çalışmada en fazla test başarımları için, YSA topolojisinin saklı katman nöronları, öğrenme oranı ve momentum sabitinin optimizasyonu konusu araştırılmıştır.


### 2. Çok Katmanlı Algılayıcı Ve Geriye Yayılım Algoritması

Çok katmanlı algılayıcı (ÇKA) ileri beslemeli eğitici bir YSA yapısıdır. Bir giriş, bir çıkış katmanı ve uygulamaya ve tasarımcıya bağlı olarak seçilen sayıda gizli katmandan oluşur. Temel bir ÇKA temsili Şekil 1'de verilmiştir.

Her bir nöronun yaptığı iş temel olarak ağırlıklandırılmış girişleri toplayıp bir net giriş elde etmek, sonrasında da bu net giriş bir aktivasyon fonksiyonundan geçirip çıkışı elde etmektir. n sayıda girişli olan nöron i'ye ait giriş çıkış bağıntısı (1)'de verilmiştir. Denklemde,  $x_j$  j'inci giriş,  $y_i$  i'inci çıkışı,  $w_{ij}$  bu girişe ve bu çıkışa ait ağırlığı temsil etmektedir.

$$y_i = f\left(\sum_{j=1}^n w_{ij}x_j\right) \quad (1)$$

Eğitme sırasında genelde geriye yayılma algoritması kullanılır. Geriye yayılma algoritması ağın ürettiği çıkış ile hedeflenen çıkış arasındaki farkı en azlamaya çalışarak ağırlıkları güncellemeye çalışır. Algoritma ismini önce çıkışa yakın olan ağırlıkları güncellemesinden alır. Geriye yayılım algoritmasında temel ağırlık güncelleme ifadesi (2)'de verilmiştir [10].



Şekil 1. Temel bir çok katmanlı algılayıcı temsili.



$$\Delta w_{ij}(t) = -\alpha \frac{\partial E}{\partial w_{ij}} + \beta \Delta w_{ij}(t-1) \quad (2.a)$$


$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (2.b)$$

Burada E ağıın ürettiği çıkış ile hedeflenen çıkış arasındaki fark,  $w_{ij}(t)$  t anında nöron ile giriş arasındaki ağırlık,  $\Delta w_{ij}(t+1)$  bir önceki andaki ağırlık ile güncel ağırlık arasındaki fark,  $\alpha$  öğrenme oranı,  $\beta$  ise momentum sabitidir. Öğrenme oranı ve momentum sabiti [0, 1] tasarımcı tarafından belirlenen sabitlerdir.

### 3. Genetik Algoritma

Evrım tabanlı yöntemler olarak, bireylerden oluşan bir popülasyonun belli bir dönüşümden geçirilmesi ve en iyi olan bireylerin varlıklarını devam ettirmesine dayanan başlıca evrimsel algoritma teknikleri, genetik algoritmalar, genetik programlama, evrım stratejileri, sınıflandırma sistemleri ve evrimsel programlama olarak sıralanabilir.

Genetik algoritmaların problemin çözümündeki başarısına karar vermedeki en önemli faktör, problemin çözümünü temsil eden bireylerin gösterimidir. Nüfus içindeki her bireyin problem için çözüm olup olmayacağına karar veren bir uygunluk fonksiyonu vardır. Uygunluk fonksiyonundan dönen değere göre yüksek değere sahip olan bireylere, nüfustaki diğer bireyler ile çoğalmaları için fırsat verilir. Bu bireyler çaprazlama işlemi sonunda çocuk adı verilen yeni bireyler üretirler. Çocuk kendisini meydana getiren ebeveynlerin (anne, baba) özelliklerini taşır. Yeni bireyler üretilirken düşük uygunluk değerine sahip bireyler daha az seçileceğinden bu bireyler bir süre sonra nüfus dışında bırakılırlar. Yeni nüfus, bir önceki nüfusta yer alan uygunluğu yüksek bireylerin bir araya gelip çoğalmalarıyla oluşur. Aynı zamanda bu nüfus önceki nüfusun uygunluğu yüksek bireylerinin sahip olduğu özelliklerin büyük bir kısmını içerir. Böylelikle, pek çok nesil aracılığıyla iyi özellikler nüfus içerisinde yayılırlar ve genetik işlemler aracılığıyla da diğer iyi



Şekil 2. Genetik Algoritmanın Genel Akış Şeması.

özelliklerle birleşirler. Uygunluk değeri yüksek olan ne kadar çok birey bir araya gelip, yeni bireyler oluşturursa arama uzayı içerisinde o kadar iyi bir çalışma alanı elde edilir [6]. Genetik Algoritmanın genel akış şeması Şekil 2.'de verilmiştir.

### 4. Yapay Arı Kolonisi

Yapay Arı Kolonisi algoritması arıların bal arama davranışlarının modellenmesi ile geliştirilmiştir. İlk olarak Karaboğa tarafından 2005 yılında tasarlanmıştır[7]. Yiyecek kaynakları optimize edilmeye çalışılan problemin olası çözümlerine karşılık gelmektedir. Bir kaynağa ait nektar miktarı, o kaynakla ifade edilen çözümün kalite değerini ifade etmektedir.

Bir kolonide 3 grup arı bulunmaktadır: işçi arılar, gözcü arılar ve kaşif arılar. Algoritmada her bir işçi arı bir nektar kaynağına atanır ve o kaynaktaki nektar miktarını hesaplar. Algoritmanın ilk adımında bu kaynaklar seçilen probleme göre rastgele olarak belirlenirken kullanılan denklem (3)'de verilmiştir.

$$x_i = l_i + \delta(u_i - l_i) \quad (3)$$

Bu denklemdeki  $\delta$ , [0,1] bir rastgele sayı,  $x_i$  rastgele belirlenen  $i$ 'inci kaynaktır. Alt limit  $l_i$ , üst limit ise  $u_i$ 'dir.

İşçi arılar edindikleri bilgileri kolonideki diğer arılarla paylaşırlar ve bu bilgilere göre gözcü arılar nektar miktarı fazla olan kaynağın komşuluğunda yeni kaynaklar ararlar, buldukları kaynaklardaki nektar miktarını hesaplarlar. Yeni kaynaklar aranırken kullanılan denklem (4)'te verilmiştir.

$$x_y = x_i + \Theta(x_i - x_k) \quad (4)$$

Bu denklemde  $\Theta$ , [-1,1] bir rastgele sayıdır.  $k$  ile  $i$  de birbirine eşit olmayan sayılardır [9].

Kaynağın uyumluluk fonksiyonu belirlendikten sonra bir kaynağın gözcü arı tarafından seçilme ihtimali, o kaynağın nektar miktarı ile doğru orantılıdır. Yani  $x_i$  kaynağının seçilme olasılığı (5)'teki gibidir. Burada  $P_i$   $x_i$  kaynağının seçilme olasılığı,  $s$  kolonideki işçi arı sayısı, yani yiyecek kaynağı sayısı,  $F(x_i)$  ise  $x_i$  kaynağına ait nektar miktarı yani uyumluluk değeridir.

$$P_i = \frac{F(x_i)}{\sum_{k=1}^s F(x_k)} \quad (5)$$



$x_i$  konumundaki nektar miktarı limit parametresi sayısınca gelişmemiş ise  $x_i$  kaynağı terk edilir ve o kaynağın arısı kaşif arı haline gelerek rastgele araştırma yapar, yeni bulduğu kaynak  $x_i$ 'ye atanır.  $x_i(c+1)$ e ait nektar miktarı  $F(x_i(c+1))$ ,  $x_i(c)$  konumundaki kaynağa ait nektar miktarından daha fazla ise arı kovana giderek bu bilgisini diğerleriyle paylaşır ve yeni pozisyon olarak  $x_i(c+1)$  akılda tutulur. Aksi durumda  $x_i(c)$  yi hafızasında saklamaya devam eder. Hem yerel hem de evrensel arama stratejilerini kullanan bu algoritmanın olasılıksal doğası sayesinde amaç fonksiyona ulaşmadaki başarısı oldukça yüksektir [8].

## 5. Ağın Optimizasyonu

Yapay sinir ağlarının dezavantajlarından biri öğrenme katsayısı, momentum sabiti ve gizli nöron sayısının deneme yanılma ile belirlenmesidir. Bu çalışmada optimize edilecek değerler olarak bu üç değer seçilmiştir. Test başarımlarını en fazla yapacak değerlerin bulunması amaçlanmıştır.

Ağ yapısı olarak, tek gizli katmanı bulunan bir çok katmanlı algılayıcı tasarlanmıştır. Geriye yayılma algoritması ile ağın eğitilmesi amaçlanmıştır. Başlangıç ağırlıkları rastgele olarak belirlenmiştir. Aktivasyon fonksiyonu olarak IRIS ve new\_thyroid için sigmoid fonksiyonu, mammographic mass için lineer fonksiyon seçilmiştir. Kullanılan veri kümelerinin yarısı eğitim, diğer yarısı test verisi olmak üzere ikiye ayrılmıştır. Bu eğitim kümeleri ile 150 iterasyonda eğitime işlemi tamamlanmıştır. Test başarımlarını hesaplanırken, aynı öğrenme oranı, gizli nöron sayısı ve momentum değerleri için rastgele başlatılan ağırlıklar ile ağ 5 kez eğitilmiş, test başarımlarını hesaplanmış ve sonuç olarak bu 5 değerlerin ortalaması kullanılmıştır.

Tablo 1. IRIS veri kümesi sınıflamasında kullanılan ÇKA ağının YAK algoritması ile optimizasyonu sonucu elde edilen değerler.

Kolonideki Arı Sayısı	İter.	Gizli Nöron Sayısı	Öğrnm. Oranı	Mom. Sabiti	Test Başarımlar Oranı [%]
16	3	2	0.7827	0.6357	97.333
14	4	2	0.8585	0.6333	97.333
12	4	4	0.6902	0.6191	97.333
10	5	2	1.4233	0.4952	97.333
8	26	4	0.8173	0.5844	97.333

YAK algoritması kullanılırken kolonideki arıların yarısı işçi arı, yarısı gözcü arı olarak seçilmiştir. Limit parametresi olarak 10 seçilmiştir. Uyumluluk fonksiyonu olarak 5 defa ÇKA ile eğitilip sınıflama yapılması sonucu elde edilen 5 test başarımının ortalaması alınmıştır. Genetik algoritma kullanılırken uyumluluk fonksiyonu olarak 5 defa ÇKA ile eğitilip sınıflama yapılması sonucu elde edilen 5 test başarımının ortalaması alınmıştır.

## 6. Sonuçlar

Bu şekilde IRIS, new\_thyroid ve mammographic mass veri kümesi için YAK algoritması ve Genetik Algoritma ile elde edilen sonuçlar sırasıyla Tablo 1,2,3,4,5 ve 6'da verilmiştir. Elde edilen en yüksek test başarımlarına göre, YAK algoritmasında kolonideki arı sayısı değiştirilerek farklı iterasyon değerlerinde ulaşılmıştır. Genetik Algoritmada ise farklı popülasyon sayıları için farklı nesil değerlerinde algoritma sonlandırılarak elde edilen sonuçlar belirtilmiştir.

Elde edilen sonuçlara göre iki algoritma da üç veri kümesi için de uygun değerlerin belirlenmesinde başarılı olmuşlardır. YAK algoritması için kolonideki arı sayısı arttıkça daha az sayıda iterasyonda en iyi değerlere ulaşılmıştır. Fakat arı sayısı fazla olduğu için hız açısından çok da büyük bir fark oluşmamıştır. Aynı durum GA için de geçerlidir. Yeterli popülasyon ile yeterli sayıda nesil denenmediğinde en yüksek başarımlar elde edilememiştir. Yeterli büyüklükler ile denendiğinde ise istenen başarımlar ve değerler elde edilebilmiştir. Gelecek çalışmalar olarak aynı yöntem ile gizli katman sayısı ve başlangıç ağırlıklarının da optimizasyonu yapılarak farklı veri kümeleri için çalışmanın genişletilmesi amaçlanmıştır. Aynı şekilde farklı ağların da optimizasyonu yapılarak algoritmaların ağlara göre başarımlarını incelenebilir.

Tablo 2. New\_thyroid veri kümesi sınıflamasında kullanılan ÇKA ağının YAK algoritması ile optimizasyonu sonucu elde edilen değerler.

Kolonideki Arı Sayısı	İter.	Gizli Nöron Sayısı	Öğrnm. Oranı	Mom. Sabiti	Test Başarımlar Oranı [%]
16	13	13	0.1808	0.9317	95.5140
14	32	4	0.3435	0.9194	95.5140
12	10	10	0.0546	0.9738	96.2617
10	23	5	0.4535	0.8768	94.5794
8	4	5	0.3438	0.8591	94.3925

Tablo 3. Mammographic\_mass veri kümesi sınıflamasında kullanılan ÇKA ağının YAK algoritması ile optimizasyonu sonucu.

Kolonideki Arı Sayısı	İter.	Gizli Nöron Sayısı	Öğnm. Oranı	Mom. Sabiti	Test Başarım Oranı [%]
16	11	13	0.2252	0.613	83.25
14	13	1	0.2307	0.6094	82.9167
12	16	3	0.3557	0.4379	82.5
10	25	7	0.1046	0.8739	82.75
8	41	6	0.2157	0.6287	83.116

Tablo 4. IRIS veri kümesi sınıflamasında kullanılan ÇKA ağının GA ile optimizasyonu sonucu.

Pop.	Nesil	Gizli Nöron Sayısı	Öğnm. Oran	Mom. Sabiti	Test Başarım Oranı [%]
5	10	2	0.37	0.757	93.0666
5	50	2	0.413	0.766	95.2
10	20	2	0.757	0.598	97.333
10	30	2	0.757	0.603	97.333
10	50	2	0.757	0.603	97.333

Tablo 5. New\_thyroid veri kümesi sınıflamasında kullanılan ÇKA ağının GA ile optimizasyonu sonucu.

Pop.	Nesil	Gizli Nöron Sayısı	Öğnm. Oran	Mom. Sabiti	Test Başarım Oranı [%]
5	20	9	0.613	0.862	94.018
10	20	19	0.216	0.925	94.579
10	30	19	0.216	0.925	95.14
10	40	5	0.216	0.925	95.327
10	50	5	0.216	0.925	95.327

Tablo 6. Mammographic\_mass veri kümesi sınıflamasında kullanılan ÇKA ağının GA ile optimizasyonu sonucu.

Pop.	Nesil	Gizli Nöron Sayısı	Öğnm. Oran	Mom. Sabiti	Test Başarım Oranı [%]
5	10	1	0.257	0.427	81.6667
10	10	10	0.22	0.554	82.125
10	20	11	0.3555	0.4204	82.2917
10	30	3	0.337	0.476	82.4166
10	40	13	0.279	0.279	82.4166

## 7. Kaynaklar

- [1] Hassim Y. M., Ghazali R., "Solving a Classification Task using Functional Link Neural Networks with Modified Artificial Bee Colony", Ninth International Conference on Natural Computation, 2013, s. , 189-193.
- [2] Shah H., Ghazali R., "Prediction of Earthquake Magnitude by an Improved ABC-MLP", Developments in E-systems Engineering, 2011, s. 312-317.
- [3] Qiongshuai L., Wang S., " A Hybrid Model of Neural Network And Classification In Wine", 3rd International Conference on Computer Research and Development, 2011, s. 58-61.
- [4] Nourani E., Rahmani A., Navin A., "Forecasting Stock Prices using a hybrid Artificial Bee Colony based Neural Network", International Conference on Innovation Management and Technology Research, 2012, s. 486-490.
- [5] Garro B., Sossa H., Vazquez R., "Artificial Neural Network Synthesis by means of Artificial Bee Colony (ABC) Algorithm", IEEE Congress on Evolutionary Computation, 2011, s. 331-338,
- [6] Rojas, R., Neural Networks, Springer-Verlag, Kısım 17, 1996
- [7] Akyol S., Alataş B., "Güncel Sürü Zekâsı Optimizasyon Algoritmaları", Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi 1, 2012, 36-50,
- [8] Bolaji A., Khader A., Al-Betar M., Awadallah M., "Artificial Bee Colony Algorithm, Its Variants And Applications: A Survey", 2013, Journal of Theoretical and Applied Information Technology
- [9] Yan G., Li C., "An Effective Refinement Artificial Bee Colony Optimization Algorithm Based On Chaotic Search and Application for PID Control Tuning", Journal of Computational Information Systems, 2011, s. 7: 9.
- [10] Rojas, R., Neural Networks, Springer-Verlag, Kısım 7, 1996.

## Metin Sınıflandırma için Yeni Bir Eğitilmiş Anlamsal Özellik Seçimi Yöntemi

Melike TUTKAN      Murat Can GANİZ      Selim AKYOKUŞ

Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
Doğuş Üniversitesi, Kadıköy, İSTANBUL

E-mail: {mtutkan, mcganiz, sakyokus}@dogus.edu.tr

### Özet

*Metin sınıflandırmasında veri ön işleme metotlarının en önemlilerinden biri de özellik seçimidir. Özellik seçimi metin sınıflandırıcılarının doğruluğunu ölçeklenebilirliğini ve performansını iyileştirmektedir. Önerilen özellik seçimi algoritması, Helmholtz prensibi tabanlı Gestalt teorisine dayanan anlam isimli bir yöntemi temel almaktadır. Bu yöntem daha önce doküman özetleme ve özellik çıkarımı için kullanılmıştır. Bu çalışmada kelimelerin her bir sınıf için anlamının hesaplandığı ve bunların genel bir sıralama için birleştirildiği bir özellik seçimi yöntemi önerilmektedir.*

### 1. Giriş

Metin madenciliğinde makine öğrenmesi algoritmalarıyla sınıflandırma yaparken en büyük sorunlardan birisi, özellik olarak kelimeler kullanıldığında özellik boyutunun çok yüksek olmasıdır. Gerçek hayatta böyle veri kümeleri çoğunlukta ve genellikle bu özelliklerin bir kısmı gürültü içerir. Bunlar üzerinde çalışma yapmak için verideki sınıflandırma açısından etkin özelliklerin seçilmesi ve verinin temizlenmesi önemli ön adımlardan birisidir. Eğer kirli, etkinliği az ve çok sayıda özellik içeren bir veri kümesi üzerinde metin sınıflandırma yapılırsa ortaya çıkan sonuç tutarlı ve güvenilir olmayabilir. Özellik seçimi metotları, veri kümesinin sınıflandırılması için daha önemli olan özelliklerin seçimini sağlar. Bundan dolayı, yapılan metin sınıflandırma uygulamaları daha hızlı çalışırken daha etkin sonuçlar üretebilir. Özellik seçimi konusunda birçok yayın yapılmıştır [1][2] ve bu konu hala önemli araştırma alanlarından bir tanesidir [3].

Bu çalışmada eğitilmiş anlamsal özellik seçimi isimli yeni bir özellik seçimi metodu geliştirilmiştir. Daha önceki çalışmalarda anlam değeri doküman özetleme

[4] ve özellik çıkarımı [5] için kullanılmış ve daha çok cümleler ve paragraflar üzerinde çalışılmıştır.

Bu çalışmada farklı veri kümelerindeki sınıflandırma açısından etkin özellikler anlam değeri yöntemiyle belirlenmiştir. Elde edilen etkin özellikleri içeren veri kümeleri üzerinde WEKA isimli makine öğrenmesi araç kiti [6] kullanılarak özellik seçimi yöntemlerinin sınıflandırma başarımına etkisi ölçülmüştür. Sınıflandırıcı olarak Multinomial Naive Bayes (MNB) seçilmiştir. Bunun sebebi MNB'nin metin sınıflandırmada çok kullanılan etkili ve hızlı bir sınıflandırıcı olması ve özellik seçimi yöntemlerine yüksek duyarlılık göstermesidir.

Bu bildiri aşağıda anlatıldığı şekilde düzenlenmiştir: ikinci bölümde anlam değerinin çalışmamızdaki tanımı yapılmış; üçüncü bölümün ilk kısmında anlam değerinin eğitilmiş anlamsal özellik seçimi metoduna nasıl dönüştürdüğümüz açıklanmış, üçüncü bölümün ikinci kısmında ise deneylerde kullandığımız diğer özellik seçimi metotları anlatılmış; dördüncü bölümünde kullanılan veri kümeleri tanıtılmış; beşinci bölümün ilk kısmında sınıf tabanlı olarak hesaplanan anlam değeri yüksek olan her sınıfa ait ilk 10 kelime sunulmuş, beşinci bölümün ikinci kısmında ise önerilen eğitilmiş anlamsal özellik seçimi metodu ile başka özellik seçimi metotları MNB sınıflandırma algoritmasının doğruluk değerlerine etkisi ölçülmüş, son bölümde ise sonuçlar üzerinde durulmuştur.

### 2. Anlam Değeri

Anlam değeri Helmholtz prensibi tabanlı Gestalt teorisine dayanmaktadır. Bu çalışmada anlam değeri literatürde ilk defa bir eğitilmiş özellik seçimi yöntemi olarak kullanılmıştır. Anlam değeri aşağıdaki formüllerle hesaplanmaktadır.

$$Anlam(k, P, D) = -\frac{1}{m} \log YAS(k, P, D) \quad (1)$$

$$YAS(k, P, D) = \binom{K}{m} \frac{1}{N^{m-1}} \quad (2)$$

Anlam değeri formülü daha önceki çalışmalarda doküman özetleme [4] ve özellik çıkarımı [5] yöntemlerinde her dokümanın ( $D$ ), içindeki paragraf ve cümle gibi parçalarının ( $P$ ), içerdiği kelimelerin ( $k$ ) anlam değerini hesaplamak için kullanılmıştır. Anlam değerinin yüksek olması kelimenin daha önemli olduğunu göstermektedir. Bu çalışmada aynı formülü eğitilmiş özellik seçimi için kullandık. Çalışmamızda tüm veri kümesini bir doküman ( $D$ ), veri kümesi içerisinde yer alan farklı sınıfları veri kümesinin parçaları ( $P$ ), veri kümesindeki özellikleri ise kelimeler ( $k$ ), olarak kabul ettik. Bu varsayıma bağlı olarak formülde yer alan her terimin açıklaması aşağıda verilmiştir:

$k$ : özellik (kök kelime, terim)

$P$ : bir sınıfa ait dokümanlar

$D$ : veri kümesindeki tüm dokümanlar

$m$ : bir sınıf içerisinde bulunan dokümanlarda  $k$  özelliğinin geçme sayısı

$K$ : tüm veri kümesinde  $k$  özelliğinin geçme sayısı

$N$ : tüm dokümanların uzunluğunun (toplam kelime sayısı) bir sınıfa ait dokümanların uzunluğuna (toplam kelime sayısı) bölümüdür.

$$N = \frac{|D|}{|P|} \quad (3)$$

Anlam değerinin hesaplanmasında kullanılan YAS (Yanlış Alarm Sayısı) değeri, anlam değeri ile ters orantılıdır. Bunun anlamı YAS değeri ne kadar küçükse o özelliğin o sınıf için anlam değeri o kadar büyüktür. Anlam değerinin büyük olması ise özelliklerin daha etkin ve önemli bir özellik olduğunu ifade etmektedir.

### 3. Özellik Seçimi Metotları

#### 3.1. En Büyük Anlamsal Özellik Seçimi (EAÖS)

İkinci bölümde açıklanan anlam formülü ile her bir özelliğin her bir sınıftaki dokümanlar için anlam değeri hesaplanmaktadır. Her bir özellik için sınıf sayısı ( $|s|$ ) kadar anlam değeri hesaplanmaktadır. En

iyi özelliği seçmek için aşağıdaki yaklaşım kullanılmıştır.

Her bir özellik için ayrı ayrı, sınıf tabanlı olarak hesaplanan anlam değerlerine bakılarak, en yüksek anlam değeri o özelliğin anlam değeri olarak kabul edilmiş ve bu metoda "EAÖS" (Eğitilmiş En Büyük Anlamsal Özellik Seçimi) ismi verilmiştir.

Bu yaklaşımla listenin üst kısmında önemli ve etkin özellikler, alt kısmında ise daha az etkin ve önemsiz özellikler içerecek şekilde sıralanmıştır. Belirlenen özellik azaltma oranına göre listenin başından sırasıyla en iyi özellikler seçilerek özellik seçimi için kullanılabilir.

#### 3.2. EOR, MOR, WOR, CDM

Bu çalışmada anlam formülüne dayanan yeni önerilmiş olan EAÖS (Eğitilmiş En Büyük Anlamsal Özellik Seçimi) yöntemi; EOR, MOR, WOR, CDM olarak kısaltılan ve aşağıda açıklanan özellik seçimi yöntemleri karşılaştırılmıştır. Bu yöntemler, klasik göreceli olasılıklar oranı (Odds Ratio) formülünün üzerinde çalışarak ve bir takım değişiklikler yapılarak ortaya atılan özellik seçimi metotlarıdır ve (4),(5),(6) ve (7)'daki formüllerle hesaplanmaktadır [2].

EOR (Extended Odds Ratio: Genişletilmiş Göreceli Olasılıklar Oranı):

$$EOR(w) = \sum_j \frac{\log P(w|c_j)(1 - P(w|\bar{c}_j))}{\log P(w|\bar{c}_j)(1 - P(w|c_j))} \quad (4)$$

WOR (Weighted Odds Ratio: Ağırlıklandırılmış Göreceli Olasılıklar Oranı):

$$WOR(w) = \sum_j P(c_j) \frac{\log P(w|c_j)(1 - P(w|\bar{c}_j))}{\log P(w|\bar{c}_j)(1 - P(w|c_j))} \quad (5)$$

CDM (Class Discriminating Measure: Sınıf Ayırıcı Ölçü):

$$CDM(w) = \sum_j \left| \frac{\log P(w|c_j)}{\log P(w|\bar{c}_j)} \right| \quad (6)$$

MOR (Multi-Class Odd Ratio: Çok Sınıflı Göreceli Olasılıklar Oranı):

$$MOR(w) = \sum_j \left| \frac{\log P(w|c_j)(1 - P(w|\bar{c}_j))}{\log P(w|\bar{c}_j)(1 - P(w|c_j))} \right| \quad (7)$$

Formüllerdeki  $P(w|c_j)$  ifadesi  $w$  kelimesinin  $c_j$  sınıfında olma olasılığını,  $P(w|\bar{c}_j)$  ifadesi ise  $w$  kelimesinin  $c_j$  sınıfı hariç diğer tüm sınıflarda olma olasılığını göstermektedir.

#### 4. Veri Kümeleri

Bu çalışmada iki farklı Türkçe veri kümesi kullanıldı. Bu kümelerdeki sınıf, doküman ve özellik sayıları Tablo 1’de sunulmuştur. Veri kümelerinde deneme amaçlı olarak farklı fakat benzer performansa sahip kök indirgeme yöntemleri kullanılmıştır.

1150haber veri kümesi, 2004 yılında hazırlanan 5 farklı haber sınıfına ait 230’ar toplamda 1150 haber içermektedir [8]. Haber metninin sınıfları: Ekonomi, Magazin, Sağlık, Siyasi ve Spor’dur. FPS5 [9] adlı kök indirgeme yöntemi kullanılarak özellikler en fazla 5 karakter olacak şekilde köklerine ayrılmıştır. Milliyet4c1k veri kümesi, 4 farklı haber sınıfına ait 2002-2011 yılları arasında toplanmış 1000’er toplamda 4000 adet haber içermektedir. Haber metninin sınıfları: Dünya, Ekonomi, Siyaset ve Spor’dur [10]. Zemberek kullanılarak özellikler köklerine indirgenmiştir [11]

Tablo 1. Veri kümelerinin boyutları

Veri kümesi	Sınıf	Doküman	Özellik
1150haber	5	1.150	6.656
Milliyet4c1k	4	4.000	21.469

#### 5. Bulgular

##### 5. 1. Anlam Değeri Yüksek Özellikler

Sınıf tabanlı olarak hesaplanan anlam hesaplamaları sonucunda 1150haber veri kümesindeki her sınıf için en önemli ilk 10 özellik Tablo 2’de, Milliyet4c1k veri kümesindeki her sınıf için en önemli ilk 10 özellik Tablo 3’te sunulmuştur.

Tablo 2. 1150haber veri kümesi için en yüksek değere sahip ilk 10 özellik (kök kelime)

Ekonomi	Magazin	Sağlık	Siyasi	Spor
cari	pekin	tümör	anaya	maçta
borsa	hande	ultra	annan	lucis
açığı	pekka	ışınl	kerkü	sahad
döviz	sosye	cildi	dgm	orteg
varil	ataiz	lazer	aihm	stadı
unakı	madon	kanam	mhp	dk
tahvi	laila	enfek	mgk	tribü
mevdu	ajda	menop	laikl	defan
ötv	dizid	cilt	bayar	golle
venez	çapki	kasla	şaron	depla

Bu veri kümelerindeki haberler incelendiğinde veri kümesinin toplandığı tarihlerdeki önemli kavram ve isimlerin listenin başında yer aldığı gözükmektedir.

Tablo 3. Milliyet4c1k veri kümesi için en yüksek değere sahip ilk 10 özellik (kök kelime)

Dünya	Ekonomi	Siyaset	Spor
osetya	gdo	balbay	hiddink
abhazy	gsyh	karabekir	forvet
saakaşvil	kobi	tutukluluk	ankaragüç
sarko	zeytinyak	kanadoğlu	bobo
pelos	goldma	selek	mhk
ateşke	fed	oramiral	gs
muharip	likidi	yarsav	tff
ayetullah	sachs	johannesburg	stoper
domino	perake	tatar	faul
annapolis	karlılık	fige	lacivertli

##### 5.2. Özellik Seçimi Yöntemlerinin Karşılaştırılması

Eğitilmiş anlamsal en büyük özellik seçimi “EAÖS” metodunun sınıflandırma performansına etkisini ölçebilmek için daha önceki çalışmalarda ortaya atılan ve iyi performans gösterdiği iddia edilen EOR, MOR, WOR ve CDM [2] özellik seçimi metodlarıyla karşılaştırılması bu bölümde yapılmıştır.

Özellik seçimi metodlarıyla özellik sayısını azalttıktan sonra MNB sınıflandırıcısının doğruluk başarımı 10 kat çapraz doğrulama (10-fold Cross Validation) yöntemi ile ölçülmüştür.

Tablo 4, 1150haber veri kümesinde kullanılan özellik seçimi yöntemlerinin MNB’in sınıflandırma performansına etkisini göstermektedir. Özellik seçimi yöntemleri kullanılarak en önemli 500, 1000, 2000, 3000, 4000, 5000, 6000 özellik seçilmiş bu sayı (Ö) “Milliyet4c1k” için 1000’er artarak 10.000’e kadar devam etmektedir. Tablolardaki değerler MNB sınıflandırıcısının doğruluk değerlerini içermektedir. Tablo 5 aynı şekilde Milliyet4c1k veri kümesi için yapılmış olan deney sonuçlarını göstermektedir.

Tablo 4. 1150 haber veri kümesi farklı özellik seçimi metodlarıyla MNB sınıflandırma doğruluğu

Ö	EAÖS	EOR	CDM	MOR	WOR
500	75,04	62,17	92,61	<b>92,70</b>	62,35
1000	86,26	71,65	93,74	<b>93,83</b>	71,57
2000	92,35	79,57	<b>93,83</b>	<b>93,83</b>	79,57
3000	<b>94,17</b>	83,39	93,74	93,83	83,39
4000	<b>94,96</b>	87,13	93,83	93,83	87,13
5000	<b>94,61</b>	89,57	93,91	93,91	89,57
6000	<b>94,35</b>	91,91	94,09	94,09	91,91

Tablo 5. Milliyet4c1k veri kümesi farklı özellik seçimi metotlarıyla MNB sınıflandırma doğruluğu

Ö	EAÖS	EOR	CDM	MOR	WOR
500	60,78	67,00	81,88	<b>81,93</b>	67,00
1000	67,40	66,33	<b>85,08</b>	<b>85,08</b>	66,33
2000	76,70	77,18	<b>86,35</b>	<b>86,35</b>	77,18
3000	81,78	80,15	<b>87,00</b>	<b>87,00</b>	80,15
4000	84,10	81,85	<b>87,13</b>	87,10	81,85
5000	<b>87,60</b>	81,40	87,33	87,35	81,40
6000	<b>88,18</b>	82,45	87,43	87,43	82,45
7000	<b>89,38</b>	83,25	87,90	87,90	83,25
8000	<b>88,78</b>	83,75	87,88	87,88	83,75
9000	<b>89,10</b>	83,78	88,00	88,03	83,78
10000	<b>88,78</b>	84,53	88,23	88,25	84,53

Tablo 4'ün başarı değerleri analiz edildiğinde EAÖS, EOR ve WOR'dan genel olarak daha iyi sonuçlar verdiği ayrıca seçilen özellik sayısı arttıkça EAÖS başarımının CDM ve MOR'un değerlerini geçtiği gözlemlenmektedir. Tablo5'in başarı değerleri analiz edildiğinde EAÖS yönteminin 4000'e kadar olan özellikler sayılarında diğer özellik seçimi yöntemleri kadar iyi çalışmadığı fakat seçilen özellik sayısı arttıkça ilk başta EOR ve WOR yöntemlerini, daha sonra her iki veri kümesinde de iyi sonuçlar veren CDM ve MOR'un başarımını geçtiği görülmektedir. Burada en önemli gözlemlerden birisi her iki veri kümesinde de en yüksek doğruluk değerlerinin EAÖS yöntemi ile elde edildiğidir.

## 6. Sonuç

Bu çalışmada anlam değeri formülü farklı bir alan olan özellik seçimi alanında kullanılarak yeni bir eğitilmiş özellik seçimi yöntemi olarak sunulmuştur. Sonuçlar incelendiğinde yeni sunulan EAÖS metodunun iyi başarımlar veren diğer metotlara kıyasla, seçilen özellik sayısı arttıkça, başarımının daha fazla olduğu gözlemlenmektedir. Ayrıca her iki veri kümesinde de en yüksek doğruluk değerleri EAÖS yöntemi ile elde edilmiştir.

Gelecek çalışmalarda yeni yöntemi farklı veri kümelerinde, farklı sınıflandırıcılarla birlikte denemeyi ve özellik seçimi yöntemleri arasında oldukça yaygın kullanılan Bilgi Kazancı (IG-Information Gain) ve Ki-kare (Chi-squared) yöntemleri ile de karşılaştırmayı planlamaktayız. Ayrıca en iyi özellikleri seçmek için bu bildiride kullandığımız "en büyük" işlemi yerine başka metotlar üzerinde de çalışmaktayız.

## 7. Teşekkür

Bu çalışma TÜBİTAK tarafından 111e239 no'lu proje ile kısmi olarak desteklenmiştir.

## 8. Kaynaklar

- [1] W. Shang, H. Huang, H. Zhu, Y. Lin, Y. Qu, Z. Wang, "A novel feature selection algorithm for text categorization", Expert Systems with Applications 33,1-5,2007
- [2] J. Chen, H. Huang, S. Tian, Y. Qu, "Feature selection for text classification with Naïve Bayes", Expert Systems with Applications 36, 5432-5435, 2009
- [3] S. Baccianella, A. Esuli, F. Sebastiani, "Using micro-documents for feature selection:The case of ordinal text classification", Expert Systems with Applications 40, 4687-4696, 2013
- [4] H. Balinsky, A. Balinsky, and S. Simske, "Document sentences as a small world," Proc. of IEEE SMC, 2011
- [5] A. Balinsky, H. Balinsky, and S. Simske, "On the Helmholtz principle for data mining," Proc. of 2011 Conf. on Knowledge Discovery, Chengdu, China, April 2011
- [6] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I. H. Witten The WEKA Data Mining Software: An Update; SIGKDD Explorations, Volume 11, Issue 1, 2009
- [7] A. Desolneux, L. Moisan, and J.-M. Morel, From Gestalt Theory to Image Analysis: A Probabilistic Approach, ser. Interdisciplinary Applied Mathematics, Springer, vol. 34, 2008
- [8] M.F. Amasyalı, A. Beken, "Türkçe Kelimelerin Anlamsal Benzerliklerinin ölçülmesi ve Metin sınıflandırmada Kullanılması",Sui Antalya, 2009
- [9] F. Can, S. Kocberber, E. Balçık, C. Kaynak, H.C. Ocalan, O. M. Vursavas, "Information Retrieval On Turkidh Texts", Journal of the American Society For Information Science and Technology, Vol,59, No,3, Pp. 407-421, February 2008
- [10] M. Poyraz, Z.H. Kilimci, M.C. Ganiz, (2014). Higher-Order Smoothing: A Novel Semantic Smoothing Method for Text Classification. Journal Of Computer Science and Technology , Vol.29, No.3, 2014, pp.376-391
- [11] A.A. Akın, M.D. Akın. "Zemberek, an open source NLP framework for Turkic Languages." Structure 10 (2007).

## Sınıflandırma Tabanlı Türkçe Soru Algılama

Zeynep Banu ÖZGER<sup>1</sup>Banu DİRİ<sup>2</sup><sup>1,2</sup> Bilgisayar Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, Esenler, İSTANBUL

Email: zeynep@ce.yildiz.edu.tr

banu@ce.yildiz.edu.tr

### Özet

*Twitter gibi mikro-blog servislerinin kullanımının son yıllarda katlanarak arttığı görülmektedir. Her gün tvit adı verilen, 140 karakterden oluşan, kullanıcıların günlük aktiviteleri, görüşleri ve ilgi alanlarından oluşan milyonlarca mesaj gönderilmektedir. Soru algılama Doğal Dil İşleme'nin bilgi çıkarımı alanının bir alt dalıdır. Dilin yapısal kurallarına uyan veya uymayan derlemlerden soru içeren cümleleri tespit etmeyi amaçlar. Çalışma kapsamında Türkçe tvitlerden oluşan bir veri seti için, Makine Öğrenmesi metotları kullanılarak bir soru algılama sistemi geliştirilmiştir. Sistemin başarısı yaklaşık %86 olarak alınmıştır.*

*Anahtar Kelimeler — Doğal Dil İşleme; Makine Öğrenmesi; Twitter.*

### 1. Giriş

Bilgi teknolojilerindeki ilerlemeler neticesinde kullanıcılar, artık sadece bir okuyucu değil aynı zamanda içerik sağlayıcısı konumuna da gelmiştir. Web 2.0 teknolojisi ile ortaya çıkan ve hızla yaygınlaşan sosyal ağ ve mikro-bloglarda kullanıcılar düşüncelerini, aktivitelerini, fotoğraf ve videolarını paylaşabilmektedir. En yaygın mikro-blog sitelerinden biri olan Twitter' da kullanıcılar kısa içeriklerini paylaşmaktadırlar.

Soru algılama Doğal Dil İşleme ve Bilgi Çıkarımı disiplinlerinin bir alt çalışma alanıdır. Soru algılama çalışmalarının amacı, bir metinde geçen soru cümlelerini tespit edebilmektir. Günümüzde Twitter sanal ortamda resmi olmayan bir bilgi etkileşim ortamı haline gelmiştir. Soru sormak ise bu etkileşimin önemli bir parçasıdır.

[1]'de insanların Twitter'daki soru sorma alışkanlıkları incelenmiştir. [2,3]'de ise insanların

Twitter'ı bilgi ihtiyaçlarını karşılamak için de kullandıkları ve sorulan soruların genellikle arama motorları ile bulunması zor olan öznel sorular oldukları sonucuna varılmıştır. Bu nedenle sosyal medya tabanlı soru algılama ve cevaplama sistemleri popüler olmaya başlamıştır.

[4]'de İngilizce tvitlerden, iki adımda, otomatik soru çıkarma işlemini gerçekleştirmiştir. İlk olarak soru içeren tvitler belirlenmiş ardından da bu tvitlerden gerçek bilgi veya yardım isteyenler çıkarılmıştır. Dent et al [5] dilbilimsel bir ayrıştırıcı ile Twitter'dan otomatik soru çıkarımı yapan bir araç geliştirmeyi hedeflemişlerdir. [6]'da forum sitelerinden soruları algılamak için ardışıl örüntü özellikleri, cevap adaylarını tanımlamak için grafik tabanlı bir metot geliştirilmiştir. [7]'de ise Wang et al. Prefixspan Algoritmasını kullanarak, soru ve cevaplarından oluşan formal olmayan sitelerden soru algılama yapmıştır. Forum sitelerinden soru algılamada [8] özellik olarak soru işareti ve 5N1K'nın yanı sıra foruma yazan kişinin aktif olma durumunu belirleyen özellikleri ve n-gramları kullanmıştır. Ding ve arkadaşları ise forum sitesinden soru ve cevap algılamada [9] Şartlı Rastgele Alanlar (Conditinal Random Fields) yöntemini kullanmışlardır. Bir diğer çalışmada elektronik postaları özetlemek için soru ve cevap algılamadan faydalanılmıştır [10].

Bu çalışma kapsamında ise Twitter API aracılığıyla toplanan Türkçe tvitler için sınıflandırma tabanlı otomatik bir soru algılama işlemi gerçekleştirilmiştir. Türkçe'de soru oluşturmada kullanılan ve Twitter'da kullanıcıların soru sorarken sıklıkla kullandığı kalıplar özellik olarak tanımlanmış ve makine öğrenmesi sınıflandırıcıları ile soru olan tvitler tespit edilmiştir.

Çalışmanın ikinci bölümünde soru algılamaya yönelik geliştirilen sistemden bahsedilmiştir. Üçüncü bölümde veri seti, dördüncü bölümde ise deneysel sonuçlardan

bahsedilmiştir. Son bölümde ise sonuç ve gelecek çalışmalara yer verilmiştir.

## 2. Sistemin Genel Yapısı

Geliştirilen uygulama temelde 4 adımdan oluşmaktadır.

- I. Twitter 4j kütüphanesi ile Türkçe tvtlerden oluşan veri tabanı oluşturulur.
- II. Tvtlerdeki sistem için anlamsız veriler bir ön işlem fonksiyonu ile temizlenir.
- III. Tanımlanan kurallar ile 'aday soru havuzu' oluşturulur.
- IV. Soru algılama için çıkarılan örüntüler ikili gösterimle tanımlanarak soru algılama işlemi gerçekleştirilmiştir.

### 2.1. Tvtlerin Temizlenmesi

Tvtleri, sistemin kullanmayacağı bilgilerden arındırmak için ön işleme fonksiyonu uygulanmıştır.

- I. Twitter'da 'retvit' olarak adlandırılan bir başka kullanıcının tvtinin gönderilmesi anlamına gelen bir özellik mevcuttur. Veri setinin eğitiminde aynı tvtin birden fazla bulunması istenmediğinden veri seti retvitlerden arındırılmıştır.
- II. "I'm at" ile başlayan, yer bildirme amaçlı yazılan tvtler elenmiştir.
- III. Tvtlerin içerisinde geçebilen url, kullanıcı adı, konu başlığı bilgileri de sistem için anlamlı olmadığından, bu ifadeler tvtlerin içerisinde çıkarılmıştır.
- IV. Bazı tvtler sadece url, kullanıcı adı veya konu başlığından ibaret olduğu için temizleme sırasında bu ifadeler silindiğinde, tvt, içeriği boş bir kayıt haline geldiğinden veri setinden silinmiştir.

### 2.2. Aday Soru Havuzunun Oluşturulması

Sistemin başarısının test edilebilmesi için tvtlerin etiketlenmesi gerekmektedir. Etiketleme işlemi ise el ile yapıldığından, etiketlenecek tvt sayısını azaltmak için, tanımlanan kurallar ile bir aday soru havuzu oluşturulup, soru olma ihtimali yüksek olan tvtler bu havuzda toplanmıştır. Gerçekte soru olan tvtlerin aday soru havuzunun dışında kalmasını önlemek için tanımlanan kurallar esnek tutulmuştur.

Türkçe' de soru cümleleri; soru ekleri, soru zarfları, soru zamirleri veya soru sıfatları ile oluşturulurlar ve soru cümlelerinin sonuna soru işareti (?) konulur. Türkçe' deki bu soru cümlesi için geçerli ifadeler ile kurallar tanımlanmış ve aday soru havuzu oluşturulmuştur. Kurallar dört grupta tanımlanmış olup aşağıdaki şekilde sıralanmaktadır:

- I. Soru İşareti
- II. Soru Eki; mı, mısın, mısınız, mıyım, mıyız, mıydın.
- III. Soru Kelimesi; ne, neden, niçin, niye, nasıl, kim, kaç, hangi.
- IV. Özel Kelime; acaba, naber, napıca(n/z/m/k), noluyo, napabil., demi, dimi, napıyo, noldu

Özel kelimeler grubu tvtlerde sıklıkla geçebilen ve bulunduğu tvite soru anlamı katabilen kelimelerden oluşmaktadır. 'napabil..' ifadesi napabilir, napabilecek, napabiliyor gibi bu kelimedenden türetilebilecek diğer kelimeleri de içersin diye bu şekilde tanımlanmıştır.

### 2.3. Soru Algılama

Tüm tvtlerin içerisinde soru içeren tvtlerin algılanması amaçlanmış, veri setini eğitmek için 73 özellik tanımlanmıştır. Tvtlerde yoğunlukla kullanılan günlük konuşma diline ait örüntüler de özellik olarak eklenmiştir.

#### 2.3.1. Tanımlanan Özellikler

Aday soru havuzu için tanımlanan kurallar daha kapsamlı hale getirilerek soruları bulmak için kullanılmıştır. Aday soru havuzunda karşılaşılan problemlerin bir kısmı giderilmiş ve tvtler içerisinde sıklıkla geçen örüntüler tespit edilmiştir. Bu örüntüler:

- I. Soru İşareti: Tvtin soru işareti içerip içermediği bir düzenli ifade ile kontrol edilir.
- II. Soru Eki: Soru ekleri için 17 özellik tanımlanmıştır. Kontrolü yapılan soru ekleri : - mı, -mısın, -mısınız, -mıyım, -mıyız, -mıydık, -mıydım, -mıydın, -mıydınız, -mıymış, -mıdır, -bilirmi, -bilirlermi, -limmi, -sekmi, -dıkmi, -larmı şeklinde sıralanmaktadır. Tvtlerin kuralızsız yapısı nedeniyle eklerin ayrı yazılması kuralının çoğu zaman ihlal edilmesi ekleri tespit etmeyi zorlaştırmıştır. Yapılan analizler sonucu -mi eki hariç diğer soru ekleri için ayrı yazılma şartı aranmaması uygun görülmüştür. Ancak, -mi ekinin oluşturduğu problemi çözmek için ilgili eke yönelik dört ayrı özellik tanımlanmıştır.



Özellikle çok yaygın kullanılan fiiller (al, bak, gör vs.) ve kelimeler (mümkünmü, doğrumu vs.) tvitlerden tespit edilerek dört küçük sözlükleştirilmiştir. Sözlükteki kelimeler için ayrı olma şartı aranmamıştır.

III. Soru Kelimesi: 33 özellik oluşturulmuştur. Kontrolü yapılan soru kelimeleri; niye, kaç, nerde, neler, nedir, kim, ney, nasıl, neden, olmuş, noldu, ne, napyo, niçin, naber, nedersin, ..neymiş..miş, neyin var, niye .. çünkü, ne diye sorsa, kaçınıcı, napıcan, naptı, naptı, noluyo, ne kadar, neli, neci, nesi, ne zaman, ne demek şeklinde sıralanmaktadır. İlgili kelimelerin bazıları soru kelimesi olarak geçebildiği gibi sıfat, zarf vs. olarak da bulunabilmektedir.

Örneğin: 'Nasıl geldin buraya kadar' bir soru iken 'Nasıl eğlendik ama yaa' soru değildir. Oluşan hataları azaltabilmek için, tvitlerin analiz edilerek kalıplar çıkarılmıştır. Mesela, yukarıdaki örnek için 'nasıl' kelimesinin cümle içerisinde hangi kalıplarla birlikteyken soru kelimesi olduğu ve olmadığı tespit edilmiş, bu duruma yönelik örüntüler oluşturulmuştur. Örüntüleri tanımlayabilmek için küçük sözlükler oluşturulmuştur.

IV. Özel Kelime: Bu kelimeler geçtiği cümleye soru anlamı katabilen kelimeler olabileceği gibi soru kelimelerinin günlük konuşma dilindeki halleri de olabilmektedir. Acaba, dimi, demi, sence, sizce, rica etse.., hayırdır, napabil.., nesin, değilmi, varmı, olurmu, öylemi, yokmu, napalım, tamamı, nen var, neymiş o, ..dedi..dedim, diye sordum ..dedi, diye sorsalar ..derim, eee şeklinde sıralanmaktadır. Burada 'napabil..' napabilir, napabilirim, napabiliriz gibi farklı ekler ile oluşturulmuş hallerini de içerebilirsin diye kısaltılarak tanımlanmıştır. '..dedi .. dedim' şeklindeki kalıplarda '..' olan yerde herhangi bir şey olabilir anlamındadır.

İlgili özellikler zaman zaman soru olmayan tvitlerde de bulunabilmektedir. Ancak, uygulamanın amacı soru olanların tespitine yönelik olduğu için soru bulmadaki hataların azaltılması öncelikli hedef sayılmış, özellikler ve örüntüler buna göre düzenlenmiştir.

Ayrıca, tvitlerde 140 karakter sınırlaması olduğundan zaman zaman sesli harflerin yazılmamaktadır. Bazen kelimelerin bazı harfleri vurgu amaçlı tekrarlanabilmektedir. Bu nedenle örüntülerde sesli

harflere bulunma, bulunmama veya birden fazla bulunma esnekliği sağlanmıştır.

### 2.3.2. Kısıtlar

Soru algılamaya yönelik uygulamanın geliştirilmesi safhasında karşılaşılan en büyük problem; aynı örüntünün her iki sınıfı da temsil eden örnekler içermesinden kaynaklanan çakışık sınıf problemi olmuştur. Uygulamada iki sınıf vardır; sorudur veya soru değildir. Bu durumu içeren her özellik sınıflardan birinin başarısını artırırken diğerini azaltmıştır. Aşağıda her iki sınıf içinde örnek içeren örüntüler sıralanmaktadır.

Tablo 1. Kısıtlar

Özellik	Soru	Soru Değil
Kaçınıcı	Kaçınıcı sezon bu	Sesini duymadan geçen bilmem kaçınıcı gün
Kim, kimin <sup>1</sup>	sence kim finali alır	of kimse yok ya twitterda
Ne...ne	bunlar ne peki neee	Bu dünya ne sana ne de bana kalmaz
..ne demek..	Abrekadabra ne demek acaba?	ne demek hocam :)
..mi..mi	Okula gitsem mi gitmesem mi	Sinan mı Tolga mı bilemedim
Neden olacak / Neden oldu	Bu adam başka hangi ölümlere neden olacak?	biraz daha yarım kalmama neden olacaksın
Ne olur / Ne için var	peki gezmeyenler ne olur	her söze ne olur inanma
Nerede	nerede idin janım :)	gozlerim nerede temali fotograf
Neden / Hangi, kaç <sup>2</sup>	nedeenn niçiiiiinnn :(	Mutlu olmam için neden yok
-mi <sup>3</sup>	Dönmedin mi daha	ayağı mı kırdım
msn <sup>4</sup>	Gelir msn lutfen	Hadi msn e gel

<sup>1</sup> Bu kelimeler birçok farklı ek alıp farklı hallerde (kime, kiminle, kimin gibi) soru ifade edebildiği için örüntü ilgili kelimeyi içeren bir sözcüğün geçip geçmediğini kontrol edecek şekilde tanımlanmıştır. Bu durumda ilgili kelimeler ile başlayan ve aslında soru amaçlı kullanılmayan bir takım kelimeleri içeren tvitlerde bu özellik tarafından tanınır hale gelmiştir. Bu durumdan kaynaklanan hatalar örüntülere eklenen küçük sözlükler ile azaltılmıştır.

<sup>2</sup> İlgili kelimeler soru kelimesi olabileceği gibi isimi soru sıfatı veya fiil olarak da kullanılabilmektedir.

<sup>3</sup> Yazım hatası nedeni ile ayrı yazılan -mi soru eki olarak değerlendirilmektedir.

<sup>4</sup> Özellikle soru ekleri için sesli harflerin bazen yazılmaması karışıklığa neden olabilmektedir.

### 3. Veri seti

Geliştirilen sistemin eğitilmesi için, bir Java kütüphanesi olan twitter4j ile 22.05.2013 ile 20.06.2013 tarihleri arasında 1.000.000 twit toplanmıştır. Tvitlerde herhangi bir kullanıcı adı, konu, yer, vs. kısıtlaması yoktur.

Çekilen 1.000.000 twitten Aday Soru Havuzuna giren 136.449 tanesi için etiketleme işlemi el ile yapılmıştır. Veri setinin büyüklüğünden dolayı etiketleme işlemi beş kişi tarafından yapılmış olup, her bir twit bir kişi tarafından etiketlenmiştir. Buna göre veri setinin 73.060 tanesi 'soru' sınıfında, kalan 63.389 tanesi ise 'soru değil' sınıfındadır.

### 4. Deneysel Çalışmalar

Twit metinleri ve sınıf bilgisinden oluşan veri setine Weka ile Naive Bayes (NB), Destek Vektör Makinesi (DVM), Rasgele Orman (RO) ve 1-NN algoritmaları, Weka'daki varsayılan değerler ile 5-kat çapraz geçişleme ile uygulanmıştır.

Soru algılama için toplam 73 örüntü çıkarılmıştır. Her twit 73 boyutlu bir özellik vektörü ile ifade edilmekte olup, twit içerisinde var olan her özellik için 1, var olmayan durumlar için de 0 değeri verilmiştir. Tablo 2' de çıkarılan özellikler kullanılarak yapılan sınıflandırma başarısı, Weka içerisinde yer alan 'StringToVector' filtresi kullanılarak elde edilen sonuçlar, ikili gösterim yapılarak elde edilen sonuçlar ile karşılaştırılmıştır.

Tablo 2. Karşılaştırmalı Sonuçlar (STWV =StringToWordVector filtresi, İG= ikili gösterim)

	Yöntem	Tutturma	Bulma	F-Ölçüm
NB	STWV	0,730	0,725	0,725
	İG	0,819	0,819	<b>0,819</b>
RO	STWV	0,814	0,812	0,812
	İG	0,866	0,859	<b>0,857</b>
DVM	STWV	0,816	0,813	0,807
	İG	0,866	0,859	<b>0,857</b>
1-NN	STWV	0,738	0,738	0,738
	İG	0,866	0,859	<b>0,857</b>

Tablo 2'de görüldüğü gibi denenen tüm makine öğrenmesi algoritmaları için ikili gösterim kullanılarak yapılan sınıflandırma, STWV filtresi ile yapılan sınıflandırmadan daha başarılı olmuştur.

İkili gösterimle yapılan sınıflandırma sonuçlarından Naive Bayes hariç, diğer üç sınıflandırıcının tutturma, bulma ve f-ölçüm değerleri aynı çıkmıştır. Ancak, sınıf hata matrisleri incelendiğinde 1-NN için doğru pozitif (true positive) sayısı 68,741 iken, Rasgele Orman için 68,708 ve DVM için 68,665'dir. F-ölçüm değerlerinin aynı çıkmalarının nedeni sınıf hata matrisinde birbirine çok yakın değerler almaları ve bu nedenle oranların aynı çıkmasıdır.

Çıkarılan özelliklerin sistemi ne kadar iyi modellediğini gözlemleyebilmek için; özelliklerin ikili gösterimlerini içeren haline Weka ile özellik seçimi uygulanmıştır. Weka mevcut özelliklerin 27 tanesini seçmiştir. Aynı sınıflandırma algoritmaları ile tekrar sınıflandırıldığında başarıda az da olsa düşüş olduğu için tüm özellikler kullanılmıştır.

### 5.Sonuçlar

Bu çalışmada Türkçe twitlerden oluşan bir derlemde soru içeren twitlerin tespit edilmesi amaçlanmıştır. Eğitim için bir milyon twit toplanmış, bir ön temizleme adımından geçirilerek 136.449 twit içeren eğitim veri seti oluşturulmuştur. Soruları tespit edebilmek için iki özellik çıkarım yöntemi kullanılmıştır. İlk olarak Weka içerisinde yer alan StringToWordVector filtresi ile elde edilen özellikler ile sınıflandırma yapılmış ve kullanılan yöntemler arasından en yüksek başarıyı 0,812 ile Rasgele Orman almıştır. İkinci olarak, Türkçe'deki soru sorma kuralları, twitler analiz edilerek çıkarılan soru kalıpları ile birleştirilerek elde edilen 73 tane özelliğin ikili gösterimiyle elde edilen özellikler ile sınıflandırma yapılmış Rasgele Orman, DVM ve K-NN için 0,857 ve Naive Bayes için de 0,819 başarı elde edilmiştir.

### 6. Kaynaklar

- [1] Paul, S.A., Chi, E., (2011a). "Is Twitter a Good Place for Asking Questions?". A Characterization Study. AAAI Conference on Weblogs and Social Media (ICWSM '11).
- [2] Morris, M. R., Teevan, J., and Panovich, K., (2010). "What do people ask their social networks, and why?: a survey study of status message q&a behavior." In Proceedings of the 28th international conference on Human factors in computing systems, CHI '10: 1739–1748. New York, NY, USA: ACM.
- [3] Paul, S.A., Chi, E., (2011b). "What is a Question? Crowdsourcing Tweet

- Categorization.” Position paper at the workshop on Crowdsourcing and Human Computation at the ACM Conference on Human Factors in Computing Systems (CHI '11).
- [4] Li ,B., Si, X, Lyu, Michael R., King, I., Chang, Edward Y., (2011). “Question Identification on Twitter”. CIKM'11, Glasgow, Scotland, UK.
  - [5] Dent, K., Paul, S., (2011). “Through the Twitter Glass: Detecting Questions in Micro-Text”. Analyzing Microtext: Papers from the 2011 AAAI Workshop.
  - [6] Cong, G., Wang, L., Lin, C.Y., Song, S. I., Sun, Y., (2008). “Finding Question-Answer Pairs from Online Forums”, SIGIR'08, Singapore.
  - [7] Wang, K., Chua, T.S., (2010) “Exploiting salient patterns for question detection and question retrieval in community-based question answering”. In COLING '10.
  - [8] Hong, L., Davison, B. D., (2009). “A Classification-based Approach to Question Answering in Discussion Boards”, SIGIR'09, Boston, USA.
  - [9] Ding, S., Cong, G., Lin, C.Y., Zhu, X., (2008). “Using conditional random fields to extract contexts and answers of questions from online forums.” In ACL.
  - [10] Shrestha, L., McKeown, K., (2004). “Detection of question-answer pairs in email conversations”. In Proc. of COLING.

## Nitelik Seçme Problemi için Diferansiyel Gelişim Algoritması ve Yapay Arı Kolonisi Optimizasyon Tekniğini Kullanan Melez Yöntem

Ezgi ZORARPACI<sup>1</sup> Selma Ayşe ÖZEL<sup>1</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik-Mimarlık Fakültesi  
Çukurova Üniversitesi, ADANA

Email:ezorarpaci@gmail.com

saozel@cu.edu.tr

### Özet

*Nitelik seçme işlemi ile özellik uzayı optimum şekilde daraltılarak veri kümesini en iyi şekilde temsil edebilecek niteliklerin bulunması amaçlanır. Bu çalışma sınıflandırma işlemleri üzerinde nitelik seçme problemi için Yapay Arı Kolonisi optimizasyon tekniği ve Diferansiyel Gelişim algoritmasını birleştirerek yeni bir melez yöntem önermektedir. Önerilen model UCI veri kümeleri üzerinde karar ağacı sınıflandırıcısı (J48) kullanılarak test edilmiştir. Alınan sonuçlar geliştirilen yöntemin sınıflandırma işleminin doğruluğunu düşürmeden ya da en az seviyede düşürerek nitelik sayısını azaltmakta, dolayısıyla yeni örneklerin sınıflandırılması için gereken sürenin azalmasına neden olmaktadır.*

### 1.Giriş

Nitelik boyutu küçültme olarak da bilinen nitelik seçimi, sınıflandırıcı modelin öğrenme aşaması için orijinal veri kümesindeki nitelikleri en iyi şekilde temsil edebilecek ilgili niteliklerin optimum bir alt kümesinin oluşturulması işlemidir.

Nitelik seçme teknikleri sayesinde öğrenme ve test süresinin kısalması, öğrenci modelin ezberlenmesinin önlenerek ya da azaltılarak daha gelişmiş bir genelleme yapılması ve ilgisiz özelliklerin elenmesi ile daha yorumlanabilir bir veri kümesinin elde edilmesi mümkün olmaktadır.

Nitelik seçme problemi için Tabu Arama (TA), Tavlama Benzetimi (TB), Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO), Karınca Kolonisi Optimizasyonu (KKO), Diferansiyel Gelişim

(DG) ve Yapay Arı Kolonisi (YAK) meta-sezgisellerini de içeren birçok yöntem geliştirilmiştir [1-6].

Diferansiyel Gelişim (DG) algoritması Price ve Storn [7] tarafından geliştirilen, iterasyonlar kullanarak belli bir uygunluk fonksiyonu ile çözümleri geliştiren bir meta-sezgisel yöntemdir. DG' de hızlı çalışma, büyük boyutlardaki karmaşık problemlere uygulanabilme ve az sayıda kontrol parametresine ihtiyaç duyulması gibi avantajların yanında kararsız yakınsama ve lokal optimuma takılma gibi dezavantajlar mevcuttur.

Yapay Arı Kolonisi (YAK) Karaboğa [8] tarafından önerilen bal arılarının beslenme davranışlarını taklit eden bir optimizasyon tekniğidir. YAK güçlü, uygulanması kolay ve çok iyi lokal arama özelliği olan bir meta-sezgisel olmasına rağmen algoritmanın yavaş yakınsama özelliği performansını düşürmektedir.

Bu çalışma DG' nin global arama stratejisi ile YAK'ın güçlü lokal arama özelliğini birleştirerek standart DG ve YAK' dan daha iyi bir performans elde etmeyi amaçlamaktadır.

### 2. Önceki çalışmalar

Bir nitelik seçme işleminin başarısı kullanılan arama stratejisi ile yakından ilgilidir. Literatüre bakıldığında nitelikleri puanlandırarak değerlendiren sıralamaya dayalı arama yöntemleri [9] ile DG ve YAK gibi meta-sezgiselleri de içeren global arama stratejileri yaygın olarak kullanılmaktadır [1-6].

Khushaba ve arkadaşları [6] DG tabanlı bir nitelik seçme algoritması geliştirmiştir. Bu çalışmada önceden belirlenen nitelik sayısı için DG operatörleri niteliklerin indis değerlerine uygulanarak hangi niteliklerin seçileceği belirlenmiştir. EEG sinyal sınıflandırma veri kümesi kullanılarak test edilen çalışmada %92,4 kesinlik değeri elde edilmiştir [6].

Prasartvit ve arkadaşları [3] nitelik seçimi için en yakın komşu (kNN) sınıflandırıcısını YAK içinde kullanarak yeni bir yöntem geliştirmiştir. Önerilen yöntem gen ifade analizi ve otistik davranışlar veri kümeleri üzerinde test edilmiş, %89,5 ile %100 arasında değişen kesinlik değerleri elde edilmiştir [3].

Palanisamy ve Kanmani [4] uygunluk fonksiyon değerlerini karar ağacı (J48) ile seçtikleri YAK tabanlı yeni bir nitelik seçme yöntemi geliştirmiştir. Geliştirilen yöntem UCI veri kümeleri ile test edilmiştir [4].

Schiezaro ve Pedrini [5] geliştirdikleri YAK tabanlı nitelik seçme yöntemini UCI veri kümeleri üzerinde test ederek %71,48 ile %98,46 arasında değişen kesinlik değerleri elde etmiştir [5].

Lokal arama ve global arama işlemleri arasındaki dengeyi sağlayabilmek amacıyla genellikle 2 ya da daha fazla sezgisel yöntem birleştirilerek melez yöntemler geliştirilmiştir. Önceki çalışmalar incelendiğinde DG ve YAK algoritmasının farklı şekillerde birleştirilerek fonksiyon optimizasyonu, yeniden düzenlenebilir anten-dizisi optimizasyonu, portföy optimizasyonu ve biyolojik modeller için parametre tahmini problemleri için kullanıldığı görülmektedir [10-15].

Shanthi ve Bhaskaran [16] mamografi resim sınıflandırma veri kümesi için YAK'ın komşu çözüm üretme operatörüne DG'nin mutant vektör üretme formülünü ekleyerek yeni bir nitelik seçme yöntemi önermiştir. Önerilen yöntem temel YAK, GA ve PSO ile karşılaştırılmıştır [16].

Yusoff ve arkadaşları [17] DG ve YAK algoritmalarını birleştirerek geliştirdikleri nitelik seçme tekniğini PSO ve KKO ile yumurtalık kanseri ve biyo-işaretleyici analizi veri kümeleri üzerinde karşılaştırmıştır [17].

### 3. Önerilen melez yöntem

Bu çalışmada DG ve YAK algoritmalarının güçlü özelliklerinin birleştirilmesinden oluşan yeni bir melez yöntem önerilmektedir.

DG algoritmasının başarısı kontrol parametrelerinin doğru ayarlanmasıyla çok yakından ilgilidir [18]. Özellikle CR (çaprazlama oranı) parametresi lokal arama ve global aramayı dengeleme açısından büyük öneme sahiptir. Düşük CR değerleri algoritmanın lokal arama özelliğini artırırken, CR' in yüksek değerleri ise global arama işlemini desteklemekte olup aynı zamanda da optimuma yakınsama sürecini kısıltmaktadır [19]. DG için bir diğer hayati parametre ise F, mutasyon ölçeği faktörüdür. Bu ölçek genel olarak [0..2] aralığında bir reel sayıdır. Bu ölçeğin yüksek değerleri global arama sürecini destekleyerek lokal optimuma takılma olasılığını azaltmaktadır [20].

YAK gözcü arılar aşamasındaki çözüm geliştirme süreciyle lokal arama işlemini çok iyi bir şekilde yönetmektedir. Ancak bu durumda da algoritma için yakınsama süreci oldukça uzamaktadır ve algoritma daha düşük performans göstermektedir [21].

Bu çalışma nitelik seçme problemi için yukarıda bahsedilen olumsuz durumları engellemek amacıyla DG algoritmasının global arama stratejisiyle YAK optimizasyon tekniğinin lokal arama özelliğini birleştirilerek yeni bir melez çözüm yöntemi önermektedir. Önerilen metodun adımları aşağıdaki gibidir:

*Adım 1. Başlangıç Popülasyonunun Oluşturulması:* Popülasyondaki her bir birey ( $X_i$ ) aşağıdaki ifadeye göre oluşturulur.

$$X_i^j = rand(0,1) \quad (1)$$

Burada,  $X_i^j$  popülasyondaki  $i$ . bireyin  $j$ . parametresini,  $rand(0,1)$  ise 0 ve 1 arasında üretilmiş rasgele bir reel değeri ifade etmektedir.

*Adım 2. İkili vektörlerin oluşturulması:* Popülasyondaki her bir birey vektör için eşitlik (2) kullanılarak bireyin ikili vektörü oluşturulur.

$$X_{ikili}_i^j = \begin{cases} 1, & \text{Eğer}(X_i^j > rand(0,1)) \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (2)$$

*Adım 3. Birey vektörler için uygunluk değerlerinin hesaplanması:* Her bir bireyin ikili vektöründe bulunan 0 değerine karşılık gelen indisteki nitelik veri kümesinden silinir. Geriye kalan nitelikler ile veri sınıflandırılır. Sınıflandırma işleminin F-ölçeği bireyin uygunluk değeri olmaktadır.

*Adım 4. Popülasyondaki bireylere mutasyon ve çaprazlama işlemlerinin uygulanması:* Bir birey ( $X_i$ ) için mutasyon vektörü oluşturulurken eşitlik (3)

kullanılır. F değeri olarak DG için önerilen değer olan 0,5 kullanılmıştır.

$$V_i^j = X_{r1}^j + F \cdot (X_{r2}^j - X_{r3}^j) \quad (3)$$

$X_{r1}$ ,  $X_{r2}$ ,  $X_{r3}$  ve  $X_i$  olarak belirtilen ifadeler sırasıyla popülasyondaki  $r1$ ,  $r2$ ,  $r3$  ve  $i$  indeksli bireyleri temsil etmektedir ve  $r1$ ,  $r2$ ,  $r3$ ,  $i$  birbirinden farklı olmak zorundadır.

Birey için mutant vektör ( $V_i$ ) oluşturulduktan sonra çaprazlama işlemine geçilmektedir. Çaprazlama işleminde mutant vektör ( $V_i$ ) ve birey vektörden belirtilen oranda genler alınarak aday vektör ( $U_i$ ) olarak adlandırılan yeni bir birey üretilmektedir. Bu üretim işlemi için eşitlik (4) kullanılır.

$$U_i^j = \begin{cases} V_i^j, & \text{Eğer } (rand(0,1) \leq CR \text{ veya } j = j_{rand}) \\ X_i^j, & \text{Diğer durumlarda} \end{cases} \quad (4)$$

$j_{rand}$  birey için rasgele seçilen bir parametre indisini belirtmektedir. Problem çözümünde DG algoritmasının global arama stratejisi kullanıldığından CR için [0,9..1] aralığında rasgele üretilen değerler alınmaktadır. Böylelikle çözüm uzayında yeni arama alanlarının keşfedilmesi sağlanmaktadır.

*Adım 5. Oluşturulan aday vektör için uygunluk değerinin hesaplanması:* Aday vektör için ikili vektör eşitlik (2) kullanılarak oluşturulur ve bu vektörde 0 değerini taşıyan nitelikler veri kümesinden silinerek geriye kalan nitelikler sınıflandırıcıya gönderilir, sınıflandırıcıdan dönen F-ölçeği değeri aday vektörün uygunluk değeri olmaktadır.

*Adım 6. Seçim işleminin uygulanması:* Bu adımda birey ( $X_i$ ) ve aday ( $U_i$ ) vektörden hangisinin bir sonraki jenerasyon için popülasyonda bulunacağına karar verilir. Uygunluk değeri daha yüksek olan vektör alınır.

*Adım 7. Popülasyondaki bireyler için uygunluk olasılık değerlerinin bulunması:* Popülasyondaki her bir birey ( $X_i$ ) için uygunluk olasılık değeri ( $p_i$ ) eşitlik 5'e göre hesaplanır.

$$p_i = \frac{uygunluk_i}{\sum_{n=1}^{birey\ sayisi} uygunluk_n} \quad (5)$$

*Adım 8. Gözcü arı işleminin uygulanması:* Bu adımda uygunluk olasılık değeri 0 ve 1 arasında üretilen sayıdan daha büyük olan bireylerin rasgele seçilmiş olan bir parametresi ( $j_{rand}$ ) üzerinde eşitlik 6'ya göre yeni aday çözüm ( $U_i$ ) oluşturulur. Daha sonra bu aday çözüm için eşitlik (2) kullanılarak ikili çözüm vektörü

oluşturulur ve bu çözüm vektöre göre sınıflandırma yapılarak aday çözümün uygunluk değeri bulunur. Bu çözümün uygunluk değeri birey çözümden daha yüksek ise birey çözüm aday çözüm ile değiştirilir. Bu adım popülasyondaki birey sayısı kadar tekrarlanır.

$$U_i^j = en\ iyi\ çözüm^j + F \cdot (X_{r1}^j - X_{r2}^j) \quad (6)$$

Algoritmanın sonlandırılabilmesi için adım 4-8 önceden belirlenen bir sonlandırma kriterine kadar tekrarlanır.

#### 4. Sonuçlar

UCI veri kümeleri %75 eğitim %25 test kümeleri olarak ayrılmıştır. Veri kümelerindeki örnek ve sınıf sayıları Tablo 1'de gösterilmektedir. Eğitim kümeleri kullanılarak, önerilen melez algoritma ile en iyi nitelik kümeleri belirlenmiştir. Elde edilen en iyi nitelik kümeleri, test veri kümeleri üzerinde 10'lu çapraz doğrulama ile sınanmıştır. Algoritmalar her bir veri kümesi için aynı çekirdek değerleri, nitelik sayısı\*4 boyutundaki popülasyon büyüklüğü ve 500 iterasyon ile 10 kez çalıştırılmış olup bu çalışmalar sonucunda elde edilen en iyi ve ortalama F-ölçeği değerleri Tablo 2.'de, 10 çalışma sonundaki en iyi çözüm için seçilen nitelik sayıları ve seçilen ortalama nitelik sayıları da Tablo 3.'de gösterilmiştir. Çalışma 4 GB RAM ve Intel Core i5-2430 M 2.4 GHz işlemci konfigürasyonu üzerinde gerçekleştirilmiştir.

Sınıflandırıcı olarak C4.5 karar ağacı sınıflandırıcısının Weka veri madenciliği yazılımındaki karşılığı olan J48 sınıflandırıcısı kullanılmıştır. Bu sınıflandırıcının seçilmesinin nedeni; Saraç ve Özel [22] tarafından yapılan çalışmada, J48 sınıflandırıcısının URL tabanlı Web sayfası sınıflandırma işleminde NaiveBayes, RBF Networks, Voted Perceptron, Threshold Selector ve VFI sınıflandırıcılarına göre daha iyi F-ölçeği değeri ile sınıflandırma yapmış olmasıdır. Gelecek çalışmalarda NaiveBayes, kNN, SVM gibi başka sınıflandırıcılarla bu çalışma yapılabilir ve sonuçlar karşılaştırılabilir.

Sonuçlar incelendiğinde, F-ölçeği değerleri açısından melez yöntemin toplam 10 veri kümesinin 7'si üzerinde standart DG ve YAK algoritmalarından ortalama olarak daha iyi bir performans sergilediği görülmektedir. Bunun yanı sıra 10 çalışma sonucunda bulunan en iyi F-ölçeği değerleri için ise melez yöntem tüm veri kümeleri üzerinde sınıflandırma performansının artmasına katkı sağlamıştır.

Nitelik sayısının azaltılması sayesinde sınıflandırma işlemi için gerekli olan toplam sürenin oldukça kısalması sağlanmıştır. Örneğin; “T.Surgery” veri kümesi için tüm nitelikler kullanılarak 10’lu çapraz doğrulama ile sınıflama işlemi 50 milisaniyede yapılırken, seçilen nitelikler ile bu işlem toplam 5 milisaniyede gerçekleştirilmiştir.

Tablo1. Veri Kümelerinin Özellikleri.

Veri Kümesi	Örnek Sayısı		Sınıf Sayısı		
	Eğitim	Test	Eğitim	Test	Toplam
Autos	121	38	6	6	6
Dermatology	267	91	6	6	6
Diabetes	576	192	2	2	2
T.Surgery	352	118	2	2	2
Glass	160	54	6	6	6
Heart-c	222	74	2	2	2
Lymph	112	36	4	4	4
Hepatitis	61	19	2	2	2
Vote	175	57	2	2	2
Zoo	76	25	7	7	7

Tablo2. Sınıflandırma sonucu bulunan ortalama F-ölçeği değerleri.

Veri Kümesi	En iyi/Ortalama F-Ölçeği Değerleri			
	DG	YAK	Melez	Tüm
Autos	0,727/0,587	<b>0,747/0,592</b>	<b>0,747/0,624</b>	0,633
Dermatology	<b>0,900/0,819</b>	0,876/0,828	0,880/0,841	0,878
Diabetes	0,737/0,662	<b>0,746/0,649</b>	<b>0,746/0,687</b>	0,667
T.Surgery	<b>0,765/0,765</b>	<b>0,765/0,765</b>	<b>0,765/0,765</b>	<b>0,765</b>
Glass	0,721/0,626	0,713/0,592	<b>0,757/0,682</b>	0,663
Heart-c	0,756/0,695	<b>0,824/0,748</b>	0,756/0,708	0,703
Lymph	0,673/0,580	0,673/0,574	<b>0,684/0,594</b>	0,609
Hepatitis	<b>0,944/0,855</b>	<b>0,944/0,817</b>	<b>0,944/0,887</b>	0,833
Vote	<b>0,964/0,889</b>	<b>0,964/0,926</b>	<b>0,964/0,921</b>	<b>0,964</b>
Zoo	<b>0,772/0,734</b>	<b>0,772/0,735</b>	<b>0,772/0,729</b>	0,733

Tablo 3. Seçilen nitelik sayıları.

Veri Kümesi	En iyi çözüm için/Ortalama Seçilen Özellik Sayısı			Toplam Nitelik Sayısı
	DG	YAK	Melez	
Autos	16/13	9/12	11/12	25
Dermatology	16/16	20/17	17/16	34
Diabetes	7/4	6/3	5/4	8
T.Surgery	5/7	7/8	5/8	16
Glass	4/4	6/4	3/5	9
Heart-c	10/7	4/5	7/6	13
Lymph	6/8	9/9	8/8	18
Hepatitis	7/9	9/9	6/9	19
Vote	7/6	7/7	6/7	16
Zoo	8/10	9/9	8/9	17

Daha sonraki çalışma için, nitelik sayıları oldukça fazla olan veri kümeleri üzerinde farklı sınıflandırıcılar kullanılarak, literatürdeki diğer nitelik

seçme yöntemleri ile bu çalışmada geliştirilen yöntem arasında bir performans değerlendirmesinin gerçekleştirilmesi planlanmaktadır.

## 5. Kaynaklar

- [1] J. Yang and V. Honavar, “Feature Subset Selection Using A Genetic Algorithm”, Feature Extraction, Construction and Selection, Springer US, 1998, p. 117-136.
- [2] Y. Chen, D. Miao and R. Wang, “A Rough Set Approach to Feature Selection Based on Ant Colony Optimization”, Pattern Recognition Letters, Elsevier, 2010, p. 226-233.
- [3] T. Prasartvit, A. Banharnsakun, B. Kaewkamnerdpong and T. Achalakul, “Reducing Bioinformatics Data Dimension with ABC-kNN”, Neurocomputing, Elsevier, 2013, p. 367-381.
- [4] S. Palanisamy and S. Kanmani, “Artificial Bee Colony Approach for Optimizing Feature Selection”, International Journal of Computer Science Issues, 9(3), 2012, p. 432-438.
- [5] M. Schiezero and H. Pedrini, “Data Feature Selection Based on Artificial Bee Colony Algorithm”, EURASIP Journal on Image and Video Processing, Springer US, 2013, p. 1-8.
- [6] R.N. Khushaba, A. Al-Ani and A. Al-Jumaily, “Feature Subset Selection Using Differential Evolution and A Statistical Repair Mechanism”, Expert Systems with Applications, Elsevier, 2011, p. 11515-11526.
- [7] R. Storn and K. Price, “Differential Evolution—A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces”, Journal of Global Optimization, Springer US, 1997, p. 341-359.
- [8] D. Karaboga and B. Basturk, “On the Performance of Artificial Bee Colony (ABC) Algorithm”, Applied Soft Computing, Elsevier, 2008, p. 687-697.
- [9] Y. Yang and J.O. Pedersen, “A Comparative Study on Feature Selection in Text Categorization”, ICML, 97, 1997, p. 412-420.
- [10] A. Alizadegan, M.R. Meybodi and B. Asady, “A Novel Hybrid Artificial Bee Colony Algorithm and Differential Evolution for Unconstrained Optimization Problems”, Advances in Computer Science and Engineering, 8(1), 2012, p. 45-56.
- [11] A. Abraham, R.K. Jatoth and A. Rajasekhar, “Hybrid Differential Artificial Bee Colony

- Algorithm”, *Journal of Computational and Theoretical Nanoscience*, 9(2), 2012, p. 249-257.
- [12] Y. Zhang, L. Wu and S. Wang, “Magnetic Resonance Brain Image Classification by An Improved Artificial Bee Colony Algorithm”, *Progress in Electromagnetics Research*, 116, 2011, p. 65-79.
- [13] A. Abdullah, S. Deris and S. Anwar, “Hybrid Evolutionary Clonal Selection for Parameter Estimation of Biological Model”, *International Journal of Computer Applications in Engineering Sciences*, 1(3), 2011, p. 313-319.
- [14] Y. Xu, P. Fan and L. Yuan, “A Simple and Efficient Artificial Bee Colony Algorithm”, *Mathematical Problems in Engineering*, Hindawi, 2013, p. 1-9.
- [15] X. Li and M. Yin, “Hybrid Differential Evolution with Artificial Bee Colony and Its Application for Design of A Reconfigurable Antenna Array with Discrete Phase Shifters”, *IET Microwaves Antennas & Propagation*, 6(14), 2012, p. 1573–1582
- [16] S. Shanthi and V.M. Bhaskaran, “Modified Artificial Bee Colony Based Feature Selection: A New Method in the Application of Mammogram Image Classification”, *International Journal of Science, Engineering and Technology Research*, 3(6), 2014, p. 1664-1667.
- [17] S.A.M. Yusoff, R. Abdullah and I. Venkat, “Adapted Bio-inspired Artificial Bee Colony and Differential Evolution for Feature Selection in Biomarker Discovery Analysis” *Recent Advances on Soft Computing and Data Mining*, Springer International Publishing, 2014, p. 111-120.
- [18] Á.A. Sá, A.O. Andrade and A.B. Soares, “Exploration vs. Exploitation in Differential Evolution”, *AISB Convention Communication, Interaction and Social Intelligence*, 1, 2008, p. 57-63.
- [19] J. Montgomery and S. Chen, “An Analysis of the Operation of Differential Evolution at High and Low Crossover Rates”, *Evolutionary Computation (CEC), IEEE Congress*, 2010, p. 1-8.
- [20] R. Mallipeddi, P.N. Suganthan, Q.K. Pan and M.F. Tasgetiren, “Differential Evolution Algorithm with Ensemble of Parameters and Mutation Strategies”, *Applied Soft Computing*, Elsevier, 2011, p. 1679-1696.
- [21] W.F. Gao and S. Liu, “Improved Artificial Bee Colony Algorithm for Global Optimization”, *Information Processing Letters*, Elsevier, 2011, p. 871-882.
- [22] E. Saraç ve S.A. Özel, “URL Tabanlı Web Sayfası Sınıflandırma”, *ASYU Sempozyumu*, 2010, p. 13-17.



## **Kril Sürüsü Algoritmasının Atölye Çizelgeleme Problemlerine Uygulanması**

Iker GÖLCÜK<sup>1</sup> ,Adil BAYKASO LU<sup>1</sup> , Fatma Selen MADENO LU<sup>1</sup>

<sup>1</sup>Endüstri Mühendisli i Bölümü, Dokuz Eylül Üniversitesi, Buca, ZM R

Kril sürüsü algoritması gerçek hayat problemlerini çözmek amacıyla yakın dönemde literatüre kazandırılmı bir sürü temelli metasezgisel algoritmadır. Algoritmanın performansı literatürde sürekli-sayı de i kenli do rusal olmayan optimizasyon problemlerinde denenmi tir. Bu çalı mada kril sürüsü algoritmasının performansı literatürde ilk kez kombinatoryal optimizasyon problemlerinden biri olan atölye tipi çizelgeleme problemlerinde test edilmi tir. Atölye tipi çizelgeleme problemleri, di er zor kombinatoryal optimizasyon problemlerini temsil eden önemli bir problem türü oldu undan, bu çalı ma algoritmanın di er kombinatoryal problemlerdeki olası performansı hakkında ön bilgiler vermektedir.

## Akıllı Şebeke Güvenliği için Veri Enjeksiyon Saldırılarının Tespiti

Alirıza YAVUZ<sup>1</sup>Mehmet Emre ÇEK<sup>2</sup>Olca AKAY<sup>3</sup><sup>1,2,3</sup>Elektrik-Elektronik Mühendisliği Bölümü

Mühendislik Fakültesi

Dokuz Eylül Üniversitesi, İZMİR

Email: aliriza.yavuz@teias.gov.tr

emre.cek@deu.edu.tr

olcay.akay@deu.edu.tr

### Özet

*Bu çalışmada, Gauss olmayan ortamlarda akıllı şebekeler için statik durum kestirimi problemi ele alınmıştır. Durum kestiriminde gürültünün Gauss olduğu yaygın olarak kabul edilir. Fakat gerçek dünya uygulamalarında gürültü aslında dürtüseldir. Gürültü alfa-kararlı dağılımla modellenmiş, durum kestirimi için gürbüz filtreler kullanılmıştır. Veri enjeksiyonu saldırılarının tespiti için kümülatif toplam (İng. CUSUM) tekniğinin performansı alfa-kararlı ortamlarda incelenmiştir.*

### 1. Giriş

Güç şebekelerinin güvenilirliğini ve etkinliğini artırmak amacıyla ileri güç, iletişim, sinyal işleme ve kontrol tekniklerinin güç şebekelerine entegre edilmesi bu konuyu popüler hale getirmiştir. Gerçek zamanlı enerji yönetim sistemleri için durum kestirimi oldukça önemlidir. Akıllı şebekelerde durum kestirimi; güç şebekesindeki her bir baradan alınan voltaj genliği ve faz açısı bilgisi olarak tanımlanır. Literatürde durum kestirimi için çoğunlukla ağırlıklı en küçük kareler yöntemi (WLS) kullanılmıştır. Bu çalışmada, gürültü alfa-kararlı olarak tanımlandığından “meridian”, “median” ve “myriad” gibi gürbüz filtrelerin performansı incelenmiş ve ağırlıklı en küçük kareler yöntemi ile kıyaslanmıştır.

Kötü niyetli kişiler, durum kestirimi işlemi sırasında kendilerini belli etmeden zararlı veriyi sisteme enjekte edip enerji kontrol merkezini yanıltabilir ve kendilerine avantaj sağlayabilirler. Bu nedenle, yapılacak veri enjeksiyonunun hızlı bir şekilde tespit edilmesi gerekir. Hızlı tespit algoritması, atağın yapıldığı zamanla tespit zamanı arasındaki gecikmenin en aza indirilmesini hedefler. Hızlı tespit ile yüksek performanslı tespit arasında bir seçim söz konusudur. Bu çalışmada kullanılan kümülatif toplam

yönteminde, eşik değeri seçimi tespit işleminin performansını belirlemektedir.

### 2. Durum kestirimi

Durum kestirimi, ölçümler ve şebeke ile ilgili parametrelerin işlenmesi sonucunda enerji sisteminin mevcut durumunun doğru bir şekilde şebeke operatörüne sunulmasını hedefler. Statik durum kestirimi, belirli bir anda elde edilen voltaj genliği ve faz açısı bilgilerini ifade eder. Aşağıdaki formülde ölçüm vektörü verilmiştir [1].

$$\mathbf{z} = h(\mathbf{x}) + \mathbf{n} \quad (1)$$

Burada  $\mathbf{x}$  durum vektörünü,  $h(\cdot)$  ölçümlerle ilişkili doğrusal olmayan fonksiyonu,  $\mathbf{n}$  ise ölçüm gürültü vektörünü ifade eder.


### 3. Alfa-kararlı dağılım

Gauss dağılımı, sinyal işlemede gürültüyü modellemek için yaygın olarak kullanılan bir dağılımdır. Fakat dürtüsel sinyallerin temsil edilmesinde yetersiz kalmaktadır. Bu yüzden, bu çalışmada dürtüsel sinyallerin modellenmesine daha uygun olan simetrik alfa-kararlı dağılım ( $S\alpha S$ ) kullanılmıştır. Alfa-kararlı dağılımın karakteristik fonksiyonu aşağıda verilmiştir.

$$\varphi(t; \alpha, \beta, \gamma, \delta) = \begin{cases} \exp[it\delta - |yt|^\alpha (1 - i\frac{2}{\pi}\beta sgn(t) \log|t|)], & \alpha = 1 \\ \exp[it\delta - |yt|^\alpha (1 - i\beta sgn(t) \tan(\frac{\alpha}{2}))], & \alpha \neq 1 \end{cases} \quad (2)$$

Alfa-kararlı dağılım 4 farklı parametre ile kontrol edilir ve  $S(\alpha, \beta, \gamma, \delta)$  şeklinde ifade edilir. Alfa,  $\alpha \in (0, 2]$ , dağılımın şeklini belirler. Beta,  $\beta \in [-1, 1]$ , dağılımın sağa veya sola eğik olmasını belirler. Gama,  $\gamma > 0$ , dağılımın yaygınlığını belirler ve Gauss dağılımındaki varyansa benzer. Delta,  $-\infty < \delta < +\infty$ , yer parametresidir ve eğilimin yatay

eksendeki pozisyonunu belirler. Şekil 1'de de görüldüğü üzere alfa küçüldükçe dağılım ağır-kuyruklu bir yapıya dönüşmektedir [2].



Şekil 1. Farklı alfa değerlerine ait kuyruk olasılık dağılımları.

## 4. Gürbüz filtreler

### 4.1. Median filtre

Median filtre,  $x[.]$  kesikli zaman sinyali üzerinde simetrik bir pencere vasıtasıyla sıralı bir şekilde ilerler. Filtre, bulunduğu noktada sağdaki ve solundaki verilerden eşit sayıda veriyi alarak, bu verileri küçükten büyüğe sıralar ve ortanca değeri filtre çıkışına verir [3]. Median filtre aşağıdaki şekilde gösterilebilir.

$$y[n] = \text{MEDIAN} [ x_1[n], \dots, x_N[n] ] \quad (3)$$

### 4.2. Meridian filtre

Meridian dağılım birbirinden bağımsız iki sıfır-ortalama Laplace dağılımın birbirine oranı şeklinde tanımlanır.  $N$  tane birbirinden bağımsız ve özdeş dağılıma sahip örnekler  $x_1, x_2, \dots, x_N$  olsun ve her biri ortak ölçek parametresi  $\Delta$  (medianity) ile meridian dağılıma uysun. Örnek meridian,  $\hat{B}$ , aşağıdaki denklem ile hesaplanır.

$$\hat{B} = \arg \min_{B \in \mathfrak{R}} \sum_{i=1}^N \log [\Delta + |x_i - B|] \quad (4)$$

Burada  $B$  konum parametresi olarak adlandırılır.  $\Delta$ , meridian filtrenin davranışını belirleyen ayarlanabilir bir parametredir. Dürtüsel ortamlarda bu parametre düşük değerler alıyorsa, filtre daha güvenilir sonuçlar veriyor demektir [4].

### 4.3. Myriad filtre

Myriad filtre, belirli bir dağılım altında maksimum olabilirlik kestirimine dayanan konum belirleme amaçlı bir süzgeç olup Gauss dışı dağılımlar için uygun bir aday süzgeçtir. Bu çalışmadaki Gauss dışı gürültü Cauchy dağılımı ile modellenmiştir.  $N$  tane birbirinden bağımsız ve özdeş dağılıma sahip örnekler  $x_1, x_2, \dots, x_N$  olsun. Bu örneklerin her biri ortak ölçek parametresi  $K$  (doğrusallık) ile Cauchy dağılıma uysun. Buna göre  $\hat{B}$  aşağıdaki denklem ile hesaplanır.

$$\hat{B} = \arg \min_{B \in \mathfrak{R}} \sum_{i=1}^N \log [K^2 + |x_i - B|^2] \quad (5)$$

$B$ , konum parametresi olarak adlandırılır. Brüt hataların etkisini logaritma fonksiyonu azaltmaktadır. Doğrusallık parametresi  $K$  myriad filtrenin güvenilirliğini belirler. Bu parametrenin küçük bir değere sahip olması filtrenin güvenilir sonuçlar verdiğini gösterir [4].

## 5. Veri enjeksiyonu saldırılarının hızlı tespiti

### 5.1. Veri enjeksiyon modeli

DC güç akış modeline dayanan siber veri enjeksiyonu saldırısı aşağıdaki şekilde modellenir [5].

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{a} + \mathbf{n} \quad (6)$$

Burada  $\mathbf{a}$ , kötü niyetli enjektörün temsil eder.  $\mathbf{H}$  matrisini kötü niyetli kişilerin bilmediği varsayılır. Eğer saldırı yapacak kişi  $\mathbf{H}$  matrisi hakkında bilgiye sahipse yani güç şebekesi hakkında bilgiye sahipse, ölçüm vektörü üzerine  $\mathbf{a} = \mathbf{H}\mathbf{c}$  şeklinde bir vektör ekleyerek operatörü şaşırtabilir. Bu durumda ölçüm vektörü aşağıdaki gibi olur [5].

$$\mathbf{z} = \mathbf{H}(\mathbf{x} + \mathbf{c}) + \mathbf{n} \quad (7)$$

Böylelikle operatör gerçek durum vektörünün  $(\mathbf{x} + \mathbf{c})$  olduğuna inanır. Geleneksel istatistik testleri bu tarz saldırıları tespit edemez. Çünkü saldırı vektörü,  $\mathbf{H}$  matrisinin alt uzayı içinde kalır.

Saldırı yapıldığı zaman, ölçüm vektörünün ortalama değeri bir sapma gösterecektir. Eğer saldırının olmadığı durum simetrik alfa-kararlı dağılıma  $S(\alpha, \beta, \gamma, \delta_0)$  sahipse, saldırı öncesi  $\delta_0$  olan ortalama değer  $\delta_1$ 'e dönüşecektir. Bu durumda, ikili hipotez aşağıdaki gibi ifade edilir.

$$\begin{cases} H_0 : z \sim S(\alpha, \beta, \gamma, \delta_0) \\ H_1 : z \sim S(\alpha, \beta, \gamma, \delta_1) \end{cases} \quad (8)$$

$\mathbf{a}_\tau$ , rastgele bir  $\tau$  zamanında yapılan bilinmeyen bir saldırı vektörü olsun. Bu durumda  $T_h$  değişim tespit zamanını temsil eder. Eğer  $T_h < \tau$  ise atak gelmeden alarm verilmiş demektir ve yanlış alarm olarak adlandırılır.  $T_h > \tau$  durumunda ise  $T_d = T_h - \tau$  gecikmeyi ifade eder. Hızlı tespit gecikmesinin azaltılması hedeflenir ve şu şekilde ifade edilir [6].

$$T_d = \sup_{\tau \geq 1} E_\tau [T_h - \tau | T_h > \tau] \quad (9)$$

## 5.2. En hızlı tespit algoritması (quickest detection)

Kümülatif toplam, Page tarafından değişim tespiti için geliştirilmiş sıralı bir analiz tekniğidir ve gecikmenin en aza indirgenmesinde oldukça etkilidir. Bu çalışmada ölçüm vektöründeki değişimlerin tespiti için iki-yönlü kümülatif toplam yöntemi kullanılmıştır. Başlangıçta atağın olmadığı varsayılır ve ortalama değer  $\delta_0$ 'dır. Atak geldiğinde bu değer  $\delta_1^+ = \delta_0 + \mu\gamma$  veya  $\delta_1^- = \delta_0 - \mu\gamma$ 'ya dönüşür. Burada  $\mu$ , tespit edilmek istenen kaymanın miktarını temsil eder. Alarm zamanı aşağıdaki gibi ifade edilebilir [7].

$$\begin{aligned} t_a &= \min \{ i : (g_i^+ \geq \theta) \cup (g_i^- \geq \theta) \} \\ g_i^+ &= g_{i-1}^+ + z_i - \delta_0 - L \\ g_i^- &= g_{i-1}^- - z_i + \delta_0 - L \end{aligned} \quad (10)$$

$z_i$ ,  $i$  anındaki ölçüm değerini ifade eder.  $L$  oluşan kaymanın genliğinin yarısını temsil eder. Eğer  $g_i^+$  veya  $g_i^-$  belirlenen eşik değeri  $\theta$ 'yı geçerse enjekte edilen veri saldırısı tespit edilmiş demektir.

## 6. Sonuçlar

### 6.1. Durum kestirimi


Bu çalışmada dürtüsel ortamda gürbüz filtreler ve en küçük kareler (WLS) yöntemi ile durum kestirimi yapılmıştır.  $1.5 \leq \alpha \leq 1.9$  aralığı için simülasyon sonuçları incelenmiş ve filtre performansları birbirleri ile kıyaslanmıştır. Gösterilen grafiklerde yatay eksen "Signal to Dispersion Ratio (SDR)", dikey eksen ise "Fractional Lower Order Error (FLOE)" yer almaktadır. FLOE aşağıdaki gibi formüle edilir.

$$FLOE = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}|^p, p < \alpha \quad (11)$$

Bu çalışmada  $p = \alpha - 0.01$  olarak alınmıştır. SDR ise matematiksel olarak aşağıdaki gibi gösterilir.


$$SDR = 20 \log_{10} \frac{A}{\gamma^{1/\alpha} \sqrt{2}} \quad (12)$$

Burada  $A$  sinyalin genliğini temsil etmektedir.




Şekil 2.  $\alpha = 1.9$  için filtre performansları.

Şekil 2 incelenecek olursa; alfa 1.9 iken gürültünün Gauss durumuna yakın olduğu söylenebilir. Myriad ve meridian filtrelerin benzer performans gösterdiği, median ve WLS'nin yüksek SDR'ler için daha iyi sonuçlar verdiği görülmektedir.




Şekil 3.  $\alpha = 1.8$  için filtre performansları.

Alfanın 1.8 olduğu Şekil 3'te de Şekil 2'dekine benzer bir performans görülmekte olup, sadece sonuçlar biraz daha kötüleşmektedir.




Şekil 4.  $\alpha = 1.7$  için filtre performansları.

Şekil 4'te de görüldüğü üzere alfanın daha düşük bir değer alması en küçük kareler metodunun performansını belirgin bir şekilde düşürmektedir. Diğer üç filtre ise genel anlamda WLS'den daha iyi performans göstermektedirler.



Şekil 6.  $\alpha = 1.5$  için filtre performansları.

Şekil 6'da, alfanın 1.5 değerini aldığı yani dürtüsellüğün en yoğun olduğu ortamda, myriad ve meridian filtre genelde en iyi performansı gösterirken, median filtre SDR'nin yüksek olduğu 20-30 aralığında en iyi performansı vermektedir.




Şekil 5.  $\alpha = 1.6$  için filtre performansları.

Şekil 5'te,  $\alpha = 1.6$  için WLS grafikteki SDR aralığında diğer üç filtreye göre iyi bir performans sergileyememektedir. Dikkat edilirse myriad ve meridian filtreler yüksek SDR değerlerinde doyuma ulaşırken, median filtre sürekli FLOE'yi düşürme eğilimindedir.

## 6.2. En hızlı tespit


Farklı alfa değerleri için CUSUM algoritmasının performans testleri yapılmış ve CUSUM tekniğinin dürtüsel ortamlardaki davranışı incelenmiştir. Dürtüsellüğün artması, CUSUM tekniğinin saldırı tespit performansını düşürmektedir.



Şekil 7. Doğru tespit oranı ve eşik değeri ilişkisi.


Şekil 7'de de görüldüğü gibi alfanın düşmesi dürtüsellüğü artırmış ve bunun sonucunda CUSUM tekniğinin performansı düşmüştür. Saldırdan önce meydana gelen güçlü darbeler CUSUM tekniğinin

erken sonlandırılmasına sebep olmuştur. Yani belirlenen eşik değeri darbeler ile aşılmış, saldırının tespiti başarısız olmuştur. Bu tarz gürültünün güçlü olduğu ortamlarda performansı artırmak için eşik değeri  $\theta$  büyük seçilebilir.



Şekil 8. Yanlış alarm oranı ve eşik değeri ilişkisi.

Alfa değerinin düşmesinin yanlış alarm oranını artırdığı Şekil 8'de görülmektedir. Yanlış alarmlardan kaçınmak için eşik değeri büyük seçilebilir. Fakat eşik değerinin büyük seçilmesi karar süresini uzatacaktır.



Şekil 9. Ortalama yakalama süresi ve eşik değeri ilişkisi.

Şekil 9'da da görüldüğü gibi alfanın küçük değerler alması ortalama yakalama süresini uzatmaktadır. Dolayısıyla, dürtüsel ortamlarda kümülatif toplam tekniğinin karar vermesi zorlaşmaktadır. Daha önce de belirtildiği gibi ortalama yakalama süresi ile doğru

tespit oranı arasında bir seçim söz konusudur. Uygulamanın hassasiyetine göre bir eşik değeri seçilmelidir. Fazla büyük bir eşik değerinin seçilmesi saldırı tespiti için gereğinden fazla zaman harcanmasına sebep olabileceği gibi, gereğinden küçük seçilen eşik değeri de doğru tespit oranını ciddi derecede düşürebilir.

## 7. Kaynaklar

- [1] Y.F. Huang, S. Werner, J. Huang, N. Kashyap ve V. Gupta, "State Estimation in Electric Power Grids: Meeting New Challenges Presented by the Requirements of the Future Grid", Signal Processing Magazine, IEEE, Eylül 2012, s. 33-43.
- [2] G. Samoradnitsky ve M.S. Taqu, Stable Non-Gaussian Random Processes: Stochastic Models with Infinite Variance, CRC Press, Florida, 1994.
- [3] G.R. Arce, Signal Processing: A Statistical Approach, John Wiley & Sons, New Jersey, 2005.
- [4] T. Pander ve T. Przybyła, "Impulsive Noise Cancellation with Simplified Cauchy-based P-norm Filter", Signal Processing, Elsevier, Eylül 2012, s. 2187-2198.
- [5] S. Cui, Z. Han, S. Kar, T.T. Kim, H.V. Poor ve A. Tajer, "Coordinated Data-Injection Attack and Detection in the Smart Grid: A Detailed Look at Enriching Detection Solutions", Signal Processing Magazine, IEEE, Eylül 2012, s. 106-115.
- [6] Y.F. Huang, H. Li, K.A. Campbell, Z. Han, "Defending False Data Injection Attack on Smart Grid Network Using Adaptive CUSUM Test", Annual Conference on Information Sciences and Systems (CISS), IEEE, Mart 2011, s. 1-6.
- [7] D.C. Montgomery, Introduction to Statistical Quality Control (4th ed.), Wiley, New York, 2000.

## Konjestif Kalp Yetmezliđi Rahatsızlıđının Yapay Sinir Ağları ve Bulanık Yapay Sinir Ağları Yöntemleri ile Teşhisi

Ali NARİN<sup>1</sup> Yalçın İŞLER<sup>2</sup> Mahmut ÖZER<sup>3</sup> Okan ERKAYMAZ<sup>4</sup>

<sup>1,3</sup>Elektrik-Elektronik Mühendisliđi Bölümü  
Mühendislik Fakültesi  
Bülent Ecevit Üniversitesi, ZONGULDAK

<sup>2</sup>Biyomedikal Mühendisliđi Bölümü  
Mühendislik-Mimarlık Fakültesi  
İzmir Katip Çelebi Üniversitesi, İZMİR

<sup>4</sup>Bilgisayar Mühendisliđi Bölümü  
Mühendislik Fakültesi  
Bülent Ecevit Üniversitesi, ZONGULDAK

alinarin@beun.edu.com islerya@yahoo.com mahmutozer2002@yahoo.com oerkaymaz@gmail.com

### Özet

*Vücudun gereksinim duyduđu miktarda kanın pompalanamaması durumuna Konjestif Kalp Yetmezliđi (KKY) denir. KKY rahatsızlıđına sahip hastaların ölüm oranı çok yüksek olduğundan erken teşhis edilmesi oldukça önemlidir. Kalp hızı deđişkenliđini kullanarak elde edilen ölçümlere geriye dođru eleme yöntemiyle başarımlı en çok deđiştiren ölçümlerden faydalanarak Yapay Sinir Ağları (YSA) ve Bulanık Yapay Sinir Ağları (ANFİS) yöntemleri ile KKY hastalarının teşhisi yapılmıştır. ANFİS yönteminde eğitim sürecindeki ortalama hata yaklaşık 0,0008 iken YSA ile yaklaşık 0.08'dir. Test sonuçlarında ise ANFİS 0,6 dolaylarında iken YSA'nın ortalama karesel hatası 0,2 dolaylarındadır. Sonuç olarak, YSA'nın KKY hastalarının teşhisinde daha başarılı olduğu tespit edilmiştir.*

### 1. Giriş

Doku ve hücrelerin ihtiyaç duydukları oksijen ve besin maddelerinin vücuda yeterli miktarda pompalanması kalbin en önemli görevidir. Kalbin yeterli miktarda kanı pompalayamaması durumunda kalp yetmezliđi ortaya çıkar [1]. Kan dolaşımının yetersizliđinden dolayı bazı doku ve damarlarda kan birikmesine konjestiflik denir. Kalp yetmezliđi hastalarının çođunluđunda bu olayın meydana gelmesinden dolayı bu rahatsızlıđa genellikle konjestif kalp yetmezliđi (KKY) denir [2].

KKY hastalarında teşhis konulduktan sonraki beş yıl içinde ölüm oranı %50 olarak tespit edilmiştir [3]. Bu nedenle KKY rahatsızlıđına erken teşhis konulabilirse hem ölüm oranı azaltılmış hem de kişilerin daha kaliteli bir yaşam sürmesi sağlanmış olur. KKY'nin teşhis edilmesinde standart olarak kullanılan elektrokardiyografi, ekokardiyografi ve göğüs röntgeni başta olmak üzere birçok klinik inceleme testleri ve yöntemlerinin yansıra kalp hızı deđişkenliđi (KHD) analizi de kullanılmaktadır [4-10]. KHD analizi sonucunda elde edilen ölçümlerden oluşturulan öznitelikler çeşitli sınıflandırıcı ve kümeleme algoritmalarına uygulanmaktadır [5]. Bu sınıflandırma algoritmalarının başarımları elde edilen özniteliklerin seçilmesi [4,5,9], normalleştirme işlemlerine [11] ve diđer önışlem uygulamalarına [12] göre deđişiklik göstermektedir. Son zamanlarda EKG ve KHD üzerine Yapay Sinir Ağları (YSA) ve Bulanık Yapay Sinir Ağları (ANFİS) sınıflandırıcı çalışmaları bulunmaktadır [15,16,17]. Bu çalışmanın amacı, KHD ölçümlerinden elde edilen öznitelikleri kullanarak literatürde yaygın kullanıma sahip YSA ve ANFİS sınıflandırıcı yöntemleri ile KKY olan hastaların teşhis edilmesidir.

### 2.Yöntem

#### 2.1 Verilerin Elde Edilmesi


Yapılan çalışmada kullanılan KHD verileri MIT/BIH veri setleri <http://www.physionet.org> internet adresinden ücretsiz olarak elde edilmiştir [14]. Kullanılan bu KHD veriler şu şekildedir:

- “Congestive Heart Failure RR Interval Database” (chf2db) veri tabanı: yaşları 34 ile 79 arasında değişen 29 adet hastadan elde edilmiş EKG kaydı.
- “Normal Sinus Rhythm RR Interval Database” (nsr2db) veri tabanı: yaşları 24 ile 76 arasında değişen 54 adet normal EKG kaydı.

Her ne kadar veri tabanları 24 saatlik KHD verilerinden oluşsa da, sonuca daha hızlı ulaşabilmek ve klinik ortamda hastaları en az şekilde rahatsız etmek için sadece 5 dakikalık (300 saniyelik) KHD verileri kullanılmıştır [4].

## 2.2. Kalp Hızı Değişkenliği Analizi Ölçümleri

KHD verileri EKG işaretindeki QRS dalga yapısının belirlenmesi sonucunda elde edilir. Çünkü QRS dalga yapısı EKG işareti içerisinde en belirgin genlik değerine sahip bileşendir (Şekil 1). QRS tespit edildikten sonra peş peşe gelen tepe noktaları arasındaki zaman farkı RR zaman serisi olarak tanımlanır [15]. KHD çalışmalarında kullanılan ölçümler için ayrıntılı bilgi kaynakçada verilen referanslarda vardır [1,5]. Burada, çalışmada kullanılan ölçümler hakkında kısaca bilgi verilecektir.



Şekil 1. EKG işaretindeki QRS dalga yapısı

Frekans alanı ölçümlerinde, güç spektral yoğunluğu (GSY) farklı frekans bölgelerindeki güç ve tepe frekansları hesaplanarak incelenir. KHD analizinde genel olarak VLF(0 0,033 Hz), LF(0,033– 0,15 Hz) ve HF(0,15–0,4 Hz) olmak üzere üç frekans bandı kullanılmaktadır [15].

Frekans alanı ölçümleri içinde Fourier dönüşümü kullanılmıştır. Hızlı Fourier dönüşümü (FFT) kullanımından önce KHD verileri 4 Hz örnekleme hızında kübik spline ara değerlendirme metodu ile yeniden örneklenmiş [15] ve analizde durağanlığı sağlamak için eğilim yok edilmiştir [12].

Diğer bir frekans alanı ölçümü olan Dalgacık Analizi ise incelenen işaretin polinomsal durağansızlıklarını ortadan kaldırmasıyla beraber işaretin zaman ve ölçek

boyutlarının birlikte incelenmesine olanak sağlar. Bu özelliğinden dolayı çalışmada kullanılan RR aralıklarının analizinde çok kullanışlı olduğu rapor edilmiştir [8]. Bu analiz yönteminde de 4 Hz ile yeniden örneklenmiş KHD verisi üzerinden sık kullanılan Daubechies-4 ana dalgacığı ile 7 seviyeli [4] Dalgacık Dönüşümü metodu kullanılmıştır.

Bu çalışmada ayrıca doğrusal olmayan yöntemlerle elde edilen Poincare haritası ölçümü öznitelik olarak kullanılmıştır.

$$SD_1 = \sqrt{\frac{1}{2}(SDSD)^2} \quad (1)$$

$$SD_2 = \sqrt{2(SD)^2 - \frac{1}{2}(SDSD)^2} \quad (2)$$

Burada, SD verilerin standart sapmasını ve SDSD ise peş peşe gelen verilerin farkının standart sapmasını ifade etmektedir. Bu iki verinin çarpımı ile Poincare haritası ölçümü elde edilmiştir.

Bu şekilde 1 adet Poincare haritası ölçümü, 2 adet FFT ölçümü ve 2 adet Dalgacık dönüşümü ölçümü olmak üzere 5 adet öznitelik kullanılmıştır (Tablo 1).

Tablo 1. Girdi olarak kullanılan KHD ölçümleri

Öznitelik	Açıklama
sd1*sd2	Poincare çizimindeki değerler çarpımı
fft_lf	Fourier düşük frekans değeri
fft_lfhf	Fourier düşük frekansın yüksek frekansa oranı
db4_ent_lf	Düşük frekans entropi Dalgacık dönüşümü
db4_energy_lf	Düşük frekans enerjisi Dalgacık dönüşümü

## 2.3 Özniteliklerin Ölçeklenmesi


Örüntü tanıma için kullanılan özniteliklerin büyüklüklerinin çok farklılıklar göstermesi nedeniyle, kullanılan özniteliklerin aynı ölçeğe indirgenmesi gerekmektedir. Bu işleme normalleştirme adı verilir [13]. Bu çalışmada kullanılan tüm öznitelikler [0,1] aralığına ölçekleme olan (Min-Max) yöntemi kullanılmıştır.



## 2.4 Model

### 2.4.1 Yapay Sinir Ağları (YSA)

YSA, insan beyninin çalışma prensibini basit olarak modelleyen sistemlerdir [18]. YSA hem doğrusal uygulamalarda hem de doğrusal olmayan uygulamalar için kullanılabilir. Genel olarak bir YSA bir giriş katmanı, bir veya birden çok saklı katman ve bir çıkış katmanından oluşmaktadır (Şekil 2).



Şekil 2. Çok katmanlı yapay sinir ağı yapısı

Bir YSA'nın her bir katmanında birçok sinir hücresi bulunmaktadır. Bu sinir hücreleri birbirlerine çeşitli şekillerde ve ağırlıklarla bağlıdır. Beklenen çıktı ile ağın çıktısı arasındaki hatanın minimum olana kadarki süreç ağın eğitim sürecidir. Ağın çıktı fonksiyonu ve hata fonksiyonu:

$$y_i = f \left( \sum_{j=1}^n w_{ij} x_j \right) \quad (3)$$

$$E = \frac{1}{2} \sum_i (y_{di} - y_i)^2 \quad (4)$$

Burada  $x_j$  girdi verisi,  $w_{ij}$  ağırlık,  $f(\cdot)$  aktivasyon fonksiyonu,  $y_i$  ağın çıktısı,  $y_{di}$  beklenen çıktıdır.

### 2.4.2 Bulanık Yapay Sinir Ağları (ANFİS)


ANFİS yapısı, bulanık mantık ve yapay sinir ağlarının birleşmesinden oluşan özel bir yapıdır. Fonksiyonel ve bulanık çıkarım yapan Sugeno çıkarım yöntemini kullanan bir yapıdır. Bu ağ, öğrenme yeteneğinin gelişmiş olması, paralel işlem yapabilmesi, yapılandırılmış bilginin temsili edilmesi ve diğer denetim tasarım metotlarıyla kolaylıkla bütünleşmesinden ötürü kullanımı oldukça yaygındır [18]. ANFİS'in mimarisi, her biri belli bir işlevi gerçekleştiren 5 katmanlı ileri beslemeli ağ yapısından oluşmaktadır. ANFİS, bulanık mantık yöntemindeki eğer-ise kural tabanına göre

çalışmaktadır.  $x$  ve  $y$  girişleri ve  $f$  gibi bir çıkışı olan Sugeno bulanık modelinin gösterimi şu şekildedir:

Kural  $i$ : Eğer  $x$ ,  $A_k$  ve  $y$ ,  $B_l$  ise  $f_i = p_i x + q_i y + r_i$

Burada,  $k = 1, \dots, m_k$  (A bulanık terimlerin sayısı),  $l = 1, \dots, m_l$  (B bulanık terimlerin sayısı),  $i = 1, \dots$ , toplam kural sayısı {en fazla kural sayısı=  $m_k * m_l$ } şeklindedir.

Ağın eğitim ve denetim sürecinde YSA öğrenme algoritmaları kullanılır. Şekil 3'de beş girişli bir ANFİS yapısının blok gösterimi vardır.



Şekil 3. Beş girişli ANFİS şeması

## 3. Sonuçlar ve Tartışma

Bu çalışmada kullanılan KHD ölçümleri, ANFİS ve YSA ile gerçekleştirilmiş sınıflandırma işlemleri için MATLAB 2013a yazılımı kullanılmıştır. Çalışmada toplam 83 kişiden elde edilmiş Poincare ölçümlerinden  $sd1*sd2$  ölçümü, Fourier dönüşümünden iki adet ölçüm ve Dalgacık dönüşümünden iki adet ölçüm olmak üzere 5 adet KHD ölçümü kullanılmıştır. Hesaplama işleminin daha hızlı ve etkin olabilmesi için daha önceki çalışmalarda geriye doğru eleme yöntemiyle belirlemiş olan bu 5 özniteliğe tercih edilmiştir. Elde edilen 5 adet özniteliği kullanarak 83 kişiden oluşan veri setinin 70'i eğitim için 13'ü test için ayrıldı. Eğitim için ayrılan veriler kullanılarak elde edilen ANFİS ve YSA ortalama hata değerleri Tablo 2'de gösterilmektedir. ANFİS yönteminde için Gauss fonksiyonu, hibrit öğrenme yöntemi, 4 erli üyelik fonksiyonu ve 30 iterasyon ile eğitim gerçekleştirilmiştir. YSA yönteminde ise saklı katmandaki nöron sayısı 20 ve Levenberg-Marquardt geri yayılım yöntemi ile eğitim gerçekleştirilmiştir. Eğitimi gerçekleştirilen yöntemler 13 adet veri ile test edilip test sonuçları Tablo 3'de gösterilmiştir. ANFİS yöntemi için elde edilen test sonuçları Şekil 4 ve 5'de gösterilmiştir. YSA için elde edilen test sonuçlarındaki regresyon değeri Şekil 6'da gösterilmiştir. Her iki yöntem kıyaslandığında eğitim


süreci olarak ANFİS'in daha başarılı olduğu görülürken test sürecinde ise YSA'nın başarılı olduğu tespit edilmiştir.

Tablo 2. YSA ve ANFİS eğitim sonuçları


YSA Eğitim Verisi		
	Veri	MSE
<b>Eğitim</b>	56	0.081803
<b>Doğrulama</b>	7	0.163990
<b>Test</b>	7	0.100695
ANFİS Eğitim Verisi		
	Veri	MSE
<b>Eğitim</b>	70	0.00087164

Tablo 3. YSA ve ANFİS test sonuçları


YSA Test Verisi		
	Veri	MSE
<b>Test</b>	13	0.21154
ANFİS Test Verisi		
	Veri	MSE
<b>Test</b>	13	0.60892



Şekil 4. ANFİS test verisi sonuçları



Şekil 5. ANFİS için giriş1 ve giriş2 için çıktılar



Şekil 6. YSA için test verisi sonuçları

Sonuç olarak KKY hastalarının normal kontrol grubundan ayırt edilmesi için YSA yönteminin daha başarılı olduğu tespit edilmiştir. Bununla beraber farklı verilerin eğitim ve test için ayrılması ile sonuçların değişebileceği düşünülmektedir.

## 5. Kaynaklar

- [1] C. Flavell and L. W. Stevenson, "Take Heart with Heart Failure", *Circulation*, 2001, 104: 89.
- [2] J. Wilbur and P. James, "Diagnosis and Management Of Heart Failure in The Outpatient Setting", *Primary Care*, 2005, 32: 1115–1129.
- [3] American Heart Association, *Heart Disease and Stroke Statistics–2006 Update: A Report From the American Heart Association Statistics Committee and Stroke Statistics Subcommittee*. *Circulation*, 2006, 113: 85–151.
- [4] Y. Isler and M. Kuntalp, "Combining Classical HRV Indices with Wavelet Entropy Measures Improves to Performance in Diagnosing Congestive Heart Failure", *Computers in Biology and Medicine*, 2007, 37(10): 1502–1510.
- [5] A. Narin, Y. Isler and M. Ozer, "Investigating the performance improvement of HRV Indices in CHF using feature selection methods based on backward elimination and statistical significance", *Computers in Biology and Medicine*, 2014, 45: 72–79.
- [6] R.G. Lee, C.C. Hsiao and C.Y. Kao, "Using Different Entropies to Analyze The Heart Rate Variability of Congestive Heart Failure Patients", *Biomedical Engineering-Applications Basis Communications*, 2011, 23: 253.
- [7] L. Pecchia, P. Melillo, M. Sansone and M. Bracale, "Discrimination Power of Short-Term Heart Rate Variability Measures for Chf Assessment", *IEEE Transactions on Information Technology in Biomedicine*, 2011, 15(1): 40–46.

- [8] U. Wiklund, M. Akay and U. Niklasson, “Short-Term Analysis of Heart-Rate Variability by Adapted Wavelet Transforms”, IEEE Engineering in Medicine and Biology Magazine, 1997, 16(5): 113–118 and 138.
- [9] A. Narin ve Y. Isler, “Konjestif Kalp Yetmezliği Hastalarının Kalp Hızı Verileri Kullanılarak Teşhisi Üzerine Temel Bileşen Analizinin Etkisi”, IEEE 20. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU2012), Fethiye / Mugla, 18–20 April 2012.
- [10] A. Narin ve Y. Isler ve M. Ozer, “Konjestif Kalp Yetmezliğinin Kalp Hızı Değişkenliği Analizi ile Teşhisinde Sınıflandırıcı Başarımlarının Karşılaştırılması”, IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU2013), Girne / KKTC, 24-26 April 2013.
- [11] Y. Isler and M. Kuntalp, “Heart Rate Normalization in The Analysis of Heart Rate Variability in Congestive Heart Failure”, Proceedings of The Institution of Mechanical Engineers Part H-Journal of Engineering in Medicine, 2010, 224(3): 453–463.
- [12] Y. Isler, M.A. Selver ve M. Kuntalp, “Kalp Hızı Değişkenliği Analizinde Eğilim Yok Etmenin Etkileri”, II. M.hendislik Bilimleri Gen. Araştırmacılar Kongresi MBGAK' 2005, İstanbul, 213–219, 17–19 October 2005.
- [13] R.O. Duda, P.E. Hart and D.G. Stork, Pattern Classification, 2nd edition, New York: Wiley, 2000.
- [14] A.L. Goldberger and Colleagues, PhysioBank, PhysioToolkit, and PhysioNet: “Components of a New Research Resource for Complex Physiologic Signals”, Circulation, 2000, 101(23): 215–220.
- [15] N. Ziosabounchi and I. Askerzade, “ANFIS Based Classification Model for Heart Disease Prediction”, International Journal of Engineering & Computer Science IJECS-IJENS, 2014, 14(2).
- [16] D. Petkovic, Z. Cojbašica, and S. Lukic, “Adaptive Neuro Fuzzy Selection of Heart Rate Variability Parameters Affected by Autonomic Nervous System”, Expert Systems with Applications, 2013, 40 (11): 4490–4495.
- [17] M. R. Homaeinezhad, E. Tavakkoli, A. Afshar, S. A. Atyabi and A. Ghaffari, “Neuro-ANFIS Architecture for ECG Rhythm-Type Recognition Using Different QRS Geometrical-Based Features”, Iranian Journal of Electrical & Electronic Engineering, 2011, 7(2).
- [18] Ç. Elmas, Yapay Zeka Uygulamaları, Yapay Sinir Ağları – Bulanık Mantık– Genetik Algoritma, Seçkin Yayınevi, Ankara, 2012.

## **Parça-Makine Graplama Problemi için Kısıt Programlama Yaklaşımı**

Filiz ENYÜZLÜLER<sup>1</sup>, Feyda TOPALOĞLU<sup>2</sup>, Adil BAYKASOĞLU<sup>3</sup>

<sup>1,2,3</sup> Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Dokuz Eylül Üniversitesi, Buca,  
ZMİR

İmalat sistemlerinde, üretim hücrelerinin tasarımı, yalın üretimin temel parçalarından biri olup, üretkenliği arttırmada önemli rol oynar. Hücresel imalat sistemi tasarımı parça ailelerini ve tezgah gruplarını belirlemekle başlar. İyi bir tasarım için sistemdeki makine ve parça sayısı gibi birçok kısıtı göz önünde bulundurmak gerekir. Kısıt programlama tekniği kombinatoriyal problemlere yeni bir yaklaşım olup zengin programlama dili ile kompleks kısıtları tanımlamada kolaylık sağlar. Bu çalışmada, parça-makine gruplama problemi için KP tekniğine dayalı bir formülasyon geliştirilmiştir. Literatürden örnek problemler hem tam sayılı programlama hem de KP modelleri ile çözülmüş, sonuçlar karşılaştırılmıştır.

## En Yakın k Komşuluk Algoritmasında Örneklerle Bağlı Dinamik k Seçimi

Faruk BULUT<sup>1</sup>M. Fatih AMASYALI<sup>2</sup><sup>1,2</sup> Bilgisayar Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, Davutpaşa, İSTANBUL

Email: f0110303@std.yildiz.edu.tr

mfatih@ce.yildiz.edu.tr

### Özet

*k en yakın komşuluk algoritması(k-NN) için uygun k parametresi, kullanıcı tarafından genellikle deneme-yanılma yöntemiyle seçilir. Bununla birlikte, bir veri setinde her bir test örneği için aynı k parametresinin kullanılması genel sınıflandırma başarısını olumsuz etkileyebilir. Çalışmamızda her bir test örneği için en uygun k parametresini kümeleme yöntemiyle bulan ve bu sayede genel sınıflandırma başarısını artıran bir yöntem üzerinde çalışılmış ve başarılı sonuçlar elde edilmiştir.*


### 1. Giriş

ken yakın komşuluk algoritması(k-NN), sabit bir k değeri ile kullanılmaktadır. Literatürde en uygun k değerinin deneme yanılma yöntemi ile bulunduğu belirtilmektedir [1]. Sabit k değerinin genel sınıflandırma başarısı üzerindeki olumsuz etkileri bu çalışmada incelenecek ve bir takım çözümler önerilecektir.

Şekil-1'de görüldüğü üzere 4 adet UCI veri seti [2] üzerinde k-NN sınıflandırıcısının k parametresi 1'den 20'ye kadar sırayla denenmiş ve doğruluk (accuracy) oranları elde edilmiştir. Görüldüğü üzere k parametresinin artırılmasıyla sınıflandırma başarısı bazılarında artmış, bazılarında azalmış, bazılarında da bir değişme olmamıştır. Bu durum k-NN algoritmasının k parametresine olan hassasiyeti göstermektedir.

Her bir örneği doğru sınıflandırmak amacıyla farklı bir k değerine gereksinim duyulduğu Tablo-1'de görülmektedir. *audiology* veri setinin test kısmında bulunan bazı örneklerin geçirme işleminde sınıflandırıcının farklı k değerleriyle bu test örneğini doğru sınıflandırıp sınıflandırmadığı gözlemlenmeye çalışılmıştır. 1 değeri sınıflandırıcının ilgili örneğin etiketini doğru tahmin ettiğini; 0 ise yanlış tahmin

ettiğini göstermektedir. Bu tabloya göre k değeri 1 alındığında 8 örnekten sadece 3 tanesi doğru bilinebilirken; k değeri 4 alındığında 6 tanesi doğru bilinebilmektedir.



Şekil 1. k-NN'de k parametresinin performansa etkisi

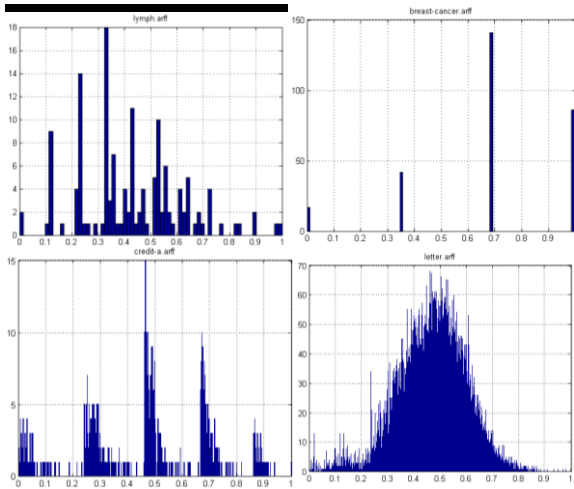
Tablo-1'de görüldüğü üzere bazı test örnekleri için k değeri artırıldığında, azaltıldığında ya da belirli aralıklarda alındığında doğru tahmin yapılmaktadır. Bu durum bize genel sınıflandırma başarısının artırmak amacıyla her test örneği için sabit bir k değeri yerine uygun bir k değerinin seçilmesi gerektiğini göstermektedir.

Tablo 1. k değerinin başarıya etkisi

	k-NN için k parametresi									
	1	2	3	4	5	6	7	8	9	10
1.örnek	0	0	0	0	0	0	0	1	1	1
2.örnek	1	1	1	1	1	1	1	1	1	1
3.örnek	0	0	0	0	0	0	0	0	0	0
4.örnek	0	0	1	1	1	1	1	1	1	1
5.örnek	0	0	0	1	1	1	0	0	0	1
6.örnek	1	1	1	1	1	1	1	1	0	0
7.örnek	1	1	1	1	1	0	1	1	1	1
8.örnek	0	0	0	1	0	0	0	0	0	0
Doğru tahmin sayısı	3	3	4	6	5	4	4	5	4	5

Şekil-2'denormalize edilmiş UCI veri setlerinden sırayla *lymph*, *breast-cancer*, *credit-a* ve *letter'm* orijin noktalarına göre tüm noktaların uzaklıklarının histogramları gözükmektedir ve veri setlerinin kendi

uzaylarındaki yayılımları hakkında bir fikir vermektedir. Orijindeki bir test noktasının sınıflandırılmasında histogram grafiğine bakacak olursak en uygun  $k$  değeri *lymph* veri setinde 2; *breast-cancer*'da 15 alınmalıdır. Çünkü orijindeki noktaya aynı uzaklıkta olan ve aynı yörünge üzerinde duran sırasıyla 2 ve 15 tane nokta kümeleri vardır. *letter* ve *credit-a* veri setinde ise en uygun  $k$  değeri için 1'den başlayarak deneme yanılma yöntemi uygulanabilir. Bu durum bize herhangi bir test örneğinin etrafındaki noktaların uzaklıklarına bağlı olarak  $k$ -NN için uygun bir  $k$  parametresinin bulunabileceğini göstermektedir.



Şekil 2. Bazı veri setlerinin histogram bilgileri


$k$ -NN sınıflandırıcısında her bir test örneği için en uygun  $k$  parametresini seçen bir sınıflandırıcı algoritması üzerinde çalışıldı. Çalışmamızın 2. bölümünde bu algoritmaya; 3. bölümünde bellek tabanlı sınıflandırıcılarda kullanılan arama yöntemlerine; 4. bölümünde elde edilen deneysel sonuçlara ve son bölümde ise değerlendirmelere yer verilmiştir.

## 2. En Yakın Küme ile Sınıflandırma

Sınıfı belirlenmek istenen bir test noktası etrafında hemen hemen aynı uzaklıkta birden fazla nokta bulunabilir. Bu durumda  $k$ -NN sınıflandırıcısı için seçilen  $k$  parametresinin 1 alınması durumunda rastgele seçimden ötürü sınıflandırma işlemi güvenilirliğini yitirmektedir. Şekil-3A'da görüldüğü üzere rastgele yapılan bu işlemde sınıf etiketi her denemede başka çıkabilmektedir.

Bir test örneğine aynı uzaklıkta birden fazla örneğin bulunma ihtimali oldukça azdır. Fakat benzer


uzaklıkta birden fazla örnek bulunabilmektedir. Şekil-3B'deki senaryoda  $k$  değerinin 1 veya daha fazla alınması durumunda sonuç farklı çıkacaktır.



Şekil 3. Sınıflandırma örnekleri

Bütün bunlar,  $k$ -NN algoritmasında her bir test örneği için en uygun  $k$  parametresinin seçilmesi gerektiğini göstermektedir. Çalışmamızda  $k$ -NN algoritmasına benzeyen fakat daha yüksek doğruluk oranına sahip olabileceği düşünülen bir sınıflandırıcı üzerinde çalışıldı. En yakın küme sınıflandırıcısı (*One Nearest Cluster*, 1NC) diye isimlendirilen bu öğrenici, test noktasına en yakın ilk kümedeki örneklerin tamamını hesaplamaya katmaktadır. 1NC tekniğinin işlem basamakları şu şekildedir:

1.  $N$ , veri setinde örnek sayısı olmak üzere, veri setine ait tüm değerleri normalize et,
2. Test noktasına en yakın  $M$  adet örneği al ve  $l$  adet kümeye böl,
3. Test noktasına en yakında noktanın ait olduğu kümenin tüm elemanlarını  $k$ -NN yöntemiyle sınıflandırma işlemine al.



Şekil 4. Kümeleyerek sınıflandırma (1NC) örneği

Şekil-4'teki örnek senaryoda test noktana değişik uzaklıkta olan noktaların histogram grafiği görülmektedir. Bu noktalar kümeleme yöntemiyle (*clustering*) 3 adet kümeye bölünmüştür. 1NC sınıflandırıcısı için en yakında bulunan küme içerisindeki 7 adet örnek hesaplamaya katılacaktır ( $k$ -NN için  $k=7$  alınacaktır).

Test noktasına en yakın  $M$  adet örneğin  $l$  adet kümeye bölünmesi ve sadece en yakındaki ilk kümenin işleme dâhil edilmesi dinamik bir yapıyı oluşturmaktadır.  $l$  adet kümenin ( $k$ -means'deki  $k$  ifadesinin  $k$ -NN'deki  $k$  ile karıştırılmaması için  $l$  ifadesi tercih edilmiştir) her birinde yaklaşık olarak  $M/l$  adet eleman olduğu düşünülebilir. Normalde  $k$ -NN sınıflandırıcısı için kullanıcı tarafından seçilen  $k$  parametresi ile bizim yöntemimizdeki  $M/l$  kombinasyonununun olması şu formül ile sağlanabilir:

$$k\text{NN}'\text{deki } k \cong \frac{M}{l} \quad (1)$$

Bu sayede  $M/l$  likiliyle her bir test örneğinin sınıflandırılması için uygun bir  $k$  değeri hesaplanmış olmaktadır.

Üzerinde çalışılan 1NC tekniğinde  $k$ -NN ve  $k$ -means yöntemlerinin toplam zaman karmaşıklıkları olduğu için normal  $k$ -NN sınıflandırıcısına göre bir miktar daha maliyetlidir [3].

### 3. En Yakın Örnekleri Arama Yöntemleri

$k$  en yakın komşuluk algoritması ( $k$ -NN) bellek tabanlı bir sınıflandırıcıdır ve sınıflandırma işleminde her bir test örneği için eğitim setinde ayrı ayrı arama yapılmaktadır. Bu durum hesaplama zamanını artırmaktadır. Uygulamamızda hesaplama zamanını düşürmek için iki tip arama algoritması kullanılmıştır. Literatürde bir veri setinde boyutsayısı  $10^3$ 'den büyük ise tam kapsamlı arama (*Exhaustive Search*);  $10^3$ 'den küçük ise  $kD$ -Tree veri yapısı ile yapılan arama yöntemini tavsiye edilmektedir [4]. Kullanılan arama yöntemleri algoritmanın başarısını etkilememektedir.

#### 3.1. Tam kapsamlı arama

Tam kapsamlı arama (*Exhaustive Search*) ile hiçbir veri yapısı ve algoritma kullanılmadan Öklid uzaklığına göre test noktasına en yakın  $k$  tane örnek sıralı bir şekilde aranır. Bu arama yönteminin zaman karmaşıklığı oldukça yüksektir.  $D$  veri setinin boyut sayısı,  $N$  de eleman sayısı olmak üzere algoritmanın Big-O notasyonuna göre istenilen bir elemanı bulmanın zaman karmaşıklığı  $O(k * D * N)$ 'dir [5].

#### 3.2. $kD$ -Tree ile arama

BSP (*Binary Space Partitioning*) yöntemlerinden biri olan  $kD$ -Tree ( $k$  Dimensional Tree), ikili arama ağacı olan BST (*Binary Search Tree*) veri yapısının çok

boyutlu türüdür. Bu veri yapısında sadece aranan bir elemanı bulma maliyeti  $O(D * \log N)$ ; her hangi bir test noktasına en yakın  $M$  adet noktanın bulunması  $O(D * M * \log N)$ 'dir. Tam kapsamlı aramada bu maliyet  $O(D * M * N)$  olduğu için  $kD$ -Tree daha avantajlıdır.

### 4. Pratik Uygulama ve Deneysel Sonuçlar

Verileri normalize edilmiş, kayıp değerleri yer değiştirilmiş, nominal değerleri ikili sayısal değerlere dönüştürülmüş 36 adet UCI veri seti, MATLAB ortamında  $5 \times 2$  çapraz geçirme ile test edildi. Veri setlerinde arama yöntemi olarak  $kD$  ağaç veri yapısı ve tam kapsamlı arama yöntemlerinden uygun olanı kullanıldı. Tablo-2'te yaptığımız çalışmanın sonuçları verilmektedir.  $k$ -NN sınıflandırıcısı için örnek olarak  $k$  parametresi 5 alınmıştır ve tüm veri setleri için doğruluk sonuçları hesaplanmıştır. İki farklı sınıflandırma mekanizması tarafından elde edilen sonuçların istatistiksel anlamlılığını tespit etmek için T-Test yöntemi [6] tercih edilmiştir. T-Test sonuçları üç farklı değer içermektedir: *win* (başarılı), *loss* (başarısız) ve *tie* (eşit).

Tablo-2'nin ilk sütununda 1NN sınıflandırıcısının; ikinci sütunda  $k=5$  alınarak elde edilen  $k$ -NN sınıflandırıcısının; üçüncü sütunda *en yakındaki küme* (1NC) sınıflandırıcısında doğruluk oranları görülmektedir. 1NC'de her bir test noktasına en yakın ( $M$  değeri) 20 eleman alınarak  $k$ -means kümeleme yöntemiyle (iterasyon sayısı=100 ve  $k$  parametresi=4 alındı) 4 adet kümeye ( $l$  değeri) bölünmüştür. Bu durumda 4 adet kümenin her birinde yaklaşık olarak 5'er adet örnek bulunduğu düşünülebilir. Bu durum  $k$ -NN için  $k=5$  anlamına gelir.

$k$ -NN ( $k=5$ ) ile 1NC ( $M/l = 20/4$ ) sınıflandırıcıları ile elde edilen doğruluk oranlarının yüzdelik artış-azalış oranları ve bu iki sınıflandırıcının T-Test sonuçları *kNN-INC karşılaştırma* isimli sütununda görülmektedir. Bu karşılaştırmada %15'e kadar sınıflandırma başarısında artış olduğunu gözlemlenmiştir. Her iki sınıflandırıcının karşılaştırması sonucunda 8 adet veri kümesinde başarı (*win*) sağlanmış, 20'sinde değişme olmamış (*tie*) ve 8 tanesinde başarısız (*loss*) olunmuştur. Ayrıca 1NC yöntemi, 1NN ile karşılaştırıldığında daha başarılı sonuçlar elde edilmiştir: 12 adet *win*, 20 adet *tie* ve sadece 4 adet *loss*. Görüldüğü üzere 1NC algoritması ile bazı veri setlerinde daha başarılı sonuçlar elde edilmiştir.



INC için  $M/l$  ikililerinden  $k$ -NN'deki  $k=5$  parametresine denk gelen 10/2, 15/3, 30/6, 50/10 ve 100/20 kombinasyonları ayrı ayrı denenmiştir. Denemelerde 20/4 ile elde edilen benzer doğruluk oranlarına ve hemen hemen aynı sayıda *win*, *tie* ve *loss* sonuçlarına ulaşılmıştır. Bu sonuçlar üç farklı çıkarım yapılmasını sağlamıştır. Birincisi benzer sonuçları veren düşük değerlikli  $M/l$  ikilisinin tercih edilmesi hesaplama süresinin kısalmasını sağlar. İkincisi  $k$ -NN'deki  $k$ 'ya eşit olması için genel olarak  $M$ ,  $k$ 'nın 3 katı alınabilir ve  $l$  değeri de 3'e sabitlenebilir ( $k \cong M/l$  olduğunu hatırlayınız). Üçüncü çıkarımda ise  $M/l$  ikilisi tek bir parametre gibi düşünülebilir.

Ayrıca tüm veri setleri için  $k$ -NN'de  $k$  değeri, sırasıyla 1'den 100'e kadar alınarak sınıflandırma başarıları elde edilmiştir. 14 adet veri setinde en yüksek başarı,  $k=1$  alındığında hesaplanmıştır. 1NN'in en iyi örnek tabanlı sınıflandırıcı olduğu veri kümelerinde INC yönteminin daha yüksek başarı elde etmesi mümkün değildi diye düşünülmüştü. Fakat INC yönteminde  $M/l$  ikilisi 20/4 alındığında bazı veri setlerinde (*ionosphere*, *d159*, *sonar*) 1NN'e göre daha da yüksek başarılar elde edilmiştir. Diğer veri setlerinde (*autos*, *glass*, *vowel*, *anneal*, *col10*, *labor*, *letter*, *mushroom*, *segment*, *soybean*, *zoo*) ise *tie* sonucu alınmıştır. Bu durum bazı veri setleri için INC'nin, en başarılı sonucu veren küçük  $k$  parametrelili  $k$ -NN'den bile daha başarılı olabileceğini göstermektedir.

## 5. Değerlendirme

$k$ -NN'de her bir örnek için sabit bir  $k$  değerinin kullanılmasına karşın çalışmamızda her bir örnek için en uygun ve farklı  $k$  değerlerinin kullanılması daha yüksek doğruluk oranları elde etmemizi sağladı. Çalışmamızda  $k$ -NN'de olduğu gibi tek bir parametre yardımıyla daha başarılı sonuçlar elde edildi. Diğer bir taraftan üzerinde çalıştığımız yöntemde, örnek tabanlı bir sınıflandırıcıya ilave olarak kümeleme yöntemi kullandığı için bir miktar zaman karmaşıklığında ve hesaplama süresinde artış oldu.

## 6. Kaynaklar

- [1] Myatt, G.J, Making Sence of Data: A Practical Guide to Exploratory Data Analysis and Data Mining, Wiley, (2007). s. 176-181.
- [2] Bache, K. & Lichman, M. UCI Machine Learning Repository <http://archive.ics.uci.edu/ml> Irvine, University of California, (2013).

- [3] Myatt, G.J, Making Sence of Data: A Practical Guide to Exploratory Data Analysis and Data Mining, Wiley, (2007). s. 120-129.
- [4] MATLAB R2014a Tutorial, KD Tree Searcher class, [www.mathworks.com/help/stats/](http://www.mathworks.com/help/stats/)
- [5] M.A.Weiss, Data Structures&Algorithm Analysis in C++, Pearson (2013), s 83-85, 614-618, 629.
- [6] Demser J., Statistical Comparisons of Classifiers over Multiple Data Sets, Journal of Machine Learning Research 7, (2006) s 1-30.

Veri seti	1NN	kNN k=5	INC M/k=20/4	kNN-INC karşılaştırma		1NN-INC karşılaştırma	
				%'lik artış	T-Test	%'lik artış	T-Test
abalone	0.2023	0.2301	0.2249	-2.26	loss	11.15	win
anneal	0.9769	0.9584	0.9715	1.36	tie	-0.55	tie
audiology	0.6757	0.6852	0.6556	-4.32	loss	-2.98	loss
autos	0.6505	0.5723	0.6010	5.02	win	-7.61	loss
balnc.-scale	0.7894	0.8576	0.8547	-0.34	tie	8.27	win
breast-cancr	0.6643	0.7098	0.7084	-0.20	tie	6.64	win
breast-w	0.9548	0.9671	0.9557	-1.18	tie	0.09	tie
col10	0.7249	0.7072	0.7168	1.36	tie	-1.12	tie
colic	0.6957	0.7777	0.7380	-5.10	loss	6.09	win
credit-a	0.7901	0.8304	0.8043	-3.14	loss	1.80	tie
credit-g	0.6824	0.7176	0.7116	-0.84	tie	4.28	win
d159	0.9451	0.9404	0.9490	0.92	tie	0.42	tie
diabetes	0.6943	0.7286	0.7143	-1.97	tie	2.88	tie
glass	0.6713	0.6410	0.6644	3.65	win	-1.03	tie
heart-statlog	0.7467	0.8052	0.7785	-3.31	loss	4.26	win
hepatitis	0.7948	0.8361	0.8039	-3.86	loss	1.14	tie
hypothyroid	0.9125	0.9329	0.9289	-0.44	tie	1.79	tie
ionosphere	0.8598	0.8387	0.8701	3.74	win	1.19	tie
iris	0.9467	0.9613	0.9520	-0.97	tie	0.56	tie
kr-vs-kp	0.8891	0.8923	0.9260	3.78	win	4.15	win
labor	0.8732	0.8421	0.8316	-1.25	tie	-4.76	loss
letter	0.9438	0.9343	0.9416	0.78	tie	-0.23	tie
lymph	0.7592	0.7915	0.7859	-0.71	tie	3.52	win
mushroom	1.0000	0.9999	0.9998	-0.01	tie	-0.02	tie
prim.-tumor	0.3874	0.4430	0.4291	-3.14	loss	10.77	win
ringnorm	0.7257	0.6623	0.7354	11.03	win	1.33	win
segment	0.9580	0.9443	0.9539	1.01	tie	-0.43	tie
sick	0.9569	0.9598	0.9562	-0.38	tie	-0.07	tie
sonar	0.8375	0.7481	0.8433	12.72	win	0.69	tie
soybean	0.8916	0.8776	0.8806	0.34	tie	-1.23	tie
splice	0.7357	0.7285	0.7628	4.71	win	3.68	win
vehicle	0.6723	0.6825	0.6752	-1.07	tie	0.43	tie
vote	0.9228	0.9297	0.9264	-0.35	tie	0.39	tie
vowel	0.9473	0.7806	0.8994	15.22	win	-5.05	loss
waveform	0.7278	0.7875	0.7476	-5.06	loss	2.72	win
zoo	0.9987	0.9929	0.9762	-1.68	tie	-2.25	tie

Tablo 2: Algoritmaların 36 veri kümesinde karşılaştırılması



## Adaptif Sinirsel Bulanık Tahmin Yöntemi İle Esnek Üstyapı Performans Tahmin Modeli Geliştirilmesi

Nihat MOROVA<sup>1</sup> Serdal TERZİ<sup>2</sup> Mehmet SALTAN<sup>3</sup>

<sup>1</sup>İnşaat Mühendisliği Bölümü

Teknoloji Fakültesi

Süleyman Demirel Üniversitesi, Çünür, ISPARTA

<sup>2,3</sup>İnşaat Mühendisliği Bölümü

Mühendislik Fakültesi

Süleyman Demirel Üniversitesi, Çünür, ISPARTA

Email: nihatomrova@sdu.edu.tr

serdalterzi@sdu.edu.tr

mehmetsaltan@sdu.edu.tr

### Özet

*Bu çalışmada Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) kullanılarak esnek asfalt üstyapı performans tahmin modeli geliştirilmiştir. ANFIS yöntemi kullanılarak oluşturulan tahmin modelinde üstyapı kalınlığı, yağışlı eşdeğer standart dingil yükü ( $T_{8,2}$ ), maksimum kaplama yüzey sıcaklığı, minimum kaplama yüzey sıcaklığı, maksimum toplam yağış TS, maksimum nem TS, yıllık maksimum ve minimum sıcaklık farklarından maksimum olan sıcaklık farkı tekrar sayısı (YMAXMİNSFMAX SFTS), yıllık maksimum kar örtüsü toplam tekrar sayısı (YMAXKARORTTS) değerleri kullanılarak Düzgünsüzlük İndeksi (m/km) ( IRI / International Roughness Index ) tahmin edilmiştir. Oluşturulan model çıktuları ile gerçek veriler karşılaştırılmış ve aralarındaki korelasyonun oldukça iyi olduğu ( $R^2=0,7021$ ) ANFIS yöntemiyle üstyapı performans tahmini yapılabileceği görülmüştür.*

### 1. Giriş

Üstyapı Yönetim Sistemi çalışmasının en önemli parametrelerinden birisi performans tahmin modeli geliştirilmesidir. Üstyapı kaplama performansı, zamana karşı yolun trafiğe hizmet verebilme kabiliyetini göstermektedir. Genellikle kaplamanın durum ve performansının niceliğini belirlemede objektif ölçüm yapabilen yöntemler kullanılmaktadır. Objektif ölçüm yöntemleri ile kaplamanın; düzgünsüzlüğü, kayma direnci, yüzey bozulmaları ve

dayanımı belirlenmektedir. Bu yöntemler aşağıdaki kararların alınmasında yardımcı olmaktadır.

1. Bakım öncelikli yolların saptanması; performans verilerine göre bakım-onarım ihtiyacı duyulan kesimlerin belirlenerek öncelik sıralamasının yapılması,
2. Bakım-onarım stratejilerinin tespiti; Yol yüzey verilerine göre en uygun yöntemin (yama, takviye, bitümlü sathi kaplama yapımı, asfaltın kazılıp tekrar kullanılması, vb.) seçilmesi,
3. Kaplama performansının ön tahmini; Mevcut verilerden faydalanarak yol ağı için ayrılan mevcut bütçenin en iyi şekilde kullanılması veya gelecek için uzun vadeli bütçenin hazırlanması.

Üstyapı düzgünsüzlüğü aracın sürüş kalitesine etki eden kaplama yüzeyindeki bozuklukların göstergesidir. Düzgünsüzlük; sürüş kalitesini, araç işletme maliyetlerini, yakıt tüketimini ve yol yapım harcamalarını etkileyen önemli bir yol yüzey karakteristiğidir. Uluslararası Düzgünsüzlük İndeksi (IRI/International Roughness Index) ile ifade edilir. 1980'lerde Dünya Bankası tarafından geliştirilen IRI, düzgünsüzlük miktarını belirtir. IRI değerleri profilometre ölçüm cihazı ile ölçülür. Birimi m/km'dir. Saatte 80 km hızla giden van tipi bir aracın ön kısmına yerleştirilen infrared veya lazer sensörler ile yol yüzey verileri toplanır. Sensörler araç içinde bulunan özel ölçüm programı içeren bilgisayara

bağlantılıdır. Sensörlerden alınan analog veriler bilgisayarda dijital verilere dönüştürülerek ölçüm esnasında ekranda görüntülenir. İsteğe bağlı olarak seçilen (minimum 25 mm-maksimum 150 mm ) aralıklarla alınan yol yüzey bilgileri sisteme kaydedilerek ölçüm sonrası istenilen bilgilerin çıkmasını sağlayan bilgisayar programları ile analiz edilerek raporlanır.

Profilometre ölçüm aracı ile ölçülen IRI değerleri yolun boyuna profil ölçümüdür. Üstyapının servis kabiliyeti endeksi büyük oranda boyuna profile bağlıdır. Boyuna profil sonucu yolun düzgünlüğü belirlenir.

Yol yüzey düzgünlüğüne göre yolların durumu aşağıda verilen Tablo 1'deki IRI değerleri doğrultusunda sınıflandırılmış ve bu sınıflandırmalara karşılık gelen bakım-onarımda öncelik sıralaması verilmiştir.

Tablo 1. IRI değerleri ve bakım-onarımda öncelik sıralaması

Düzensüklük Değeri (IRI-m/km)	Düzensüzlük Sınıflaması	Bakım-Onarım Öncelik Sıralaması	Kaplamanın IRI Değerlerine Göre Yapılması Gerekenler
0 - 0,71	Çok İyi	6	Yeni veya yeni sayılabilen kaplama; bir süre için iyileştirmeye ihtiyaç duymaz.
0,72 - 1,11	İyi	5	İyi durumdaki kaplama; yakın gelecekte iyileştirmeye ihtiyaç duymaz.
1,12 - 1,58	Orta-İyi	4	Trafiğe bağlı olarak yakın gelecekte iyileştirmeye ihtiyaç duyacaktır.
1,59 - 1,80	Orta	3	Mevcut kullanılabilirliğini sürdürebilmek için yakında onarım gerektirir.
1,81 - 2,13	Kötü	2	Eski hizmet kabiliyetini geri kazanabilmesi için hemen iyileştirme gerekir.
> 2,13	Çok Kötü	1	-

IRI değerleri 0'da mükemmeldir. IRI değeri 0'a yaklaştıkça yolun sürüş konforunun iyi, IRI değeri 0'dan uzaklaştıkça yolun sürüş konforunun kötü olduğu ve yol yüzey düzgünlüğünün arttığı görülür. Yeni yapılan yol kesimlerinin 0 – 1.11 IRI değerlerine sahip olması gerekmektedir.

Performans tahmini için literatürde regresyon modeli en çok kullanılan yöntemdir. Fakat son yıllarda bilgisayar teknolojisindeki gelişmelerle birlikte yapay zekâ teknikleri de bu amaçla kullanılmaya başlanmıştır.

Yapay zekâ teknolojisi 1950'lerde gelişmeye başlamış, 1970'lerden sonra önemi artmış ve 1990 larda bilim haline gelmiştir. Bu teknoloji insan zekâsının çalışma prensiplerini kopyalamak ve onu taklit etmek şeklinde tanımlanabilir. Pek çok bilim dalında uygulama sahası bulmuştur [1].

Bu çalışmada, esnek üstyapı performans tahmini için bir ANFIS tahmin modeli geliştirilmiştir.

## 2. Adaptif sinir ağına dayalı bulanık çıkarım sistemi (ANFIS)

Neuro-fuzzy ağları, bulanık sistemlerin dilsel bilgi sunumu ile sinir ağlarının öğrenme gücünü birleştiren modelleme teknikleridir.


ANFIS, öğrenme ve adaptasyon işlemlerini kolaylaştırmak için, adaptif sistemlerden yararlanan bulanık Sugeno modelidir. Böyle bir yaklaşım bulanık mantığı daha sistematik ve tecrübeye daha az bağlı hale getirmektedir.

Aşağıda verilen iki bulanık kurala bağlı olarak 1. derece bulanık Sugeno modeli için olası ANFIS mimarisi Şekil 1'de verilmiştir.

Kural 1: Eğer  $x$  is  $A_1$  and  $y$  is  $B_1$ , ise  $f_1 = (p_1x + q_1y + r_1)$

Kural 2: Eğer  $x$  is  $A_2$  and  $y$  is  $B_2$ , ise  $f_2 = (p_2x + q_2y + r_2)$

Bu kurallarda  $p_i$ ,  $q_i$  ve  $r_i$  her bir kural için, denklem sabitleridir.



Şekil 1. ANFIS mimarisi [3]

Şekilden görüleceği gibi ANFIS, beş tabakalı ileri beslemeli bir yapay sinir ağı mimarisine sahiptir. Bu mimari için öğrenme algoritmasının temel görevi, ANFIS çıktısı ile öğrenme verilerini benzetmek için tüm uyarlanabilir parametreleri ayarlamaktır. Eğitim veri seti, sinir ağına tanıtılır ve herhangi bir eğitim algoritması yardımıyla ağ eğitilir. Model çıktısı ile öğrenme verileri arasındaki hata fonksiyonun minimum olduğu şartların belirlenmesi hedeflenir (Uzundurukan, 2006).

1. tabakadaki hücreler, adaptif (uyarlanabilir) hücrelerdir ve hücre sayısı girdi değişkeni sayısına eşittir. Bu tabakadaki hücrelerin çıktıları ( $O_{1i}$ ) için Eşitlik 1 ve 2'de verilmektedir (Jang vd., 1997).

$$O_{1i}^1 = \mu_{A_i}(x) \quad i = 1, 2 \quad (1)$$

$$O_{1i}^1 = \mu_{B_{i-2}}(y) \quad i = 3, 4 \quad (2)$$

Burada,  $A_i$  ve  $B_i$  herhangi bir bulanık küme parametresi,  $A_i \mu$  ve  $B_i \mu$  bu küme parametreleri için üyelik dereceleridir. Çan eğrisi şeklinde üyelik fonksiyonu kullanıldığında,  $A_i \mu$  için aşağıdaki eşitlik verilebilir.

$$\mu_{A_i} = \frac{1}{1 + \left[ \frac{(x-c_i)^2}{a_i} \right]} b_i \quad i = 1, 2 \quad (3)$$

Burada,  $a_i$ ,  $b_i$  ve  $c_i$  sırasıyla, çan eğrisi şekilli üyelik fonksiyonun sigması, eğimi ve merkezidir.

2. tabakadaki hücreler sabittir ve hücre sayısı kural sayısına eşittir. Hücre girdileri, kuralların öncül kısmındaki değişkenlerin üyelik fonksiyonu değerleridir ve hücre çıktıları ( $O_{2i}$ ) kuralların ağırlık derecelerini ( $W_i$ ) vermektedir.

$$W_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2 \quad (4)$$

3. tabakadaki hücreler de sabit hücrelerdir, girdileri önceki tabakadan aldıkları ağırlık derecelerdir. Bu tabakada ağırlık dereceleri normalize edilir.

$$W_i = W_i / \left( \frac{W_1}{W_2} \right) \quad i = 1, 2 \quad (5)$$

4. tabakadaki hücreler adaptif hücrelerdir ve bu hücrelerin çıktısı eşitlik 6'daki şekilde hesaplanır.

$$O_{2i}^4 = \bar{W}_i f_i = W_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (6)$$

Burada  $p_i$ ,  $q_i$  ve  $r_i$  model parametreleridir.

5. tabakada çıktı elde edilir. Bu tabaka basit toplama fonksiyonu olarak çalışmaktadır.

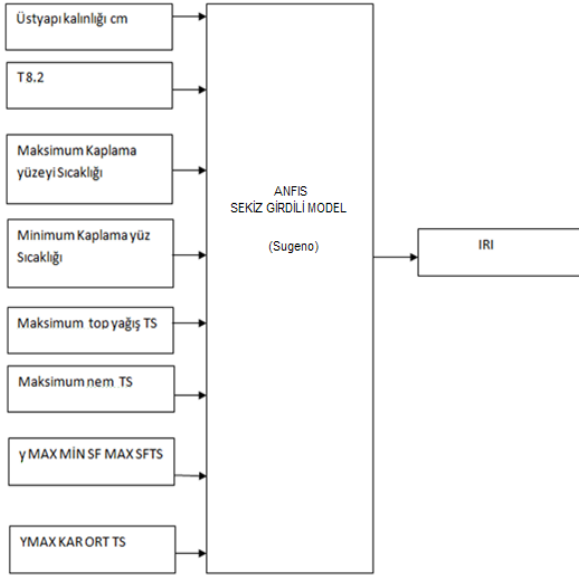
$$O_{2i}^5 = \sum_i W_i f_i = \frac{\sum_i W_i f_i}{\sum_i W_i} \quad i = 1, 2 \quad (7)$$

Bu çalışmada ANFIS analizleri, MATLAB R2010a Fuzzy Logic Toolbox programı kullanılarak yapılmıştır.

### 3. Geliştirilen ANFIS modeli


Performans tahmini amacıyla hibrit yöntemlerden biri olan ve Bulanık Mantık (BM) yöntemi ile Yapay Sinir Ağları (YSA) yöntemlerinin birlikte çalıştığı Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) kullanılmıştır. ANFIS, Sugeno tipindeki bir modele dayalı olarak işlem yapan adaptif ağ yapılı bir bulanık sonuç çıkarım yöntemidir. Yöntemin esası, belirli bir giriş-çıkış veri kümesinden yararlanılarak uygun bulanık kural kümesinin ortaya konulması ve adaptif özellikli bir ağ yapısı vasıtasıyla sistem parametrelerinin sistematik olarak ayarlanmasına dayanır.

Geliştirilen modelde sekiz (üstü yapı kalınlığı,  $T_{8,2}$ , maksimum kaplama yüzey sıcaklığı, minimum kaplama yüzey sıcaklığı, maksimum toplam yağış TS, maksimum nem TS, YMAX MİN SF MAX SFTS, YMAX KAR ORT TS) girdi parametresi kullanılarak IRI değeri tahmin edilmeye çalışılmıştır. Geliştirilen modelin mimarisi Şekil 2'de görülmektedir. Bu kapsamda Hergüner (2009)'dan elde edilen Karayolları Genel Müdürlüğü'nün (KGM) otoyollarından topladığı verilerdir.




Şekil 2. Geliştirilen modelin mimarisi


ANFIS yöntemi ile yapılan modellemede elde edilen üyelik fonksiyonları Şekil 3, 4, 5, 6, 7, 8, 9, 10 ve 11’de görülmektedir.




Şekil 3. Üstyapı kalınlığı girdisine ait üyelik fonksiyonu




Şekil 4. T8.2 girdisine ait üyelik fonksiyonu




Şekil 5. Maksimum kaplama yüzeyi sıcaklığı girdisine ait üyelik fonksiyonu




Şekil 6. Minimum kaplama yüzeyi sıcaklığı girdisine ait üyelik fonksiyonu




Şekil 7. Maksimum toplam sıcaklık girdisine ait üyelik fonksiyonu




Şekil 8. Maksimum nem TS girdisine ait üyelik fonksiyonu



Şekil 9. YMAX MİN SF MAX SFTS girdisine ait üyelik fonksiyonu



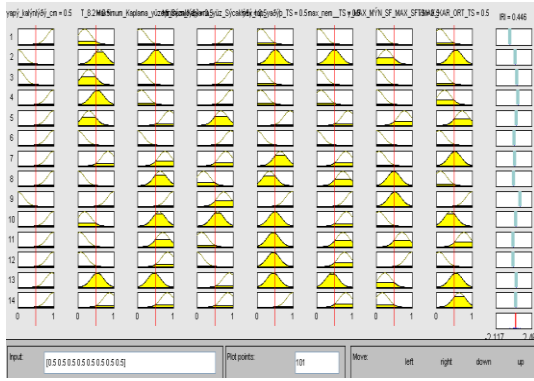
Şekil 10. YMAX KAR ORT TS girdisine ait üyelik fonksiyonu




Şekil 11. IRI çıktısına ait üyelik fonksiyonu

#### 4. Araştırma Bulguları

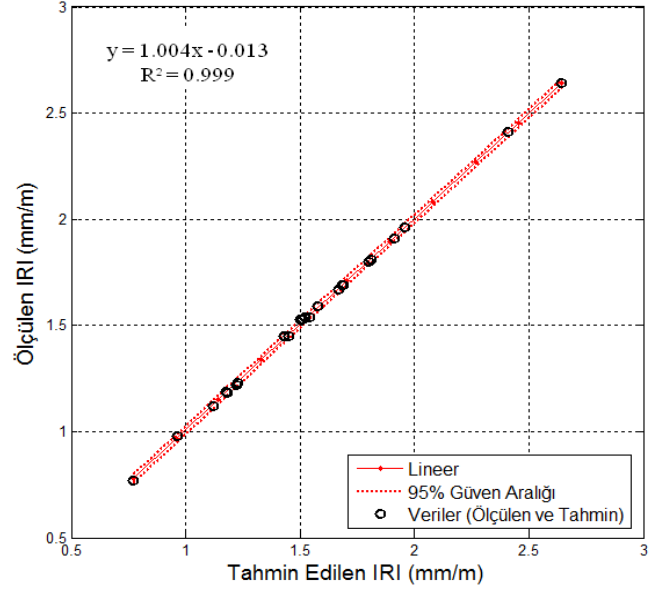
Şekil 12'de örnek bir çözüm ekranı görülmektedir. Şekil 13'te eğitim seti amaçlanan ve bulunan değerlerin dağılımı, Şekil 14'te ise eğitim seti için amaçlanan değerler ile tahmin edilen değerler arasındaki ilişki grafiği görülmektedir. Benzer olarak Şekil 15'te eğitim seti için amaçlanan ve bulunan değerlerin dağılımı verilmiştir. Şekil 16'da ise test seti için amaçlanan değerler ile tahmin edilen değerler arasındaki ilişki grafiği görülmektedir. Şekilde mavi daireler gerçek değerleri, kırmızı yıldızlar ise tahmin edilen değerleri göstermektedir.




Şekil 12. Çözüm ekranı




Şekil 13. Eğitim seti amaçlanan ve bulunan değerlerin dağılımı



Şekil 14. Amaçlanan değerler ile tahmin edilen değerler arasındaki ilişki



Şekil 15. Test seti amaçlanan ve bulunan değerlerin dağılımı



Şekil 16. Amaçlanan değerler ile tahmin edilen değerler arasındaki ilişki

Geliştirilen ANFIS modellerinin eğitim ve test kümeleri için hesaplanan  $R^2$ , RMSE ve SEE değerleri Tablo 2’de verilmiştir.

Tablo 2. ANFIS ile IRI tahminine ait istatistikler

İstatistik	$R^2$	SSE	RMSE
Eğitim Seti	0,999	0,00198	0,009083
Test Seti	0,7021	0,2366	0,2175

ANFIS ile geliştirilen sekiz girdili birinci modele ait  $R^2$  değerleri eğitim ve test seti için sırasıyla 0,999 ve 0,702 olarak belirlenmiştir.

## 5. Sonuçlar

Bu çalışmada Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) metodu kullanılarak asfalt üstyapı performans tahmin modeli geliştirilmiştir. Bu kapsamda Hergüner (2009)’dan elde edilen Karayolları Genel Müdürlüğü’nün (KGM) otoyollarından topladığı verilerdir. Çalışmada üstyapı kalınlığı, yığılımlı eşdeğer standart dingil yükü, maksimum kaplama yüzey sıcaklığı, minimum kaplama yüzey sıcaklığı, maksimum toplam yağış tekrar sayısı, maksimum nem tekrar sayısı, yıllık maksimum ve minimum sıcaklık farklarından maksimum olan sıcaklık farkı tekrar sayısı, yıllık maksimum kar örtüsü toplam tekrar sayısı ve IRI parametreleri kullanılmıştır. Performans tahmin modeli geliştirilirken performans göstergesi olarak IRI değeri seçilmiştir.

Geliştirilen ANFIS modeli ile gerçek değerlere ait sonuçlar karşılaştırılmış ve modelin güvenilirliği test edilmiştir. Yapılan karşılaştırmada geliştirilen model ile gerçek değerler kullanılarak bulunan sonuçların tahmin edilebildiği ve ayrıca geliştirilen model kullanılarak gerçek değerlere ulaşamaması durumlarında üstyapı performansının tahmin edilebileceği belirlenmiştir. Ayrıca bu çalışmanın Performans tahminine etki eden diğer parametrelerin de kullanılarak oluşturulacak yeni modellerin geliştirilmesine örnek teşkil edeceği düşünülmektedir.

## 5. Teşekkür

Bu çalışma TÜBİTAK 1001 projesi, Proje No: 108M052, Süleyman Demirel Üniversitesi Bilimsel Araştırma Projeleri Birimi (BAP) Proje No: 3122-D-12 projelerinin sağladığı destekle tamamlanmış olup

yazarlar TÜBİTAK ve Süleyman Demirel Üniversitesine teşekkürü bir borç bilirler.

## 6. Kaynaklar

- [1] S. Terzi, N. Morova, M. Kardeşahin, “Bulanık Mantık Metodu ile Asfalt Üstyapı Performans Tahmin Modeli Geliştirilmesi”, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu, 2010.
- [2] S. Tuzcuoğlu, “Yapay Zeka Teknikleri Depremde Kullanılması Ve Küme Kuramları”, D.Ü. mühendislik fakültesi fen ve mühendislik bilimleri dergisi, cilt 5, sayı 1, syf 73-78, 2003.
- [3] J.S.R., Jang, 1993. ANFIS: adaptive-network-based fuzzy inference system, IEEE Trans. Syst. Man Cybern. 23(3), 665–685.
- [4] S. Uzundurukan, “Zeminlerin Şişme Özelliklerine Etkiyen Temel Parametrelerin Belirlenmesi ve Modellenmesi”, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 185s. Isparta. 2006.
- [5] R.J.-S., Jang, C.T. Sun and E. Mizutani. “Neuro-Fuzzy and Soft Computing; Computational Approach to Learning and Machine Intelligence”. Prentice Hall, 1997.
- [6] Hergüner, A.T., 2009. Türkiye Otoyol Ağı İçin Üstyapı Yönetim Sistemi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 239s. İstanbul.

# Mobilya Üretim Tesisinde Genetik Algoritma ile Makine Düzenleme

Ali KANDEMİR<sup>1</sup> Rembiye KANDEMİR<sup>2</sup>

<sup>1</sup>Endüstri Mühendisliği Bölümü  
Mühendislik Fakültesi  
Kırklareli Üniversitesi, KIRKLARELİ  
<sup>2</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
Trakya Üniversitesi, EDİRNE

Email: ali.kandemir@klu.edu.tr

rembiyeg@trakya.edu.tr

## Özet

*Tesis düzenleme, üretim sisteminin verimliliği üzerinde önemli bir etkiye sahiptir. İyi yapılan bir düzenleme üretim sisteminin verimliliğini yükseltir ve işletmenin rekabet gücünü artırır. Mobilya üretiminin yapıldığı tesislerde çok farklı ürünlerin ve farklı işlem rotaların olması bu tesislerde düzenlemeyi daha önemli hale getirmektedir. Bu çalışmada, mobilya üretimi yapan bir tesiste sezgisel yaklaşımlardan biri olan genetik algoritma kullanılarak mevcut sistemde toplam taşıma mesafesinin azaltılmasına yönelik bir makine düzenleme işlemi yapılmıştır. Düzenleme işlemi için fabrikada en fazla üretilen ürünler ve bu ürünlerin üretilmesinde kullanılan makineler ve iş istasyonları veri olarak kullanılmıştır. Geliştirilen uygulama ile mevcut toplam taşıma mesafesinde %17.6 kadar bir azalma sağlanmıştır.*

## 1. Giriş

Günümüzde, ticari rekabet ortamındaki işletmeler, her türlü araç ve yöntemi kullanarak kaliteden ödün vermeden maliyetlerini minimize etmeye çalışmaktadırlar. En küçük atölyeden uluslararası büyük sanayi kuruluşlarına kadar başarılı işletmelere bakıldığında; tamamının, yapacakları işin büyüklüğü ve niteliğine göre bir tesis kurma; bu tesise en uygun şekilde yerleşim sağlama; bu yerleşimi değişen şartlara göre sürekli yenileme konusunda özel bir çaba içinde olduğu gözlenmektedir.

Karmaşık ve NP-zor olan tesis düzenleme problemi [1] üretim sektöründe başarılı bir şekilde yapılması durumunda işletmenin toplam giderlerinde %50'ye, toplam taşıma maliyetlerinde de %30'a varan bir azalma sağlayabileceği vurgulanmaktadır [2]

Ürün ve hizmet üreten işletmelerde tesisin yerleştirilmesi konusu verimlilik ve giderler üzerinde etkin olan temel faktörlerden birisi olmasından dolayı uzun zamandır üzerinde çalışılan önemli

konulardan birisi olmuştur. Yapılan çalışmalar uygulama ve deneysel olarak sürdürülmektedir. Elde edilen çalışma sonuçlarına dayalı olarak da farklı alanlara göre daha uygun olan metotlar önerilmektedir.

Tesis yerleşimi problemi, bazı durumlarda tüm çözüm alternatiflerinin denenemeyeceği sayıda alternatif çözüme sahip olduğundan dolayı, son yıllarda bu alanda tüm alternatif çözümleri değil, olası en uygun çözümleri arayan sezgisel yöntemler öne çıkmaktadır. Bu yöntemlerden birisi de genetik algoritmalarıdır. Düzenleme alanında yapılan çalışmalardan bazıları şunlardır: Suresh, Vinod, ve Sahu [3] kuadratik atama problemine dayalı bir tesis düzenleme için GA uygulaması yapmışlar ve düzenlemede etkin kullanılabileceğini vurgulamışlardır. Rajasekharan, Peters, ve Yang [4] karmaşık bir tamsayı programlamaya dayalı esnek üretim sistemlerin düzenlemesini optimize etmeye yönelik bir GA uygulaması üzerinde çalışmışlardır. Mak, Wong, ve Ghan [5] bir üretim tesisinde tesisin düzenlenmesi için bir genetik algoritma uygulaması yapmışlar, bunu atelye üretim ortamında malzemenin akışı ve makinein düzenleme şekli bakımından bir matematik modelle değerlendirmişlerdir. Tavakkoli-Moghaddain ve Shayan [6] genetik algoritmayı tesis alanlarının eşit ve eşit olmadığı durumlar için kuadratik atama probleminin çözümü için uygulamışlardır. Lee, Han, ve Roh [7] genetik algoritma tesis içindeki duvarları ve boşlukları dikkate alarak bir düzenleme çalışması yapmışlardır. El-Baz [8] farklı malzeme akışlarının yer aldığı üretim sistemlerinde malzeme taşıma maliyetini en azlayan bir düzenlemeyi gerçekleştirmek için genetik algoritmayı kullanmışlardır. Lee, Roh, ve Jeong [9] çok katlı bir tesisin düzenlenmesinde duvar ve boşlukları baz alan çalışmada genetik algoritmayı kullanmışlardır.

Bu çalışmada mevcut bir mobilya üretim tesisinde genetik algoritma kullanılarak toplam malzeme taşıma mesafesini azaltacak düzeleme ele alınmıştır.

## 2. Tesis Yerleşim Problemi

Tesis yerleşim problemi (TYP) uzun bir araştırma geçmişine sahiptir. Yerleşim problemi Koopmans ve Beckmann tarafından 1957 yılında Kuadratik atama problemi (KAP) olarak önerilmiştir [10].Düzenleme işleminde, ürünlerin ve hizmetlerin üretilebilmesi için ihtiyaç duyulan herşeyin gerekli yerlere uygun bir şekilde konulması ele alınır. Düzenleme ile ilgili çalışmalarda toplam taşıma mesafesinin azaltılması konusunun daha çok ön plana çıktığı görülmektedir. Düzenlenmenin belirlenmesinde farklı faktörler olmasına rağmen, üretilen ürünlerin çeşitliliği ve miktarları belirleyici olmaktadır. Bu iki temel faktörün şekillendirdiği düzenleme şekilleri; sabit ürüne göre düzenleme, prosese göre düzenleme, ürüne göre düzenleme ve hücresele düzenlemedir[11]

Mobilya üretiminin yapıldığı tesislerde ürün çeşitliliği fazladır. Bu ürünlerin üretilmesi farklı işlem rotalarını gerektirir. Bu da üretim esnasında gereksiz taşımaları azaltarak taşıma mesafelerini kısaltma gibi önemli bir düzenleme problemini ortaya çıkarır. Bu çalışmada mevcut bir mobilya üretim tesisinde en çok üretilen sekiz ürün ve bu ürünlerin üretimi için kullanılan makineler düzenleme işlemi için kullanılmıştır. Ürünlerin üretiminde kullanılan makineler ve iş istasyonları Tablo 1 de verilmiştir. Üretilen ürünleri oluşturan parçalarının izlediği makine ve iş istasyonlarına bağlı olarak elde edilen makineler arası taşıma matrisi de Tablo 2 de verilmiştir.

Table 1. Makine ve iş istasyonları

Sıra No	Makine ve iş istasyonları
1	Boyahane
2	Boyutlandırma (CNC)
3	CNC Makinesi
4	Postforming
5	Daire Testere Makinesi
6	Delik Makinesi
7	Pres
8	Tutkallama Makinesi
9	Zımpara Makinesi
10	Freze Makinesi
11	Temizleme Makinesi
12	Kenar Bantlama Makinesi
13	Menteşe Makinesi
14	Montaj

Mevcut yerleştirmede yer alan makine konumları dikkate alınarak merkezler arası uzaklıklar doğrusal mesafe değerine göre hesaplanmış ve Tablo 3'te verilmiştir. Bu veriler kullanılarak genetik algoritma ile toplam taşıma mesafesini azaltmaya yönelik çözüm alternatifleri aranmıştır. Makine ve iş istasyonu olarak konumlarının değiştirilmesi ihtiyaç duydukları alan bakımında büyük ve değiştirilmelerinde sorun oluşan toplam dört bölüm

yerleştirmede ilk dört konuma yerleştirilmiş ve bu konumlar çözüm araştırması sürecinde sabit tutulmuştur.

Tablo 2: Makineler arası taşıma matrisi

From/To	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	-													
2		-	18		1	8		4	5	23				
3			-		15	17				4			1	2
4				-	6		6							
5					-	3	3			1				
6						-				2	1			3
7							-	10		1				
8								-	4	2				
9									-	5				
10										-	2	4		
11											-	4		
12												-		
13													-	
14														-

Tablo 3. Yerleşim merkezleri arası mesafeler (metre)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.0	12.5	38.5	54.5	50.0	50.5	37.5	35.0	24.0	33.0	31.0	36.0	60.5	56.0
2		0.0	26.0	46.0	41.5	38.0	29.0	26.5	15.5	20.5	18.5	23.5	48.0	43.5
3			0.0	22.0	17.5	12.0	14.0	21.5	22.5	43.5	15.5	12.5	22.0	17.5
4				0.0	8.5	13.0	17.0	20.5	30.5	65.5	37.5	34.5	23.0	22.5
5					0.0	6.5	21.5	29.0	30.0	61.0	33.0	30.0	14.5	18.0
6						0.0	26.0	33.5	34.5	54.5	26.5	23.5	10.0	11.5
7							0.0	7.5	13.5	48.5	20.5	17.5	36.0	31.5
8								0.0	11.0	46.0	18.0	19.0	43.5	39.0
9									0.0	35.0	15.0	20.0	44.5	40.0
10										0.0	28.0	31.0	49.5	43.0
11											0.0	5.0	29.5	25.0
12												0.0	24.5	20.0
13													0.0	6.5
14														0.0

## 3. Genetik Algoritma

Genetik Algoritmalar (GA) arama ve optimizasyon problemlerinde çözüm olarak uyarlanabilecek yöntemlerdir. Bu algoritmalar doğadaki organizmaların genetik işlemlerini taklit eden yapılarıdır [6,12]. İlk kez Charles Darwin'in "The Origin of Species" kitabında belirttiği gibi, doğal popülasyonlar "en güçlüünün hayatta kalması" prensibine göre evrimleşirler. Bu durumdan hareketle, GA doğru bir şekilde modellenip, kodlandığı takdirde gerçek hayat problemlerine çözüm üretecek şekilde evrilebilirler [13]. Doğal davranışların doğrudan bir analogisi olan GA prensipleri ilk kez Holland tarafından ortaya konulmuştur [14].

GA doğada geçerli olan en iyinin yaşaması kuralına dayanarak sürekli iyileşen çözümler ürettiği için problemlerde "iyi"nin ne olduğunu belirleyen bir uygunluk (fitness) fonksiyonu ve yeni çözümler üretmek için yeniden kopyalama (recombination),



çaprazlama (crossover), değiştirme (mutation) gibi operatörleri kullanır. GA problemlere tek bir çözüm üretmek yerine farklı çözümlerden oluşan bir çözüm kümesi (popülasyon) üretir. İzlenen bu yolla arama uzayında aynı anda birçok nokta değerlendirilmekte ve sonuçta bütünsel çözüme ulaşma olasılığı yükselmektedir.

GA da genlerin oluşturduğu topluluk kromozom, kromozomların oluşturduğu topluluk popülasyon olarak ifade edilir. Kromozomun yapısı;

$$Kromozom = G_i = G_1 G_2 \dots G_n$$

şeklinde tanımlanmaktadır. Burada  $G_i$ ,  $i = 1, 2, \dots, n$  genleri göstermektedir.  $i$  değeri genin konumu (lokus) dur. Bir kromozomun uzunluğu ( $n$ ) genellikle sabit tutulur. Kromozomlar, 0-1 sayı dizisi veya harf dizisi (permütasyon kodlama) şeklinde kodlanabileceği gibi reel kodlama da kullanılabilir. Gösterim türünün seçimi çoğu zaman, problemin yapısına ve kullanılacak algoritmanın ayrıntılarına bağlıdır.

Bu çalışmada kromozomların gösterimi harf kodlaması ile yapılmıştır. Her makine bir harfle ifade edilmektedir, örneğin;  $A_1 B_2 C_3 D_4 E_5 \dots N_n$  olası durumlardan biridir. Kromozom dizisindeki diziliş ise makinelerin konumlarını göstermektedir. Sırası ile  $A$  makinesi 1. konum,  $B$  makinesi 2. konum,  $\dots, N$  makinesi  $n$ . konum yerini ifade eder. Değerlendirme için kullanılan uygunluk fonksiyonu denklem (1) ile ifade edilmektedir.

$$\min T = \sum_{i=1}^n \sum_{j=1}^n m_{ij} t_{ij} \quad (1)$$

Denklemden;  $T$  toplam taşıma mesafesini,  $m_{ij}$   $i$  bölümünden  $j$  bölümüne taşıma mesafesi,  $t_{ij}$   $i$  bölümünden  $j$  bölümüne yapılan taşıma miktarını ifade etmektedir.

Çalışmada, başlangıç popülasyonunun tamamı rastgele üretilmiş ve popülasyon sayısı 10 olarak seçilmiştir. Birey seçimi, *Sabit Durum Seçimi* ve *Elitizm* yöntemine göre yapılmıştır. Bir sonraki nesilde yeni popülasyonu elde etmek için kromozomlar küçükten büyüğe doğru sıralanmış ve belirlenen üç farklı oranı (%10, %20 ve %30) kadar popülasyondaki zayıf olan kromozomlar elimine edilmiş, geriye kalan bireyler yeni popülasyona değiştirilmeden aktarılmıştır. Popülasyon sayısını tamamlamak için en iyilerin içinden rasgele seçilen bireyler eşleştirilir, çaprazlama ve mutasyon işlemi uygulayarak yeni bireyler üretilir.

Çaprazlama işlemi iki ebeveyninden gelen bilgileri harmanlar ve yeni çocuklar üretir. Geleneksel olarak GA modellerinde, standart çaprazlama; tek nokta, iki nokta ve tek biçimli (uniform) olarak kullanılır [14].

Fakat bu operatörler sıralı permütasyon problemlerinde hatalı kromozomlar üretirler, bu nedenle bunların yerine PMX (partially matched crossover), OX (order crossover), CX (cycle crossover) gibi operatörler kullanılmıştır [15] Çalışmada kullanılan çaprazlama tekniği olarak Davis tarafından önerilen iki noktalı OX-Sıralı Çaprazlama operatörü kullanılmıştır.

GA da mutasyon kullanımının amacı, optimum çözümü bulmaya çalışırken popülasyondaki kromozom çeşitliliğini sağlayarak arama uzayını yaymak ve genişletmektir. Permütasyon kodlamada çaprazlama işleminde olduğu gibi mutasyonda da çeşitli teknikler geliştirilmiştir. Bu çalışmada, ters çevirme (inversion) ve karşılıklı değişim (exchange) olarak iki farklı mutasyon tekniği kullanılmıştır.

#### 4. Bulgular ve Sonuç


Çalışmada popülasyon sayısı 10, iterasyon sayısı 5000, OX çaprazlama tekniği ve iki farklı mutasyon (ters çevirme ve karşılıklı değişim) ve elitizm için %90, %80 ve %70 kriterleri uygulanarak her bir mutasyon için 100 ayrı deneme çözümü üretilmiştir. Farklı elitizm oranı ve farklı mutasyonlara bağlı olarak elde edilen veriler Tablo 4'te toplu olarak verilmiştir. Her denemede elde edilen en iyi sonuç verilerinden oluşan grafikler Şekil 1, Şekil 2 ve Şekil 3'te verilmiştir.

Tablo 4. Farklı mutasyon ve elitizime bağlı veriler


Pop.Sayısı : 10		Çaprazlama : OX			
		Elitizm	%90	%80	%70
Mutasyon Değişim	Ortalama Değer (m)	3154.4	3148.2	3160.8	
	İyileşme %	16.4	16.6	16.2	
	En Düşük Değer (m)	3111	3111	3111	
	En Yüksek Değer (m)	3210	3270	3292	
	En düşük Değer Sayısı	4	29	29	
Mutasyon Ters	Ortalama Değer (m)	3162.6	3167.2	3157.9	
	İyileşme %	16.2	16.1	16.3	
	En Düşük Değer (m)	3111	3111	3111	
	En Yüksek Değer (m)	3276	3267	3270	
	En düşük Değer Sayısı	25	17	28	

Mobilya tesisindeki mevcut yerleştirmeye (ABCDEFGHIJKLMN) göre çalışma için seçilen ürünlerin toplam taşıma mesafesi 3773.5 metre olarak hesaplanmıştır. Tablo 4'teki veriler değerlendirildiğinde elde edilen verilerin ortalaması açısından karşılıklı-değişim mutasyonu en iyi değer ile %80 elitizmde elde edilmiştir.


Her iki mutasyon tekniği için %70 elitizm en düşük değeri bulma yönünden daha başarılı gözükmektedir.



Şekil 1. Elitizm %90 için en iyi sonuçlar



Şekil 2. Elitizm %80 için en iyi sonuçlar



Şekil 3. Elitizm %70 için en iyi sonuçlar

Yapılan çalışma ile mevcut duruma göre, her iki mutasyon tekniği için %16.1 ile %16.6 arasında toplam taşımada azalma sağlanabilmektedir. Bulunan en düşük değere (3111 metre) göre *ABCDNEGHIJFKL* yerleşimi ile toplam

taşımada %17.6 azalma elde edilmektedir. Bu sonuç bir işletme açısından önemli bir kazanımdır.

## 5. Kaynaklar

- [1] M.R. Garey, ve D.S. Johnson, Computers and intractability: A guide to the theory of NP-completeness, New York: WH Freeman,1979.
- [2] J.A. Tompkins, J.A. White, Facilities planning, 2nd edn. New York, John Wiley, 1996.
- [3] G. Suresh, V.V. Vinod, ve S. Sahu, A genetic algorithm for facility layout International Journal of Production. Research **33** (12), 1995, 3411-3423.
- [4] M. Rajasekharan, B.A. Petersand, T. Yang, A genetic algorithm for facility layout design in flexible manufacturing systems, International Journal of Production Research **36** (1), 1998, 95-110.
- [5] K.L. Mak, Y.S. Wong, ve F.T.S. Chan, A genetic algorithm for facility layout problems, Computer Integrated Manufacturing Systems **11** (1-2), 1998,113-127
- [6] R. Tavakkoli-Moghaddain, ve E. Shayan, Facilities layout design by genetic Algorithms, Computers & Industrial Engineering **35** (3-4), 1998, 527-530.
- [7] K.Y. Lee, S.N. Han, ve M.I. Roh, An improved genetic algorithm for facility layout problems having inner structure walls and passages, Computers and Operations Research, **30**, 2003, 117-138.
- [8] M.A. El-Baz, A genetic algorithm for facility layout problems of different manufacturing environments, Computers & Industrial Engineering **47**, 2004, 233-246
- [9] K.Y. Lee, M.I. Roh, ve H.S. Jeong, An improved genetic algorithm for multi-floor facility layout problems having inner structure walls and passages, Computers & Operations Research, **32**(4), 2005, 879-899.
- [10] T.C. Koopmans, ve M. Beckmann Assignment problems and the location of economic activities, Econometrica, Vol. 25, 1957.
- [11] S.S. Heragu, Facilities design. Boston: BWS, 1997
- [12] Y. Zhang, X. Zhu, Y. Luo, Applying genetic algorithms to task planning of multi-agent systems, International Conference on Computer and Industrial Engineering, 1997, 411-414.
- [13] D. Beasley, D.R. Bull, ve R.R. Martin, An Overview of Genetic Algorithms: Part 1, Fundamentals, University Computing, 1993a
- [14] J.H. Holland, Adaptation in Natural and Artical Systems, MIT Press, 1975
- [15] D.E. Goldberg, Genetic algorithms in search, optimisation, and machine learning, Addison-Wesley Publishin, 1989.

## Yapay Sinir Ağları İle Doğru Meslek Seçimi

Dilara BOZYILAN<sup>1</sup>

Faruk BULUT<sup>2</sup>

<sup>1</sup>İstanbul Kabataş Erkek Lisesi  
Kabataş, İSTANBUL

<sup>2</sup>Bilgisayar Mühendisliği Bölümü  
Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, Davutpaşa, İSTANBUL

Email: [dilarabozyilan@hotmail.com](mailto:dilarabozyilan@hotmail.com)

[f0110303@std.yildiz.edu.tr](mailto:f0110303@std.yildiz.edu.tr)

### Özet

*Meslek seçimi insan hayatını etkileyen bir karardır. Hatalı tercihler bireyi yaşam boyu mutsuz eder. Yapılan araştırmalarda Türkiye’de ve dünyada yaygın olarak yanlış meslek seçimi yapıldığı görülmüştür. Bu çalışmada doğru meslek seçimine yardımcı olmak amacıyla yapay zekâ uygulamalarından yararlanılmıştır. Geliştirilen karar destek sisteminde, hata toleranslı, eğitilebilen, deneyime dayalı özgün bir Yapay Sinir Ağları (YSA) mekanizması kullanılmıştır. Değişik sektörlerde çalışan ve mesleğinde memnun olan kişilerden elde edilen verilerle bir eğitim seti oluşturulmuştur. Bu eğitim seti, YSA’ya aktarılarak sistem eğitilmiştir. Yapılan çapraz geçişleme işlemlerinde ve uygulamalarda başarılı sonuçlar elde edilmiştir.*

### 1. Giriş

Meslek seçimi, bireyin yaşamında çok önemli bir yere sahiptir. Kişi, yetenek, ilgi ve istekleri doğrultusunda doğru bir meslek seçimi yaparsa başarılı, verimli ve mutlu olur. Buna karşılık bir kişi kişisel özelliklerini ve yeteneklerini göz önünde tutmadan meslek seçimi yaptığında da başarısız, verimsiz ve mutsuz olur [1]. Bu nedenle birey, meslek seçerken, kendi özellikleri ile seçeceği mesleğin nitelikleri arasında uygunluk olmasına dikkat etmelidir. Araştırma bulgularına göre, yetenek, beceri, ilgi ve ideallerine uygun meslek seçmiş olanların sayısı az, iş veya mesleğinden şikâyet edenlerin sayısı çoktur [2].

Meslek seçiminin ne denli büyük bir sorun olduğu ile alakalı geniş kapsamlı bir araştırma yapılmıştır. Uğur Kariyer Merkezi’nin yaptığı bir araştırmada insanların %85’inin hatalı meslek seçimi yaptığı görülmüştür[2]. TRT’nin 1000 kişi üzerinde yaptığı bir anket çalışmasında benzer sonuçlar elde edilmiştir. Bireylerin %32,9’unun kendilerine uygun olmayan bir

meslekte çalıştıklarını; %42,3’ünün ise mesleklerinden memnun olmadıklarını tespit etmişlerdir [3]. Yanlış meslek seçiminin üniversite sınavı öncesi yapıldığı da bir gerçektir.

Bu nedenle orta öğretim sıralarında öğrencilerin seçimlerine yardımcı olacak bir karar destek sistemi üzerinde çalışılması amaçlanmıştır. Bu çalışma beş ana bölümden oluşmaktadır. İlk olarak çalışmada kullanılacak olan veri setinin nasıl oluşturulduğu anlatılmıştır. Daha sonra YSA’nın mimari yapısının nasıl olacağı belirlenmiştir. En son olarak elde edilen deneysel sonuçlar ve yorumlara yer verilmiştir.

### 2. Veri Setini Hazırlanması

Sistemin doğru sonuçlar vermesi için, eğitim setimizin güvenilir olması gerekmektedir. Bu amaçla iyi bir anketin hazırlanması için meslek seçiminde etkili olan tüm faktörler analiz edildi. Bu konu ile ilgili birçok makale tarandı [1-4] ve 50 kadar soru ankete ilave edildi. *8.Ek Anket Soruları* başlığı altında verilen her bir soru bireyin kişisel özelliklerini irdeleyen ve mesleklere olan yatkınlığını analiz eden bir yapıdadır.

Hazırlana anket soruları değişik meslek gruplarında çalışan bireylere uygulandı. Çalışmada meslekler 5 kategoriye ayrılmıştır. Bunlar hukuk, tıp, mühendislik, sosyal bilimler ve medya sektörüdür. Kategorilerin sayısının kısıtlıdır ve meslek türleri detaylı olarak belirtilmemiştir. Bunun nedeni çok sınıflı bir eğitim setinde sınıflandırma başarısının düşük çıkacak olmasındandır.

Her kategoriden belirli kurumlarla görüşüp resmi izin alınmıştır. İzin aldığımız kurumlar arasında TRT, İstanbul Barosu, Büyükçekmece İlçe Milli Eğitim Müdürlüğü, Bilgisayar Mühendisleri Odası ve ATV-Sabah Medya firması gibi kurumlar bulunmaktadır.

Tablo 1'de görüldüğü gibi 202 kişiyle anket yapılmıştır. Fakat eğitim setine sadece mesleğinden memnun 56 kişi dâhil edilmiştir.

	Anket Yapılan Kişi Sayısı	Mesleğinden Memnun Olan Kişi Sayısı
Hukuk	40	11
Tıp	47	8
Mühendislik	63	16
Sanat	33	9
Medya	19	12

Tablo 1. Eğitim Seti

### 3.YSA Oluşturma ve YSA'nın Eğitimi

Çalışmamızda YSA'nın eğitilmesi için *Perceptron* öğrenme algoritması kullanılmıştır. Bu bölümde YSA'nın çalışma prensibine, yapısına ve kullanılan aktivasyon fonksiyonuna yer verilmiştir.

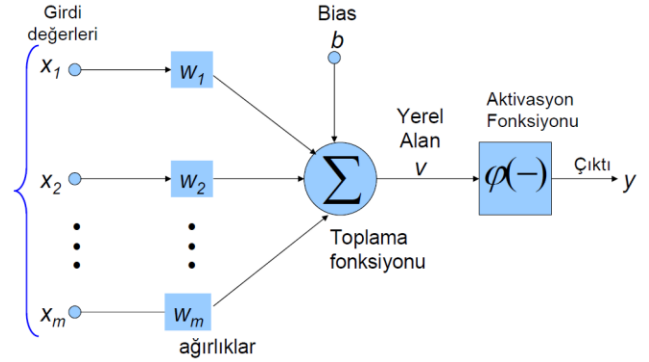
#### 3.1. YSA'nın Çalışma Prensibi

Yapay Sinir Ağları, hata üzerine dayandırılmış bir öğrenme algoritmasıdır. Temel iki işlevi, karar vermek ve öğrenmektir. Bunu da ağırlıklar, aktivasyon fonksiyonu ve *bias* sayesinde yapar. Ağırlıklar, her cevabın değerlendirmeye gitmeden önce çarpıldığı katsayıdır. Tüm cevaplar, kendilerine ait ağırlıklarla çarpılarak toplanır. Daha sonra aktivasyon fonksiyonuna bu değer gönderilmesi sonucu ortaya çıkan cevap, mekanizmanın kararı olur. *Bias* ise, kullanıcıdan kullanıcıya, mekanizmanın çalışma şekline veya amacına göre değişebilen, kullanıcı tarafından eklenen kat sayıdır. Şekil 1'de yapay bir sinir ağının çalışması gösterilmiştir [5].

#### 3.2. Katman Sayısı ve Bias

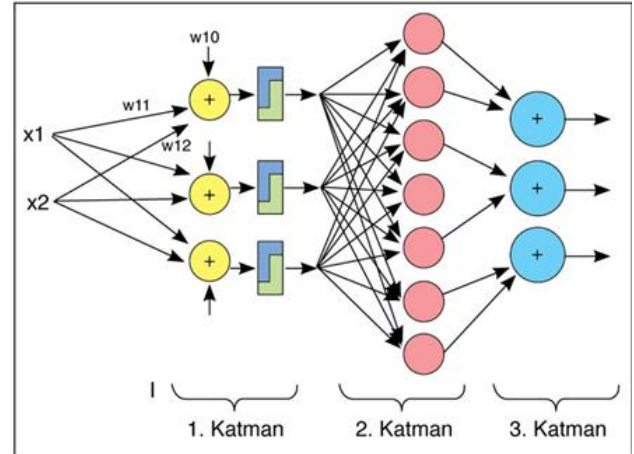
Eğitim setinde bulunan veri sayısı öğrenme ve sınıflandırma başarısını doğru orantılı bir şekilde etkilenmektedir. Etiketli verilerin toplanması esnasında karşılaşılan güçlüklerden ötürü az sayıda veri eğitim setine eklenebilmiştir. YSA sisteminin güvenilirliği ve sınıflandırma performansını artırmak amacıyla bir takım değişiklikler yapılmıştır. Katman sayısı, her katmandaki *perceptron* sayısı, *bias* katsayısının değeri, eğitimdeki iterasyon sayısı sayısının ve en iyi aktivasyon fonksiyonunun seçilmesi ile YSA sistemi özgülendirildiği gibi sınıflandırma performansı da artırılmıştır. Bunun için birçok deneme yapılarak *bias* için en ideal katsayın 0.7 olduğu görülmüştür. 3 katmanlı bir YSA, en karmaşık problemleri bile

çözebildiğinden katman sayısını Şekil 2'de görüldüğü gibi 3'te sabit tutulmuştur [6].



Şekil 1. Yapay Sinir Ağları

Oluşturulan YSA'nın çalışma prensibi, Şekil 1'de görüldüğü gibidir. İlk katmanda (*input layer*), bir test girdisine ait tüm özellikler (*attribute*),  $w_i$  ağırlığıyla çarpılarak toplanır. Elde edilen değer *bias* katsayısı ile çarpılarak aktivasyon fonksiyonuna ve gizli katmana (*hidden layer*) iletilerek son katmandan (*output layer*) çıktı alınır [7].




Şekil 2. YSA Katmanları ve Bias

#### 3.3. Aktivasyon Fonksiyonu

Kullanılabilecek pek çok aktivasyon fonksiyonu vardı. Eğitim seti 5 sınıf etiketli yani 5 boyutlu bir uzay olduğu için iyi bir seçim yapılmalıdır. Doğru ve hassas sonuçların elde edilebilmesi için *Sigmoid* aktivasyon fonksiyonu tercih edilmiştir. Fonksiyonun çalışma prensibi Şekil 3'te; formülü ise (1) nolu formülde görülmektedir [7-8].

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (1)$$



Şekil 3. Sigmoid Aktivasyon Fonksiyonu

#### 4. Deneysel Sonuçlar

Deneysel sonuçların elde edilebilmesi için C programlama dili ve Weka programı kullanılmıştır. YSA'nın özgünleştirilebilmesi için C'de yazdığımız kodlardan yararlanılmıştır.

Çalışmanın doğruluk ve performans analizini yapmak amacıyla çapraz geçişleme işlemi yapılmıştır. Birini Dışarıda Bırak (Leave One Out) yöntemi ile yaptığımız çapraz geçişleme işleminden *confusion matrix* tablosu elde edildi. Bu yöntem, sırasıyla eğitim setinden bir veriyi test girdisi olarak kullanıp, geride kalan eğitim seti ile yeni bir YSA oluşturmayı amaçlar. Tüm veri seti için yapılan bu uygulama ile her bir test verisinin sonucu *Confusion Matrix* tablosuna aktarılır. Eğitim setinde bulunan 56 kişiden bulunmaktadır. Bunların 9 tanesi hukukçu, 10 tanesi tıpçı, 11 tanesi mühendis, 12 tanesi de sözelci ve 8 tanesi de medya sektöründe çalışan kişilerden oluşmaktadır.

Tablo 2'de kendi YSA kodlarımızla oluşturduğumuz *Confusion Matrix* tablosu görülmektedir. Bu tabloda yatay olarak değerler toplandığında gerçekte var olan her bir sınıfın kaç adet örneği olduğu görülür. Dikey olarak bakıldığında ise sınıflandırıcı algoritmanın her bir örnek için verdiği kararın ne olduğu gösterilir.

Tablo 2: ConfusionMatrix Tablosu

	Hukuk	Tıp	Mühendislik	Sanat	Medya
Hukuk	8	0	0	1	2
Tıp	0	6	1	0	1
Mühendislik	1	1	12	0	2
Sanat	1	0	0	7	1
Medya	1	0	1	1	9

Bu tablodan YSA sisteminin elde edilen ile doğruluk (*accuracy*) oranı 0.75'dir. Sınıflandırıcının her bir sınıf üzerindeki başarısı için Netlik, Hassasiyet ve F1 Skoru metrikleri kullanılmıştır.

Netlik (*Precision*): Netliği hesaplamak için doğru tahmin edilenleri tüm tahminlerin sayısına bölünür (2). Her bir sınıf etiketi için ayrı ayrı hesap yapılmalıdır. Bunun nedeni sınıflandırıcının her bir sınıftaki netliğini hesaplamak içindir.

$$P = \frac{\text{Doğru Tahmin Edilenler}}{\text{Tahmin Sayısı}} \quad (2)$$


Hassasiyet (*Recall*): Doğru tahmin edilenlerin gerçek değere oranıdır ve (3) numaralı formül ile bulunur.

$$R = \frac{\text{Doğru Tahmin}}{\text{Gerçek Değer}} \quad (3)$$

F1 Skoru: Netlik ve hassasiyetin harmonik ortalamasıdır ve (4) numaralı formül ile bulunur.

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (4)$$

Her bir sınıf etiketi için elde edilen P, R ve F1 değerleri Şekil 4'te görüldüğü gibidir.




Şekil 4. P, R ve F1 değerleri

Şekil 5'te diğer sınıflandırma yöntemleriyle YSA yönteminin karşılaştırılması yapılmıştır. Destek Vektör Makinesi (*SVM*), Karar Ağacı (*Decision Tree*), k En Yakın Komşuluk algoritması (*k-NN*) ve Naive Bayes sınıflandırıcısı gibi sınıflandırıcılarla Weka programı kullanılarak karşılaştırıldı. SVM sınıflandırıcısı iki sınıflı eğitim setlerinde kullanılabilirdiği için eğitim setimizden sadece tıp ve mühendislik etiketindeki verilerden yeni bir veri seti oluşturularak uygulama yapıldı. Ayrıca yapılan çalışmalar sonucunda, çevrim (*epoch*) sayısını artırdığımızda doğruluk oranının arttığı görüldü. Veri



seti ile yapılan eğitimde çevrim sayısının belirli bir düzeye kadar artırılmasının sistemin doğruluğunu doğru oranda etkilediği gözlemlendi. 500'den sonra artırdığımız değerler için doğruluk oranında bir artış olmadı. Bu nedenle çevrim sayısını 500'de tutmayı tercih edildi.



Şekil 5. Sınıflandırıcıları karşılaştırma

Bu veri setinde YSA algoritmamızın doğruluk değerinin beklenildiği kadar yüksek düzeyde çıkmadığı görüldü. Doğruluk oranının düşme sebeplerinin şu nedenlerden olduğu düşünülmektedir:

- Denetimli öğrenme için etiketli örneklerin (*instance*) yeteri sayıda olmayışı,
- Eğitim setindeki özellik (*feature*) sayısının fazla olması,
- Eğitim setinde 5 sınıf türünün bulunması.

Bütün bunlar uzayın seyrek bir yapı (*sparce*) meydana getirmesine sebep olmuştur. Özellik sayısının, PCA (*Principal Component Analysis*) ve Faktör Analizi gibi yöntemler kullanılarak azaltılması sınıflandırma başarısını artırmaktadır. İleri uygulamalarda bu tür yöntemler kullanılabilmesi gibi bütçeli, komisyonlu çalışmalar yapılarak daha güvenilir bir YSA mekanizması oluşturulabilir. Bu sayede üniversite tercihlerinden önce bireyin en sağlıklı tercih yapması sağlanabilir.

## 5.Değerlendirme

Üzerinde çalıştığımız projede insan psikolojisi, insana ait kabiliyetler ve bir takım insansı özellikler sayısallaştırılarak yapay bir karar destek sistemi geliştirildi. Bu sistemde mesleğinden memnun bireylerden elde edilen verilerle yeni ve özgün bir

YSA sınıflandırıcısı önerildi. Önerilen sistem ile diğer sınıflandırıcıların performansları kıyaslandı.

## 6.Teşekkür

Anket çalışması yapabilmemiz için bize resmi izin veren, destekleyen, hoş gören İstanbul İl Milli Eğitim Müdürü Dr. Muammer YILDIZ'a, İstanbul B.çekmece Anadolu Lisesi'ne, İstanbul İl Sağlık Müdürlüğüne, İstanbul Çapa Eğitim ve Araştırma Hastanesine, İstanbul Bilgisayar Mühendisleri Odasına, İstanbul Baro'suna ve ATV Ana Haber Spikeri Cem ÖĞRETİR'e teşekkürlerimizi bir borç bilir, saygı ve sevgilerimizi sunarız.

## 7. Kaynaklar

- [1] RAZON N. "Meslek seçiminde gençlere nasıl yardım edebiliriz? "Aile ve Çocuk Dergisi II. Grafik Sanatlar Matbaası, İstanbul 1982, <http://www.ekipnormarazon.com> Alınma Tarihi: 18.09.2013
- [2] Uğur Kariyer Merkezi, Meslek Seçimi Araştırması, İstanbul, 2010.
- [3] TRT'nin Yapmış Olduğu "1000 Kişiyi Sorduk" adlı çalışmalarından biri: "Türkiye'de ve Dünya'da Yanlış Meslek Seçimi", <http://tvarsivi.com/player.php?y=446&z=2013-08-22%2012:47:00>, Alınma Tarihi: 22.10.2013
- [4] KIYAK S. "Lise Öğrencilerinin Meslek Seçimi Yaparken Temel Aldığı Kriterler", TC. Yeditepe Üniversitesi Sosyal Bilimler Enstitüsü, 2006.
- [5] Prof. Dr. Çetin ELMAS. "Yapay Zeka Uygulamaları". Seçkin Yayıncılık, 2010. s. 50-87
- [6] KUBRICK, S. Artificial Intelligence Kitabı, 2009. S. 90-91.
- [7] Nebiyev V. "Yapay Zeka Problemler- Yöntemler- Algoritmalar" ,2013. Seçkin Yayıncılık. S. 100-110.
- [8] RUSELL, Stuart. "Artificial Intelligence: A Modern Approach", Prentice Hall, 3 Ed., 2009. S. 71-72.

## 8. Ek - Anket soruları

Aşağıdaki 50 adet anket sorusundan ilk 43 tanesinin cevabı evet ve hayır şeklindedir. Eğitim setine evet cevabı 1 olarak; hayır cevabı 0 olarak kaydedilmiştir. 44-50 arasındaki soruların cevapları ise şıklıdır. Bu sorular sisteme nominal (*string*) olarak aktarılmıştır. Anketteki soruların her biri YSA'nın giriş katmanı için özellik (*attribute*) olarak alınmıştır.

1. İnsanların sorunlarına çözüm aramayı sever misiniz?
2. İnsanlara karşı empati yapabilir misiniz?
3. Sabırlı mısınız?
4. Size dertlerini anlatan insanları dinlerken onlara karşı dürüst olur musunuz?
5. Başkalarını dinlemeyi sever misiniz?
6. Çevrenizde fikirleri kabul edilen biri misiniz?
7. Anlatmayı sever misiniz?
8. Yapılan bir haksızlık karşısında müdahale eder misiniz?
9. Etkileyici konuşma yeteneğiniz var mı?
10. Olayları farklı bakış açılarıyla yorumlar mısınız?
11. Küçüklüğünüzde oynadığınız oyunlarda lider olur muydunuz?
12. Sorumluluk alır mısınız?
13. Çekingen misinizdir?
14. Disiplinli misiniz?
15. Kararsız mısınız?
16. Hafızanız kuvvetli midir?
17. “Nasıl başarılı olunur” gibi kitaplar okur musunuz?
18. Hayatınızı plan program dâhilinde yaşar mısınız?
19. Ekonomik gelişmeleri takip eder misiniz?
20. Gazete veya haberleri takip eder misiniz?
21. Hayatınızda hiç satış yaptınız mı? (limonata, kurabiye, oyuncaklarınız vs.)
22. Etrafınızda olup biten olayların aslını öğrenmek için garip bir merak duyar mısınız?
23. Makine ve malzemeler ile çalışmaktan hoşlanır mısınız?
24. Etrafınızda gördüğünüz nesnelere nasıl çalıştığını merak eder misiniz?
25. Elektronik aletlere merak duyar mısınız?
26. Yeni bir nesne gördüğünüzde bu nesneyi detaylı inceler misiniz?
27. İnsanları yönetmeyi sever misiniz?
28. Kitap okumayı sever misiniz?
29. Tarih kitapları okumaktan hoşlanır mısınız?
30. İnsan ve evrenin niçin yaratıldığını düşünür müsünüz?
31. Bilim-teknik türü dergiler okur musunuz?
32. Bulmaca çözmeyi sever misiniz?
33. Harita üzerinde farklı ülkelerin yerlerini bulmayı sever misiniz?
34. Gördüğünüz ilginçliklerin fotoğraflarını çeker misiniz?
35. Rekabetten hoşlanır mısınız?
36. Aldığınız olumsuz eleştiriler sizi kızdırır mı?
37. Bilmediğiniz bir kelime için sözlüğe bakar mısınız?
38. Sanat sergilerini gezmeyi sever misiniz?
39. Bir işi bitirmeden başka bir işe başlar mısınız?
40. Canlıların fizyolojik işleyişini incelemeyi sever misiniz?
41. Hayvanları sever misiniz?
42. Uzun süre masa başında çalışmaya sabredebilir misiniz?
43. Doğayla iç içe olmaktan hoşlanır mısınız?
44. Küçüklüğünüzde aşağıdaki oyuncaklardan hangisiyle daha fazla zaman geçirdiniz?  
a) Top  
b) Pelüş hayvan  
c) Uzaktan kumandalı araba  
d) Müzik aletleri  
e) Kukla
45. Matematik soruları mı, edebiyat metinleri mi?  
a) Matematik soruları  
b) Edebiyat metinleri
46. Grup çalışması mı, bireysel çalışmalar mı?  
a) Grup çalışması  
b) Bireysel çalışma
47. Bilginin mi deneyimin mi gücüne inanırsınız?  
a) Bilgi  
b) Deneyim
48. Mantığınız mı sizin için ön plandadır, duygularınız mı?  
a) Mantık  
b) Duygular
49. Size ait hangi özelliğinizle öne çıkmak istersiniz?  
a) Zekâmla  
b) Paramla  
c) Sanatımla
50. Ne sıklıkla hayal kurarsınız?  
a) Genellikle kurarım  
b) Arada bir kurarım  
c) Hiç kurmam

# Kognitif EEG İşaretleri İçin Öznitelik Seçimi Tabanlı Kanal Seçimi ve Sınıflandırma

Server Göksel ERALDEMİR<sup>1</sup> Esen YILDIRIM<sup>2</sup> Serdar YILDIRIM<sup>3</sup> Yakup KUTLU<sup>4</sup>

Mustafa Kemal Üniversitesi İskenderun Meslek Yüksekokulu<sup>1</sup>  
Mustafa Kemal Üniversitesi Mühendislik Fakültesi<sup>2,3,4</sup>

Email: [servergoksel@gmail.com](mailto:servergoksel@gmail.com)<sup>1</sup> [esen.yildirim@yahoo.com](mailto:esen.yildirim@yahoo.com)<sup>2</sup> [yildirims@gmail.com](mailto:yildirims@gmail.com)<sup>3</sup> [yakupkutlu@gmail.com](mailto:yakupkutlu@gmail.com)<sup>4</sup>

## Özet

**Bu çalışmada sayısal ve metinsel işlemlerin yapılması sırasında beyinde oluşan EEG işaretlerinin sınıflandırılması hedeflenmiştir. Bu amaçla sağlıklı ve gönüllü deneklerden uluslararası 10-20 sistemine uygun olarak, EEG verileri kaydedilerek bir veritabanı oluşturulmuştur.**

**Bu veriler Ayrık Dalgacık Dönüşümü yöntemi ile özniteliklerine ayrılmış ve bu öznitelikler üzerinde öznitelik seçimi yapılarak en etkili kanallar belirlenmiştir. Tüm kanallardan ve sadece etkin olduğu belirlenen kanallardan elde edilen öznitelikler BayesNet kullanılarak sınıflandırılmıştır. Tüm kanallar kullanıldığında %88,8 doğru pozitif oranı ve %89,2 kesinlik elde edilirken, en etkili on kanalın kullanılmasıyla %90 doğru pozitif ve %90,3 kesinlik değerlerine ulaşılmıştır.**

## 1. Giriş

Beynin her türlü aktivitesinde oluşan EEG işaretleri çok karmaşık yapıya sahiptir. En tepe noktası ile minimum noktası arasındaki genlik değerleri 1-100 $\mu$ V arasındadır [1].

EEG işaretlerinde değer değişimleri çok ani zaman aralıklarında ortaya çıktığı için sinyal durağan değildir. Bu nedenle genlik, frekans ve zaman bilgileri sürekli ve ani olarak değişmektedir [2,3,4]. Bu karmaşık kayıtlarda gerekli verileri bulmak ve bunlardan bir anlam çıkarmak uzmanlık isteyen bir alandır. Her çekim alanında uzman bir kişi bulundurulamayacağı için EEG kayıtları çeşitli sinyal işleme yöntemleri ile işlenir ve elde edilen veriler farklı makine öğrenme teknikleri ile sınıflandırılır. Böylelikle ham EEG verilerinden çok daha anlamlı

bilgilere ulaşılmış olur. Literatürde bulunan pek çok çalışmada, EEG sinyal analizinde Fourier dönüşümü kullanılmıştır [2,3]. EEG sinyallerinin durağan olmaması nedeniyle Fourier dönüşümünün EEG kayıtlarının analizinde yeterli gelmediği görülmüştür [2]. Dalgacık Dönüşümü (DD) bu eksiklikleri gidermek için geliştirilmiş bir dönüşüm türüdür. Bu analiz yöntemi EEG- ECG gibi durağan olmayan bio- işaretlerin analizinde rahatlıkla uygulanabilmektedir ve literatürde bulunan birçok çalışmada kullanılmıştır [5,6,7].

Araştırmacılar okuma ve problem çözme işlemleri sırasında oluşan sinyallerin farklılıklarının tespiti ve sınıflandırılması için çeşitli çalışmalarda bulunmuşlardır. Oliviera ve arkadaşları, sessiz okuma ile okumanın olmadığı durumlarda EEG sinyallerini en yakın komşuluk algoritması (kNN) kullanarak %84,41 doğru pozitif ve %15,59 yanlış pozitif değeri ile sınıflandırmışlardır [8]. Mostow ve diğerleri ise yetişkinler ve çocuklar kolay ve zor metinleri okurken tek kanallı EEG kullanarak kaydettikleri işaretlerden okuyucunun yetişkin veya çocuk olduğunu ve okunmuş olan metnin zorluk derecesini %39-%59 arasında doğruluk oranlarıyla ayırt edebilmişlerdir [9]. Diğer bir çalışmada Federice C.G. ve Carole R.B. 16 öğrenci üzerinde yaptıkları deneylerde, matematik sınav sorusu çözerken çekilen EEG sinyallerinden öğrencinin soruyu doğru ya da yanlış cevapladığını kolay problemler için %87, zor problemler için %78 ortalama doğruluk değerleriyle rastgele bir tahminden daha iyi tahmin edebilmişlerdir [10].

Bu çalışmada, sayısal işlemlerin ve metinlerin yer aldığı görseller esnasında kaydedilen EEG işaretlerinin ayırt edilmesi hedeflenmektedir. Bu amaçla 18 gönüllü denekten toplanan veriler gürültüden temizlenerek bölütlere ayrılmış ve DD ile öznitelikler çıkarılarak BayesNet ile sınıflandırılmıştır.



## 2. MATERYAL VE YÖNTEM

Bu çalışmada, her hangi bir sağlık problemi bulunmayan, sayısal ve sözel bölümlerde eğitim görmekte olan üniversite öğrencisi deneklerden gönüllülük esası ile alınan EEG verileri kullanılmıştır. Bu EEG verileri Nihon Kohden 1200 marka 32 kanaldan 1kHz örnekleme ile yüksek kalitede çekim yapabilen, şebeke gürültülerini otomatik temizleyebilen dijital EEG çekim cihazı ile kaydedilerek özgün bir veritabanı elde edilmiştir.

Toplanan veriler ilk olarak ön işlemden geçirilmiş, daha sonra uzunluğu 1 saniye olan %75 örtüşmeli kayan pencereler kullanılarak Dalgacık Dönüşümü yoluyla öznitelikler çıkartılmış, Korelasyon Tabanlı Öznitelik Seçimi (KTÖS) ile en etkin kanallar belirlenmiş; tüm kanallar ve en etkili kanallar için elde edilen öznitelikler BayesNet kullanılarak sınıflandırılmıştır. Çalışmada izlenen yöntem Şekil 1'de özetlenmiştir.

EEG Veritabanı	EEG verileri, 18 denekten, 22 elektrot 26 kanal kullanılarak 1kHz örnekleme frekansı ile toplanmıştır.
Ön İşlem	Şebeke Gürültüsü temizlenerek 120 Hz alçak geçiren Filtre uygulanmıştır.
Öznitelik Çıkarımı	ADD ile (db4 dalgacığı kullanılarak) özniteliklerine ayrıştırılmıştır.
Kanal Seçimi	KTÖS ile en çok seçilen özniteliklerin belirlenerek kanal seçimi yapılmıştır.
Sınıflandırma İşlemleri	Tüm kanallar ve 10 en çok seçilen kanal kullanılarak BayesNet ile sınıflandırma yapılmıştır.

Şekil 1. İşlem Akışı

### 2.1. Verilerin Toplanması

EEG verileri gönüllü deneklerden uluslararası 10-20 sistemine uygun olarak kafa derisi üzerine yerleştirilen elektrotlar yardımı ile toplanmıştır. Çekimden önce ve çekim sırasında şu hususlar dikkat edilmiştir:

- Denekler saçlarının temiz olması, jöle gibi saç şekillendiricilerinin olmaması ve saçların kısa olması konusunda uyarılmıştır.
- Deneklere çekimden önce herhangi bir ilaç kullanmamaları gerektiği söylenmiştir.

- Deneklerden işlemleri yapmaya çalışmaları istenmiş, heyecan faktörüne karşılık, işlemlerin yetiştirilmesi ve metinlerin tamamının zaman içerisinde okumalarının gerekli olmadığı vurgulanmış ve sadece ekrandaki sayısal işleme veya sözel metine odaklanmaları gerektiği ifade edilmiştir.
- Deneklere çekim sırasında el, kol, kafa, bacak ve göz gibi organlarını oynatmamaları gerektiği söylenmiş ve başlangıçta rahat pozisyonda oturmaları sağlanmıştır.

Deneklere örneği Şekil 2 ve Şekil 3'te gösterilen her biri 13.25 sn'lik 30 adet sayısal işlem ve 30 adet metin içeren slaytlar gösterilmiştir. Veriler bu yöntem ile 18 adet gönüllü denekten toplanmıştır. Denekler 19-24 yaş arasında yükseköğrenim gören ve gözlük kullanmayan gençler arasından seçilmiştir.

EEG kayıtları 1 kHz örnekleme frekansı ile, 22 elektrot kullanılarak alınmıştır. Bu elektrotlardan referans noktasına göre 26 kanallık veri kaydı oluşturulmuştur; Fp1-A1, Fp2-A2, F3-A1, F4-A2, C3-A1, C4-A2, P3-A1, P4-A2, O1-A1, O2-A2, F7-A1, F8-A2, T3-A1, T4-A2, T5-A1, T6-A2, Fp2-O2, Fp1-O1, Fp1-Fp2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4 ve O1-O2.

$$\begin{array}{r} 17584 \\ + 9108 \\ \hline \end{array}$$

Şekil 2. Sayısal Slayt Örneği

Dünyada kötülükler olduğu sürece şiddet de olacaktır. Şiddet, şiddetle değil, sevgiyle ortadan kaldırılır. Güzelliklere, güzel duygularla yaklaşmak kolaydır. Önemli olan, insanlık için olumsuzluk olan durumların karşısına güzel duygularla çıkmaktır.

Şekil 3. Sözel Slayt Örneği

Deneyin yapıldığı ortam gürültüden arındırılmış, ışıklandırmasının yeterli olması sağlanmıştır. Şekil 4'de görüldüğü gibi deneklerin çekim sırasında temiz ve kısa saçlı olmaları istenmiş, rahat ve hareket

etmeden durmalarını sağlayacak şekilde oturmaları sağlanmıştır.



Şekil 4. Deneklerin Çekim Sırasındaki Pozisyonları

## 2.2. Önışleme

Kayıtlardaki 50 Hz'lik şebeke gürültüsü EEG cihazı tarafından doğrudan bastırılmış ve 120 Hz kesme frekansı ile alçak geçiren filtreden geçirilmiştir. Böylelikle veriler yüksek frekanslı gürültülerden arındırılmıştır. Elde edilen verileri bölütlere ayırma işleminde sayısal ve metinsel bölümlerde bulunan, ilk slaytlar ve son iki slayt senkronizasyondan dolayı oluşabilecek sıkıntıları gidermek için kullanılmamıştır. Geriye kalan her bölümdeki 27'şer adet slayt, 13.25 saniyelik veriler halinde bölünmüştür.

## 2.3. Özniteliklerin Elde edilmesi

Bu çalışmada öznitelik çıkarımı için Ayrık Dalgacık Dönüşümü (ADD) yöntemi kullanılmıştır [2,11,12].

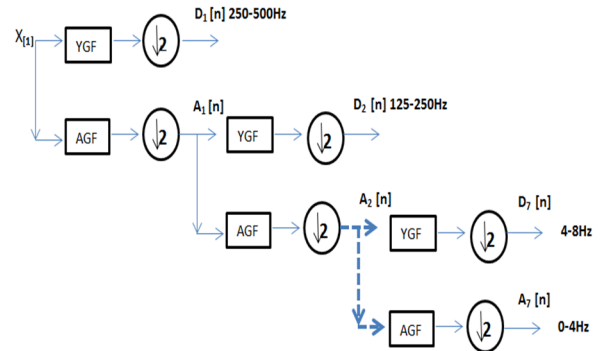
### 2.3.1 Ayrık Dalgacık Dönüşümü

Ayrık Dalgacık Dönüşüm (ADD), dalgacık analizi için filtre bankaları kullanır. Filtre bankası, işaretli frekans bantlarına ayıran filtrelerden oluşur [13]. İşaret, orijinal işaretin yeniden elde edilebileceği şekilde, dalgacık katsayılarına ayrıştırılır. Bu katsayılar işaretin farklı frekans bantlarında temsil edilmiş şeklindedir. Ayrık zamanlı bir işaret analiz edildiğinde, işaretin frekans içeriğini eşit parçalara bölen yüksek ve alçak geçiren filtrelerden geçirilirler. Şekil 5'te YGF yüksek geçiren filtreyi, AGF ise alçak geçiren filtreyi temsil etmektedir. Filtre bankasının alçak ve yüksek geçiren filtre dalları, işaret için sırasıyla yaklaşım ve detayları vermektedir. İşlem sonucunda elde edilen filtre sonuçları, giriş işaretinin frekans içeriklerinin yarısına sahip olmasına rağmen giriş işareti ile aynı sayıda örneğe sahiptir. Bu nedenle alt örnekleme yapılarak çıkışlardaki toplam örnek sayısındaki fazlalık yok edilir. Filtre bankası istenen çözünürlüğe bağlı olarak istenildiği kadar genişletilebilir. Her seviyede frekans içeriği ikiye bölünür, yüksek geçiren filtre sonucunda elde edilen

katsayılar  $X(n)$ 'nin frekans içeriğinin üst yarısını simgelerken, alçak geçiren filtre sonucunda elde edilen katsayılar alt yarısını simgeler. Bu işlem istenilen frekans çözünürlüğü elde edilene kadar tekrarlanabilir.

### 2.3.2 Özniteliklerin Çıkartılması

Bu çalışmada veriler 1 saniye uzunluğunda 0,25 sn'lik kaydırmalardan elde edilen pencereleme bölünmüştür. Her pencere ADD ile analiz edilerek öznitelikler çıkartılmıştır. Analiz için db4 ana dalgacık fonksiyonu kullanılmıştır. Çıkartılan özniteliklerde 1 kHz'lik örnekleme frekansı göz önüne alındığında, ilk üç detay katsayısı yüksek frekans aralığına sahip olduğundan  $D_1$ ,  $D_2$  ve  $D_3$  katsayıları kullanılmamıştır. Öznitelik vektörü oluşturulurken  $D_4$ ,  $D_5$ ,  $D_6$ ,  $D_7$  detay katsayıları ve  $A_7$  yaklaşım katsayısı kullanılmıştır. Öznitelikler bu katsayıların standart sapması ve katsayıların mutlak değerlerinin ortalaması, maksimumu ve minimumu kullanılarak oluşturulmuştur.



Şekil 5 7. Seviye Ayrık Dalgacık Dönüşümü

## 2.4. Kanal Seçimi

### 2.4.1. Korelasyon Tabanlı Öznitelik Seçimi

Öznitelik seçimi yöntemleri esasen yüksek sayıdaki özniteliklerden sınıflandırma işlemine katkısı en yüksek olanların seçilmesi amacıyla kullanılmaktadır. Bu işlem sayesinde literatürde boyutun laneti olarak bilinen sorun (curse of dimensionality) olarak bilinen sorun da ortadan kaldırılmaktadır [14].

KTÖS yöntemi birbirleri ilişkisi az olan fakat sınıfla yüksek ilişkili olan öznitelikleri seçerek bir alt öznitelik kümesi oluşturur. Bu amaçla, öznitelikleri tek tek değerlendirmek yerine alt öznitelik kümelerini puanlanarak en uygun alt küme bulunur.

### 2.4.2. Kanal Seçimi


Kullanılan kanal sayısının doğru pozitif oranını etkilemeyecek şekilde azaltılması analiz süresini

azaltacağından sistemin kullanılabilirliğini artıracaktır. Bu nedenle sınıflandırmada en etkili kanalları bulmak önem arz etmektedir. Bu çalışmada sınıflandırma problemine en yüksek katkıyı sağlayan kanalların bulunmasında Korelasyon Tabanlı Öznitelik Seçimi yönteminden faydalanılmıştır. Kanal seçimi yapılırken şu işlem sırası kullanılmıştır;

1. KTÖS yardımıyla seçilmiş öznitelikler bulunmuştur.
2. Seçilmiş özniteliklerin hangi kanallarda olduğu tespit edilmiştir.
3. Kanallara ait seçilmiş özniteliklerin sayısının toplamı bulunmuştur.
4. Bu işlem basamakları her denek için tekrarlanarak tüm deneklerde en çok kullanılan öznitelikler bulunmuştur.
5. Tüm deneklerde seçilen öznitelik sayıları dikkate alınarak, kanallar en çok seçilen öznitelige sahip olandan en düşüğe doğru sıralanmıştır. Daha sonra bu kanallar analize teker teker eklenerek analiz tekrarlanmıştır.

Tablo-1 Öznitelik Sayısı Ve Kanal İsimleri

Kanal Adı	Seçilen Öznitelik Sayısı
Fp1-Fp2	113
O1-O2	69
T5-T6	52
T3-A1	51
T6-A2	49
Fp1-A1	43
T4-A2	42
Fp1-O1	42
F8-A2	40
F7-F8	39
P3-P4	32
Fp2-O2	31
O2-A2	30
F7-A1	28
T5-A1	24
T3-T4	24
Fp2-A2	22
O1-A1	22
C3-C4	22
F3-F4	21
P4-A2	20
F4-A2	15
C3-A1	13
C4-A2	13
F3-A1	12
P3-A1	10



Şekil 6 Seçilen Kanallara ait Elektrotlarının Gösterimi

Tablo-1'de kanalar ve o kanallara ait özniteliklerin seçilme sayıları, Şekil 6'da ise seçilen kanalların elektrotlarının yerleştirildiği bölgeler gösterilmektedir. Bu bölgelerden Fp1-Fp2'nin bulunduğu frontal lob problem çözme işlemlerinin yapılmasında kullanılan bölge olarak literatürde yer almaktadır [15]. Bu nedenle en çok seçilen kanal olması beklenen bir sonuçtur.

## 2.5. Sınıflandırma

Bu çalışmada sınıflandırma işlemi için Bayesian Ağları kullanılmıştır.


### 2.5.1. BayesNet

Bayesian ağları Bayes teoremine göre çalışmaktadır. Bayes teoremi iki farklı olaya bağlı olarak olasılık hesabına dayanan bir teoremdir. Birbirinden bağımsız X ve Y olayları için, iki olayın aynı anda oluşma olasılığı iki olayın ayrı ayrı oluşma olasılıkları çarpımına eşittir. Bağımlı olaylarda ise bu olasılık aşağıdaki şekilde elde edilir:

$$P(X\Lambda Y) = P(X) * P(X|Y) \quad (1)$$

Bu formül bize X ve Y durumlarının bir arada olma olasılığını vermektedir [16].

Bayes ağ çok terimli verilerin analizinde kullanılan algoritmadır. Bu algoritma zor problemleri verimli ve güvenilir bir şekilde çözmek için var olan yöntemlerin geliştirilmesi ile oluşmuştur. Bayes ağ çok terimli verilerin birbirleri ile olan olasılıklarını hesaplamak için çok güçlü bir algoritmadır.



Şekil 7 Örnek BayesNet Gösterimi

Şekil 7’de C düğümünün ana düğümleri A ve B iken, C düğümü D ve E düğümleri için ana düğümdür. Bu durumların oluşma olasılığı şartlı ve birleşik olasılık dağılımı ile tanımlanmaktadır ve formül 1’de verilen eşitlik ile aralarındaki ilişki tanımlanabilir.

$$p(X) = \prod_{i=0}^{n-1} p(X_i|\pi_i)$$

Bu formülde  $X = (X_0, \dots, X_{n-1})$  değişkenlerin vektörünü,  $\pi_i$  ise  $X_i$ ’lerin ana düğümlerini göstermektedir. Bayes ağ yapılarında olayın etkisi olan çocuk düğümler ve olayın nedeni olan ana düğümler bulunmaktadır [17].

## 2.6. Değerlendirme

Çalışma sonuçlarının değerlendirilmesinde 10 kat çapraz doğrulama kullanılmıştır. Bu yöntemde veri kümesi iki parçaya ayrılır. Birinci aşamada veriler rastgele 10 eşit parçaya ayrılır veri kümelerinin her defa bir tanesi test için, geri kalan dokuz tanesi ise eğitim için kullanılır. Bu işlem on defa tekrarlanır ve bu on tekrarın ortalaması alınır. Bu işlemde her veri bir defa test verisi olarak kullanılır.

Sonuçların değerlendirilmesinde kullanılan Doğru Pozitif Oranı (True Positive Rate) Formül (3.1)’de gösterildiği gibi, her iki sınıfa ait doğru tahmin edilmiş etiket sayısının (DTEES) toplam etiket sayısına (TES) oranı ile bulunur.

$$\text{Doğru Pozitif Oranı} = \frac{\text{DTEES}}{\text{Toplam Etiket Sayısı}} \quad (2)$$

Yanlış Pozitif Oranı (False Positive Rate) yanlış tahmin edilmiş etiket sayısının (YTEES) toplam etiket sayısına bölünmesiyle bulunur.


$$\text{Yanlış Pozitif Oranı} = \frac{\text{YTEES}}{\text{Toplam Etiket Sayısı}} \quad (3)$$

## 3 SONUÇLAR

Tablo 2’de 26 kanal kullanılarak elde sınıflandırma sonuçları verilmiştir. Yapılan çalışma sonuçları genel olarak incelendiğinde sayısal ve sözel düşüncenin sınıflandırmasında doğru pozitif oranının %72,3 ile %96,5 arasında değişmekte olduğu görülmektedir. Ayrıca yanlış pozitif değeri olarak en düşük %3,5 ve en yüksek %27,7 olarak bulunmuştur. Kesinlik değeri ise %73,5 - %96,5 arasındadır.

En çok seçilen kanaldan başlanarak, kanallar sırasıyla analize dahil edildiğinde ve BayesNet ile sınıflandırıldığında. Grafik-1’de bu sınıflandırma sonuçları verilmiştir. Bu sonuçlara göre, en çok seçilen ilk 10 kanal kullanılarak ortalama doğru pozitif oranı %90 değerine ulaşılmış, bundan sonra

dahil edilen kanallar bu oranı artıramamışlardır. Bu nedenle 10 kanal kullanılarak yapılan çalışmanın ayrıntılı sonuçları Tablo 3’de verilmiştir. Bu kanallar sırası ile Fp1-Fp2, O1-O2, T5-T6, T3-A1,T6-A2, Fp1-A1,T4-A2, Fp1-O1, F8-A2 ve F7-F8’ dir.



Grafik-1 Seçilen 10 Kanala Göre BayesNet Sınıflandırma Sonuçları

Tablo-2 26 Kanallı BayeNet Sonuçları

26 Kanallı BayesNet Sınıflandırma Sonuçları			
Sıra No	Doğru Pozitif Oranı	Yanlış Pozitif Oranı	Kesinlik
1	0,866	0,134	0,867
2	0,845	0,155	0,853
3	0,723	0,277	0,730
4	0,843	0,157	0,860
5	0,930	0,070	0,930
6	0,877	0,123	0,878
7	0,965	0,035	0,965
8	0,894	0,106	0,899
9	0,921	0,079	0,921
10	0,900	0,100	0,910
11	0,910	0,090	0,910
12	0,839	0,161	0,849
13	0,931	0,069	0,932
14	0,895	0,105	0,906
15	0,927	0,073	0,927
16	0,899	0,101	0,901
17	0,929	0,071	0,933
18	0,888	0,112	0,893
<b>Ortalama</b>	<b>0,888</b>	<b>0,112</b>	<b>0,892</b>

Tüm kanallarda en yüksek doğru pozitif oranı %96,5 iken sadece seçilen 10 kanal kullandığında ise en yüksek doğru pozitif oranı %96 olmuştur. Yanlış pozitif değeri 26 kanallı sınıflandırmada ortalama olarak %11,2 olurken, 10 kanal kullanılarak yapılan sınıflandırmada %10 olarak gerçekleşmiştir.

Tablo-2 ve Tablo-3 incelendiğinde Doğru pozitif oranlarında 26 kanallı verinin analizi sonucunda %88,8 başarı sağlanırken, 10 kanallı verinin analizinde bu oran %90 olarak gerçekleştiği görülmektedir.

Tablo-3 Seçilen 10 Kanala Göre BayesNet Sınıflandırma Sonuçları

10 Kanallı BayesNet Sınıflandırma Sonuçları			
Denek Sıra No	Doğru Pozitif	Yanlış Pozitif	Kesinlik
1	0,886	0,114	0,887
2	0,850	0,150	0,857
3	0,726	0,274	0,731
4	0,916	0,084	0,917
5	0,947	0,053	0,947
6	0,869	0,131	0,869
7	0,960	0,040	0,961
8	0,893	0,107	0,895
9	0,900	0,100	0,900
10	0,919	0,081	0,923
11	0,926	0,074	0,926
12	0,836	0,164	0,843
13	0,936	0,064	0,936
14	0,943	0,057	0,944
15	0,936	0,064	0,936
16	0,901	0,099	0,902
17	0,939	0,061	0,942
18	0,925	0,075	0,927
<b>Ortalama</b>	<b>0,900</b>	<b>0,100</b>	<b>0,902</b>

Ayrıca 26 kanallı kullanılan sınıflandırmada 8 adet %90 üstü sınıflandırma oranı oluşurken, 10 kanala göre yapılan sınıflandırmada %90 üstü başarı sayısı 12 adettir. Bu sonuçlar dikkate alındığında kanal sayısı azaltılmasına rağmen, kullanılan kanalların sayısal ve metinsel işaretlerin analiz edilmesinde doğru pozitif oranı olarak %90'nın üstünde başarı sağladığı görülmüştür.

Bu oranlar beyinde matematiksel ve metinsel işlevlerin ayırt edilmesinde beyin bölgelerinden frontal lob ve oksipital lob üzerine yerleştirilecek olan elektrotların %90'nin üstünde sınıflandırma başarısı sağlayacağını göstermiştir.

#### 4 KAYNAKLAR

- [1] Yazgan, E., ve KORÜREK, M., Tıp Elektroniği. İTÜ Matbaası, 1996.
- [2] Coskun, M., İSTANBULLU, Ayhan “EEG İşaretlerinin FFT ve Dalgacık Dönüşümü ile Analizi”, Akademik Bilişim Kongresi, 2012,1-3 Şubat 2012
- [3] Sunay, M., EEG Sinyallerinde Yapay Zeka Tekniklerinin Uygulanması, Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, 2008.
- [4] Kalaycı, T., EEG Dikenlerini Yapay Sinir Ağları ile Tanınması., Doktora Tezi, Ege Üniversitesi Sağlık Bilimleri Enstitüsü, 1996
- [5] Batar, H., EEG İşaretlerinin Dalgacık Analiz Yöntemleri Kullanılarak Yapay Sinir Ağları İle Sınıflandırılması, Yüksek Lisans Tezi, Kahramanmaraş Üniversitesi, Fen Bilimleri Enstitüsü, 2005.
- [6] Altınbaş, A., EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşümü Ve Dalgacık Dönüşümü Kullanarak Analiz Edilmesi, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, 2007.
- [7] Demir, Ö., EEG Dalgalarının Wavelet (dalgacık) Dönüşümü İle Değerlendirilmesi, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
- [8] Oliviera, I., Grigori, O., Guimaraes, N., “EEG Signal Analysis For Silent Visual Reading Classification”, International Journal Of Circuits, Systems And Signal Processing, Issue 3, Volume 3, 2009, pp. 119-126.
- [9] Mostow, J., Chang, K.-M., Nelson, J., “Toward Exploiting EEG Input in a Reading Tutor”, AIED 2011. LNCS, Springer, Heidelberg 2011, pp. 230-237.
- [10] Federico Cirett Galán, Carole R. Beal, “EEG Estimates of Engagement and Cognitive Workload Predict Math Problem Solving Outcomes”, User Modeling, Adaptation, and Personalization(UMAP), 2012, pp. 51-62.
- [11] Übeyli, E.D. ve Güler, İ., “Dalgacık Dönüşümü İle EEG İşaretlerinden Çıkarılan Öznitelik Vektörleri Üzerinde İstatistiksel İşlemlerin Gerçekleştirilmesi”, Eleco 2004,s. 230-234.
- [12] Übeyli, E.D., “Wavelet/Mixture Of Experts Network Structure For Eeg Signals Classification”, Expert Systems with Applications, 2008, s. 1954-1962.
- [13] Strang, G., Nguyen, T., Wavelets and Filter Banks, Wellesley-Cambridge Press, 1997.
- [14] Lee, T.J., Park, S.M., Sim, K.B., “Electroencephalography Signal Grouping and Feature Classification Using Harmony Search for BCI”, Journal of Applied Mathematics 2013, pp. 1-9.
- [15] Burgess PW, “Strategy Application Disorder: The Role Of The Frontal Lobes In Human Multitasking”, Psychophysiology, 2000, pp. 279-288.
- [16] Çorapçioğlu, M.E., “TIPÇIT: Tıbbi Karar Destek Sistem Çekirdeği”, Yüksek Lisans Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, 2006.
- [17] Ben-Gal I., Bayesian Networks, in Ruggeri F., Faltin F. & Kenett R., Encyclopedia of Statistics in Quality & Reliability, Wiley & Sons, 2007.
- [18] Friedman, N., Geiger, D., Goldszmidt, M., “Bayesian Network Classifiers”. Machine Learning 29, 1997, pp. 131-163.

## Laguerre Fonksiyonları Kullanarak DA Motor Hızının Sürekli Zamanlı Model Öngörülü Kontrolü

Yahya DANAYİYEN<sup>1</sup> İsmail H. ALTAŞ<sup>2</sup>

<sup>1,2</sup>Elektrik Elektronik Mühendisliği Bölümü

Mühendislik Fakültesi

Karadeniz Teknik Üniversitesi, Merkez, TRABZON

yahya@ktu.edu.tr

ihaltas@ ktu.edu.tr

### Özet

*Bu çalışmada laguerre fonksiyonları kullanarak doğru akım motor hızının sürekli zamanlı model öngörülü kontrolü yapılmıştır. Kontrolör tasarımı durum uzayı modeli kullanılmıştır. Optimal giriş işaretinin elde edilmesinde kontrol işaretinin türevi kullanılmış ve işaretin elde edilmesinde Laguerre fonksiyonlarından yararlanılmıştır. Çalışmanın asıl amacı sistemin çıkışı olan motor hızının istenen referans değeri en iyi şekilde takip edebilmesi için en uygun kontrol işareti elde etmektir. Kontrol işareti ve referans hızla çıkış hızı arasındaki hatayı içeren maliyet fonksiyonunun minimizasyonunda kayan ufuk kontrol ilkesinden faydalanılmıştır. Sistem parametreleri (  $p$ : zaman skala faktörü,  $N$ : kullanılan terim sayısı,  $T_p$ : öngörü ufku ) değiştirilerek sonuçlar elde edilip karşılaştırılmıştır. Ayrıca sisteme PID kontrolör eklenmiş ve elde edilen sonuçlar klasik öngörülü kontrolör ile karşılaştırılmıştır.*

### 1. Giriş

Model Öngörülü Kontrol (MPC)'lün temel amacı maliyet fonksiyonunu minimize ederek sistem çıkışının bir sonraki değerini hesaplamak için en uygun kontrol sinyalini üretmektir. PID gibi klasik kontrol yöntemlerinin sistemdeki kısıtların üstesinden gelmede, ölü zaman gidermede, çok değişkenli sistemlerde zaman gecikmelerinin azaltılmasında etkili olmaması öngörülü kontrolün hızlı bir şekilde gelişmesini sağlamıştır. Bunun sonucu olarak öngörülü kontrol 1970'lerden sonra gerek endüstride gerek akademik çevrede hızlı bir şekilde kullanılmaya başlanmıştır. İlk defa 1970 yılında Richalet tarafından petro-kimya rafinerisinde kullanılan yöntem, Cutler ve Remarker'in Dinamik Matris Kontrol yöntemini geliştirmesiyle hızlı bir gelişim göstermiş ve 1987

yılında Remarker'in geliştirdiği Genelleştirilmiş Öngörülü Kontrol yöntemiyle kullanım alanı sanayi, güç sistemleri, robotik gibi alanlarda artmıştır. Öngörülü kontrol yöntemlerinin (DMC, GPC, MAC) matematiksel ifadelerinin açıklanması ve kontrolör tasarımında kullanılan yöntemlerin özetlendiği bir çalışma Holkar ve Wagmare tarafından yapılmıştır [1]. Birim basamak cevabı tekniği kullanılarak durum kestirim yöntemi geliştirilerek öngörülü kontrol için durum uzayı modelinin özetlendiği bir çalışma ise [2]'de yapılmıştır. Kısıtlamalı çok girişli çok çıkışlı aktif manyetik rulman sistemi için sürekli zamanlı model öngörülü kontrol yönteminin tasarlandığı bir çalışma [3]'te yapılmıştır. Laguerre fonksiyonları kullanarak ayrık zamanlı öngörülü kontrol tasarımı ve laguerre fonksiyonlarının parametrelerinin değiştirilerek optimizasyon probleminin tam olarak çözüldüğü bir çalışma [4]'te, laguerre fonksiyonlarının kontrol işaretinin elde edilmesinde kullanıldığı çalışmalar ise [5] ve [6] 'da yapılmıştır.

Bu çalışmada sürekli mıknatıslı doğru akım motor hız kontrolü için laguerre fonksiyonları kullanarak model öngörülü kontrolör tasarlanmıştır. Tasarlanan sistemime PID kontrolör eklenerek benzetim sonuçları karşılaştırılmıştır. Çalışmada sırasıyla 2. bölümde öngörülü kontrolün temel matematiksel ifadeleri verilmiş, kontrol işaretinin laguerre fonksiyonları kullanarak elde edilişi gösterilmiştir. Tasarımda kullanılan maliyet fonksiyonu yine bu bölümde verilmiştir. 3. Bölümde doğru akım motor modeli ve sistemin genel blok diyagramı gösterilmiştir. 4. Bölümde ise benzetim sonuçları gösterilmiştir.

### 2. Model Öngörülü Kontrol



Bozucu etki içermeyen sürekli zamanlı m girişli q çıkışlı bir sistemin durum uzayı modeli (1) ve (2)'de ifade edilmektedir.

$$\dot{x}_m(t) = A_m x_m(t) + B_m u(t) \quad (1)$$

$$y(t) = C_m x_m(t) + D_m u(t) \quad (2)$$

Durum uzayı modelini yardımcı matrislerle ifade etmek için yaklaşık değişkenler tanımlanarak yeni durum matrisi elde edilir.

$$z(t) = \dot{x}_m(t) \quad (3)$$

$$y(t) = C_m x_m(t) \quad (4)$$

Yeni durum matrisi (5)'teki gibi olur.

$$x(t) = [z(t)^T \quad y(t)^T]^T \quad (5)$$

Yeni durum vektörü kullanılarak yardımcı matrislerle gösterilen yeni durum uzayı modeli (6) ve (7)'deki gibi olur.

$$\begin{bmatrix} \dot{z}(t) \\ y(t) \end{bmatrix} = \begin{bmatrix} A_m & 0_m^T \\ C_m & 0_{qxq} \end{bmatrix} \begin{bmatrix} z(t) \\ y(t) \end{bmatrix} + \begin{bmatrix} B_m \\ 0_{qxm} \end{bmatrix} \dot{u}(t) \quad (6)$$

$$y(t) = [0_m \quad I_{qxq}] \begin{bmatrix} z(t) \\ y(t) \end{bmatrix} \quad (7)$$

Burada  $I_{qxq}$  birim matris,  $0_{qxq}$ ,  $0_{qxm}$ ,  $0_m$  ise sıfır matrislerdir.

## 2.1. Sistem durumlarının ve çıkışın öngörülmesi

Şuan ki zaman  $t_i$  'de belirli bir öngörü ufku  $T_p$  'de sistemin bir sonraki durumunun değerini ve sistemin çıkışının bir sonraki değerini veren öngörü ifadeleri sırasıyla (8) ve (9)'da ifade edilmiştir.

$$x(t_i + \tau | t_i) = e^{A\tau} x(t_i) + \int_0^\tau e^{A(\tau-\gamma)} B \dot{u}(\gamma) d\gamma \quad (8)$$

$$y(t_i + \tau | t_i) = C e^{A\tau} x(t_i) + C \emptyset(\tau)^T \eta \quad (9)$$

Burada  $\emptyset(\tau)$  konvolüsyon integralidir. Matlab'da hesaplatılmıştır. Optimizasyon probleminin çözümünde kullanılan maliyet fonksiyonu ise denklem (10)'te gösterilmiştir.

$$J = \int_0^{T_p} \left\{ (r(t_i + \tau) - y(t_i + \tau))^T Q (r(t_i + \tau) - y(t_i + \tau)) + \dot{u}(\tau)^T R \dot{u}(\tau) \right\} d\tau \quad (10)$$

Ağırlık parametreleri  $Q$  ( $Q \geq 0$ ) ve  $R$  ( $R \geq 0$ ) ayarlanarak maliyet fonksiyonunun en optimum şekilde minimizasyonu sağlanır.

## 2.2. Kontrol işaretinin elde edilmesi

Kontrol işaretinin elde edilmesinde laguerre fonksiyonları kullanılmıştır ve kontrol işaretinin türevinin bu fonksiyonlarla nasıl elde edildiği [6]'da detaylı olarak açıklanmaktadır. Eğer sistemde sabit referans işareti veya bozucu etki mevcutsa, kontrol işaretinin sifira yakınsaması zor olur. Çünkü kontrol işareti, referans yörüngesini takip edebilmesi için referans sinyalinin büyüklüğü ve sistemin sürekli hal kazancıyla ilişkili sıfır olmayan sabit bir değere yakınsamaya ihtiyaç duyar. Bundan dolayı sistemin girişi olarak kontrol işaretinin türevi alınmıştır [6].

Belirli bir öngörü ufku  $T_p$  ve şu anki zaman  $t_i$  'de kapalı çevrim sistemin ifadesi sırasıyla (11) ve (12)'te gösterilmiştir.

$$x(\tau) = e^{(A-BK)\tau} x(t_i) \quad (11)$$

$$\dot{u}(\tau) = -K e^{(A-BK)\tau} x(t_i) \quad (12)$$

Kontrol işaretinin türevi laguerre fonksiyonları ile aşağıdaki gibi elde edilir.

$$\dot{u}(\tau) = \sum_{i=1}^N c_i l_i(\tau) = L(\tau)^T \eta \quad (13)$$

$$\eta = [c_1 \quad c_2 \quad \dots \quad c_N]^T \quad (14)$$

m girişli bir sistem için kontrol vektörü:

$$\dot{u}(\tau) = [\dot{u}_1(\tau) \quad \dot{u}_2(\tau) \quad \dots \quad \dot{u}_m(\tau)]^T \quad (15)$$

Kayan ufuk kontrol prensibi gereği sisteme en uygun şekilde hesaplanan kontrol işaretinin ilk değeri uygulanır (16) ve geri kalanları sıfır sayılır.

$$\dot{u}(t)_i = \begin{bmatrix} L_1(0)^T & 0_2 & \cdot & \cdot & 0_m \\ 0_1 & L_1(0)^T & \cdot & \cdot & 0_m \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0_1 & 0_2 & \cdot & \cdot & L_m(0)^T \end{bmatrix} \begin{bmatrix} \eta_1 \\ \eta_1 \\ \cdot \\ \cdot \\ \eta_m \end{bmatrix} \quad (16)$$

### 2.3. Sistemin Tanımı

Bu çalışmada sabit miktatlı doğru akım motorun durum uzayı denklemleri kullanılmıştır. Motora ait durum uzayı modeli (17) ve (18)'de gösterilmiştir. Motorun parametreleri ise tablo 1'de verilmiştir.


$$\begin{bmatrix} \frac{di_a(t)}{dt} \\ \frac{dw(t)}{dt} \\ \frac{d\theta(t)}{dt} \end{bmatrix} = \begin{bmatrix} -\frac{R}{L} & -\frac{K_m}{L} & 0 \\ \frac{K_m}{J} & -\frac{K_f}{J} & 0 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i_a(t) \\ w(t) \\ \theta(t) \end{bmatrix} + \begin{bmatrix} \frac{1}{L} \\ 0 \\ 0 \end{bmatrix} V(t) \quad (17)$$

$$y(t) = \begin{bmatrix} 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i_a(t) \\ w(t) \\ \theta(t) \end{bmatrix} \quad (18)$$

Sürekli zamanda model öngörülü kontrolör tasarlanarak sistemin denetlenmesine ait blok diyagram şekil 1'de gösterilmektedir. Şekil 1'den sistemin durum geri beslemeli bir sistem olduğu görülmektedir.

Tablo 1. DA Motor parametreleri.

Açıklama	Sembol	Değer
Armatür direnci	$R$	1.4 $\Omega$
Armatür endüktansı	$L$	0.0805 H
Sürtünme Katsayısı	$K_f$	0.095 N.m.s/rad
Zıt emk sabiti	$K_m$	0.095 V.s/rad
Eylemsizlik momenti	$J$	7.432e-4 kg.m <sup>2</sup>



Şekil 1. Sistemin genel gösterimi

Şekil 1'deki gösterimde PID kontrolör de mevcuttur. Sistemin gürbüzlüğünü arttırmak için kullanılan bu yöntemle PID olmadan tasarlanan yöntem karşılaştırılmıştır. Referas hız olarak 156 rad/sn alınmıştır. Kontrolör tasarımında Matlab yazılımı kullanılmıştır.

### 3. Sonuçlar


Tasarlanan sistemin ayar parametreleri değiştirilerek elde edilen sonuçlar karşılaştırılmıştır. Zaman skala faktörü  $p$ , kullanılan terim sayısı  $N$ , öngörü ufku  $T_p$  ve PID parametresinin farklı değerleri için elde edilen sonuçlar gösterilmiştir. Zaman skala faktörünü sabit tutup terim sayısı artırıldığında sistemdeki aşmanın azaldığı görülmüştür. Şekil 2 ve şekil 3 incelendiğinde bu durum açık olarak görülmektedir. Terim sayısı kontrol işaretinin laguerre fonksiyonunu yakalamasında etkili olmaktadır.  $K_p$  değeri azaltıldığında sistemdeki aşmanın azaldığı ancak oturma zamanının arttığı görülmektedir. Kontrol işaretine uygulanan ağırlık parametresini değiştirerek oturma zamanının azaltılabildiği görülmüştür.  $p$  değeri artırıldığında sistemdeki aşmanın azaldığı görülmüştür. Şekil 4'te bu durum görülmektedir. Tablo 2'de ise şekillerin elde edilmesinde kullanılan parametre değerlerine göre sistemin geri besleme kazancının aldığı değerler görülmektedir.  $N$  terim sayısı artırıldığında kontrol işaretinin serbestlik derecesi de artmaktadır.

Ağırlık parametreleri değiştirildiğinde istemin kapalı çevrim cevabında önemli değişiklikler olmaktadır. Şekil 4'te görüldüğü gibi aşmanın önemli ölçüde azalmasının sebebi kontrol işareti üzerine uygulanan  $R$  ağırlık parametresidir. Bunun yanında dezavantaj olarak kontrol işaretinin türevin değerinde önemli ölçüde artma meydana gelmektedir.


Tablo 2.  $K_{MPC}$  değerleri.

Tasarım parametreleri	$K_{mpc}$ matrisi
$T_p = 10, p = 3, N = 4$	[0.2849 -0.0026 0 5.3057]
$T_p = 10, p = 1, N = 2$	[0.1425 -0.0013 0 2.6539]
$T_p = 5, p = 1, N = 4$	[0.1412 -0.0013 0 2.6371]






Şekil 2. Sistemin MPC ve PID-MPC ile simülasyonu ( $T_p = 10, p = 3, N = 4, K_p = 30, K_I = 1, K_D = 0,9$ )



Şekil 3. Sistemin MPC ve PID-MPC ile simülasyonu ( $T_p = 10, p = 1, N = 2, K_p = 10, K_I = 1, K_D = 0,9$ )

#### 4. Değerlendirme

Bu çalışmada ortonormal fonksiyonlar kullanılarak sürekli zamanda model öngörülü kontrolör tasarlanmıştır. Sistemin arzu edilen kapalı çevrim performansına kolaylıkla ulaşabilmek için laguerre fonksiyonları ayar parametrelerinin etkili bir biçimde kullanılabilmesini benzetim sonuçları göstermiştir. Yine aynı şekilde tasarıma eklenen PID kontrolörün parametreleri de değiştirilerek sistemin davranışında iyileştirmeler yapılabildiği gözlemlenmiştir. Sistemin davranışı PID-MPC ve sadece MPC kontrolör uygulanarak incelenmiş ve sonuçlar karşılaştırmalı olarak gösterilmiştir. Kullanılan öngörülü kontrol yöntemi ve öngörülü kontrolör tasarım aşamaları matematiksel ifadeleriyle birlikte verilmiştir.



Şekil 4. Sistemin MPC ve PID-MPC ile simülasyonu ( $T_p = 5, p = 1, N = 4, K_p = 10, K_I = 1, K_D = 0,9$ )

#### 5. Kaynaklar

- [1] K.S. Holkar, L.M. Wagnare, "An Overview of Model Predictive Control", International Journal of Control and Automation, Aralık,2010, Vol. 3 No. 4.
- [2] J.H. Lee, M. Morari, C.E. Garcia, "State-Space Interpretation of Model Predictive Control", Automotive, Nisan,1994, s. 707-717.
- [3] J. Huand, L. Wang, Y. Huang, "Continuous Time Model Predictive Control for a Magnetic Bearing System", Progress In Electromagnetics Research Symposium, Mart, 2007, Çin.
- [4] B. Khan, J.A. Rossiter, "Triple Mode MPC or Laguerre MPC: a comparison", American Control Conference, Haziran 29-Temmuz-01, 2011, San Fransisco.
- [5] J.A. Rossiter, L. Wang, "Exploiting Laguerre functions to improve the feasibility/performance compromise in MPC", Decision and Control, Aralık, 2008, Cancun.
- [6] L. Wang, "Continuous time model predictive control design using orthonormal functions", International Journal of Control, Kasım, 2010, Cancun, s. 1588-1600.
- [7] A.M. Sharaf, İ.H. Altaş, E. Özkop, "Elektrikli Araçlar İçin Çift Çevrim Destekli DA Motor Kontrol Uygulaması", XII. EEBB Mühendisliği Ulusal Kongresi Ve Fuarı, Eskişehir, Kasım 14-18,2007.
- [8] A.M. Sharaf, E. Elbakush, İ.H. Altaş, "A Predictive Dynamic Controller For PMDC Motor Drivers ", The Fifth International Conference on Industrial Automation, Montreal,Quebec,Canada, June 11-13, 2007.

## Hipertiroidili Hastalarda Kognitif Fonksiyonların İncelenmesi

Miray ALTINKAYNAK<sup>1</sup> Ayşegül GÜVEN<sup>2</sup> Nazan DOLU<sup>3</sup> Kürşat ÜNLÜHİZARCI<sup>4</sup>

<sup>1,2</sup>Biyomedikal Mühendisliği Bölümü  
Mühendislik Fakültesi

<sup>3</sup>Fizyoloji Bölümü, <sup>4</sup>Endokroloji Bölümü  
Tıp Fakültesi  
Erciyes Üniversitesi, KAYSERİ

Email: miray@erciyes.edu.tr, aguven@erciyes.edu.tr, dolu@erciyes.edu.tr, kursad@erciyes.edu.tr

### Özet

*Yapılan çalışma ile toplumda sıkça karşılaşılan hipertiroidi hastalığındaki kognitif fonksiyonlar, hastalara ait işitsel uyarılmış sinyallerden çıkarılan özelliklerle objektif bir şekilde yorumlanmıştır. 26 hipertiroidili ve 26 sağlıklı kişide gerçekleştirilen çalışmada, ERP kayıtları MP150 sistemi ile 10-20 sistemine göre yerleştirilen elektrodlarla alınmıştır. Standart işitsel oddball paradigması görevi uygulanıp, görev olarak farklı işitsel uyarılara karşılık sağ ve sol ellerindeki butonlara basmaları istenmiştir. Verilen göreve göre gruplar arasındaki P300 latans ve genlikleri karşılaştırıldığında, hipertiroidili hastalarda, kontrol grubuna göre P300 latansında uzama ve P300 genliğinde yükselme bulunmuştur. Hipertiroidili hastalarda P300 latansında uzama kognitif bilgilenme sürecinde gecikmeyi, artmış P300 genliği ise kognitif bilgilenme ve dikkat aktivitesinde artmayı göstermektedir.*

### 1. Giriş

Tiroid hormonları gerek normal fizyolojik fonksiyonların sürdürülmesinde gerekse kognitif fonksiyonlarda çok önemli bir yer almaktadır. Düşünmek, algılamak ve belleğe yerleştirmek gibi zihinsel yetilerin hepsi “kognitif fonksiyon” genel teriminin içerisinde yer alır..

Yapılan birçok çalışmada hipotiroidili hastalarda konsantrasyon olma güçlüğü, mental aktivitenin yavaşladığı, bilgilerin geri çağrılmasında bozulma olduğu, kısa süreli hafızanın gerilediği ve psikomotor becerilerin bozulduğu gösterilmiştir [1] ve tedavi edilmeyen uzun süreli hipotiroidi durumlarında

kognitif fonksiyonların geriye döndürülemediği bildirilmiştir.

Hipertiroidili hastaların dikkat, görsel hafıza, kelime hafızası gibi kognitif fonksiyonları Standardize Mini Mental Test (SMMT), Benton test ve Rey'in şekilleri, görsel hafıza testleri, kelime öğrenme ve kule yapma testi gibi çeşitli nöropsikiyatrik testlerle araştırılmış, bazı çalışmalarda bozukluk olduğu öne sürülürken [2], bazılarında normal olduğu saptanmıştır [3]. Nöropsikiyatrik testler, kognitif fonksiyonların değerlendirilmesinde önemli yere sahip olmasına rağmen, testin uzman olmayan kişiler tarafından uygulanması, bulunulan ortamın gürültülü olması, hastanın eğitim durumu gibi olumsuz ortam ve/veya kişi faktörleri testin güvenilirliğini ortadan kaldırmaktadır. Bu projede hipertiroidili hastaların kognitif fonksiyonları daha spesifik ve objektif bir ölçüm olan uyarılmış potansiyeller (UP) ile araştırılacaktır.

Uyaran veya olaya reaksiyonda beyinde oluşan ve başın saçlı derisinden kaydedilen elektriksel değişikliklere uyarılmış potansiyeller denir. Temelde bu yöntemde, denekler bilişsel görevlerle meşgul edilirken EEG kaydı alınmaktadır. EEG'nin bölümleri spesifik uyarılara eş zamanlı oluşur ve ortalaması alınır. Bunlar beynin bir olaya veya uyarıya reaksiyonunu temsil eder ve UP'ye karşılık gelirler.

Uyarılmış İşitsel Potansiyeller (UIP), işitsel uyarana bir cevap olarak kortikal aktivitedeki lokal değişikliklerden meydana gelirler. Uyarının önemi konusunda bilinçli bir karar verilmesi gerekiyorsa ya da ilgili görevde belirli bir cevap verilmesi isteniyorsa UP dalga formu bu uyarana karşı büyük pozitif bileşen gösterir ve bu genellikle P300 kompleksi olarak adlandırılır. P300 dalgasının, hafızanın güncellenmesi ve dikkat etmenin altında yatan

kognitif süreçleri yansıttığı bildirilmektedir [4]. P300 latansı, ödevle ilişkili uyarıyı tanımak için geçen süreyi, P300 genliği ise, dikkat, beklenti ve uyarının önemi ile ilişkili bilişsel işlevleri yansıtır ve kognitif fonksiyonların kantitatif değerlendirilmesinde yaygın olarak kullanılmaktadırlar [5].

Uyarılmış potansiyeller beyin işlevinin anlaşılması için, şizofreni [6], Parkinson [7], epilepsi [8], alzheimer [9] gibi beyinle ilgili birçok hastalığın araştırılmasında kullanılmıştır. Bu hastalıklardaki ÜİP sinyallerinin analizlerinde genellikle zaman domeninde, işaretteki belli pik noktaların (P50, P300 vs.) latans ve genlik bilgisi gibi özelliklerin kullanımı üzerine yoğunlaşmıştır.


Çalışmamızda, hipertiroidi tanısı konmuş ancak henüz ilaç tedavisine başlanmamış hastalardaki kognitif bozuklukları incelemek amacıyla işitsel oddball paradigması görevi süresince beyin dalgaları kaydedildi. Oddball paradigması esnasında gönüllülere dinledikleri seslerle ilişkili görevler verilerek ellerindeki butonlara basmaları istendi. P300 dalgaları beynin direk aktivitesi olup diğer nöropsikiyatrik testler gibi dış uyarılardan etkilenmediğinden, butona doğru bastıkları zamanlardaki P300 dalgaları değerlendirilerek dikkat düzeyleri ölçülmüş oldu. Farklı görevlerde P300 dalgaları ölçülerek, görev yükünün dikkate etkisi değerlendirildi. Ayrıca farklı beyin bölgelerinden kayıt yapılarak, beynin hangi bölgesinin etkilendiği araştırıldı.

## 2. Yöntem

### 2.1 Çalışma Grubu ve Kayıtlar


Araştırma, Erciyes Üniversitesi Tıp Fakültesi İç Hastalıkları AD. Endokrinoloji Polikliniğine ayaktan başvuran, bilgilendirilmiş onam formunu imzalayan ve hipertiroidi tanısı alan 26 hasta ve 26 sağlıklı bireyde yapılmıştır. Elektrofizyolojik kayıtlar, Fizyoloji AD'da bulunan MP150 sistemi (Biopac, ABD) ve bu sisteme uyumlu 8 adet EEG amplifikatörleri ile alınmıştır.

Kayıtlar için uluslararası 10-20 sistemine göre gönüllülerin kafasına yerleştirilen ve saçlı deri için tasarlanan özel Ag/AgCl elektrotlar kullanılmıştır. ÜİP'ler, beynin frontal (Fz, Fp1, Fp2), santral (Cz), parietal (Pz, P3, P4) ve oksipital (Oz) bölgelerinden kaydedilmiştir. Referans noktası, her iki kulak memesine yerleştirilen Ag-AgCl disk elektrotlarının bileşkesi olarak alınmıştır.



Şekil 1. Uluslararası 10/20 sistemine göre elektrodların yerleşiminin şematik gösterimi

Referans ve kayıt elektrotları uygun şekilde yerleştirilerek, ilk önce spontan EEG, ardından oddball işitsel uyarı modeli kullanılarak ÜİP kayıtları alınmıştır. Test boyunca denekten, hedef uyarıyı her duyduğunda sağ elindeki butona basması ve hedef olmayan uyarıyı önemsememesi istenmiştir. EEG işaretlerinden her bir uyarıya karşılık gelen cevaplar üst üste toplanarak ÜİP sinyali elde edilmiştir. Şekil 1' de kontrol grubundan elde edilen örnek bir ÜİP sinyali gösterilmiştir.



Şekil 2: Kontrol grubundan ÜİP örneği

### 2.2 Lineer Diskriminant Analizi

Diskriminant analizi (DA), sınıflandırma modellerinin geliştirilmesinde kullanılan, istatistiksel sınıflandırma yöntemidir. Nesnelerin sınıflandırılmasında genel olarak bazı matematiksel eşitliklerden yararlanır. Diskriminant fonksiyonları olarak adlandırılan bu eşitliklerden faydalanılarak birbirine en çok benzeyen sınıfların oluşturulması için sınıfların ortak özellikleri belirlenmeye çalışılır. Ayırma amacı ile kullanılan bu

sınıf karakteristikleri diskriminant değişkenleri olarak adlandırılır. Kısaca, iki veya daha fazla sınıfa ait farklılıkların bu diskriminant değişkenleri ile ortaya konulur [10].

Sonuçlar genellikle grup içi oranları, gruplar arası oranları ve de toplam varyansı da içeren bir kurala göre hesaplanmaktadır.

Matematiksel ifade aşağıdaki gibidir:

$$f_{km} = u_0X_{1km} + u_1X_{2km} + \dots + u_pX_{pkm} \quad (1)$$

Burada;

$f_{km}$ = m durumunun k grubunda doğal diskriminant fonksiyonundaki değeri;

$X_{ikm}$ = m durumunun k-ıncı grupta  $X_i$  ayırt edici fonksiyonundaki değeri;

$u_i$ = fonksiyonda istenen özellikleri üreten katsayılarıdır.

Böyle bir fonksiyon bulunurken amaç, gruplar arası kareler toplamının, gruplar içi kareler toplamına oranını maksimum yapacak p adet özelliği ayıracak doğrusal bileşeni bulmaktır.

Yani,

$$F = \max \left( \frac{\text{Gruplar Arası Varyans}}{\text{Grup İçi Varyans}} \right) \quad (2)$$

### 3. Sonuçlar

Tablo 1’de uyarılma potansiyeli P300 latanslarının, Tablo 2’de uyarılma potansiyeli P300 genliklerinin elektrot yerleştirme bölgelerine göre ortalama değerleri ve ANOVA ile bölgelere göre yapılan grup içi istatistiksel karşılaştırmaları görülmektedir. Yapılan analizde her 2 grupta da P300 latans ve genliklerinde bölgelere göre istatistiksel farklılık bulunmamıştır. ( $p>0.05$ ). Bu yüzden yapılan gruplar arası karşılaştırmalar sadece Fz bölgesinde gerçekleştirilmiştir.

Tablo 1. P300 latanslarının (msn) bölgelere göre ortalamaları ve grup içi istatistiksel karşılaştırmaları (ortalama  $\pm$ SH)


Elektrotlar	Kontrol grubu	Hipertiroidili grup
Fz	314.0 $\pm$ 8.0	427.0 $\pm$ 9.0
FP1	316.1 $\pm$ 7.6	430.8 $\pm$ 7.5

FP2	318.6 $\pm$ 7.2	428.2 $\pm$ 9.0
Cz	318.7 $\pm$ 6.7	432.8 $\pm$ 6.9
Pz	318.6 $\pm$ 6.7	427.0 $\pm$ 9.0
P3	322.2 $\pm$ 5.6	427.8 $\pm$ 8.8
P4	320.5 $\pm$ 6.3	428.8 $\pm$ 8.7
Oz	321.5 $\pm$ 5.9	435.8 $\pm$ 8.6

Tablo 2. P300 genliklerinin ( $\mu$ V) bölgelere göre ortalamaları ve grup içi istatistiksel karşılaştırmaları (ortalama  $\pm$ SH)

Elektrotlar	Kontrol grubu	Hipertiroidili grup
Fz	13,14 $\pm$ 0,60	27,75 $\pm$ 0,87
FP1	13,56 $\pm$ 0,53	28,18 $\pm$ 0,79
FP2	13,29 $\pm$ 0,55	28,07 $\pm$ 0,94
Cz	14,36 $\pm$ 0,44	29,22 $\pm$ 0,74
Pz	14,46 $\pm$ 0,38	29,17 $\pm$ 0,71
P3	13,78 $\pm$ 0,49	29,18 $\pm$ 0,62
P4	14,19 $\pm$ 0,39	28,84 $\pm$ 0,60
Oz	14,17 $\pm$ 0,44	29,61 $\pm$ 0,69

Fz bölgesinden alınan kayıtlar lineer diskriminant analizi ile sınıflandırılmış ve kontrol grubu ve hipertiroidili grup başarıyla birbirinden ayrılmıştır. (Şekil 3)



Şekil 3: Sınıflandırma Sonuçları

### 4. Tartışma

Uyarılmış potansiyellerden P300 dalgası kognitif fonksiyonun araştırıldığı çalışmalarda sıklıkla kullanılmaktadır. Beynin farklı bölgelerindeki etkilenmeleri yansıtması, hastanın motivasyonunun veya eğitim durumunun kayıtları etkilememesi, kognitif fonksiyon bozukluklarını daha erken saptayabilmesi bakımından UP’lerin standart kağıt

üzerindeki testlere üstünlükleri bulunmaktadır. Çalışmamızda, hipertiroidi tanısı konmuş ancak henüz ilaç tedavisine başlanmamış hastalarda ve sağlıklı gönüllülerde işitsel oddball paradigması süresince beyin dalgaları kaydedildi. Gönüllülere dinledikleri seslerle ilişkili görevler verilerek ellerindeki butonlara basmaları istendi. P300 dalgaları beyin direk aktivitesi olup diğer nöropsikiyatrik testler gibi dış uyaranlardan etkilenmediğinden, butona doğru bastıkları zamanlardaki P300 dalgaları değerlendirilerek dikkat düzeyleri ölçülmüş oldu. Farklı görevlerde P300 dalgaları ölçülerek, görev yükünün dikkate etkisi değerlendirildi. Ayrıca farklı beyin bölgelerinden kayıt yapılarak, beyin hangi bölgesinin etkilendiği araştırıldı.

Hipertirodi durumunda kognitif bozuklukların incelendiği, Özata vd. yaptıkları çalışmada 20 hipertiroidili hastanın 4'ünde oddball P300 latansında istatistiksel olarak anlamlı uzama olduğunu, diğer 16 hastanın ise normal P300 latansına sahip olduğunu bulmuşlardır. Ancak çalışmalarında P300 genliklerini değerlendirmemişlerdir [11] Münte ve ark.'nın çalışmasında [12] subklinik hipertiroidide oddball paradigması ile P300 dalga genliğinde azalma olduğu bulunmuştur. Bir diğer çalışmada ise UİP de kontrol grubuna göre hipertiroidide herhangi bir değişiklik gözlenmemiştir [13]. Bizim çalışmamızda farklı beyin bölgelerinden alınan P300 latans ve genlik bilgilerinden bölgelere göre istatistiksel farklılık bulunmamıştır. ( $p>0.05$ ). Yapılan çalışma ile hipertiroidili bireylerin kognitif fonksiyonların kontrol grubundan belirgin bir şekilde farklılık gösterdiği, kontrol grubu ile karşılaştırıldığında P300 latansında uzama ve P300 genliğinde yükselme gözlenmiştir.

## 5. Teşekkür

Çalışmamız TÜBİTAK 1001 proje kapsamında 108S249 proje numarası ile destek almıştır.

## 6. Kaynaklar

- [1] Cooke G, Mullally S, Correia N, vd.2013. "Hippocampal Volume is Decreased in Adult-Onset Hypothyroidism", *Thyroid*, 433-440.
- [2] Zhang W., Song L., Yin, X., Zhang, J vd. 2014. "Grey matter abnormalities in untreated hyperthyroidism: A voxel-based morphometry study using the DARTEL approach". *European Journal of Radiology*, 83 (1), 43-48.

- [3] Lillevang-Johansen M, Petersen I, vd. . 2014. "Is previous hyperthyroidism associated with long-term cognitive dysfunction? A twin study" *Clin Endocrinol (Oxf)*, 80(2), 290-5
- [4] Picton, T.W. 1992. "The P300 wave of the human event related potential", *J Clin Neurophysiol*, 9, 456-479.
- [5] Dolu, N., Basar-Eroglu, C., Özemsi, Ç., Süer, C. 2005. "An assessment of working memory using P300 wave in healthy subjects", *International Congress Series*, 1278, 7-10.
- [6] Jansen B.H. vd. 2010. "Auditory Evoked Potential Variability in Healthy and Schizophrenia Subjects", *Clinical Neurophysiology*, 121, 1233-1239.
- [7] Margaret M., Hallett M., 2013, "Effect of cued training on motor evoked potential and cortical silent period in people with Parkinson's disease" *Clinical Neurophysiology*, 124, 545-550.
- [8] Caravaglios G. vd. 2001. "Auditory Event-related Potentials (P300) in Epileptic Patients". *Neurophysiol. Clin.*, 31, 121-129.
- [9] Limongi F. vd. 2013. "Somatosensory Evoked Potentials and Pain Assessment in Alzheimer's Disease, *European Geriatric Medicine*, 4, 384-388]
- [10] Çamdeviren H. Lojistik Regresyon ve Diskriminant Analizi, Doktora Tezi, Ankara Üniversitesi, Ankara, 2000: 89-91.
- [11] Özata, M., Ozkardes, A., Corakei, A., Beyhan, Z., Gundogan, M.A. 1997. "Event related brain potentials in patients with hypothyroidism", *Endocr. Pract.*; 3, 349-352.
- [12] Münte T.F., vd. 2001. "Alterations of Cognitive Functions Induced by Exogenous Application of Thyroid Hormones in Healthy Men: A Double-Blind Cross-Over Study Using Event-Related Brain Potentials", *Thyroid*, 11 (4), 385-391, (2001).
- [13] Thornton A.R.D. ve Jarvis S.J. 2008. "Auditory brainstem response findings in hypothyroid and hyperthyroid disease", *Clinical Neurophysiology*, 119, 786-790

## BİLGİSAYAR GÖRMESİ VE GRADYAN İNİŞ ALGORİTMASI KULLANILARAK ROBOT KOL UYGULAMASI

Bilal İŞÇİMEN<sup>1</sup> Hüseyin ATASOY<sup>2</sup> Yakup KUTLU<sup>3</sup>  
Serdar YILDIRIM<sup>4</sup> Esen YILDIRIM<sup>5</sup>

<sup>1,2,3,4,5</sup>Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
Mustafa Kemal Üniversitesi, İskenderun, HATAY

{<sup>1</sup>biscimen, <sup>2</sup>hatasoy, <sup>3</sup>ykutlu, <sup>4</sup>serdar, <sup>5</sup>eyildirim}@mku.edu.tr

### Özet

*Bu çalışmada bilgisayar görmesi ve robot kol uygulaması birleştirilerek gören, bulan, tanıyan ve görevi gerçekleştiren bir akıllı robot kol uygulaması gerçekleştirilmiştir. Bu amaçla yemek servisinde kullanılan malzemeleri tanıyarak bunları servis düzeninde dizen veya toplayan bir akıllı robot kol tasarlanmıştır. Yemek servisinde kullanılan malzemelerin resimleri toplanarak yeni bir veri tabanı oluşturulmuştur. Oluşturulan sistem veri tabanındaki malzemeleri görüntü işleme teknikleri kullanarak sınıflandırıp etiketleyerek ilgili objelerin koordinatlarını robot kola göndermektedir. Verilerin sınıflandırılmasında kNN sınıflandırıcı kullanılmış ve %90 başarımla elde edilmiştir. Daha sonra robot kol eklem açıları gradyan iniş yöntemiyle hesaplanarak hareketini yapması sağlanmıştır.*

### 1. Giriş

Bilgisayar görmesi, resimlerden gerçek dünyayı tanımlayıcı veriler elde eden bir alandır. Bilgisayar görmesinin amacı, görüntüleri almak, işlemek, analiz etmek ve anlamlı verileri elde etmek için metotlar kullanarak insan görüsü yeteneklerini sayısal ortamda taklit etmektir [1, 2]. Görüntü anlama geometri, fizik, istatistik ve öğrenme teorisi ile yapılandırılmış modeller kullanarak görüntü verisinden simgesel bilgi çözülmesi olarak görülebilir [3].

Bilgisayar görmesi birçok alanda kullanılan otomatik görüntü analizi teknolojisini kapsar. Birçok bilgisayar görmesi uygulamasında bilgisayarlar belirli bir görevi yerine getirmek için önceden programlanmıştır, fakat öğrenmeye dayalı metotlar giderek yaygınlaşmaktadır. Otomasyonlu kontrol işlemleri, navigasyon, olayların algılanması, objelerin ve çevrenin modellenmesi gibi işlemler için oluşturulmuş

sistemler bilgisayar görmesi uygulamaları için verilebilecek örneklerdendir.

Bilgisayar görmesindeki temel problem görüntü işleme ve görüntü verisinin bir obje, özellik veya aktivite içerip içermediğini belirlemektir. Bu iş bir insan tarafından kesin sonuçla ve zahmetsiz bir şekilde yapılabilir, fakat hala bilgisayar görmesi ile rastgele durumlardaki rastgele objeler için tatmin edici bir şekilde gerçekleştirilememiştir. Bu sorunu çözmek için var olan yöntemlerin en iyi başarımları basit geometrik şekiller, insan yüzleri, basılı ya da elle yazılmış karakterler ya da araçlar gibi belirli objeleri ve özel koşullar altında, genellikle iyi aydınlatılmış, arka planı ve pozunu kameraya göre ayarlanmış objeleri tanımlar.

Literatürde konu ile ilgili herhangi bir çalışma olmadığından dolayı veri sınıflandırma başarısının karşılaştırılması yapılamamaktadır. Fakat bilgisayar görmesi, görüntü işleme teknikleri ve robot veya robot kol birleşiminden meydana gelen, performans ölçümü verilmeyen laboratuvar çalışmaları mevcuttur.

Yapılan çalışmaların birinde bir dama tahtasının iç köşelerini otomatik olarak tanımak için düzlemsel bir dama tahtası resmi üzerindeki yerel yoğunlukların karakteristiği ve ızgara yapısının mimarisi kullanılacak bir yaklaşım önerilmiştir. Önerilen yöntem resmin köşelerinin tespit edilmesi, siyah ve beyaz kare kesişimlerindeki köşelerin tanınması ve ızgara çizgilerinin kesişim yerlerindeki köşelerin tanınmasından meydana gelmektedir. Yapılan deneyler önerilen sistemin kamera kalibrasyonu için zaman maliyetini azalttığını, kalibrasyon işlemini hızlandırdığını ve özellikle birden fazla görüntü temelli otomatik kalibrasyon için uygun olduğunu açıkça göstermiştir [8].

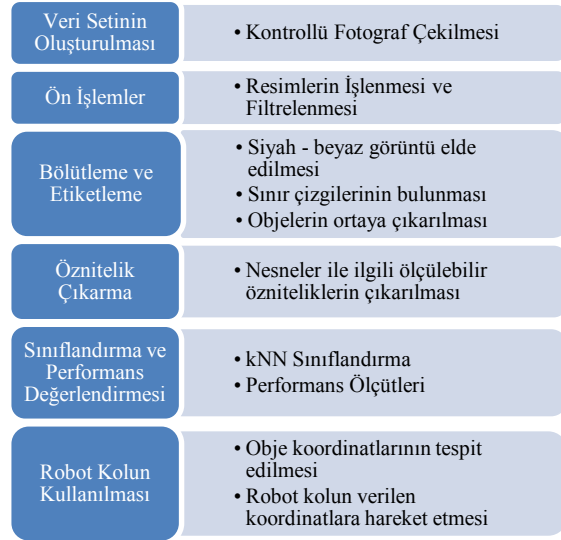
Başka bir çalışmada taş, kağıt, makas oyunu oynayabilen bir robot tasarlanmıştır. İnsan ve robot oyunu karşılıklı olarak oynamaktadır. İnsan elinin şeklinin tanınması oluşturulan görüntü işleme sistemi ile gerçekleştirilmiştir. Robot taş, kağıt, makas hamlelerinden birini rastgele oynamakta ve kişinin hamlesi ile karşılaştırmaktadır. Kazanma ya da kaybetme durumuna göre ses, vücut hareketi ve yüz mimikleri ile tepkiler göstermektedir [9].

Robotun taş, kağıt, makas oynaması üzerine kurulu diğer bir çalışmada oyunu %100 kazanma oranıyla oynayan bir robot el geliştirilmiştir. Kişi “bir, iki, üç” şeklinde bir zamanlama ile taş, kağıt, makastan birini oynamaktadır. Robot el de bu zamanlamaya uyarak kişiyi yenmek için bu üç seçenekten birini oynar. İnsan elinin tanınması yüksek hızlı bir görme ile 1 milisaniyede gerçekleştirilir ve elin konumu ve şekli tanınır. Robot el bileğinin açısı insan elinin konumuna göre kontrol edilir. Görme ile insan elinin şekline bağlı olarak taş, kağıt, makastan biri tanınır. Böylece robot el kişiyi yenmek için taş, kağıt, makas arasından gerekli olan hamleyi oynar [10].

Bu çalışmada bilgisayar görmesi ve robot kol uygulaması birleştirilerek gören, bulan, tanıyan ve görevi gerçekleştiren bir akıllı robot kol uygulaması gerçekleştirilmiştir.

## 2. Materyal ve yöntem

Bu bölümde yemek servisi malzemeleri ile ilgili verilerin elde edilmesi, verilerin hazırlanmasında yapılan ön işlemler, veriler için kullanılacak öznelik çıkarma yöntemleri, sınıflandırma, sınıflandırmada başarı performansı ve robot kolun kullanılması anlatılmaktadır. Şekil 1’de önerilen sistemde uygulanan adımlar gösterilmektedir.



Şekil 1: Önerilen sistemde uygulanan adımlar

### 2.1. Verilerin elde edilmesi

Bu çalışmada yemek servisinde kullanılan malzemelerden tabak, çatal, kaşık, bıçak ile ilgili bir veri tabanı oluşturulmuştur. Her nesnenin koyu renkli bir fon üzerinde nesnenin kendisi zemin üzerinde farklı açılarla farklı konumlarda bulunacak şekilde dik bir açı ile resimleri çekilmiş ve veri tabanına kaydedilmiştir.

Elde edilen veri tabanındaki nesnelere ve dağılımları ile ilgili bilgiler Tablo 1’de gösterilmiştir. Ayrıca, sistemi test etmek için farklı sayı ve dağılımlarda yerleştirilmiş karışık nesnelere oluşan resimler de çekilmiştir. Toplam 150 adet olan bu resimlerden bir örnek Şekil 2’de verilmiştir.

Tablo 1: Toplanan veri setindeki nesne dağılımı

Nesne	Veri Sayısı
Büyük bıçak	36
Küçük bıçak	75
Oval tabak	48
Yassı tabak	30
Kaşık	69
Çatal	65
<b>Toplam</b>	<b>323</b>





Şekil 2: Test verisi örneği

## 2.2. Ön işlemler

Bilgisayar görmesinde bir görüntü elde edilmesinden itibaren görüntü ve içerisindeki objeler ile ilgili yorum yapılabilmesi için görüntü üzerinde birçok işlem gerçekleştirilir [4]. Ön işleme, görüntü verisinden bilgiler elde etmek için görüntü üzerinde bir yöntem uygulanmadan önce veriyi yöntem tarafından ihtiyaç duyulacak hale getirme işlemidir. Yeniden ölçekleme, görüntü temizleme, kontrast iyileştirme buna örnek verilebilir.

## 2.3. Objelerin bulunması ve öznelik çıkarma

Elde edilen malzeme resimleri görüntü işleme teknikleri ile işlenmiş ve resimlerdeki objeler ortaya çıkarılmıştır. Bunun için aşağıdaki adımlar takip edilmiştir.

- Giriş verisi olarak kullanılan renkli resim gri tonlu resme dönüştürülmüştür.
- Sobel filtresi yardımıyla kenar tespiti yapılmıştır.
- Satır matris şeklindeki bir morfolojik yapı elemanı ile filtrelenen resimde kenar bozuklukları düzeltilmiş ve sınırlar belirginleştirilmiştir.
- Aşındırma ve genişletme işlemleri ile sınırlardaki piksel taşmaları ve kayıpları giderilmiştir.
- Sınırların içi doldurularak objenin kapladığı alanda bir bütünlük sağlanmış ve böylece her bir obje ortaya çıkarılmıştır.

Ortaya çıkan objelerin sınıflandırılması ve etiketlenmesinde objelere ilişkin alan, ana eksen uzunluğu, küçük eksen uzunluğu, dış merkezlik (basıklık), yönelim, dışbükey alanı, dolu alanı, eşdeğer çap, obje alanının kendisini çevreleyen en

küçük dörtgenin alanına oranı ve çevre bilgisi olmak üzere 11 özellik öznelik olarak kullanılmıştır.

## 2.4. Sınıflandırma ve performans değerlendirilmesi

Sınıflandırıcı kNN (En Yakın k Komşu) olarak belirlenmiştir [5]. Bu sınıflandırma yönteminde bir veri uzayına sonradan katılan bir elemanın uzayda önceden bulunan her bir elemana olan uzaklığı hesaplanır. Elde edilen uzaklık bilgilerine bakılarak yeni elemana en yakın olan k tane eleman ağırlıklı olarak hangi sınıfa ait ise yeni eleman da o sınıfa aittir denir.

Bu çalışmada oluşturulan sınıflandırma modeli performans ölçümü N Kere Çapraz Doğrulama (N-Fold Cross Validation) yöntemiyle yapılmıştır. Bu yöntemde eldeki bütün veriler N tane eşit gruba bölünür. İşlem grup sayısı kadar devam etmek üzere her seferinde bir grup test için geriye kalan diğer gruplar da eğitim için ayrılır. Böylece bütün gruplar hem test hem de eğitim için kullanılmış olmaktadır. Bu çalışmada N=10 olarak ele alınmıştır.


Sınıflandırma işlemlerinde performans ölçütü olarak duyarlılık (DUY), seçicilik (SEÇ), belirlilik (BEL) ve genel başarımlar alınmıştır. Seçicilik aynı zamanda hassasiyet (precision) veya pozitif öngörü değeri olarak adlandırılır. Duyarlılık, ayrıca çağırma (recall) veya doğru pozitif oranı olarak adlandırılmaktadır. Genel başarımlar ise gerçek doğruların tüm örneklerle oranıdır. Bu ölçütler çok sınıflandırıcı doğruluk tablosuna göre elde edilmektedir [6].

## 2.5. Robot kol açılarının hesaplanması ve hareketi

Sınıflandırma yapıldıktan sonra kaşık, çatal ve bıçağın görüntüdeki ağırlık merkezleri, tabakların uç noktaları robot kolun ulaşacağı hedef olarak seçilmektedir. 3 boyutlu uzaydaki bu hedeflere ulaşılabilmesi için bilinmesi gereken açılar, hedefler iki düzlemde (x-y ve x-z) incelenerek hesaplanmaktadır.

Robot kolun x-y düzleminde belli bir hedefe varması için gerekli olan eklem açıları yapay sinir ağlarında hata fonksiyonunu minimize etmek için kullanılan gradyan iniş yöntemi ile hesaplanmıştır [7] (Şekil 4). Gradyan iniş yöntemi ile bir fonksiyonun yerel minimum veya maksimum noktasına adım adım yaklaşılar. Çalışmada bu yöntem hedeflenen koordinatlar  $x_h, y_h$  ile bulunulan koordinatlar  $x_k, y_k$  (1, 2) arasındaki farkı ifade eden hata fonksiyonu  $E$ 'yi (3) minimize etmek için kullanılmıştır.





Şekil 3: x-y düzleminde kemik uzunlukları (u) ve açılar (α)

$$x_k = \sum_i u_i \cos \alpha_i \quad (1)$$

$$y_k = \sum_i u_i \sin \alpha_i \quad (2)$$

$$E = \frac{(x_h - x_k)^2 + (y_h - y_k)^2}{2} \quad (3)$$

Minimum noktaya ulaşılması için hata fonksiyonunun gradyanının (4, 5) tersi yönünde, gradyanın belli bir katı ( $\eta$ , adım katsayısı) kadar ilerlenir (6).

$$\nabla E(x_1, x_2, \dots, x_n) = \left( \frac{\partial E}{\partial x_1}, \frac{\partial E}{\partial x_2}, \dots, \frac{\partial E}{\partial x_n} \right) \quad (4)$$

$$\frac{\partial E}{\partial \alpha_j} = u_j \sin \alpha_j (x_h - \sum_i u_i \cos \alpha_i) - u_j \cos \alpha_j (y_h - \sum_i u_i \sin \alpha_i) \quad (5)$$


$$\alpha_{i(t)} = \alpha_{i(t-1)} - \eta \frac{\partial E}{\partial \alpha_j} \quad (6)$$

Son değer ile bir önceki değer arasındaki fark bir belirlenen duyarlılık ( $d$ ) değerinin altına düştüğünde minimum değere ulaşıldığı kabul edilerek ilerleme durdurulur (7).

$$|\alpha_{i(t)} - \alpha_{i(t-1)}| < d \quad (7)$$

Robotun kolun x-y düzlemindeki hareketi belirlendikten sonra x-z düzlemindeki hareketi (Şekil 5) için gerekli son açı ( $\theta$ ) aşağıda gösterildiği gibi hesaplanmıştır (8).

$$\theta = \text{atan} \left( \frac{z}{x} \right) \quad (8)$$




Şekil 4: x-z düzleminde kemik uzunlukları (u) ve açı ( $\theta$ )

Hesaplanan açılar, x-z ekseninde dönebilen 4 eklemlili robot kolun 3 boyutlu uzayda belirlenen noktalara ulaşmasını sağlamaktadır.

### 3. Sonuç ve tartışma

Bu çalışmada bilgisayar görmesi ve robot kol uygulaması birleştirilerek gören, bulan, tanıyan ve görevi gerçekleştiren bir akıllı robot kol uygulaması gerçekleştirilmiştir. Kurulan düzenek Şekil 5 ve 6'da gösterilmiştir. Materyal olarak yemek servisinde kullanılan malzemelerin resimleri toplanarak bir veri tabanı oluşturulmuştur. Oluşturulan sistemi iki aşama olarak değerlendirmek uygun olur: Birinci aşama görme ve tanıma sisteminin performansı, ikinci aşama ise birinci aşama sonucu ile gelen bilgi doğrultusunda robot kolun istenilen koordinata hareketidir.

Birinci aşamada elde edilen verileri görüntü işleme teknikleri ve kNN sınıflandırıcı kullanarak sınıflandırıp etiketleyen bir yazılım gerçekleştirilmiştir. Sınıflandırma işlemlerinde performans ölçütü olarak duyarlılık (DUY), seçicilik (SEÇ), belirlilik (BEL) ve genel başarıml alınmıştır. Genel başarıml performansı %90 olarak elde edilmiştir. Diğer ölçütlere ilişkin veriler aşağıdaki tabloda ayrıntılı olarak gösterilmiştir (Tablo 2).



Şekil 5: Kurulan düzenneğin grafiği



Şekil 6: Kurulan düzenek

Tablo 2: Verilerin sınıflandırılmasında başarımlar tablosu

Malzemeler	BEL	SEÇ	DUY
Büyük bıçak	%96,9	%75,7	%73,7
Çatal	%97,3	%89,6	%92,3
Kaşık	%99,2	%97,2	%100
Küçük bıçak	%94,8	%81,9	%78,7
Oval tabak	%100	%100	%100
Yassı tabak	%100	%100	%100
<b>Ağırlıklı Ort.</b>	<b>%98</b>	<b>%90,7</b>	<b>%90,8</b>

İkinci aşamada sınıflandırılan kaşık, çatal ve bıçağın görüntüdeki ağırlık merkezi ile tabakların uç nokta koordinatları robot kolun ulaşacağı hedef olarak seçilmektedir. Gönderilen koordinatlara ulaşmak için robot kol eklem açıları gradyan iniş yöntemiyle hesaplanarak hareketini yapması sağlanmıştır.

Bu çalışmada 3 eklemlilik, hareket kabiliyeti sınırlı bir robot kol kullanılmış, bu sebeple verilen görevler belirli açı ve koordinat koşullarında gerçekleştirilmiştir. Planlanan çalışma, robot kolun daha esnek hareket edebildiği mobil bir sistem hazırlamaktır. Bu konuda daha çok eklem sahip ve daha yüksek açı ve koordinatlara erişebilen hareketli bir düzenek ile çalışmanın geliştirilmesi amaçlanmaktadır.

#### 4. Kaynaklar

- [1] Kulkarni, A. D. (2001). *Computer vision and fuzzy-neural systems*. Prentice Hall PTR. ISBN: 0-13-570599-1
- [2] Jain, R., Kasturi, R., & Schunck, B. G. (1995). *Machine vision*. McGraw-Hill. ISBN: 0-07-113407-7

- [3] Forsyth, D. A., Ponce, J. (2002). *Computer vision: a modern approach*. Prentice Hall Professional Technical Reference. ISBN: 0-13-085198-1
- [4] Davies, E. R. (2004). *Machine vision: theory, algorithms, practicalities*. Morgan Kaufmann. ISBN: 0-12-206093-8.
- [5] Duda, R. O., Hart, P. E., Stork, D. G. (2012). *Pattern classification*. John Wiley & Sons. ISBN: 0-471-05669-3
- [6] Eberhart, R. C., Dobbins, R. W. (1990). *Neural network PC tools: a practical guide*. Academic Press Professional, Inc. ISBN: 0-12-228640-5
- [7] Bishop, C. M. (1995). *Neural networks for pattern recognition*. Clarendon Press.
- [8] Wang, Z., Wang, Z., Wu, Y. (2010). Recognition of corners of planar pattern image. In *Intelligent Control and Automation (WCICA), 2010 8th World Congress on* (pp. 6342-6346). IEEE.
- [9] Hasuda, Y., Tshibashi, S., Kozuka, H., Okano, H., & Ishikawa, J. (2007, June). A robot designed to play the game "Rock, Paper, Scissors". In *Industrial Electronics, 2007. ISIE 2007. IEEE International Symposium on* (pp. 2065-2070). IEEE.
- [10] Ishikawa Watanabe Lab., University of Tokyo [www.k2.t.u-tokyo.ac.jp/fusion/Janken/index-e.html](http://www.k2.t.u-tokyo.ac.jp/fusion/Janken/index-e.html)

## Klasik Türk Müziği Makamlarının Tanınması

Merve Ayyüce KIZRAK<sup>1</sup> Bülent BOLAT<sup>2</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü

Mühendislik Fakültesi

T.C. Haliç Üniversitesi, Kağıthane, İSTANBUL

<sup>2</sup>Elektronik ve Haberleşme Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, Davutpaşa, İSTANBUL

Email: <sup>1</sup>ayyucekizrak@halic.edu.tr

<sup>2</sup>bbolat@yildiz.edu.tr

### Özet

*Bu çalışmada en yaygın 6 Klasik Türk Müziği makamının yapay sinir ağları ile tanınmasına çalışılmıştır. Öznitelik olarak Mel frekans kepsral katsayıları, Delta-Mel frekans kepsral katsayıları ve doğrusal öngörü katsayıları, yapay sinir ağı olarak ise radyal taban fonksiyon ağları, genelleştirilmiş regresyon sinir ağları ve olasılıksal sinir ağları kullanılarak en başarılı öznitelikler ve sinir ağı tespit edilmeye çalışılmıştır. Öznitelikler hesaplanırken kullanılan ses parçacıklarının uzunluğunun başarıma etkisi de ayrıca irdelenmiştir. En yüksek başarımlı Delta-Mel frekans kepsral katsayıları ve olasılıksal sinir ağı ile %89.60 olarak elde edilmiştir.*

### 1. Giriş

Müzik matematikle ilişkilendirilen, tanımlanabilen ve insanoğlunun hayatının her döneminde varlığını sürdüren en önemli kültürel olgulardandır [1]. Müzik bilgi erişimi (Music Information Retrieval-MIR) sistemleri özellikle ses veri tabanlarının yaygınlaşması ve internet sayesinde bilgiye erişimin kolaylaşması nedeniyle önem kazanan ve gelişmekte olan bir alandır. MIR uygulamalarında amaç, herhangi bir müzik parçasının içerdiği eserin türü, kullanılan çalgılar, icracılar, eserin adı vs gibi bilgilerin otomatik olarak elde edilmesidir. Literatürde bu alanda yapılan çalışmalar çoğunlukla batı müziği üzerinde yoğunlaşmaktadır. Ancak, batı müziği için tanımlanan matematiksel temel, yapısal farklılıklardan dolayı yerel müzikler için yetersiz kalmaktadır [2]. Klasik Türk Müziğinin (KTM) karakteri olan makam kavramının batı müziğinden farklı, kendine özgü niteliklere sahip olması ve Asya, Ortadoğu, Kuzey Afrika gibi çok geniş coğrafyalara

etki etmesi dolayısıyla son yıllarda bu alanda da çalışmalar yapılmaya başlanmıştır.

Batı müziği ile KTM arasındaki farklılıklar temel olarak aşağıdaki gibidir.

- Batı müziğinde akort frekansı tek bir nota ile ifade edilirken (La4=440Hz), KTM'de böyle bir değer bulunmamaktadır. Ahenk sistemi olarak adlandırılan birden çok akort değeri bulunmaktadır [3].
- Batı müziğinde bir oktav 12 perdeye bölünürken, KTM'de oktav 17 ile 79 arasında değişen eşit olmayan perde bölmeleri ile tanımlanmaktadır. Bu farklılık farklı icracıların farklı skalalar kullanmasından ve standart bir skalanın olmayışından kaynaklanmaktadır [2].
- Batı müziğinde her bir notanın temel frekansı kesin bir şekilde tanımlı iken KTM'de notaların temel frekansları yaklaşık olarak tanımlıdır ve çoğu zaman icracı kendi üslubuna göre bu frekansları bir miktar değiştirebilmektedir. Buna bağlı olarak batı müziğinde müzisyene bağlı değişimler minimum iken, KTM'de çalınan ezgi müzisyenlerin kişisel deneyimlerine bağlı olarak değişkenlik göstermektedir.
- KTM'de makamlar, gamlara ek olarak melodik seyir kurallarından oluşan bir meşk sistemiyle tanımlanmaktadır.
- Batı müziğindeki çalgıların perde aralıklarının standartlaştırılmış olması bunların matematiksel ve yazılımsal olarak sınıflandırılmasında kolaylık sağlarken, KTM'de hem çalma stiline icracıya göre değişik süslemeler içermesinden hem de pek çok enstrümanın (yaylı tambur, ney vs.) frekans karakteristiklerinin karmaşık olmasında dolayı

frekans analizlerinde başarıya ulaşmak zorlaşmaktadır.

Literatürde KTM üzerine yapılmış güncel çalışmalarda bulunan sonuçlar Tablo 1'de verilmiştir.

Tablo 1. Literatürdeki güncel çalışmalar.

Yazar	Yöntem	Başarım
Kalender vd. [1]	Ayrık dalgacık katsayıları + bileşik YSA, Monofonik	%95.83
Gedik ve Bozkurt [3]	Perde aralık histogramı + şablon eşleştirme, Monofonik	%92
Bozkurt [4]	Perde frekansı histogramı + Gauss Karışım Modeli, Monofonik	%77.38
Ioannidis vd. [5]	Harmonik perde sınıfı profilleri + şablon eşleştirme	%74.17
Kalaycı ve Körükoğlu [6]	K-ortalamalar + YSA, polifonik	%70
Kızrak vd. [7]	MFCC + PNN, Polifonik	%89.40

KTM'de bilinen makam sayısının 600 civarındadır fakat bunların 20 tanesi günümüze ulaşmayı başarmıştır. Bu makamların da önemli bir kısmı nadiren kullanılmaktadır. Türkiye Radyo ve Televizyon Kurumu'nun arşivleri kaynak alındığında 6 makamın toplam eserlerin ortalama %91'ini oluşturduğu görülmektedir. Bu nedenle bu çalışmada eserlerin çoğunu oluşturan Tablo 2'de verilen 6 makam üzerinde durulmuştur.

Tablo 2. Makam isimleri ve dağılımları [8].

Makam	Eser Sayısı	Arşiv Eserleri İçindeki Oranı (%)
Nihavend	2123	31.90
Kürdili Hicazkar	1221	18.34
Rast	1171	17.59
Mahur	566	8.50
Hicazkar	521	7.83
Hicaz	497	7.47
<b>Toplam</b>	<b>6099</b>	<b>91,63</b>

Bu çalışmada en sık rastlanılan 6 KTM makamının yapay sinir ağları ile tanınması üzerinde durulmuştur. Öznitelik olarak Mel frekans kepstral katsayıları (MFCC), Delta-MFCC ve doğrusal öngörü katsayıları (LPC), yapay sinir ağı olarak ise radyal taban

fonksiyon ağları (RBF), genelleştirilmiş regresyon sinir ağları (GRNN) ve olasılıksal sinir ağları (PNN) kullanılarak en başarılı öznitelikler ve sinir ağı tespit edilmeye çalışılmıştır. Özniteliklerin hesaplanmasında kullanılan ses parçacıklarının uzunluğunun başarıma etkisi de ayrıca irdelenmiştir. Çalışmanın ikinci bölümünde kullanılan veri kümesi üzerinde durulmuştur. Çalışmada kullanılan yapay sinir ağları 3. bölümde özetlenmiş, öznitelikler ise 4. bölümde verilmiştir. 5. bölüm uygulama detaylarına ayrılmışken 6. bölümde elde edilen sonuçlar irdelenmiştir.

## 2. Veri Kümesi

KTM'nin otomatik tanınmasına yönelik çalışmaların büyük kısmı tek enstrümanla icra edilen ses kayıtları kullanılarak gerçekleştirilmektedir [1,3,4,5,6]. Ancak bu durum, geliştirilen uygulamanın geçerliliğini kuşkuya düşürmektedir. Gerçek bir şarkı genellikle birden fazla enstrümanla icra edilmektedir. Bu nedenle, gerçekçiliği arttırabilmek amacıyla bu çalışmada kullanılan ses örnekleri, ticari CD ve internet üzerindeki ücretsiz kaynaklardan elde edilen eserlerden oluşturulmuştur. Eserler seçilirken en sık kullanılan 6 makam seçilmiştir. Tablo 3 çalışmada hangi makamdan kaç adet eserin kullanıldığını göstermektedir.

Tablo 3. Veri kümesindeki eserlerin dağılımı [7].

Makam	Eser Sayısı
Hicaz	6
Hicazkar	10
Kürdili Hicazkar	13
Mahur	12
Nihavend	12
Rast	9
<b>Toplam</b>	<b>62</b>

KTM eserleri zemin, nakarat ve meyan olmak üzere üç ana bölüme ayrılır. Makam bilgisi, eserin giriş yani zemin kısmında veya nakarat kısmında bulunmaktadır. Nakarat kısmının eserin kaçınıcı saniyesinde bulunduğunu belirlemek için belirli bir yöntem bulunmadığından veri kümesi oluştururken eserlerin ilk 20sn'lik kısımları seçilmiştir. Solistin cinsiyetinin sonucu etkilememesi amacıyla seçilen kısımlarda eseri seslendiren yorumcunun sesinin bulunmamasına dikkat edilmiştir. Kullanılan tüm

eserler 22050 Hz'de örneklenmiştir. Özniteliklerin hesaplanmasında kullanılan ses parçacıklarının uzunluğunun başarıma etkisini araştırmak amacı ile 20 sn'lik ses örnekleri 2, 4, 6, 8 ve 10 s'lik örtüşmeyen parçalara bölünerek 5 farklı veri kümesi oluşturulmuştur. Elde edilen veri kümelerinde sırasıyla 620, 310, 186, 124 ve 94 adet ses parçacığı bulunmaktadır.

### 3. Sınıflandırıcılar

#### 3.1. Radyal taban fonksiyon sinir ağı

Radyal taban fonksiyon sinir ağı, üç katmanlı eğitici bir sinir ağı türüdür. Giriş katmanının görevi giriş verisini ara katmana aktarmak, çıkış katmanının görevi ise ağa uygulanan girişin sınıfını belirlemektir. Ağın eğitimi, ara katmandaki merkezlerin belirlenmesi ile ara katmandaki nöronlar ile çıkış katmanındaki nöronlar arasındaki ağırlıkların belirlenmesinden ibarettir. Ara katmandaki j. nöronun aktivasyon fonksiyonu merkezi ( $C_j$ ) ve açıklığı ( $\sigma_j$ ) cinsinden aşağıdaki gibidir:

$$\varphi_j(X) = \exp\left(-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right) \quad (1)$$

Çıkış katmanındaki j. nöronun çıkışı ise şu şekilde hesaplanır:

$$s_j(X) = \sum_{i=1}^K W_{ij}\varphi_{ii}(X) + b_j \quad (2)$$

Burada  $\omega_{ij}$  i. ara katman nöronu ile j. çıkış nöronu arasındaki ağırlık K ise ara katmandaki nöron sayısıdır [9].

#### 3.2. Genelleştirilmiş regresyon sinir ağı

Genelleştirilmiş regresyon sinir ağı RBF'in özel bir halidir. GRNN'de merkezler ve ağırlıklar RBF'te olduğu gibi yineleme ile değil, giriş verisinin deterministik bir fonksiyonu olarak belirlenir [10].

#### 3.3. Olasılıksal sinir ağı

Olasılıksal sinir ağı ilk olarak Specht tarafından önerilmiştir. PNN'in çıkışı,  $f_i(x)$  i. sınıfın olasılık yoğunluk fonksiyonu,  $P_i$  sınıfın görülme sıklığı,  $L_i$  de bir ceza terimi olmak üzere Bayes karar kuralına göre aşağıdaki eşitsizliği sağlayan sınıf olarak belirlenir:

$$f_i(x) \cdot P_i \cdot L_j > f_j(x) \cdot P_j \cdot L_i, \text{ tüm } i \neq j \quad (3)$$

Burada olasılık yoğunluk fonksiyonları Parzen penceresi yardımı ile şu şekilde hesaplanır:

$$f(x) = \frac{1}{(2\pi)^{m/2}\sigma^m n} \sum_{i=1}^n \exp\left[-\frac{(x - x_i)^r(x - x_i)}{2\sigma^2}\right] \quad (4)$$

## 4. Öznitelikler

### 4.1. Doğrusal öngörü katsayıları

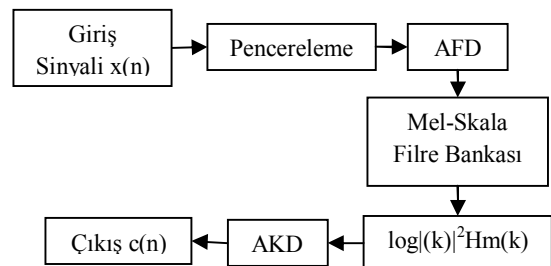
Doğrusal öngörü analizi tüm-kutup sinyal modelleme yöntemlerinden biridir. Buna göre doğrusal ayrık bir sistemin şu anki çıkışı, önceki p adet çıkışının bir kombinasyonu olarak öngörülebilir [11]:

$$\hat{y}(n) = \sum_{i=1}^p a_i y(n-i) \quad (5)$$

Burada  $a_i$  katsayıları tüm kutup bir süzgeç tanımlar ve doğrusal öngörü katsayıları (LPC) olarak adlandırılır. Katsayıların  $y(n)$  ile  $\hat{y}(n)$  arasındaki karesel ortalama hatayı (MSE) minimize edecek şekilde belirlenmesi gereklidir. LPC'ler normal denklemlerin çözülmesi ile elde edilebileceği gibi, Levinson-Durbin algoritması gibi hızlandırılmış bir algoritma ile de hesaplanabilir [11]. Bu çalışmada LPC'ler Levinson-Durbin algoritması ile hesaplanmıştır.

### 4.2. Mel frekans kepstrum katsayıları

MFCC, ses tanıma uygulamalarında sıkça kullanılan ve başarıyı yüksek bir özniteliktir. MFCC, zamana bağlı olan  $x(n)$ 'in mel skalasına çevrilmiş Fourier dönüşümünün logaritmasının ters Fourier dönüşümü olarak tanımlanmıştır. Bu çalışmada MFCC'nin hesaplanmasında işlemsel yükü daha az olan süzgeç bankası yöntemi kullanılmıştır [12]. Bu yöntemde önce  $x(n)$ 'in güç spektrumu Mel skalasına göre düzenlenmiş bir süzgeç dizisi ile çarpılarak Mel spektrumu elde edilir. Mel spektrum karmaşık sayılar içermediğinden MFCC'nin hesaplanması için Mel spektrumun logaritmasının ayrık kosinüs dönüşümünün alınması yeterlidir (Şekil 1).



Şekil 1. MFCC'nin süzgeç bankası ile hesaplanması.

### 4.3. Delta-mel frekans kepstrum katsayıları

Delta-MFCC, MFCC'nin 1. türevi olarak tanımlanmıştır. Bu tanıma göre i. çerçeve için k. Delta MFCC şu şekilde hesaplanır:

$$DMFCC^i(k) = MFCC^{i+1}(k) - MFCC^i(k) \quad (6)$$

## 5. Uygulama

Genel bir ifade olarak, ses sinyalleri durağan olmadığı söylenebilir. Başka bir deyişle ses sinyallerinin istatistikleri zamanın birer fonksiyonudur, yani hesaplanan istatistikler ölçümün alınmaya başlandığı ana bağlıdır. Bu nedenle ses sinyalleri durağan sayılabilecekleri en uzun zaman aralığı kadar çerçevelere bölünerek analiz edilmelidir. Bu çalışmada çerçeve uzunluğu olarak 20 ms seçilmiştir. Daha önce hazırlanmış olan ses parçacıkları 20 ms uzunluklu çerçeveler bölünerek her çerçeve için öznelilikler hesaplanmış ve her parçacık için elde edilen özneliliklerin ortalaması alınmıştır. Böylelikle 3 farklı öznelilik grubu ve 5 farklı ses parçacığı uzunluğu için toplan 15 farklı veri kümesi elde edilmiştir. LPC'ler 20. dereceden hesaplanırken MFCC'ler 12. dereceden hesaplanmıştır. Her bir veri kümesi eğitime ve test kümesi olmak üzere ikiye bölünmüş, yapay sinir ağları eğitime verileri ile eğitilerek test veri kümeleri ile test edilmiştir. Verilerin %60'ı eğitime için kullanılmıştır. Eğitime için kullanılan parçacıkların alındığı eserler test kümesinde yer almamıştır. Sinir ağlarının eğitimi sırasında ağların parametreleri deneme yanılma yöntemi ile belirlenmiştir. Tablo 4, 5 ve 6 elde edilen sonuçları özetlemektedir.

Tablo 4. LPC'ler ile elde edilen sonuçlar.

Başarım (%)	Ses Parçacığının Uzunluğu				
	2s	4s	6s	8s	10s
PNN	<b>53.95</b>	53.82	53.29	53.03	48.23
GRNN	<b>53.68</b>	53.19	51.16	50.89	42.91
RBF	<b>51.84</b>	51.07	50.84	47.76	42.11

Tablo 5. MFCC'ler ile elde edilen sonuçlar.

Başarım (%)	Ses Parçacığının Uzunluğu				
	2s	4s	6s	8s	10s
PNN [7]	68.40	84.40	<b>89.40</b>	83.73	82.82
GRNN	52.12	76.20	<b>84.30</b>	75.34	75.26
RBF	58.48	58.87	<b>72.61</b>	62.26	62.81

Tablo 6. Delta-MFCC'ler ile elde edilen sonuçlar.

Başarım (%)	Ses Parçacığının Uzunluğu				
	2s	4s	6s	8s	10s
PNN	60	79.40	86	<b>89.60</b>	70.67
GRNN	63.20	76.26	83	<b>88.13</b>	79.40
RBF	55.43	58.45	<b>72.82</b>	62.38	61.90

## 7. Sonuçlar

Bu çalışmada KTM eserlerinin makamlarının otomatik olarak belirlenmesine çalışılmıştır. Bunun için LPC, MFCC ve Delta-MFCC'ler öznelilik olarak kullanılmış ve 3 farklı sinir ağı denenmiştir. Ayrıca analiz edilen ses parçacıklarının uzunluğunun başarıma etkisi de incelenmiştir.

Yapılan denemelerin sonunda MFCC ve Delta-MFCC'lerin öznelilik olarak LPC'den daha iyi sonuçlar verdiği görülmüştür. Sinir ağları arasında ise PNN diğerlerinden daha başarılı olduğu gözlenmiştir. Öznelilik olarak LPC kullanıldığında parçacıkların süreleri kısaldığında başarımanın arttığı görülmüştür. MFCC için en yüksek başarıım 6s'lik ses parçacıkları ile elde edilirken Delta-MFCC için en yüksek başarıım 8s uzunluğunda ses parçacıkları ile elde edilmiştir. Elde edilen en başarılı sonuç, 8s'lik parçacıklardan hesaplanan Delta-MFCC ile olasılıksal sinir ağı kullanılarak %89.60 olarak elde edilmiştir. Bu deneme için en iyi  $\sigma$  değeri 0,4 olarak bulunmuştur. Bu sonuç, literatürdeki polifonik sesler ile yapılan çalışmalardan daha başarılı, monofonik sesler ile yapılan çalışmalar ile de kıyaslanabilecek durumdadır. Ancak, gerçek dünyadan gelen MIR problemlerinin polifonik sesler içerdiği düşünüldüğünde bu çalışmada önerilen yöntemin daha gerçekçi olacağı aşikardır. Çalışmanın daha sonraki aşamalarında farklı sinir ağlarının yanı sıra alternatif öznelilik gruplarının denenmesi ve ayrıca MFCC derecesinin başarıma etkisinin araştırılması planlanmaktadır.

## 8. Kaynaklar

- [1] N. Kalender, M. Ceylan, O. Karakaya, "Türk Müziği Makamlarının Sınıflandırılması için Yeni Bir Yaklaşım: Kombine YSA", ASYU 2012 Akıllı Sistemler Yenilikler ve Uygulamaları Symposium, Trabzon, Turkey, 2012.
- [2] B. Bozkurt, A. C. Gedik, M. K. Karaosmanoğlu, "Türk Müziği için Müzik Bilgi Erişimi:

- Problemler, Çözüm Önerileri ve Araçlar”, SIU 2009, 2009.
- [3] A. C. Gedik, B. Bozkurt, "Automatic Classification of Turkish Traditional Art Music Recordings by Arel Theory", Proc. Conference on Interdisciplinary Musicology, Thessaloniki, Greece, 2-6 July 2008.
- [4] A. C. Gedik, B. Bozkurt, "Pitch Frequency Histogram Based Music Information Retrieval for Turkish Music", Signal Processing, vol. 90, pp. 1049-1063, 2010.
- [5] L. Ioannidis, E. Gómez, P. Herrera, "Tonal Based Retrieval of Arabic and Middle-East Music by Automatic Makam Description", 9th International Workshop on Content based Multimedia Indexing, Madrid 2011.
- [6] I. Kalaycı, S. Korukoğlu, "Classification of Turkish maqam music using k-means algorithm and artificial neural networks (in Turkish)", Proc. 20th IEEE Signal Processing and Communications Applications Conference (SIU), 2012.
- [7] M. A. Kizrak, K. S. Bayram, B. Bolat, "Classification of Classic Turkish Music Makams", Innovations in Intelligent Systems and Applications (INISTA), 2014.
- [8] H. T. Sümbüllü, A. Albuz, " Türk sanat müziği dizilerinin bilgisayar destekli makamsal analizi", International Journal of Human Sciences, Vol:8 No:1, pp. 144-198, 2011.
- [9] Paredes, V., Vidal, E., A Class-Dependent Weighted Dissimilarity Measure for Nearest Neighbor Classification Problems, Pattern Recognition Letters, Vol. 21, pp. 1027-1036, 2000.
- [10] Wong, H. S., Wu, M., vd. A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems, Proceedings Of IEEE Pacific Rim Conference On Multimedia, 2000.
- [11] Rabiner, L. ve Juang, B., "Fundamentals of Speech Recognition", Prentice Hall, NewYork, 1993.
- [12] Molau, S. et al., "Computing Mel-frequency Cepstral Coefficients on the Power Spectrum," IEEE Int. Conf. Acoustics, Speech, and Signal Processing, vol. 1, pp. 73-76, 2001.

## Rüzgâr Enerjili Ekonomik Yük Dağıtım Probleminin Yerçekimsel Arama Algoritması ile Çözülmesi

Serhat DUMAN<sup>1</sup>

Nuran YÖRÜKEREN<sup>2</sup>

İsmail H. ALTAŞ<sup>3</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi  
Düzce Üniversitesi, DÜZCE

<sup>2</sup>Elektrik Mühendisliği Bölümü, Mühendislik Fakültesi  
Kocaeli Üniversitesi, KOCAELİ

<sup>3</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi  
Karadeniz Teknik Üniversitesi, TRABZON

serhatduman@duzce.edu.tr

nurcan@kocaeli.edu.tr

ihaltas@ktu.edu.tr

### Özet

*Bu çalışmada güç sistemlerinin en önemli optimizasyon problemlerinden biri olan ekonomik yük dağıtım problemi rüzgar enerjisi de dahil edilip Yerçekimsel Arama Algoritması (YAA) kullanılarak çözülmüştür. Önerilen yaklaşım IEEE 30 baralı 6 generatörlü test sistemine uygulanmıştır. Benzetim çalışmaları sonucunda elde edilen sonuçlar literatürdeki diğer sonuçlar ile karşılaştırılmış ve önerilen yaklaşımdan elde edilen sonuçların daha iyi olduğu sunulmuştur.*

### 1. Giriş

Ekonomik yük dağıtım (ED) problemi güç sistemlerinin işletilmesi konusunda son zamanlarda birçok araştırmacı tarafından ele alınan en önemli optimizasyon problemlerinden biridir. ED probleminin ana amacı sistemin toplam yük talebini ve iletim hattı kayıplarını karşılayacak şekilde üretim birimlerinin belirlenen sınır değerleri içerisinde tutularak minimum yakıt maliyetini sağlayacak çıkış güçlerinin planlanması olarak belirtilmektedir [1-3].

Bu problem literatürde farklı optimizasyon algoritmaları ile bir çok araştırmacı tarafından ele alınmıştır. Niu ve ark. aritmetik çarpazlama operatörü kullanarak oluşturdukları hibrit harmoni arama algoritması ile farklı ekonomik yük dağıtım problemlerini çözmüşlerdir. Önerdikleri algoritmadan elde edilen sonuçların literatürdeki diğer sonuçlardan daha iyi olduğunu göstermişlerdir [4]. Basu ve Chowdhury Cuckoo arama algoritmasını kullanarak konveks, konveks olmayan ve mikro şebekelerinde dahil edildiği ekonomik yük dağıtım problemlerini

çözmüşlerdir. Elde edilen sonuçlara göre önerilen algoritmanın literatürdeki optimizasyon algoritmalarına göre daha iyi sonuçlar verdiğini belirtmişlerdir [5]. Cai ve ark. bulanık mantık ile adaptif hale getirilmiş kaotik karınca sürü optimizasyon algoritmasını ekonomik yük dağıtım problemine uygulamışlardır. Önerilen optimizasyon algoritmasını farklı test sistemlerin çözümünde kullanmışlar ve elde edilen sonuçları literatürdeki sonuçlarla karşılaştırmışlardır. Bu sonuçlara göre önerilen yaklaşımın bu problemi çözmeye etkili olduğunu belirtmişlerdir [6].

Literatürde ekonomik yük dağıtım problemi biyocoğrafya tabanlı optimizasyon algoritması [7], harmoni arama algoritması [8], arı kolonisi [9] ve bulanık mantık ile adaptif hale getirilmiş parçacık sürü optimizasyon [10] algoritmaları ile çözülmüştür.

Bu çalışmada, Rashedi ve ark. [11] tarafından Newtonun hareket ve yerçekimi kanuna dayalı olarak son zamanlarda geliştirilen Yerçekimsel Arama Algoritması (YAA) kullanılmıştır. YAA bir çok araştırmacı tarafından farklı optimizasyon problemlerine uygulanarak üstünlüğü gösterilmiştir [12-15]. Önerilen yaklaşım rüzgar enerjisinin de dahil edildiği ekonomik yük dağıtım problemine uygulanmış olup benzetim çalışmaları sonucunda elde edilen sonuçlar literatürdeki diğer sonuçlarla karşılaştırılmıştır. Karşılaştırma sonuçlarına göre önerilen yaklaşımın bu problemi çözmeye üstünlüğü gösterilmiştir.



## 2. Ekonomik Yük Dağıtım Problemi

Ekonomik yük dağıtım problemi, güç sistemlerinde bulunan üretim birimlerinin her birinin üreteceği gücün bulunması ve denklem (1)'e gösterilen 2. dereceden fonksiyonda yerine konarak toplam yakıt maliyetinin bulunması esasına dayanmaktadır.

$$F_i(P_{Gi}) = a_i + b_i P_{Gi} + c_i P_{Gi}^2 \quad (1)$$

Burada  $F_i(P_{Gi})$   $i$ . üretim biriminin yakıt maliyeti fonksiyonu,  $P_{Gi}$   $i$ . üretim biriminin ürettiği güç değeri,  $a_i$ ,  $b_i$ ,  $c_i$   $i$ . üretim biriminin yakıt maliyeti katsayılarıdır.

Ekonomik yük dağıtım probleminde kayıplı bir sistemde aktif güç dengesi eşitliği denklem (2)'de gösterilmiştir.

$$\sum_{i=1}^N P_{Gi} - P_{yük} - P_{kayıp} = 0 \quad (2)$$

Üretim birimlerinin sınır değerleri aşağıdaki gibi ifade edilmektedir.

$$P_{Gi}^{min} \leq P_{Gi} \leq P_{Gi}^{maks} \quad (3)$$

Sistemin iletim hattı kayıpları aktif gücün ve B kayıp matrisinin bir fonksiyonu olarak denklem (4)'te gösterilmiştir.

$$P_{kayıp} = \sum_{i=1}^N \sum_{j=1}^N P_{Gi} B_{ij} P_{Gj} \quad (4)$$

Denklem (2)'de gösterilen güç eşitlik denklemi rüzgâr enerjisinin  $P_w$  sisteme dâhil edilmesi ile aşağıdaki gibi ifade edilir.

$$\sum_{i=1}^N P_{Gi} + P_w - P_{yük} - P_{kayıp} = 0 \quad (5)$$

Denklem (5)'de ifade edilen  $P_w$  rüzgâr gücü,  $P_{av}$ 'ye bağlı olarak denklem (6)'daki gibi sınırlandırılmaktadır.

$$P_{kayıp} + P_{yük} - \sum_{i=1}^N P_{Gi} \leq P_{av} \quad (6)$$

## 3. Yerçekimsel Arama Algoritması

Yerçekimsel arama algoritması (YAA), Rashedi ve arkadaşları tarafından geliştirilen Newton'un hareket ve yerçekimi kanunlarına dayalı bir optimizasyon algoritmasıdır [11]. Yerçekimi ve hareket kanunlarından esinlenilerek geliştirilen YAA, etkin bir hesaplama kabiliyetine sahip olup arama uzayındaki her bir parçacık bir kütle olarak kabul

edilmektedir. Arama uzayındaki her bir kütle Newton yerçekimi ve hareket kanunlarının benzetimi ile arama uzayında hareket ederek en iyi çözüme ulaşmaya çalışırlar. YAA başlangıç popülasyonu aşağıdaki gibi ifade edilmektedir.

$$X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n) \quad (7)$$

$x_i^d$   $d$ . boyuttaki  $i$ . kümenin konumu temsil ederken  $n$  ise arama uzayının boyutudur. Eğer problem bir minimizasyon problemi ise  $best(k)$  ve  $worst(k)$  denklem (8)'deki gibi gösterilir.

$$\begin{aligned} best(k) &= \min_{j \in \{1, \dots, N\}} fit_j(k) \\ worst(k) &= \max_{j \in \{1, \dots, N\}} fit_j(k) \end{aligned} \quad (8)$$

Algoritmanın başlangıcında kullanıcı tarafından belirlenen yerçekimi sabitine atanan değer iterasyona bağlı olarak azalması, arama hızının kontrol edilmesi ve  $k$ . iterasyondaki yer çekimi sabiti denklem (9-10)'da gösterilmektedir.

$$G(k) = G(G_0, k) \quad (9)$$

$$G(k) = G_0 e^{-\alpha \frac{k}{K}} \quad (10)$$

Uygunluk değerleri hesaplandıktan sonra  $k$ . iterasyondaki  $i$ . ajana ait kütle denklem (11-12)'ye göre hesaplanmaktadır.

$$m_i(k) = \frac{fit_i(k) - worst(k)}{best(k) - worst(k)} \quad (11)$$

$$M_i(k) = \frac{m_i(k)}{\sum_{j=1}^N m_j(k)} \quad (12)$$

Arama uzayındaki ajanın ivmesini hesaplarken onun üzerine uygulanan toplam güçler yerçekimi kanununa bağlı olarak denklem (13)'deki gibi hesaplanmaktadır.

$$F_{ij}^d(k) = G(k) \frac{M_i(k) \times M_j(k)}{R_{ij}(k) + \epsilon} (x_j^d(k) - x_i^d(k)) \quad (13)$$

$R_{ij}(k) = (\|X_i(k), X_j(k)\|_2)$  şeklinde ifade edilmektedir. Hareket kanunundan yararlanarak ajana ait ivme denklem (14)'de ivmeye bağımlı olarak değişen hızı denklem (15) ve hıza bağımlı olarak değişen konum değeri denklem (16)'da gösterilmektedir.

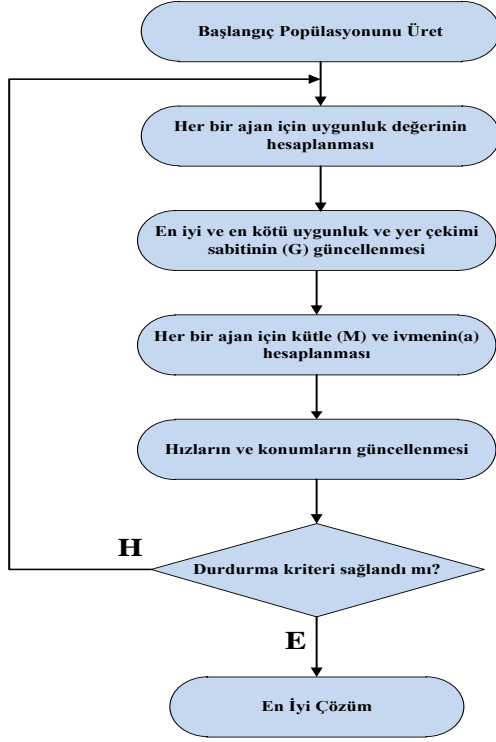
$$a_i^d(k) = \frac{F_{ii}^d(k)}{M_{ii}(k)}$$

$$\sum_{j \in k_{best}, j \neq i} rand_j G(k) \frac{M_j(k)}{R_{ij}(k) + \epsilon} (x_j^d(k) - x_i^d(k)) \quad (14)$$

$$v_i^d(k+1) = rand_i \times v_i^d(k) + a_i^d(k) \quad (15)$$

$$x_i^d(k+1) = v_i^d(k+1) + x_i^d(k) \quad (16)$$

Burada  $rand_i$  ve  $rand_j$  değerleri [0,1] arasında düzgün dağılımlı sayıyı,  $\varepsilon$  küçük bir değeri ve  $R_{ij}(k)$   $i$  ve  $j$  ajanları arasındaki mesafeyi ifade etmektedir. YAA ait akış diyagramı Şekil 1'de gösterilmiştir.



Şekil 1. YAA akış diyagramı.

#### 4. Benzetim Çalışmaları

YAA, rüzgar enerjisinden üretilen gücün ve sistemin iletim hatları kayıplarının da dahil edildiği ekonomik yük dağıtımına uygulanmıştır. IEEE 30 baralı 6 generatörlü test sisteminde talep edilen güç


1800 MW olup 10%'luk gücü rüzgar enerjisinden karşıladığı kabul edilmiştir [3]. Sisteme ait veriler [3,16,17] alınmıştır. Sistemin iletim hattı kayıplarının hesaplanmasında kullanılan B kayıp matrisi Tablo 1'de gösterilmiştir. Tablo 2'de ise üretim birimlerine ait maliyet fonksiyonu katsayıları ve sınır değerleri gösterilmiştir. Denklem (17)'de problemin amaç fonksiyonu gösterilmektedir. Rüzgar enerjisinin de katıldığı ekonomik yük dağıtım problemi çözümünde kullanılan YYA parametreleri  $G_0=100$ ,  $\alpha=15$ , ajan veya popülasyon sayısı  $N=50$ , iterasyon sayısı 300 olarak alınmıştır.

$$\min F_{\text{toplam}} = \min \sum_{i=1}^N F_i(P_i) \quad (17)$$

Tablo 1. B kayıp matrisi

$B = 10^{-5}$	20.0	1.0	1.5	0.5	0	-3.0
	1.0	30.0	-2.0	0.1	1.2	1.0
	1.5	-2.0	10.0	-1.0	1.0	0.8
	0.5	0.1	-1.0	15.0	0.6	5.0
	0	1.2	1.0	0.6	25.0	2.0
	-3.0	1.0	0.8	5.0	2.0	21.0


YAA'nın test sistemine 30 kez uygulanması ile elde edilen minimum toplam yakıt maliyeti değerleri Şekil 2'de gösterilmiştir. Ayrıca YAA algoritmasından 6. eğitim denemesinde elde edilen toplam minimum yakıt maliyeti değerinin iterasyona bağımlı olarak değişimi Şekil 3'de gösterilmiştir. Şekil 3'te toplam yakıt maliyetinin yaklaşık olarak 15-20. iterasyon arasında minimum değerine ulaştığı görülmektedir. Şekil 4'de ise iletim hattı kaybının iterasyona bağımlı olarak değişimi ve iletim hattı kaybının yakıt maliyeti eğrisindeki gibi yaklaşık 15-20. iterasyon arasında en uygun değeri bulunduğu görülmektedir.



Şekil 2. YAA ile elde edilen toplam yakıt maliyeti değerleri


Tablo 2. Üretim birimlerinin maliyet fonksiyonu katsayıları ve sınır değerleri

Parametre	$P_{G1}$	$P_{G2}$	$P_{G3}$	$P_{G4}$	$P_{G5}$	$P_{G6}$
a	85.6348	303.7780	847.1484	274.2241	847.1484	202.0258
b	8.43205	6.41031	7.42890	8.30154	7.42890	6.91559
c	0.002035	0.003866	0.002182	0.001345	0.002182	0.005963
$P_G^{\min}$	150	150	150	150	150	150
$P_G^{\max}$	600	600	600	600	600	600



Şekil 3. Yakıt maliyeti değişim eğrisi

Tablo 3’de YAA algoritmasından elde edilen en iyi çözüme ait generatörlerin çıkış güçlerini, minimum toplam yakıt maliyeti değeri ve sistemin aktif güç kayıp değeri gösterilmiştir. Ayrıca literatürde var olan dinamik adaptif bakteri yem arama (DABFA) algoritmasından elde edilen sonuçlarla karşılaştırılmıştır. Test sistemi için YAA ile elde edilen en iyi, ortalama ve en kötü olarak elde edilen çözümleri Tablo 4’te literatürdeki diğer sonuçlarla birlikte verilmiştir. Tablo 4’te koyu olarak gösterilen çözümler detaylı bir şekilde incelendiğinde, YAA ile elde edilen minimum toplam yakıt maliyeti değerlerinin literatürdeki sonuçtan daha iyi olduğu görülmektedir.



Şekil 4. İletim hattı kaybının iterasyona göre değişim eğrisi

Tablo 3. YAA algoritmasından elde edilen sonuçlar

	Metot	
	DABFA [3]	YAA
$P_{G1}$ (MW)	269.3201	215.3897
$P_{G2}$ (MW)	270.4433	282.2411
$P_{G3}$ (MW)	435.2460	452.2427
$P_{G4}$ (MW)	329.0709	319.3406
$P_{G5}$ (MW)	261.0364	274.5521
$P_{G6}$ (MW)	158.5697	181.0584
$P_{kayıp}$ (MW)	103.6863	<b>104.8245</b>
Yakıt Maliyeti (\$/h)	16853.4982	<b>16833.58213</b>

Tablo 4. YAA algoritmasından elde edilen sonuçların karşılaştırılması

	Yakıt Maliyeti (\$/h)	
	DABFA [3]	YAA
Minimum	16853.4982	<b>16833.58213</b>
Ortalama	16862.5962	<b>16833.59975</b>
Maksimum	16866.5732	<b>16833.61266</b>
Aralık Değişimi	13.0750	<b>0.03053</b>

## 5. Sonuçlar

Bu çalışmada, Rashedi ve ark. tarafından son zamanlarda geliştirilen sezgisel algoritmalarından biri olan yerçekimsel arama algoritması rüzgar enerjisinin dahil olduğu ekonomik yük dağıtım probleminin çözümü için IEEE 30 baralı 6 generatörlü test sisteminde başarılı bir şekilde uygulanmıştır. Önerilen algoritma tarafından elde edilen sonuçların literatürdeki diğer sonuçlardan daha iyi olduğu görülmüştür. Sonuç olarak sezgisel arama yapısına sahip olan YAA’nın rüzgar enerjisinin dahil edildiği ekonomik yük dağıtım probleminin çözümüne kolay bir şekilde uygulandığı gösterilmiştir.

## 6. Kaynaklar

- [1] L. Benasla, A. Belmadani, M. Rahli, “Spiral optimization algorithm for solving combined economic and emission dispatch”, International

- Journal of Electrical Power and Energy Systems, 62, 2014, s. 163-174.
- [2] R. Roy, S.P. Ghoshal, "A novel crazy swarm optimized economic load dispatch for various types of cost functions", International Journal of Electrical Power and Energy Systems, 30, 2008, s. 242-253.
- [3] I.A. Farhat, M.E. El-Hawary, "Dynamic adaptive bacterial foraging algorithm for optimum economic dispatch with valve-point effects and wind power", IET Generation, Transmission & Distribution, 4(9), 2010, s. 989-999.
- [4] Q. Niu, H. Zhang, X. Wang, K. Li, G.W. Irwin, "A hybrid harmony search with arithmetic crossover operation for economic dispatch", International Journal of Electrical Power and Energy Systems, 62, 2014, s. 237-257.
- [5] M. Basu, A. Chowdhury, "Cuckoo search algorithm for economic dispatch", Energy, 60, 2013, s. 99-108.
- [6] J. Cai, Q. Li, L. Li, H. Peng, Y. Yang, "A fuzzy adaptive chaotic ant swarm optimization for economic dispatch", International Journal of Electrical Power and Energy Systems, 34, 2012, s. 154-160.
- [7] S. Rajasomashekar, P. Aravindhababu, "Biogeography based optimization technique for best compromise solution of economic emission dispatch", Swarm and Evolutionary Computation, 7, 2012, s. 47-57.
- [8] E. Khorram, M. Jaberipour, "Harmony search algorithm for solving combined heat and power economic dispatch problems", Energy Conversion and Management, 52, 2011, s. 1550-1554.
- [9] M. Basu, "Bee colony optimization for combined heat and power economic dispatch", Expert Systems with Applications, 38, 2011, s. 13527-13531.
- [10] T. Niknam, H.D. Mojarrad, M. Nayeripour, "A new fuzzy adaptive particle swarm optimization for non-smooth economic dispatch", Energy, 35, 2010, s. 1764-1778.
- [11] E. Rashedi, H. Nezamabadi-pour, S. Saryazdi, "GSA: A gravitational search algorithm", Information Science, 179 (13), 2009, s. 2232-2248.
- [12] R.K. Sahu, S. Panda, S. Padhan, "Optimal gravitational search algorithm for automatic generation control of interconnected power systems", Ain Shams Engineering Journal, 2014, <http://dx.doi.org/10.1016/j.asej.2014.02.004>.
- [13] P. K. Roy, "Solution of unit commitment problem using gravitational search algorithm", International Journal of Electrical Power and Energy Systems, 53, 2013, s. 85-94.
- [14] E. Rashedi, H. Nezamabadi-pour, S. Saryazdi, "Filter modeling using gravitational search algorithm", Engineering Applications of Artificial Intelligence, 24 (1), 2011, s. 117-122.
- [15] J. Sarker, S.K. Goswami, "Solution of multiple UPFC placement problems using gravitational search algorithm", International Journal of Electrical Power and Energy Systems, 55, 2014, s. 531-541.
- [16] M.F. AlHajri, M.E. El-Hawary, "Pattern search optimization applied to convex and non-convex economic dispatch", IEEE International Conference on Systems, Man and Cybernetics (ISIC 2007), 2007, s. 2674-2678.
- [17] I.A. Farhat, "Economic and economic-emission operation of all-thermal and hydro-thermal power generation systems using bacterial foraging optimization", Doktora Tezi, Dalhousie University, Mart 2012.

## Destek Vektör Makinelerinde Parametre Seçiminin Duygu Analizi Üzerindeki Etkisi

Aysun GÜRAN<sup>1</sup>, Mitat UYSAL<sup>2</sup>, Özge DOĞRUSÖZ<sup>3</sup>

<sup>1,2</sup>Bilgisayar Mühendisliği Bölümü

<sup>3</sup>İşletme Bölümü

Doğuş Üniversitesi, Kadıköy, İSTANBUL

Email: adogruso@dogus.edu.tr    muysal@dogus.edu.tr    ozgedogruso@gmail.com

### Özet

*Son zamanlarda kişilerin kullandıkları ürünler ve aldıkları hizmetler hakkındaki görüşlerini sosyal medya üzerinden paylaşması duygu analizi konusunun önem kazanmasını sağlamıştır. Duygu analizi ile ilgili çalışmalarda sınıflandırma metodu olarak destek vektör makinelerinin (DVM) başarılı performansı pek çok kez vurgulanmıştır. Bu çalışma ile duygu analizinin gerçekleştirebileceği farklı veri setleri üzerinde DVM yöntem performansını etkileyen parametre değişimlerinin sınıflandırma performansı üzerindeki etkileri incelenmiş ve farklı deneyler sonucu elde edilen durumlar yorumlanmıştır.*

### 1. Giriş

İnternetteki veri miktarının genişlemesi ve sosyal medyanın ticarete olan etkisi firma-tüketici ilişkisini farklı bir boyuta taşımaktadır. İnsanların satın aldıkları ürün ve hizmetler hakkındaki olumlu-olumsuz kişisel düşünceleri artık sadece firma ile tüketici arasında kalmamakta, sosyal medya üzerinden de paylaşılmaktadır. Yaşanan bu durumun etkisiyle sosyal medya ve bloglar aracılığı ile paylaşılan gönderilerin duygu (sentiment) analizi sürecinden geçirilerek otomatik olarak sınıflandırılması büyük bir önem taşımaktadır.

Literatürde Türkçe veri setlerinin kullanıldığı bir çok duygu analizi çalışması mevcuttur: Çalışma [1], seçilen TV programları için yapılan yorumları olumlu, olumsuz veya nötr olarak etiketlemiş ve hesaplanan skor değerine bağlı olarak TV reyting sonuçlarının tutarlılığını test etmiştir. Çalışma [2], Twitter üzerinde Naïve Bayes (NB), Rastgele Orman (RO) ve Destek Vektör Makinesi (DVM) gibi makine öğrenmesi yöntemlerini kullanarak duygu analizini gerçekleştirmiş ve en başarılı sonuçlara DVM ile ulaşıldığını belirtmiştir. Çalışma [3], eğiticili ve geleneksel terim ağırlıklandırma yöntemleriyle Türkçe Twitter gönderileri üzerinde duygu analizini

gerçekleştirmiş ve yine NB, RO, DVM ve karar ağaçları (J48) arasından en başarılı sınıflandırma metodu olarak DVM'leri işaret etmiştir. DVM'lerin kullanıldığı bu çalışmalar [2][3], DVM'leri Weka yazılımında varsayılan parametreleri ile kullandıklarını belirtmişlerdir. Halbuki DVM'lerin kullanımında, yöntem performansını etkileyebilecek bir çok faktör mevcuttur. Bu faktörler, uygun çekirdek fonksiyonunun seçimi ve çekirdek fonksiyonuna ait uygun parametrelerin belirlenmesidir. Bu etmenler probleme göre uygun seçilmediği takdirde DVM'nin genelleştirme performansı olumsuz yönde etkilenecektir. Bu çalışma ile duygu analizinin uygulanabileceği üç veri seti üzerinde, DVM'lerde belirlenen çekirdek fonksiyonu için kullanılabilir parametre değer değişimlerinin yöntem performansı üzerindeki etkisi araştırılmıştır. DVM kullanımında radyal tabanlı çekirdek fonksiyonu parametrelerini örgü arama (grid search) yöntemi ile belirleyen bir durum irdelenmiştir. Kullanılan veri setleri Kemik doğal dil işleme grubunun yayınlamış olduğu veri setleri içinden seçilmiştir. Sistem tasarımı için veri setlerine ait karakter tabanlı n-gramlar, kelime tabanlı n-gramlar, noktalama işaretleri gibi özellikleri içeren arff uzantılı dosyalar yaratılmış ve Weka LibSVM modülü kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.


Bildirinin geri kalan kısmı şu şekildedir: Bildirinin ikinci bölümünde destek vektör makineleri anlatılmıştır; üçüncü bölümünde kullanılan veri setleri tanıtılmış ve sistem özelliklerinden söz edilmiştir. Sonuçlar bölümünde ise genel yorumlarda bulunularak gelecek çalışmalardan bahsedilmiştir.

### 2. Destek vektör makineleri

Destek vektör makinesi iki boyutlu uzayda doğrusal, üç boyutlu uzayda düzlemsel ve çok boyutlu uzayda hiperdüzlem şeklindeki ayırma mekanizmaları ile

veriyi iki ya da daha çok sınıfa ayırma yeteneğine sahiptir.

Veri grubunun bir doğru ile ayrılabilirdiği durum, grubun lineer olarak ayrılabilirdiği durumdur. Burada Vapnik ve diğerleri [4] tarafından ileri sürülen bir fikir, iki sınıfı ayıran nesnenin bir doğru yerine bir koridor olması ve bu koridorun genişliğinin bazı veri vektörleri tarafından belirlenerek mümkün olan en büyük genişlikte olmasıdır. Şekil 1'de bu durum görülmektedir:



Şekil 1. İki sınıfın doğrusal olarak ayrılabilirdiği durum.


D doğrusu  $\langle w, x \rangle + b = 0$  denklemi ile belirlenmekte olup,  $w$  ağırlık vektörü ve  $b$  de sabit sayı (bias) değeridir. D1 doğrusu  $\langle w, x \rangle + b = 1$  denklemi ile ve D2 doğrusu  $\langle w, x \rangle + b = -1$  denklemi ile belirlenir. D1 ve D2 doğruları arasındaki uzaklık (marjin)  $d$  ile gösterilirse, analitik geometri bilgileri ile,  $d$ 'nin ( $d = \frac{2}{\|w\|}$ ) şeklinde hesaplanabileceği kolayca görülür.  $\|w\|$  değeri  $\|w\| = \sqrt{w_1^2 + w_2^2}$  şeklinde hesaplanır.  $d$ 'nin maksimum değerinin elde edilmesi için doğal olarak  $\|w\|$ 'nin ya da  $\|w\|^2$ 'nin minimum değerinin bulunması gerekir. Buna göre optimizasyon problemi,

$$\min. \frac{1}{2} \|w\|^2 \quad (1)$$

$$\text{Kısıtlar: } y_i \cdot (\langle w, x \rangle + b) \geq 1$$

haline gelecektir. Bu problem primal problem olarak adlandırılır.

Şekil 2 ile iki sınıfın geniş bir marjin boyunca net olarak ayrılabilirdiği durum görülmektedir. Bu durumda sınırı aşma durumunu simgeleyen  $\zeta_i$  parametresi amaç fonksiyonu içine girecek ve bu parametrenin de minimum olması istenecektir.



Şekil 2. İki sınıfın net olarak ayrılabilirdiği durum.

Buna göre primal optimizasyon problem:


$$\min. J(w, \zeta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \zeta_i \quad (2)$$

$$\text{Kısıtlar: } y_i \cdot (\langle w, x \rangle + b) \geq 1 - \zeta_i \quad i=1,2,\dots,n$$

$$\zeta_i \geq 0$$

şekline gelecektir. Burada  $\zeta_i$  değişkenleri gevşek (slack) değişken olarak isimlendirilir. Burada,  $w$ ,  $b$  ve  $\zeta_i$  değişkenlerinin en iyi değerleri aranacaktır.  $C$  parametresi için de şu bilgiler faydalı olacaktır:  $C$ 'nin değeri 0 ile sonsuz arasında herhangi bir değer olabilir.  $C$  parametresi modeli kuran kişi tarafından hatayı tolere etmek amacı ile uygun bir değer olarak seçilir.  $C$  değeri 0'a yaklaşırsa gevşek değişkenler kısıtsız hale gelir. Bu durumda marjin genişliği maksimum hale gelir; marjin içinde ya da yanlış tarafta kaç tane veri olduğu önemini yitirir. Bu durum bazı hallerde yararlıdır. Öğrenme fazında hassasiyet azalır ancak yeni data kabulünde başarı artar.  $C$ 'nin sonsuza yaklaşması hassasiyeti çok artırır; marjin genişliği çok azalır. Öğrenme fazında hassasiyet yüksek ancak yeni veri kabulünde güçlükler oluşur.  $C$ 'nin değeri kullanıcının tecrübesine göre deneme-yanılma yöntemi ile belirlenir.

Birçok veri kümesi için, iki boyutlu durumdaki veriler, doğrusal ayraç yardımı ile birbirinden ayrılabilir değildir. Şekil 3'te bu durum görülmektedir:



Şekil 3. Verilerin lineer bir ayraç ile ayrılabilirdiği durum.

$x \rightarrow \Phi(x)$  dönüşümünün yapılması ile ayırıcı düzlem  $f(x) = w \cdot \Phi(x) + b = 0$  haline gelecektir. İki boyutlu uzaydaki ifadelerde,  $\langle x_i, x_j \rangle$  skaler çarpımları yerine çok boyutlu uzayda  $\langle \Phi_i, \Phi_j \rangle$  şeklindeki iç çarpımlar gelecektir. Bu durumda  $\langle \Phi_i, \Phi_j \rangle$  çarpımı yerine,  $K(X_1, X_2) = \Phi(X_1) \cdot \Phi(X_2) = \Phi(X_1)^T \cdot \Phi(X_2) = \langle \Phi(X_1), \Phi(X_2) \rangle$  şeklinde tanımlanan bir K fonksiyonu kullanılabilirse o takdirde özellikle çok büyük veri miktarları için çok büyük zaman harcanarak hesaplanabilecek olan  $\langle \Phi(X_1), \Phi(X_2) \rangle$  iç çarpımları yerine  $K(X_1, X_2)$  ifadesi ile bu hesaplamaları çok daha az işlem ve zaman harcayarak gerçekleştirmek mümkün olacaktır. Burada K fonksiyonu bir çekirdek (kernel) adını alır;  $\langle \Phi(X_1), \Phi(X_2) \rangle$  ifadesi yerine K'nın kullanılması ise çekirdek püf noktası (kernel trick) olarak isimlendirilir. Tablo 1'de, K kernel fonksiyonu için kullanılabilir alternatifler hakkında bilgi verilmektedir:

Tablo 1. Kernel fonksiyonları.

Kernel Adı	Formülü	Parametreleri
Doğrusal	$x^T y + c$	Yok
Polinomial (Polynomial)	$(x^T y + 1)^d$	d
Radyal tabanlı (Radial Basis)	$\exp(-\gamma \ x - y\ ^2)$	$\gamma$
Sinir ağı sigmoid (neural network sigmoid)	$\tanh(a x^T y + b)$	a, b

DVM'lerde dikkate alınması gereken önemli bir konu da büyük veri gruplarının belirli özelliklere göre ikiden fazla gruba ayrılma durumudur. Destek vektör makinesini çok sayıda sınıf durumunda kullanabilmek için, problem çok sayıda ikili sınıf problemine dönüştürülmelidir. En çok kullanılan yaklaşımlar: Biri ve diğerleri (One vs All) yaklaşımı ile Bire bir (One vs One) yaklaşımıdır [5]. Bu çalışmada bire bir yaklaşımı kullanılmıştır.

### 3. Kullanılan veri setleri ve sistem özellikleri

Bu çalışmada Kemik doğal dil işleme grubunun [6] yayınlamış olduğu toplam üç veri seti kullanılmıştır. VS1, VS2, VS3 sırasıyla birinci, ikinci ve üçüncü veri setini ifade etmek üzere, bu veri setleri ile ilgili bilgiler Tablo 2 ile belirtilmiştir:

Tablo 2. Veri setleri tanıtımı.

Veri Seti	Açıklama
VS1	Bu set 3 farklı sınıfa ait (olumlu, olumsuz, nötr) toplamda 3000 tweet içermektedir.
VS2	Bu set çeşitli blog yazarlarının 4 farklı ruh halleriyle (neşeli, sinirli, üzgün, karışık) yazdıkları 157 blog yazısını içermektedir.
VS3	Bu set 3 farklı yorum sınıfına (olumlu, olumsuz, nötr) ait 35'er, toplamda 105 film yorumu içermektedir.

DVM'lerin kullanımında, yöntemin performansını etkileyebilecek faktörler, uygun çekirdek fonksiyonunun seçimi ve çekirdek fonksiyonuna ait uygun parametrelerin belirlenmesidir. Bu faktörler probleme göre uygun seçilmediği takdirde, DVM'nin genelleştirme performansı olumsuz yönde etkilenecektir. Bu bildiriye, DVM yöntemine ait radyal tabanlı çekirdek fonksiyonu parametresini ( $\gamma$ ) ve C ceza parametresini örgü arama (grid search) yöntemi ile belirleyen bir durum irdelenmiştir. Örgü arama yöntemi, 10 kat çapraz geçirme (10-fold cross validation) ile, ilgilenilen parametre uzayını uygun aralıklarda ayrıklaştırmakta ve her bir düğüm noktasına karşılık gelen değerleri çekirdek fonksiyonu parametreleri olarak DVM yöntemine girdi olarak vermektedir [7]. Ardından, geçirme verileri üzerinde en yüksek sınıflandırma performansını veren parametre değerleri en uygun parametre olarak seçilmektedir. C ve  $\gamma$  değerleri örgü arama metoduna göre  $C = \{10^1, 10^2, 10^3, 10^4\}$ ,  $\gamma = \{10^{-1}, 10^{-2}, 10^{-3}, 10^{-4}, 10^{-5}, 10^{-6}\}$  kümelerinin kartezyen çarpımı ile elde edilen ikililer kullanılarak belirlenmiştir. DVM yönteminin belirtilen şartlarda uygulanması için Weka LibSVM modülü kullanılmıştır.

### 4. Sonuçlar ve gelecek çalışmalar

Bu bölümde DVM yöntem performansının farklı  $\gamma$  ve C parametrelerine göre incelenen veri setleri üzerindeki başarımların değerleri incelenmiştir.

Tablo 3, parametrelerin VS1 üzerindeki etkisini göstermektedir. Burada veri seti hazırlanırken özellik olarak karakter tabanlı 2-gram, 3-gram, 4-gram ve 5-gramlar birlikte kullanılmıştır. Kullanılan özellikler veri seti [6] referansı ile indirildiğinde görülebilecek olan "ozellikler.txt" metnindedir. Weka yazılımının girdisi olan arff dosyası n-gram özelliklerinin baz alınmasıyla kelime sıklığı metriği kullanılarak oluşturulmuştur. Bu şartlar altında toplam 15368 adet özellik elde edilmiştir. Bu dosya üzerinde Korelasyon

Tabanlı Özellik Seçici (Correlation-based Feature Selection-CFS) özellik seçim algoritması uygulanarak özellik sayısı 247'e düşürüldükten sonra yapılan farklı deneyler ile Tablo 3'teki başarımların değerleri elde edilmiştir.

Tablo 3. Parametre seçiminin VS1 üzerindeki etkisi.

	C:10 <sup>4</sup>	C:10 <sup>3</sup>	C:10 <sup>2</sup>	C:10 <sup>1</sup>
$\gamma: 10^{-6}$	0,556	0,452	<b>0,429</b>	0,429
$\gamma: 10^{-5}$	0,622	0,557	0,452	0,429
$\gamma: 10^{-4}$	<b>0,633</b>	0,622	0,557	0,452
$\gamma: 10^{-3}$	0,624	0,633	0,621	0,56
$\gamma: 10^{-2}$	0,558	0,594	0,624	0,622
$\gamma: 10^{-1}$	0,543	0,542	0,548	0,594

Tablo 3 incelendiğinde parametre değişikliklerinin DVM performansı üzerinde oldukça etkili olduğu görülmektedir. En düşük performans (0,429) ile en başarılı performans (0,633) değeri arasında oldukça yüksek bir farklılık gözlemlenmiştir.

Tablo 4, incelenen farklı parametrelerin VS2 üzerindeki etkisini göstermektedir. Burada veri seti hazırlanırken özellik olarak karakter 2-gram, 3-gram, kelime kökleri, noktalama işaretlerinin sıklığı gibi farklı özellikler kullanılmıştır. Kullanılan özellikler veri setinin [6] referansından indirildikten sonra görülebilecek olan "ozellikler.txt" dosyasından incelenebilir. VS2'de incelenen toplam özellik sayısı 23018 adettir. CFS özellik seçim algoritmasından sonra bu sayı 54'e düşürülmüştür. Tablo 4'de belirtilen DVM başarımların değerleri bu şartlar altında oluşturulmuştur. Tablodan görüldüğü üzere en yüksek başarımların değeri (0,751) aynı veri seti üzerinde farklı parametreler ile elde edilen en düşük başarımların oranı ise (0,305) dir. Başarımların farkı oldukça yüksektir.

Tablo 4 Parametre seçiminin VS2 üzerindeki etkisi.

	C:10 <sup>4</sup>	C:10 <sup>3</sup>	C:10 <sup>2</sup>	C:10 <sup>1</sup>
$\gamma: 10^{-6}$	0,694	0,643	0,318	<b>0,305</b>
$\gamma: 10^{-5}$	<b>0,751</b>	0,70	0,643	0,318
$\gamma: 10^{-4}$	0,713	0,738	0,687	0,624
$\gamma: 10^{-3}$	0,694	0,694	0,719	0,713
$\gamma: 10^{-2}$	0,707	0,707	0,707	0,719
$\gamma: 10^{-1}$	0,528	0,528	0,528	0,528

Tablo 5, parametrelerin VS3 üzerindeki etkisini göstermektedir. Burada veri seti hazırlanırken özellik olarak VS2'de olduğu gibi karakter 2-gram, 3-gram, kelime kökleri, noktalama işaretlerinin sıklığı gibi

farklı özellikler kullanılmıştır. Kullanılan özellikler yine veri setinin [6] referansından indirildikten sonra görülebilecek olan "ozellikler.txt" dosyasından incelenebilir. VS3'de incelenen toplam özellik sayısı 6439 adettir. CFS özellik seçim algoritmasından sonra bu sayı 64'e düşürülmüştür. Sonuçlara göre en yüksek başarımların oranı 0,752 iken en düşük başarımların oranı yüksek bir düşüş ile 0,342 olarak elde edilmiştir.

Tablo 5. Parametre seçiminin VS3 üzerindeki etkisi.

	C:10 <sup>4</sup>	C:10 <sup>3</sup>	C:10 <sup>2</sup>	C:10 <sup>1</sup>
$\gamma: 10^{-6}$	0,514	0,371	0,342	0,342
$\gamma: 10^{-5}$	<b>0,752</b>	0,514	0,371	0,342
$\gamma: 10^{-4}$	0,752	0,752	0,514	0,371
$\gamma: 10^{-3}$	0,658	0,752	0,752	0,523
$\gamma: 10^{-2}$	0,714	0,714	0,752	0,704
$\gamma: 10^{-1}$	0,666	0,666	0,666	0,666

Bu deneylerin sonucunda seçilen farklı parametrelerin DVM başarımları üzerinde etkili olduğu gözler önüne sergilenmiştir. Bu durum incelenemeyen diğer aralıklar için çok daha yüksek başarımların sonuçlarını karşımıza çıkarabilir. Üstelik farklı çekirdek fonksiyonları da birbirinden farklı sonuçlar sergileyecektir. Dolayısıyla DVM'ler uygulanırken parametre optimizasyonu için hızlı metodların önerilmesi sistemin çalışma süresi ve performansı adına çok önemlidir. Bundan sonraki çalışmalarımızda amacımız parametre optimizasyonu için sezgisel metodlar üzerinde durmak olacaktır.

## 6. Kaynaklar

- [1] D. Kayahan, A. Sergin, B. Diri, "Twitter ile TV Program Reytinglerinin Belirlenmesi", IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU 2013, Kıbrıs, 2013.
- [2] M. Meral, B. Diri, "Twitter üzerinden duygu analizi", IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU 2014, Trabzon, 2014.
- [3] M. Çetin, F. Amasyalı, "Eğitici ve Geleneksel Terim Ağırlıklandırma Yöntemleriyle Duygu Analizi", IEEE 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU 2013, Kıbrıs, 2013.
- [4] C. Cortes ve V. Vapnik. Support vector networks. Machine Learning, 20:273–297, 1995.
- [5] C.W. Hsu ve C.J. Lin, "A Comparison of Methods for Multiclass Support Vector Machines", IEEE Transactions On Neural Networks, 13(2), 415-425, 2002.
- [6] Kemik doğal dil işleme grubu: <http://www.kemik.yildiz.edu.tr/>
- [7] G. Taşkın Kaya, H. Kaya, "Destek Vektör Makinaları Model Parametrelerinin Yüksek Boyutlu Model Gösterilimi ile Optimizasyonu ve Hiperspektral Görüntülere Uygulanması", IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU 2014, Trabzon, 2014.



# OTOMATİK TANIMLANMIŞ HEDEF TAKİP SİSTEMİ

Mehmet Ali DURĞAY<sup>1</sup> Onur ULUSOY<sup>2</sup> Mehmet Emin DENİZ<sup>3</sup>  
<sup>4</sup>Yrd.Doç.Dr. Tolgay KARA

<sup>1,2,3,4</sup>Elektrik-Elektronik Mühendisliği Bölümü Mühendislik Fakültesi  
 Gaziantep Üniversitesi, Şehitkamil, GAZİANTEP

Email: <sup>1</sup>[mehmetalidurgay@gmail.com](mailto:mehmetalidurgay@gmail.com) <sup>2</sup>[onurulusoy1990@gmail.com](mailto:onurulusoy1990@gmail.com) <sup>3</sup>[emndeniz@gmail.com](mailto:emndeniz@gmail.com)  
<sup>4</sup>[kara@gantep.edu.tr](mailto:kara@gantep.edu.tr)

## Özet

*Bu bildiride silah sistemlerinde hedef karakteristiği temelinde esnekliği ve entegrasyonu yüksek bir takip mekanizmasının tasarımı ve üretimini sunulmuştur. Görüntü işleme teknikleriyle hedef karakteristiğinin belirlenmesi ve ayırt edilmesi sağlanırken servo kontrol teknikleriyle de iki eksende hedefin izlenmesi ve işaretlenmesi başarılmıştır. Sistemin mekanik tasarımı ve ilk örnek üretimi gerçekleştirilmiş, elektronik ve yazılım bağıntıları tamamlanarak testler uygulanmıştır. İki farklı hedef karakteristiği için sistemin hedef takip başarımı ortaya konmuştur.*

*Anahtar sözcükler: hedef takip sistemleri, otomatik güvenlik sistemleri, görüntü işleme.*

## 1. Giriş

Savunma endüstrisi, gelişmiş ve gelişmekte olan ülkelerin temel odaklarından biridir. Savunma sistemlerine ayrılan bütçe her geçen sene kullanılan kritik teknolojilerin araştırılması ve geliştirilmesiyle artarak ülke bünyesine katma değer olarak dönmektedir. Takip sistemleri, silah sistemleri ve hedef saptama ile ilgili yapılan araştırmalar görüntü işleme ve pozisyonlamanın ne kadar önemli bir konu olduğunu ortaya koymuştur. İki eksende hareketin hedef saptama noktasında doğruluk değerinin yükseltilmesi için sistem hatalarının etkin bir şekilde hesaplanıp minimize edilmesi gerekmektedir. Görüntü işleme teknikleri kullanılarak hedef takibi yapan otomatik silah sistemleri son yılların ilgi gören savunma sanayi araştırma konuları arasındadır [1-3]. Mevcut çalışmada hedef tanıma ve takip etme özelliğine sahip bir otomatik silah sistemi için temel bir tasarım hedeflenmiş ve iki farklı hedef


karakteristiği olan renk ve hareket için sistemin başarımı incelenmiştir.

## 2. Sistem Tasarımı

Geliştirilen takip sisteminin girdilerinin işlenmesi ve sistemin genel yapısında çıktı olarak alınması ile ilgili temel öğeler mekanik ve yazılım kısımlarıdır. Sistemin genel işleyişi ile ilgili öğelerin incelenmesi şu şekildedir:

### 2.1. Mekanik


Günümüzde tüm tasarım ve üretim içeren konularda iki aşama bulunmaktadır. Bu aşamalar, bilgisayar destekli tasarım ve bilgisayar destekli üretimdir [4]. Şekil 1. de tasarımı ifade edilen parçaların üretiminde 3D yazıcı ve CNC kullanılmıştır. Sistemin çıktı elemanının esnek olabilmesi, mekanik tasarım ile ilişkilidir. Anahtar kilit uyumu şeklindeki parça tasarımıyla, dişliye bağlanan ekipmanlar çıktıyı belirlemektedir.



Şekil 1. 3D yazıcı çıktıları

Sistem Şekil 2. de gösterildiği gibi mekanik anlamda açık döngü sistemidir. Mikrodenetleyiciden

gönderilen bilgiler ile sabit mesafede servo motorlara kalibrasyonu yapılmış açı bilgisi gönderilmektedir.




Şekil 2. Mekanik sistemin blok diyagramı

Mikrodenetleyiciye gönderilen açı bilgisi, alınan iki boyutlu görüntünün sınırlarının, servoların sınırlarına oranlanmasında (1) ve (2) kullanılmıştır. Bununla birlikte iki boyutlu düzlem eşit bir şekilde açılara bölünerek kalibre edilmektedir.

$$\text{Camwidth}/(\text{xmax} - \text{xmin}) = \text{xratio} \quad (1)$$

$$\text{Camheight}/(\text{ymax} - \text{ymin}) = \text{yratio} \quad (2)$$

Servo yapısındaki potansiyometre, servo motorların pozisyon skalasını belirlerken sürücü ise servo motoru Arduino ile sürmemizi sağlamaktadır. Şekil 3. de sistemin iki eksende hareketine olanak veren mekanizmanın tamamlanmış tasarımı yer almaktadır.




Şekil 3. Tasarımı tamamlanmış mekanizma

Sistemin genel çalışma prensibinde servolara gelen bilgiler doğrultusunda servo motorlar, "Processing" yazılımıyla alınan görüntü penceresindeki hedefi takip edebilecek şekilde hareket edebilmektedirler.

## 2.2. Yazılım

Kameradan alınan görüntüyü işleyerek otonom olarak, belirlenen renkteki bir nesneyi bulma, bulunan nesneyi takip etme, hareket tespit etme ve güvenli renk tespit etme işlemini yapmaktadır. RGB renk teknolojisi ile kameradan pikseller halinde aldığımız görüntü, programımıza art arda resimler halinde gelir. Aldığımız bu resimleri, boyutunu kendi belirlediğimiz bir ekran penceresinde inceliyoruz. Yazılım, bu ekran içerisinde, belirlenen renkte nesneyi RGB renk

teknolojisi kullanarak, bizim belirlediğimiz tolerans aralığında aramaktadır [5]. Tolerans değeri ortamın renk yoğunluğuna göre ayarlanıp, arka plandaki diğer renkler ile kıyaslama yapılarak, istenen renkteki nesne derhal çerçeve içine alınmaktadır. Çerçeve içine alınan nesne tespit edilmiştir, artık takip işlemi başlamaktadır. Takip işlemi artarda gelen resim karelerini kıyaslayarak aradaki farkı görmeye başlamaktadır. Tespit edilen nesnenin, karelerdeki yer değiştirmesine göre sistem nesneyi takip etmektedir. Sistemin yazılımında kodlanmış olan kontrol mekanizması, Şekil 4. deki blok diyagramında verilmiştir.



Şekil 4. Yazılımın blok diyagramı

Hareket tespit sistemi ise belirlenen bir nesneyi değil belirlenen tolerans değeri üstünde olan hareketi algılar. Bunu aynı şekilde resimleri kıyaslayarak yapar. Takip sisteminden farkı ise belirlenen bir renkteki objeyi değil herhangi bir hareketli nesneyi takip etmesidir. Resimler kıyaslanarak değişiklikler algılanıp hareket tespiti yapıldığı için belirli bir eşik değerine ihtiyaç olmaktadır. Eşik değeri üstündeki farklılıklar hareket olarak algılanıp takip edilmektedir. Sistemin karar mekanizması üç aşamadan oluşmaktadır ve bu aşamalar Tablo 1'de verildiği gibidir [6,7].


Tablo 1. Hareket izleme sistemi karar mekanizması

Hedef Saptama	Hedef İzleme	Karar Aşaması
Web Kamera	Hedefin hızı ve hareketini hesapla	Tehdit ise vur
RGB Görüntü	Hedefi izle	Tehdit değilse hedef saptama noktasına geri dön
Takip edilecek kadar büyük		
Hedef işaretle		

Hareket tespit sisteminde güvenli renk tanımı yapılabilmektedir. Bunu belirlenen nesne takip sistemi aracılığı ile yapmaktadır. Sistem güvenli rengi algılayınca derhal hareket algılamayı kapatmaktadır.

Şekil 5. de tasarlanmış ara yüz ile istenen rengin algılanması, hareketin takibi ve tolerans

değerlerindeki değişim ile hedefin boyutuna göre tespit etme ve izleme gerçekleşmektedir. Objeye saptama, hareketi ve rengi izleme özelliklerini OpenCV kütüphanelerinin içerisinde bulunan kütüphanelerin yardımıyla gerçekleştirmektedir. Görüntü işleme konusunda Java yazılım dilinden yararlanılmış, Processing 2 ara yüzü kullanılmıştır [8]. Hedefi saptamayla ilişkili fonksiyonlar Tablo 2'deki gibidir.



Şekil 5. Tanımlanmış renk ve güvenli renk seçenekleri

Tablo 2. Objeye saptama fonksiyonları

Fonksiyon	Fonksiyon özelliği
void start()	Görüntü almayı ve alınan görüntülerin kullanımını etkinleştirir.
void stop()	Görüntü işleme döngüsünü durdurur.
cameraImage(), image()	Alınan görüntüyü matrislere kaydetme işlemini gerçekleştirir.
float x, float y, float w, float h	Görüntü ve gerçek düzlemde iki boyutu tanımlar. range[0;1]
float xMin, float yMin, float xMax, float yMax	Kamera tarafından algılanan cismin sınırlarını belirler.
void setThreshold	Görüntüde tespit edilmesi istenen objelerin boyut veya renk olarak eşik değerini belirler.
void computeBlobs (int[] pixels)	Seçim moduna göre alan tanımı yapar.
int getBlobNb ()	Tanımlanan alanı girdi olarak alır.
Blob getBlob (int n)	Alınan girdiği yazılımda çağırılır.

Hedefi izlemeyle ilişkili fonksiyonlar Tablo 3'deki gibidir. Hedefi manüel olarak kontrol etmeye ilişkin fonksiyonlar ise Tablo 4'deki gibidir. Servo kontrol tekniklerinin yazılım kısmı Arduino prototiplendirme

kartıyla yapılmış olup, yazılım dili olarak Pseudo C kullanılmıştır.

Tablo 3. İzlemeyle ilgili fonksiyonlar

Fonksiyon	Fonksiyon özelliği
void update()	Döngüde meydana gelmiş veya gelebilecek değişiklikleri güncelleyerek çıktıya yansıtır
void adaptivity	Alınan görüntülerin fonksiyona uygun olan kısımlarını alır.
retinaImage()	Geçici belleğe alınan resimleri çağırmak için kullanılır.
findGlobs(int state)	Alınan görüntü sıklığının artırılmasında ve istenen karelerin girdi olarak alınmasında kullanılır.

Tablo 4. Manüel kontrol fonksiyonları

Fonksiyon	Fonksiyon özelliği
mouseX	Farenin yatay eksenindeki koordinatlarını içerir.
mouseY	Farenin yatay eksenindeki koordinatlarını içerir.
mousePressed	Fare tıklamasıyla çağırılan fonksiyonu ifade eder.

Derlenen yazılımın giriş elemanı kabul edilen görüntünün değerleri matrislere depolanır. Karar aşamasından geçer. Yazılımın yürütülmesi esnasında servo motorlara gönderilen sinyalin, belirlenmiş sabit  $z'$  (piksel) mesafesinde çıktı kabul edilen hareketin yatay düzlemde beta; dikey düzlemde de alfa açısı miktarınca değiştiği gözlenmektedir. Servo motorların istenen menzilde, tarama yapması ve istenen düzlem ölçüsünde kısıtlanması mümkündür. Açık çıkışının matematiksel ifadesi dikey düzlemde (3) ve yatay düzlemde (4) gibidir.

$$\alpha = \tan^{-1} \left( \frac{y_{max} - y_{min}}{z'} \right) \quad (3)$$

$$\beta = \tan^{-1} \left( \frac{x_{max} - x_{min}}{z'} \right) \quad (4)$$

$z' = \text{Belirlenmiş sabit mesafe}$

### 3. Sonular ve neriler

Günümüzde görüntü işleme, elektronik ve yazılımsal olarak kapasitelerdeki artış ve hesaplama gücündeki hızlı ilerlemeyle kendine her dalda uygulama alanı bulmaktadır. Sivil güvenlik uygulamalarında kullanılan görüntü işleme tekniklerinin askeri güvenlikte de uygulama alanı bulması yakın gelecekte yaygınlaşması muhtemeldir. Görüntü işleme ve otomatik kontrol yöntemlerinin bir arada kullanılması ise son yıllarda öne çıkan bir yaklaşımdır. Bu yaklaşımla önerilen ve prototip olarak üretilen sistemin bu türde uygulamalara bir örnek teşkil etmesi ve insan faktörünün olumsuz etkilerini ortadan kaldıracak akıllı savunma sistemleri için bir başlangıç olması hedeflenmiştir.

Tasarımı ve üretimi gerçekleştirilmiş takip sistemi, iki ekseninde kameradan alınan görüntüleri başarıyla işlemiş, tasarlanan ara yüz ile opsiyonların arasında geçişi anlık olarak sistemin çalışma karakteristiğine entegre etmiştir. İşlenen görüntülerin içerisinde istenen değerler atanmış, arama kriteri olarak sistemin arka planında çalıştırılmıştır. Hedefin saptanmasını takip eden servo kontrol sistemi, alınan görüntülerin seri haberleşme yöntemiyle mikrodenetleyiciye aktarılmasıyla mekanik bir pozisyonlamaya dönüşmüştür.

Sistemin elektromekanik elemanlarının ve algılayıcı (sensör) ekipmanlarının iyileştirilmesiyle veya yükseltilmesiyle hata payı düşük, farklı hedef türlerini saptamayı ve izlemeyi mümkün kılacak bir çıktı ortaya konulabilir. 3D yazıcı desteğiyle üretilmiş parçaların sisteme kattığı esneklik ile birlikte, çıktı türünü hızlı bir şekilde değiştirecek kabiliyet bulunmaktadır. Hedefin güneş olarak belirlenmesiyle, güneş panelinin pozisyonlanması; hedefin termal aktivite olarak belirlenmesiyle yangın söndürücü sistemin pozisyonlanması; hedef listesi olarak bir kayıt defterinin tanıtılmasıyla kamera sistemlerine bireyin konumunu pozisyonlaması sistemin kabiliyetleri dahilindedir.

### 4. Teşekkür

Bu çalışma, Gaziantep Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü “EEE 499 Graduation Project” dersi kapsamında mezuniyet projesi olarak gerçekleştirilmiştir. Bu olanağı sağlayan bölümümüz öğretim üyelerine ve mezuniyet projesi komitesine teşekkür ederiz.

### 5. Kaynaklar

- [1] Shue, Sam, Claude Hargrove, and James Conrad. "Low cost semi-autonomous sentry robot." *Southeastcon, 2012 Proceedings of IEEE*. IEEE, 2012.
- [2] AKIR, Hüseyin, and Habibe Kübra BABACAN. "Hareketi Algılayan Kamera Destekli Güvenlik." *INTERNATIONAL JOURNAL OF INFORMATICS TECHNOLOGIES* 4.2 (2011).
- [3] Abielmona, Rami, et al. "Mission-driven robotic intelligent sensor agents for territorial security." *Computational Intelligence Magazine, IEEE* 6.1 (2011): 55-67.
- [4] SARCAR, MMM, K. Mallikarjuna Rao, and K. LALIT NARAYAN. *Computer aided design and manufacturing*. PHI Learning Pvt. Ltd., 2008.
- [5] Trussell, H. Joel, Eli Saber, and Michael Vrhel. "Color image processing: Basics and special issue overview." (2005).
- [6] Moeslund, Thomas B., and Erik Granum. "A survey of computer vision-based human motion capture." *Computer Vision and Image Understanding* 81.3 (2001): 231-268.
- [7] Wang, Xiang-Yang, Yong-Jian Yu, and Hong-Ying Yang. "An effective image retrieval scheme using color, texture and shape features." *Computer Standards & Interfaces* 33.1 (2011): 59-68.
- [8] Reas, Casey, and Ben Fry. "Processing: programming for the media arts." *AI & SOCIETY* 20.4 (2006): 526-538.

## Konjestif Kalp Yetmezliğinin Hilbert-Huang Dönüşüm ile Analizi

Gökhan ALTAN<sup>\*1</sup>, Apdullah YAYIK<sup>2</sup>, Yakup KUTLU<sup>3</sup>, Serdar YILDIRIM<sup>4</sup>, Esen YILDIRIM<sup>5</sup>

<sup>1,3,4,5</sup>Bilgisayar Mühendisliği Bölümü, Mustafa Kemal Üniversitesi, HATAY

<sup>2</sup>Kara Kuvvetleri Komutanlığı

gokhanaltan@mku.edu.tr, ayayik@kkk.tsk, ykutlu@mku.edu.tr, serdar@mku.edu.tr, eyildirim@mku.edu.tr

### Özet

*Hilbert-Huang Dönüşümü (HHD) lineer olmayan ve sabit olmayan sinyaller üzerinde öznitelik belirleme, filtreleme ya da benzeri işlemlere ön işleme olarak sıkça kullanılmaktadır. Bu çalışmada, HHD yönteminin kalp ritim sinyallerine uygulanması sonucu elde edilebilecek özniteliklerin belirlenmesi ve kullanılması üzerine çalışmalar yapılmış ve Konjestif Kalp Yetmezliği (KKY) olan hastaların kontrol grubundan ayırt edilmesi için kullanılmıştır. Çalışmada kalp hızı değişkenlerinden elde edilen RR sinyalleri, HHD işleminden geçirilerek içsel mod fonksiyonları (IMF) elde edilmiş, dönüşüm sonrası istatistiksel bilgiler öznitelik olarak çıkarılmıştır. Elde edilen öznitelikler, Yapay Sinir Ağları (YSA) kullanılarak sınıflandırma başarımı incelenmiştir. Sonuç olarak, elde edilen son sinyallerin istatistiksel öznitelikleri kullanılarak %95.65 sınıflama başarımı elde edilmiştir.*

### 1. Giriş

Sinyal analizinde, birçok integral dönüşümler ve bu dönüşümlerin daha sonuçlanması zor olan döngüsel olanları kullanılır. Fourier Dönüşümü, Laplace Dönüşümü, Hilbert Dönüşümü, Wavelet Dönüşümü ve diğerleri bu integral dönüşümlerin en önemlilerindedir [1]. Gün geçtikçe artan çalışmalar sonrasında lineer ve sabit olmayan veriler üzerindeki imkânları genişleten tekniklere ihtiyaç duyulmuştur. HHD bunlardan biridir. HHD, veri analizi konusunda yeni sayılabilecek kullanıma sahip bir metottur. Bu dönüşüm lineer olmayan ve sabit olmayan sinyaller için uygulanabilir niteliktedir [2].

Son yıllarda yapılan çalışmalarda HHD, EEG sinyalleriyle incelenerek şeker hastalığının tespiti [7], epileptik nöbet tahmini [3], ses sinyallerini HHT uygulanması filtreleme ve öznitelik çıkarma işlemleri [8], spektrum algılamasına yönelik sayısal modülasyon sınıflandırması [9], ECG sinyallerinde kalp kulaklığı seçirmesi rahatsızlığının tespiti [10]

gibi birçok çalışmada kullanılan bir araç olmuştur. Bu akademik çalışmalara bakıldığında, EEG, ECG, Ses Sinyali, Elektrik sinyalleri ve resim gibi birçok alanda öznitelik çıkarmak için kullanılan HHD, bu çalışmada KKY hastalarını normal insanlardan ayırmak için kullanılacaktır. KKY, organizmanın metabolik ihtiyaçlarını karşılayacak yeterli kardiyak debinin kalp tarafından sağlanamaması halidir. Kalp, ihtiyaç duyduğu durumlarda debi kapasitesini %200-600 oranında arttırabilir. Kalbin bu artırılabilen debi kapasitesinin aşılması veya artan debi ihtiyacını karşılayamaması durumunda KKY rahatsızlığı teşhisi konur [6].

Bu çalışmada, HHD yöntemiyle elde edilen öznitelikler KKY hastalığının teşhis edilmesinde kullanılmıştır. Her bir IMF'e göre başarımlar değerlendirilmiştir ve karşılaştırılmıştır.

## 2. Materyal ve Yöntemler

### 2.1. Hilbert-Huang Dönüşümü (HHD)

HHD, doğrusal olmayan ve durağan olmayan süreçlerin analizi için kullanılan uyarlamalı bir yöntemdir. Algoritmanın matematiksel ifadesi durma değerlerinin esnekliği sebebiyle keskin ve net bir şekilde tanımlanamamıştır [3]. HHD, iki aşamalı bir analiz yöntemidir. İlk olarak Amirik Mod Ayırma (AMA) ile sürece ilişkin sinyalin, her biri frekans modülasyonlu birer işaret olan İçsel Mod Fonksiyonu (IMF) çıkartılır. Elde edilen her bir IMF'den Hilbert İzgesel Analizi (HİA) ile zaman-frekans alanında anlık frekans ve genlik değerleri elde edilir. HHD doğrusal olmayan ve durağan olmayan süreçlerin zaman-frekans-enerji gösterimlerinde, diğer yöntemlerden daha keskin, ayırt edici ve net sonuçlar verir [2].

#### 2.1.1. Amirik Mod Ayırma (AMA)

Doğrusal olmayan ve durağan olmayan süreçlere ait veriler için kullanılan esnek bir analiz yöntemidir. Diğer dönüşümlerden ayrıldığı en önemli özelliği

rasgele bir işaretin, kendine ait farklı frekanslardaki öz kip salınımlarından oluştuğu varsayımıyla sinyalden ayrı salınımlar üreten bir algoritma olmasıdır. Her salınım yerel uç noktalarıyla elde edilen yerel ortalamalarına göre simetrik. Her bir farklı salınım IMF ile gösterilir. IMF aşağıdaki iki temel koşulu sağlayacak şekilde seçilir [2,4]: Tüm sinyalde, yerel uçdeğerlerin ve sinyalin sıfırdan geçişlerin sayısı ya aynı olmalı ya da farkları 1'e eşit olmalıdır. Herhangi bir  $t$  anında, yerel maksimumların ve yerel minimumların birleştirilmesiyle elde edilen üst zarfın ve alt zarfın ortalama değeri sıfır olmalıdır.


IMF'ler elde edilirken belirtilen şartları, HİA ile anlık frekans değerleri hesaplanırken negatif frekansların oluşmasını önlemek ve dar bantlı sinyallerin anlık frekans değerlerini, bantta tutmak için kullanılır.

AMA işleminde, yerel maksimumlar tarafından belirlenen üst zarf ile yerel minimumlar tarafından belirlenen alt zarfın ortalaması alınarak yerel ortalama değeri bulunur. Şekil 1'de görülmektedir.

Bulunan ortalama değer asıl sinyalden çıkarılarak elde edilen yeni sinyalin IMF olma koşulunu sağlayıp sağlamadığı kontrol edilir. Eğer sağlamıyorsa tekrar yerel maksimum ve yerel minimum değerleri kullanılarak yerel ortalama değeri tekrar hesaplanır. Bu işlem elde edilen sinyal IMF oluncaya kadar gerçekleştirilir. Bu sinyal, asıl sinyalden çıkarılarak artık sinyal elde edilir ve aynı IMF oluşturma işlemleri artık sinyal için yapılmaya devam edilerek tüm sinyal için monotonik bir fonksiyon elde edilinceye kadar devam eder.

Sinyal monotonik bir fonksiyon olduğunda ya da sinyalde yalnızca bir adet yerel uç değeri olduğunda bu sinyalden IMF çıkarmak mümkün değildir ve AMA işlemine son verilir. AMA işleminden sonra  $c$  elde edilen IMF,  $r(t)$  artık sinyal ve  $n$  algoritmadaki adım sayısını ifade eder [3].

$$x(t) = \sum_{n=1}^n c_i(t) + r_n(t) \quad (1)$$



Şekil 1. AMA uygulanan bir KKY sinyali.

### 2.1.2. Hilbert İzgesel Analizi

Doğrusal olmayan sinyallerin en önemli özelliklerin başında tek bir salınım süresinde anlık frekans değerlerini gösteren içsel dalga frekans modülasyonu. Sinyalin karakteristiğini en anlaşılır şekilde anlık frekans değerleri verir. Anlık frekans değeri Hilbert Dönüşümü (HD) sinyalin karakteristiğini belirlemeye yönelik frekans işlemidir [2,3].

Gerçek değerli  $x(t)$  fonksiyonunun HD uygulanmış halinin karmaşık eşleniği  $y(t)$ 'ye eşittir.

$$y(t) = H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (2)$$

HD yardımıyla analitik  $x(t)$  fonksiyonu aşağıdaki gibi yazılır:

$$z(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (3)$$

Yukarıdaki ifadede anlık genlik ve faz fonksiyonu şu şekildedir:

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad (4)$$

$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (5)$$

Yukarıdaki fonksiyondan anlık frekans bilgisi elde edilebilir:

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (6)$$

$$f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (7)$$

$x(t)$  işaretine AMA işlemi uygulandıktan sonra her bir IMF'nin Hilbert Dönüşümü alınırsa  $x(t)$  işaretinin analitik ifadesi elde edilebilir. Her bir IMF'nin anlık frekans ve genlik değerleri (4), (5), (6) ve (7) yardımıyla şu şekilde ifade edilir:

$$x(t) = \Re \left\{ \sum_{i=1}^n a_i(t) e^{j\omega_i(t)t} \right\} \quad (8)$$

Yukarıdaki denklem her bir IMF'nin genlik ya da frekans modülasyonlu işaretler olduğunu göstermektedir. AMA, işareti değişken genlik ve frekans ölçeklerinde analiz ederek durağan olmayan işaretler için oldukça iyi bir ayırıştırma işlemi gerçekleştirir [3].

Genliğin frekans-zaman dağılımına ( $\omega$ ) Hilbert İzgesi denir. Hilbert İzgesi kullanılarak, Marjinal İzgesi de hesaplanabilir [2,3].

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (9)$$



## 2.2. Veritabanı

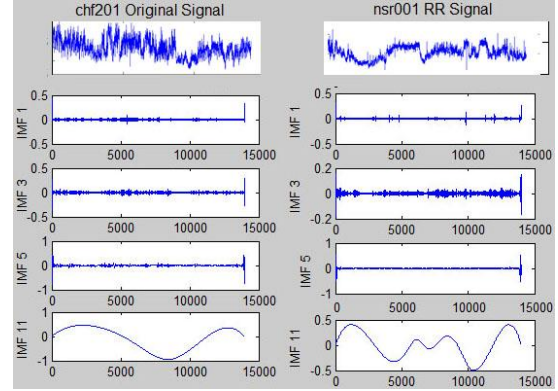
Bu çalışmada Physionet veritabanından KKY ve Normal grup RR kayıtları kullanılmıştır [5]. Yaşları 34 ile 79 arasında değişen, KKY hasta veritabanı, 8 erkek, 2 bayandan alınmıştır. Normal grup veri tabanı yaşları 28 ve 76 arasında değişen 30 erkek ve yaşları 58 ile 73 arasında değişen 24 bayandan alınmıştır. Sinyallerin çok uzun olmasının ve ECG sinyallerinde hastanın anlık durumlarından kaynaklı fazla gürültüye sahip olmasından dolayı, gürültüsüz 3 saatlik formlar alınarak tüm analiz işlemlerinde kullanılmıştır.

## 2.3. Ön İşlemler ve Özniteliklerin Çıkarılması

Elde edilen sinyaller aynı frekans değerine getirilmiş ve her biri AMA işlemine tabi tutulmuştur. AMA işlemi uygulanmış sinyallerin tüm IMF'lerine HIA uygulanarak aynı sayıda HHD işlemleriyle sinyal elde edilmiştir. HHD uygulanmış bir KKY ve normal grup insan ECG RR sinyali ve bu sinyalden elde edilen bazı IMF dağılımı Şekil 2'de görülmektedir. 83 adet sinyale ait, her bir sinyalin 10 ile 14 arasında değişen IMF elde edilmiştir. Burada her kayıt için ilk 10 IMF Öznitelik çıkartmak için kullanılmıştır. Daha sonra Hilbert dönüşümü yapılarak, istatistiksel öz nitelik çıkarma işlemleri gerçekleştirilmiştir. Her bir IMF dönüşümüne ait minimum, maksimum, orta değeri, ortalama, varyans, kovaryans, sık tekrar edilen değer, korelasyon katsayısı, enerji ve standart sapma gibi 10 adet öznitelik hesaplanmıştır.

## 2.4. Sınıflandırma ve Performans Ölçümü

Yapay sinir ağlarının(YSA)'da giriş değerleri, ağırlıkları ya da rastgele alınan ağırlıklar ile çıkış değerleri elde edilmektedir. Bu işlem elde edilen çıkış değeri ile gerçek çıkış değeri arasındaki hatayı minimum yapana kadar sürer. Buna modelin eğitimi denir. Bu eğitimde nöronların ağırlıkları belirlenmiş grafiği elde edilir. YSA'nın avantajlarından bazıları; bilinen durumlardaki sonuçları kullanarak bilinmeyen durumlar hakkında karar verebilmesi ve sistemin geçerliliğini belirleyen güvenilirlik ile verimlilik derecesinin yüksek olmasıdır [11].



Şekil 2.KKY ve Normal ECG RR Sinyali ve IMF'leri

Bu sistemin başarımlarının değerlendirilmesinde, genel başarımlar ölçütü, belirlilik ve hassasiyet ölçütleri kullanılmıştır [10,11]:


## 3. Sonuçlar

Medikal teşhis sistemlerinde hassasiyet ve belirlilik, nüfus genelindeki rahatsızlıkları belirlemeyen, test için esas alınan hâkim bağımsız test karakteristikleridirler [7,11]. Bu durumlar göz önünde bulundurularak ECG sinyallerinden ele alınan 3 saatlik kalp hızı sinyallerden HHD işlemi sonucu IMF'ler elde edilmiştir. Elde edilen her IMF'nin dönüşüm yönteminden elde edilen öz nitelikleri birleştirilerek veri kümesi oluşturulmuştur. Oluşturulan veri kümesinin üçte biri test için geri kalan kısmı eğitim için kullanılmıştır. Eğitim kümesi için kullanılan değerlerin denekleri rastgele seçilmiş ve deneklerin geri kalanları test kümesi olarak seçilmiştir. Çalışmada Matlab paket programı kullanılmıştır. 10 gizli katman, hiperbolik tanjant sigmoid fonksiyonu ile geriye yayılım ağı eğitim fonksiyonu kullanılarak YSA yapısı eğitilmiştir. Rastgele seçilen eğitim kümesinde bulunan öznitelikler, YSA ile sınıflandırılmış hassasiyet, genel başarımlar ve belirlilik değerleri hesaplanmıştır. Bu işlem tüm IMF'ler için yapılmış ve 100 deneme sonucu elde edilen en iyi değerler Tablo 1'de belirtilmiştir. sonuçlar kendi içerisinde değerlendirildiğinde 3 ve 4 numaralı IMF sinyallerinin genel başarımlar oranları diğer IMF'lere göre oldukça yüksek olduğu saptanmıştır.

Tablo 1. YSA Sınıflandırma Sonuçları.

	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
<b>Hassasiyet</b>	71.42	78.57	100,00	92.85	92.85	85.71	85.71	85.71	78.57	78.57
<b>Belirlilik</b>	60.00	70.00	100,00	90,00	87.50	77.77	77.77	75.00	66.67	66.67
<b>G.Başarımlar</b>	69.56	78.27	95.65	95.65	86.95	82.60	82.60	78.26	73.91	69.56

%95.65 gibi genel başarımları sonucu elde edildiği görülmüştür. Genel başarımların yanında sistemin güvenilirliğini ölçen Hassasiyet ve Belirlilik değerlerine göre de daha yüksek olduğu görülmektedir. Şekil 3'te performans grafiği gösterilmiştir. Elde edilen bu verilere göre KKY olan hastadan alınan RR sinyaller, HHD işlemleri uygulanması sonucu istatistiksel öznitelikler oluşturulmuş ve KKY olup olmadığının belirlenmesi 3 numaralı IMF ile %95.65 Genel Başarımlar, %100 Hassasiyette ve %100 Belirlilikte tespit edilebilmektedir.



Şekil 3. Performans grafiği.

Literatürde KKY hastalığını teşhisi için çok farklı yöntemler kullanılarak öznitelikler çıkartılmıştır. Bunlar içinde, poicare fark değerlerini ve istatistiksel değerleri [6], EKG sinyalinin öz değerlerini [12], ikinci derece fark harita grafiği verilerini kullanarak [13], genlikte ve zamanda eşit frekans yöntemi [14], kalp hızı değişkenlerinin normalleştirilmesi [15] gibi farklı değerlerini sınıflandırıcıda öznitelik olarak kullanılmıştır.

HHD, işareti değişken genlik ve frekans ölçeklerinde analiz ederek durağan olmayan işaretler için oldukça iyi bir ayrıştırma işlemi gerçekleştirdiği söylenebilir.

#### 4. Kaynaklar

[1] M. Johansson: The Hilbert Transform, Master thesis, Växjö University, Sweden  
 [2] A.B. N.E. Huang, Z. Shen, S.R. Long, M.L. Wu, H.H. Shih, Q. Zheng: The empirical mode decomposition and Hilbert spectrum for nonlinear and nonstationary time series analysis, London A, Vol. 454, pp. 903–995, 1998  
 [3] F.Duman, N.Özdemir, E.Yıldırım, "Patient Specific Seizure Prediction Algorithm Using Hilbert-Huang Transform". IEEE-EMBS Intern. Conf on BHI. Hong Kong, Shenzhen 2012  
 [4] Y. Hou, H.Tian, "An automatic modulation recognition algorithm based on HHD and SVD",

Image and Signal Processing(CTSP), 3rd International Cong.vol.8,pp.3577-3581, 2010.  
 [5] Goldberger, A.L., Amaral, L.A.N., vd. 2000. PhysioBank, PhysioToolkit, and PhysioNet: 101(23), e215–e220.  
 [6] Y. İşler and M. Kuntalp, "Combining classical HRV indices with wavelet entropy measures improves to performance in diagnosing congestive heart failure.," Comput. Biol. Med., vol. 37, no. 10, pp. 1502–10, Oct. 2007.  
 [7] S.Bursikova, "Application of Hilbert-Huang Transform to the data of blood glucose profile", Student's Conference STC 2007, Faculty of Mechanical Engineering, Czech Technical University, Prague  
 [8] M.Verner, "Hilbert-Huang Transform, its features and application to the audio signal", Student's Conference STC 2007, Faculty of Mechanical Engineering, Czech Technical University, Prague  
 [9] Y.Tanç, A.Akan, "Hilbert-Huang Dönüşümü İle sayısal Modülasyon türü Sınıflandırması 21st Signal Processing and Communications Applications Conference (SIU2013), pp,1-4, April 2013, DOI: 10.1109/SIU.2013.6531183  
 [10] U Maji, M Mitra, S. Pal, "Automatic Detection of Atrial Fibrillation Using Empirical Mode Decomposition and Statistical Approach", 2013  
 [11] Duda, R.O., Hart, P.E., Stork, D.G. 2000. Pattern Classification. 2. Baskı, Wiley, New York.  
 [12] E. D. Ubeyli, "Adaptive neuro-fuzzy inference system for classification of ECG signals using Lyapunov exponents.," Comput. Methods Prog Biomed., 2009.  
 [13] R. A. Thuraisingham, "A Classification System to Detect Congestive Heart Failure Using Second-Order Difference Plot of RR Intervals.," Cardiol. Res. Pract., vol. 2009, p. 807379, Jan. 2009.  
 [14] U. Orhan, "Real-time CHF detection from ECG signals using a novel discretization method.," Comput. Biol. Med., vol. 43, no. 10, pp. 1556–62, Oct. 2013.  
 [15] Y. Isler, and M. Kuntalp, Heart Rate Normalization in the Analysis of Heart Rate Variability in Congestive Heart Failure, Proceedings of the IMechE Part H: Journal of Engineering in Medicine, vol. 224(3), 453-463, 2010



# SÜRÜ SİMÜLASYON PROGRAMI GELİŞTİRİLMESİ VE PERFORMANSININ İNCELENMESİ

Fatih Cemal CAN<sup>1</sup>, Hayrettin ŞEN<sup>2</sup>

<sup>1,2</sup> Mekatronik Mühendisliği Bölümü  
Mühendislik ve Mimarlık Fakültesi  
İzmir Katip Çelebi Üniversitesi, İZMİR

Email: fatihcemal.can@ikc.edu.tr

hayrettin.sen@ikc.edu.tr

## Özet

*Doğada bulunan canlıların sürü davranışları robotik uygulamaların geliştirilmesi açısından oldukça önemlidir. Sürülerin kolektif yapıları sürü robotlarının kontrol edilmesinde kullanılmaktadır. Bu çalışmada balık sürülerinin davranış hareketleri temel alınarak bir bilgisayar simülasyonu geliştirilmiştir. Simülasyon dört farklı durum içermektedir. Arama, sürü, beslenme, ve kaçış durumlarının simülasyonu yapılmıştır. Geliştirilen simülasyon daha sonraki çalışmalarda robotik balıkların kontrolünde kullanılacaktır.*

## 1. Giriş

Kolektif hareketler, sürü içerisindeki bireylerin karşılıklı iletişimi ile gerçekleşir. Bu hareketler doğada bulunan balık, arı, kuş ve karınca gibi bazı hayvanlar tarafından sergilenmektedir. Bireyler arasındaki ikili ilişkiler en basit şekli ile üç kural ile ifade edilebilir. Birinci kural bireyin belli bir mesafede bulunan diğer bireylere yaklaşmasıdır (çekim alanı). İkinci kural bireyin diğer bireylere mümkün olduğunca yakın kalmasıdır (paralel yönlenme alanı). Sonuncusu ise bireylerin çarpışmalarını önlemek için uzaklaşma alanıdır (itme alanı).

Bilgisayarın bulunuşundan sonra hızlı bir şekilde gelişmesi ile kolektif hareketlerin simülasyonlarını oluşturmak kolaylaştı. Literatürde bir çok simülasyon çalışması bulunmakta. Bunlardan ilki 1987 yılında Craig tarafından geliştirilen kuş simülasyonu idi [1]. Bilgisayar donanımının yeni gelişmeye başladığı bu yıllarda benzer simülasyon çalışmaları çok azdı. Fakat, günümüzde bu tip çalışmalar oldukça yaygındır. İnada balık sürülerinin kolektif hareketleri 50 birey kullanılarak incelemiştir [2]. Söz konusu

çalışmada sürünün gitmeyi tercih ettiği yön analiz edilmiştir. Simülasyon çekim, paralel yönlenme ve itme alanlarını içermektedir. Diğer bir taraftan, Ströbom sadece çekim alanı içeren bir model önermiştir [3]. Ströbom bu çalışmada önerilen model ile üç farklı faz üretmiştir. Bu üç faz sürü, yönlenmesiz dönme ve hizalanmış grup hareketidir.

Kolektif hareket üzerine hazırlanan bilgisayar programlarının geliştirilmesinde kullanılan algoritmalar sürü robotlara uygulanmıştır. Hayvanlar tarafından sergilenen kolektif hareketler sürü robotlarının kontrolünü sağlamaktadır. Atyabi eğitilen ve test edilen sürü robotlar tasarlamıştır [4]. Benzer bir çalışma Venayagamooty tarafından iki yeni yaklaşım önerilerek sunulmuştur [5]. İlk yaklaşım bireyler üzerine gömülü bir fuzzy mantığıdır. İkincisi sürü üzerine uygulanan fuzzy mantığı kontrolcü tasarımıdır.

Bu çalışmada dört farklı durumdan oluşan yeni bir sürü simülasyonu geliştirilmiştir. Simülasyon üç farklı canlı tipi içermektedir. Büyük, orta ve küçük tipte balıklar simülasyona eklenebilmektedir. Bu çalışmada geliştirilen simülasyon, Can ve arkadaşları tarafından sunulan çalışmanın devamı niteliğindedir [6]. Simülasyon özellikleri oldukça geliştirilmiştir.

## 2. Kolektif Hareketin Matematiksel Modeli

Bu çalışmada bireylerin pozisyonlarının belirlenmesine yönelik matematiksel model kullanılmıştır[2,7]. Bu matematiksel model bilgisayar ile modellemeye çok uygun olduğu için tercih edilmiştir. Simülasyon çalışmaya devam ederken simülasyona bireyler eklenebilir. Simülasyon alanına fare ile tıkladığında, simülasyona bir birey eklenmektedir. Bu yüzden simülasyon başlangıcında

kesin birey sayısı belirlenmemiştir. Bireylerin simülasyon alanı üzerindeki başlangıç konumu  $(x_j(0), y_j(0))$  kullanıcı tarafından belirlenmektedir. Bireylerin hızları ve dönmeleri random fonksiyonu kullanılarak hesaplanmıştır.

$$t = t + \Delta t \quad (1)$$

Zaman  $(t)$ , (1) ile verilen denklem ile hesaplanmıştır. Zaman adımı  $(\Delta t)$  20 mili saniye olarak seçilmiştir. Simülasyonun başlangıcında da zaman sıfır olarak ayarlanmıştır.

Bireylerin pozisyonu onların bir önceki pozisyonuna, yeni hızına ve yeni oryantasyonuna (o anki x eksenini ile yapığ açı değeri) göre belirlenir:

$$x_j(t) = x_j(t - \Delta t) + \Delta t v_j(t) \cos \beta_j(t) \quad (2)$$

$$y_j(t) = y_j(t - \Delta t) + \Delta t v_j(t) \sin \beta_j(t) \quad (3)$$

Burada  $x_j(t)$ ,  $y_j(t)$ ,  $v_j(t)$  ve  $\beta_j(t)$  j nolu bireyin  $t$  zamanında sırasıyla yatay pozisyonunu, dikey pozisyonunu, hızını ve oryantasyonunu tanımlamaktadır. Hız ve oryantasyon Gamma dağılımı kullanılarak rastgele bir fonksiyonla tanımlanmıştır.

### 3. Önceki ve Yeni Simülasyondaki Kolektif Hareket

Sürünün bireyleri bazı matematiksel kurallara göre hareket etmelidirler. Huth [7] ve Inada [2]'nin çalışmalarında gösterilen matematiksel modelin benzeri bu çalışmada kullanılmıştır. Bireyler arasındaki bütün Euclidean mesafeleri program tarafından hesaplanmaktadır. Bireylerin yönü hesaplanan mesafeye göre belirlenmektedir. Bu mesafe çekim, paralel yönlenme ve itme alanının yançapları ile karşılaştırılmalıdır. Eğer hesaplanan mesafe *çekim alanı* içinde ise bireyler birbirlerine doğru hareket ederler. Bireyin diğer bireylere mümkün olduğunca yakın kalması *paralel yönlenme alanı* içinde oluşmaktadır. Bireylerin çarpışmalarını önlemek için uzaklaşma alanı *itme alanı* olarak tanımlanmıştır.

Önceki simülasyonda [6] sürü içinde ikili ilişkileri incelemek için sadece iki birey bulunuyordu. Önceki simülasyona sabit engeller ve yemler eklenebiliyordu. Yeni simülasyon geniş ölçüde önceki simülasyon temel alınarak geliştirilmiştir. Yeni çalışmada kullanılan daha büyük simülasyon alanı ilk gelişmedir. Yeni simülasyonda ikiden daha fazla birey

oluşturulabilir. Simülasyon alanına fare ile tıklanarak simülasyona yeni bir birey eklenebilir. Yemler bu simülasyonda hareketli olarak programlanmıştır. Simülasyon sırasında yemlerin sayısı değişebilir. Eğer yem avcıya çok yakınsa avcı yemi yiyebilir yada yemin hızını artırarak kaçma ihtimalide vardır. Önceki simülasyonun algoritması sabit yemler nedeniyle yeni algoritmadan daha kolaydır. Yeni simülasyonda hareketli yemleri eklemek için bir buton bulunmaktadır. Bireyler yemlere ilişkin konumlarına göre davranırlar.


Simülasyon algoritması oluşturulurken bazı varsayımlar dikkate alınmıştır. Bu varsayımlar aşağıdaki gibidir;

1. Birey sayısı sabit bir sayıya kadar kısıtlanmamıştır. Program çalışırken bile simülasyon alanının herhangi bir yerine yeni bireyler eklenebilir. Fakat, bilgisayarın performansı da göz önünde bulundurulmalıdır.
2. Balıkların hareketi için iki boyutlu sınırlı bir alan tanımlanmıştır. Bu varsayım kolektif hareketi gözlemlemek için yararlıdır. Çünkü sürü hareketi sınırlı alandan dolayı kolaylıkla şekillenebilir.
3. Bireylerin hareketi iki parametre tarafından sağlanır: hız ve yön.
4. Her bireyin pozisyonu ve oryantasyonu her 20 milisaniyede bir hesaplanır. Aynı zamanda bireyin kontrolü bu zaman aralığında sağlanır.
5. Bir balığın hareketi gruptaki her bir balık tarafından etkilenebilir. Bireyler arası Euclidean mesafesi bireylerin karar vermesinde etkilidir.
6. Bireylerin hareketi dış etkilere maruz kalabilir. Örneğin, herhangi bir sayıda hareketli yem eklenebilir ve bu eklenen yemler bireylerin hareketini etkiler.

### 4. Simülasyonda Bireylerin Tanımlanması İçin Kullanılan İki Metot Ve Bunların Performansa Etkisi

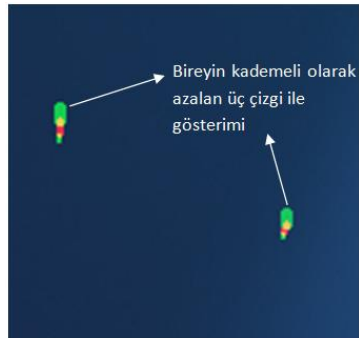
Simülasyon Intel Core Duo CPU P7350 2.00 GHz işlemci, 4 GB RAM, Nvidia Geforce 9600M GS ekran kartı özelliklerine sahip bilgisayarda test edilmiştir. Simülasyon Windows Vista 32-bit işletim sisteminde çalıştırılmıştır.

Bireylerin grafikleri doğrudan bilgisayarda çalışan simülasyonun performansını etkilemiştir. Mesela, Şekil 1'de gösterildiği gibi baş kısmı için daire ve kuyruk kısmı için çizgi kullanıldığında, bilgisayarın performansı yaklaşık olarak otuz bireyli bir simülasyonda önemli ölçüde azalmaktadır. Kolektif simülasyon çalışmalarının bazıları, simülasyonda bireyleri gösterirken benzer metodu kullanmışlardır [2,3,6]. Fakat, bu metod bilgisayarın performansı için iyi değildir. Bireylerin sayısı artarken bilgisayarın işlemcisi simülasyonu çalıştırmakta zorlanmaktadır.



Şekil 1. Bireylerin tanımlanması için ilk metod

Diğer taraftan, eğer Şekil 2'deki gibi kafa kısmından kuyruk kısmına kadar kalınlığı kademeli olarak azalan üç çizgi kullanılırsa, simülasyonun çalışma performansı bir önceki metoda göre artar. Aynı zamanda simülasyonun grafiksel gerçekliği daha iyi bir forma dönüştürülür.




Şekil 2. Bireyin tanımlanması için ikinci metod

Simülasyon iki grafiksel gösterim metodu için de çalıştırılmıştır. Bilgisayarın performansı Windows CPU ölçer kullanılarak ölçülmüştür. İlk tanımlama metodu için 35 birey kullanıldığında, işlemci kullanımı % 59 ve RAM kullanımı % 61'dir. İkinci tanımlama metodu 37 birey için kullanıldığında işlemci kullanımı % 28 ve RAM kullanımı % 61'dir (Şekil 3'e bakınız).


Aynı simülasyon Intel Core i5-3210M 2.50 GHz işlemci, 4 GB RAM, Intel HD Graphics 4000 ekran

kartı özelliklerine sahip başka bir bilgisayarda yeniden test edilmiştir. Bilgisayarın donanımı simülasyon performansı için önemlidir. Bu kez simülasyon Windows7 64-bit işletim sisteminde çalıştırılmıştır. İki bilgisayar karşılaştırıldığında bu bilgisayar işlemci ve işletim sistemi bakımından bir öncekinden daha iyidir.

CPU ölçer aracından yapılan ölçüme göre de ikinci bilgisayarın performansı birinciye göre daha iyidir. Ayrıca bireyin ikinci tanımlama şekli daha iyi performans sonucu vermiştir (Şekil 4'e bakınız).




Şekil 3. Bireylerin iki farklı tanımlama metodu ve bunların performansa etkisi- ilk bilgisayar (Windows Vista CPU ölçer)



Şekil 4. Bireylerin iki farklı tanımlama metodu ve bunların performansa etkisi- ikinci bilgisayar (Windows 7 CPU ölçer)

Simülasyon renkli şekiller ile gösterilmiştir. Fakat balıkların kolektif hareketi zaman değişirken bu şekillerden (Şekil 3 ve 4) anlaşılabilir. Bu yüzden, balıkların kolektif hareketini kağıt üzerinde daha açık bir şekilde göstermek durumundayız. Zamanla balık hareketlerini tanımlamak için gri tonlama gösterimi kullanılabilir. Şekil 5'te bireylerin zamana göre hareketi, okların gri ton koyuluğuna göre tanımlanır.



Şekil 5. Balık hareketlerinin gri tonlama gösterimi

## 5. Sonuçlar

Bu çalışmada balıkların kolektif hareket simülasyonu çalışılmıştır. Bir önceki simülasyon çalışması oldukça geliştirilmiştir. Simülasyon iki ayrı dizüstü bilgisayar üzerinde test edilmiş ve performans sonuçları karşılaştırılmıştır.

Bireylerin grafiksel tanımlamaları için iki ayrı metod önerilmiş ve performans kıyaslamaları yapılmıştır. Simülasyon için üç kademeli çizgiden oluşan gösterim performans açısından daha iyi bulunmuştur.

Bir sonraki çalışma için geliştirilen algoritma sürü mobil robotlar üzerinde uygulanacaktır.

## 6. Kaynaklar

- [1] Craig W. Reynolds, "Flocks, Herds, and Schools: A Distributed Behavioral Model", Computer Graphics, Volume 21, Number 4, July 1987, s. 26-34
- [2] Inada Y., "Steering mechanism of fish schools", Complexity International, Volume 08, 2000, s. 1-9.
- [3] Strömbom D., "Collective motion from local attraction", Journal of Theoretical Biology, Volume 283, Issue 1, 21 August 2011, s. 145-151.

- [4] Atyabi A., Somnuk P.-A., Ho C. K., "Navigating a robotic swarm in an uncharted 2D landscape", Applied Soft Computing, Volume 10, 2010, s. 149-169.
- [5] Venayagamoorthy G. K., Grant L. L., Doctor S., "Collective robotic search using hybrid techniques: Fuzzy logic and swarm intelligence inspired by nature", Engineering Applications of Artificial Intelligence, Volume 22, 2009, s. 431-441.
- [6] F. Cemal CAN, Çağdaş BAYRAM, A.Kaan TOKSOY, Hakan AVSAR, Serhan OZDEMIR, "Characterization Of Swarm Behavior Through Pairwise Interactions By Tsallis Entropy", ICAI 2005, Las Vegas, Nevada, USA, Volume 2, 2005, s. 736-741.
- [7] A. Huth and C. Wissel, "The Simulation of the Movement of Fish Schools", J. theor. Biol., 1992, s. 365-385.

## FPGA Tabanlı Gerçek Zamanlı Bir Görüntü İşleme Sisteminin Gerçeklenmesi

Vecdi Emre LEVENT<sup>1</sup>Fethullah KARABİBER<sup>2</sup><sup>1,2</sup>Bilgisayar Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, Beşiktaş, İSTANBUL

E-Posta: emre@levent.tc

fkara@yildiz.edu.tr

### Özet

*Mevcut merkezi işlemci gibi standart mimariler her geçen gün artan işlem gücü ihtiyacına cevap verememektedir. Alanda Programlanabilir Kapı Dizileri (FPGA) gibi yeniden yapılandırılabilir donanımlar paralel işlem yapabilmesinden ötürü bu ihtiyaçları karşılayabilmektedir. Bu yapılar kullanılarak uygulamaya özgü ve daha hızlı çalışabilen donanım tasarımları gerçekleştirilmektedir. Görüntü işleme uygulamaları, özellikle gerçek zamanlı ve yüksek çözünürlüklü görüntülerin işlenmesi yüksek hesaplama gücü gerektirmektedir. Bu çalışmada farklı kaynaklardan alınan görüntülerin gerçek zamanlı işlenmesi için FPGA tabanlı bir donanım sistemi geliştirilmiştir. Bunun için paralel işleme ve boruhattı özellikleri kullanılarak gerçek zaman ve çözünürlük kısıtları düşünülerek iki boyutlu medyan filtre gerçekleştirilmiştir. Bununla birlikte bir görüntü işleme sisteminin ihtiyaç duyacağı arayüzler, görüntü sıkıştırma ve hedef cihaza aktarım modülleri gerçekleştirilmiştir.*

### 1. Giriş

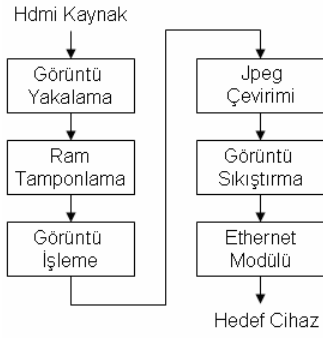
Görüntü işleme yüksek işlem gereksinimi bakımından maliyetli bir konudur. Standart donanımlar bu hesapları yapmakta yetersiz kalabilmektedir. Bu durumda görüntü işleme algoritmalarının donanım üzerinde gerçekleştirilmesi ihtiyacı ortaya çıkmaktadır. Çalışmamızda görüntü işleme uygulamalarında yaygın olarak kullanılan medyan filtresinin FPGA üzerinde gerçekleştirilmesi, görüntünün hedef cihaza nasıl aktarıldığı ve bir görüntü işleme sisteminde olması gereken bazı modüllerin tasarımları gösterilmiştir.

Görüntü işleme algoritmalarının daha hızlı bir şekilde yürütülmesini sağlamak için donanımsal olarak

gerçeklenmesi yoğun bir şekilde çalışılan konulardan biridir. Öncü çalışmalardan olan Thitimajshima'nın yapmış olduğu çalışmada görüntünün FPGA üzerinde yumuşatma işlemi gerçekleştirilip, bilgisayara aktarımını sağlamış olduğu bir sistem bulunmaktadır[1]. Bir diğer çalışmada Zhar ve ark.[2] birçok görüntü işleme algoritmasının sırasıyla FPGA kullanarak nasıl uygulanabileceği göstermişlerdir. Bianchi ve ark[3] çalışmalarında mobil robot uygulamaları için eşik alma, kenar bulma, segmentasyon işlemleri gerçekleştirilmiştir. Hiraiwa ve ark.[4] ise hareket algılama için bir donanımsal platform geliştirmişlerdir.

Bu çalışmada görüntünün sistematik biçimde nasıl işlenebileceği konuları ile birlikte görüntü işleme sisteminin ihtiyacı olan bazı modüller verilmiştir. Bu sistemin bilgisayar ya da başka bir cihazdan kontrol edilebiliyor olması sistemi öne çıkartan özelliklerden biridir. Bu çalışmada yüksek çözünürlüklü görüntünün alınması, görüntü işleme, filtreleme, sıkıştırma, hedefe aktarım işlemleri donanımsal olarak gerçekleştirilmiştir. Bununla birlikte geliştirilen yazılım, donanım sistemi ile iletişim kurarak görüntü işleme sonucunu alma ve gösterilme işlemini yapmaktadır.

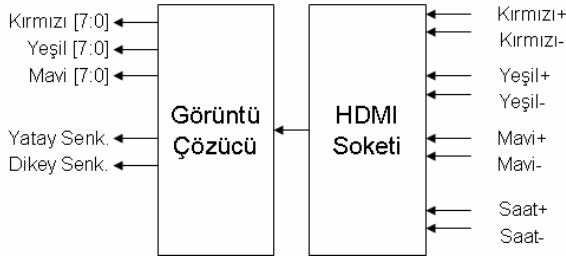
Bu çalışmada geliştirilen görüntü işleme sisteminin mimarisi Şekil 1'de verilmektedir. Sistemin işleyişi HDMI arayüzünden yüksek çözünürlüklü görüntünün yakalaması ile başlamaktadır. Görüntü yakalama işlemi için Xilinx firmasının sunmuş olduğu bir modül kullanılmıştır. Görüntü alınımının ardından medyan filtre ve renk uzayı dönüşümleri, filtreleme, ham görüntünün boyutunun büyük olması sebebi ile JPEG'e çevrilerek görüntünün boyutlarının azaltılması, sıkıştırılmış görüntünün tasarlanan Ethernet modülü ile hedef cihaza aktarımı işlemleri yapılmıştır.



Şekil 1. Geliştirilen Sistemin Mimarisi

## 2. Görüntü Yakalama

Yüksek çözünürlüklü görüntünün alınma işlemi, Xilinx firmasının sunmuş olduğu xapp495[5] modülü kullanılarak gerçekleştirilmiştir. Bu modül ile her saat çevriminde RGB renk bilgileri her renk 8'er bit olmak üzere 24 bit, yatay ve dikey senkron sinyalleri birer bit olarak alınmaktadır. Satır, sütun başlangıç ve bitişinin tespiti bu sinyaller aracılığı ile yapılmaktadır. Bu modülün blok diyagramı Şekil 2'de genel hatlarıyla verilmektedir.



Şekil 2. Görüntü Yakalama Modülü

## 3. Medyan Filtre ile Gürültü Temizleme

Medyan filtre, görüntü ve sinyal işleme konularında özellikle tuz-biber gürültüsünü kaldırmak için sıklıkla uygulanmakta olan bir filtre türüdür. Belirlenen maske içerisindeki piksel değerleri sıralanmaktadır. Sıralanan elemanlardan sıra olarak ortadaki eleman o matris grubunun medyan pikselini vermektedir. Bu medyan pikselin değeri mevcut piksel değeri ile değiştirilerek gürültüden arındırılmış olur.

Bu çalışmada 3x3'lük medyan filtre uygulanması donanımsal olarak gerçekleştirilmiştir. Kullanılan donanım kaynağını en verimli biçimde kullanmak için görüntünün tamamını tamponlamak yerine, 3 satır içeren piksel dizisi tamponlanmıştır. Tamponlanan piksel dizilerine gürültü azaltmak için medyan filtre uygulanmaktadır. Sistemde medyan tespitindeki

sıralama ihtiyacının karşılanması için Birleştirmeli Sıralama (Merge Sort) algoritması kullanılmıştır. Bu sıralama algoritmasının daha hızlı çalışabilmesi için Şekil 3'de verilen ve paralel olarak çalışan türü uygulanmıştır [6][7]. Sıralama işlemi 4 saat çevriminde yeni bir pikselin, bir önceki pikselin hesaplanmasının bitmesini beklemeden işlenmeye başlaması için medyan filtre modülü boru hattı yapısı ile çalışmaktadır.



Şekil 3[8]: Birleştirmeli sıralama algoritmasının paralel olarak çalışması.


Şekil 4a'da verilen resimde tuz ve biber gürültüsü eklenmiş olan örnek bir görüntü verilmektedir. Şekil 4b'de Matlab kullanarak medyan filtre uygulanmış, Şekil 4c'de ise FPGA üzerinde medyan filtre uygulanmış sonuçları verilmektedir. Sonuçlar görsel olarak incelendiğinde donanım olarak gerçekleştirilen medyan filtrenin görüntüdeki gürültüyü başarılı bir şekilde giderdiği görülmektedir. Görsel olarak başarılı olduğu gibi hız açısından kıyaslanamayacak kadar performansı yüksektir. Matlab'da bu işlem 0.2ms sürerken FPGA kullanarak aynı işlem 40ns gibi çok kısa bir sürede yürütülmektedir.



Şekil 4. (a) Tuz ve Biber Gürültülü Resim (b) Matlab Medyan Filtre Çıktısı (c) Sistem Çıktısı

#### 4. Renk Uzayı Dönüşümü

Sistem içerisinde gerçekleştirilen bir diğer işlem ise renk uzayı değişimidir. Alınan pikseller RGB renk uzayında bulunmaktadır. RGB renk uzayında filtreleme yapılırken gölge, ton değişimlerinden etkilendiği için bir diğer renk uzayı olan HSV'ye dönüşüm işlemi gerçekleştirilmiştir.



Şekil 5. RGB'den HSV renk uzayına dönüşüm.

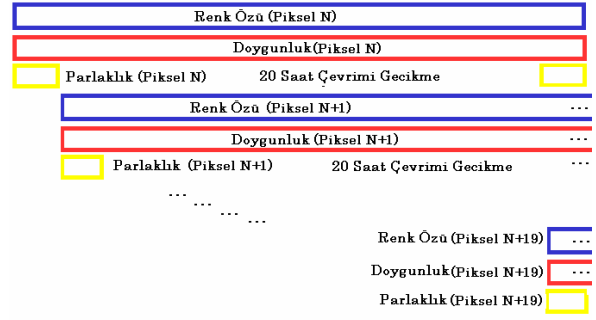
$$H(\text{Hue}): \begin{cases} 0, & \text{max} == \text{min} \\ (60^\circ * \frac{g-b}{\text{max}-\text{min}}) \bmod 360^\circ, & \text{max} == r \\ (60^\circ * \frac{b-r}{\text{max}-\text{min}} + 120^\circ), & \text{max} == g \\ (60^\circ * \frac{r-g}{\text{max}-\text{min}} + 240^\circ), & \text{max} == b \end{cases}$$

$$S(\text{Saturation}): \begin{cases} 0, & \text{max} == 0 \\ \frac{\text{max}-\text{min}}{\text{max}} = 1 - \frac{\text{min}}{\text{max}}, & \text{Degilse} \end{cases}$$

$V(\text{Value}): \text{max}$

\*  $\text{max} = \max(r, g, b)$ ,  $\text{min} = \min(r, g, b)$

Hue ve Saturation değerlerinin hesaplanması esnasında kullanılan bölme işlemi FPGA üzerinde 20 saat çevirimi gecikmeye sebebiyet vermektedir. Bölme işlemi tamamlandıktan sonra yeni pikselin işlemine devam etmek, sistemin çıktı vermesini oldukça geciktirecektir. Bu sorun medyan filtre bölümünde olduğu gibi boruhattı yapısı ile aşılabilmektedir. Şekil 6'da verilen Boruhattı yaklaşımı ile 20 saat çevirimi gecikmeli, ardışık olarak dönüştürme işlemi gerçekleştirilmiş pikseller alınmaktadır. Bu aşamada belirlenen renk aralıkları ile filtreleme gerçekleştirilerek, diğer renklerin arka plana dönüşümü sağlanmaktadır.




Şekil 6. RGB-HSV Dönüşüm Boruhattı Yapısı.

#### 5. Görüntü Sıkıştırma

1024x768 çözünürlüklü 30fps ile gelmekte olan görüntünün aktarımında sıkıştırılmadan aktarım için 67,5 MB trafik gerektirmektedir. Bu durum aktarım için büyük bir yük getireceği için görüntünün sıkıştırılarak aktarımı gerçekleştirilmesi yapılmalıdır. Sıkıştırma işlemi için opencores.org sitesindeki JPEG Encoder modülü[9] kullanılmıştır. Bu modül piksel değerlerini alarak, Şekil 7'de verilen adımlar izlenerek JPEG kodlaması gerçekleştirilmektedir.

JPEG'in başlangıç biti "FFD8", bitiş biti "FFD9" dur. Bilgisayar tarafındaki geliştirilen yazılımda başlangıç ve bitiş bitleri kontrol edilerek resim dizileri ekrana yansıtılmıştır.

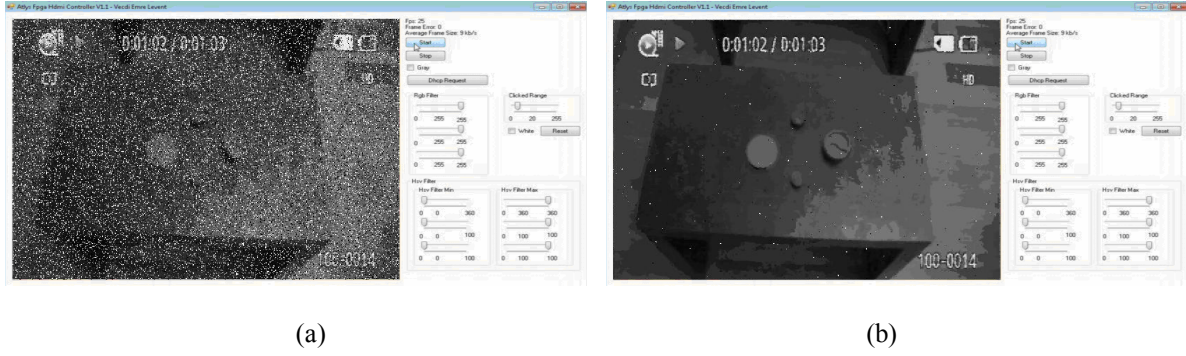


Şekil 7. JPEG Kodlama Modülü

#### 5. Sonuçlar

Donanım sistemi ile iletişim kurarak görüntü işleme sonucunu alma ve gösterilme işlemi yapmak için bir yazılım geliştirilmiştir. Şekil 8'de verilen arayüz, .net ortamında tasarlanmıştır. Uygulama ethernetten gelen UDP veridizisini almaktadır. Hedef cihaza gönderilmek üzere çevirim işleminin ardından, Ethernet arayüzü kullanarak UDP protokolü ile aktarım gerçekleştirilmiştir.





Şekil 8: Geliştirilen Uygulama Arayüzü. (a) Gürültülü bir görüntü (b) Medyan filtre sonucu.

FPGA’da gerçekleştirilmiş olan boruhattı yapısı sayesinde, piksellere uygulanacak işlemler her saat çevriminde başlatılabilmektedir. FPGA tarafında görüntü işleme için sadece 24 çevrim saatlik gecikme yaşanırken, ardışık işlem yapan mimarilerde ancak pikselin hesaplanma işlemi bittikten sonra bir diğerine geçilebilmektedir. Yaklaşık olarak birbirini beklemesi gereken 30 işlem bulunmaktadır. Yani 30 işlemin bitiminin ardından yeni pikselin değerleri hesaplanabilecektir. 100 Mhz ile çalıştırılan FPGA’in yaptığı hesaplama ancak 3 Ghz ile çalışan işlemci ile gerçekleştirilebilir. Algoritma karmaşıklığı arttıkça işlemci bu hız ihtiyacını karşılayamayacak hale gelecektir. Sistem Xilinx Spartan 6 FPGA üzerinde gerçekleştirilmiş olup, 6125 Saklayıcı(Register) ve 7040 Başvuru Çizelgesi(Lookup Table) kullanılmıştır.

## 6. Sonuç ve Gelecek Çalışmalar

Bu çalışmada FPGA kullanılarak bir görüntü işleme sistemi geliştirilmiştir. Bu sistemde en sık kullanılan görüntü işleme uygulamalarında Medyan filtre gerçekleştirilmiştir. Bununla birlikte Renk uzayı dönüşümü ve görüntü sıkıştırma gibi uygulamalarda gerçekleştirilmiştir. Gerçekleme yapılırken paralel işleme ve boruhattı özellikleri kullanılmıştır. Elde edilen sonuçlara göre FPGA üzerinde boruhattı yapısı ve paralellik kullanıldığı takdirde, standart ardışık işlem yapan standart mimarilerin hız bakımından FPGA tabanlı sistemlere yetişmesi mümkün olmamaktadır. Dolayısı ile gerçek zamanlı, yüksek performans gerektiren uygulamalarda FPGA uygulaması yapılması zaruri olmaktadır.

Görüntü işleme algoritmalarının işlemci üzerinde koşturulması yerine, FPGA üzerinde işlemlerin gerçekleştirilip bilgisayara hesaplanmış sonuçların döndürülmesi tasarımcılara büyük avantaj sağlayabilmektedir. Bu ihtiyaçtan yola çıkarak geliştirilecek olan bir API ile temel görüntü işleme

algoritmalarının FPGA’den çağırılabilmesi, ileride çalışılacak konulardan olacaktır.

## 7. Kaynaklar

- [1] P. Thitimajshima, FPGA-Based Real Time Digital Image Processing System, 4th World CSCC, 13 Haziran 2000
- [2] N. Zhar, A. Ali, M. Eleulji ve A. Raji, “A Specific-domain Design Tool for FPGA-based Image and Video Processing System”, International Journal of Computer Applications (0975 – 8887) Volume 56– No.11, 2012
- [3] R. A. C. Bianchi ve A. H. R. Costa, “Implementing Computer Vision Algorithms in Hardware: An FPGA/VHDL-Based Vision System for a Mobile Robot”, RoboCup 2001: Robot Soccer World Cup V Lecture Notes in Computer Science Volume 2377, 2002, pp 281-286, 2002
- [4] J. Hiraiwa ve E. Vargas ve S. Toral, “An FPGA based Embedded Vision System for Real-Time Motion Segmentation”, 17th International Conference on Systems, Signals and Image Processing, 17 Haziran 2010
- [5] B. Feng, “XAPP495: Implementing a TMDS Video Interface in the Spartan-6 FPGA”, 13 Kasım 2010
- [6] S.G. Akl, “Parallel Sorting Algorithms. Academic Press”, 1985
- [7] A. Jaj, “An Introduction to Parallel Algorithms. Addison-Wesley”, 1992
- [8] E. Omara, “Parallel Merge Sort using Barrier”, blogs.msdn.com, Erişim Tarihi: 11.07.2014
- [9] K. Michael, G. Clement ve A. Tekyıldız, “JPEG Encoder”, opencores.org Erişim Tarihi: 11.07.2014



**Açgözlü Rastsalla tırılmı Uyarlamalı Arama Algoritmasının Farklı Yerel Arama Yapılarıyla Akı Tipi Çizelgeleme Problemlerine Uygulanması**

Adil BAYKASO LU<sup>1</sup>, Fatma Selen MADENO LU<sup>1</sup>, Alper HAMZADAYI<sup>1</sup>, Iker GÖLCÜK<sup>1</sup>

<sup>1</sup> Endüstri Mühendisli i Bölümü, Dokuz Eylül Üniversitesi, Buca, zmir

Bu çalı mada açgözlü rastsalla tırılmı uyarlamalı arama algoritmasının farklı yerel arama yapılarını kullanarak performansları bilimsel yazında yer alan test problemi ile test edilmi tir. Önerilen yerel arama yapısının iyi sonuçlar verdi i yapılan deneyler sonucunda ortaya konulmu tur.

## İçkin Kip İşlevlerinin Kaynak Sayılarına Göre Dağılımı

Mehmet Erdal ÖZBEK

Elektronik ve Haberleşme Mühendisliği Bölümü  
Mühendislik Fakültesi  
İzmir Üniversitesi, İZMİR

Email: erdal.ozbek@izmir.edu.tr

### Özet

*Görgül kip ayrışımı ile zaman ortamındaki bir işaret için kip işlevlerine ayrıştırılabilmektedir. Birden çok sayıdaki işaretlerin birleşiminden oluşan tek bir karışım işaretinden, için kip işlevleri aracılığı ile karışımı oluşturan kaynak işaretlerin sayısının bulunması hedeflenmiştir. Bu amaçla bu çalışmada iki ve üç kaynağa sahip karışımlarda için kip işlevlerinin enerjilerinin kiplere göre dağılımı ortaya çıkarılarak frekans kümelerinde baskın olan kip işlevleri belirlenmiştir.*

### 1. Giriş

Gözlemlere dayanarak bilinmeyen bir işaretin elde edilmesi gözü kapalı kaynak ayrıştırması olarak bilinmektedir ve birçok alanda uygulanmaktadır [1,2]. Genellikle gözlemler bir grup algılayıcının çıkışından elde edilen kaynak işaretlerinin farklı birleşimlerinden oluşmaktadır. Bu birleşimleri oluşturan kaynak işaretlerinin birbirlerinden istatistiksel olarak bağımsız olduğu varsayımına dayanan bağımsız bileşen analizi [3], en yaygın olarak bilinen ve kullanılan yöntemlerden biridir. Yakın zamanda gözü kapalı yerine, oluşturulan modeller ve yan-bilgi ile bilgilendirilmiş kaynak ayrıştırmanın kullanılmasının ayrıştırma başarımında artış sağladığı gösterilmiştir [4,5].

Yapısı itibariyle gözü kapalı kaynak ayrıştırması probleminde kaynak sayısı bilinmemektedir. Literatürde genellikle kaynak sayısının algılayıcı sayısına eşit olduğu varsayımı kullanılmakta ve çözüm önerileri bu öngörü üzerine kurulan yapılara dayanmaktadır. Ancak kaynak sayısının önceden bilindiği varsayımında bulunmadan ya da gözlemlerin kaynak sayısından daha az olduğu durumlarda, kaynak sayısının belirlenmesi problemin çözümü için yardımcı olabilmektedir [6-9].

Kaynak sayısının belirlenmesi amacıyla birçok yöntem bulunmakta ise de, durağan ve doğrusal olmayan işaretlerin analizinde kullanılan görgül kip ayrışımı önemli bir yer tutmaktadır [10]. Görgül kip ayrışımı yönteminin herhangi bir zaman ortamı işaretini için kip işlevlerine ayrıştırması sayesinde farklı işaretlere ait temel işlevler işaretin kendisinden çıkarılabilmekte, temel işlevlerin sabit olduğu geleneksel yöntemlerin aksine, uyarlanabilir ayrıştırma sağlanabilmektedir.

Azaltılmış sayıdaki karışımdan kaynakların belirlenmesi probleminde görgül kip ayrışımının kullanılması ile yöntemin yakın frekanslı işaretlerin ayrıştırılmasında yararlı olabileceği gösterilmiştir [11]. Ele alınan bir diğer yaklaşımda, görgül kip ayrışımı yöntemi parametre kestirim yöntemi ile karşılaştırılmış ve belirli varsayımlar göz önüne alınarak kip bileşenlerine ayrıştırılma yapılmıştır [6]. Ayrıştırma amacıyla kip bileşenleri ilinti faktörlerine göre gruplandırılmış, enerjinin en büyük olmasına dayanan kıstasa dayandırılarak kaynak sayısının belirlenmesine çalışılmıştır.

Bu çalışmada ise için kip işlevlerinin farklı kaynak sayılarına göre enerjilerinin oranlarının dağılımı incelenmiştir. Farklı frekanslara sahip kaynak işaretlerinin oluşturduğu karışımın en büyük enerjili için kip işlevleri ile ilişkisi ortaya çıkarılmıştır.

### 2. Görgül kip ayrışımı

Görgül kip ayrışımı yönteminde herhangi bir zaman ortamı işareti için kip işlevleri kümesine ayrıştırılmaktadır. İçkin kip işlevleri iki koşulu sağlamalıdır:

1. İşaretin en büyük değerlerinin sayısı ve sıfır geçiş sayısı eşit olmalı ya da en çok bir farklı olmalıdır.

- Herhangi bir noktada, yerel en büyük değer ile en küçük değer tarafından belirlenen zarfın ortalama değeri sıfır olmalıdır.

Bu işlemler süzme işlemi adı verilen adımlar aracılığı ile gerçekleştirilmektedir.

## 2.1. Süzme işlemi

Verilen bir  $x(t)$  işareti için süzme işlemi aşağıdaki şekilde özetlenebilir [12,13]:


- $x(t)$ 'nin bütün uçdeğerlerini belirle.
- En küçük (büyük) uçdeğerler arasında aradeğerleme yaparak zarf işaretlerini  $e_{min}(t)$  ( $e_{max}(t)$ ) elde et.
- Ortalamayı ( $m(t) = \frac{1}{2}(e_{min}(t) + e_{max}(t))$ ) hesapla.
- İşareten ortalamayı çıkararak detayı ( $d(t) = x(t) - m(t)$ ) elde et.
- Belirli bir sonlandırma kriterine kadar döngüye devam et.

Süzme işlemi sonunda işaret,

$$x(t) = m_K(t) + \sum_{k=1}^K d_k(t) \quad (1)$$

şeklinde, artık kalan bir işaret parçası  $m_K(t)$  ile sıfır ortalamalı içkin kip işlevleri  $d_k(t)$  toplamından oluşmaktadır.

Örnek bir işaret için görgül kip ayrışımı sonucunda elde edilen içkin kip işlevleri Şekil 1'de verilmiştir.



Şekil 1. İşareten görgül kip ayrışımı ile ayrıştırılmış içkin kip işlevleri.

## 3. Yapılan çalışmalar ve sonuçlar

Bu çalışmada farklı genlik, frekans ve faza sahip işaretlerin oluşturduğu karışımlardan içkin kip işlevleri elde edilerek, farklı sayıdaki kaynak işaretlerinin farklı frekanslı örnekleri üzerinden içkin kip işlevlerinin dağılımı incelenmiştir.

Bu amaçla,

$$x_n(t) = a_n \cos(2\pi f_n t + \theta_n) \quad (2)$$


ile verilen kaynak işaretleri oluşturularak,

$$x(t) = \sum_{n=1}^N x_n(t) \quad (3)$$

olmak üzere, farklı kaynak sayılarına göre işaret karışımları elde edilmiştir. Daha sonra bu karışıma görgül kip ayrışımı uygulanarak Şekil 1'de verilen örnekteki gibi tek kanallı karışım işareti içkin kip işlevlerine ayrıştırılmıştır. İçkin kip işlevlerinin enerjilerinin toplam enerjeye oranı olarak

$$e_k = \frac{|d_k(t)|^2}{\sum_{k=1}^K |d_k(t)|^2} \quad (4)$$

hesaplanan enerji oranı sonuçlarına göre, Şekil 2'de de gösterildiği gibi en yüksek enerji oranına birinci içkin kip işlevinin sahip olduğu ve artan kip sayısı ile enerji oranının üstel bir şekilde azaldığı görülmektedir.




Şekil 2. İçkin kip işlevleri enerjilerinin kiplere göre dağılımı.

Bu çalışmada amaç, karışımı oluşturan işaretlerin frekanslarının birbirine yakın değerlere sahip bulunduğu içkin kip işlevlerinin enerjilerinin kiplere göre ne şekilde dağıldığının belirlenmesidir. Bilindiği üzere iki yakın frekanslı işaret için görgül kip ayrışımının çözünürlüğü incelenmiş ve yöntemin

sınırlılıkları belirlenmiştir [14]. Bu çalışmada ise iki yakın frekanslı işaret karışımı için bilinen bu sınır, hem uzak frekans değerleri için hem de ikiden fazla sayıdaki kaynak işareti ele alınarak değerlendirilmiştir. Bu amaçla iki ve üç kaynak işaretin birleşiminden oluşan karışım işaretinin görgül kip ayrıştırılması sonunda elde edilen içkin kip işlevleri işaretlerin farklı frekans değerleri alma durumlarına göre kümelendirilmiştir. İçkin kip işlevlerinin bulunmasında esas olarak genliklerin oranı önemli olacağından [14], işaretler arası farklılıkları ortadan kaldırmak amacıyla rastgele üretilen kaynak işaretlerin genlik değerleri birim değerler olarak seçilmiştir.

### 3.1. İki kaynaklı karışımlar

Öncelikle, iki kaynak işareten oluşmuş karışım için içkin kip işlevleri dağılımı kaynak işaretlerin sahip oldukları frekans değerlerine göre kümelendirilmiştir. Frekans değerleri olası iki durumdan birinde: bir işaretin frekansının diğer işaretin frekansına yakın olduğu durumda (durum 1), ya da yeterince uzak olduğu durumda (durum 2) bulunacaktır. Frekans değerlerinin yakınlığı ya da uzaklığının belirlenmesi amacıyla, büyük frekansın %10 komşuluğundaki frekans değerleri yakın, diğer değerler ise uzak olarak kabul edilmiştir. Rastgele üretilen 1000 örnek işaret üzerinden elde edilen dağılım Şekil 3'te gösterilmektedir.




Şekil 3. İki kaynaklı karışımlar için içkin kip işlevleri dağılımı.

Yakın olarak adlandırılan frekanslarda doğal olarak daha az sayıda karışım bulunmaktadır. Bu karışım tek bir frekansa sahip gibi görülerek işaret sadece birinci kip işlevine ayrıştırılmaktadır. Birbirinden farklı

frekanslardaki karışımlarda ise baskın olarak ikinci kip işlevi görülmektedir.

### 3.2. Üç kaynaklı karışımlar

Benzer şekilde üç kaynaklı karışımlar için içkin kip işlevlerinin enerji oranları incelendiğinde Şekil 4'te verilen dağılım elde edilmiştir. Ancak burada üç kaynak bulunduğundan frekansların olası kümelendirme durumu da üç farklı şekilde olabilmektedir. Durum 1 olarak adlandırılan, üç frekans değerinin de birbirine yakın olduğu durumdur. Bir frekans değerinin diğer iki birbirine yakın frekans değerinden uzak olduğu durum ise ikinci durum olarak adlandırılmıştır. Üçüncü ve son durum ise her bir frekans değerinin diğerlerinden uzak olduğu durumu göstermektedir.



Şekil 4. Üç kaynaklı karışımlar için içkin kip işlevleri dağılımı.

İki kaynaklı karışımlarda olduğu gibi üç kaynaklı karışımlarda da yakın frekanslı işaretler daha az sayıda bulunmaktadır. Bir frekansın diğerlerinden daha uzak bulunması durumunda işaret iki kaynaklı işaret gibi ilk iki kip işlevi ağırlıklı olarak kümelenebilir. Her üç frekans da birbirinden uzak olduğunda ise üçüncü içkin kip işlevinin etkisinin de artmış bulunduğu gözlenmektedir.

## 4. Değerlendirme

Bu çalışmada içkin kip işlevlerinin işaret karışımlarından kaynak sayısının bulunması için kullanılması önerilmiştir. Bu sayıyı belirlemek için iki ve üç kaynaklı karışımlar oluşturularak içkin kip işlevlerinin kiplere göre enerjilerinin dağılımı incelenmiştir. Kiplere göre dağılımın işaretlerin farklı frekans değerlerine göre kümelendirilmesi ile kaynak işaretlerinin sayısının belirlenmesine çalışılmıştır.

Her ne kadar kip işlevleri enerjilerinin dağılımında birinci kipi ağırlığı daha fazla olsa da, kaynak sayısının belirlenmesinde ikinci kip daha öne çıkmıştır. Bunun nedeninde görgül kip ayrışımının çözünürlük sorunu yatmaktadır. Yakın frekanslı iki kaynağın kip karışması sonucunda tek bir frekanslı kaynak gibi görülmesi ile birinci durum olarak ifade edilen yakın frekanslarda birinci kip işlevi ağırlıkta olmaktadır. Ancak kaynak sayısı arttığında ve bu yüzden frekanslardan biri uzak durumunda olduğunda ikinci kip işlevinin hem uzakta tek kalan frekanslı kaynak nedeniyle hem de yakın frekanslı iki işaretin oluşturduğu kümenin tek gibi görülmesiye, ayrıca da herbir işaret birbirlerinden uzak frekanslara sahip olduğunda üç işaretin enerjisinin üç içkin kip işlevine yayılması nedeniyle, ağırlığı artmıştır.

Bu çalışmanın sonuçları benzer şekilde dört ve daha fazla sayıdaki kaynakların karışımı için de elde edilebilmektedir. Ancak bu durumda ele alınacak durum sayısı da doğal olarak artmaktadır. Yine de, ikinci ve üçüncü içkin kip işlevlerinin kaynak sayısının belirlenmesinde önemli bir rolü olduğu ortaya çıkmaktadır.

## 5. Teşekkür

Bu çalışma TÜBİTAK 113E330 projesi kapsamında desteklenmektedir.

## 6. Kaynaklar

- [1] A. Cichocki, S. Amari, Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications, Wiley, 2002.
- [2] P. Comon, C. Jutten, Handbook of Blind Source Separation, Academic Press, 2010.
- [3] A. Hyvarinen, J. Karhunen, E. Oja, Independent Component Analysis, John Wiley & Sons, 2001.
- [4] A. Ozerov, A. Liutkus, R. Badeau, G. Richard, "Coding-based informed source separation: Nonnegative tensor factorization approach", IEEE Transactions on Audio, Speech, and Language Processing, 21(8), August 2013, pp. 1699-1712.
- [5] E. Vincent, N. Bertin, R. Gribonval, F. Bimbot, "From blind to guided audio source separation", IEEE Signal Processing Magazine, May 2014, pp. 107-115.
- [6] A. Aissa-El-Bey, K. Abed-Meraim, Y. Grenier, "Underdetermined blind audio source separation using modal decomposition", EURASIP Journal

- on Audio, Speech, and Music Processing, 2007, pp. 1-15.
- [7] G. R. Naik, D. K. Kumar, "Determining number of independent sources in undercomplete mixture", EURASIP Journal on Advances in Signal Processing, 2009, pp. 1-5.
- [8] J. G. A. Barbedo, A. Lopes, P. J. Wolfe, "Empirical methods to determine the number of sources in single-channel musical signals", IEEE Transactions on Audio, Speech, and Language Processing, 17(7), 2009, pp. 1435-1444.
- [9] M. K. I. Molla, K. Hirose, "Single-mixture audio source separation by subspace decomposition of Hilbert spectrum", IEEE Transactions on Audio, Speech, and Language Processing, 15(3), 2007, pp. 893-900.
- [10] N. E. Huang, Z. Shen, S. R. Long, M. L. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, H. H. Liu, "The empirical mode decomposition and Hilbert spectrum for nonlinear and non-stationary time series analysis", Proc. R. Soc. London A, 454, 1998, pp. 903-995.
- [11] R. Balocchi, D. Menicucci, M. Varanini, "Empirical mode decomposition to approach the problem of detecting sources from a reduced number of mixtures", Proc. of the 25th Annual International Conference of the IEEE EMBS, Cancun-Mexico, 2003, pp: 2443-2446.
- [12] G. Rilling, P. Flandrin, P. Gonçalves, "On empirical mode decomposition and its algorithms", IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing, Grado-Italy, 2003.
- [13] P. Flandrin, G. Rilling, P. Gonçalves, "Empirical mode decomposition as a filter bank", IEEE Signal Processing Letters, 11(2), February 2004, pp. 112-114.
- [14] G. Rilling, P. Flandrin, "One or two frequencies? The empirical mode decomposition answers", IEEE Transactions on Signal Processing, 56(1), January 2008, pp. 85-95.

## Çevresel Ekonomik Yük Dağıtım Probleminin İyileştirilmiş Yerçekimsel Arama Algoritması ile Çözümü

Serhat DUMAN<sup>1</sup> İsmail H. ALTAŞ<sup>2</sup> Nuran YÖRÜKEREN<sup>3</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi  
Düzce Üniversitesi, DÜZCE

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi  
Karadeniz Teknik Üniversitesi, TRABZON

<sup>3</sup>Elektrik Mühendisliği Bölümü, Mühendislik Fakültesi  
Kocaeli Üniversitesi, KOCAELİ

serhatduman@duzce.edu.tr

ihaltas@ktu.edu.tr

nurcan@kocaeli.edu.tr

### Özet

*Günümüzde, elektrik enerjisinin üretiminde fosil kaynaklı yakıtların kullanılması çevre kirliliğine yol açmaktadır. Bu çalışmada güç sistemlerinin en önemli optimizasyon problemlerinden biri olan ekonomik yük dağıtım problemi çevre kirliliğinde dikkate alınarak tek amaçlı bir optimizasyon problemi olarak düşünülmüştür. Problemin çözümünde son zamanlarda geliştirilen İyileştirilmiş Yerçekimsel Arama Algoritması (İYAA) kullanılmıştır. Önerilen yaklaşım IEEE 30 baralı 6 generatörlü test sistemine uygulanmıştır. Benzetim çalışmaları sonucunda elde edilen sonuçlar literatürde daha önce elde edilen sonuçlar ile karşılaştırılmış ve değerlendirilmesi yapılmıştır.*

### 1. Giriş

Güç sistemlerini işletilmesinde en önemli konulardan biri olan ekonomik yük dağıtım (ED) problemi sistemdeki var olan yükün üretim birimleri tarafından belirlenen kısıtlar içerisinde minimum maliyette olacak şekilde çıkış güçlerinin ayarlanması olarak belirtilir [1-3]. Kömür, petrol ve doğal gaz gibi fosil kaynaklı yakıtları kullanan üretim birimleri atmosfere parçacık ve gazlardan oluşan nitrojen oksit NO<sub>x</sub>, sülfür dioksit SO<sub>x</sub> ve karbondioksit CO<sub>2</sub> atıkların ortaya çıkmasına neden olup çevresel kirliliğe neden olmakla birlikte küresel ısınmaya da yol açmaktadır [3-4]. Çevresel etkilerde göz önünde bulundurulduğunda, ED problemi emisyon etkilerinin de dahil edildiği çok amaçlı bir optimizasyon problemine dönüşmektedir. Bu problem ağırlıklı toplam metodu [5] kullanılarak hem ekonomik yük

dağıtımının hem de emisyon değerinin belirlenebileceği tek amaçlı optimizasyon problemine döndürülür. Bu problem literatürde farklı optimizasyon algoritmaları ile bir çok araştırmacı tarafından ele alınmış ve hibrit parçacık sürü ve yerçekimsel arama algoritması [3], çok amaçlı diferansiyel gelişim algoritması [4], yapay arı kolonisi [5], çok amaçlı evrim algoritmaları [8], bulanık mantık temelli bakteri yem arama algoritması [9], diferansiyel gelişim algoritması [10], çok amaçlı parçacık sürü optimizasyon algoritması [11], zıt konumlu harmoni arama algoritması [12], yerçekimsel arama algoritması [13], benzerlik tabanlı çaprazlama operatörü kullanılarak geliştirilen genetik algoritmaları [14] ile çözülmüştür.

Bu çalışmada, öncelikli olarak Rashedi ve ark. [15] tarafından Newton'un hareket ve yerçekimi kanuna dayalı olarak geliştirilen Yerçekimsel Arama Algoritması (YAA) ele alınmıştır. Daha sonra Khajehzadeh ve ark. tarafından 2012 [16] yılında hız sınırlama denklemleri kullanarak iyileştirdikleri YAA işlemi anlatılmıştır. Son olarak iyileştirilmiş YAA algoritması tek amaçlı çevresel ekonomik yük dağıtım problemine uygulanmış olup benzetim çalışmaları sonucunda elde edilen sonuçlar literatürdeki diğer sonuçlarla karşılaştırılmıştır. Karşılaştırma sonuçlarına göre önerilen yaklaşımın çevresel ekonomik yük dağıtım problemini çözmedeki başarısı değerlendirilmiştir.

## 2. Çevresel Ekonomik Yük Dağıtım Problemi

Çevresel ekonomik yük dağıtım problemi, yakıt maliyeti ve  $\text{NO}_x$  emisyon miktarının dahil edildiği birleştirilmiş amaç fonksiyonunun minimize edilmesi olarak tanımlanmaktadır. Başka bir ifade ile talep edilen yükü karşılamak için termik santrallerde güç üretiminde kullanılan yakıtların yakılması ile ortaya çıkan zararlı emisyon miktarının ve toplam yakıt maliyetinin minimum olduğu andaki üretim birimlerinin aktif güç değerlerinin belirlenmesidir. Sistemde bulunan termik santrallerde her birinin üreteceği gücün bulunması ve denklem (1)'de gösterilen ikinci dereceden fonksiyonda yerine konarak toplam yakıt maliyetinin bulunması esasına dayanmaktadır [3,5,8-10].

$$F_i(P_{Gi}) = a_i + b_i P_{Gi} + c_i P_{Gi}^2 \quad (1)$$

Burada  $F_i(P_{Gi})$   $i$ . üretim biriminin yakıt maliyeti fonksiyonu,  $P_{Gi}$   $i$ . üretim biriminin ürettiği güç değeri,  $a_i$ ,  $b_i$ ,  $c_i$   $i$ . üretim biriminin yakıt maliyeti katsayılarıdır. Termik santrallerde fosil yakıtların yakılması ile her bir termik ünite tarafından salınan emisyonların toplam miktarı ikinci dereceden bir fonksiyonun toplamı ve bir üstel fonksiyonu olarak ifade edilmektedir [3,8,9].

$$E_i(P_{Gi}) = 10^{-2} \times (\alpha_i + \beta_i P_{Gi} + \gamma_i P_{Gi}^2) + \zeta_i \exp(P_{Gi} \lambda_i) \quad (2)$$

Ekonomik yük dağıtım problemi kayıpsız bir sistemde aktif güç dengesi eşitliği denklem (3)'de gösterilmiştir.

$$\sum_{i=1}^{NG} P_{Gi} - P_{yük} = 0 \quad (3)$$

Termik üretim birimlerinin sınır değerleri aşağıdaki gibi ifade edilmektedir.

$$P_{Gi}^{min} \leq P_{Gi} \leq P_{Gi}^{max} \quad (4)$$

Minimizasyon yapılacak çevresel ekonomik yük dağıtımına ait amaç fonksiyonu denklem (5)'de gösterilmiştir [5,9].

$$AF = w \sum_{i=1}^{NG} F_i(P_{Gi}) + (1 - w) h \sum_{i=1}^{NG} E_i(P_{Gi}) \quad (5)$$

Denklemden termik yakıt maliyeti  $F_i(P_{Gi})$ ,  $\text{NO}_x$  emisyon fonksiyonu ise  $E_i(P_{Gi})$  ile gösterilmektedir.  $w$   $0 \leq w \leq 1$  arasında değişen ağırlık faktörü,  $h$  ölçekleme faktörü,  $NG$  ise sistemdeki toplam termik üretim birimlerinin sayısını göstermektedir. Denklem (5)'de

$w=1.0$  değerini alması durumunda sadece yakıt maliyetinin,  $w=0.0$  değerini alması durumunda ise sadece  $\text{NO}_x$  emisyon miktarının minimumun olmasının istendiği duruma karşılık gelmektedir. Toplam yakıt maliyeti ve toplam  $\text{NO}_x$  emisyon miktarı denklem (6-7)'de gösterilmektedir.

$$F_T(P_{Gi}) = \sum_{i=1}^{NG} F_i P_{Gi} \quad (6)$$

$$E_T(P_{Gi}) = \sum_{i=1}^{NG} E_i P_{Gi} \quad (7)$$

## 3. Yerçekimsel Arama Algoritması

Yerçekimsel arama algoritması, son zamanlarda geliştirilen Newton'un hareket ve yerçekimi kanunlarına dayalı en yeni optimizasyon algoritmalarından biridir [15]. Rashedi ve ark. 2009 [15] yılında yerçekimi ve hareket kanunlarından esinlenilerek geliştirdikleri YAA, etkin bir hesaplama kabiliyetine sahip olup arama uzayındaki her bir parçacık bir kütle olarak kabul edilmekte ve algoritmada ajan olarak adlandırılmaktadır. Probleme göre belirlenen arama uzayındaki her bir ajan Newton yerçekimi ve hareket kanunlarının benzetimi ile çözüm uzayında hareket ederek en iyi çözüme ulaşmaya çalışırlar. İlk olarak çözüm uzayı oluşturulurken YAA'nın başlangıç popülasyonu aşağıdaki gibi ifade edilmektedir.

$$X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n) \quad (8)$$

$x_i^d$   $d$ . boyuttaki  $i$ . kümenin konumu temsil ederken  $n$  ise arama uzayının boyutunu göstermektedir. Eğer problem bir minimizasyon problemi ise  $best(k)$  ve  $worst(k)$  denklem (9)'daki gibi gösterilir.

$$\begin{aligned} best(k) &= \min_{j \in \{1, \dots, N\}} fit_j(k) \\ worst(k) &= \max_{j \in \{1, \dots, N\}} fit_j(k) \end{aligned} \quad (9)$$

Algoritmanın başlangıcında kullanıcı tarafından belirlenen yerçekimi sabitine atanan değer iterasyona bağlı olarak azalması, arama hızının kontrol edilmesi ve  $k$ . iterasyondaki yer çekimi sabiti denklem (10-11)'de gösterilmektedir.

$$G(k) = G(G_0, k) \quad (10)$$

$$G(k) = G_0 e^{-\alpha \frac{k}{K}} \quad (11)$$

Problemin uygunluk değerleri hesaplandıktan sonra  $k$ . iterasyondaki  $i$ . ajana ait kütle denklem (12-13)'e göre hesaplanmaktadır.

$$m_i(k) = \frac{fit_i(k) - worst(k)}{best(k) - worst(k)} \quad (12)$$

$$M_i(k) = \frac{m_i(k)}{\sum_{j=1}^N m_j(k)} \quad (13)$$

Arama uzayındaki ajanın ivmesini hesaplarken onun üzerine uygulanan toplam güçler yerçekimi kanununa bağlı olarak denklem (14)'deki gibi hesaplanmaktadır.

$$F_{ij}^d(k) = G(k) \frac{M_i(k) \times M_j(k)}{R_{ij}(k) + \varepsilon} (x_j^d(k) - x_i^d(k)) \quad (14)$$

$R_{ij}(k) = \left( \|X_i(k), X_j(k)\|_2 \right)$  şeklinde ifade edilmektedir. Hareket kanundan yararlanarak ajana ait ivme denklem (15)'de, ivmeye bağımlı olarak değişen hızı denklem (16) ve hıza bağımlı olarak değişen pozisyonun değeri denklem (17)'de gösterilmektedir.

$$a_i^d(k) = \frac{F_i^d(k)}{M_{ii}(k)} = \sum_{j \in k_{best}, j \neq i} rand_j G(k) \frac{M_j(k)}{R_{ij}(k) + \varepsilon} (x_j^d(k) - x_i^d(k)) \quad (15)$$

$$v_i^d(k+1) = rand_i \times v_i^d(k) + a_i^d(k) \quad (16)$$

$$x_i^d(k+1) = v_i^d(k+1) + x_i^d(k) \quad (17)$$

Burada  $rand_i$  ve  $rand_j$  değerleri  $[0,1]$  arasında düzgün dağılımlı sayıyı,  $\varepsilon$  küçük bir değeri ve  $R_{ij}(k)$   $i$  ve  $j$  ajanları arasındaki mesafeyi ifade etmektedir.

### 3.1. İyileştirilmiş YAA

Khajehzadeh ve ark. 2012 yılında YAA'nın hız denklemlerine sınırlama yaklaşımı getirerek YAA'nın daha etkili çözüme ulaşmasını amaçlamışlardır [16]. Araştırmacılar klasik YAA'daki ajanın hızı sezgisel bir yapıya sahip olduğu için kontrol edilemeyen bir yörüngede ve problem uzayında geniş bir alanda hareket ettiğini belirtirler. Çözüm uzayında meydana gelen salınımları ve ani patlama ve sapmaları önlemek amacı ile belirlenen aralığa göre ajanın hızının sınırlandırılmasını aşağıdaki gibi ifade etmektedirler.

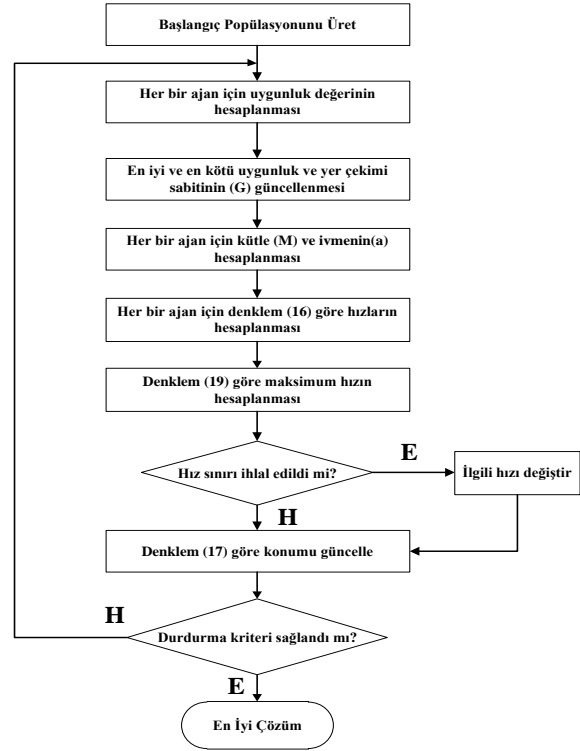
$$-V_{max} \leq v_i^d \leq V_{max} \quad (18)$$

$$V_{max} = [1 - (k/K)^h] \times V_{max0} \quad (19)$$

$$V_{max0} = \alpha \times (x_{max} - x_{min}) \quad (20)$$

$0 < \alpha \leq 1$  olan değer olarak kullanılmaktadır.  $k$  şu anki iterasyon sayısı,  $K$  ise maksimum iterasyon sayısı olarak ifade edilir. İyileştirilmiş yerçekimsel

arama algoritmasına (İYAA) ait akış diyagramı Şekil 1'de gösterilmiştir.



Şekil 1. İYAA akış diyagramı.


## 4. Benzetim Çalışmaları

İYAA algoritması IEEE 6 generatörlü 30 baralı ekonomik ve emisyon yük dağıtım problemine 283.4 MW veya 2.834 pu yük talebiyle iletim hattı kayıplarının ihmal edilmesi durumunda uygulanmıştır. Test sistemindeki üretim birimlerine ait yakıt maliyeti, emisyon katsayıları ve üretim birimlerinin sınır değerleri Tablo 1'de gösterilmiştir [12]. Denklem (5)'de gösterilen amaç fonksiyonuna göre  $w=1.0$  olduğu durumda sistemin toplam yakıt maliyeti,  $w=0.0$  olduğu durumda ise toplam emisyon değeri hesaplanmaktadır. Ekonomik ve emisyon yük dağıtım probleminin çözümünde kullanılan İYAA parametreleri  $G_0=40$ ,  $\alpha=20$ , ajan veya popülasyon sayısı  $N=100$ ,  $\alpha=0.1$ ,  $h=0.05$ , iterasyon sayısı 300 olarak alınmıştır. İYAA'nın test sistemine 30 kez uygulanması ile elde edilen minimum toplam yakıt maliyeti değerleri Şekil 2'de gösterilmiştir. Ayrıca YAA algoritmasından 10. eğitim denemesinde elde edilen toplam minimum yakıt maliyeti değerinin iterasyona bağımlı olarak değişimi Şekil 3'de gösterilmiştir. Şekil 3'te toplam yakıt maliyetinin yaklaşık olarak 50-65. iterasyon arasında minimum değerine ulaştığı görülmektedir.



Tablo 1. Üretim birimlerinin maliyet fonksiyonu, emisyon katsayıları ve sınır değerleri


Parametre	$P_{G1}$	$P_{G2}$	$P_{G3}$	$P_{G4}$	$P_{G5}$	$P_{G6}$
a	10	10	20	10	20	10
b	200	150	180	100	180	150
c	100	120	40	60	40	100
$\alpha$	4.091	2.543	4.258	5.326	4.258	6.131
$\beta$	-5.554	-6.047	-5.094	-3.550	-5.094	-5.555
$\gamma$	6.490	5.638	4.586	3.380	4.586	5.151
$\zeta$	2.0E-4	5.0E-4	1.0E-6	2.0E-3	1.0E-6	1.0E-5
$\lambda$	2.857	3.333	8.000	2.000	8.000	6.667
$P_G^{\min}$	5	5	5	5	5	5
$P_G^{\max}$	150	150	150	150	150	150




Şekil 2. İYAA ile elde edilen toplam yakıt maliyeti değerleri

Şekil 4’de ise toplam emisyon miktarının iterasyona göre değişimi gösterilmektedir. Toplam minimum emisyon miktarının yaklaşık 50 iterasyondan sonra en uygun değere geldiği Şekil 4’den açıkça görülmektedir.

minimum toplam yakıt maliyeti değeri (YM(\$/h)), toplam emisyon (EM(ton/h)), talep edilen yük (TU(pu)) değerleri ve literatürde farklı optimizasyon algoritmaları tarafından elde edilmiş değerlerde karşılaştırılması gösterilmektedir.



Şekil 3. İterasyona göre değişen yakıt maliyeti eğrisi



Şekil 4. İterasyona göre değişen toplam emisyon miktarı eğrisi

Tablo 2 ve 3’de YAA algoritmasından elde edilen en iyi çözüme ait generatörlerin çıkış güçlerini,

Tablo 2’deki karşılaştırma sonuçlarına göre İYAA’nın toplam yakıt maliyeti değeri hibrit parçacık sürü ve

yerçekimsel arama algoritması (HPSO-GSA), parçacık sürü optimizasyon algoritması (PSO) ve diferansiyel gelişim (DE) algoritmalarından elde edilen sonuçlar ile aynı olduğu, diğer optimizasyon algoritmalarından elde edilen sonuçlardan ise daha iyi olduğu görülmektedir. Tablo 3'te koyu olarak gösterilen çözümler detaylı bir şekilde incelendiğinde, YAA ile elde edilen minimum emisyon değeri literatürdeki elde edilen diğer sonuçlarla benzerlik gösterdiği görülmektedir.

## 5. Sonuçlar

Bu çalışmada, son zamanlarda geliştirilen sezgisel algoritmalarından biri olan yerçekimsel arama

algoritmasının Khajehzadeh ve ark. tarafından hız sınırlama denklemleri kullanılarak iyileştirme yapılan İYAA algoritması ekonomik ve emisyon yük dağıtım probleminin çözümü için IEEE 30 baralı 6 generatörlü test sisteminde başarılı bir şekilde uygulanmıştır. Önerilen algoritma tarafından elde edilen sonuçların literatürdeki diğer sonuçlarla karşılaştırıldığından benzer sonuçlar elde edildiği görülmüştür. Bu çalışmada, iyileştirilmiş YAA'nın ekonomik ve emisyon yük dağıtım probleminin çözümüne kolay bir şekilde uygulandığı gösterilmiştir.

Tablo 2. İYAA'dan elde edilen sonuçların farklı optimizasyon algoritmalarından elde edilen sonuçlar ile karşılaştırılması (yakıt maliyeti için)

Yöntem	P <sub>G1</sub>	P <sub>G2</sub>	P <sub>G3</sub>	P <sub>G4</sub>	P <sub>G5</sub>	P <sub>G6</sub>	TU(pu)	YM(\$/h)	EM(ton/h)
LP[6]	0.150	0.300	0.550	1.050	0.460	0.350	2.860	606.31	0.223
MOSST[7]	0.1125	0.3020	0.5310	1.0208	0.5311	0.3625	2.860	605.890	0.222
NSGA[8]	0.1038	0.3228	0.5123	1.0387	0.5324	0.3241	2.8341	600.34	0.2241
NPGA[8]	0.1116	0.3153	0.5419	1.0415	0.4726	0.3512	2.8341	600.31	0.2238
SPEA[8]	0.1009	0.3186	0.5400	0.9903	0.5336	0.3507	2.8341	600.22	0.2206
MBFA[9]	0.1133	0.3005	0.5202	0.9882	0.5409	0.3709	2.834	600.17	0.2200
NSGA-II[11]	0.1059	0.3177	0.5216	1.0146	0.5159	0.3583	2.834	600.155	0.2219
BB-MOPSO[11]	0.1090	0.3005	0.5234	1.0170	0.5238	0.3603	2.834	600.112	0.2222
DE[10]	0.110	0.300	0.524	1.016	0.524	0.360	2.834	600.11	0.2231
OHS [12]	0.1086	0.2995	0.5315	1.0121	0.5230	0.3591	2.8338	600.00	0.2219
PSO[3]	0.1066	0.2996	0.5243	1.0164	0.5262	0.3609	2.834	600.11	0.2223
GSA[3]	0.0947	0.2650	0.5418	0.9819	0.5070	0.4435	2.8339	601.06	0.2204
HPSO-GSA[3]	0.1096	0.2998	0.5243	1.0162	0.5243	0.3598	2.834	600.11	0.2221
<b>İYAA</b>	<b>0.1096</b>	<b>0.3000</b>	<b>0.5240</b>	<b>1.0163</b>	<b>0.5243</b>	<b>0.3598</b>	<b>2.834</b>	<b>600.11</b>	<b>0.22215</b>

Tablo 3. İYAA'dan elde edilen sonuçların farklı optimizasyon algoritmalarından elde edilen sonuçlar ile karşılaştırılması (emisyon için)

Yöntem	P <sub>G1</sub>	P <sub>G2</sub>	P <sub>G3</sub>	P <sub>G4</sub>	P <sub>G5</sub>	P <sub>G6</sub>	TU(pu)	YM(\$/h)	EM(ton/h)
LP [6]	0.150	0.300	0.550	1.050	0.460	0.350	2.860	606.31	0.223
MOSST [7]	0.4095	0.4626	0.5426	0.3884	0.5427	0.5142	2.860	644.11	0.1942
NSGA[8]	0.4072	0.4536	0.4888	0.4302	0.5836	0.4707	2.8341	633.83	0.1946
NPGA [8]	0.4146	0.4419	0.5411	0.4067	0.5318	0.4979	2.834	636.04	0.1943
SPEA[8]	0.4240	0.4577	0.5301	0.3721	0.5311	0.5190	2.834	640.42	0.1942
MBFA[9]	0.3943	0.4627	0.5423	0.3946	0.5346	0.5056	2.8341	636.73	0.1942
NSGA-II[11]	0.4074	0.4577	0.5389	0.3837	0.5352	0.5110	2.8339	638.249	0.1942
BB-MOPSO[11]	0.4071	0.4591	0.5374	0.3838	0.5369	0.5098	2.8341	638.262	0.1942
DE[10]	0.406	0.459	0.538	0.383	0.538	0.510	2.834	638.27	0.1952
OHS [12]	0.412116	0.466949	0.547454	0.3711771	0.534693	0.501016	2.833999	639.5493	0.1942
PSO[3]	0.4017	0.4604	0.5403	0.3875	0.5360	0.5081	2.834	637.67	0.1942
GSA[3]	0.5000	0.5643	0.4435	0.4429	0.4818	0.4014	2.8339	643.96	0.1969
HPSO-GSA[3]	0.4062	0.4591	0.5379	0.3829	0.5379	0.5100	2.834	638.27	0.1942
<b>İYAA</b>	<b>0.4097</b>	<b>0.4563</b>	<b>0.5244</b>	<b>0.3930</b>	<b>0.5310</b>	<b>0.5196</b>	<b>2.834</b>	<b>637.9112</b>	<b>0.1942</b>

## 6. Kaynaklar

- [1] B.H. Chowdhury, S. Rahman, "A review of recent advances in economic dispatch", *IEEE Transactions on Power Systems*, 5(4), 1990, s. 1248-1259.
- [2] A. Mahor, V. Prasad, S. Rangnekar, "Economic dispatch using particle swarm optimization: a review", *Renewable and Sustainable Energy Reviews*, 13, 2009, s. 2134-2141.
- [3] S. Jiang, Z. Ji, Y. Shen, "A novel hybrid particle swarm optimization and gravitational search algorithm for solving economic emission load dispatch problems with various practical constraints", *International Journal of Electrical Power and Energy Systems*, 55, 2014, s. 628-644.
- [4] M. Basu, "Economic environmental dispatch using multi-objective differential evolution", *Applied Soft Computing*, 11, 2011, s. 2845-2853.
- [5] D. Aydin, S. Özyön, C. Yaşar, T. Liao, "Artificial bee colony algorithm with dynamic population size to combined economic and emission dispatch problem", *International Journal of Electrical Power and Energy Systems*, 54, 2014, s. 144-153.
- [6] A. Farag, S. Al-Baiyat, T.C. Cheng, "Economic load dispatch multiobjective optimization procedures using linear programming techniques", *IEEE Transactions on Power Systems*, 10(2), 1995, s. 731-738.
- [7] D.B. Das, C. Patvardhan, "New multi-objective stochastic search technique for economic load dispatch", *IEE Proc. Gener. Transm. Distrib.*, 145(6), 1998, s. 747-752.
- [8] M.A. Abido, "Multiobjective evolutionary algorithms for electric power dispatch problem", *IEEE Transactions on Evolutionary Computation*, 10(3), 2006, s. 315-329.
- [9] P.K. Hota, A.K. Barisal, R. Chakrabarti, "Economic emission load dispatch through fuzzy based bacterial foraging algorithm", *International Journal of Electrical Power and Energy Systems*, 32, 2010, s. 794-803.
- [10] R.E. Perez-Guerrero, J.R. Cedeno-Maldonado, "Differential evolution based economic environmental power dispatch", *Proc. 37th Annual North American Power Symp.*, 2005, s. 191-197.
- [11] Y. Zhang, D.W. Gong, Z. Ding, "A bare-bones multi-objective particle swarm optimization algorithm for environmental/economic dispatch", *Information Sciences*, 192, 2012, s. 213-227.
- [12] A. Chatterjee, S.P. Ghoshal, V. Mukherjee, "Solution of combined economic and emission dispatch problems of power systems by an opposition-based harmony search algorithm", *International Journal of Electrical Power and Energy Systems*, 39, 2012, s. 9-20.
- [13] U. Güvenç, Y. Sönmez, S. Duman, N. Yörükeren, "Combined economic and emission dispatch solution using gravitational search algorithm", *Scientia Iranica*, 19(6), 2012, s. 1754-1762.
- [14] U. Güvenç, "Combined economic emission dispatch solution using genetic algorithm based on similarity crossover", *Scientific Research and Essays*, 5(17), 2010, 2451-2456.
- [15] E. Rashedi, H. Nezamabadi-pour, S. Saryazdi, "GSA: A gravitational search algorithm", *Information Science*, 179 (13), 2009, s. 2232-2248.
- [16] M. Khajehzadeh, M.R. Taha, A. El-Shafie, M. Eslami, "A modified gravitational search algorithm for slope stability analysis", *Engineering Applications of Artificial Intelligence*, 25, 2012, s.1589-1597.

## Parçacık Sürü Optimizasyonu ve Hücresel Otomata Tabanlı

### Sayısal Görüntü Karıştırma Yöntemi

Büşra KAYA<sup>1</sup> Fadime ÖZER<sup>2</sup> Gizem DURSUN<sup>3</sup> Gülay AYDOĞDU<sup>4</sup> Ufuk ÖZKAYA<sup>5</sup>

<sup>1,2,3,4,5</sup>Elektronik ve Haberleşme Mühendisliği Bölümü  
Mühendislik Fakültesi  
Süleyman Demirel Üniversitesi, ISPARTA

Email: busra23kaya@gmail.com fadimeozer.1992@gmail.com gizemdursun91@gmail.com  
gulayaydogdu07@gmail.com ufukozkaya@sdu.edu.tr

#### Özet

*Sayısal görüntü karıştırma, görüntü şifreleme ve görüntüye bilgi gizleme gibi önemli uygulamalarda kullanılmaktadır. Bu çalışmada, gri seviyeli görüntüler için hücresel otomata ve parçacık sürü optimizasyonu tabanlı yeni bir sayısal görüntü karıştırma yöntemi sunulmaktadır. Hücresel otomata yöntemi görüntü karıştırma matrisini oluştururken, parçacık sürü optimizasyonu ise en başarılı görüntü karıştırma performansını sağlayan optimum görüntü karıştırma matrisini elde etmektedir. Önerilen yöntem, farklı boyutlarda olan iki test görüntüsüne uygulanmış ve başarı performansı incelenmiştir. Elde edilen sonuçlar ışığında; önerilen yöntemin işlem yoğunluğunu azalttığı, daha az işlem süresinde daha başarılı karıştırma performansı sergilediği ve pasif saldırılara karşı daha güvenli olduğu gözlenmiştir.*

#### 1. Giriş

Sayısal görüntü karıştırma, görüntü şifreleme ve steganografi uygulamalarında sıklıkla kullanılan yöntemlerdendir. Sayısal görüntü karıştırma işlemi, bir görüntünün piksel değerlerinin konumlarının belirli bir kurala veya yönteme göre değiştirilmesi ve yeniden sıralanması şeklinde gerçekleştirilmektedir. Bilgi güvenliğinin sağlanabilmesi için başarılı algoritmalar ve yöntemlere ihtiyaç duyulmaktadır. Literatürde sayısal görüntü karıştırma problemleri için araştırmacılar tarafından kaotik dizi [1,2], lineer kanonik transform [3], fibonacci dizisi[4], hücresel otomata [5-9] gibi birçok yöntem önerilmiştir. Hücresel otomata, karmaşık sistemlerin modellenmesinde sıklıkla kullanılan ayrık bir modeldir. Hücresel otomata, tanımlı olduğu kurallar çerçevesinde karmaşık sistemleri daha basite

indirgeyerek çözme kabiliyeti nedeni ile görüntü karıştırma ve şifreleme uygulamalarında kullanılan önemli bir yöntem haline gelmiştir. Diğer taraftan, hücresel otomatanın özel bir türü olan hayat oyunu teorisi de görüntü karıştırma problemlerine uygulanmaktadır [5,8,9]. Ancak, hayat oyunu teorisi kullanılarak gerçekleştirilen sayısal görüntü karıştırma uygulamalarının başlıca problemi, hayat oyunu teorisinin en temel bileşeni olan tohum matrisinin random oluşmasıdır. Görüntü karıştırma işlemi random oluşan tohum matrisi ve sonrasında bu matrise bağlı oluşan yeni nesil matrislerine göre yapılmaktadır. Halbuki, her giriş görüntüsü için mümkün olan en iyi karıştırma performansını sağlayan optimum tohum matrisi elde edilmelidir. Diğer taraftan, karıştırma seviyesinin artması görüntü karıştırma performansını artırır da işlem yükü ve süresinde hatırı sayılır bir artışa neden olmaktadır.

Bu çalışmada, girişine gelen gri seviyeli bir görüntü için mümkün olan en iyi karıştırma performansını sağlayan tohum matrisinin ve dolayısıyla görüntü karıştırma matrisinin elde edilmesi hedeflenmektedir. Hedeflenen görüntü karıştırma matrisinin (i) komşu pikseller arasındaki korelasyonu minimize etmesi, (ii) pasif saldırılara karşı güvenli olması istenmektedir.

Takip eden bölümlerde, sayısal görüntü karıştırma ve optimizasyon aşamaları sırasıyla izah edilmiş ve sonrasında ise elde edilen sonuçlar paylaşılmıştır.

#### 2. Önerilen Yöntem

Sayısal görüntü karıştırma için önerilen yöntem temel olarak iki aşamadan oluşmaktadır. Birinci aşamada görüntü karıştırma işlemi için önerilen görüntü karıştırma matrisinin elde edilmesi ve uygulanması

anlatılmıştır. İkinci aşamada ise, görüntü karıştırma matrisinin en önemli bileşeni olan tohum matrisinin ve dolayısıyla görüntü karıştırma matrisinin optimizasyonu gerçekleştirilmiştir. Bu bölümde sırasıyla bu iki aşama izah edilecektir.

## 2.1. Sayısal Görüntü Karıştırma

Sayısal görüntü karıştırmada temel prensip görüntünün piksellerinin konumlarını değiştirmek ve komşu pikselleri arasındaki korelasyon değeri çok düşük olan yeni bir görüntü elde etmektir. Elde edilen yeni görüntünün komşu pikselleri arasındaki korelasyonun minimum seviyede olması, görüntü şifreleme veya görüntüye veri gizleme uygulamalarında orijinal görüntünün istatistiksel saldırılarla elde edilmesini zorlaştırmaktadır. Bu nedenle, başarılı ve gürbüzlüğü yüksek karıştırma algoritmalarına ihtiyaç duyulmaktadır. Bu çalışmada hücresele otomatının özel bir çeşidi olan hayat oyunu teorisi kullanılarak sayısal görüntü karıştırma işlemi gerçekleştirilmiştir. Takip eden alt bölümlerde sırasıyla hayat oyunu teorisi, önerilen hayat oyunu tabanlı görüntü karıştırma yöntemi ve görüntü karıştırma performans parametreleri izah edilecektir.

### 2.1.1. Hayat Oyunu Teorisi

Hayat oyunu (Game of Life) teorisi John Horton Conway tarafından 1970'li yıllarda geliştirilmiştir. 2-boyutlu özel bir hücresele otomata çeşidi olan hayat oyunu  $m \times n$  boyutlarında random bir tohum matris ( $A_0$ ) ile başlar. Tohum matristeki her hücre iki değere sahip olmaktadır. Ölü hücreler "0" durumu ile ve canlı hücreler ise "1" durumu ile ifade edilmektedir. Her hücrenin sonraki nesillerdeki  $A_n$  ( $n = 1, 2, 3, \dots$ ) durumu ise bir hücre ve onun komşuları arasında tanımlanan durum güncelleme kuralları ile belirlenmektedir. Bu kurallar her nesilde geçerli olup her hücrenin durumu eşzamanlı olarak güncellenmektedir. Durum güncelleme kuralları aşağıda verilmiş olan 4 temel kuraldan oluşmaktadır:

**Kural 1)** Canlı bir hücre eğer ikiden daha az canlı komşu hücreye sahipse bir sonraki nesilde yalnızlıktan ölür.

**Kural 2)** Canlı bir hücre eğer üçten daha fazla canlı komşu hücreye sahipse bir sonraki nesilde kalabalıktan ölür.

**Kural 3)** Canlı bir hücre eğer iki veya üç adet canlı komşu hücreye sahipse bir sonraki nesilde durumunu korur.

**Kural 4)** Ölü bir hücre eğer üç adet canlı komşu hücreye sahipse bir sonraki nesilde yaşar.

### 2.1.2. Hayat oyunu tabanlı görüntü karıştırma


Çalışmanın görüntü karıştırma aşamasında iki fazlı bir görüntü karıştırma yaklaşımı önerilmektedir. Birinci fazda, komşu pikseller arasındaki korelasyon kırılırken, ikinci fazda ise karıştırma etkisi maksimize edilmektedir. Önerilen görüntü karıştırma yaklaşımı temel olarak 5 adımdan oluşmaktadır:

**1. Adım:** Tohum matrisi  $A_0$  random olarak üretilir. Tohum matrisi, karıştırma işlemi uygulanacak olan gri seviyeli görüntü ile aynı boyuttur.

**2. Adım:** Hayat oyunu gerçekleştirilir ve yeni nesil matrisler  $A_n$  ( $n = 1, 2, 3, \dots$ ) üretilir. Nesil sayısı  $n$  aynı zamanda görüntü karıştırma seviyesini belirlemektedir.

**3. Adım:** Görüntü karıştırma matrisi ( $GKM$ ) (1)'de verilen eşitlik ile elde edilmektedir. Şekil 1'de ise  $n = 4$  için görüntü karıştırma matrisinin üretilmesi gösterilmiştir.

$$GKM(i, j) = \sum_{k=1}^n A_k(i, j) \times 2^{(k-1)} \quad (1)$$



Şekil 1.  $n = 4$  için görüntü karıştırma matrisinin üretilmesi

**4. Adım:** Bu adımda birinci faz gerçekleşmektedir. Orijinal gri seviyeli görüntünün piksellerinin konumları bir önceki adımda elde edilen görüntü karıştırma matrisine göre değiştirilmektedir.

Orijinal görüntünün piksel konumları satır öncelikli değişmektedir ve burada görüntü karıştırma matrisinin satır öncelikli sırada ve küçükten büyüğe doğru değerlerine göre değişim söz konusudur. Karıştırma seviyesini ( $n$ ) artırmak görüntü karıştırma matrisi eleman değerlerinde çeşitliliği artıracığından daha güçlü bir karıştırma işleminin gerçekleşmesini sağlayacaktır. Ancak, bu durum işlem yoğunluğunu ve süresini artıracaktır.

**5. Adım:** Bu adımda ikinci faz gerçekleşmektedir. Bir önceki adım sonucunda elde edilen ön karıştırma görüntüsü piksel konumları satır öncelikli sırada değiştirilmektedir. Burada görüntü karıştırma matrisinin sütun öncelikli sırada ve büyükten küçüğe doğru değerlerine göre değişim söz konusudur. Bu adım sonunda görüntü karıştırma işlemi tamamlanmaktadır.

### 2.1.3. Performans parametreleri

Bir sayısal görüntü karıştırma yönteminin başarısını ölçen ilk performans parametresi komşu pikseller arasındaki korelasyon değerleridir. Dolayısıyla orijinal görüntünün ve karıştırılmış görüntünün yatay, dikey ve köşegen korelasyon değerleri elde edilmektedir. Bu çalışmada, korelasyon değerleri görüntüden rasgele seçilen 4000 örnek için elde edilmektedir.

Diğer performans parametresi gri fark derecesidir (GFD). GFD, karıştırılmış görüntü ve orijinal görüntü arasında tanımlanmış bir parametredir. GFD değeri önerilen yöntemin karıştırma etkisini vermektedir. Karıştırma etkisi ise, karıştırılmış görüntünün pasif saldırılara karşı gürbüzlüğü hakkında bilgi vermektedir[5].

$$GD(i, j) = \frac{1}{4} \sum_{(i', j')} [P(i, j) - P(i', j')]^2 \quad (2)$$

$$E(GD(i, j)) = \frac{\sum_{i=2}^{M-1} \sum_{j=2}^{N-1} GD(i, j)}{(M-2) \times (N-2)} \quad (3)$$

$$GFD = \frac{E'(GD(i, j)) - E(GD(i, j))}{E'(GD(i, j)) + E(GD(i, j))} \quad (4)$$

Burada,  $E(GD(i, j))$  ve  $E'(GD(i, j))$  değerleri sırasıyla orijinal görüntünün ve karıştırılmış görüntünün ortalama gri fark değerlerini vermektedir. GFD değeri -1 ile +1 değerleri arasında değer almaktadır ve karıştırma işleminin başarısı +1 değerine yaklaştıkça artmaktadır[5].

## 2.2. Görüntü karıştırma matrisinin optimizasyonu

### 2.2.1. Hücresel otomata

Görüntü şifreleme ve karıştırma uygulamalarında 2-boyutlu hücresel otomata yapıları kullanılmaktadır. Bu yapılar,  $m \times n$  adet hücreden oluşmaktadır. Her bir hücre canlı veya ölü olmak üzere iki duruma sahiptir ve bu durumlar sırasıyla "1" ve "0" ile temsil edilmektedir. Bir hücrenin durumu üst satırındaki üç komşu hücrenin durumuna bağlıdır. Bu durumda komşu hücreler için  $2^3 = 8$  adet farklı durum söz konusudur (Tablo 1). Komşu hücrelerin sahip olduğu farklı durumlar neticesinde  $2^8 = 256$  adet kural oluşmaktadır. Örneğin kural-90 ele alınırsa, ikili sistemdeki  $90 = (01011010)_2$  değeri Wolfram kodu ile yeni hücrenin durumunu belirleyen değerlere dönüştürülmektedir (Tablo 1). Bu sayede komşu hücrelerin sahip olduğu duruma karşı yeni hücrelerin durumu bu değerlerle belirlenmektedir.

Tablo 1. Kural-90 için yeni hücrenin durumu

Komşu Hücrelerin Durumu			Yeni Hücrenin Durumu
0	0	0	0
0	0	1	1
0	1	0	0
0	1	1	1
1	0	0	1
1	0	1	0
1	1	0	1
1	1	1	0

### 2.2.2. Parçacık sürü optimizasyonu

Parçacık sürü optimizasyonu (PSO), popülasyon tabanlı bir optimizasyon yöntemidir ve ilk olarak Kennedy ve Eberhart tarafından kuş ve balık sürülerinin sosyal davranışlarının incelenmesi sonucu ortaya çıkmıştır [10-11]. Literatürde farklı disiplinlerden birçok problem için kullanılan bu yöntem ile ilgili detaylı bilgiler ilgili referanslardan sağlanabilir [10-11].

Bu aşamada, optimum görüntü karıştırma matrisini elde etmek için iki boyutlu bir PSO algoritması kullanılmıştır. Burada, optimizasyon parametreleri hücresel otomata kuralı ve karıştırma seviyesidir. Bu parametrelerin optimize edilmesi ile en uygun görüntü karıştırma matrisine ulaşılabacaktır.  $m \times n$

boyutlarındaki bir giriş görüntüsü için öncelikle  $1 \times n$  boyutunda rasgele bir giriş vektörü oluşturulmaktadır. PSO algoritması tarafından elde edilen hücresele otomata kuralı değeri kullanılarak giriş görüntüsü ile aynı boyutta olan  $A_0$  tohum matrisi oluşturulmaktadır. Daha sonrasında ise, PSO algoritmasının diğer optimizasyon parametresi olan karıştırma seviyesi değeri ile yeni nesil matrisler oluşturulur. Son olarak da eşitlik (1) ile verilen kurala göre görüntü karıştırma matrisi elde edilir.

PSO algoritmasında en uygun hücresele otomata kuralı ve karıştırma seviyesi değerini elde etmek için aşağıdaki hedef fonksiyonu kullanılmıştır.

$$H.F. = \left| \frac{(kor)_{yatay} \times (kor)_{dikey} \times (kor)_{köşegen}}{GFD} \right| \quad (5)$$

Hedef fonksiyonunun minimize edilmesi korelasyon değerlerinin daha düşük değerlere ve benzer şekilde GFD değerinin de daha büyük değerlere ulaşmasını sağlayacaktır. Algoritmada, 10 parçacık kullanılmış ve maksimum iterasyon sayısı 50 olarak belirlenmiştir. PSO algoritmasında eylemsizlik katsayısı 0.9 olarak belirlenmiş ve her iterasyonda lineer olarak azaltılmıştır. Parçacıkların hızlarının güncellenmesinde yer alan öğrenme katsayıları ise  $c_1 = c_2 = 2$  olarak seçilmiştir. Hücresele otomata kuralı 1 ile 255 değerleri arasında ve karıştırma seviyesi ise 1 ile 10 değerleri arasında optimize edilmiştir.

### 3. Sonuçlar

Önerilen yöntem literatürde bu tip çalışmalarda en çok kullanılan gri seviyeli iki görüntüye (Lena ve kameraman) uygulanmıştır. Çalışmada iki farklı yöntem uygulanmıştır. Birinci yöntemde, bölüm 2.1'de izah edilen görüntü karıştırma matrisi random tohum matrisi ve hayat oyunu ile elde edilmiş ve görüntü karıştırma performansı incelenmiştir. Burada, karıştırma seviyesi ( $n$ ) 15 olarak seçilmiştir. İkinci yöntemde ise, çalışmada önerilen yöntem uygulanmıştır. Her iki yöntem de 10 kez uygulanmış ve performansları irdelenmiştir. Tablo 2 ve tablo 3'te her iki yöntem ile elde edilmiş olan ortalama sonuçlar verilmiştir.

Tablo 2 ve tablo 3'te verilen sonuçların ışığında önerilen yöntemin komşu pikseller arasındaki korelasyonu daha iyi düşürdüğü ve daha büyük GFD


değerlerini elde ettiği görülmektedir. Hayat oyunu yönteminde standart sapmanın daha fazla olması  $A_0$  tohum matrisinin random elde edilmesi ile açıklanabilir. Şekil 2 ve şekil 3'te Lena ve kameraman test görüntüleri ve karıştırma işlemi sonucunda elde edilen yeni görüntüler verilmiştir.

Tablo 2. Lena için her iki yöntemle elde edilen korelasyon ve GFD değerleri


Korelasyon	Hayat Oyunu Yönt.		Önerilen Yöntem	
	Ortalama	St. Sapma	Ortalama	St. Sapma
Yatay	0.0005	0.0124	0.0001	0.0143
Dikey	0.0242	0.0128	0.0055	0.0015
Köşegen	0.0085	0.0124	0.0005	0.0019
GFD	0.9511	0.0001	0.9516	0.0013

Tablo 3. Kameraman için her iki yöntemle elde edilen korelasyon ve GFD değerleri

Korelasyon	Hayat Oyunu Yönt.		Önerilen Yöntem	
	Ortalama	St. Sapma	Ortalama	St. Sapma
Yatay	0.0035	0.0214	-0.0001	0.0033
Dikey	0.0302	0.0190	0.0117	0.0088
Köşegen	0.0041	0.0157	0.0001	0.0003
GFD	0.8958	0.0003	0.8967	0.0006




Şekil 2. a) Lena b) Karıştırılmış görüntü




Şekil 3. a) Kameraman b) Karıştırılmış görüntü

Şekil 2-b'de görülen karıştırılmış görüntü kural-75 ile elde edilmiş tohum matrisi ve  $n=10$  için elde edilmiştir. Benzer şekilde, şekil 3-b'deki görüntü ise kural-86 için elde edilen tohum matrisi ve  $n=8$  için elde edilmiştir. Görüldüğü üzere önerilen yöntem, hayat oyunu yöntemi ile  $n=15$  için elde edilen karıştırma performansının üstüne çıkmaktadır ve bunu daha az işlem yoğunluğu ve işlem süresi ile gerçeklemektedir. Önerilen yöntemin komşu pikseller arasındaki korelasyonu düşürme performansı da sırasıyla şekil 4 ve şekil 5'de verilmiştir. Burada, dağılım grafikleri orijinal ve karıştırılmış görüntüye ait rasgele 4000 piksel ile yatay komşusu için elde edilmiştir.

Bu çalışmada, önerilen yöntem gri seviyeli görüntüler için başarılı bir karıştırma performansı sergilemektedir. Hem önerilen görüntü karıştırma matrisi ile etkili bir görüntü karıştırma işlemi gerçekleştirilmiş hem de PSO algoritmasının kullanımı ile önerilen bu sistem gürbüz bir hale getirilmiş ve karıştırma performansı iyileştirilmiştir. Bundan sonraki çalışmalarda, önerilen yöntemin renkli görüntüler için uygulanabilirliğinin incelenmesi ve güvenlik analizlerinin yapılması hedeflenmektedir.



Şekil 4. Komşu piksellerin korelasyonu (Lena)



Şekil 5. Komşu piksellerin korelasyonu (Kameraman)

#### 4. Kaynaklar

- [1] Shou-Dong L. ve Hui X., "A New Color Digital Image Scrambling Algorithm Based on Chaotic Sequence", Int. Conf. on Comp. Science and Service System, Washington, DC, USA, 2012, s. 922-925.
- [2] Yongqi W. ve Zhang H., "A Color Image Blind Watermarking Algorithm Based on Chaotic Scrambling and Integer Wavelet", Int. Conf. on Network Computing and Information Security, Washington, DC, USA, 2011, s. 413-416.
- [3] Khatri N. ve Agrawal N., "Double Image Encryption Using Double Pixel Scrambling and Linear Canonical Transform", 4th Int. Conf. on Computing, communications and Networking Technologies, Tiruchengode, India, 2013, s. 1-5.
- [4] Shi H. ve Lv F., "A Blind Watermark Algorithm for Color Image Based on Dual Scrambling Technique", 3rd Int. Sym. on Int. Information Technology and Security Informatics, Washington, DC, USA, 2010, s. 781-785.
- [5] A. L. A. Dalhoum, B. A. Mahafzah, A. A. Awwad, I. Aldamari, A. Ortega, ve M. Alfonseca, "Digital image scrambling using 2D cellular automata," IEEE Transactions on Multimedia, vol. 19, no. 4, 2012, s. 28-36.
- [6] Rong W. C., Liu J. J. Ve Liang G. Y., "A DCT\_SVD Domian Watermarking Algorithm for Digital Image Based on Moore-model Cellular Automata Scrambling", Int. Conf. on Intelligent Computing and Integrated Systems, Guilin, China, 2010, s. 104-108.
- [7] Lou Y. ve Hu T., "A novel image security system based on cellular automata and improved chaotic system", 5th Int. Cong. on Image and Sig. Proc., Sichuan, China, 2012, s. 1139-1142.
- [8] Ye R. ve Li H., "A Novel Image Sacrambling and Watermarking Scheme based on Cellular Automata", Int. Symp. on Electronic Commerce and Sec., Guangzhou, China, 2008, s. 938-941.
- [9] Qadir F., Peer M. A. ve Khan K. A., "Digital Image Scrambling Based on Two Dimensional Cellular Automata", Int. Journal of Comp. Net. and Info. Security, cilt. 5, no. 2, 2013, s. 36-41.
- [10] Kennedy, J. ve Eberhart, R. C., "Particle Swarm Optimization", Proc. of IEEE Int. Conf. on Neu. Netw., Perth, Australia, 4:, 1995, s. 1942-1948.
- [11] Eberhart, R. C. ve Kennedy, J., "A new optimizer using particle swarm teory", Proc. of the Sixth Int. Symposium on Micro Machine and Human Science, Nagoya, Japan, 1995, s. 39-43.



## Çok Hedefli Parçacık Sürü Optimizasyonu için Smith Abağı Yaklaşımı

Yunus DURSUN<sup>1</sup>      Ufuk ÖZKAYA<sup>2</sup>

<sup>1,2</sup>Elektronik ve Haberleşme Mühendisliği Bölümü  
Mühendislik Fakültesi

Süleyman Demirel Üniversitesi, ISPARTA

Email: yunusdursun@yandex.com

ufukozkaya@sdu.edu.tr

### Özet

*Bu çalışmada, çok hedefli parçacık sürü optimizasyonu için Smith abağına dayalı yeni bir yaklaşım önerilmiştir. Bu yaklaşım ile her bir parçacığın konumunu lokal en iyi parçacığa göre güncellemeleri sağlanmaktadır ve lokal en iyi parçacığın belirlenmesinde ise empedans ve admitans çemberleri kullanılmıştır. Önerilen yöntem, farklı davranışa sahip üç test fonksiyonuna uygulanmış ve performans parametreleri incelenmiştir. Elde edilen sonuçlar ışığında, Smith abağı yaklaşımının çok hedefli optimizasyon uygulamaları için başarılı olduğu gözlenmiştir.*

### 1. Giriş

Günümüz mühendislik tasarım problemlerinde tasarım hedeflerinin eşzamanlı olarak çözülmesi amaçlanmaktadır. Tasarım problemlerinin büyük bir çoğunluğu da birbirleriyle zıt davranışa sahip tasarım hedeflerini içermektedir. Yani, bir tasarım hedefini iyileştirmek diğerlerinde kötüleşmeye neden olmaktadır. Dolayısıyla, tasarım probleminin çözümünde tek bir çözüm noktasından bahsetmek yeterince doğru olmayıp, bunun yerine hedeflerden birisi için diğerlerinden ödün vermeden elde edilecek bir çözüm kümesine ulaşmak gerekmektedir ve bu tip problemlerin çözümü için çok hedefli optimizasyon yöntemleri kullanılmaktadır.

Literatürde çok hedefli optimizasyon için bir çok yöntem bulunmaktadır. Bunlar arasında en çok bilinenler ise; evrimsel strateji [1], genetik algoritma[2-3], parçacık sürü optimizasyonu tabanlı çok hedefli optimizasyon yöntemleridir. PSO algoritmasında, parçacıklar en iyi performansa sahip olan parçacığın rehberliğinde optimum çözüm noktasını ararlar. Global optimum tekil bir çözüm noktasında olduğundan en iyi performansa sahip parçacığa göre pozisyon değiştirmek oldukça mantıklı

bir davranıştır. Ancak, çok hedefli optimizasyon problemlerinde çözümü ifade eden birden çok çözüm noktası bulunduğundan çözüm kümesini elde edebilmek için parçacık konumlarının aynı parçacığa göre değil, çözüm kümesine ulaşmayı sağlayacak en uygun parçacığa göre güncellenmesi gerekmektedir. Dolayısıyla, çok hedefli parçacık sürü optimizasyon yönteminde sürünün hepsine kılavuzluk eden “global en iyi” kavramının yerini “lokal en iyi” kavramı almaktadır [4-6]. Çok hedefli optimizasyonda temel amaç, çözüm kümesini oluşturan bütün çözüm noktalarını en doğru şekilde elde etmek olduğundan, lokal en iyi parçacığın tayininde başarılı bir yöntem veya yaklaşıma ihtiyaç duyulmaktadır.

Bu çalışmada, çok hedefli optimizasyon problemlerinin parçacık sürü optimizasyonu yöntemi ile çözümü için bir yaklaşım önerilmektedir ve lokal en iyi parçacığın belirlenmesinde Smith abağı empedans ve admitans çemberleri kullanılmıştır. Önerilen yaklaşım, farklı davranıştaki üç test fonksiyonuna uygulanmış ve performansı yakınsama ve çözüm çeşitliliği açısından değerlendirilmiştir.

### 2. Parçacık Sürü Optimizasyonu

Parçacık sürü optimizasyonu (PSO), popülasyon tabanlı bir optimizasyon yöntemidir ve ilk olarak Kennedy ve Eberhart tarafından kuş ve balık sürülerinin sosyal davranışlarının incelenmesi sonucu ortaya çıkmıştır [7-8]. PSO algoritması bir parçacık sürüsü ile optimizasyon problemine çözüm aramaktadır ve burada her bir parçacık optimizasyon problemi için birer potansiyel çözüm noktasını temsil etmektedir.  $s$  adet parçacıktan oluşan bir sürüde her parçacık için üç parametre tanımlanmaktadır.

$x_i$  : Parçacığın güncel konumu;

$v_i$  : Parçacığın güncel hızı;

$p_i$  : Parçacığın bireysel en iyi konumudur.

Parçacıklar her işlem adımında geçmişteki tecrübeleri ile o anki performanslarını kıyaslayarak bireysel en iyi konumlarını güncellemektedirler. Güncelleme işlemi (1) nolu eşitlik uyarınca yapılmaktadır. Burada,  $f$  hedef fonksiyonunu simgelemektedir.

$$p_i(t+1) = \begin{cases} p_i(t), & f(x_i(t+1)) \geq f(p_i(t)) \\ x_i(t+1), & f(x_i(t+1)) < f(p_i(t)) \end{cases} \quad (1)$$

PSO algoritmasında parçacıklar, her bir işlem adımında bireysel performanslarını kıyaslayarak ve sürüde etkileşim içinde olduğu parçacıklardan en iyi performansa sahip olan parçacığın (global en iyi parçacık) konumunu kullanarak hızlarını ve konumlarını güncellemektedirler. Hız güncelleme işlemi parçacığın her bir boyutu için yapılmaktadır. Hız güncelleme işlemi eşitlik (2) ile ifade edilmektedir.

$$v_{i,j}(t+1) = \omega[v_{i,j}(t) + c_1 r_{1,j}(t)[p_{i,j}(t) - x_{i,j}(t)] + c_2 r_{2,j}(t)[g_j(t) - x_{i,j}(t)]] \quad (2)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3)$$

Burada,  $\omega$  eylemsizlik katsayısıdır ve parçacıkların önceki hızlarının ne kadarını bir sonraki işlem adımında koruyacaklarını belirler. Algoritma, iki adet bağımsız rastgele değişken kullanmaktadır ( $r_{1,j}(t) \sim U(0,1)$  ve  $r_{2,j}(t) \sim U(0,1)$ ). Bu rastgele değerler algoritmanın rastlantısal doğasını ortaya koymaktadır.  $c_1, c_2$  katsayıları değerleri  $[0,2]$  arasında olan öğrenme (hızlanma) katsayılarıdır.  $p_{i,j}(t)$ ,  $i$ . parçacığın  $t$ . işlem adımına dek elde etmiş olduğu bireysel en iyi konumunun  $j$ . boyutundaki değeridir.  $g_j(t)$  ise,  $t$ . işlem adımında sürüdeki en iyi performansa sahip parçacığın konumunun  $j$ . boyutundaki değeridir.

$$f(g(t)) = \min \{f(p_1(t)), f(p_2(t)), \dots, f(p_s(t))\} \quad (4)$$

$$g(t) \in \{p_1(t), p_2(t), \dots, p_s(t)\}$$

Eşitlik (2)'de görüldüğü üzere bir parçacığın konumunu güncellerken üç parametre ön plana çıkmaktadır. Birincisi, parçacığın sahip olduğu hız değeridir. İkincisi ise, parçacığın bireysel en iyi konumudur ve son olarak da sürüdeki en iyi performansa sahip parçacığın (global en iyi) konumudur. Dolayısı ile, parçacıklar hem kendi tecrübelerini hatırlayarak hem de sürüdeki en iyi

performansa sahip parçacığın kılavuzluğunda konumu güncellemektedir.

### 3. Çok Hedefli Optimizasyon

Çok hedefli optimizasyon,  $m$  adet hedef fonksiyonun ( $\vec{f}(\vec{x}) = (f_1(\vec{x}), f_2(\vec{x}), \dots, f_m(\vec{x}))$ )  $X$  karar uzayında tanımlanan kısıtlamalara ve  $n$  adet karar değişkenine göre eşzamanlı olarak gerçekleştirilen minimizasyon veya maksimizasyon işlemidir. Çok hedefli optimizasyon problemlerinde kullanılan yöntemlerden biri her bir hedefi tek bir hedef fonksiyonunda bir araya getirmektir. Hedef fonksiyonlarını bir araya getirmede en çok kullanılan yöntem ise, bu fonksiyonları ağırlıklı doğrusal toplamlar şeklinde ifade etmektir. Her bir hedef fonksiyonunun çarpılması gereken ağırlıklar, hedefin toplam fonksiyon içindeki ağırlığını kaybetmeyeceği şekilde seçilmelidir. Elde edilecek değerlerin her bir hedef için belirlenmiş ağırlıklara bağlı olacağı açıktır. Buna rağmen her bir hedef fonksiyonu için tanımlanmış ağırlık değerleri, uygun olarak seçilerek oluşturulmuş bir doğrusal toplam fonksiyonu, herhangi bir optimizasyon algoritması ile optimize edilerek oldukça başarılı değerler elde edilebilir. Çok hedefli optimizasyon problemlerinde kullanılan en geçerli yöntemlerden bir diğeri de pareto optimal analizidir.


#### 3.1. Pareto Optimal Analizi

Çok hedefli optimizasyon problemleri genellikle birbirleri ile zıt davranışa sahip hedeflerden oluşmaktadır. Dolayısıyla, mevcut hedeflerden birine yakınlığa sahip bir çözüm noktası diğer hedeflerden uzaklaşmaktadır. Bu durumda, çok hedefli optimizasyon problemlerinin çözümünü sadece tekil bir çözüm noktası veya vektörü ile tanımlamak ve diğer çözüm noktalarından daha iyi olduğunu her zaman garanti etmek mümkün değildir. Bunun yerine, domine edilmemiş çözümler olarak isimlendirilen bir optimal çözüm kümesi elde edilmesi gerekmektedir. (Şekil 1). Bu çözüm kümesi pareto baskınlık ilişkileri kullanılarak elde edilmektedir. Örneğin;  $\vec{x}_1, \vec{x}_2 \in X$   $m$  adet hedef fonksiyonuna sahip bir çok hedefli bir optimizasyon probleminde iki çözüm vektörü için:

- $\vec{x}_1 \preceq \vec{x}_2$  ( $\vec{x}_1, \vec{x}_2$ 'ye az baskındır) eğer ve sadece eğer  $f_i(\vec{x}_1) \leq f_i(\vec{x}_2)$ , her  $i \in \{1, 2, \dots, m\}$  için,

- $\vec{x}_1 \prec \vec{x}_2$  ( $\vec{x}_1, \vec{x}_2$  'ye baskındır) eğer ve sadece eğer  $\vec{x}_1 \preceq \vec{x}_2$  ve  $f_j(\vec{x}_1) < f_j(\vec{x}_2)$  en az bir  $j \in \{1, 2, \dots, m\}$  için,
- ( $\vec{x}_1 \sim \vec{x}_2$  ( $\vec{x}_1, \vec{x}_2$  'den farksızdır) eğer ve sadece eğer  $\vec{x}_1 \preceq \vec{x}_2$  'ye baskın değildir ve  $\vec{x}_2 \preceq \vec{x}_1$  'e baskın değildir.

$\vec{x}_1$  ve  $\vec{x}_2$  'nin diğer çözüm vektörlerine baskın oldukları ve birbirlerine ise baskın olmadıkları durumda bu iki çözüm vektörü karşılıklı olarak optimal çözüm olarak kabul edilir ve pareto-optimal olarak isimlendirilmektedir. Pareto optimal çözüm kümesi, farklı hedef fonksiyonları arasındaki ödünleşim yüzeyini ifade etmektedir ve bu kümeye pareto sınırı (front) denir.



Şekil 1. Parametre uzayından, fonksiyon uzayına geçiş ve domine edilmemiş çözümler

#### 4. Smith Abağı Yaklaşımı

Smith abağı yaklaşımı ile geliştirilen PSO algoritmasının aşamalarını izah edersek:

1. Optimizasyon probleminin boyutu, optimize edilecek parametrelerin alt ve üst sınırları, hedef fonksiyonları ve parçacık sayısı belirlenir.
2. Parçacıkların pozisyonları alt ve üst sınırlar arasında rasgele tayin edilir. Parçacıkların ilk hız değerleri sıfır olarak tayin edilir ve her bir parçacığın ilk bireysel en iyi konumları ilk konumlarına eşitlenir. Her bir iterasyonda en iyi çözümleri saklamak üzere arşiv oluşturulur.
3. Sürüdeki her bir parçacık hedef fonksiyonlarına uygulanır ve fonksiyon değerleri elde edilir. Her bir parçacık hedef uzayındaki fonksiyon değerini ve geçmişteki fonksiyon değerlerini karşılaştırarak bireysel performansını günceller.
4. Parçacıkların hedef uzayındaki fonksiyon değerleri arasından domine edilmemiş çözümler pareto yöntemi ile bulunur ve domine edilmemiş

olan parçacıkların konumları ve fonksiyon değerleri arşive gönderilir.

5. Her bir parçacık kendisine en iyi rehberi (lokal en iyi) seçerek ve kendi bireysel performansını hatırlayarak hızını ve konumunu günceller.


Lokal en iyi parçacığın belirlenmesi ise sırasıyla şu şekildedir:

- Arşivde depolanan parçacıkların fonksiyon değerleri eşitlik (5) ve (6) ile Smith abağı uzayına eşleştirilir.  $i$ . arşiv üyesinin fonksiyon değerleri ( $f_{i,1}, f_{i,2}$ ) olmak üzere fonksiyon değerleri empedans ve admitans değerlerine dönüştürülür.

$$Z_i = f_{i,1} + jf_{i,2} (\Omega) \quad (5)$$

$$Y_i = \frac{1}{Z_i} (\Omega)^{-1} \quad (6)$$

- Diğer parçacıkların fonksiyon değerleri de eşitlik (5) ve (6) ile Smith abağı uzayına eşleştirilir.
- Bu aşamada her parçacık arşivdeki parçacıklardan en uygun lokal en iyi parçacığı seçer. Burada, bir parçacık için dört farklı lokal en iyi parçacık seçilir.

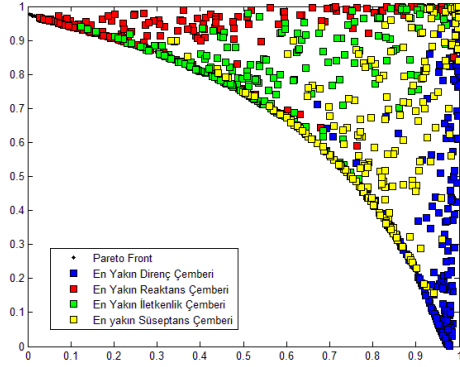


Şekil 2. Bir parçacığın lokal en iyi parçacık tayini

Bir parçacık için dört farklı lokal en iyi parçacık seçilir (Şekil 2):

1. En yakın direnç çemberi üzerinde bulunan arşiv üyesi,
2. En yakın reaktans çemberi üzerinde bulunan arşiv üyesi,
3. En yakın iletkenlik çemberi üzerinde bulunan arşiv üyesi,
4. En yakın süseptans çemberi üzerinde bulunan arşiv üyesi.

Şekilden de görüldüğü üzere parçacık farklı arşiv üyelerine bağlı olarak konumunu güncelleyecektir. Şekil 3'te yukarıda maddeler halinde verilen dört farklı durumun sonuca olan etkisi grafiksel olarak sunulmuştur. Görüldüğü üzere, her durum pareto eğrisinin belirli bir bölgesinde yoğunlaşmakta ve nihayetinde gerçek pareto eğrisini sağlamaktadır.



Şekil 3. Lokal en iyi tayin çeşitlerinin pareto front üzerindeki etkisi

## 5. Sonuçlar

Önerilen yaklaşımın başarısı literatürde sıkça kullanılan üç farklı test fonksiyonuna uygulanarak değerlendirilmiştir. Algoritma her test fonksiyonu için 40 kez çalıştırılmıştır. Maksimum iterasyon sayısı 2000 ve parçacık sayısı 100 olarak belirlenmiştir. Şekil 4, 5 ve 6'da elde edilen grafiksel sonuçlar verilmiştir.

**Test Fonksiyonu-I:** Kursawe Test Fonksiyonu [9]

$$\text{Minimize } Et = \begin{cases} f_1(x) = \sum_{i=1}^2 \left[ -10 \exp \left( -0.2 \sqrt{x_i^2 + x_{i+1}^2} \right) \right] \\ f_2(x) = \sum_{i=1}^3 \left[ |x_i|^{0.8} + 5 \sin(x_i^3) \right] \end{cases} \quad (7)$$

$$-5 \leq x_i \leq 5, \quad 1 \leq i \leq 3.$$

**Test Fonksiyonu-II:** Schaffer-I Test Fonksiyonu

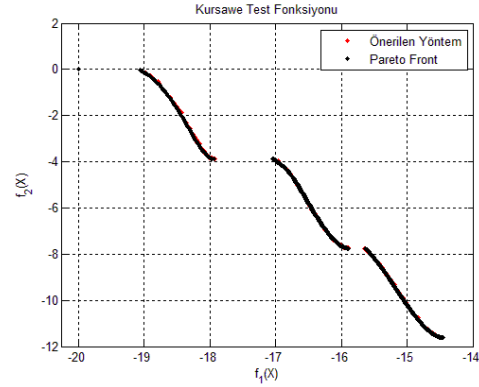
$$\text{Minimize } Et = \begin{cases} f_1(x) = x^2 \\ f_2(x) = (x-2)^2 \end{cases} \quad (8)$$

$$-A \leq x \leq A, \quad 10 \leq A \leq 10^5.$$


**Test Fonksiyonu-III:** Fonseca & Fleming Test Fonksiyonu

$$\text{Minimize } Et = \begin{cases} f_1(x) = 1 - \exp \left( -\sum_{i=1}^n \left( x_i - \frac{1}{\sqrt{n}} \right)^2 \right) \\ f_2(x) = 1 - \exp \left( -\sum_{i=1}^n \left( x_i + \frac{1}{\sqrt{n}} \right)^2 \right) \end{cases} \quad (9)$$


$$-4 \leq x_i \leq 4, \quad 1 \leq i \leq n.$$



Şekil 4. Kursawe için elde edilen pareto front



Şekil 5. Schaffer-I için elde edilen pareto front



Şekil 6. Fonseca & Fleming için elde edilen pareto front

Önerilen yöntemin performansını değerlendirmek amacıyla bazı ilave değerlendirmeler yapılmıştır. Bu

niceliksel değerlendirmeler Van Veldhuizen ve Lamont tarafından geliştirilmiş olan yakınsama ve çeşitlilik parametreleridir [10]. Yakınsama metriği, algoritma ile elde edilen pareto frontun gerçek pareto fronta ne kadar yaklaşık elde edildiğini ifade etmektedir. Bu metrik için minimum ve hedef değer "0" dır. Diğer metrik ise algoritma tarafından elde edilen pareto frontu oluşturan noktaların dağılımını vermektedir. Minimum ve hedef değeri "0" olan bu metrik de bulunan pareto frontun iki ekstremum nokta arasındaki dağılımını vermektedir. Diğer bir deyişle, elde edilen çözümlerin ne kadar düzgün dağıldığını ifade etmektedir.

Tablo 1. Önerilen yöntemin yakınsama performansı

Test Fonksiyonu	Minimum	Maksimum	Ortalama	Medyan	Std. Sap.
Kursawe	0.000879	0.0014	0.0011	0.0011	0.00007648
Schaffer	0.00049564	0.0005153	0.0005097	0.0005072	0.00000612
Fonseca And Fleaming	0.00051618	0.0006628	0.0005821	0.0005896	0.00068063

Tablo 2. Önerilen yöntemin çeşitlilik performansı

Test Fonksiyonu	Minimum	Maksimum	Ortalama	Medyan	Std. Sap.
Kursawe	0.0393	0.0996	0.0503	0.0464	0.0120
Schaffer	0.0109	0.0137	0.0123	0.0122	0.0013
Fonseca And Fleaming	0.0066	0.0077	0.0071	0.0068	0.0005115

Önerilen yöntem farklı yapıdaki (konveks, konkav, sürekli, süreksiz) test fonksiyonları için başarılı yakınsama ve çeşitlilik performansı göstermektedir. Gelecek çalışmalarda, yöntem hakkında daha kesin yargılara varılabilmesi için literatürdeki diğer test fonksiyonlarına uygulanması planlanmaktadır.

## 6. Kaynaklar

- [1] J. D. Knowles and D. W. Corne, "Approximating the nondominated front using the Pareto archived evolution strategy," *Evol. Comput.*, vol. 8, pp. 149–172, 2000.
- [2] C. A. Coello Coello and G. T. Pulido, "Multiobjective optimization using a micro-genetic algorithm," in *Proc. Genetic and Evolutionary Computation Conf. (GECCO'2001)*, L. Spector, E. D. Goodman, A. Wu, W. B. Langdon, H.-M. Voigt, M. Gen, S. Sen, M. Dorigo, S. Pezeshk, M. H. Garzon, and E. Burke, Eds., San Francisco, CA, 2001, pp. 274-282.
- [3] K. Deb, S. Agrawal, A. Pratab, and T. Meyarivan, "A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II," in *Proc. Parallel Problem Solving From Nature VI Conf.*, 2000, pp. 849–858.
- [4] Carlos A. Coello Coello, Gregorio Toscano Pulido, and Maximino Salazar Lechuga. Handling Multiple Objectives With Particle Swarm Optimization. *IEEE Transactions on Evolutionary Computation*, 8(3):256–279, June 2004.
- [5] Hu, X. ve Eberhart, R., (2002), "Multiobjective optimization using dynamic neighborhood particle swarm optimization", *IEEE proceedings, World congress on Computational Intelligence*, 1677-1681.
- [6] Mostaghim, S. ve Teich, J., (2003), "Strategies for finding good local guides in multi-objective particle swarm optimization (mopso)", *IEEE 2003 Swarm Intelligence Symposium*.
- [7] Kennedy, J. ve Eberhart, R. C., (1995), "Particle Swarm Optimization", *Proc. of IEEE International Conference on Neural Networks*, 1995, Perth, Australia, 4: 1942-1948.
- [8] Eberhart, R. C. ve Kennedy, J., (1995), "A new optimizer using particle swarm theory", *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 1995, Nagoya, Japan, 39-43.
- [9] F. Kursawe, "A variant of evolution strategies for vector optimization," in *Lecture Notes in Computer Science*, H. P. Schwefel and R. M. Männer, Eds. Berlin, Germany: Springer-Verlag, Oct 1991, vol. 496, *Proc. Parallel Problem Solving From Nature*, 1st Workshop, PPSN I, pp. 193–197.
- [10] D. A. Van Veldhuizen and G. B. Lamont, "Multiobjective evolutionary algorithm research: A history and analysis," *Dept. Elec. Comput. Eng., Graduate School of Eng., Air Force Inst. Technol., Wright-Patterson AFB, OH, Tech. Rep. TR-98-03*, 1998.

## El Geometrisi Tabanlı Kısıtlamasız ve Temassız Bir Kimliklendirme Sistemi

Özkan BİNGÖL<sup>1</sup>

Murat EKİNCİ<sup>2</sup>

Ahmet GÖKDOĞAN<sup>3</sup>

<sup>1</sup>Yazılım Mühendisliği Bölümü, <sup>3</sup>Matematik Mühendisliği Bölümü  
Mühendislik Fakültesi

Gümüşhane Üniversitesi, GÜMÜŞHANE

<sup>2</sup>Bilgisayar Mühendisliği Bölümü

Mühendislik Fakültesi

Karadeniz Teknik Üniversitesi, TRABZON

bingolo@gumushane.edu.tr

ekinci@ktu.edu.tr

gokdogan@gumushane.edu.tr

### Özet

*El geometrisi tabanlı sistemler, ilk geliştirilen ve uygulanan biyometrik sistemlerden birisidir. Düşük çözünürlüklü kameralardan bile yüksek başarımının elde edilebildiği bu sistemler üzerine yapılan çalışmalarda genellikle kullanıcıları kısıtlayıcı işaretçiler veya düzenekler kullanılmaktadır. Bu çalışmada ise, tamamen kısıtlamasız ve düzenekten bağımsız bir sistem önerilmektedir. Bir kamera yardımıyla alınan el görüntüsü Aktif Görünüm Modeli ile bölütlenmekte ve kimliklendirme için kullanılacak özellikler çıkarılmaktadır. Sistemi test etmek için IITD Avuçiçi Veritabanı ve k-EYK sınıflandırma teknikleriyle sistemin başarımı incelenmiştir.*

*Anahtar Kelimeler: El geometrisi, Akif Görünüm Modeli, biyometri, tanıma*

### 1. Giriş

El geometrisi tabanlı biyometrik sistemler, elin ve parmakların geometrik özellikleri arasındaki ilişkileri kullanarak doğrulama yapan sistemlerdir. Bu sistemler; ayırteci özellikler olarak, parmakların genişlikleri ve uzunlukları, avuçiçinin genişliği ve alanı gibi özellikleri kullanmaktadırlar. Kullanım kolaylığı, özellik sayısının az olması, düşük çözünürlüklü kameraların yeterli olması ve diğer el tabanlı biyometrik sistemlere rahatlıkla dahil edilebilmesinden dolayı, özellikle çok fazla kullanıcı olan yerlerde tercih edilen bir sistemdir[8].

Bu konuyla ilgili çalışmalar ve bunların uygulamaları diğer biyometrik özelliklere göre daha eskilere dayanmaktadır. 1960'lı yılların ortalarında Robert

Miller ilk otomatik el geometri tanımlama cihazını tasarlamış ve tamamen mekanik olan bu cihazın patentini almıştır. 1970'li yıllarda ise Identimation firması tarafından ilk ticari ürün (Identimat isminde bir el geometrisi tarayıcısı) geliştirilmiş ve 1987 yılına kadar bu cihazlar üretilmeye devam edilmiştir[1].

Sonraki yıllarda, dijital tarayıcılar ve kameraların gelişimi ile mekanik olmayan, daha hızlı çalışan uygulamalar gerçekleştirilmiştir. Jang ve ark.[2] çalışmalarında, el geometrisi özelliklerini kullanan önyükleme tekniğine dayalı bir sistem geliştirmişlerdir. Jain ve ark. [3], 50 farklı kişi ve 16 farklı açıdan alınan görüntülerin olduğu bir veri tabanı üzerinde parmakların uzunluğu ve genişliğine göre elde edilen özellikleri kullanan bir sistem geliştirmiştir. Sanchez-Riello ve ark. [4] elin renkli görüntüsünden 25 adet özellik kümesi çıkaran bir sistem geliştirmişler. Bu sistemde 20 kişilik küçük bir veri tabanı kullanmışlar ve %96'lık bir tanıma oranı ulaşımlardır. Jain ve Duta [9] eldeki geometrik özelliklerin yerine parmakların hizalama şekline göre bir sistem geliştirmişler. Sidlauskas[1] ise 3B el profil tanımlayıcı bir cihaz geliştirmiştir.

Geliştirilen bu ve benzeri sistemlerde sabit işaretçiler yardımıyla elin hareketi kısıtlanarak geometrik özellikler elde edilmektedir. Bu kısıtlamalar, sistemin hata oranını çok düşürmesine rağmen, bazı özel durumlardaki kullanıcılardan dolayı, sistemin performansı olumsuz yönde etkilenmektedir. Örneğin, bir veya birden fazla parmağını kaybetmiş, yüzük vb. takı kullanan ya da gut gibi hastalığı olan kişilerin sistemi kullanmaları zorlaştırmaktadır. Aynı zamanda bu sistemlerde, kullanıcılar ellerini mutlaka cam gibi bir düz yüzey üzerine yerleştirmeleri istenmektedir. Bu

da beraberinde bulaşıcı hastalıkların yaygınlaşmasını yani hijyen problemlerini ortaya çıkarmaktadır.

Bu durumlar dikkate alınarak son zamanlarda kısıtlamasız ortamda bazı sistemler geliştirilmeye çalışılmıştır. Kumar ve ark.[5] işaretçi olmayan yüksek çözünürlüklü el görüntüleri üzerinde çalışmışlar, fakat bu çalışmalarında el geometrisinden ziyade avuç içi özelliklerine odaklanmışlardır. Park ve Kim [6] elin avuç içi kısmı yerine üst tarafından aldıkları el geometrik özelliklerini ve Kızılötesi kameralarla aldıkları damar örüntüsü ile birleştirerek bir çalışma gerçekleştirmişlerdir. Xin ve ark.[7] temassız bir sistemde aldıkları el görüntülerinde ilk önce kayan pencere filtreleme algoritması kullanarak parmakların uç noktaları ve parmak birleşme noktalarını belirlemiş, sonrasında ise bunlar arasında uzaklık, açı ve uzunluk gibi özellikleri çıkarmışlardır.

Tüm bu uygulamalara genel olarak bakıldığında geliştirilen sistemler ya ciddi kısıtlamalar içermektedirler ya da kutu benzeri bir platforma bağımlıdır. Platformun ortadan kaldırılması durumunda ise farklı ışık kaynakları görüntü kalitesinin bozulmasına neden olacak ve çok değişkenli arka plan görüntüleri elin ortamdan ayrıştırılması zorlaştıracaktır. Özellikle kamera açısına el ile aynı renkte nesnelere girmesi el bölütlemesini engelleyebilmektedir.

Bu çalışmada, platformdan bağımsız, kısıtlama amaçlı herhangi bir işaretleyici içermeyen, el geometrisi tabanlı bir biyometrik sistem önerilmiştir. Elin doku özelliğinden faydalanarak, arka plandan ayrıştırılması için Aktif Görünüm Modeli (AGM) kullanılmıştır. AGM modelinin içerdiği şekil modeli yardımıyla da el geometrik özellikleri çıkarılmıştır. Böylece bölütleme ve özellik çıkarımı işlemi tek bir aşamada gerçekleştirilmiştir.

## 2. Önerilen Yöntem

Platformdan bağımsız, tamamen kısıtlamasız olarak düşünülen bu sistem, kabaca aşamalardan oluşmaktadır:

- (1) Görüntünün elde edilmesi
- (2) AGM ile el bölütlemesi
- (3) Geometrik özelliklerin çıkarılması
- (4) k-EYK ile özelliklerin sınıflandırılması

### 2.1. AGM ile El Bölütlemesi

El üzerinde geometrik özellikler çıkarmak ve elin bölütlenmesi AGM yardımıyla gerçekleştirilebilir. AGM, nesnenin şekil ve görünüş önsel bilgisini kullanarak çözüm uzayını kısıtlayan model tabanlı nesne konumlama metodudur. AGM'de şekil ve doku değişimleri Temel Bileşenler Analizi (TBA) ile modellenmektedir.


AGM, önceden ele ait önemli noktaların koordinatları saptanmış eğitim resimleri ile eğitilir. Eğitim kümesindeki tüm elleri  $\{(s,g)\}$  şeklinde ifade edebiliriz:

$$s = s_0 - \Phi s p \quad (1)$$

$$g = g_0 - \Phi t q \quad (2)$$

burada  $s$  ve  $g$ , sırasıyla şekil vektörü ve doku vektörü;  $s_0$  ve  $g_0$  ortalama şekil ve ortalama doku;  $\Phi s$  ve  $\Phi t$  şekil ve dokunun özvektörleri;  $p$  ve  $q$  şekil ve dokunun parametre vektörleridir. Daha fazla detay için [10-12] çalışmalarına bakılabilir.

Bu çalışmada AGM'nin bir el üzerine oturtulabilmesi için 28 adet nirengi noktası belirlenmiştir (Şekil 1). Bu noktalar avuç içi ve parmaklarda sınır çizgileri üzerinde olacak şekilde seçilmiştir. Şekil 1.'de de görüldüğü üzere belirlenen noktalar elin bütün alanını kapsamamaktadır. Buradaki amaç, bir el tam olarak kamera açısına girmese bile tanıma işleminin gerçekleştirilebilmesidir. Ayrıca, sonraki bölümde bahsedilen göreceli metrikler sayesinde elin ölçklemeden de bağımsız hale getirilmesi sağlanmıştır.



Şekil 1. AGM nirengi noktaları



## 2.2. El geometrik özelliklerinin çıkarılması

Tanımda kullanılmak üzere alan ve uzunluğa bağlı olarak el için değişmez olabilecek özellikler belirlenmiştir. Kişilerin el büyüklüklerinin farklı olması, elin kamera düzlemine göre yakın veya uzakta olması ve parmakların açıklık durumlarından kaynaklanacak problemleri gidermek için özellikler göreceli olarak seçilmiştir. Bu amaçla, uzunluk özellikleri parmak boğum genişliklerinin ortalama uzunluğuna ( $\ell$ ) oranına göre, alan özellikleri ise parmakların boğum alanlarının toplamına ( $A$ ) oranlayarak bulunmuştur. Buna göre  $\ell$  şu şekilde hesaplanmaktadır:

$$\ell = (||P_5-P_6|| + ||P_{11}-P_{17}|| + ||P_{17}-P_{18}|| + ||P_{23}-P_{24}||) / 4 \quad (3)$$

burada  $|| \cdot , \cdot ||$  iki nokta arasındaki Öklid uzaklıktır.  $A$  değeri ise;

$$A = \sum_{i=1}^4 A_i \quad (4)$$

şeklinde hesaplanmaktadır. Burada her bir  $A_i$  değeri,  $i$ . parmağın boğumu üzerindeki 6 nokta arasında kalan alandır (Örneğin yüzük parmağı için  $P_9, P_{10}, P_{11}, P_{12}, P_{13}$  ve  $P_{14}$  arasında kalan alan). Buna göre bir parmak üzerindeki her bir  $(x_j, y_j)$  noktası ( $j=1..6$ ) ve  $(x_1, y_1) = (x_7, y_7)$  olmak üzere parmak boğum alanı şu şekilde bulunabilir:

$$A_i = \frac{1}{2} \left| \sum_{i=1}^6 (x_{i,j} y_{i,j+1} - x_{i,j+1} y_{i,j}) \right| \quad (5)$$

(3) ve (4) denklemleri yardımıyla bir parmağa ait hesaplanan geometrik özellikler aşağıda verilmiştir (Hesaplamalar örnek olarak yüzük parmağı ( $i=2$ ) için gösterilmiştir).

$$\text{Eklem genişliği } (f_1) = ||P_{11}-P_{12}|| / \ell \quad (6)$$

$$\text{Boğum genişliği } (f_2) = ||P_{10}-P_{13}|| / \ell \quad (7)$$

$$\text{Taban genişliği } (f_3) = ||P_9-P_{14}|| / \ell \quad (8)$$

$$\text{Boğum sol uzunluğu } (f_4) = ||P_9-P_{11}|| / \ell \quad (9)$$

$$\text{Boğum sağ uzunluğu } (f_5) = ||P_{12}-P_{14}|| / \ell \quad (10)$$

$$\text{Boğum alanı } (f_6) = A_{i=2} / A \quad (11)$$

Bu denklemler yardımıyla bir parmaktan 6 adet toplamda 24 adet özellik çıkarılmıştır. Ayrıca avuç

içinden elde edilen aşağıdaki üç özellik ile beraber toplamda 27 adet özellik belirlenmiştir.

$$\text{Avuçiçi genişliği } (f_{25}) = ||P_1-P_{28}|| / \ell \quad (12)$$

$$\text{Avuçiçi sol uzunluk } (f_{26}) = ||P_1-P_3|| / \ell \quad (13)$$

$$\text{Avuçiçi sağ uzunluk } (f_{27}) = ||P_{26}-P_{28}|| / \ell \quad (14)$$


## 2.3. Geometrik Özelliklerin Sınıflandırılması

AGM modelinden nirengi noktaları yardımıyla her bir görüntü için 27 adet özellikten oluşan bir özellik vektörü oluşturulmuş ve bu vektör her bir kullanıcının ID'si ile etiketlenerek k-En Yakın Komşuluk (k-EYK) algoritması ile sınıflandırılmıştır.

k-EYK yöntemi, denetimli öğrenme yöntemlerinden birisidir. Algoritma, daha önce eğitilmiş bir sisteme, yeni bir veri geldiğinde, onun en yakın k adet komşusuna bakarak hangi sınıfa dahil olacağına karar verir. Algoritmanın başarısını k sayısı ve benzerlik ölçümü gibi kriterler belirlemektedir.

## 3. Deneysel Çalışmalar

Geliştirilen bu sistemde, el ile ilgili biyometriklerin test edilmesi amacıyla sıklıkla literatürde tercih edilen IITD Dokunmasız Avuçiçi Veritabanı[13] tercih edilmiştir. Bu veritabanı, 12-57 yaş arasındaki 235 kullanıcıdan alınan sol ve sağ ele ait 800x600 çözünürlükteki görüntülerden oluşmaktadır (Şekil 2). Her bir el için en az 6 farklı görüntü alınmıştır.



Şekil 2. Kullanılan veritabanından örnek görüntüler

Bu veritabanından rasgele seçilen 25 adet farklı kişiye ait birer görüntü üzerinde, AGM modelinin eğitimi için, elle 28 adet nokta işaretlenmiş ve sistem eğitilmiştir. Bu noktalar sayesinde hem AGM modeli ele uydurulabilir hem de parmak öznitelikleri tespit edilebilir. Daha sonra veritabanındaki tüm görüntüler için eğitilmiş AGM yardımıyla el bölütlemesi yapılmıştır. AGM'nin başarılı bir arama yapması için ilk arama başlangıç konumu ve ölçeklendirmesi çok önemlidir. Bu nedenle 3-seviyeli görüntü pramitleri oluşturularak arama uzayı küçültülmüştür.



AGM modelinden nirengi noktaları yardımıyla her bir görüntü için özellik vektörleri oluşturulmuştur. k-EYK algoritması için her kullanıcıya ait 5 adet görüntüden elde edilen özellik vektörü eğitim amacıyla kullanılmış, eğitimde kullanılmayan 1'er adet görüntüde sınıflandırma başarımını test etmek için kullanılmıştır. Algoritma eğitimde her bir kullanıcı için 5 adet görüntü kullanıldığından, sınıflandırma algoritması k=1, k=3 ve k=5 için değerlendirmeler yapılmıştır.

#### 4. Sonuçlar ve Tartışma

El geometrik özelliklerin tespit edilmesi ve kullanılması oldukça kolaydır. Bu nedenle, nispeten düşük seviyeli güvenlik gerektiren yerlerde ve özellik sayısı diğer biyometrilere oranlara daha az olduğu için çok kullanıcı olan yerlerde rahatlıkla kullanılabilir.

Bu çalışmada el geometrisi tabanlı ancak elin herhangi bir kısıtlama altında kalmadan veya herhangi bir yere temas etmeden, hatta el görüntüsüne arka plan serbestliği sağlayacak bir kimliklendirme yöntemi önerilmiştir. Ayrıca bölütleme işlemi ile özellik çıkarma işlemi AGM modeli üzerinden gerçekleştirilerek birleştirilmiştir. Bunun özellikle gerçek zamanlı uygulamalar için büyük bir avantaj sağlayacağı düşünülmektedir.

Önerilen sistemde kameradan bir görüntü üzerinde daha önce eğitilmiş AAM modeli çalıştırılarak elin bölütlemesi yapılmış, buradan elde edilen şablon üzerinden 27 adet el geometrik özelliği tespit edilmiştir. Bu özellikler, üç farklı k değeri ile k-EYK sınıflandırma algoritması kullanılarak sınıflandırılmıştır. Sonuç olarak k=1 için %97.65'lük, k=3 için %96.38 ve k=5 için %94.26'lık doğru sınıflandırma oranları tespit edilmiştir.

Elde edilen sonuçlar istenilen seviyede değildir ancak bu çalışmanın devamında; geliştirilen bu sistem, şu anda üzerinde çalıştığımız avuç içi örüntü tanıma sistemi ile birleştirilmesi planlanmaktadır. Birleştirilmiş sistem, yeni oluşturmaya başladığımız el veritabanı (Şekil 1.) ile bir uygulama alanında test edilecektir.

#### 5. Teşekkür

Bu çalışma, Gümüşhane Üniversitesi Bilimsel Araştırma Projeleri Komisyonu tarafından desteklenmiştir. (GÜBAP 13.F5121.02.2, 2013)

#### 6. Kaynaklar

- [1] D.P. Sidlauskas ve S. Tamer, "Hand geometry recognition." Handbook of Biometrics. Springer US, 2008. 91-107.
- [2] B.J. Jang, G.S. Jou, K.H. Shiu, C.C. Han, ve C.J. Shiu, "Hand features verification system of creatures," European Patent TW476917, 2002.
- [3] A.K. Jain, A. Ross, ve S. Pankarti, "A prototype hand geometry based verification system," in Proc. 2nd Int. Conf. Audio Video Based Biometric Personal Authentication, Mar. 1999, pp. 166-171.
- [4] R. Sanchez-Reillo, C. Sanchez-Avila, ve A. Gonzales-Marcos, "Biometric identification through hand geometry measurements," IEEE Trans. Pattern Anal. Mach. Intell., vol. 22, no. 10, pp. 1168-1171, Oct. 2000.
- [5] A. Kumar, ve David Zhang. "Hand-geometry recognition using entropy-based discretization." Information Forensics and Security, IEEE Transactions on 2.2 (2007): 181-187.
- [6] G.T.Park, ve S.Kim. "Hand biometric recognition based on fused hand geometry and vascular patterns" Sensors 13.3 (2013): 2895-2910.
- [7] C. Xin, X. Wu, Z. Qiushi, T. Youbao, "A contactless hand shape identification system." Advanced Computer Control (ICACC), 2011 3rd International Conference on. IEEE, 2011.
- [8] N. Duta, "A survey of biometric technology based on hand shape" Pattern Recognition 42.11 (2009): 2797-2806.
- [9] A.K. Jain ve N. Duta, "Deformable matching of hand shapes for verification," in Proc. Int. Conf. Image Processing, Oct. 1999, pp. 857-861.
- [10] M. Aykut ve M. Ekinci, "AAM-Based Palm Segmentation in Unrestricted Backgrounds and Various Postures for Palmprint Recognition". Pattern Recognition Letters 34.9 (2013): 955-962.
- [11] T.F. Cootes, G.J. Edwards ve C.J. Taylor "Active Appearance Models", IEEE Transactions on Pattern Analysis and Machine Intelligence, 23.6 (2001): 681-685.
- [12] F. Kahraman, B. Kurt, ve M. Gökmen. "Aktif Görünüm Modeline Dayalı Yüz Tanıma" 13. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2005.
- [13] A. Kumar, "Incorporating Cohort Information for Reliable Palmprint Authentication," Proc. ICVGIP, Bhubneshwar, India, pp. 583-590, Dec. 2008.

## Zaman Bölgesi Saçılım Sinyallerinin Yapısal Öznitelikleri ve Yapay Sinir Ağları Kullanılarak Dielektrik Küresel Hedeflerin Sınıflanması

Mehmet Mert TAYGUR<sup>1</sup> M. Alper SELVER<sup>2</sup> E. Yeşim ZORAL<sup>2</sup>

<sup>1</sup>Fen Bilimleri Enstitüsü, Dokuz Eylül Üniversitesi, Buca, İZMİR

<sup>2</sup>Elektrik ve Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi  
Dokuz Eylül Üniversitesi, Buca, İZMİR

Email: mtaygur@gmail.com alper.selver@deu.edu.tr yesim.zoral@deu.edu.tr

### Özet

*Benzer şekilli cisimlerden saçılan elektromanyetik dalgaları kullanarak ayırt etme probleminin çözümü, geliş açısına bağımlılıktan dolayı oldukça zordur. Bu bağımlılığı ortadan kaldırmak için, saçılım sinyallerinden ayırıcı öznitelikler çıkarılmalı ve işlenmelidir. Bu çalışmada, küresel geometriye sahip dielektrik hedeflerin tanınması için bir sınıflandırma yöntemi önerilmektedir. İlk olarak saçılım sinyallerinin yapısal özellikleri kullanılarak öznitelikler elde edilmiştir. Daha sonra bu öznitelikler ile yapay sinir ağı tabanlı bir sınıflayıcı tasarlanmıştır. Dielektrik küreler temel alınarak yapılan benzetimler ile sistem başarımı incelenmiştir.*

### 1. Giriş

Elektromanyetik saçılım sinyallerini kullanarak hedef tanıma, dalganın geliş açısına bağımlı olduğundan çözümü zor bir problemdir [1]. Tanıma işleminin etkin bir biçimde yapılabilmesi için saçılım sinyalinden ayırt edici öznitelikler çıkarılmalı ve uygun şekilde işlenmelidir [2]. Bununla birlikte, çıkarılan öznitelikler gürültüye karşı da dayanıklı olmalıdır [3].


Tasarlanacak bir hedef sınıflama sisteminde iki ana bileşen bulunmaktadır. Bunlardan ilki hedeflerin karakteristik özelliklerini ifade ederek diğer hedeflerden ayrılmasını sağlayacak özniteliklerin çıkarılmasıdır. Çıkarılan öznitelikler, hedefe bağlı karakteristik özellikleri hedefin pozisyon ve görüldüğü açıdan bağımsız olarak tanımlanabilmelidir [4]. Gerçek hayatta uygulanabilirliğin artırılması içinse, çıkartılacak özniteliklerin gürültüye karşı gürbüz olmaları gerekmektedir [5].

Bu çalışmada, geç-zaman sinyallerinden doğrudan çıkarılan yapısal özniteliklerin hedef sınıflamada kullanılabilirliği üzerine bir sınıflayıcı tasarımı gerçekleştirilmiştir. Farklı yarıçaptaki dielektrik kürelerin hedef olarak seçildiği çalışmada, küre yarıçapının geç zaman saçılım sinyallerinde neden olduğu yapısal değişimlerin çıkarılması ile yeni bir öznitelik kümesi tanımlanmıştır. Tanımlanan yeni öznitelik kümesi ile ifade edilen farklı yarı çaplardaki dielektrik küresel hedeflerin sınıflanması için yapay sinir ağları kullanılmış, elde edilen sonuçlar ile geliştirilen sistemin başarımı değerlendirilmiştir.


### 2. Saçılım Sinyallerinin Elde Edilmesi

Polarizasyonu x eksenine ve yayılma doğrultusu z eksenine olan bir dalganın dielektrik küreye çarptıktan sonra saçılmasının analitik olarak ifade edilmesi, Hertz ve Debye potansiyelleri kullanılarak mümkündür [3]. Saçılım verisi küresel koordinatlarda  $\varphi=\pi/2$  düzleminde, hedef küreden 72 cm uzaklıkta ( $R=72$  cm) ve 18 farklı bistatik en-boy açısı ( $\theta=10^\circ, 20^\circ, \dots, 180^\circ$ ) için alınmıştır. Uzak alan ifadeleri frekans uzayında 0-12 GHz bant aralığında 873 veri noktası ve 13.75 MHz frekans çözünürlüğü kullanılarak elde edilmiştir. Daha sonra IFFT (Inverse Fast Fourier Transform) kullanılarak toplam 5.115 ns'lik 1024 tane örnek içeren saçılım sinyali zaman uzayında elde edilmiştir.

Şekil 1'de farklı yarıçaptaki kürelerden saçılan geç zaman sinyalleri verilmiştir. Sinyallerin farklı yapısal özellikler gösterdiği aşikardır. Şekil 2'de ise aynı yarıçaptaki küreden farklı görüş açıları için elde edilen geç zaman sinyallerindeki değişimler gösterilmiştir. Farklı yarıçaptaki dielektrik kürelerin, görüş açısından bağımsız olarak sınıflanması için Şekil 1'deki değişimlere duyarlı olması ve Şekil 2'deki değişimlerden etkilenmemesi gerekmektedir.






Şekil 1. 120 derece geniş açısında 3 farklı yarıçapa sahip (2cm, 3cm, 4cm) dielektrik küreden elde edilen saçılma sinyali



Şekil 2. 3 cm yarıçapa sahip dielektrik küreden 3 farklı geniş açısında (80°, 100°, 120°) elde edilen saçılma sinyali

Sınıflandırıcının başarımı ilk olarak gürültüsüz saçılım sinyalleriyle ölçülmüş, daha sonra bu sinyallere gürültü eklenerek aynı benzetimler tekrar edilmiştir.



Şekil 3. 0.4 cm yarıçaplı küreden 90° açıyla elde edilmiş 15, 5, -5 dB SNR değerine sahip saçılım sinyalleri

### 3. Öznitelik Çıkarma

Öznitelik çıkarma algoritması saçılım sinyallerinin görsel özellikleri temel alınarak çalışmaktadır. Sinyallerin salınım yapan bir karakteristiğe sahip olduğu göz önünde bulundurularak (Şekil 1, 2) 6 tane öznitelik belirlenmiştir. Bu öznitelikler aşağıdaki gibidir;

- 1) Tepe ve dip noktaların genliği
- 2) Tepe ve dip dalga şekillerinin yatay eksene göre soldan genişliği
- 3) Tepe ve dip dalga şekillerinin yatay eksene göre sağdan genişliği
- 4,5) Tepe ve dip dalga şekillerinin yatay eksenin sağ ve sol taraflarına göre eğimleri
- 6) Tepe ve dip noktaların birbirine olan uzaklığı

Bu veriler ışığında, verilmiş tek bir saçılım sinyalinde toplam n tane tepe ve dip nokta olduğu düşünülürse sonuç olarak 6n-1 tane öznitelik elde edilecektir. Özniteliklerin doğruluğu öncelikli olarak tepe ve dip noktaların doğru tespit edilmesini gerektirmektedir. Sinyalin gürültüye maruz kalması sonucu ortaya

çıkacak olumsuz etkileri ortadan kaldırmak için kural tabanlı bir yöntem kullanılmıştır.

Öncelikle sinyal belli bir eşik seviyesi belirlenerek kırılmış, bu sayede sinyalin anlamlı kısımları korunmuştur. Daha sonra sinyal örnek bazında incelenerek belli bir eşik seviyesini belli bir aralık boyunca geçen diziler aranır ve bu sayede tepe veya dip noktaları bulunur. Bu dönüm noktalarının bulunmasından sonra dalga şeklinin genişliğine ilişkin öznelilikler sıfır geçiş noktalarından faydalanarak bulunur.

#### 4. Çok Ölçekli Yakınsama ile Saçılım Sinyallerinin Temsili

Özneliliklerin çıkarılması için belirlenen algoritmik kurallar, sinyalin üzerine gelecek gürültünün etkilerini azaltmak üzere belirlenmiştir. Gürültünün az olduğu durumlarda tanıma başarımının daha yüksek olduğu deneysel olarak görülmüştür. Bu sebeple, gürültülü sinyaller bir yakınsama yöntemiyle yeniden oluşturulmuştur. Geliştirilen algoritma 3 ana adımdan oluşmaktadır.

- 1) Sinyal eşit uzunluklu parçalara ayrılır.
- 2) Her parçanın merkezine simetrik Gauss eğrileri yerleştirilir. Gauss eğrilerinin standart sapması üzerinde çalışılan parça uzunluğunun 0.125 katı olarak belirlenmiştir. Eğrinin mutlak maksimum değeri orjinal sinyalin mutlak maksimum değerinin 0.01 katı olarak alınmıştır.
- 3) Her parçanın sınırları içerisinde, hatayı minimum kılacak şekilde Gauss eğrileri eklenir.

Dikkat edilmesi gereken önemli bir nokta, parçaların uzunluklarının ardışıl olarak değiştiriliyor olmasıdır. Yukarıda bahsedilen yöntemde parça uzunluğu 256'dan 32'ye kadar 31 adımda azalarak gitmektedir. Seçilen uzunluklar 2'nin 0.1 aralıklı kuvvetleri olarak belirlenmiştir. Bu sayede parçalar ardışıl olarak birbirlerinin üzerine gelerek yeniden oluşturulmuş dalga şeklinin daha düzgün olmasını sağlar.

#### 5. Sınıflama

Yapılan benzetimlerde 4 farklı yarıçapa sahip küreler ( $r=1.8, 2.4, 3.0, 3.6$  cm) temel alınmıştır. Her küre için 18 farklı açı değeri kullanılarak toplamda 72 tane örnek elde edilmiş ve eğitim yapılmıştır. Çalışmada yapay sinir ağı olarak çok katmanlı ileri beslemeli ve

geri yayımlı yapay sinir ağı (MLP) [6] doğrusal olmayan eğri yakınsama görevinde etkin bir yöntem olan Levenberg-Marquardt [7] yordamı ile birlikte kullanılmıştır. Veri kümesinin küçük olmasından dolayı, K-kat çapraz doğrulama kullanılmıştır [8]. Çalışmada farklı sayıda katlarda çapraz onaylama ile benzetimler yapılmıştır ancak bu bildiriye 9 kat için elde edilen sonuçlar verilmiştir. 30 deneyin ortalaması alınarak elde edilen elde edilen Doğru Sınıflama Oranı değerleri Tablo 1 ve Tablo 2'de sunulmuştur.

Tablo 1'de gürültüden arındırarak daha verimli öznelilik çıkarılması için önerilen çok ölçekli yakınsama yönteminin kullanılması ile elde edilen sonuçlar verilmiştir. Tablo 2'de ise saçılım sinyalinden önerilen özneliliklerin doğrudan çıkarılması ile elde edilen benzetimler için doğruluk değerleri verilmiştir.

Tablo 1. Yakınsama yapılmış sinyal için sınıflandırma doğruluk tablosu

Doğruluk (%)	Küre 1	Küre 2	Küre 3	Küre 4
SNR=1000	96.25	94.81	92.13	93.1
SNR=-5	92.73	86.66	73.65	76.48

Tablo 2. Yakınsama yapılmamış sinyal için sınıflandırma doğruluk tablosu

Doğruluk (%)	Küre 1	Küre 2	Küre 3	Küre 4
SNR=1000	95.83	92.54	87.52	88.56
SNR=-5	78.98	70.37	65.04	69.86

#### 6. Sonuç

Çalışma sonucunda elde edilen veriler yakınsama işleminin düşük SNR koşullarında gözle görülür bir iyileşme sağladığını göstermektedir. Bununla beraber, geliş açısına olan bağımlılık ortadan kalkmıştır. Benzetim sonuçları dielektrik kürelerin önerilen öznelilik kümesi ile çok yüksek başarımla sınıflanabildiğini göstermektedir.

- [1] Zhou D., Liu G., Wang J., "Spatio-temporal target identification method of high-range resolution radar", Pattern Recognition, vol. 33, s. 1-7, 2000.
- [2] Chen S., Radar Target Identification with Relative Amplitudes and Unknown Target

- Aspect Angles, IEEE, 1990, IEEE Aerospace and Electronics Conference, Vol.1, 1990
- [3] M. Seçmen, ve G. Turhan Sayan, "Radar Target Classification Method With Reduced Aspect Dependency And Improved Noise Performance Using MUSIC Algorithm", IET Radar Sonar and Navigation Vol. 3 No. 6, 2009, s. 583-595
- [4] P. B. Silverstein , O. S. Sands and F. D. Garber "Radar target classification and interpretation by means of structural descriptions of backscatter signals", Proceedings of IEEE Radar Conference, pp.21 -25 1991
- [5] G. Turhan Sayan, "Real Time Electromagnetic Target Classification Using A Novel Feature Extraction Technique With PCA-Based Fusion", IEEE Transactions On Antennas And Propagation Vol. 53 No. 2, s. 766-776
- [6] S. Haykin, Neural Networks: A Comprehensive Foundation, Prentice Hall, 2nd edition, 1998.
- [7] Reed, R., Marks, R. J.: Neural Smthing: Supervised Learning in Feed forward Artificial Neural Networks, MIT Press, 1999.
- [8] K. Fukunaga, "Statistical pattern recognition," in Hand. of Pat. Recog. Image Pro., T.Y. Young, Eds., NY, 1986, 3-32.

## Kolektif Öğrenme Algoritmalarıyla Çocuklarda Obezite Hastalığına Yakalanma Olasılıklarının Hesaplanması

Beyza Nur KÖKCÜ<sup>1</sup> Rukiye Dilruba KÖSE<sup>2</sup> Faruk BULUT<sup>3</sup>  
M. Fatih AMASYALI<sup>4</sup>

<sup>1,2</sup> Özel Büyükçekmece Fatih Fen Lisesi, Beylikdüzü, İSTANBUL  
<sup>3,4</sup> Bilgisayar Mühendisliği Bölümü, Elektrik-Elektronik Fakültesi  
Yıldız Teknik Üniversitesi, Davutpaşa, İSTANBUL

Email: beyzanurkokcu@gmail.com dilrubakose@gmail.com f0110303@std.yildiz.edu.tr  
mfatih@ce.yildiz.edu.tr

### Özet

İleri yaşlarda meydana gelen obezite hastalığının temelini çocukluk yıllarındaki beslenme ve yaşam alışkanlıklarıyla ilgili olduğu bilimsel çalışmalarla tespit edilmiştir. Çalışmamız çocuklarda obeziteye yakalanma riskini hesaplayan bir erken uyarı sistemi üzerinedir. Makine öğrenmesi kolektif öğrenme algoritmaları (Ensemble Methods) kullanılarak yapay ve özgün bir klinik karar destek sistemi geliştirilmiştir. Bu amaçla çalışmamızda kullanılmak üzere hazırlanan bir anket ile devlet hastanelerinden ve okullarından veriler toplanarak bir eğitim seti oluşturulmuştur. Eğitim seti üzerinde kolektif öğrenme algoritmalarıyla yapılan öğrenme ve çapraz geçirme işlemlerinde başarılı sonuçlar elde edilmiştir.

### 1. Giriş

Dünyadaki yaygın hastalıklardan biri olan obezite, besinlerle alınan enerjinin harcanan enerjiden fazla olması ve fazla enerjinin vücutta yağ olarak depolanması sonucu ortaya çıkan bir hastalıktır. Dünya Sağlık Örgütü tarafından obezite, sağlığı bozacak ölçüde vücutta aşırı yağ birikintisi olarak tanımlanmıştır [1]. Klinik olarak obeziteyi tanımlamak için vücut kitle indeksi (VKİ) ölçütü olarak kullanılır ve (1) numaralı formül ile hesaplanır. VKİ sonucuna göre bireyin obez olup olmadığı Tablo 1'deki verilere göre sınıflandırılır.

$$VKI = \frac{Ağırlık}{boy^2} \quad (1)$$

Tablo 1. VKİ sınıflandırması

Vücut Kitle İndeksi (VKİ)	Sonuç
18.5 kg / m <sup>2</sup> 'den düşük	Zayıf
18,5-24,9 kg / m <sup>2</sup> arasında	Normal kilolu
25-29.9 kg / m <sup>2</sup> arasında	Fazla kilolu
30-39.9 kg / m <sup>2</sup> arasında	Obez(şişman)
40 kg / m <sup>2</sup> 'den büyük	İleri derecede obez

Çocukluk çağında başlayan obezitenin erişkin dönemde de devam etmesi ve sağlık için risk oluşturması söz konusudur. Çocuklukta obezite, 5-6 yaş arası ve gelişim döneminde artış göstermektedir. Obez çocukların yaklaşık %35'i, obez adolesanların ise %80'i erişkin yaşa ulaştıklarında da obez kalmaktadırlar. Diğer yandan erişkin yaşlarda görülen obezite vakalarının %30 kadarında başlangıcın çocukluk çağlarına dayandığı bilinmektedir [2]. Bu nedenle çocukluk ve ergenlik döneminde obeziteden korunma ve tedavi giderek önem kazanmaktadır. Gerekli tedbirler erken yaşta alınmadığında hastalığın ileri yaşlarda tedavi edilmesi ise daha da zorlaşmaktadır[3].

Bu nedenle çocuklarda obezite riskinin erken tespit ve tedavi edilmesi daha da önemli hale gelmektedir. Çalışmamız erken teşhis koyan bir klinik karar destek sistemi üzerinedir. Erken tespit ile alınacak önlemler ve yapılan tedaviler sonucunda çocuğun bir ömür boyu sağlıklı bir hayat geçirmesi amaçlanmıştır. Çalışmamızda ikinci bölümde oluşturulan modele, üçüncü bölümde kullanılan metotlara, dördüncü bölümde deneysel sonuçlara ve beşinci bölümde değerlendirilmelere yer verilmiştir.

## 2. Model Oluşturma ve Veri Toplama

Çalışmanın işleyişi temel olarak dört ana aşamadan oluşmaktadır. Bunlar gerekli verilerin elde edilebilmesi için anket sorularının hazırlanması, okul ve hastanelerden verilerin anket yardımıyla toplanması, algoritmaların uygulanması ve sonuçların elde edilip yorumlanması şeklindedir.

### 2.1. Anket Oluşturma ve Veri Seti Hazırlama

Çalışmada kullanılmak üzere özgün bir eğitim seti oluşturulması amaçlandı. Bu amaçla obezite riskini tespit etmek için hazırlanan anket soruları 6 ana bölüme ayrılmıştır:

1. Bireyin temel özellikleri ve VKİ değeri,
2. Psikolojik durumu,
3. Aile bilgileri,
4. Haftalık aktivite sıklığı,
5. Günlük öğün sıklığı,
6. Bazı besin gruplarını tüketim sıklığı.

#### 2.1.1. Temel özellikler

Bu bölümde bireyin cinsiyeti, yaşı, kilosu ve boyu sorularak VKİ değeri hesaplanmıştır.

#### 2.1.2. Psikolojik özellikler

Psikolojik sorunların yemek yeme alışkanlığını tetiklediği bilimsel çalışmalarda yer almaktadır [4-5]. Bundan dolayı bu bölümde 3 adet soru sorularak bireyin psikolojik durumu değerlendirildi. Psikolojik bir rahatsızlığın olup olmadığı, çok üzücü bir olay yaşanıp yaşanmadığı ve ailevi sorunların olup olmadığı soruldu.

#### 2.1.3. Ailevi özellikleri

Bu bölümdeki sorular, çocukların genetik olarak obeziteye yatkın olup olmadığını incelemek amacıyla bilimsel çalışmalardan yararlanarak [4-5-6] hazırlanmıştır.

1. Ailede (şeker hastalığı) var mı?
2. Ailede obez olan var mı?
3. Ailede sigara içen var mı?
4. Anne boy ve kilo değerleri nedir?
5. Baba boy ve kilo değerleri nedir?
6. Aylık gelir durumunuz nedir?

#### 2.1.4. Aktivite sıklığı

Hareketsiz yaşam ve elektronik cihaz karşısında geçirilen fazla süre obezite riskini arttırmaktadır [2]. Bireyin aktivite sıklığını incelemek amacıyla sportif ve bedensel aktivitelere ayrılan süre ile bilgisayar ve televizyon karşısında geçirilen süre sorulmuştur.

#### 2.1.5. Öğün alışkanlıkları

Öğünlerin sıklık durumu, ara öğünlerde abur cubur yeme alışkanlığı, ayaküstü tarzı yiyeceklerin tüketim sıklığı obeziteye neden olduğu literatürde ispatlanmıştır [3,5] ve Tablo-2'deki sorular sorulmuştur.

Tablo 2. Öğün alışkanlıklarıyla ilgili sorular

	Sıklıkla Her Gün	Arada bir Normal	Hiç Çok az
1) Kahvaltı			
2) Öğle yemeği			
3) Ara öğün			
4) Akşam yemeği			
5) Gece yatarken			

#### 2.1.6. Besin tüketim sıklığı

Bireyin Tablo-3'te bulunan besinleri tüketme sıklığı çocuklarda obezite oluşum riskini etkilediği yapılan çalışmalarla ortaya konmuştur [5-6].

Tablo 3. Besin tüketim sıklığı ile ilgili sorular

	Sıklıkla Her Gün	Arada bir Normal	Hiç Çok az
1) Süt ve süt ürünleri			
2) Et ve et ürünleri			
3) Tahıl ürünleri			
4) Reçel, bal Tereyağı			
5) Fast-food Hamur işi Cips patates Gazlı içecek Meyve suyu Şeker çikolata			
6) Meyve-Sebze			

## 2.2. Veri Toplama ve Eğitim Seti Oluşturma

Alınan resmi izin belgeleriyle İstanbul Üniversitesi Çapa Eğitim ve Araştırma Hastanesi, Şişli Etfal

Eğitim ve Araştırma Hastanesi bünyesindeki Çocuk Sağlığı ve Anabilim dalında Büyüme-Gelişme ve Pediatrik Endokrinoloji bölümlerinde anketler yapıldı. 7-15 yaş aralığındaki 60 kadar çocuk obez hastalardan toplanılan veriler eğitim setine eklendi. Ayrıca Büyükçekmece İlçe Milli Eğitim Müdürlüğünden alınan diğer bir resmi izinle Adem Çelik İlk Okulu ve Orta Okulunda, 7-15 yaş aralığındaki obez olmayan 40 öğrenciye anketler uygulanarak eğitim seti güçlendirildi.

Böylece 100 veriden oluşan özgün bir eğitim seti kullanılan algoritmalar için hazır hale getirildi. Bölüm 2.1.'de 6 kategoriye ayrılan anket soruları oluşturulan eğitim setinde kullanılabilmesi için sayısal değerlere dönüştürüldü. Sorulara etki derecelerine göre puan verildi. Her bir kategori eğitim seti için bir özellik (*attribute*) olarak düşünüldü. Tüm veriler daha sonra normalize edildi.

### 3.Yöntemler

Sınıflandırma yöntemlerinden biri olan kolektif öğrenme (*Ensemble Learning*) metotları tekil öğrencilerin öğrenme başarısını artırmak için kullanılmaktadır. Çalışmamızda temel öğrenci (*base learner*) olarak örnek tabanlı öğrenciler tercih edilmiştir. C programlama dilinde yazılabilmesi ve özelleştirilebilmesinden dolayı tekil öğrenci olarak en yakın komşuluk algoritması (kNN) seçilmiştir.

#### 3.1. Tekil Öğrenciler

kNNsınıflandırıcısının2 farklı türü temel öğrenci olarak kullanıldı:

1. Normal kNN
2.  $1/d^2$ uzaklık ağırlıklık NN

Örnekler arası uzaklığı hesaplamak için Öklid yöntemi kullanıldı. Öklid uzaklık ölçüsü kullanılarak  $N$  boyutlu uzayda  $a$  ve  $b$  noktaları arasındaki uzaklık (2) numaralı formül ile hesaplanır:

$$d(a, b) = \sqrt{\sum_{i=1}^N (x_{ai} - x_{bi})^2} \quad (2)$$

Bilindiği üzere kNN yöntemi, en yakın  $k$  adet komşunun sınıf etiketlerinin ortalaması ile bulunur.  $1/d^2$  uzaklık ağırlıklı kNN yöntemi, örneklerin test örneğine olan uzaklıklarına bağlı olarak hesaplamadaki ağırlıklarını dikkate alarak sınıflandırma yapar. Bu teknikte yakındaki kayıtların

hesaplamadaki ağırlığı fazla; uzaktakilerin ağırlığı ise azdır[9-10]. Her bir kaydın hesaplamadaki ağırlığı şu formüller ile bulunur:

$$w_i = \frac{1}{d_i^2} \quad (3)$$

$x$  test örneğinin sınıfı ise (4) numaralı formül ile bulunur:

$$f(x) = \frac{\sum_{i=1}^k w_i f(a_i)}{\sum_{i=1}^k w_i} \quad (4)$$

Formüldeki  $k$ , kNN'deki  $k$ 'yı;  $a_i$  ise hesaplamaya katılan  $k$  adet örneğinin etiketini göstermektedir.

### 3.2. Kolektif Öğrenme Metotları

Kolektif öğrenmede kullanılan tekil öğrenciler genellikle bir karar ağacından oluşmaktadır; yerine göre SVM (*Support Vector Machine*) gibi başka bir sınıflandırıcı da olabilir. Tekil öğrencilerin bir araya gelerek öğrenci topluluğu (*ensemble*) oluşturmalarına kolektif öğrenme denir. Birçok uygulamada kolektif öğrenme başarısı tekil öğrenmeye göre yüksektir [7-8]. Örnek tabanlı tekil öğrencilere uygun olduğundan dolayı aşağıdaki kolektif öğrenme metotları kullanılmıştır:

1. Yerine koyarak örnekleme (*Bagging*)
2. Oylama (*Voting*)
3. Rastsal alt uzaylar (*Random Subspaces*)

#### 3.2.1. Yerine koyarak örnekleme (*Bagging*)

*Bagging* metodu (*Boot strapping AGGregating*), var olan bir eğitim setinden yeni eğitim setleri türeterek temel öğrenciyi yeniden eğitmeyi amaçlayan bir yöntemdir. Şekil-1'de yöntemin çalışma stili görülmektedir.


Eğitim setinden yaklaşık olarak %63,2 kadar orijinal örnek alınır ve alınan örneklerden bazıları çoğaltılarak eğitim setleri %100'e tamamlanır. Her defasında bu işlem yapılarak farklı eğitim setleri elde edilir. Her eğitim seti temel öğrenciye uygulanır ve alınan kararlar demokrasi usulüyle birleştirilir.

#### 3.2.1. Oylama (*Voting*)

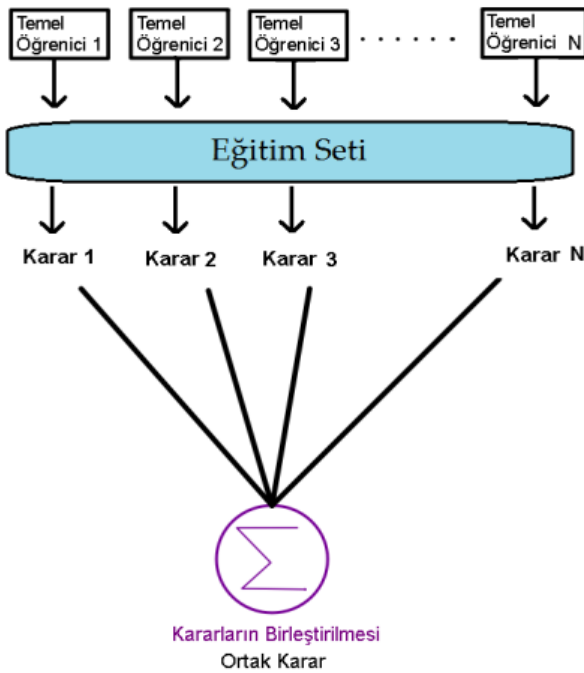
Oylama tekniğiyle sınıflandırmada en çok oy olan etiketin sonucu baz alınır. Basit oylamada tüm sınıflandırıcıların ağırlığı birbirine eşittir. Her bir



sınıflandırıcının tüm sınıf etiketleri hakkında verdikleri kararlar birleştirilir ve ortalamaları alınır. En yüksek oranın çıktığı sınıf etiketi test örneğine atanır. Çalışmamızda ikili sınıflandırma yani {0,1} sınıfları vardır. Şekil-2'de algoritmanın çalışma stili görülmektedir.




Şekil 1. Bagging yöntemi.



Şekil 2. Oylama (voting) yöntemi.

### 3.2.1. Rastsal altuzaylar (Random subspaces)

Bu yöntem, öğrenci topluluğundaki her bir öğrenciyi aynı eğitim seti ile eğitmek yerine aynı eğitim setinin bazı özelliklerini hariç tutup yeni eğitim setleri türeterek öğrencileri eğitmeyi amaçlamaktadır. Her bir öğrenci rastgele seçilen özellikler grubu ile oluşturulmuş yeni eğitim setleri ile eğitilir. Öğrencilerin farklı kararları birleştirilerek komite kararı oluşturulur [9]. Şekil-3'de bu tekniğin çalışma stili görülmektedir.



Şekil 3. Rastsal alt uzaylar yöntemi.


## 4. Deneysel Sonuçlar

Deneysel sonuçlar üç ana başlık altında incelenmiştir. Bunlar öğrencilerin doğruluk oranları, özelliklerin sınıflandırmadaki bilgi kazançları ve özelliklere ait korelasyon matrisi şeklindedir.

### 4.1. Doğruluk Oranları

Çalışmamızda, kNN ve uzaklık ağırlıklı kNN yöntemleri için değişik  $k$  parametreleriyle 21 adet birbirinden farklı temel öğrenici oluşturuldu. Temel öğrenciler eğitim seti üzerine uygulandı. Temel öğrencilerin eğitim seti üzerindeki doğruluk oranları

%70 ile %76 arasında değişmektedir. 21 farklı sınıflandırıcının doğruluk oranlarındaki farklılık 1 ile 15 arasında alınan değişik  $k$  parametreleriyle sağlanmaya çalışılmıştır. Fakat kolektif öğrenmenin başarılı olabilmesi için öğrencilerin kararları arasında farklılık (*diversity*) olmalıdır. kNN sınıflandırıcısının farklı  $k$  parametrelili türleri farklılığı sağlayamamıştır. Bu nedenle 21 temel öğrencinin doğruluk oranları birbirine çok yakındır.



Şekil 4. DeneySEL sonuçlar

Şekil-4’de görüldüğü üzere oylama ve yerine Oylama ve yerine koyarak örnekleme (*bagging*) yöntemlerinde de sırasıyla %80 ve %88 başarı elde edilmiştir. Bu durum doğruluk açısından bir miktar gelişme sağlandığını göstermektedir. Güncel hayatta da alınan ortak kararın çoğu zaman doğru sonuçlar verdiği ve güvenilir olduğu bilinmektedir.

Tekil öğrenci olarak seçilen örnek tabanlı öğrencilerin kolektif öğrenmede kullanılmasının başarıyı istenilen düzeyde artırmadığı görülmüştür. Rastasal alt uzayların %93 gibi çok yüksek bir oranda başarı elde etmesinin nedeni türetilen yeni eğitim setlerinde farklılığın (*diversity*) kendiliğinden oluşması olarak görülmüştür. 6 boyutlu eğitim setinden 4 boyutlu olarak seçilen 10 farklı eğitim seti kombinasyonu çoğul öğrenme başarısını artırmıştır. Eğitim setindeki VKİ ve beslenme alışkanlıklarının bulunduğu özellikler rastasal alt uzaylar uygulamasında silinmediğini önemle vurgulamak isteriz. Bu özellikler obezite riskinin belirlenmesinde büyük bir öneme sahiptir. Bu özelliklerin değişik kombinasyonlarda bulunmaması durumunda obeziteyi tespit etmek zorlaşır ve bu da doğruluk oranının düşük çıkmasına sebep olur.

## 4.2. Bilgi Kazancı

Weka yazılımı kullanılarak oluşturduğumuz eğitim setinin elde edilen bilgi kazançları (*information gain*) Tablo-4’de olduğu gibidir.

Elde edilen bu değerlere göre obezitenin birinci nedeni VKİ çıkmıştır. VKİ, obeziteyi tanımlayan bir faktör olduğu için bir neden olarak görülmemeli, VKİ-Obezite arasında yüksek bir korelasyon gibi değerlendirilmelidir. 2. sırada yer alan bazı besin gruplarının tüketim sıklığı obeziteyi tetikleyen en önemli faktör olarak düşünülmelidir. Çok az bir farkla 3. sırada yer alan bireyin içinde bulunduğu psikolojik durum da diğer bir etmendir.

Tablo 4. Özelliklerin bilgi kazançları

Sıra	Özellik	IG
1	VKİ	0.2894
2	Bazı besin gruplarını tüketim sıklığı	0.1947
3	Psikolojik durumu	0.1828
4	Günlük öğün sıklığı	0.1548
5	Aktivite	0.1236
6	Aile bilgileri	0.0704

## 4.3. Korelasyon Matrisi

Tablo-5’te eğitim setinde bulunan özelliklerin matris korelasyonları hesaplanmıştır. Özelliklerin kısaltmaları şu şekildedir:

- Öz-1. Bireyin temel özellikleri ve VKİ değeri,
- Öz-2. Psikolojik durumu,
- Öz-3. Aile bilgileri,
- Öz-4. Haftalık aktivite sıklığı,
- Öz-5. Günlük öğün sıklığı,
- Öz-6. Bazı besin gruplarını tüketim sıklığı.

Tablo 5. Özelliklerin matris korelasyonu

	Öz-1	Öz-2	Öz-3	Öz-4	Öz-5	Öz-6
Öz-1	1	0.17	0.10	0.06	0.05	0.46
Öz-2		1	0.65	0.25	0.20	0.22
Öz-3			1	0.17	0.07	0.42
Öz-4				1	0.16	0.47
Öz-5					1	<b>0.78</b>
Öz-6						1

Bilindiği üzere -1 değerlikli korelasyon, iki değişken arasında tam ters ilişkiyi; 0, ilişkisizliği; +1 ise tam lineer düz ilişkiyi göstermektedir. Genel olarak 0.80 ve üzeri değerler anlamlı bir korelasyonun göstergesidir. Öz-5 (*günlük öğün sıklığı*) ile Öz-6 (*bazı besin gruplarını tüketim sıklığı*) arasındaki 0.78'lik değer arada güçlü bir korelasyon olduğunu göstermektedir. Yani ankete katılan öğrencilerin gün içindeki öğün sayıları ile bazı besin gruplarını tüketme sıklıkları arasında doğru orantı oluşmuştur.

Tablodaki diğer verilerin düşük olması ankette sorulan soruların birbirlerinden bağımsız olduğunu göstermektedir.

## 5. Değerlendirme ve ileri uygulamalar

Çalışmamızda sınıflandırma başarısını artırmak için kullanılan kolektif öğrenme yöntemleri farklı bir alana uygulandı. Orijinal, güvenilir ve gerçek bir eğitim seti kullanılarak kolektif öğrenciler ile çağın büyük bir sorununa karşı *linik karar destek sistemi* geliştirildi. Oluşturulan bu erken uyarı sistemi sayesinde gelişmekte olan bir çocuğun obezite riski çocuktan alınan bilgilerle tahmin edilmeye çalışılabilir. Çıkan sonuçlara göre yüksek risk yüzdesine sahip kişiler haberdar edilip ilgili kurumlara yönlendirilebilir.

## 6. Teşekkürler

Anket çalışması yapabilmemiz için bize resmi izin veren, destekleyen, hoş gören İstanbul İl Millî Eğitim Müdürü Dr. Muammer YILDIZ'a, İstanbul İl Sağlık Müdürlüğüne, Şişli Etfal Eğt. Ve Arşt. Hastanesi ile Çapa Eğt. Ve Arşt. Hastanesi yönetimine ve çalışanlarına, B.Çekmece Adem Çelik İlkokulu yönetici ve öğretmenlerine, İstanbul Çapa Eğt. Ve Arşt. Hastanesi Büyüme-gelişme ve Pediyatrik Endokrinoloji bilim dalı Öğretim Üyesi Prof.Dr. Nurçin SAKA'ya, Şişli Etfal Eğt. Ve Arşt. Çocuk Endokrinoloji Doktoru Uz. Dr. Mehmet BOYRAZ'a teşekkürlerimizi bir borç bilir saygı ve sevgilerimizi sunarız.

## 7. Kaynaklar

- [1] Erken Yaşta Görülen Obezite: Nedenleri ve Tedbirle, Doç. Dr. A. ONAY Beşikçi, Mised Dergisi; Sayı:23-24, s. 82-85, 2010.
- [2] A. Parlak, Ş. Çetinkaya, Çocuklarda Obezitenin Oluşumunu Etkileyen Faktörler, Fırat Sağlık

Hizmetleri Dergisi; Cilt:2, Sayı:5, s. 24-35, (2007).

- [3] F. Şimşek, B.Ulukol, M. Berberoğlu, S.B. Gülnar, Ankara'da bir ilköğretim okulu ve lisede obezite sıklığı, Ankara Üniversitesi Tıp Fakültesi Mecmuası; s. 163-166, 2005.
- [4] Çocukluk Çağında Obezite, Dr. K. Babaoğlu, Dr. Ş. Hatun, Kocaeli, Sted Dergisi; Cilt 11, 2002.
- [5] İlköğretim Çağındaki Çocuklarda Obezite Prevalansının Belirlenmesi ve Risk Faktörlerinin Araştırılması, S. Öztora, S. Hatipoğlu, M.B. Barutçugil, B. Salihoğlu, R. Yıldırım, E.Şevketoğlu, Bakırköy Tıp Dergisi; Cilt 2, 2006.
- [6] Çocukluk Döneminde Obezite, Prof. Dr. P.Cinaz, Sağlık&İnsan Dergisi; s. 32-34, 2012.
- [7] Ethem Alpaydın, Yapay Öğrenme kitabı, Boğaziçi Üniversitesi Yayınevi, İstanbul, 2010
- [8] M. Fatih Amasyalı, "Yeni Makine Öğrenmesi Metotları ve İlaç Tasarımına Uygulanması", Doktora Tezi, Yıldız Teknik Üni., İstanbul, 2008.
- [9] Tin Kam Ho, The Random Subspace Method for Constructing Decision, Pattern Analysis and Machine Intelligence, IEEE Transactions, Lucent Tech no 1., Volume: 20 , Issue: 8, pp: 832 - 844 , AT&T Bell Labs., Murray Hill, NJ , 1998

# BULANIK ANALİTİK HİYERARŞİ PROSESİ YÖNTEMİ KULLANILARAK YEŞİL TEDARİKÇİ FİRMA SEÇİMİ: ENERJİ SEKTÖRÜNDE BİR UYGULAMA

ZeynepKARALI<sup>1</sup>

A. YeşimYAYLA<sup>2</sup>

<sup>1,2</sup>Makine Mühendisliği Bölümü  
Teknoloji Fakültesi  
Marmara Üniversitesi, Kadıköy, İSTANBUL

Email: zynp.karalii@gmail.com

yayla@marmara.edu.tr

## Özet

Günümüzde işletmeler çevreye duyarlı yeşil üretim sistemleri tasarlamak, atıklarını azaltmak, çevresel riskleri yönetmek ve sosyal sorumluluk bilinciyle hareket etmek amacıyla tedarik zincirlerini çevreye daha duyarlı bir yapıya dönüştürmekte ve yeşil tedarik zinciri yönetimini benimsemektedirler. Bu çalışmada, enerji sektöründe faaliyet gösteren ve yeşil tedarik zinciri yönetimi uygulamaları olan bir firma için en iyi yeşil tedarikçi firma seçimi problemi ele alınmıştır. Bu amaçla öncelikle hiyerarşik karar modeli oluşturulmuş ve modelde yer alan kriterler dikkate alınarak bulanık Analitik Hiyerarşi Prosesi yönteminin kullanımıyla en yüksek önem ağırlığına sahip tedarikçi firma işletmenin en iyi yeşil tedarikçisi olarak seçilmiştir.

## 1. Giriş

İsraf ve atıkların azaltılması, ürün ve ham maddelerin, doğal kaynakların korunması ve bu kaynakların sürdürülebilir kılınması gibi amaçlar içeren yeşil tedarik zinciri yönetimi (YTZY), 1990'lı yıllardan itibaren akademik çevrelerin ve üreticilerin ilgisini çekmiştir.[1]

Yeşil tedarik zinciri, sistemin tüm aşamalarında çevreye duyarlı bir yaklaşımı esas kılmaktadır. Sistem; tedarik işleminin doğal kaynaklara zarar vermeden ya da en az zararla gerçekleştirilmesi, üretim sırasında ortaya çıkan atıkların çevreye zarar vermeden yok edilmesi, kalite ve çevre standartlarına uygun olarak üretimi gerçekleştirmek amacıyla çeşitli belgelerin alınması, çevreye duyarlı ürünlerin üretilmesi, lojistik faaliyetlerde en iyi ağ tasarımının yapılması ve kullanılan araç ve yakıtlara dikkat

edilmesiyle tüm süreç içerisinde ortaya çıkacak olan atıkların sistemli bir şekilde yönetilmesini içermektedir [2].

Bu çalışmada, Türkiye için yeni bir yaklaşım olarak kabul edilen YTZY'yi benimseyen, enerji sektöründe faaliyet gösteren bir firmanın yeşil tedarikçi seçimi problemi ele alınmış ve problemin çözümü Bulanık Analitik Hiyerarşi Prosesi (BAHP) yöntemi ile gerçekleştirilerek tedarikçi seçimi yapılmıştır.

## 2. Yeşil tedarik zinciri yönetimi

Çevre konusundaki yeni dönem, dünya çapında, imalat işletmeleri için yeni bir zorluğu ortaya çıkarmıştır. Bu zorlama, endüstriyel gelişim ile çevre korumacılığının birlikte var olmasının yollarını geliştirmektedir. Bu zorunluluğu karşılamanın ilk adımı, tüm tedarik zincirinin ana yapısının yeniden tanımlanarak, tedarik zinciri işlemlerinin, ürünün kullanımı sonrası ve paketlemesini içerecek şekilde dizayn edilmesi, toplanması ve tekrar kullanılması ile mevcut tek yönlü tedarik zinciri yapısının, kendi içerisinde kapalı devre haline getirilmesidir [3].

Çevresel sürekliliğin sağlanması hususundaki baskıların artması firmaların, ürün ve servislerinin çevresel etkilerini azaltacak stratejik uygulamalara olan ihtiyacını artırmıştır. Bu nedenle firmaların ekolojik verimliliğini artırırken, çevresel risk ve etkileri azaltarak pazar payı hedeflerini arttırıp kar elde etmeleri için YTZY'yi benimsemeleri gerekir [4].

YTZY felsefesinin temelinde, tedarik zinciri boyunca atık maddeleri (enerji, emisyon, kimyasal/ tehlikeli katı atıklar v.b.) ortadan kaldırmak veya minimize etmek vardır. Yeşil bileşenini ekleyerek bu tanımın

ötesinde, yeşil tedarik + yeşil üretim + yeşil dağıtım + tersine lojistik kavramlarının tanımlanmasıyla yeşil tedarik zinciri yönetimi kavramı açıklanır [5].

### 3. Yeşil tedarikçi seçimi

Yeşil satın alma; işleme tabi tutulacak olan hammaddelerin veya yarı mamullerin seçiminde çevreye duyarlı, geri dönüştürülmüş, işlevi sona erdikten sonra toprakta kolayca çözülebilen veya tekrar işlenebilen özellikler gibi çevresel niteliklerin, satın alma işleminde göz önünde bulundurulması ve tedarikçi seçimini etkilemesidir. Satın alma işlemi yeşil tedarik zincirinin en önemli parçasıdır çünkü üretilecek ürünlerin niteliğini büyük ölçüde hammadde ve tedarik edilen ürünler belirler [6].

Tedarik zincirini oluşturmadaki ya da onun etkinliğini artırmadaki en önemli konu, tedarikçiler arasından uzun dönemli ilişkiler kurmaya uygun daha işbirlikçi olanlarını seçmektir. Geleneksel tedarikçi seçimi yaklaşımı sadece fiyat temeline dayanmaktaydı. İşletmeler günümüzde tedarikçi seçimi için sadece fiyat kriterinin kullanımının yeterli olamayacağını fark etmişler ve dikkatlerini daha kapsamlı olan çok kriterli karar verme tekniklerine yöneltmişlerdir. Çok kriterli karar verme tekniklerinde geleneksel; kalite, dağıtım, maliyet ve hizmet kriterleri çevresel, sosyal, politik ve müşteri memnuniyetine dayalı kriterlerle bütünleştirilmiştir. İşletmeler doğru tedarikçilerle çalışarak maliyetlerini azaltmalarının yanı sıra ürün geliştirme zamanlarının azalması, ürün kalitesinin iyileştirilmesi ve tedarik sürelerinin kısalmasıyla birlikte rekabet avantajı da elde etmişlerdir [7].

Bir işletme, tedarik merkezi sayısını azaltarak, daha az sayıda tedarikçi ile harcamalarında düzenlemeye, böylece de daha düşük toplam maliyete ulaşabilir. Daha az tedarikçi, aynı zamanda, kilit tedarikçiler ile daha iyi ilişkilerin geliştirilebilmesi anlamına da gelmektedir [8].

### 4. Bulanık Analitik Hiyerarşi Prosesi yöntemi kullanılarak bir ısı kontrol firmasında yeşil tedarikçi firma seçimi

#### 4.1. Uygulama yapılacak firmanın tanıtılması

ABC A.Ş., bir ısı kontrol firması olup, yanma ve ısıtma teknolojilerinde lider marka konumuyla gaz, sıvı yakıt ve çift yakıt brülör imalatında, ürün yelpazesinin de 12 kW' den 20.000 kW' ye kadar mevcut ihtiyaçlara uygun ürünler yer almaktadır. Her türlü kazan dairesi

ve/veya proses uygulamaları için, yakıt tercihi, tercih edilen yakıt türüne göre armatürlerin seçimi, ebatlandırılması, akım şemaları hazırlanması, fizibilite çalışmaları, proses ve müşterinin beklentilerine uygun otomasyon sistemi çalışmaları ABC A.Ş.'nin rutin olarak verdiği mühendislik desteği kapsamındadır.

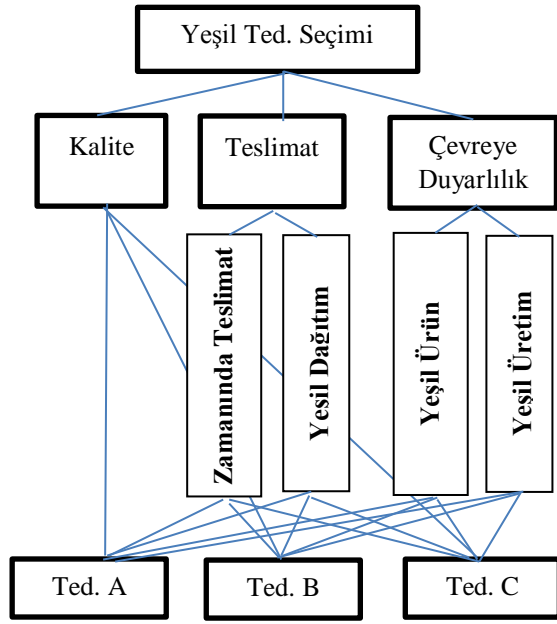
#### 4.2. Yeşil tedarikçi firma seçimi probleminin tanımlanması

Bu çalışmada, Yeşil Tedarik Zinciri Yönetimi (YTZY) uygulayan ABC AŞ'nin brülör üretiminde kullandığı yarı mamulleri satın aldığı tedarikçileri arasından yeşil tedarikçi firma seçimi problemi ele alınmış ve çözümde BAHP yöntemi kullanılmıştır.

AHP yaygın kullanım alanına sahip, çok kriterli karar verme yöntemlerinden birisidir. Yöntemin anlaşılması kolaydır, kullanışsız bir matematik içermez fakat hala insani düşünme stilini yansıtamamaktadır. Bu nedenle, hiyerarşik bulanık problemleri çözmek için BAHP geliştirilmiştir. Karar vericiler genellikle, aralıklı karar vermeyi sabit değerli karar vermeye göre daha rahat bulmaktadır. Çünkü karşılaştırma sürecinin bulanık doğasında tercihleri konusunda kesinlik yoktur [9]. Bu çalışmada, karşılaştırmalarda üçgen bulanık sayılar kullanarak BAHP'nin yönetimi için yeni bir yaklaşım sunan Chang'ın modeli esas alınmıştır. BAHP algoritmasının çözüm adımları ile ilgili detaylı bilgi [9],[10],[11] nolu referanslardan edinilebilir.

#### 4.3. Hiyerarşik karar modelinin oluşturulması

Yeşil tedarikçi firma seçimi probleminin çözümünde temel alınacak hiyerarşik karar modeli Şekil 1. 'de yer almaktadır. Modelin yapılandırılması, ABC A.Ş.'nin satın alma bölümünde çalışan iki mühendisin görüş ve değerlendirmeleri ve konu ile ilgili literatür temel alınarak gerçekleştirilmiştir. Şekil 1 'den de görüldüğü gibi, alternatif tedarikçiler (Ted. A, Ted. B, Ted. C), kalite (K), teslimat (T) ve çevreye duyarlılık (ÇD) ana kriterleri ile zamanında teslimat (ZT), yeşil dağıtım (YD), yeşil ürün (YÜ) ve yeşil üretim (YÜT) alt kriterleri açısından değerlendirilmektedir.



Şekil 1. Hiyerarşik karar modeli

#### 4.4. İkili karşılaştırma matrisleri ve ağırlıkların hesaplanması

En iyi yeşil tedarikçinin seçimi amacına yönelik problemin çözümünde ilk olarak, ana kriterlerin birbiriyle ve alt kriterlerin birbiriyle karşılaştırmaları yapılmıştır. Bu karşılaştırmalarda aşağıdaki bulanık üçgen sayılar kullanılmıştır [12].

(1,1,1) → Eşit önemli

(1,2,4) → Uzlaşma durumunda iki ardışık yargı arasındaki değer

(1,3,5) → Biraz önemli

(3,5,7) → Fazla önemli

(5,7,9) → Çok fazla önemli

(7,9,11) → Aşırı derecede önemli

Aşağıdaki tablolarda yer alan kıyaslamalar, ABC A.Ş.'nin satın alma bölümünde çalışan iki mühendisin ortak görüşleri ile belirlenmiştir.

Tablo 1. Amacımıza göre bulanık değerlendirme matrisi

	K	T	ÇD
K	(1,1,1)	(3,5,7)	(1,1,1)
T	(1/7,1/5,1/3)	(1,1,1)	(1,3,5)
ÇD	(1,1,1)	(1/5,1/3,1)	(1,1,1)

$$S_K = (5,7,9) \otimes (1/18.3, 1/13.5, 1/9.3) = (0.3, 0.5, 1)$$

$$S_T = (0.08, 0.12, 0.25)$$

$S_{ÇD} = (3,5,7) \otimes (1/18.3, 1/13.5, 1/9.3) = (0.2, 0.4, 0.8)$  elde edilir. Bu vektörleri kullanarak,

$$V(S_K \geq S_T) = 1, V(S_K \geq S_{ÇD}) = 1, V(S_T \geq S_K) = 0, V(S_T \geq S_{ÇD}) = 0.15, V(S_{ÇD} \geq S_T) = 1, V(S_{ÇD} \geq S_K) = 0.83 \text{ bulunur. Bu sayede,}$$

Tablo 1'den ağırlık vektörü  $W_A = (0.546, 0, 0.454)^T$  şeklinde hesaplanır.

Tablo 2. Teslimat kriteri açısından alt kriterlerin değerlendirilmesi

	ZT	YD
ZT	(1,1,1)	(1,3,5)
YD	(1/5,1/3,1)	(1,1,1)

Tablo 2'den ağırlık vektörü  $W_T = (0.7, 0.3)^T$  şeklinde hesaplanır.

Tablo 3. Çevreye duyarlılık kriteri açısından alt kriterlerin değerlendirilmesi

	YÜT	YÜ
YÜT	(1,1,1)	(1/7,1/5,1/3)
YÜ	(3,5,7)	(1,1,1)

Tablo 3'den ağırlık vektörü  $W_{ÇD} = (0, 1)^T$  şeklinde hesaplanır.

#### 4.5. Alternatif tedarikçilerin kriterlere göre değerlendirilmesi

Bu değerlendirmelerde aşağıdaki bulanık üçgen sayılar kullanılmıştır [12].

(3,5,5) → Çok iyi

(1,3,5) → İyi

(1,1,1) → Orta

(1/5,1/3,1) → Düşük

(1/5,1/5,1/3) → Çok düşük

Tablo 4. Kalite kriteri açısından alternatif tedarikçilerin değerlendirilmesi

	A	B	C
A	(1,1,1)	(1,3,5)	(3,5,5)
B	(1/5,1/3,1)	(1,1,1)	(1,3,5)
C	(1/5,1/5,1/3)	(1/5,1/3,1)	(1,1,1)

Tablo 4'den ağırlık vektörü  $W_K = (0.578, 0.37, 0.052)^T$  şeklinde hesaplanır.

Tablo 5. Zamanında teslimat alt kriteri açısından alternatif tedarikçilerin değerlendirilmesi

	A	B	C
A	(1,1,1)	(1,3,5)	(1,1,1)
B	(1/5,1/3,1)	(1,1,1)	(1/5,1/3,1)
C	(1,1,1)	(1,3,5)	(1,1,1)

Tablo 5'den ağırlık vektörü  $W_{ZT} = (0.5, 0, 0.5)^T$  şeklinde hesaplanır.

Tablo 6. Yeşil dağıtım alt kriteri açısından alternatif tedarikçilerin değerlendirilmesi

	A	B	C
A	(1,1,1)	(1,3,5)	(3,5,5)
B	(1/5,1/3,1)	(1,1,1)	(1,3,5)
C	(1/5,1/5,1/3)	(1/5,1/3,1)	(1,1,1)

Tablo 6'dan ağırlık vektörü  $W_{YD} = (0.6, 0.4, 0.02)^T$  şeklinde hesaplanır.

Tablo 7. Yeşil ürün alt kriteri açısından alternatif tedarikçilerin değerlendirilmesi

	A	B	C
A	(1,1,1)	(1,1,1)	(1,3,5)
B	(1,1,1)	(1,1,1)	(1,3,5)
C	(1/5,1/3,1)	(1/5,1/3,1)	(1,1,1)

Tablo 7'den ağırlık vektörü  $W_{YÜ} = (0.41, 0.41, 0.18)^T$  şeklinde hesaplanır.

Tablo 8. Yeşil üretim alt kriteri açısından alternatif tedarikçilerin değerlendirilmesi

	A	B	C
A	(1,1,1)	(1,1,1)	(1,3,5)
B	(1,1,1)	(1,1,1)	(1,3,5)
C	(1/5,1/3,1)	(1/5,1/3,1)	(1,1,1)

Tablo 8'den ağırlık vektörü  $W_{YÜT} = (0.41, 0.41, 0.18)^T$  şeklinde hesaplanır.

Tablo 9. Amacın ana kriterleri

	K	T	ÇD	Seçenek önem ağırlığı
Ağırlık	0.546	0	0.454	
Alternatif				
A	0.578	0.53	0.41	0.50
B	0.37	0.12	0.41	0.39
C	0.052	0.35	0.18	0.11

## 5. Sonuç

Bu çalışmada, ABC A.Ş.'nin brülör üretiminde kullanılan yarı mamulleri satın aldığı üç tedarikçisi arasından en iyi yeşil tedarikçi firmanın seçimi problemi ele alınmıştır. Problemin çözümünde çok kriterli karar verme yöntemlerinden BAHF yöntemi kullanılmıştır. Bu yöntemin kullanılması, karar vericilerin AHP' de değerlendirme skorlarını belirlemede çoğu zaman yaşadığı emin olmama zorluğunu yok edebilir. Tablo 9.' dan da görüldüğü gibi en yüksek önem ağırlığına sahip A tedarikçisi firmanın en iyi yeşil tedarikçisi olarak seçilir. Bu tür karşılaştırmalar için ELECTRE, DEA, TOPSIS, ANP gibi çok kriterli karar verme metotları da kullanılmaktadır. Farklı akademik çalışmalarda bu metotlar değişik seçim problemlerine uygulanabilir ve sonuçları kıyaslanabilir.

## 6. Kaynaklar

[1] Korkankorkmaz N., "Yalın ve Yeşil Tedarik Zinciri Yönetimine İlişkin Bir Araştırma",

- Yüksek Lisans Tezi, Gebze İleri Teknoloji Enstitüsü Sos. Bil. Ens., 2012.
- [2] Özese E., "Yeşil Tedarik Zinciri Yönetimi ve Ambalaj Sanayiinde Bir Uygulama", Yüksek Lisans Tezi, Marmara Üniv. Sos. Bil. Ens, 2009.
- [3] Beamon, B., "Designing the Green Supply Chain", Logistics Information Management, Vol.12, Iss: 4, 1999, s.332-342.
- [4] Zhu Q., Sarkis J., Geng Y., "GreenSupplyChain Management in China: Pressures, Practices and Performance", International Journal of Operations and Production Management, Vol.25, Iss. 5, 2005, s. 449-468.
- [5] Ninlawan, C., Seksan, P., Tossapol, K., Pilada W., "The Implementation of Green Supply Chain Management Practices in Electronics Industry", Proceedings of the International Multi Conference of Engineers and Computer Scientists, Vol.3, IMECS 2010, Hong Kong, Mart 2010, s. 17-19.
- [6] Güner S., "Kobilerde Yeşil Tedarik Zinciri Algılaması: Sakarya Bölgesi Uygulaması", Yüksek Lisans Tezi, Sakarya Üniversitesi Sos. Bil. Ens., Temmuz 2010.
- [7] Vatansever K., "Tedarikçi Seçim Kararlarında Bulanık TOPSIS Yönteminin Kullanımı ve Bir Uygulama", Anadolu Üniversitesi Sosyal Bilimler Dergisi, C.13, S.3, 2013, s.155-168.
- [8] Öz E., Baykoç Ö.F., "Tedarikçi Seçimi Problemine Karar Teorisi Destekli Uzman Sistem Yaklaşımı", Gazi Üni. Müh. Mim. Fak. Dergisi, C.19, No.3, 2004, s.275-286.
- [9] Başlıgil H., "The Fuzzy Analytic Hierarchy Process For Software Selection Problems", Sigma Journal of Engineering and Natural Sciences, Vol. 3, 2005, s.24-33.
- [10] Yayla, A.Y., Akçay S., "Selection of Third-party Providers of Transportation Services in a Confectionary Company by Using Fuzzy Analytical Hierarchy Process", 1st International Fuzzy Systems Symposium, October 2009, Ankara, Turkey.
- [11] Lee, S.K., Mogib G., Kima, J.W., Gimc B.J., "A Fuzzy Analytic Hierarchy Process Approach for Assessing National Competitiveness in the Hydrogen Technology Sector", International Journal of Hydrogen Energy, 33, 2008, s.6840-6848.
- [12] Kazançoğlu Y., Ada E., "Perakende Sektöründe Tedarikçi Seçiminin Bulanık AHP ile Gerçekleştirilmesi", Savunma Bilimleri Dergisi, Cilt 9, Sayı 1, 2010, s.29-52.

## PSO Algoritması ile Çok Katmanlı Algılayıcı Ağ Mimarisinin Belirlenmesi

Alper ÇALIŞKAN<sup>1</sup> Sibel ÇİMEN<sup>2</sup> Tülay YILDIRIM<sup>3</sup>

Elektronik ve Haberleşme Mühendisliği Bölümü  
Elektrik-Elektronik Fakültesi  
Yıldız Teknik Üniversitesi, Beşiktaş, İSTANBUL

Email: <sup>1</sup>acaliskan@yildiz.edu.tr

<sup>2</sup>sblcmn@gmail.com

<sup>3</sup>tulay@yildiz.edu.tr

### Özet

ÇKA (Çok Katmanlı Algılayıcı) ağında kullanılacak olan en uygun eğitim algoritmasının ve optimum nöron sayısının belirlenmesi önemli bir etkidir. Bu iki parametre maksimum test başarımları temel alınarak Parçacık Sürü Optimizasyonu (PSO) algoritması ile optimize edilmiştir. Eğitilecek veri kümeleri olarak mamografik kitle, wine ve kan bağıışı ele alınmıştır. Optimizasyon sonuçlarından yola çıkarak belirlenen eğitim algoritmaları ve nöron sayıları verilmiştir. En uygun eğitim algoritmasının trainrp (resilient geriye yayılımı) olduğu anlaşılmıştır. Maksimum test başarımları mamografik kitle, wine ve kan bağıışı için sırasıyla %81.45, %96 ve %84.14 elde edilmiştir.

### 1. Giriş

Sezgisel bir optimizasyon algoritması olan Parçacık Sürü Optimizasyonu (PSO) popülasyon temelli olup Dr.Eberhart ve Dr.Kennedy tarafından geliştirilmiştir [1].

PSO'nun popülasyon temelli olması, kuş veya balık sürülerinin sosyal davranışlarından esinlenerek geliştirilmiş olmasından kaynaklıdır. PSO, olasılıksal bir optimizasyon yöntemidir ve çok değişkenli ve parametrelili optimizasyon problemlerinin çözümlerinde kullanılmaktadır [2]. PSO, algoritmaları, optimizasyon problemlerinde yaygın olarak kullanılmaktadır [3].

Bu çalışmada bir ÇKA ağı için gerekli olan gizli katmandaki nöron sayısı ve belirlenen 5 öğrenme algoritmasından (trainrp (Resilient geriye yayılımı), trainlm (Levenberg-Marquardt geriye yayılımı), traingd (Gradyant düşümü geriye yayılımı), traingdx (Momentum ve adaptif öğrenme oranı ile gradyant düşümü geriye yayılımı) ve trainoss (one-step secant geriye yayılımı)) ideal olan algoritmanın Parçacık Sürü

Optimizasyonu ile belirlenmesi hedeflenmiştir ve farklı popülasyon sayılarıyla kıyaslamaları yapılmıştır.

### 2. Parçacık sürü optimizasyonu

Optimizasyon, belirlenen amaç için belirli kısıtlamalar yapılarak en uygun ve en iyi çözümün elde edilmesidir. En iyi çözüm; probleme, çözüm metoduna ve belirlenen hata toleransına bağlı olarak problemde probleme göre değişkenlik gösterebilir.

Optimizasyon problemlerinin çözümünde matematiksel yöntemlerin kullanılıyor olmuş olması gibi dezavantajlarından ötürü performansı daha yüksek yöntemler geliştirilmiş ve bu gelişim esnasında doğadaki olaylar temel alınarak sezgisel optimizasyon algoritmaları geliştirilmiş. Bu algoritmalar da sezgisel yöntemler olarak adlandırılmıştır.

PSO, sürü zekâsına dayanan bir algoritmadır. Sürü halinde hareket eden hayvanların çoğu zaman rastgele sergiledikleri hareketlerin, amaçlarına daha kolay ulaşmalarını sağladığı görülmüştür. PSO bireyler arasındaki sosyal bilgi paylaşımını esas alır. PSO'da her bireye parçacık ve parçacıklardan oluşan popülasyona da sürü denir. Her bir parçacık kendi pozisyonunu, bir önceki tecrübesinden yararlanarak sürüdeki en iyi pozisyona doğru ayarlar. PSO, temel olarak sürüde bulunan bireylerin pozisyonunun, sürünün en iyi pozisyona sahip olan bireyine yaklaştırılmasına dayanır [3].

#### 2.1. PSO algoritması

PSO'da her parçacık bir çözüm sunar. Kurulacak olan algoritma kuş sürüsü üzerinden olacak olursa, bu durumda her bir parçacık bir kuşu ifade etmektedir. Tüm parçacıkların uygunluk fonksiyonuna bağlı olarak bulunan uygunluk değerleri vardır. Parçacıklar, kuşların uçuşlarını yönlendiren hız bilgisine benzer bir bilgiye sahiptir. PSO rastgele üretilmiş belirli sayıda çözümle (parçacıkla) başlatılır ve parçacıklar güncellenerek en uygun çözüm değeri araştırılır. Parçacıkların her biri, parçacığın en iyi kendi çözümü (pbest) ve tüm



parçacıkların en iyi çözümü (gbest) kullanılarak güncellenir ve bu değerler hafızada saklanır.

**BEGIN**

X Tane Parçacığa Hız ve Konum Değerleri Ata

**REPEAT**

**FOR**  $i=1$  TO  $X$

Uygunluk Değerini Hesapla;

Pbest Değerini Güncelle;

Gbest Değerini Güncelle;

**END FOR**

**UNTIL** Sonlandırma Kriteri

**END**

*Şekil 1. PSO Algoritması [4].*

Hız ve pozisyon değerlerinin güncellenmesi için kullanılan hız vektörü;

$$v_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$$

Parçacığın hızı ve konumunun güncellenmesi sırasıyla eşitlik (1) ve (2) de verilmiştir.

$$v_i^{k+1} = v_i^k + c_1 \text{rand}_1^k (pbest_i^k - x_i^k) + c_2 \text{rand}_2^k (gbest^k - x_i^k) \quad (1)$$

$$X_i^{k+1} = x_i^k + V_i^{k+1} \quad (2)$$

### 2.1.1. PSO parametreleri

- Parçacık sayısı: Genelde 20-40 arasındadır.
- Parçacık boyutu: Probleme göre değişkenlik gösterir.
- $V_{\max}$  = Bir iterasyonda, bir parçacıkta meydana gelebilecek maksimum hız değişikliğini belirler.
- Parçacık aralığı: Örneğin x1 için (-5,5)
- Öğrenme faktörleri:  $c_1$ ,  $c_2$  olup [0,4] aralığında seçilebilir.
- Sonlandırma kriteri: Minimum hata veya iterasyon sayısı olabilir.

### 2.1.2. PSO'nun avantajları [5]

- PSO, sürü zekası temeline dayanır. Bilimsel araştırmalar ve mühendislik alanında kullanılabilir.
- PSO'da mutasyon hesabı yoktur; parçacığın hızına göre hesap yapıldığı için daha az parametre gerektirir.
- Az parametre gerektirdiği için PSO hesabı kolaydır. Geliştirilen farklı hesaplamalarla

kıyaslandığında optimizasyon yeteneği yüksektir.

- PSO, gerçek sayılarla işlem yapabildiği için herhangi bir dönüşüme ihtiyaç duyulmaz.

### 2.1.3. PSO'nun dezavantajları [5]

- Saçılma problemlerinde sonuç vermez.
- Enerji gibi koordine olmayan sistemlerde çalışmaz.

## 3. ÇKA Mimarisinin Belirlenmesi

Algılayıcılar, doğrusal olmayan problemlerde çözüm vermediği için, ÇKA (Çok Katmanlı Algılayıcı) yöntemi ortaya konmuştur ve bu algılayıcılar, hatanın geriye yayılması mantığına dayanır.

Bu çalışmada ÇKA (Çok Katmanlı Algılayıcı) ağında kullanılacak olan en uygun eğitim algoritması ve optimum nöron sayısının belirlenmesi hedeflenmiştir. Bu iki parametre maksimum test başarımları oranları temel alınarak PSO algoritması ile optimize edilmiştir.

Sınıflama yapılacak veri kümeleri olarak (<http://archive.ics.uci.edu/>) adresinden mamografik kitle, wine ve kan bağıışı seçilmiştir. Veri kümeleri eğitim ve test örnekleri eşit sayıda olacak şekilde ayrılmış olup sırasıyla mamografik kitle için 480, wine için 30 ve kan bağıışı için 374 adet örnek ele alınmıştır.

Mamografik kitle veri kümesinde iyi huylu ve kötü huylu olmak üzere 2 sınıf bulunmaktadır. 961 örneğe sahip bu veri kümesindeki örneklerin 445 tanesi kötü huylu, 561 tanesi iyi huylu tümörlerden oluşmaktadır. Mamografi kitlelerinin yoğunluğu, şekli, hastanın yaşı gibi toplamda 5 özelliğe sahiptir. Wine verisinde 3 sınıf bulunmaktadır. 1. sınıfa ait 59, 2. sınıfa ait 71 ve 3. sınıfa ait 48 adet veri bulunmaktadır. 13 girişe sahip olan bu verinin magnezyum, renk yoğunluğu gibi belirleyici özellikleri vardır. Kan bağıışı 4 özelliğe sahip 748 örnek bulunmaktadır. Kan bağıışı yapanların sayısı 178, yapmayanların ise 570 olarak verilmiştir. Tüm veriler eşit bir şekilde 2'ye bölünmüştür ve eğitim için EG, test için TE dosyası oluşturularak işlemler yapılmıştır. Mamografik kitle için 480 eğitim, 480 test örneği, wine için 30 eğitim, 30 test ve kan bağıışı için de 374 eğitim ve 374 test örneği seçilmiştir.

Sınıflama problemlerindeki ağ yapısının uygun seçimi başarılı bir sınıflama yapmak için büyük önem taşımaktadır. Bu sebeple ağ seçiminin iyi yapılması gerekmektedir. Deneme yanılma yoluyla tespit edilen

bazı parametreler, en iyileme yapılarak başarımları daha yüksek olacak şekilde seçilebilir.

Parçacık sürü optimizasyonu yardımıyla en yüksek başarımları veren eğitim algoritması ve ağdaki nöron sayısının bulunması hedeflenmiştir. ÇKA eğitiminde kullanılan beş farklı eğitim algoritması optimizasyon için seçilmiştir. 1-5 olarak numaralandırılmış bu algoritmalar sırasıyla trainrp, trainlm, traingd, traingdx ve trainoss seçilmiştir. Trainrp, ağırlık ve bias değerlerini Resilient geriye yayılım algoritmasına göre, trainlm ise Levenberg-Marquardt geriye yayılım algoritmasına göre günceller. Traingd öğrenme algoritması ağırlık ve bias değerlerini güncellerken gradyent düşümüne bağlı iken traingdx buna ek olarak momentum ve adaptif öğrenme oranını kullanır. Trainoss öğrenme algoritması ise one-step secant metodunu kullanarak ağırlık ve bias değerlerini günceller. Optimizasyon parametrelerinde, iterasyon sayısı 5, popülasyon sayısı ise 4, 8 ve 16 seçilerek eğitim işlemi yapılmıştır. Tablo 1, Tablo 2 ve Tablo 3'de optimize edilen ÇKA parametreleri için veri kümelerinin maksimum ortalama test başarımları verilmiştir. Tablolar incelendiğinde ağırlıklı olarak 1. eğitim algoritmasının yani trainrp'nin en yüksek test başarımlarına ulaştığı görülmektedir. Mamografi verisi için trainrp 6 nöron sayısı ile %81.45 başarımları, wine verisi için trainrp, 5 ve 10 nöronla %96 başarımları, kan bağışısı için de 3 nöron sayısı ile %84.14 başarımları elde edilmiştir.

Tablo 1. Mamografik kitle verisi için farklı popülasyon sayılarına göre optimize edilen ÇKA parametreleri

PSO	Eğitime (EG)		Test (TE)	
	Eğitime Algoritması	Nöron Sayısı	Max. Ortalama Test Başarımları Oranı	Süre (sn)
pop=4	5	14	%80.87	1776
pop=8	1	6	%81.45	2778
pop=16	1	14	%81.37	7049

Tablo 2. Wine verisi için farklı popülasyon sayılarına göre optimize edilen ÇKA parametreleri

PSO	Eğitime(EG)		Test(TE)	
	Eğitime Algoritması	Nöron Sayısı	Max. Ortalama Test Başarımları Oranı	Süre (sn)
pop=4	1	10	%96.00	144.01
pop=8	1	11	%92.66	229.23
pop=16	1	5	%96.00	591.28

Tablo 3. Kan bağışısı verisi için farklı popülasyon sayılarına göre optimize edilen ÇKA parametreleri

PSO	Eğitime(EG)		Test(TE)	
	Eğitime Algoritması	Nöron Sayısı	Max. Ortalama Test Başarımları Oranı	Süre (sn)
pop=4	1	3	%84.14	1113
pop=8	1	4	%84.01	2329
pop=16	2	3	%84.14	4730

ÇKA ağı ile yapılan eğitimlerde her seferinde farklı sonuçlar elde etmek mümkün olduğundan tek bir seferde sınıflamanın doğru yapılıp yapılmayacağını kestirmek mümkün olmayabilir. Bu sebeple eğitim işlemi 10 defa tekrarlanıp elde edilen sonuçların ortalaması alınarak oluşturulmuştur. Ayrıca optimizasyon ve eğitim işleminin yapıldığı süreler de belirtilmiştir.

Optimizasyon algoritmasındaki popülasyon sayısının test başarımları oranı üzerindeki etkisi ve sonuçlar Tablo 1, Tablo 2 ve Tablo 3'de her bir veri seti için verilmiştir. Wine verisi için popülasyon sayısı 4 veya 16 seçildiğinde test başarımları oranlarında herhangi bir farklılık olmamıştır. Her iki durumda da %96'lık bir başarımları oranı elde edilmiştir. Mamografi verisi için ise popülasyon sayısı 4 olduğu durumda durum uzayının az

olmasından dolayı en iyi çözümler bulunamayabilmektedir, ancak algoritmanın tamamlanma süresi kısalmıştır. Popülasyon sayısı 8 ve 16 olduğunda daha yüksek test başarımları elde edilmiştir, fakat çözüm üretme süresi popülasyon sayısı arttıkça uzamaktadır. [6]'da yapılan çalışmada mamografik kitlelerin görüntüleri üzerinden yapılan çalışmadaki başarımları oranı %77 olarak verilirken bu optimizasyon ile yapılan çalışmamızda %81'lik bir başarımları oranı elde edilmiştir. Kan bağışısı verisi için popülasyon sayısının 4 ve 16 olduğu durumda maksimum başarımları oranı elde edilmiştir. [7]'de yapılan kan bağışısı tahmininde %78.2'lik bir başarımları söz konusu iken ÇKA optimizasyonu ile yapılan çalışmamızda başarımları oranı %84.14'tür.

#### 4. Sonuç

Yapılan çalışmanın sonucunda, PSO algoritması kullanılarak istenilen herhangi bir veri kümesi için optimum bir ÇKA yapısı elde edilebildiği gözlemlenmiştir. Ayrıca bu ağımları ortalama başarımları oranının yüksek olmasını da ayrı bir avantaj olarak göz önüne alabiliriz, dezavantajını ise arama uzayının artması sebebiyle ağımları toplam eğitim süresinin artması olarak tanımlayabiliriz. Yine de, bu algoritma ile bir ağımları eğitiminin başlangıcında karşılaşılan kullanıcının deneme yanılma aşamasına maruz kalmadan en uygun ağımları yapısı elde edilebilmektedir.

Daha sonraki çalışmalarda, nöron sayısı ve eğitim algoritmaları haricinde, ağımları gizli katman sayısı, aktivasyon fonksiyonu, momentum katsayısı, öğrenme oranı ve hatta ÇKA dışında RBF, GRNN, SVM gibi ağların da optimizasyon değişkeni olarak atanması ile çok daha kapsamlı bir analiz yapılması mümkündür.

#### 5. Kaynaklar

- [1] Leong, W.F, Multiobjective Particle Swarm Optimization: Integration of Dynamic Population and Multiple-Swarm Concepts and Constraint Handling, Yüksek Lisans Tezi, Oklahoma State Üniversitesi, Elektrik Mühendisliği, 2002.
- [2] Akyol, S. ve Alataş, B., "Güncel Sürü Zekası Optimizasyon Algoritmaları", *Nevşehir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1, 3 6-50, 2012.
- [3] Özsağlam, Y. M. ve Çunkaş, M., "Optimizasyon Problemlerinin Çözümü için Parçacık Sürü Optimizasyonu Algoritması", *Politeknik Dergisi*, 11, 299-305, 2008.

- [4] Ortakçı, Y., Göloğlu, C., "Parçacık Sürü Optimizasyonu ile Küme Sayısının Belirlenmesi", Akademik Bilişim'12 – XIV. Akademik Bilişim Konferansı, 335-341, 2012.
- [5] Bai, Q., "Analysis of Particle Swarm Optimization Algorithm", *Computer and Information Science*, 3, 180-184, 2010.
- [6] Bovis, K., Singh, S., Fieldsend, J. ve Pinder, C., "Identification of masses in digital mammograms with MLP and RBF Nets", Proceedings of the IEEE-INNS-ENNS International Joint Conference on, 342-347, 2000.
- [7] Darwiche, M., Feuilloy, M., Bousaleh, G. ve Schang, D., "Prediction of blood transfusion donation", Research Challenges in Information Science (RCIS) Fourth International Conference on, 51-56, 2010.

## GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANARAK OZONLANMIŞ KAYISILARIN MORFOLOJİK ÖZELLİKLERİNİN İNCELENMESİ

### INVESTIGATION OF THE MORPHOLOGICAL FEATURES OF OZONATED APRICOT USING IMAGE PROCESSING TECHNIQUES

*Mahmut Sinecen<sup>1</sup>, M. Burak Büyükcan<sup>2</sup>, Cengiz Caner<sup>3</sup>*

1. Bilgisayar Mühendisliği Bölümü  
Adnan Menderes Üniversitesi  
mahmutsinecen@gmail.com

2. Tarım Makinaları Bölümü  
Çanakkale 18 Mart Üniversitesi  
buyukcanb@comu.edu.tr

3. Gıda Mühendisliği  
Çanakkale 18 Mart Üniversitesi  
ccaner@comu.edu.tr

#### ÖZETÇE

*Kayısının tazeliğini korumak için özel önem veya önlemlerin alınması gerekmektedir. Bu yöntemlerden bir tanesi de ozon kullanımudur. Ozon, günümüzde gıda muhafazası ve gıda üretim alanlarının sterilizasyonunda kullanılabilir. Sebze ve meyvelerin kalitelerinin farklı aletsel teknikler kullanılarak tespit edilmesinden dolayı görüntü işleme teknikleri son zamanlarda gıda ve tarım ürünlerinin iç ve dış özelliklerini hızlı, temassız ve tahribatsız muayene için güçlü bir analitik araç olarak uygulanmaktadır. Yapılan çalışmada görüntü işleme yöntemleri kullanılarak ozonlanmış kayisuların zamana göre morfolojik özellikleri incelenmektedir. Çalışma sonucunda en uygun ozonlama değeri 5ppm-5dk olarak ölçülmüştür.*

#### ABSTRACT

*Special importance or taking measures are required to preserve the freshness of apricot. One of these methods is the use of ozone. Nowadays, ozone can be used for sterilization of the food storage and food-producing areas. Lately, image processing techniques have been administered fast, non-contact and non-destructive examination the interior and exterior features of fruits and vegetables as a powerful analytical tool due to the different instrumental techniques using to identify quality of food and agricultural products. In this study investigated morphological characteristics of ozoned apricots using image processing method according to the time. As a result the optimal ozone values were measured as 5ppm-5min.*

#### 1. GİRİŞ

Kayısı, ülke ekonomisi ve beslenme için önemli bir meyvedir. Kayısı ülkemizde Doğu Anadolu, Akdeniz, Marmara, Ege ve İç Anadolu Bölgelerinde yetiştirilmektedir. Türkiye yıllık 695 bin ton kayısı üretimi ile dünyada ilk sırada yer almaktadır [1]. Çanakkale ilinde 2010 yılı verilerine göre yaklaşık olarak 2600 ton taze kayısı üretimi gerçekleşmektedir [2]. Taze halde muhafaza süresi çok kısa olan bu değerli meyve türünün, sadece üretiminin artırılması yeterli olmayıp; raf ömrünün de artırılması gerekmektedir.

Ozon uygulaması, gıdaların depolama süresinin uzatılmasında yaygın ve etkin bir şekilde kullanılmaktadır [3] ve [4].

Ozon, yüksek oksidasyon yeteneğine sahip, yükseltgen ve antimikrobiyal bir madde olup gıdaların raf ömürlerinin arttırılmasında ve kalitesinin yükseltilmesinde tavsiye edilebilir [5].

Gıda sektöründe kullanılan kalite ve güvence yöntemleri, geleneksel insan kaynaklı görsel denetim sistemleri kullanılarak uygulanmaktadır. Bu tür yöntemler, yorucu, zahmetli, zaman alıcı, tutarsız ve masraflıdır. Kalite kriterini değerlendirme işleminin tahripsiz olması, üretimin hızlı ve verimli olmasını sağlarken, artan değerlendirme doğruluğuna ilave olarak üretim maliyetlerini de azaltır [6]. Görüntü İşleme teknikleri gıda özelliklerinin belirlenmesi için otomatik ve tahribatsız bir yöntem sağlamakta olup gıda endüstrisinde farklı çeşitli ürünlerin kalitelerinin sınıflandırılmasında uygulama alanları bulunmaktadır [7], [8] ve [9].

Bu çalışma da Görüntü İşleme teknikleri kullanılarak ozonlanmış kayisuların morfolojik özellikleri üzerindeki etkisi incelenecektir.

#### 2. MATERYAL VE YÖNTEM

Bu çalışmada kullanılan kayisular ÇOMÜ Dardanos Yerleşkesinde bulunan Hasanbey kayısı çeşidine ait kayısı ağaçlarından temin edilmiştir. Meyveler, yuvarlak şekilli ve 35-50 gr. ağırlığında olan “Prunus armeniaca L” çeşidi kayisulardır.

Toplanan kayisular aynı gün laboratuvar ortamına getirilerek kendi içlerinde uygulamalara göre ayrılmıştır. Her bir uygulama için 30 adet kayısı örneği kullanılarak toplamda 270 adet kayısı örneği bulunmaktadır.

##### 2.1. Ozon

Ozon gazı, TKZ-6G model taşınabilir tip ozon jeneratörüyle elde edilmiştir (Şekil 1). Kayisulara hava sızdırmayan tüp içerisinde çeşitli dakikalarda ve değişik konsantrasyonlarda ozon gazı verilmiştir.




Şekil 1: Ozon Jeneratörü Sistemi

Seçilen kayısılar gruplara ayrılacak, birinci gruptaki kayısılar kontrol grubu olduğundan ozon uygulamasına tabi tutulmayacaktır. İkinci gruptaki kayısılar 1 ppm, üçüncü gruptaki kayısılar 5 ppm, dördüncü gruptaki kayısılar 10 ppm, beşinci gruptaki kayısılar ise 20 ppm ozon içeren ozon gazına maruz kalmıştır. Her bir ozon konsantrasyonunda kayısıların bekleme süresi olarak 5 ve 10 dk olarak seçilmiştir. Ozon uygulanmış kayısılar buzdolabında  $\pm 40\text{ C}^\circ$  de depolanmıştır.

Ozon uygulamaları;

- Kontrol
- 1 ppm-5dk
- 1 ppm-10 dk
- 5 ppm-5 dk
- 5 ppm-10 dk
- 10 ppm-5dk
- 10ppm-10dk
- 20 ppm-5dk
- 20 ppm-10 dk



Şekil 2: Uygulamalar için sınıflandırılan kayısı örnekleri

## 2.2. Görüntü Alınması

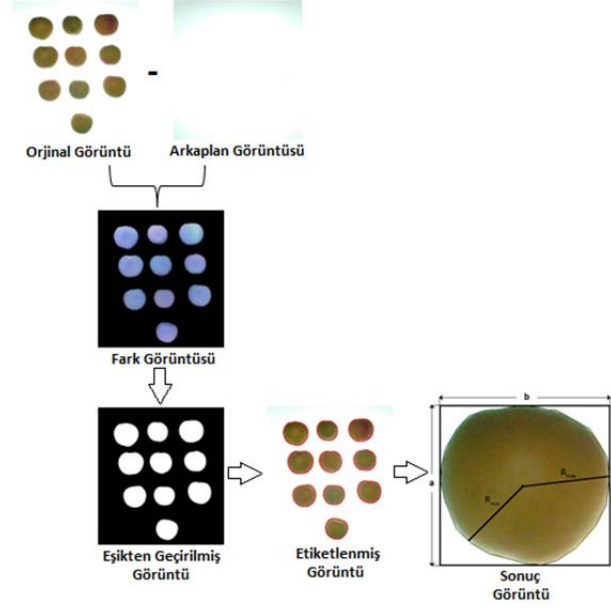
Görüntüler, Şekil 3'de gösterildiği gibi Fujifilm S2000 model dijital fotoğraf makinesiyle çekilmiştir. 12 MP resim boyutunda (4048X3040) ve ISO 400 formatında resimler elde edilmiştir. Her bir resimde 10 adet kayısı bulunacak şekilde resimleri çekilmiştir. Elde edilen fotoğraflar MATLAB programında Image Processing Toolbox kullanılarak istenilen özellikler;

- Kayısıların toplam alanı,
- Kayısıların çevre değerleri,
- Kayısıların içerisine alan en küçük dikdörtgen alanı,
- Kayısıların içerisine alan en küçük konkavın alanı,
- Kayısıların merkez noktalarına göre en kısa yarıçapı,
- Kayısıların merkez noktalarına göre en uzun yarıçapı,

elde edilmiştir (Şekil 4).




Şekil 3: Örneklerin görüntülerinin alınması



Şekil 4: Görüntü İşleme Adımları


## 3. SONUÇLAR

Şekil 5'de tüm uygulamalarda 1.günden sonra bir düşüşün olduğu gözlemlenmiştir. Bu düşüş kayısıların depolama süresi ilerledikçe fiziksel alanlarında negatif yönde bir değişim olduğunu göstermektedir. 20ppm-10dk ozon uygulanmış kayısıların alanlarında yaklaşık %28 oranında küçülme görüldüğü gözlemlenirken, 5ppm-5dk uygulanmış kayısılarda bu oran %21 olarak kalmıştır.




Şekil 5: Kayısıların alan ölçümleri değişimleri

Kayısılarda meydana gelen çap değişimi ürünlerin büzüşerek küçüldüğünün göstergesi olarak kabul edilmektedir. Şekil 6 (a)'da görüldüğü üzere en uzun çaptaki en fazla değişim %14 ile 20ppm-10 dk'da olurken en az değişim yaklaşık %10 ile 5 ppm-5 dk'da gerçekleşmiştir. Şekil 6 (b)'de ise yine en fazla değişim %16 ile 20 ppm-10 dk'da gerçekleşmiştir. Kayıslara 20 ppm ozon gazı 10 dk süre ile uygulandığında ürünlerde boyutsal olarak küçülme görülerek su kaybına yol açtığı düşünülmektedir.




(a)




(b)

Şekil 6: Kayısı çaplarının depolama süresi boyunca değişimi

Görüntü işleme ile kayısıların fiziksel özelliklerini belirlemede ürünün sınırlarını tanımlanmasında kullanılmak üzere geometrik şekillerden yararlanılmaktadır. Yapılan analizler sonucunda ürünlerin sınırlarını belirleyen en küçük dikdörtgen alanı ve konkavlığı hesaplandığında en büyük değişimin 20 ppm-10dk'da, en küçük değişimin ise 5 ppm-5 dk'da olduğu görülmektedir (Şekil 7).



(a)




(b)


Şekil 7: Kayısı köşegenlerinin depolama süresince değişimi

Çevre ve yarıçap değişimlerinde oransal olarak en çok değişime uğrayan 20 ppm-5dk olurken en az değişim 5ppm-5dk uygulamasında görülmektedir. Genel olarak bakıldığında;

yüksek konsantrasyonda ozon uygulanan kayısıların fiziksel ölçülerinde yüksek oranda değişim olduğu görülmektedir. En az değişimin ise orta konsantrasyon diyebileceğimiz 5ppm-5dk uygulamasında görülmektedir (Şekil 8).



(a)



(b)

Şekil 8: Kayısıların çevre ve yarıçap değişimleri

#### 4. TARTIŞMA

Yapılan çalışma da ozonlanmış kayısıların morfolojik yapılarındaki değişimlerinin zamana bağlı olarak görüntü işleme yöntemleri ile incelenmiştir. Elde edilen bulgulara göre 5 ppm 5 dk'lık ozonlama değerinin kayısılar üzerinde en az bozulma etkisi göstermektedir.

Bu çalışma ile görüntü işleme tekniklerinin gıda ürünlerinin analizinde de geleneksel yöntemlerden farklı olarak hızlı, etkin ve temassız bir yöntem olarak kullanılmasının uygun olduğu görülmektedir.

İleriki çalışmalarda kayısıların morfolojik özellikleri yanında, renk ve yüzey özellikleri de elde edilerek değişimin farklı yapay zekâ algoritma yöntemleri değerlendirilmesi amaçlanmaktadır.

#### 5. KAYNAKÇA

- [1] FAO, <http://faostat.fao.org/>, 10.2.2014.
- [2] TÜİK,2011.[http://rapor.tuik.gov.tr/reports/rwservlet?hayvancilik=&report=BARAPOR68.RDF&p\\_yil=2010&p\\_kod=3&p\\_duz1=0&p\\_mad1=1130204&p\\_dil=1&p\\_bolum=4&desformat=html&ENVID=hayvancilikEnv](http://rapor.tuik.gov.tr/reports/rwservlet?hayvancilik=&report=BARAPOR68.RDF&p_yil=2010&p_kod=3&p_duz1=0&p_mad1=1130204&p_dil=1&p_bolum=4&desformat=html&ENVID=hayvancilikEnv).
- [3] Nadas, A., Olmo, M., & Garcia, J. M. (2003). Growth of Botrytis cinerea and strawberry quality in 372 ozone-enriched atmospheres. Journal of Food Science, 68(5), 1798-1802.
- [4] Ruiz, D., et al. (2005). "Carotenoids from New Apricot (Prunus armeniaca L.) Varieties and Their Relationship with Flesh and Skin Color." Journal of

- Agricultural and Food Chemistry 53(16): 6368-6374.
- [5] Sun, D. W. (Ed.). (2010). Hyperspectral imaging for food quality analysis and control. Elsevier.
- [6] ElMasry, G., Sun, D. W., & Allen, P. (2011). Non-destructive determination of water-holding capacity in fresh beef by using NIR hyperspectral imaging. Food Research International, 44(9), 2624-2633.
- [7] Azodanlou R., Darbellay C., Luisier J., Villettaz J.ve Amadò R., Quality Assessment of Strawberries (Fragaria Species), J. Agric. Food Chem.,51(3), 715–721, (2003).
- [8] Felföldi J., Szepes A., Machine Vision Based Quality Assessment of Fruits and Vegetables,Proceedings of the World Congress of Computers in Agriculture and Natural Resources,42-48, (2002).
- [9] Cho N., Chang D., Lee S.H., Kim H.J., Lee Y.H., Development of Automatic Sorting System for Green Pepper Using Machine Vision, 2007 ASAE Annual Meeting 076106.

## **Genetik Algoritma Kullanarak Çift Rotorlu Sistemin Gürbüz Denetleyicisinin Kazançlarının Ayarlanması**

Alper Bayrak<sup>1</sup>, Fırat Do an<sup>2</sup>, Enver Tatlıcıo lu<sup>2</sup>

<sup>1</sup> Abant zzet Baysal Üniversitesi, Elektrik-Elektronik Mühendisli i Bölümü, Bolu

<sup>2</sup> zmir Yüksek Teknoloji Enstitüsü, Elektrik-Elektronik Mühendisli i Bölümü, zmir

Bu çalı mada, helikopteri temsil eden ve çift-rotorlu çok-giri li çok-çıkı lı sistem olarak adlandırılan sistem ele alınmı tır. Bu sistem, sabit bir mafsallık üzerine oturtulmu tur ve gerçek bir helikopterin manevra kabiliyetinin iki açığa indirgenmi hali olarak ifade edilebilir. Do rusalsızlı ı yüksek bir sistemdir ve bu sebeple do rusal olmayan denetleyici tasarımı gerektirir. Bu tür sistemler için denetleyici tasarlamak zor olmakla beraber, bir di er zorluk da tasarlanan denetleyicinin kazançlarının ayarlanmasıdır. Bu sebepten ötürü, bu çalı manın ana itisini, genetik algoritma kullanarak, tasarlanan denetleyicinin, kazançlarını ayarlamak olu turmaktadır.



## CUDA Platformunda İki Boyutlu Ayırık Haar Dalgacık Dönüşümü

Selçuk ASLAN

Hasan BADEM

Tayyip ÖZCAN

Alper BAŞTÜRK

Erciyes Üniversitesi, Bilgisayar Mühendisliği Bölümü  
Mühendislik Fakültesi  
Melikgazi, KAYSERİ

Email: {selcukaslan, hbadem, tozcan, ab}@erciyes.edu.tr

### Özet

*Ayrık Haar dalgacık (wavelet) dönüşümü, gürültülü ve gürültüsüz resimlerin sıkıştırılmasında oldukça etkili bir yöntemdir. Ardışık piksel çiftlerine ait değerlerin ortalama ve farklarının alınmasına dayalı yaklaşımın getirdiği işlem kolaylığı ile resim üzerinde paralel uygulanabilir olması, dönüşümün grafik kartlarında gerçekleştirilerek hızlandırılmasının önünü açmaktadır. Bu çalışmada iki boyutlu ayırık Haar dalgacık dönüşümü, NVIDIA tarafından sunulmuş Compute Unified Device Architecture (CUDA) programlama ortamı ile farklı üretici firmaların yine farklı hesaplama kapasitelerine sahip grafik kartlarına aktarılarak test edilmiştir. Dönüşümün CUDA platformuna uyarlanmış paralel modelinin, işlemciler üzerinde çalışan seri uygulamasına kıyasla çalışma sürelerini oldukça kısalttığı görülmüştür.*

### 1. Giriş

Zaman dizileri, belirli bir sürecin sonunda örneklenen veya ölçümü yapılan değere ilişkin gözlemler topluluğu olarak nitelenebilir. Zaman dizilerinin daha iyi yorumlanması ve temsil ettikleri sistemin özelliklerinin belirlenebilmesi adına, dizinin zaman alanından frekans alanına aktarılması veya dönüştürülmesi gerekmektedir. Zaman uzayından frekans uzayına geçişi sağlayacak çok sayıda matematiksel yaklaşım olmakla birlikte, Fourier, Hilbert, Radon dönüşümleri ile son zamanlarda uygulama sahası oldukça genişleyen görece yeni ve ilk kez Alfred Haar'ın doktora tezinde bahsettiği dalgacık sözcüğü ile anılan Dalgacık dönüşümü bunlardan bazılarıdır [1]. Dalgacık dönüşümü, Fransız matematikçi Joshep Fourier tarafından saptanmış bütün periyodik fonksiyonların ağırlıklandırılmış basit trigonometrik fonksiyonların toplamı şeklinde ifade edilebileceğini temeline dayanır [1].

Dalgacık dönüşümü başlangıçta sismik verilerin analizi amacıyla sunulmuş olmasına karşın, işaret işlemeden yapay sinir ağlarına, veri madenciliğinden kısmi diferansiyel denklemlerin çözümüne kadar çok sayıda değişik uygulama sahalarında kullanılmıştır [1]. Dönüşümün, değişim hızı yüksek işaretlerin analizini kolaylaştırma yeteneğine ek olarak sunmakta olduğu veri sıkıştırma özelliği, büyük boyutlu resim ve video verilerinin işleme sahasında da geniş kullanım alanı bulmasına olanak sağlamıştır [2,3]. Güncel sayılabilecek resim sıkıştırma standartlarından biri olan JPEG-2000 ile önemli bir video kodlama standardı haline gelmiş MPEG-4 dalgacık tabanlı algoritmalar kullanılmaktadır [2,3].

Resim verisinin sunumu ve dönüşümün piksel değerleri üzerinde görece basit aritmetik işlemlerin sıralı yapılma zorunluluğunun olmaması, grafik kart tabanlı paralel mimarilerin kullanılabilirliğini daha önemli hale getirmekte ve yaygınlaştırmaktadır. 2007 yılında Wong, 2008 yılında Tenllado iki boyutlu ayırık dalgacık dönüşümünün sıkıştırma performansının artırılması ve farklı dalgacık fonksiyonlarına ait paralel modellerin karşılaştırılması amacı ile programlanabilir grafik kartlarını kullanmışlar [4,5], sonrasında Franco ile Van der Laan doğrudan CUDA platformunu kullanarak farklı dalgacıklar üzerinde dönüşüm performansını çeşitli üretici firmalara ait işlemciler üzerinde çalıştırılmış seri uygulamalar ile karşılaştırmışlardır [6,7]. Bu çalışmada, iki boyutlu ayırık Haar dalgacık dönüşümü CUDA paralel hesaplama mimarisi üzerine taşınmış ve geliştirilen paralel model farklı kartlar üzerinde test edilerek grafik kartlarının hızlandırma kapasiteleri incelenmiştir. İkinci ve üçüncü bölümlerde, sırasıyla ayırık Haar Dalgacık dönüşümü ve CUDA platformunun temel özelliklerinden bahsedilmiş, dördüncü bölümde CUDA platformuna aktarılması dönüşümün farklı kartlar ile test ve karşılaştırma

işlemleri yapılmış, son bölümde ise sonuç ve önerilere yer verilmiştir.


## 2. Ayrık Haar Dalgacık Dönüşümü

Ayrık Haar dalgacık dönüşümünün resim verisi üzerinde uygulanması, önce satır sonra da tüm sütunlarda alçak ve yüksek geçiren filtrelerin her dönüşüm seviyesinde kullanılması temeline dayanır [1-3].  $N = 2^m, m \in Z^+$  olmak üzere,  $N$  örneğe sahip tek boyutlu  $c_0 = (c_0^0, c_0^1, \dots, c_0^{N-1})$  sinyalinin komşu ikilileri, katsayıları  $(1/\sqrt{2}, 1/\sqrt{2})$  olan ve  $H$  ile gösterilen alçak geçiren filtre, sonrasında katsayıları  $(1/\sqrt{2}, -1/\sqrt{2})$  olan ve  $G$  ile gösterilen yüksek geçiren filtre kullanılarak işlendiğinde, örnek sayıları  $N/2$  olan  $c$  ve  $d$  sinyalleri;

$$c_k^j = \sum_n h[n]c_{2k+1}^{j-1}, k \in \{1, 2, \dots, N/2^j\} \quad (1)$$

$$d_k^j = \sum_n g[n]c_{2k+1}^{j-1}, k \in \{1, 2, \dots, N/2^j\} \quad (2)$$

(1) ve (2) eşitlikleri kullanılarak, dönüşümün  $j$ . seviyesi için üretilebilir. Aşağıda ayrık Haar dalgacık dönüşümünün farklı dönüşüm seviyeleri için alçak ve yüksek geçiren filtre çifti ile nasıl gerçekleştirildiği gösterilmektedir.




Şekil 1. Alçak ve yüksek geçiren filtrelerin ardışık uygulanması.

İki boyutlu ayrık Haar dalgacık dönüşümünde ise, önce alçak ve yüksek geçiren filtre çifti yatay doğrultuda, yani tüm satırlar için yukarıda bahsedilen tek boyutlu sinyal üzerinde uygulandığı gibi geçirildikten sonra, alçak ve yüksek geçiren filtre çifti yatayda işlenmiş veri düşey doğrultuda, yani tüm sütunlar için yukarıda bahsedilen tek boyutlu sinyal üzerinde uygulandığı gibi geçirilmesi şeklinde modellenmiştir. Böylece iki boyutlu veri, resim verisi, her biri başlangıç boyutlarının yarısı olan alçak-alçak, yüksek-alçak, alçak-yüksek ve yüksek-yüksek filtrelenmiş işaretlerden oluşan dört bölgeye ayrılmış olacaktır. Alçak-alçak filtrelenmiş bölge, orijinal resim verisinin sıkıştırılmış halidir ve dönüşümün ilerleyen seviyelerinde bu bölgeye ait işaretler kullanılacaktır.

## 3. CUDA Platformunun Temel Özellikleri

Kullanıcı taleplerinin gerçek zamanlı, oldukça yüksek çözünürlüklü grafikler üzerinde yoğunlaşması, çok sayıda paralel çalışabilir çekirdeğe sahip yüksek işlem gücü ve band genişlikli grafik işleme birimlerinin geliştirilmesinin önünü açmıştır [8]. Grafik işleme birimlerinin bu özellikleri, merkezi işlem birimlerinde, grafik işleme birimlerine kıyasla daha çok transistör iş akış kontrolü ile veri depolama için ayrılmıştır, aritmetik işlem miktarının veri taşıma, kopyalama işlem miktarına oranının daha yüksek olduğu sinyal işleme, modelleme ve biyoinformatik problemlerinin çözüldüğü pek çok uygulamada hesaplama maliyetlerini düşürmüştür [8-10].

2006 yılında NVIDIA firması, ürettikleri grafik işleme birimlerinin, paralelleştirilebilirliği yüksek ve veri bağımlılığı az kompleks problemlerin çözümünde kullanılabilmesi için CUDA adını verdikleri genel paralel hesaplama, programlama platformunu, C gibi üst seviye bir programlama dilinin de aralarında bulunduğu pek çok dil desteği ile uygulama geliştiricilere duyurmuştur [8]. CUDA programlama platformu, grafik işleme biriminde  $N$  farklı CUDA iplik (thread) yapısı aracılığı ile  $N$  kez paralel çalıştırılacak fonksiyonu çekirdek (kernel) olarak isimlendirmektedir [9,10]. Probleme ve çalıştırılacağı cihazın sınırlamalarına bağlı olarak iplik elemanları tek, iki veya üç boyutlu iplik bloklarından oluşmuş, yine tek, iki veya üç boyutlu ızgara (grid) yapıları şeklinde organize edilmektedir. CUDA uygulamasından çekirdek çağrıldığında, çekirdek için belirlenmiş iplik blokları eş zamanlı çalışabilme özelliğine sahip *Streaming Multiprocessor (SM)* birimlerine dağıtılır. *SM* birimleri kendi içlerinde *Single Instruction Multiple Thread (SIMT)* adı verilen bir mimariyi kullanarak çok sayıda iplik elemanını paralel çalıştırabilecek özellikte inşaa edilmiştir [9]. Aşağıda dört ve iki *SM* birimi üzerine sekiz ve dört iplik bloğunun dağıtılması durumu örneklenmiştir [8].



Şekil 2. Dört (a) ve iki (b) *SM* birimine sahip grafik işleme birimlerinde blokların dağılımı.


#### 4. Ayrık Haar Dalgacık Dönüşümünün CUDA Platformuna Aktarılması

İki boyutlu ayrık Haar dalgacık dönüşümünün önce tüm satırlar sonrasında da tüm sütunlar üzerinden geçirilen alçak ve yüksek geçiren filtre çifti ile yapılıyor olması, aynı dönüşüm seviyesinde tüm satır ve sütunlarda filtreleme işleminin paralel olarak gerçekleştirileceği iki farklı CUDA çekirdeği tasarımını mümkün kılmaktadır. Bütün satırlar üzerinde filtrenin paralel geçirildiği çekirdek için her bir blok bir satırı, bütün sütunlar üzerinde filtrenin paralel geçirildiği çekirdek için de her bir blok bir sütünü işleyen iplik kümelerinden oluşmaktadır. Aşağıda iki boyutlu ayrık Haar dalgacık dönüşümünün çekirdek yapılarına ait ızgara, blok ve iplik düzenlemesine ilişkin kod bloğu gösterilmektedir.

```
#define THREADSINXDIM .....
#define THREADSINYDIM .....
#define BLOCKSINXDIM .....
#define BLOCKSINYDIM .....
#define LEVELOFWAVELET .....
;
for( int levelOfWavelet = 1; levelOfWavelet <= LEVELOFWAVELET; levelOfWavelet++)
{
    dim3 gridOfBlocks( BLOCKSINXDIM, BLOCKSINYDIM,
        HEIGHTOFIMAGE / ( BLOCKSINXDIM * BLOCKSINYDIM * ( 2 ^ ( levelOfWavelet - 1 ) ) );
    dim3 blockOfThreads( THREADSINXDIM, THREADSINYDIM,
        WIDTHOFIMAGE / ( THREADSINXDIM * THREADSINYDIM * ( 2 ^ levelOfWavelet ) );
    haarWaveletForRows<<<gridOfBlocks, blockOfThreads>>>(...);
    haarWaveletForColumns<<<gridOfBlocks, blockOfThreads>>>(...);
}
```

Şekil 3. Izgara, blok yapıları ve iplik sayılarının dalgacık seviyesine göre düzenlenmesi.

Şekil 3'de verilen kod bloğundan anlaşılacağı üzere, ızgara ve blok yapılarının x ve y boyutlarına ilişkin uygun değerler belirlendikten sonra, z boyutuna ait değer resim verisinin satır ve sütun sayısı, önceden belirlenmiş x ve y boyutlarına ilişkin değerler ve dönüşümün uygulanma seviyesine bağlı olarak adaptif ayarlandığı görülmektedir. Aşağıda 512 satır, 512 sütundan oluşmuş bir resim verisi için, çekirdek yapılarına ait ızgara, blok ve iplik düzenlemesi ızgara ve blok yapılarının x ve y boyutlarına 8 değeri atanması durumu için verilmiştir.



Şekil 4. Izgara ve blok yapılarının 1. Seviye (a) ve 2. Seviye (b) durumları.

Boyutları 512x512 ve 1024x1024 olan resim verileri, iki boyutlu ayrık Haar dalgacık dönüşümünün CUDA uygulaması, CUDA SDK 5.5 yüklü sistemde ASUS GeForce GTX 560 Ti Direct CU II, MSI GeForce GTX 760 Twin Frozr ve Gigabyte GeForce GTX Titan grafik kartları üzerinden, dönüşümün seri uygulaması ise Intel i7-2600 (CPU1) ve i3-550 (CPU2) numaralı işlemcileri üzerinden 10 farklı kez orijinal resim verisi 4 kat küçültülecek şekilde çalıştırılmış, dönüşümün tamamlanması için kullanılan çekirdek ve seri fonksiyonların çalışma süreleri kaydedilmiş, ardından ortalamaları alınmıştır. Her biri 3.2 GHz çalışma hızına sahip 2 çekirdeği ile 4 iş parçacığı yönetebilen i3-550 numaralı işlemci, her biri yük altında 3.8 GHz, diğer durumlarda ise 3.4 Ghz çalışma hızına sahip 4 çekirdeği ile 8 iş parçacığı yönetebilen i7-2600 numaralı işlemci performansları, ayrıntıları Tablo 1'de verilen grafik kartlarının performansları ile karşılaştırılmıştır.

Tablo 1. Kullanılan grafik kartları ve özellikleri.

Grafik Kart	Kısaltma	Grafik İşlemci	Memory Clock(Mhz)	Base Clock(MHz)
GTX 560 Ti	GPU1	GF114	4000	830
GTX 760	GPU2	GK104	6008	980
GTX Titan	GPU3	GK110	6008	837

Resim verisinin kartlara aktarılması dönüşümü gerçekleştiren çekirdek yapılarının çalışma sürelerinden bağımsız olmasına karşın, işlemci ve grafik kartlarının performans karşılaştırılması sadece çekirdek çalışma süreleri üzerinden yapılmamış, çekirdek çalışma süreleri ile kopyalama işlemleri boyunca geçen sürelerin toplanması sonucu elde edilen değer karşılaştırma sürecine dahil edilmiştir. Bu sayede grafik kartların veri aktarım özellikleri ile ilgili de genel bir kaniya varılabilecektir. i7-2600 ve i3-550 numaralı işlemciler için 512x512 boyutlu resim dönüşümü 10 farklı tekrarın ortalaması sırasıyla 5.010 ms (milisaniye) ve 6.012 ms bulunurken, 1024x1024 boyutlu resim dönüşümünün 10 farklı tekrarının ortalaması sırasıyla 33.571 ms ve 17.535 ms olarak kaydedilmiştir. Ekran kartları için ise sadece çekirdek ve çekirdek süresi ile toplanmış kopyalama süreleri Tablo 2'de verilmiş, Tablo 3'te ise karşılaştırma sonuçlarına yer verilmiştir.

Tablo 2. Sadece çekirdek ve kopyalama maliyeti dahil edilmiş süreler.

	512x512		1024x1024	
	Çekirdek (ms)	+Bellek (ms)	Çekirdek (ms)	+Bellek (ms)
GPU1	0.354	0.676	1.901	3.643
GPU2	0.375	0.547	2.878	4.324
GPU3	0.105	0.279	0.402	1.764

Tablo 3. Veri kopyalama maliyetleri dahil edilmiş süreler üzerinde karşılaştırma.

CPU/GPU	512x512		1024x1024	
	CPU1	CPU2	CPU1	CPU2
GPU1	7.411x	8.893x	4.813x	9.215x
GPU2	9.159x	10.474x	4.055x	7.764x
GPU3	17.957x	21.548x	9.941x	19.031x

Tablo 3'te verilen karşılaştırma sonuçlarından görüleceği üzere artan kopyalama maliyetlerine rağmen dönüşüm performansının, ilk işlemciye kıyasla 1024x1024 boyutlu resim için 4.813, 4.055 ve 9.941 kat, ikinci işlemciye kıyasla ise 9.215, 7.764 ve 19.031 kat hızlandığı görülmüştür. Kopyalama maliyetlerinin çekirdek çalışma sürelerine dahil edilmediği durumlarda ise 1024x1024 boyutlu resim için dönüşüm performansı ilk işlemciye kıyasla 6.093, 9.224 ve 43.619 kat hızlandırılmıştır.

## 5. Sonuçlar

İki boyutlu ayrık Haar dalgacık dönüşümün CUDA platformu ile grafik işleme birimlerine aktarıldığı bu çalışmada, grafik kartlarının uygun problem ve paralelleştirme senaryoları altında çalışma sürelerini seri eşdeğerlerine kıyasla oldukça azalttığı farklı üretici firmalara ait grafik kartları kullanılarak tespit edilmiştir. Elde edilen sonuçlardan yola çıkılarak, birden fazla grafik kartı barındıran sistemler üzerinde farklı paralelleştirme senaryoları kullanılarak resim verileri üzerinde dönüşüm için geçen sürelerin daha da kısaltılabileceği öngörülmektedir. Paralel senaryolardan verinin parçalanıp grafik kartlarına aktarılması şeklinde modellenenlerinin kopyalama maliyetlerini de azaltacağı dikkate alındığında daha büyük boyutlu resim verileri üzerinde oldukça kısa sürelerde istenilen seviyelerde dönüşüm gerçekleştirilebileceği söylenebilir.

## 6. Kaynaklar

- [1] R. Polikar, "The Story of Wavelets", Physics and Modern Topics in Mechanical and Electrical Engineering, N. Mastorakis (Eds.), World Scientific and Electrical Engineering Society, 1999.
- [2] P. Porwik, A. Lisowska, "The Haar-Wavelet Transform in Digital Image Processing: Its Status and Achievements", Machine Graphics & Vision, 2004, s. 79-98.
- [3] K.H. Talikder, K. Harada, "Haar Wavelet Based Approach for Image Compression and Quality Assessment of Compressed Image", International Journal of Applied Mathematics, 2007, s. 1-9.
- [4] T.T. Wong, C.S. Leung, P.A. Heng ve J. Wang, "Discrete Wavelet Transform on Consumer-Level Graphics Hardware", IEEE Transactions on Multimedia, 2007, s. 668-673.
- [5] C. Tenllado, J. Setoain, M. Prieto, L. Pinuel ve F. Tirado, "Parallel Implementation of the 2D Discrete Wavelet Transform on Graphics Processing Units: Filter Banks versus Lifting", IEEE Transaction on Parallel and Distributed Systems, 2008, s. 299-310.
- [6] J. Franco, G. Bernabe, J. Fernandez ve M.E. Acacio, "A Parallel Implementation of the 2D Wavelet Transform Using CUDA", 17th Euromicro International Conference Parallel, Distributed and Network-based Processing, Weimar, 2009, s. 111-118.
- [7] W.J. Van der Laan, A.C. Jalba, B.T.M. Roerdink, "Accelerating Wavelet Lifting on Graphics Hardware Using CUDA", IEEE Transactions on Parallel and Distributed Systems, 2011, s. 132-146.
- [8] NVIDIA, NVIDIA CUDA C Programming Guide V. 5.5, NVIDIA Corporation, 2013.
- [9] NVIDIA, NVIDIA CUDA C Best Practices Guide V. 5.5, NVIDIA Corporation, 2013.
- [10] S. Cook, CUDA Programming A Developer's Guide to Parallel Computing with GPUs, Morgan Kauffmann, 2013.

**YAZAR L STES**

<b>Yazar Adı</b>	<b>Sayfa Numarası</b>
A. Co kun SÖNMEZ	62
A. Cüneyd TANTU	18
A. Serdar TA AN	72
A. Ye im YAYLA	206
Abdullah Erhan AKKAYA	6
Adil BAYKASO LU	71, 72, 91, 102, 171
Ahmet GÖKDO AN	192
Ali KANDEM R	113
Ali NAR N	1, 97
Alırza YAVUZ	92
Alper BA TÜRK	219
Alper BAYRAK	218
Alper ÇALI KAN	210
Alper HAMZADAYI	171
Apdullah YAYIK	159
Aslıhan KARTÇI	73
Aysun GÜRAN	151
Ay egül GÜVEN	132
Banu D R	18, 31, 81
Begüm ÇEK RGE	49
Beyza Nur KÖKÇÜ	200
Bilal Ç MEN	136
Burcu FELEKO LU	72
Bülent BOLAT	141
Bülent URUL	27
Bü ra KAYA	182
Cengiz CANER	214
Cevahir PARLAK	31
Cüneyt GÜZEL	vii
Demet YILMAZ	22
Derman AKGÖL	58
Derya B RANT	49
Dilara BOZYILAN	117
E. Ye im ZORAL	196
Ebru DURMU	44
Enver TATLICIO LU	218
Eray YILDIZ	18
Erman AKTÜRK	58
Esen YILDIRIM	122, 136, 159
Ezgi ZORARPACI	86
Fadime ÖZER	182
Faruk BULUT	62, 103, 117, 200

Fatih Cemal CAN	163
Fatma Selen MADENO LU	91, 171
Fehmi Burçin ÖZSOYDAN	71
Fethullah KARAB BER	167
Fırat DO AN	218
Filiz ENYÜZLÜLER	102
Gizem DURSUN	182
Gökhan ALTAN	159
Gözde ÖZSERT	54
Gülay AYDO DU	182
Hasan BADEM	219
Hayrettin EN	163
Hüseyin ATASOY	136
brahim TÜRKÖ LU	35
lker GÖLCÜK	91, 171
smail H. ALTA	128, 146, 176
James GEORGE	54, 58
Kazım HANBAY	35
Kür at ÜNLÜH ZARCI	132
M. Burak BÜYÜKCAN	214
M. Fatih AMASYALI	62, 103, 200
M. Mine ENYÜZ	72
Mahmut ÖZER	1, 97
Mahmut S NECEN	214
Mehmet Ali DUR AY	155
Mehmet Emin DEN Z	155
Mehmet Emre ÇEK	92
Mehmet Erdal ÖZBEK	172
Mehmet Fatih AKAY	54, 58
Mehmet HACIBEYO LU	40
Mehmet Mert TAYGUR	196
Mehmet SALTAN	107
Melike ÇA LAYAN	49
Melike TUTKAN	77
Merve Ayyüce KIZRAK	141
Miray ALTINKAYNAK	132
Mitat UYSAL	151
Muhammed Fatih TALU	6
Murat Can GAN Z	77
Murat EK NC	192
Murat KARAKOYUN	40
Mustafa AÇIKKAR	54
Mustafa Alper SELVER	196
Mustafa YEN AD	67

Mücahit ÇALI AN	35
Nazan DOLU	132
Nihat MOROVA	107
Nihat PAMUK	12
Nuran YÖRÜKEREN	146, 176
Nurhan DUDAKLI	72
Nurhan Gürsel ÖZMEN	44
Okan ERKAYMAZ	97
Olca AKAY	92
Onur ULUSOY	155
Özge DO RUSÖZ	151
Özkan B NGÖL	192
Özlem TERZ	22
Pelin YILDIRIM	49
Rembiye KANDEM R	113
Rukiye Dilruba KÖSE	200
Selçuk ASLAN	219
Selim AKYOKU	77
Selma Ay e ÖZEL	86
Serdal TERZ	107
Serdar YILDIRIM	122, 136, 159
Serhat DUMAN	146, 176
Server Göksel ERALDEM R	122
Sibel Ç MEN	210
eyda TOPALO LU	102
Tahsin BAYKAL	22
Tayyip ÖZCAN	219
Tolgay KARA	155
Tülay YILDIRIM	73, 210
Ufuk ÖZKAYA	182, 187
Vecdi Emre LEVENT	167
Yahya DANAY YEN	128
Yakup KUTLU	67, 122, 136, 159
Yalçın LER	1, 97
Yavuz CENG Z	27
Yunus DURSUN	187
Zehra Gülru ÇAM	73
Zeynep Banu ÖZGER	81
Zeynep KARAL	206
Zhaleh SADREDD N	44