

Ocak'24

Sayı/Number: 1 / Volume: 14
Yıl/Year: 2024

Yayın Sahibi

TMMOB
Elektrik Mühendisleri Odası Adına
Mahir ULUTAŞ

Sorumlu Yazı İşleri Müdürü

Eylem ÖLMEZOĞLU

Yayın İdare Merkezi

Ihlamur Sokak No:10 Kat:3
Kızılay - Ankara
Tel: (312) 425 32 72
Faks: (312) 417 38 18
<http://bilimseldergi.emo.org.tr>
bilimseldergi@emo.org.tr
EMO Üyelerine parasız dağıtılır

Dergi Koordinatörü

Sevgi Kinacı
sevgi.kinaci@emo.org.tr

Sayfa Düzeni

TMMOB
Elektrik Mühendisleri Odası

Yayın Türü

Yerel Süreli Yayın
6 ayda bir yayınlanır

Basım Adedi

500

Basım Tarihi

Ocak 2024

EMO BİLİMSEL DERGİ

Elektrik, Elektronik, Bilgisayar, Biyomedikal
Mühendisliği Bilimsel Dergisi

The Journal of Electrical, Electronics, Computer and
Biomedical Engineering

YAYIN KURULU

BAŞ EDİTÖR/EDITOR IN CHIEF

Prof. Dr. Timur Aydemir
Kadir Has Üniversitesi

EDİTÖRLER/EDITORIAL BOARD

Prof. Dr. Erhan Akın
Fırat Üniversitesi

Prof. Dr. Güven Önbilgin
Ondokuz Mayıs Üniversitesi

Prof. Dr. Arif Nacaroğlu
Gaziantep Üniversitesi

Prof. Dr. Özlem Özgün
Hacettepe Üniversitesi

Prof. Dr. Muhittin Gökmen
MEF Üniversitesi



TMMOB

Elektrik Mühendisleri Odası

UCTEA/Chamber of Electrical Engineers

EMO Bilimsel Dergi Danışma Kurulu

Prof. Dr. A. Hamit Serbest	Çukurova Üniversitesi
Prof. Dr. Altay Güvenir	Bilkent Üniversitesi
Prof. Dr. Cengizhan Öztürk	Boğaziçi Üniversitesi
Prof. Dr. Erhan Akın	Fırat Üniversitesi
Prof. Dr. Güven Önbilgin	Ondokuz Mayıs Üniversitesi
Prof. Dr. Murat Eyüboğlu	Orta Doğu Teknik Üniversitesi
Prof. Dr. Timur Aydemir	Kadir Has Üniversitesi
Prof. Dr. Ali Hikmet Doğru	Orta Doğu Teknik Üniversitesi
Prof. Dr. Arif Nacaroğlu	Gaziantep Üniversitesi
Prof. Dr. Atilla Bir	Fatih Sultan Mehmet Vakıf Üniversitesi
Prof. Dr. Aydın Köksal	Bilişim A.Ş.
Prof. Dr. Aydoğan Özdemir	İstanbul Teknik Üniversitesi
Prof. Dr. Aysin Baytan Ertüzün	Boğaziçi Üniversitesi
Prof. Dr. Belgin Turkey	İstanbul Teknik Üniversitesi
Prof. Dr. Bülent Sankur	Boğaziçi Üniversitesi
Prof. Dr. Cüneyt Güzeliş	Yaşar Üniversitesi
Prof. Dr. Erdal Panayırıcı	Kadir Has Üniversitesi
Prof. Dr. Erkan Afacan	Gazi Üniversitesi
Prof. Dr. Ferit Acar Savacı	İzmir Yüksek Teknoloji Enstitüsü
Prof. Dr. H. Bülent Ertan	Orta Doğu Teknik Üniversitesi
Prof. Dr. Haldun Karaca	Dokuz Eylül Üniversitesi
Prof. Dr. İbrahim Eksin	İstanbul Teknik Üniversitesi
Prof. Dr. İnci Çilesiz	İstanbul Teknik Üniversitesi
Prof. Dr. İrfan Karagöz	Gazi Üniversitesi
Prof. Dr. İsmail Hakkı Altaş	Karadeniz Teknik Üniversitesi
Prof. Dr. İsmail Hakkı Çavdar	Karadeniz Teknik Üniversitesi
Prof. Dr. Kemal Leblebicioğlu	Orta Doğu Teknik Üniversitesi
Prof. Dr. Lale Tükenmez Ergene	İstanbul Teknik Üniversitesi
Prof. Dr. Mithat İdemen	Okan Üniversitesi
Prof. Dr. Muhittin Gökmen	MEF Üniversitesi
Prof. Dr. Murat Aşkar	İzmir Ekonomi Üniversitesi
Prof. Dr. Müjde Güzelkaya	İstanbul Teknik Üniversitesi
Prof. Dr. Osman Eroğul	TOBB Ekonomi ve Teknoloji Üniversitesi
Prof. Dr. Oya Kalıpsız	Yıldız Teknik Üniversitesi
Prof. Dr. Özlem Özgün	Hacettepe Üniversitesi
Prof. Dr. Sermin Onaygil	İstanbul Teknik Üniversitesi
Prof. Dr. Tayfun Akgül	İstanbul Teknik Üniversitesi
Doç. Dr. Ahmet Hasan Koltuksuz	Yaşar Üniversitesi
Doç. Dr. Osman Abul	TOBB Ekonomi ve Teknoloji Üniversitesi
Bora Güngören	Portakal Teknoloji
Fikret Küçükdeveci	Kardinero Medikal
Hasan Ali Pazar	Siemens

İÇİNDEKİLER / CONTENTS

Elektrikli Araç Şarj Kümelerinin Çok Temsilcili Sistem Yaklaşımıyla Enerji Yönetimi ve Şarj Koordinasyonu <i>Energy Management and Charging Coordination of Electric Vehicle Charging Clusters with a Multi-agent System Approach</i> Gülen Akyün, Erdem Gümrükçü, Murat Yılmaz	7
Yeni Üretilen XLPE İzolasyonlu Tek Damarlı Bir Güç Kablosunun Kaçak Empedansının Hesabı <i>Calculation of the Leakage Impedance of a Newly Produced XLPE Insulated Single-Core Power Cable</i> Hakan Çanta, Reşat Mutlu, Rabia Korkmaz Tan	19
Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme <i>A Study on Deep Learning and Artificial Neural Network Models</i> Ercan Akın, Mustafa Ergin Şahin	27
EEG+YKS Tabanlı Beyin Bilgisayar Arayüzü Sistemlerinde Makine Öğrenme Tekniklerinin Kullanımına İlişkin İnceleme <i>Research on the Use of Machine Learning Techniques in EEG+YKS-Based Brain Computer Interface Systems</i> Ebru Ergün, Önder Aydemir, Onur Erdem Korkmaz	39
Derin Evrişimsel Sinir Ağ Mimarisi ve Zaman Frekans Gösterimini Kullanılarak Büyük Güçlü Motor Arızalarının Tespiti <i>Diagnosis of Large Power Motor Faults Using Deep Convolutional Neural Network Architecture and Time Frequency Representation</i> İlhan Aydın, Emrullah Aydın, Erhan Akın, Seyfullah Kaner	51
Muharip İHA'ların İnsanlı Savaş Uçaklarından Yönetilmesi İçin Gerekli Otonomi Seviyelerinin Belirlenmesi Üzerine Bir Araştırma <i>A Research On Determining The Autonomy Levels Necessary For Managing Combatant UAVs From Manned Combat Aircraft</i> Güray Kasapoğlu, Özer Demir, Halil Sert, Tolga Türkmen, Haluk Gözde, Serkan Kurt	61
Kalp Yetmezliği Tahmininin Kategorik Olarak Farklı Tip Makine Öğrenmesi Yöntemleri ile Uygulanmasına Yönelik Bir Değerlendirme Çalışması <i>An Evaluation Study on the Application of Heart Failure Prediction with Categorically Different Type Machine Learning Methods</i> İsmail Atacak	73
Panoramik Radyograflarda Diş Tiplerinin Sınıflandırılması İçin Derin Öğrenme Yöntemlerinin Karşılaştırılması <i>Comparison of Deep Learning Methods for Classification of Tooth Types in Panoramic Radiographs</i> Berrin Çelik, Mehmet Zahid Genç, Mahmut Emin Çelik	87

Elektrikli Araç Şarj Kümelerinin Çok Temsilcili Sistem Yaklaşımıyla Enerji Yönetimi ve Şarj Koordinasyonu

Energy Management and Charging Coordination of Electric Vehicle Charging Clusters with a Multi-agent System Approach

  
Gülen Akyün^{1, 2}, Erdem Gümrükçü², Murat Yılmaz¹

¹Elektrik-Elektronik Fakültesi/Elektrik Mühendisliği Bölümü
İstanbul Teknik Üniversitesi
akyun15@itu.edu.tr, myilmaz@itu.edu.tr

²Karmaşık Güç Sistemlerinin Otomasyonu Enstitüsü
RWTH Aachen Üniversitesi
erdem.guemruekcue@eonerc.rwth-aachen.de

Özet

Bu çalışmada çok sayıda şarj ünitesi içeren elektrikli araç şarj istasyonları gibi araçtan-her şeye (V2X) özellikli kümelenmiş sistemlerin enerji yönetimi için temsilci tabanlı bir yaklaşım sunulmaktadır. Önerilen yaklaşımla, şarj kümelerinin yerel yük dengeleme yeteneklerini artırmak ve tepe/ortalama güç oranını azaltmak amaçlanmaktadır. Çok temsilcili bu sistemde, her temsilci bir enerji üreticisi veya tüketicisini temsil etmektedir. Araçların park süresine ve mevcut/hedef şarj durumlarına (SOC) göre, bağlı oldukları şarj ünitelerinin rolü tüketici veya üretici olarak güncellenmektedir. Temsilciler, belirli zamanda talep ettikleri veya sağlayabilecekleri gücü hesaplamakta ve birbirleriyle müzakere etmektedirler. Bu kapsamda müzakere protokolü ayrıntılı olarak sunulmuş ve yaklaşımın yerel yük dengeleme performansını göstermek için benzetişimler gerçekleştirilmiştir. Ayrıca, yaklaşımın farklı durumlar için performansını değerlendirmek üzere rastgele senaryolar üzerinden değerlendirmeleri de yapılmıştır.

Anahtar kelimeler: Elektrikli araç, araçtan her şeye, şarj kümesi, yük dengeleme, çok temsilci sistem

Abstract

This paper presents an agent-based approach for energy management of vehicle-to-everything (V2X) featured clustered systems such as an electric vehicle (EV) charging stations with multiple charging units. The proposed approach, it is aimed to increase the local load balancing capabilities of the charger clusters and to reduce the peak/average power ratio. In the multi-agent system, each agent represents an energy producer or consumer. Depending on the charging duration of the vehicles and current/target state of charge (SOC), the role of the charger units is updated as consumer or producer. Agents calculate the power they demand or can provide at a specified time, and negotiate with each other. In this study, the negotiation protocol is explained in detail and simulations are made to show the local load-balancing performance of the approach. In addition, the approach is simulated for random scenarios to evaluate the performance for different situations.


Keywords: Electric vehicles, vehicle-to-everything, charger cluster, load-balancing, multi-agent system

1. Giriş

Geleneksel elektrik güç sistemlerinin yapısı, büyük güç üreticilerinden dağıtım şebekelerine oradan da tüketiciye hiyerarşik bir iletim olarak tanımlansa da günümüzde bu kavram yerel üreticiler ve depolama sistemleri ile değişmektedir. Enerji piyasasında dağıtık enerji kaynaklarının (DER) yaygınlaşması ve bilgi teknolojisindeki gelişmeler ile geleneksel güç sistemi anlayışı yerini yerelleştirilmiş konseptlere bırakmaktadır. Tüketicilerin aynı zamanda yerel üreticiler de olabildiği bu yaklaşım dağıtık üretim (DG) olarak adlandırılmaktadır. Bu kavram hem enerji tüketicileri hem enerji sistemi operatörleri hem de enerji politikası geliştiricileri için son 25 yılda süregelen en dikkat çeken kavramlardan biri olmuştur [1]. Buna paralel olarak, çeşitli DER'ler ve akıllı şebeke konsepti içeren bir enerji dağıtım şebekesi anlayışına doğru bir yönelim vardır [2]. Diğer taraftan ulaşımında elektrifikasyon, akıllı şebekeye entegre şekilde DER olarak çalışabilecek elektrikli araçlara da (EV) işaret etmektedir. EV'ler, güç esneklikleri sayesinde şebekeye mobil ve dağıtılmış bir enerji depolama sistemi görevi görebilir ve yerel yükler için güç sağlayabilirler [3, 4]. Şekil 1'de araçtan şebekeye (V2G) ve şebekeden araca (G2V) güç akışı sistemi ve temel birimleri gösterilmiştir.

Elektrikli araçlar elektrik dağıtım şebekesi için bir yük olmanın yansıra enerji depolama olanağı da sağlayabilmektedir. Çift yönlü enerji akışına olanak veren batarya şarj sistemleri ve şarj/deşarj zamanlamasının kontrol edildiği akıllı şarj sistemleriyle beraber mevcut enerji üretim ve dağıtım kapasitesi daha güvenilir ve verimli kullanılabilirken, şebekenin güç dağılımını ve dolayısıyla tasarımını etkileyecek etkileşimler ortaya çıkmaktadır. Bu kapsamda VOG (kontrolsüz şarj, prize takıldığı anda şarj), V1G (akıllı şarj), V2G (şarj/deşarj), V2B (şebekeyle etkileşimsiz araçtan binaya), V2H (şebekeyle etkileşimsiz araçtan eve), V2X (araçtan her şeye – yayaya V2P, araca V2V, alt yapıya V2I, buluta V2C) bağlantılı mobilite (CM) olarak tanımlanan yapılar ve özellikleri Tablo 1'de verilmektedir.

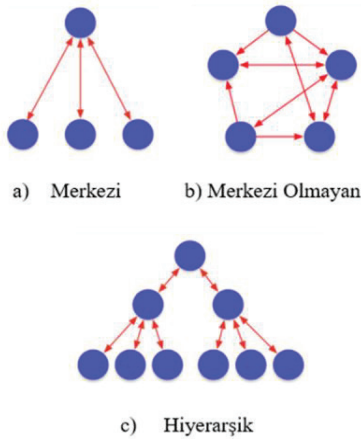
V2G teknolojilerinde enerji akışının çift taraflı olması gibi veri akışı da çift yönlüdür. Şebeke ve elektrikli araçlar arasında veri aktarımı karmaşık bir iletişim yapısına neden olur. EV toplu



Şekil 2: Vadi Doldurma ve Tepe Tıraşlama

Elektrikli araçlar gibi depolama sistemleri ve yenilenebilir enerji gibi yeni nesil enerji kaynakları ile şebekedeki birçok unsurun enerji akışını izlemek ve kontrol etmek için bir enerji yönetim sistemine (EMS) ihtiyaç duyulmaktadır. EV şarj kümeleri için EMS hedefleri belirlenirken, ekonomik, çevresel veya teknik faktörlerin yanı sıra kullanıcının menfaatleri de dikkate alınmaktadır. Ekonomik temelli bu hedefler doğrultusunda kontrol yönteminin mimari yapısı belirlenir ve tepe yükün en aza indirilmesi veya yük profilinin düzleştirilmesi gibi amaçlara dayalı algoritmalar geliştirilir. Bu kapsamdaki çeşitli araştırmalar çok etmenli sistemler, markov zincirleri, stokastik algoritma gibi stratejiler kullanılmaktadır. Ayrıca Konveks optimizasyon, Dinamik optimizasyon, Oyun teorisi, Genetik algoritma (GA), Parçacık sürüşü optimizasyonu (PSO) gibi bazı araçlar enerji yönetim sistemi problemlerini çözmek için sıkça kullanılır [5].

EMS uygulamaları genel olarak bu kontrol mimarilerine bağlıdır; merkezi ve merkezi olmayan olarak ayrılabilir. Hiyerarşik EMS kavramı bazı çalışmalarda merkezi olmayan EMS yaklaşımı içinde yer alsa da yeni kaynaklarda bu yaklaşıma her iki mimari türünün avantajlarını birleştiren üçüncü bir yaklaşım olarak yer verilmektedir [13, 14]. Şekil 3'te bu mimarilerin yapısı gösterilmiştir.



Şekil 3: Enerji Yönetim Sistemi Mimarileri

Elektrikli araçlar yaygınlaştıkça, EV'lerin öngörülemez davranışları nedeniyle güç talebi yönetimi daha zor hale gelecektir. Bir EV filosundaki şarj süreçlerini temsil edebilecek etkili bir modele ihtiyaç vardır. Mets ve

Verschueren, yalnızca yerel yük sinyali aracılığıyla elde edilen yük bilgilerini gerektiren ve iletişim gerektirmeyen bir enerji yönetimi stratejisiyle küresel yük profilini düzleştirmeyi amaçlamıştır [8]. Sonuçlar global yük profilinde iyileşme vaat etse de kullanım kolaylığı tartışmalıdır. Elektrikli araç şarjı ile ilgili buna benzer birçok çalışma, bir operatörü EV şarjından sorumlu kılmaktadır. Ancak operatörün küresel hedeflerini ön planda tutan bu yaklaşım, V2X hizmetleri sağlayan EV kullanıcılarının memnuniyetini her zaman dikkate almamaktadır. Buna karşılık, son yayınlar her şarj cihazının hesaplama kabiliyetine sahip olduğunu varsayarak karar sürecini müzakere eden temsilci tabanlı bir şema önermektedir [15]. Literatürde, EV filolarının şarj kontrolünde temsilci tabanlı yaklaşım, yük dengeleme, frekans ve gerilim regülasyonu gibi çeşitli hedeflere ulaşmak için kullanılmıştır [16-21]. Temsilci tabanlı çalışmalardan elde edilen sonuçlar, EV kullanıcılarının menfaatleri açısından olumlu sonuçlar göstermektedir. Aljohani ve ark. Güney Florida'dan alınan geçmiş verilere dayalı olarak mikro şebeke işletmelerinde EV'lerin şarjına yönelik dinamik fiyatlandırma için çok temsilcili hiyerarşik bir mimari önermektedir [22]. Sonuçlar, diğer yöntemlere kıyasla şarj maliyetlerinde önemli bir düşüş olduğunu göstermektedir. Valogianni ve ark. hem EV araç sahiplerinin çıkarları hem de şebeke istikrarı hedeflerini bir araya getirerek çok temsilcili EV şarj koordinasyonu önermektedir [23]. Ancak, önerilen yaklaşım V2X'i desteklememektedir.

Bu çalışmada kümelmiş sistemlerde EV şarjını yönetmek ve bir EV kümesi içinde güç dengelemesi sağlamak için temsilci tabanlı bir enerji yönetim yaklaşımı önerilmiştir. Tepe gücün düşürülmesi dengeli ve verimli bir yük profili sağlayacak ve bu da şebeke kalitesini iyileştirecektir. Bu enerji yönetimi konsepti, SwarmGrid-X algoritmasının değiştirilmiş bir versiyonuna ve tüketici-üretici temsilcileri arasındaki bir müzakere protokolüne dayanmaktadır. Önceki SwarmGrid uygulamalarından farklı olarak, bu çalışmada uygulanan senaryolarda şarj üniteleri çift yönlüdür. Yani hem araçtan-şebekeye deşarj hem de şebekeden-araca şarj yapılabilmektedir. Ayrıca, şarj ünitelerine bağlı EV'lerin talep profilleri önceki senaryolarda aynı iken, bu çalışmada ele alınan senaryolarda EV'lerin şarj talepleri heterojendir ve şarj talep profilleri ve araçların esnekliği çeşitlidir. Bu nedenle, bu çalışmada ilham alınan algoritma bu ihtiyaçlara göre değiştirilmiş ve kümelmiş EV filosunun enerji yönetiminin taleplerine maliyet faktörü göz ardı edilerek uyarlanmıştır. 2. Bölüm'de enerji yönetim sistemleri karşılaştırmalı olarak ele alınmış ve önerilen yaklaşımın çıkış noktasından bahsedilmiştir. 3. Bölümde yaklaşımın detayları ve şarj kümelerine entegrasyonu ele alınmıştır. 4. Bölüm'de yaklaşımın benzetişim sonuçları üzerinde tartışılmış, 5. Bölümde ise sonuçlar açıklanmıştır.

2. EV Şarjı için Güç Akışı Kontrolü ve Enerji Yönetim Sistemi

Elektrikli araçların şebekeye entegrasyonu, şebeke bileşenlerinin ve ekipmanlarının aşırı yüklenmesine neden olabilecek bir ek güç talebi yaratır. Artan EV şarj talebi nedeniyle, transformatörler ve besleme kabloları gibi yerel dağıtım elemanları yüksek stres seviyesinden etkilenmektedir. Bu sorunları önlemek ve güç tedarikini sorunsuz bir şekilde sürdürmek için EV şarjını koordine etmek gerekmektedir. Hem dağıtım şebekesinin güvenliğini ve güvenilirliğini sağlamak

hem de EV şarj talebini en iyi şekilde karşılamak ve kullanıcı memnuniyetini sağlamak, EV şarjı için EMS ile mümkündür. EMS, güç sisteminin arz-talep dengesini korumak için enerji kaynakları arasındaki enerji akışını koordine etmektedir. Bu sayede yüklerin taleplerinin sürekli olarak karşılanması sağlanırken güç sisteminin güvenilirliği, kararlılığı ve verimi artırılır. EV şarjı için enerji yönetimi yaklaşımı belirlenirken, pik yükün azaltılması ve yük profilinin düzleştirilmesi gibi hedeflere bağlı olarak, şarj koordinasyon yöntemleri ve şarj algoritmaları geliştirilmektedir. EV şarj istasyonlarında güç akışını kontrol ederken merkezi ve merkezi olmayan koordinasyon yöntemleri ön plana çıkmaktadır.

Merkezi EMS yaklaşımında, bir merkezi birim veya toplayıcı şebeke kalitesi ve müşteri önceliklerini dikkate alacak şekilde optimum bütünsel çözümü elde etmeyi hedeflemektedir. Bu yaklaşım, tüm parametreleri dikkate alarak toplam işletme maliyetini düşürme açısından merkezi olmayan mimariye göre avantajlıdır. Öte yandan, tüm bilgiler tek bir birimde toplanarak analiz edildiğinden, birim sayısına bağlı olarak hesaplama yükü artar. Merkezi olmayan yaklaşım yönteminde ise herhangi bir merkezi kontrol birimine bağımlılık yoktur. Yerel birimler kendi planlarını oluşturarak diğer yerel birimlerle iletişim kurabilmektedir. Yardımcı bir merkezi birim bu planları bir araya getirebilir ancak karar verme yetkisi olmaz. Bu yaklaşımda, kullanıcı memnuniyeti ve elektrik fiyatı şarj kararını belirleyen en önemli faktörlerdir. Merkezi olmayan EMS, sunduğu operasyon esnekliği nedeniyle genişletilebilir uygulamalar için uygundur. Bununla birlikte, merkezi olmayan koordinasyonda, her EV'in talebi öncelikli olduğundan, genel sistem için optimum çözüm her zaman garanti edilemeyebilir.

Tablo 2: Enerji yönetim yaklaşımları

	Avantajlar	Dezavantajlar
Merkezi	<ul style="list-style-type: none"> Küresel optimizasyon Düşük işletme maliyeti Kolay implementasyon 	<ul style="list-style-type: none"> Müşteri gizliliğinin olmaması Karmaşık ve pahalı iletişim Yüksek hesaplama yükü Düşük genişletilebilirlik
Merkezi Olmayan	<ul style="list-style-type: none"> Daha yüksek müşteri gizliliği Dağıtılmış hesaplama yükü Yüksek genişletilebilirlik Daha yüksek tüketici kabulü Daha yüksek hata toleransı 	<ul style="list-style-type: none"> Daha yüksek işletme maliyeti Kesin optimizasyonda eksiklik Etkili iletişim sistemi ihtiyacı
Hiyerarşik	<ul style="list-style-type: none"> Daha yüksek genişletilebilirlik Daha yüksek güvenilirlik Yüksek doğruluk Güç kalitesiyle başa çıkma İşletme maliyetini yönetme EV filoları için uyarlanabilirlik Katmanlı kontrol 	<ul style="list-style-type: none"> Karmaşık kontrol Zor implementasyon

Merkezi ve merkezi olmayan mimarinin avantajlarını birleştiren üçüncü bir yapı olan hiyerarşik kontrol mimarisinde yerel kontrol birimleri ve bunlara bilgi sağlayan merkezi bir birim bulunmaktadır. Aslında hiyerarşik kontrol, birçok dolaylı ve doğrudan toplayıcıya bölünerek oluşturulan yapıları nedeniyle tam merkezi veya merkezi olmayan kontrol olarak sınıflandırılmamaktadır. Bu yapıda merkezi bir kontrolör ve ona bilgi sağlayan yerel kontrolörler bulunmaktadır. Sağladığı katmanlı yapı sayesinde merkezi mimarinin aşırı işlem yükünü ortadan kaldırırken, merkezi olmayan yapının global optimizasyon sağlamaması gibi dezavantajlara çözüm olabilir. Bu mimarinin handikabı herhangi bir seviyede hata olması durumunda bilgi aktarımının kesintiye uğrama potansiyelidir. Bu üç mimarinin avantajları ve dezavantajları Tablo 2'de karşılaştırılmalı olarak gösterilmiştir.

2.1. Temsilci Tabanlı Koordinasyon Yaklaşımı

Temsilci tabanlı yaklaşım veya çok temsilcili sistem (MAS), literatürde merkezi olmayan veya hiyerarşik koordinasyon altındaki alternatif bir tekniktir. MAS, iki veya daha fazla temsilcinin küresel ortak bir hedefe ulaşmak için kendi yerel hedeflerine ulaştığı bir sistemdir. Esnekliği ve genişletilebilirliği nedeniyle, bu yaklaşım dağıtım şebekesi uygulamalarında ve DER'lerde giderek daha fazla kullanılmaktadır [16, 17].

Temsilci tabanlı modelleme yaklaşımı, kararlarını yerel olarak veren birçok birimden oluşan bir yapının sistem davranışını, bileşenleri olan akıllı birimlerin birbiriyle ilişkisi üzerinden ifade etmeyi sağlar. Modelleme yapılırken tüm temsilciler aynı şekilde modellenirse de girdi ve çıktı parametreleri ve çevre koşulları farklı olabilir. Sistem modellemesini kolaylaştıran özelliklerden biri temsilcilerin tanımlanıp, modellenenilmesi ve daha sonra kopyalanarak çoğaltılabilmesidir. Ayrıca bu yaklaşımın en büyük avantajlarından biri de benzetişim sırasında bile temsilcilerin durumlarının dinamik olarak değişebilmesi, var olan temsilcilerin kaldırılması veya yeni temsilciler eklenerek sistemin sürekli güncellenebilmesidir. Bu nedenle temsilci tabanlı yaklaşım, uzun vadeli ve değişken senaryolar için çok uygundur. Temsilci tabanlı modelleme, temsilci tabanlı koordinasyon konseptlerinin enerji sistemlerinde bilgisayarlar aracılığıyla uygulamasını kolaylaştırır. Bunun için, modellenen davranışı benzetişim ortamında üretmeye yarayan yazılımların, temsilcilerin otonom kararlarını belirleyen bilgisayarlarda çalıştırılması yeterlidir. Temsilci tabanlı koordinasyon yaklaşımının bir başka avantajı da tek birimdeki bir arızanın sistemin geri kalanını etkilememesidir. Bu, sistemi potansiyel arızalara karşı daha dirençli hale getirmektedir.

Elektrikli araçların şarjı için enerji yönetiminde ise temsilci tabanlı yaklaşım, şarj cihazlarının veya EV'lerin temsilci olarak adlandırıldığı ve karar sürecinin merkezi bir yapıdan bağımsız olarak yürütüldüğü koordinasyonu temsil eder. Bu yaklaşımda öncelik genellikle kullanıcı memnuniyetini sağlamaktır. Temsilcilerin her biri, elektrikli araç şarjını yönetmek için gereken verileri bilir ve diğer temsilcilerle görüşebilir. Temsilci, yerel bilgi ve müzakereler sonucunda bir karar verebilir. Ancak bu durumda her temsilci kendi kararını vereceği için güvenilirlik açısından süreç sürekli tekrarlanmalıdır. Ayrıca sistemin genel durumunun iyiliği için

genellikle çok temsilcili olarak adlandırılan hiyerarşik mimariler kullanılabilir.

Dağıtık enerji kaynaklarının enerji yönetimi için umut vaat eden bir yöntem olarak görülen MAS, beraberinde birçok karmaşıklığı da getirmektedir. Temsilci sayısındaki artışla birlikte iletişim karmaşıklığının artması kaçınılmaz olacaktır. Buna bir çözüm olarak, Dähling ve diğerleri tamamen dağıtılmış ve hiyerarşik bir kontrole dayalı SwarmGrid-X konseptini önermektedir [24]. Temel olarak, Swarmgrid-X, Kolen ve diğerleri tarafından önerilen Swarmgrid [25] konseptinin genişletilmiş bir versiyonudur ve MAS tabanlıdır. Hem tüketici hem de üretici olarak hareket edebilen temsilciler, yerel hedeflerine ulaşmak için çalışma aralıklarını hesaplayarak esnekliklerini ortaya koymakta, birbirleriyle müzakere etmektedirler. Üniteler, içinde buldukları sürü adı verilen topluluk içindeki güç tüketimini aynı üretimle nötralize etmeye çalışırlar. Çalışmalar, yerel dengeleme üzerine yapılan benzetişimler, DER'lere uygun ve etkin bir enerji yönetimi sağlayabileceğini ve algoritmanın DER'lerin dağıtım şebekesine katılımına olumlu katkı sağlayacağını göstermektedir.

3. Temsilci Tabanlı Yaklaşımın Şarj Kümelerine Entegrasyonu

Çalışma kapsamında önerilen enerji yönetim yaklaşımı ve yazılım algoritması, kümelenecek EV şarj cihazlarına entegre edilmiştir. Yaklaşım, bir şarj ünitesinde bulunan her bir şarj ünitesinin, merkezi bir ünite olmaksızın birbiriyle anlaşması ve böylece şarj ünitesi içerisinde güç nötralizasyonu hedefine ulaşması amaçlanmış ve bu kapsamda önerilen yaklaşımın ayrıntıları ele alınmıştır. Bu yaklaşım tamamen merkezi olmayan yapısı ile temsilcilerin yerel hedefleri doğrultusunda sürü kontrolü sağlamaktadır. Temsilci davranışı, yerel bilgilere ve diğer temsilcilerle müzakerelerin sonucuna dayalı olarak temsilci tarafından belirlenmekte ve eyleme geçilmektedir. Temsilciler her zaman her temsilci ile iletişim kurmak zorunda değildir ve iletişim ortakları zaman içinde değişebilmektedir. Bununla birlikte, her temsilcinin belirli bir zaman diliminde belirli bir iletişim ortakları listesi vardır. Sürü davranışı, temsilciler arasındaki iletişim ve temsilcilerin bireysel kontrol davranışlarının bir sonucu olarak ortaya çıkmaktadır. Bu yaklaşımda, sistem operatörü müdahalesini en aza indirmesine ve yerel davranışa yüksek öncelik verilmesine rağmen, gerektiğinde sistem operatöründen gelen sinyallere öncelik verecek şekilde temsilci davranış kuralları tasarlanabilmektedir. Dağıtım şebekesi kontrolünün dağıtıldığı, yerel arızalara ve haberleşme sorunlarına karşı dayanıklılığının artırıldığı bu yaklaşımda, tek bir birim arızası durumunda sistem çalışır durumda olacaktır.

Bir şarj istasyonundaki her EV'in bağlı olduğu her bir şarj ünitesi (CU), hesaplama kabiliyetine sahip bir temsilcidir ve üretici veya tüketici olarak atanabilir. Temsilciler tarafından temsil edilen CU'lerin toleransları, EV'lerin şarj taleplerinin aciliyetine göre hesaplanır ve temsilciler, üretici veya tüketici olarak atanır. Daha sonra merkezi bir birimden bağımsız olarak diğer temsilcilerle iletişim kurarak sağlayabilecekleri veya talep ettikleri güçleri birbirlerine sunarlar. İki temsilci arasındaki görüşmeler sonucunda güç akışı başlar ve küme içinde güç nötralizasyonu sağlanmaya çalışılır.

Temsilciler arasındaki iletişimi yönetmek için Akıllı Fiziksel Temsilciler Kuruluşu (Intelligent Physical Agents Foundation-FIPA) standartlarında çeşitli görüşme protokolleri sunulmaktadır [26]. Bununla birlikte, çalışma kapsamında, gerçek dünyadaki uygulamada gerekli olabilecek kısıtlamalar dikkate alınmamıştır. Aynı şekilde gerekli iletişim altyapısına ilişkin veri alışverişinin de uygun ve güvenli bir şekilde yapıldığı varsayılmaktadır. Çalışma, yalnızca temsilci tabanlı yaklaşımı EV şarj kümelerine entegre etmenin fizibilitesini araştırmaktadır. Bu nedenle, odak noktası daha çok temsilciler arasındaki kontrol davranışı ve müzakere süreçleridir.

Birçok MAS tabanlı uygulamada, temsilcilerin yerel kontrol davranışı genel bir durum değişkeni olarak ayarlanır ve sistem davranışı tüm bu davranışların sonucudur. Ancak bu, anlaşma algoritmasında olası hatalar olması durumunda sistem davranışını tamamen yanıtlanabilir. Bu makalede ele alınan yaklaşımda ise kontrol davranışı tamamen yerel bilgilere ve sürü içindeki müzakerelere dayalıdır, hiçbir global değişken dikkate alınmaz. Bu şekilde DER'lere kontrol kararı yetkisi verilmektedir. Önerilen yaklaşımdaki sistem, mevcut elektrik şebekesiyle uyumlu esnek temsilci sürülerinin oluşturulmasına izin vermektedir.

3.1. Bir Temsilcinin Rolünün Belirlenmesi

Elektrikli araçların bağlı olduğu şarj ünitelerini temsil eden temsilcilerin rolü her bir zaman adımında güncellenmektedir. Her temsilci için iki rol seçeneği mümkündür:

- EV batarya paketinin şarj talebini karşılamak için üretici arayan bir tüketici,
- EV batarya paketini deşarj ederek başka bir EV batarya paketini şarj edebilen bir üretici.

Bir temsilcinin üretici veya tüketici olarak atanması şarjın belirli süre kesilmesine karşı toleransına bağlıdır. Daha yüksek toleransa sahip bir temsilci, daha esnek bir enerji kaynağı olduğundan üretici görevi görür. Bu tolerans değeri ve rol, temsilci tarafından temsil edilen EV'in mevcut ve hedef batarya SOC'sine ve park süresine göre belirlenir.

Denklem 1'de $m(t)$ olarak belirtilen parametre, temsilcinin t anındaki toleransıdır. Bu değer EV'in şarj talebine ve şarj cihazının gücüne ve talebin karşılanma hızına göre hesaplanır. $m(t)$ ile gösterilen anlık tolerans, her zaman adımında güncellenen dinamik bir değerdir.

$$m(t) = 1 - \frac{\frac{soc(t_h) - soc(t)}{P_s} E}{t_h - t} \quad (1)$$

$SOC(t_h)$ ve $SOC(t)$ parametreleri sırasıyla EV'in hedef ve mevcut şarj durumunu gösterir. E , EV bataryasının kWh cinsinden enerji kapasitesini ve P_s , şarj cihazının gücünü temsil eder. t_h parametresi ise EV'in tahmini kalkış zamanını göstermektedir.

Ayrıca, temsilcinin rolünü belirlemek üzere, 0 ile 1 arasında bir eşik değeri m_s belirlenir. Temsilcinin toleransının m_s değerinden büyük olması, EV'in hesaplanan zaman adımı için şarj gecikmesini tolere edebileceğini ve o süre içinde bataryasını boşaltabileceğini gösterir. Bu durumda temsilci V2X işlemini gerçekleştirebilen bir üretici rolü üstlenir. Öte yandan, m_s

eşiğinden düşük bir toleransa sahip bir temsilci tüketici temsilcisi olarak atanır. Denklem 2'de temsilci rolünün belirli bir eşiğe göre atanması gösterilmektedir.


$$rol = \begin{cases} \text{tüketici, } m(t) < m_\delta \\ \text{üretici, } m(t) \geq m_\delta \end{cases} \quad (2)$$

3.2. Bir Temsilcinin İşlem Aralığı

Aynı sürüdeki üretici ve tüketici arasındaki müzakere süreci başlamadan önce, her iki temsilci de aktif çalışma aralıklarını belirler. Bunun için tüketici temsilcisi t_1 'den t_2 süresine kadar (sözleşme süresi olarak) talep ettiği gücü, üretici temsilci ise bu süre zarfında sağlayabileceği gücü hesaplar. Tüketici temsilcinin, t_1 - t_2 zaman aralığında talep ettiği güç P_t Denklem 3'teki gibi hesaplanır. Burada $SOC_t(t_2)$ ve $SOC_t(t_1)$ sırasıyla tüketici temsilcinin hedef ve mevcut SOC'sini, E_t ise enerji kapasitesini temsil eder. EV bataryasının şarj gücü P_s şarj cihazının gücü kadar olabilir.

$$P_t = \min \left\{ P_s, \frac{(SOC_t(t_2) - SOC_t(t_1)) * E_t}{t_2 - t_1} \right\} \quad (3)$$

Üretici temsilci ise önce t_2 anında (kontratın sonunda) sahip olabileceği minimum SOC'yi, buna göre de t_1 - t_2 arasında verebileceği gücü hesaplamalıdır. Bunu açıklayabilmek için Şekil 4'te, iki EV'yi temsil eden biri üretici diğeri tüketici olarak atanan iki temsilcinin SOC değişimi basit bir örnek olarak gösterilmiştir. Sarı çizgi, t_1 zamanında üretici olarak atanan temsilciyi ve yeşil çizgi, t_1 zamanında tüketici olarak atanan temsilciyi temsil etmektedir. t_1 - t_2 zaman aralığında üretici temsilci bataryayı deşarj ederek tüketici temsilciyi şarj eder. Daha sonra kendi bataryasını (şebekeden veya başka bir araçtan) t_2 - t_3 aralığında şarj eder. Bu durumda üretici temsilcinin t_3 hareket anına kadar hedef SOC'ye ulaşabilmesi için t_2 anında sahip olması gereken minimum SOC'yi hesaplaması gerekir.



Şekil 4: Temsilcilerin SOC değişimleri

Denklem 4'te gösterildiği gibi, tüketici temsilcinin t_2 zamanındaki sahip olması gereken minimum SOC'si, tahmini kalkış zamanındaki hedef $SOC_u(t_h)$, şarj gücü P_s ve EV batarya paketinin kapasitesi E_u ile hesaplanır. Daha sonra üreticinin t_1 - t_2 zaman diliminde sağlayabileceği güç, Denklem 5'te ki gibi mevcut SOC $SOC_u(t_1)$, ve minimum SOC $SOC_u(t_2)$, ve batarya kapasitesi E_u 'ye göre hesaplanır. Üreticinin sağlayabileceği güç, şarj cihazının maksimum gücü kadar olabilir. Bu değerler her zaman aralığı için sürekli olarak hesaplanır.

$$SOC_u(t_2) = SOC_u(t_h) - \frac{P_s \cdot (t_h - t_2)}{E_u} \quad (4)$$

$$P_u = \min \left\{ P_s, \frac{(SOC_u(t_1) - SOC_u(t_2)) * E_u}{t_2 - t_1} \right\} \quad (5)$$

Bu hesaplamalar yapılırken kullanıcıların V2X işlemine katılma istekliliği hesaplamalara dahil edilmemiş, önerilen enerji yönetim yaklaşımının uygulanabilirliği için sadece teknik hesaplamalar yapılmıştır.

3.3. Müzakere Protokolü

Müzakereler her bir temsilcinin çalışma aralığına göre yapıldığından elektrikli araçların bireysel SOC hedefleriyle çelişmeyen sonuçlar üretilir. Müzakere sonucunda yerel güç dengelemesi de sağlandığı için küresel hedeflere de ulaşılmaktadır. Bu müzakereler her zaman iki temsilci arasında olmasına rağmen, bir temsilci aynı zaman adımı için birden fazla temsilci ile görüşebilmektedir. Müzakereyi her zaman bir tüketici başlatır. Tüketici temsilcisi, sürüsünde güç talebinin bir kısmını veya tamamını karşılayacak bir üretici arar. Güç talebine bağlı olarak, bir temsilcinin sürüsü büyüyebilir veya küçülebilir.


3.3.1. Dizin kolaylaştırıcısı

Dizin Kolaylaştırıcısı (DK), tüm kümelerdeki temsilcilerin dinamik olarak değişen bilgilerini bilen bir hizmet listesi veya sunucudur. Temsilcilerin türleri ve konumları, DK'de saklanan bilgilerdir. Üretici arayan tüketici temsilcilerine talep edildiğinde bilgi verebilmektedir, ancak herhangi bir karar verme yetkisi bulunmamaktadır. Ayrıca DK, kümedeki temsilcilerin diğer parametreleri hakkında bilgi sahibi değildir. Talebini karşılamak için daha fazla üreticiye ihtiyaç duyan veya sürüsünde üretici olmayan bir tüketici, DK'ya bir mesaj gönderir. DK belirtilen mesafede üretici temsilcileri bulur ve bilgilerini talep eden tüketici ile paylaşır. Bu durumda, her iki temsilci de birbirinin sürüsüne eklenir.

3.3.2. Temsilciler arasındaki sözleşmeler

Tüketici temsilci sürüsünde bulunan üretici temsilciye teklif çağrısı gönderir. Üretici belirtilen süre boyunca istenilen gücü sağlayabilecek ise bu çağrıya teklif ile karşılık verir; tüketici teklifi kabul eder ve sözleşme yapılır. Böylece müzakere tamamlanır ve güç akışı başlar. Aksi halde üretici tüketiciye ret mesajı gönderir ve tüketici yeniden arama sürecini başlatır. Tüketici temsilci talebinin sadece bir kısmını üreticiden karşılıyorsa sözleşme yapılır, ancak tüketici kalan talebi karşılamak için başka bir üretici daha arar. Bir temsilci aynı anda birden fazla temsilci ile sözleşme yapabilir. Bu müzakereler, her adımda güç talebine göre yeni parametrelerle sürekli olarak güncellenir. Tüketici talebinin tamamını veya bir kısmını üretici temsilcilerden karşılayamaması durumunda, kalan güç talebini şebekeden karşılar. Şekil 5'te temsilcilerin müzakere süreci akış diyagramıyla ayrıntılı olarak gösterilmiştir.

durumda (Şekil 5) tüketimin çok fazla ertelenmesi ardından tekrar piklere neden olmuştur.



Şekil 7: Kontrolsüz şarj ve $m_{\delta} = 0.75$ ile önerilen yaklaşım

Algoritmanın performansı, senaryo periyodu boyunca bağlı olan araçların taleplerine ve şarj sürelerine de bağlıdır. Bu nedenle, güç profilindeki iyileşme tüm kümelerde aynı değildir. Bir önceki bölümde detaylı olarak açıklandığı gibi, toleransı gösteren $m(t)$ değeri, temsilcinin rolünü belirler. Toleransı, belirlenen m_{δ} değerinin üzerinde olan temsilciler üretici olarak atanır. Farklı m_{δ} eşik değerleri için aynı benzetişim yapıldığında, Tablo 2'de verilen tepe ve ortalama değerler elde edilmiştir. Bu sonuçlar 10 kümenin tamamı yani tüm sistem için hesaplanmış ve m_{δ} 'nın 1 olduğu yani üreticinin olmadığı durumda karşılaştırılmıştır.

Tablo 3: Tepe/Ortalama Yük Karşılaştırması


	$m_{\delta}=1.00$	$m_{\delta}=0.75$	$m_{\delta}=0.50$	$m_{\delta}=0.25$
Tepe Yük (kW)	351.5	335.2	357.1	379.3
Ortalama Yük (kW)	150.5	150.5	150.5	150.5
Tepe/Ortalama	2.33	2.22	2.37	2.52

Tablo 3'de görülebileceği gibi, algoritmanın m_{δ} tolerans değerine bağlı olduğu açıktır. Daha yüksek bir m_{δ} değeri için, temsilcileri üretici olarak atamak daha zordur. Bu durumda, $m_{\delta}=1$ değeri, hiçbir temsilcinin üretici olmadığı ve V2X işleminin olmadığı kontrolsüz durumla aynıdır. Aksine, m_{δ} tolerans eşliğinin daha küçük olması durumunda, daha fazla temsilci üretici olarak atanır, yani V2X'e daha fazla EV katıldığı için yerel güç dengelemesi sağlanır. Bu durumda kümedeki pik yüklerin daha da azalması beklenecektir. Ancak, tablodan da görülebileceği gibi, daha düşük bir m_{δ} değeri seçmek her zaman daha düşük bir tepe gücü ile sonuçlanmaz. Örneğin $m_{\delta} = 0.75$ için ölçülen tepe güç 335 kW iken, simülasyonlarda $m_{\delta} = 0.5$ eşik değerinde daha yüksek tepe güçler ölçülmüştür ve bu tepe güçlerin kontrolsüz durumdaki güç değerinden bile yüksek olduğu görülmektedir. Bu yüksek tepe değerlerinin nedeni, Şekil 7'te gösterildiği gibi farklı bir kümenin (7. küme) güç profilinden bir örnek verilerek açıklanmaktadır.

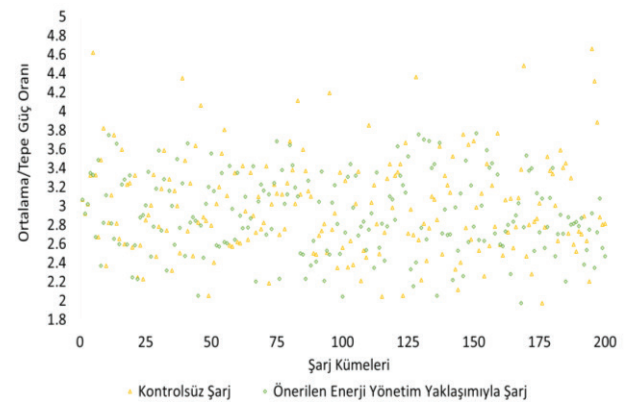
Küçük bir m_{δ} değeri seçmek, t zamanında daha fazla temsilcinin üretici olmasına neden olur ve bunlar diğer EV'leri T zamanında şarj eder. Ardından, $t+T$ 'de kendilerini tüketici olarak şarj

etmeleri gerekir. Bu durumda şarjı $t+T$ zamanına ertelenen EV sayısı çok daha fazla olacak ve $t+T$ zamanında çok yüksek pik talepleri görülecektir. Bunun en dramatik örneği 7. kümenin güç profilinde görülmektedir. $m_{\delta} = 0.25$ tolerans değeri ile gerçekleştirilen benzetişimde, benzetişimin başında ertelenen şarj talebinin daha sonra nasıl bir pik talep ile sonuçlandığı açıkça görülmektedir.

EV'lerin varış süreleri, mevcut ve hedef SOC'leri ve park etme süreleri gibi senaryodaki birçok öngörülemez değişkenin etkisi de çok önemlidir. Yüksek pik taleplerden kaçınmak için, kümelerin ve sistemin geçmiş güç talep profillerine dayalı olarak bir tahmin yapılabilir ve bir kontrol algoritması geliştirilebilir. Bu şekilde, bu rastgeleliğin neden olabileceği olası sorunların önüne geçilebilir. Tahminlerden yola çıkılarak her t anına farklı m_{δ} değeri atanırsa, güç talebinin eş zamanlı olması durumunda daha fazla üretici atanabilir ve doğru zamanda V2X modu ile çok daha iyi dengeleme yapılabilir. Temsilci tabanlı yaklaşımın farklı senaryolardaki performansını değerlendirmek için, 20 farklı senaryoda 10 farklı şarj cihazı kümesinin tepe-ortalama oranı dağılımı Şekil 8'de gösterilmektedir.



Şekil 8: $m_{\delta} = 0.25$ ile önerilen yaklaşım ve şarjın ertelenmesi (7. Küme)



Şekil 9: 20 farklı senaryoda 10 farklı şarj ünitesinin tepe/ortalama oranı dağılımı

Yeşil noktalar kontrolsüz durumdaki, turuncu noktalar ise enerji yönetimi yaklaşımı uygulandığındaki sonuçları göstermektedir. EV'lerin varış ve kalkış saatleri, hedef ve mevcut SOC gibi senaryodaki belirsizlikler, enerji yönetimi yaklaşımı uygulandığında sonucun her zaman daha iyi çıkmasıyla sonuçlanmayabilir. Ancak senaryoların çoğunda temsilci tabanlı enerji yönetimi performansının daha iyi sonuçlar verdiği gözlemlenmektedir. Kontrolsüz durumda

benzetişimlerde tepe-ortalama oranı 4.65'e kadar yükselirken, önerilen yaklaşımla en fazla 3.76 olduğu görülmektedir.

Diğer taraftan, önceki kısımdaki değerlendirmelerden farklı olarak tolerans eşiği m_s ve diğer değişkenler dikkate alınmadan algoritmanın hesaplama performansı test edildiğinde ve çözüme yakınsama için gereken süre kümedeki temsilci sayısı artırılarak hesaplandığında senaryodaki temsilci sayısı 125'ten az ise çözümün 60 saniyede yakınsayabileceği görülmektedir. Bu pratik bir uygulama için önemlidir. Bu nedenle ölçeklenebilirlik eşiği olarak 60 saniyelik bir süre seçilebilir. Temsilci sayısındaki artış daha fazla müzakere ile sonuçlandırıldığı için hesaplama süresi de buna paralel olarak artmaktadır. Ancak küme sayısındaki artış bu yayındaki uygulama kapsamında herhangi bir değişikliğe neden olmamaktadır. Bunun nedeni müzakerelerin sadece küme içinde gerçekleşmesidir. Bu nedenle kümelerin paralel yürüttüğü bu işlemler ek bir hesaplama yüküne neden olmaz.

5. SONUÇLAR

Bu çalışmada, temsilci tabanlı bir enerji yönetimi algoritması, kümelendirilmiş EV şarj sistemleri için uyarlanmış ve geliştirilen yazılım algoritması ile uygulanmıştır. Önerilen yaklaşımda, şarj cihazlarına bağlı EV'lerin şarj taleplerinin aciliyetine ve algoritmadaki tolerans eşiğine bağlı olarak, şarj ünitelerini temsil eden temsilcilere üretici veya tüketici rolü atanmaktadır. Tüketici rolündeki temsilciler, DK adlı bir sunucu aracılığıyla üreticilerin bilgilerini alır, sürülerine ekler ve müzakere eder. Müzakere bir sözleşmeyle sonuçlanırsa, güç akışı belirtilen sözleşme süresi üreticiden tüketiciye sağlanır. Müzakere sürecinde maliyet faktörü katılımcılar tarafından gözlenmez. Çalışma kapsamındaki performans değerlendirmesi, bu yaklaşım her biri 12 şarj üniteli 10 şarj kümesinden oluşan bir sisteme uygulanarak yapılmıştır. Kontrolsüz çalışmanın ve önerilen yaklaşımın güç profilleri karşılaştırılmıştır. Uygun tolerans eşiği yani m_s seçimiyle, temsilcilerin üretici veya tüketici olarak V2X'e katılarak, önerilen temsilci tabanlı yaklaşımın bir kümenin tepe-ortalama oranını %41'e kadar azalttığı gösterilmiştir. Bu yaklaşımla yapılan benzetişimler sonucunda, EV'lerin yalnızca tüketici olmaktan çıkıp V2X ile yerel elektrik üreticisi haline gelmesinin şarj kümelerinin güç profili üzerinde olumlu bir etkisi gözlemlenmiştir. Öte yandan farklı tolerans değerlerinin algoritmanın performansı üzerindeki etkisi de ele alınmıştır.

Temsilci olarak adlandırılan birimlerin sınırlı yerel bilgi ile yeterli kontrol kararları alabildiği gözlemlenmiştir. Temsilciler, merkezi bir kontrol ünitesine ihtiyaç duymadan ve sistem ya da küme bilgisi olmadan bireysel hedefleri doğrultusunda küme içerisindeki güç talebini karşılayabilirler. Temsilciler, literatürdeki diğer yaklaşımlara kıyasla çok az iletişim yükü ile birbirleriyle müzakere ederek güç alışverişinde bulunabilirler. Bu durum, herhangi bir merkezi kontrol olmaksızın temsilci tabanlı bir yaklaşımın uygulanabilirliğini göstermektedir.

Diğer taraftan, şarj ünitelerine bağlı EV'lerin profili diğer birçok uygulamada aynı iken, bu çalışmada EV'lerin şarj talepleri değişkendir ve EV'lerin V2X için toleransı da değişkendir. Benzetişim süresi boyunca bir şarj ünitesine bağlı EV'lerin sayısı, EV'lerin varış ve hedef SOC'leri tamamen rastgeledir. Bu, herhangi bir senaryoda, farklı EV'lerin bağlı olduğu bir şarj ünitesinin rolünün, her zaman adımında güncellendiği anlamına gelir. Bu enerji yönetim algoritması ile

önceki çalışmalardan farklı olarak çift yönlü şarj işlemi ele alınmaktadır. Böylece V2X fonksiyonlarının en etkin şekilde kullanılması ve EV'lerin boşta kaldıkları sürelerde verimli bir şekilde kullanılması amaçlanmaktadır. V2X işlevi sayesinde, kümelerdeki tepe güç talebi ve şarj ünitelerinin aşırı yükü azaltılmıştır.

Gelecekteki çalışmalar için, küme içindeki bu güç dengelemesinin kümeler arasında da yapılabilmesi için her bir kümenin toplam davranışını temsil eden temsilcilerin atanması önerilebilir. Bu sayede küme içerisinde talebin karşılanmaması durumunda doğrudan şebekeden talep etmek yerine başka bir kümeden güç talebinde bulunabilecektir. Ancak, böyle bir uygulamada, kümeler arasındaki anlaşmanın hesaplama yükü de dikkate alınmalıdır. Yapılabilecek diğer bir iyileştirme, tolerans eşiği değerini her t zaman adımı için dinamik hale getirerek, kümelerin talebine ve kümedeki EV'lerin değişkenliğine bağlı olarak uyum sağlayabilecek şekilde geliştirmektir. Böylece tepe yükler en aza indirilebilir ve yük profili düzleştirilebilir.

6. Kaynaklar

- [1] Lopes, J.P., Hatzigaryriou, N., Mutale, J., Djapic, P. and Jenkins, N. (2007). Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities, *Electric power systems research*, 77(9), 1189–1203.
- [2] Kong, Q., Fowler, M., Entchev, E., Ribberink, H. and McCallum, R. (2018). The role of charging infrastructure in electric vehicle implementation within smart grids, *Energies*, 11(12), 3362.
- [3] Taljegard, M., Göransson, L., Odenberger, M. and Johnsson, F. (2019). Electric vehicles as flexibility management strategy for the electricity system—A comparison between different regions of Europe, *Energies*, 12(13), 2597.
- [4] S. Saxena, H. E. Z. Farag, L. S. Hilaire and A. Brookson, "A Techno-Social Approach to Unlocking Vehicle to Everything (V2X) Integration: A Real-World Demonstration," in *IEEE Access*, vol. 11, pp. 17085–17095, 2023,
- [5] Hussain, M.T., Sulaiman, N.B., Hussain, M.S. and Jabir, M. (2021). Optimal Management strategies to solve issues of grid having Electric Vehicles (EV): A review, *Journal of Energy Storage*, 33, 102114.
- [6] R.J., Matos, M.A., Soares, F.J. and Lopes, J.A.P. (2011). Optimized bidding of a EV aggregation agent in the electricity market, *IEEE Transactions on Smart Grid*, 3(1), 443–452.
- [7] Abdullah, H.M., Gastli, A. and Ben-Brahim, L. (2021). Reinforcement learning based EV charging management systems—a review, *IEEE Access*, 9, 41506–41531.
- [8] Mets, K., Verschueren, T., Haerick, W., Develder, C. and De Turck, F. (2010). Optimizing smart energy control strategies for plug-in hybrid electric vehicle charging, 2010 IEEE/IFIP network operations and management symposium workshops, IEEE, pp.293–299.
- [9] Yılmaz, M. and Krein, P.T. (2012). Review of the impact of vehicle-to-grid technologies on distribution systems and

- utility interfaces, *IEEE Transactions on power electronics*, 28(12), 5673–5689.
- [10] Pearre, N.S. and Ribberink, H. (2019). Review of research on V2X technologies, strategies, and operations, *Renewable and Sustainable Energy Reviews*, 105, 61–70.
- [11] Ravi, S.S. and Aziz, M. (2022). Utilization of electric vehicles for vehicle-to-grid services: progress and perspectives, *Energies*, 15(2), 589.
- [12] Hou, L., Dong, J., Herrera, O. E., & Mérida, W. (2023). Energy management for solar-hydrogen microgrids with vehicle-to-grid and power-to-gas transactions. *International Journal of Hydrogen Energy*, 48(5), 2013-2029.
- [13] Rathor, S.K. and Saxena, D. (2020). Energy management system for smart grid: An overview and key issues, *International Journal of Energy Research*, 44(6), 4067–4109.
- [14] Cheng, Z., Duan, J. and Chow, M.Y. (2018). To centralize or to distribute: That is the question: A comparison of advanced microgrid management systems, *IEEE Industrial Electronics Magazine*, 12(1), 6–24.
- [15] Yin, H., Alsabbagh, A. and Ma, C. (2021). A decentralized power dispatch strategy in an electric vehicle charging station, *IET Electrical Systems in Transportation*, 11(1), 25–35.
- [16] Ringler, P., Keles, D. and Fichtner, W. (2016). Agent-based modelling and simulation of smart electricity grids and markets—a literature review, *Renewable and Sustainable Energy Reviews*, 57, 205–215.
- [17] Unda, I.G., Papadopoulos, P., Skarvelis-Kazakos, S., Cipcigan, L.M., Jenkins, N. and Zabala, E. (2014). Management of electric vehicle battery charging in distribution networks with multi-agent systems, *Electric Power Systems Research*, 110, 172–179.
- [18] Mureddu, M., Scala, A., Chessa, A., Caldarelli, G., Musio, M. and Damiano, A. (2014). An agent based approach for the development of EV fleet Charging Strategies in Smart Cities, 2014 IEEE International Electric Vehicle Conference (IEVC), IEEE, pp.1–8.
- [19] Saner, C.B., Trivedi, A. and Srinivasan, D. (2022). A Cooperative Hierarchical Multi-Agent System for EV Charging Scheduling in Presence of Multiple Charging Stations, *IEEE Transactions on Smart Grid*, 13(3), 2218–2233.
- [20] Garau, M. and Torsæter, B.N. (2021). Agent-Based Analysis of Spatial Flexibility in EV Charging Demand at Public Fast Charging Stations, 2021 IEEE Madrid PowerTech, IEEE, pp.1–6.
- [21] Mocci, S., Natale, N., Ruggeri, S. and Pilo, F. (2014). Multi-agent control system for increasing hosting capacity in active distribution networks with EV, 2014 IEEE International Energy Conference (ENERGYCON), pp.1409–1416.
- [22] Aljohani, T., Ebrahim, A. and Mohammed, O. (2020). Dynamic real-time pricing structure for electric vehicle charging considering stochastic microgrids energy management system, 2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe), pp.1–8.
- [23] Valogianni, K., Ketter, W. and Collins, J. (2015). A multiagent approach to variable-rate electric vehicle charging coordination, *Proceedings of the 2015 International Conference on Autonomous Agents and Multiagent Systems*, pp.1131–1139.
- [24] Dähling, S., Kolen, S. and Monti, A. (2018). Swarm-based automation of electrical power distribution and transmission system support, *IET Cyber-Physical Systems: Theory & Applications*, 3(4), 212–223.
- [25] Kolen, S., Isermann, T., Dähling, S. and Monti, A. (2017). Swarm behavior for distribution grid control, 2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), pp.1–6.
- [26] Intelligent Physical Agents Foundation- FIPA, <http://www.fipa.org/>, (Erişim zamanı; Nisan, 18, 2023).

Özgeçmişler



Gülen Akyün, Elektrik Mühendisliği alanındaki lisans derecesini 2020 yılında, yüksek lisans derecesini 2023 yılında İstanbul Teknik Üniversitesi'nde tamamladı. Lisans bitirme projesinde Elektrikli Otobüsler için batarya sistemi tasarımı üzerine çalışırken, Yüksek lisans tezini Elektrikli araçların şebeke entegrasyonu ile ilgili yazdı. Ekim 2022'den bu yana Almanya'nın Aachen kentinde Elektrikli araç odaklı Li-ion batarya testleri yapan bir şirkette Li-ion hücre testi takımında proje mühendisi olarak görev yapmaktadır.



Erdem Gümrükçü, Lisans derecesini 2015 yılında İstanbul Teknik Üniversitesi'nden Elektrik Mühendisliği alanında aldı ve yüksek lisans derecesini 2018 yılında Almanya'nın Aachen şehrinde bulunan RWTH Aachen Üniversitesi'nden elektrik güç mühendisliği alanında tamamladı. Şu anda, aynı üniversitede, büyük ölçekli elektrikli araç şarjı için enerji esnekliği yönetimi ve optimizasyonu konusundaki doktora çalışmalarını sürdürmektedir. 2018'den bu yana E.ON Enerji Araştırma Merkezi bünyesindeki Karmaşık Şebekelerin Otomasyonu Enstitüsü'nde görev yapmaktadır.



Murat Yılmaz, İstanbul Teknik Üniversitesi - İTÜ, Elektrik-Elektronik Fakültesi Elektrik Mühendisliği Bölümü'nde 1995 yılında Lisans, 1999 yılında Yüksek Lisans ve 2006 yılında Doktorasını tamamlamıştır. 1996-1999 yılları arasında Türkiye Teknoloji Geliştirme Vakfı - TTGV ve TÜBİTAK projelerinde araştırmacı olarak projelerde çalıştıktan sonra 1999 yılında İTÜ Elektrik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaya başlamıştır. University of Illinois at Urbana-Champaign (UIUC) Elektrik ve Bilgisayar Mühendisliği Bölümü'nde 2007-2008 yılları arasında UIUC doktora sonrası araştırmacı bursu, 2011-2012 yılları arasında ise TÜBİTAK doktora sonrası araştırmacı bursu ile misafir araştırmacı olarak bulunmuş ve elektrikli araç teknolojileri ve itiş sistem gereksinimlerine yönelik uluslararası projelerde görev almıştır.

2014 yılında İTÜ Elektrik-Elektronik Fakültesi Elektrik Mühendisliği Bölümü'nde Öğretim Üyesi olarak göreve başlamış olup aynı bölümde görevine devam etmektedir. Aynı zamanda 2022 yılında TÜBİTAK BİGG kapsamında kurucu ortak olarak bulunduğu EVİNNO A.Ş. firması kapsamında Ar-Ge çalışmalarına da devam etmektedir. Araştırma alanları arasında güç elektroniği devrelerinin tasarımı, modellemesi, kontrolü ve uygulamaları; elektrik makinalarının uygulamaya yönelik tasarımı, modellemesi, kontrolü ve optimizasyonu; elektrikli ve karma araç teknolojileri, modellemesi, itiş sistemi tasarımı, enerji yönetim sistemi (EMS) ve şebeke ile etkileşimleri (V2G/G2V); enerji depolama sistemleri, batarya teknolojileri, modellemesi, SoX kestirim algoritmaları ve yönetimi (EMS), batarya şarj sistemleri ve altyapı gereksinimleri bulunmaktadır.

Yeni Üretilen XLPE İzolasyonlu Tek Damarlı Bir Güç Kablosunun Kaçak Empedansının Hesabı

Calculation of the Leakage Impedance of a Newly Produced XLPE Insulated Single-Core Power Cable

Hakan Çanta¹, Reşat Mutlu², Rabia Korkmaz Tan³

¹Ünika Üniversal Kablo Sanayi ve Tic. A.Ş., Tekirdağ, Türkiye

hakan@unika.com.tr

²Elektronik ve Haberleşme Mühendisliği Bölümü, Çorlu Mühendislik Fakültesi, Tekirdağ Namık Kemal Üniversitesi, Tekirdağ, Türkiye

rmutlu@nku.edu.tr

³Bilgisayar Mühendisliği Bölümü, Çorlu Mühendislik Fakültesi, Tekirdağ Namık Kemal Üniversitesi, Tekirdağ, Türkiye

rkorkmaz@nku.edu.tr

Öz

Tek damarlı kablolar elektrik sistemlerinde yaygın olarak kullanılmaktadır. Kaçak empedans bu kabloların önemli bir parametresidir. XLPE güç kablolarında yalıtkan olarak kullanılan en yaygın malzemedir. Kablonun XLPE ve Bakır Polyester band katmanlarının kompleks elektriksel geçirgenliği kabloun kaçak akımını belirler. XLPE'nin ve Bakır Polyester bandın (Mylar) kompleks elektriksel geçirgenliği, hem çalışma frekansının hem de sıcaklığın bir fonksiyonudur. Bir güç kablosunda sıcaklık, yarıçapın bir fonksiyonu olarak değişir ve bu da kablo kaçak empedansının hesaplanmasını zorlaştırır. Bu çalışmada literatürden alınan veriler ve sayısal entegrasyon kullanılarak kabloun kaçak empedansının nasıl hesaplanacağı gösterilmiştir.

Anahtar kelimeler: Kablo modelleme, Tek Damarlı Güç Kablosu, Kablo Kaçak Empedansı, XLPE Malzemesi.

Abstract

Single-core cables are widely used in electric power systems. Their leakage impedance is an important parameter. XLPE is the most common material used as an insulator in power cables. The complex permittivities of XLPE and Copper Polyester tape layers (Mylar) of the cable determine its leakage current. The complex permittivity of XLPE and Copper Polyester tape are functions of both operation frequency and temperature. In a power cable, the temperature varies as a function of radius, which makes the calculation of the leakage impedance difficult. In this study, it is shown how to calculate the leakage

impedance of the cable using the data taken from the literature and numerical integration.

Keywords: Cable modeling, Single-Core Power Cable, Cable Leakage Impedance, XLPE Material.

1. Giriş

Tek damarlı güç kabloları genellikle güç iletimi için kullanılır [1]. AC direnci [1, 2] ve yalıtkan admitansı [1, 3] gibi kablo parametrelerinin hesaplanması karmaşık ve zor süreçlerdir. Kabloların analitik modellenmesi, geçici hal veya kararlı esnasında da oldukça zordur [4, 5]. Şebeke frekanslarında, bir kablo modelinin en az dört kablo parametresine, R, L, C ve G, ihtiyacı vardır [5]. C ve G, kaçak admitansını veya buna karşılık gelen kaçak empedansını hesaplamak için kullanılır. XLPE genellikle Tek damarlı güç kablolarında yalıtkan olarak kullanılır ve kompleks elektriksel geçirgenlik gibi parametreleri ve yaşlanması büyük ölçüde sıcaklığa bağlıdır [1, 6]. Ayrıca, artan sıcaklık ve kabloun yaşı ile XLPE özdirenci ve kaçak akım artar [7, 8]. IEC 60287 standardı, bir çalışma koşulu altındaki bir kabloun Ampasite değerini (akım taşıma kapasitesi) hesaplamak için kullanılır [9, 10]. Bu nedenle XLPE güç kablolarını bir FEM programı kullanarak termal olarak analiz etmek önemlidir [10]. Aşırı ısınma ve gerilim stresi kabloları erken yaşlandırabilir [11]. Bu kabloların ampasite azalmasının hesaplama yöntemleri [12]'de değerlendirilmiştir. Akımda harmoniklerin varolması da kabloun ampasitesinde bir azalmaya neden olmaktadır [13]. Yalıtkan yapısal kusurlarının (defolarının) kablo içindeki elektrik alan dağılımı ve dolayısıyla kabloların kaçak akımı üzerinde de etkisi vardır [14]. XLPE çok önemli bir malzemedir, Bundan dolayı daha iyi kullanımı için kaçak akımı, sulu ağaçlanma ve temas açısı gibi özelliklerinin incelenmesi gerekir [15-17]. Bir XLPE numunesinin kaçak

akımı ve kompleks bağıl elektriksel geçirgenliği ölçülür ve sıcaklık ve frekansın bir fonksiyonu olarak verilir [17]. XLPE yaşlanmasının kaçak akımı üzerindeki etkisi [18]'de incelenmiştir. [17, 18]'de deneyler esnasında dikdörtgen bir prizma XLPE örneği kullanılmıştır, ancak tek damarlı bir güç kablosundaki XLPE silindirik bir geometriye sahiptir ve bu nedenle kaçak empedansını hesaplamak için silindirik geometri dikkate alınmalıdır. Ayrıca, uzun tek damarlı bir güç kablosunda kararlı halde sıcaklık, radyal mesafenin bir fonksiyonudur ve güç kablosunun Mylar, Zırh ve Hffr gibi başka kısımları da vardır. Bu bölgeler, tek damarlı bir güç kablosunun kaçak empedansının hesaplanmasını daha zorlaştırır. Bu çalışmada, XLPE için [17]'deki veriler ve kablunun diğer kısımları için [19-21]'deki veriler kullanılarak, XLPE ve Mylar malzemelerin frekans ve sıcaklık bağımlılığı dikkate alınarak, silindirik koordinatlarda sayısal integral olarak ve Matlab programında gerekli kodu yazarak, yaşlanmamış tek damarlı bir güç kablosunun kaçak empedansı hesaplanmıştır. Böyle bir program, tek damarlı güç kablolarını tasarlamak ve analiz etmek için kullanılabilir.

Bu makale takip eden sırada düzenlenmiştir. İkinci bölümde ise tek damarlı kablunun ısı transfer modeli verilmiştir. Üçüncü bölümde ise XLPE ve Mylar yalıtkanların elektriksel geçirgenlik modelleri sunulmuştur. Dördüncü bölümde, bu güç kablosunun kaçak empedansı bu elektriksel geçirgenlik modelleri kullanılarak hesaplanır. Makale sonuç bölümü ile sonuçlandırılmıştır.

2. Tek Damarlı Kablonun Isı Transfer Modeli

Tek damarlı kablo topolojisi Şekil 1'de gösterilmiştir. Kablo iletkeninde harcanan elektrik gücü şu şekilde verilir:

$$p = R_{AC} I_{rms}^2 \quad (1)$$

Burada I_{rms} faz akımı ve R_{AC} kablunun AC direncidir.

Uzun bir silindirin termal direnci [22] şu şekilde verilir:

$$R_{TH} = \frac{\ln(r_2/r_1)}{2\pi kL} \quad (2)$$

Burada L , r_2 , ve r_1 sırasıyla silindirin uzunluğu, dış yarıçapı ve dış yarıçapıdır, ve k termal iletkenliğidir.

Uzun bir kablo için, XLPE, Bakır polyester (Mylar) bant, Bakır zırh ve HFFR yalıtkan katmanlarının termal direnci sırasıyla şu şekilde verilir:

$$R_{THXLPE} = \frac{\ln(r_{XLPE}/r_c)}{2\pi k_{XLPE}L} \quad (3)$$


$$R_{THMylar} = \frac{\ln(r_{Mylar}/r_{XLPE})}{2\pi k_{Mylar}L} \quad (4)$$

$$R_{THArmour} = \frac{\ln(r_{Armour}/r_{Mylar})}{2\pi k_{Armour}L} \quad (5)$$

$$R_{THHffr} = \frac{\ln(r_{Hffr}/r_{Armour})}{2\pi k_{Hffr}L} \quad (6)$$

Burada r_c bakır iletkenin yarıçapıdır, r_{XLPE} XLPE tabakasının dış yarıçapıdır, r_{Mylar} mylar tabakasının dış yarıçapıdır, r_{Armour} bakır zırhın dış yarıçapıdır, r_{Hffr} Hffr tabakasının dış yarıçapıdır, k_{XLPE} XLPE'nin termal iletkenliğidir, k_{Mylar} Mylar'ın termal iletkenliğidir, k_{Armour}

zırhın termal iletkenliğidir ve k_{HFFR} hffr'nin termal iletkenliğidir.



MAKE UP

1. Conductor : Annealed Bare or Tinned stranded copper in accordance with IEC 60228 CL2 or CL5
2. Insulation : Cross-linked polyethylene XLPE in accordance with IEC 60092-360
3. Tape : Copper polyester tape
4. Armour : Bare or Tinned copper wire braid in accordance with IEC 60092-350
5. Outer Jacket : Halogen free extruded compound, SHF1 or SHF2 in accordance with IEC 60092-360

Şekil 1: Tek damarlı kablo yapısının yandan görünümü (Ünika Universal Kablo Sanayi ve Tic. A.Ş.'nin izniyle kullanılmıştır)

Kararlı halde, Fourier yasası kullanılarak, kablo içinden aktarılan güç şu şekilde hesaplanır:

$$p = \frac{T_c - T_s}{R_{THXLPE} + R_{THMylar} + R_{THArmour} + R_{THHffr}} \quad (7)$$

Burada T_c bakır iletken sıcaklığıdır ve T_s ortam sıcaklığıdır.

Bakır zırh bir Faraday kafesi gibi davranır ve iletken ile zırh arasındaki XLPE ve Mylar katmanları, kablunun kaçak empedansını ve akımını belirler. Bundan dolayı XLPE ve Mylar tabakalar içindeki sıcaklık dağılımı bilinmelidir. Katmanların iç ve dış yarıçaplarında sıcaklığı biliniyorsa, kararlı halde radyal konumun (yarıçapın) bir fonksiyonu olarak iç (dahili) sıcaklıkları Denklem (2) kullanılarak bulunabilir. Elektriksel-termal analogiyi kullanarak, kararlı halde, XLPE katmanı boyunca sıcaklık farkı şu şekilde bulunur:

$$T_c - T_x = p R_{THXLPE} \quad (8)$$

Burada T_x XLPE'nin dış yarıçapındaki sıcaklıktır ve

$$T_x = T_c - \frac{R_{THXLPE}(T_c - T_s)}{R_{THXLPE} + R_{THMylar} + R_{THArmour} + R_{THHffr}} \quad (9)$$

olarak hesaplanır.

Simülasyonlarda [23]'ten alınan ve Tablo 2'de verilen termal iletkenlikleri kullanılmıştır. Kablunun yeterince uzun olduğu varsayılırsa, kararlı halde, XLPE yalıtkan tabakası içindeki sıcaklık dağılımı şu şekilde verilir:

$$T(r) = (T_c - T_x) \frac{\ln(r/r_{XLPE})}{\ln(r_c/r_{XLPE})} + T_x \quad (10)$$

Kararlı durumda, Mylar tabaka içindeki sıcaklık dağılımı şu şekilde verilir:

$$T_x - T_m = p R_{THMylar} \quad (11)$$

Burada T_m Mylar'ın dış yarıçapındaki ($r = r_{Mylar}$ 'daki) sıcaklıktır ve

$$T_M = T_X - \frac{R_{THMylyar}(T_X - T_M)}{R_{THXLPE} + R_{THMylyar} + R_{THArmour} + R_{THHffr}} \quad (12)$$

olarak hesaplanır. Kararlı durumda, Mylar tabaka içindeki sıcaklık dağılımı şu şekilde verilir:

$$T(r) = (T_X - T_M) \frac{\ln(r/r_{Mylar})}{\ln(r_{XLPE}/r_{Mylar})} + T_M \quad (13)$$

Sıcaklık dağılımı ve çalışma frekansı kullanılarak kablonun kaçak empedansı bulunabilir.

Tek damarlı kablonun fiziksel boyutları Tablo 1'de sunulmuştur. Bakır ve HFFR'ın termal iletkenlikleri [19]'dan alınmıştır. Mylar'ın termal iletkenliği [20]'den alınmıştır. XLPE'nin termal iletkenliği [23]'ten alınmıştır. Malzemelerin termal iletkenlikleri Tablo 2'de verilmiştir. İç iletken sıcaklığı 90 °C ile sınırlandırılmalıdır [10]. Simülasyonlarda iletken ve ortam sıcaklığı sırasıyla 90 °C ve 20 °C olarak alınmıştır. Kararlı hal ısı transfer analizi Denklem (3) - (13) kullanılarak yapılmış ve katman sınırlarındaki sıcaklıklar Tablo 3'te verilmiştir. Bir sonraki bölümde malzemelerin elektriksel geçirgenliklerini ve elektriksel iletkenliklerini hesaplamak için kullanılacak olan XLPE ve Mylar yalıtkanlarının içindeki sıcaklık dağılımları Şekil 2'de görülebilir.

Tablo 1: Tek damarlı kablonun fiziksel boyutları.



Boyutun İsmi	Boyutun Sembolü	Boyutun Değeri (mm)
Bakır iletken yarıçapı	r_c	7.62
XLPE iletken dış yarıçapı	r_{XLPE}	9.62
Mylar dış yarıçapı	r_{Mylar}	9.99
Zırh dış yarıçapı	r_{Armour}	10.59
HFFR dış yarıçapı	r_{HFFR}	12.19

Tablo 2: Tek damarlı kablo tabakalarının ısı iletkenlik parametreleri, k [W/m.°K].

Malzeme	Termal İletkenlik Sembolü	Termal İletkenlik Değeri
Bakır	$k_{Armour} = k_{Copper}$	398
XLPE	k_{XLPE}	0.28
Mylar	k_{Mylar}	0.155 (25.0 - 75.0 °C sıcaklık bölgesi aralığında)
HFFR	k_{HFFR}	0.25

Table 3: Arayüz sınırlarındaki sıcaklıklar [°C]

The temperature	Its value
$r = r_c$ 'deki iletken sıcaklığı, T_c	90 °C
$r = r_{XLPE}$ 'deki XLPE sıcaklığı, T_X	55.505 °C
$r = r_{Mylar}$ 'deki bakır polyester (Mylar) bandın sıcaklığı, T_M	45.414 °C
$r = r_{Armour}$ 'deki zırh sıcaklığı, T_{Armour}	45.408 °C
$r = r_{HFFR}$ 'deki HFFR sıcaklığı yada ortam sıcaklığı, $T_{HFFR}(= T_S)$	20 °C



Şekil 2: a) XLPE ve b) Mylar tabakalarının içindeki sıcaklığın yarıçapa göre değişimi

3. Yalıtkanların Kompleks Elektriksel Geçirgenlik Modelleri

Bu bölümde, XLPE ve Mylar malzemelerinin bağlı kompleks elektriksel geçirgenlik modelleri verilmiştir.

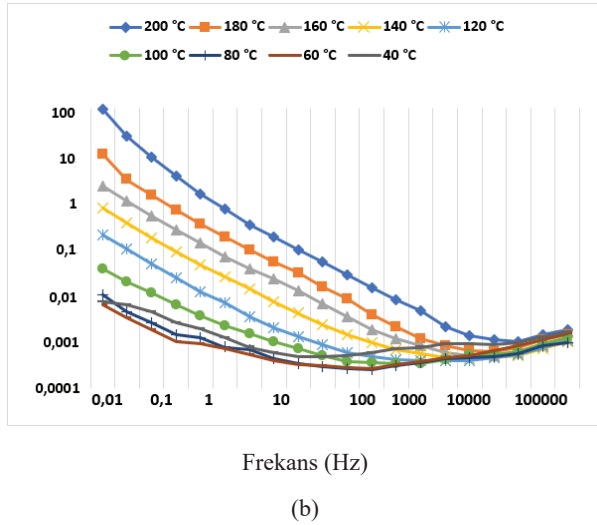

3.1 XLPE Yalıtkanının Kompleks Elektriksel Geçirgenlik Modeli

Bu bölümde, XLPE kablosunun bağlı kompleks elektriksel geçirgenlik özellikleri verilmiştir. [17]'de, XLPE malzemesinin kompleks elektriksel geçirgenliği ölçülmüş ve sunulmuştur. Bu çalışmada bahsedilen veriler Getdata programı kullanılarak yeniden üretilmiştir [24]. Geçirgenliğin hem gerçek hem de sanal kısımları, sıcaklık (T) ve frekansın (f) bir fonksiyonu olarak alınmıştır. Bunlar Şekil 3'te gösterilmiştir. XLPE 'nin

bağıl kompleks elektriksel geçirgenliği, $\epsilon_{XLPE}(\omega, T)$, şu şekilde verilmiştir:

$$\epsilon_{XLPE}(\omega, T) = \epsilon_0 \epsilon'(\omega, T) - j\epsilon_0 \epsilon''(\omega, T) \quad (14)$$

Burada ϵ' ve ϵ'' bağıl kompleks elektriksel geçirgenliğin gerçek ve sanal kısımlarıdır, ϵ_0 boşluğun geçirgenliğidir ve $\omega = 2\pi f$ açısal frekanstır.



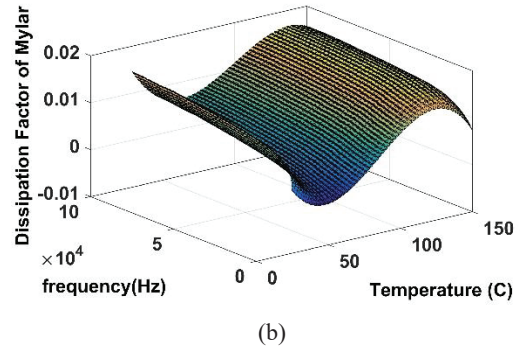

Şekil 3: [17]'den alınıp yeniden üretilmiş frekansa ve sıcaklığa bağlı ölçülmüş bağıl kompleks elektriksel geçirgenliğin a) gerçek kısmı ϵ' ve b) sanal kısmı ϵ'' .

3.2 Mylar Yalıtkanının Kompleks Elektriksel Geçirgenlik Modeli

Bu bölümde Mylar'ın bağıl elektriksel geçirgenlik ve dielektrik kayıp faktörü özellikleri verilmiştir. Mylar'ın elektriksel özellikleri de Getdata veri alma programı kullanılarak [21]'den alınmıştır. Ne yazık ki, [21]'den alınan veriler [16]'dan alınan XLPE verileri kadar zengin değildi. Mylar'ın hem bağıl elektriksel geçirgenliği, $\epsilon_{Mylar}(\omega, T)$ hem de dielektrik kayıp faktörü, $DP_{Mylar}(\omega, T)$, sıcaklık (T) ve frekansın (f) iki boyutlu bir fonksiyonu olarak kabul edilmiştir ve her ikisi de Şekil 4'te gösterilmiştir. Mylar'ın bağıl elektriksel ve kayıp faktörü kullanılarak, Mylar'ın elektriksel iletkenliği

$$\sigma_{Mylar}(\omega, T) = \omega \epsilon_0 \epsilon_{Mylar}(\omega, T) DP_{Mylar}(\omega, T) \quad (15)$$

olarak hesaplanır.



Şekil 4: Mylar'ın sıcaklık ve frekansa bağlı olarak a) bağıl elektriksel geçirgenliği ve b) dielektrik kayıp katsayısı.

4. XLPE Kablonun Kaçak Empedansı

XLPE'nin kaçak empedansa katkısı şu şekilde bulunabilir:

$$Z_{S1} = \int_{r_C}^{r_{XLPE}} \frac{dr}{j\omega \epsilon(\omega, T) 2\pi r L} \quad (16)$$

$$Z_{S1} = \int_{r_C}^{r_{XLPE}} \frac{dr}{j(\epsilon_0 \epsilon'(\omega, T) - j\epsilon_0 \epsilon''(\omega, T)) 2\pi r L} \quad (17)$$

Bu kaçak empedans integrali, toplam XLPE katman sayısı N_{XLPE} olarak alınarak sayısal olarak hesaplanabilir:

$$Z_{S1} = \sum_{i=0}^{N_{XLPE}} \frac{\Delta r}{(\epsilon_0 \epsilon'(\omega, T(i)) - j\epsilon_0 \epsilon''(\omega, T(i))) 2\pi r(i) L} \quad (18)$$

Burada i XLPE katman numarasıdır, $r(i) = r_C + i\Delta r$ i .inci XLPE katmanının dış yarıçapıdır ve $T(i) = (T_C - T_X) \frac{\ln(r(i)/r_{XLPE})}{\ln(r_C/r_{XLPE})} + T_X$ i .inci XLPE katmanın dış yarıçaptaki sıcaklığıdır.

Mylar'ın kaçak empedansa katkısı şu şekilde bulunabilir:

$$Z_{S2} = \int_{r_{XLPE}}^{r_{Mylar}} \frac{dr}{(\sigma_{Mylar}(\omega, T) + j\omega\epsilon_{Mylar}(\omega, T))2\pi r L} \quad (19)$$

Benzer şekilde, kaçak empedans integrali, toplam Mylar katman sayısı N_{Mylar} olarak alınarak sayısal olarak hesaplanabilir:

$$Z_{S2} = \sum_{i=0}^{i=N_{Mylar}} \frac{\Delta r}{(\sigma_{Mylar}(\omega, T(i)) + j\omega\epsilon_{Mylar}(\omega, T(i)))2\pi r(i)L} \quad (20)$$

Burada i Mylar katman numarasıdır, $r(i) = r_{XLPE} + i\Delta r$ i .inci Mylar katmanının dış yarıçapıdır, ve

$$T(i) = (T_X - T_M) \frac{\ln(r(i)/r_{Mylar})}{\ln(r_{XLPE}/r_{Mylar})} + T_M$$

i .inci Mylar katmanının dış yarıçaptaki sıcaklığıdır.

Kablonun kaçak empedansı, Mylar ve XLPE katkılarının toplamı olarak hesaplanır:

$$Z_P = Z_{S1} + Z_{S2} \quad (21)$$

Kablonun kaçak empedansının eşdeğer direnci ve eşdeğer reaktansı sırasıyla

$$R_S = Re\{Z_P\} \quad (22)$$

ve

$$X_S = Re\{Z_P\} \quad (23)$$


olarak verilmiştir: Kablonun kaçak empedansının mutlak değeri

$$Z_P = \sqrt{R_S^2 + X_S^2} \quad (24)$$


olarak hesaplanabilir. Kablonun kayıp faktörü veya kayıp tanjantı

$$\tan\delta = \frac{R_S}{X_S} \quad (25)$$


olarak hesaplanabilir. Bu çalışmada kablonun akımı ve gerilimi sinüzoidal olarak kabul edilmiştir. Kablonun kaçak empedansını hesaplamak için Matlab'da bir kod yazılmıştır. Matlab dosyasının girişleri Tablo 1-2'de verilen parametreler; kablo uzunluğu, XLPE kompleks geçirgenlik fonksiyonu, Mylar elektriksel iletkenlik ve elektriksel geçirgenlik fonksiyonları, iletken sıcaklığı ve ortam sıcaklığı olarak seçilmiştir. XLPE tabakasının birim uzunluk başına kaçak empedansı, kaçak reaktansı ve kaçak direnci ($L = 1$ metre) Tablo 1-3'te verilen parametreler için hesaplanmıştır ve Şekil 5-8'de gösterilmiştir.



Şekil 5: $T_S=40$ °C ve $T_C=80$ °C için bu güç kablosunun kaçak empedansının (Z_p) frekansa göre değişimi

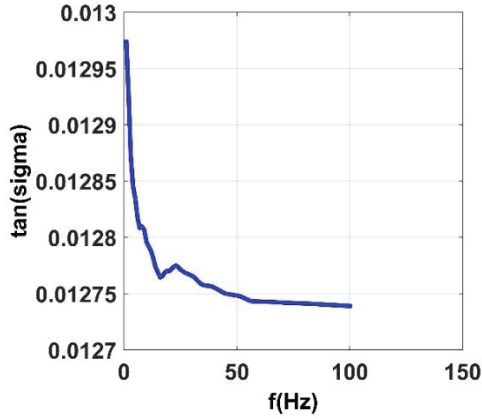


(a)



(b)

Şekil 6: $T_S=40$ °C ve $T_C=80$ °C için bu güç kablosunun a) eşdeğer kaçak direncininin (R_p) ve b) eşdeğer kaçak reaktansının (X_p) frekansa göre değişimi



Şekil 7: $T_S=40$ °C ve $T_C=80$ °C için $\tan\delta$ 'nın frekansa göre değişimi.

5. Sonuç

[16]'da, XLPE malzemesinin kompleks elektriksel geçirgenliği, bir dikdörtgen prizma XLPE örneği için ölçülmüştür. Bununla birlikte, tek damarlı bir güç kablosu silindirik bir geometriye ve yarıçapa bağlı bir sıcaklığa sahiptir. Bu çalışmada, tek çekirdekli bir XLPE güç kablosunun kaçak empedansı, deneysel XLPE verileri ile Mylar kataloğunun verileri kullanılarak hesaplanmış ve hesaplanmasında silindirik geometri nedeniyle sayısal integralin kullanılabileceği gösterilmiştir. Kararlı halde XLPE tek damarlı kablunun kaçak empedansının reel ve sanal kısmı yani eşdeğer kaçak direnci ve eşdeğer kaçak reaktansı ile dielektrik kayıp faktörü $\tan\delta$ da frekansın bir fonksiyonu olarak hesaplanmıştır.

6. Teşekkür

Bu çalışma Ünika Üiversal Kablo Sanayi ve Tic. A.Ş. Araştırma ve Geliştirme Merkezi tarafından desteklenmiştir. Proje numarası: **UPN-2002**.

7. Kaynaklar

- [1] G. F. Moore (Ed.), *Electric cables handbook*. Blackwell Science, UK, 1997
- [2] Dai D., X. Zhang, & J. Wang, "Calculation of AC resistance for stranded single-core power cable conductors", *IEEE Transactions on Magnetics*, vol. 50, no. 11, pp. 1-4, 2014.
- [3] P. Wagenaars, P. A. Wouters, P. C. Van Der Wielen, & E. F. Steennis, "Approximation of transmission line parameters of single-core and three-core XLPE cables", *IEEE transactions on dielectrics and electrical insulation*, vol. 17, no. 1, pp. 106-115, 2010.
- [4] B. Gustavsen, "Panel session on data for modeling system transients insulated cables", *2001 IEEE Power Engineering Society Winter Meeting, Conference Proceedings (Cat. No. 01CH37194)*, COLUMBUS, OHIO, USA, 2001, vol. 2, pp. 718-723. doi:10.1109/PESW.2001.916943.
- [5] Z. H. Yuan, & Y. Du, "Harmonic impedance of single-core armored cables", *2003 IEEE PES Transmission and*

Distribution Conference and Exposition (IEEE Cat. No. 03CH37495), Dallas, TX, USA, 2003, vol. 1, pp. 45-48. doi: 10.1109/TDC.2003.1335154

[6] O. E. Gouda & Z. Matter, "Effect of the temperature rise on the XLPE dielectric properties", *IEEE Proceedings of the 35th Midwest Symposium on Circuits and Systems*, 1992, pp. 95-98. doi: 10.1109/MWSCAS.1992.271325.

[7] W. A. Thue (Ed.), *Electrical power cable engineering*, CRC Press, Boca Raton, 2017.

[8] G. J. Anders, *Rating of electric power cables in unfavorable thermal environment*, Hoboken, NJ, USA, Wiley-IEEE Press, 2005.

[9] IEC Publication 60287, *Calculation of the continuous current ratings of cables*, 1982, 3. Ed., 1995.

[10] F. Aras, & C. Oysu, "Thermal analysis of 154 kV underground cable joint using finite element method", *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 22, no. 3, 281-286, 2007.

[11] F. Aras, V. Alekperov, N. Can, & H. Kirkici, "Aging of 154 kV underground power cable insulation under combined thermal and electrical stresses", *IEEE Electrical Insulation Magazine*, vol. 23, no. 5, pp. 25-33, 2007. doi: 10.1109/MEI.2007.4318272.

[12] F. Aras, C. Oysu, & G. Yilmaz, "An assessment of the methods for calculating ampacity of underground power cables", *Electric Power Components and Systems*, vol. 33, no. 12, pp. 1385-1402, 2005. doi: 10.1080/15325000590964425.

[13] Y. G. Sahin, & F. Aras, "Investigation of harmonic effects on underground power cables", *2007 IEEE International Conference on Power Engineering, Energy and Electrical Drives*, Setubal, Portugal, 2007, pp. 589-594. doi: 10.1109/POWERENG.2007.4380123.

[14] C. Uydur, O. Arıkan, & O. Kalenderli, "The Effect of insulation defects on electric field distribution of power cables", *2018 IEEE International Conference on High Voltage Engineering and Application (ICHVE)*, Athens, Greece, 2018, pp. 1-4. doi: 10.1109/ICHVE.2018.8641936.

[15] M. Karhan & M. Uğur, "XLPE izoleli tek damarlı orta gerilim kablolarında elektrik alanının sulu ağaçlanmaya etkisinin incelenmesi", *Güç Sistemleri Konferansı (GSK2016)*, İstanbul, 2016.

[16] M. Karhan, M. F. Çakır, Ö. Arslan, F. İssi, & V. Eyüpoğlu, "XLPE dielektrik malzemelerde elektrik alanının temas açısına ve damlacık şekline etkisi", *Gazi Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 36, no. 3, pp. 1747-1760, 2021. <https://doi.org/10.17341/gazimmfd.700362>.

[17] Y. Du, P. Geng, J. Song, M. Tian, & D. Pang, "Influence of temperature and frequency on leakage current of XLPE cable insulation", *2016 IEEE International Conference on High Voltage Engineering and Application (ICHVE)*, Chengdu, China, 2016, pp. 1-4. doi: 10.1109/ICHVE.2016.7800648.

[18] P. Geng, J. Song, M. Tian, Z. Lei, & Y. Du, “Influence of thermal aging on AC leakage current in XLPE insulation”, *AIP Advances*, vol. 8, no. 2, 025115. 2018. <https://doi.org/10.3390/polym14153147>.

[19] B. Perka & K. Piwowarski, “A Method for Determining the Impact of Ambient Temperature on an Electrical Cable during a Fire”, *Energies*, vol. 14, no. 21, 7260, 2021. <https://doi.org/10.3390/en14217260>.

[20] Anonim, “DuPont Teijin Films Mylar”, Matweb (Online), https://www.matweb.com/search/datasheet_print.aspx?matguid=981d85aa72b0419bb4b26a3c06cb284d, [June 06, 2023]

[21] Anonim, “Elektrikal properties”, DuPont Teijin Films (Online),

<https://europe.dupontteijinfilms.com/media/2431/info-mylar-a-electrical-properties.pdf>, [Access date; June 10, 2023]

[22] Y. A. Cengel, *Introduction to thermodynamics and heat transfer*, McGraw-Hill, New York, 1997.

[23] S. Manjang, & B. Armynah, “The radial distribution of temperature in XLPE cable an analysis the finite element numerical method”, *2006 IEEE 8th International Conference on Properties & applications of Dielectric Materials*, Denpasar, Bali, 2006, pp. 439-442. doi: 10.1109/ICPADM.2006.284209.

[24] Anonim, “GetData Graph Digitizer 2.26”, Software.informer (Online), <https://getdata-graph-digitizer.software.informer.com/> [Access date; June 02, 2023]

Özgeçmişler



Hakan Çanta, 1984 Yılında Kırklareli’de doğdu. İlk ve orta öğrenimi Kırklareli Vize’de tamamladı. 2002 Yılında Kırklareli Teknik Lisesi Elektrik Bölümünü ikincilikle bitirdi. Lise stajını Tekirdağ, Çerkezköy’de bulunan o günkü adıyla Aksu iplik Dokuma T.A.Ş. Elektrik Bakım bölümünde tamamladı. 2002 Yılında Kocaeli Üniversitesi Elektrik Öğretmenliği bölümüne başladı. Üniversite yıllarında Kocaeli’de Hyundai, Crown metalbox gibi firmalara teknik destek sağlayan bir firmada staj yaptı, Staj sonrası tam zamanlı ve yarı zamanlı olarak elektrik teknisyeni görevinde çalıştı. Türkiye’nin en büyük sanayi kuruluşlarındaki teknik ekiplerle çalışma tecrübesine sahip oldu. 2006 yılında okul bittikten sonra askere gitti ve Bolu il jandarma komutanlığında kısa dönem jandarma çavuş olarak askerlik hizmetini tamamladı. Askerlik sonrası 2010’a kadar ücretli öğretmenlik ve üretim sorumlusu gibi alanlarda kamu ve özel sektörde görev aldı. 2010 yılında Ünika Universal Kablo Ar-ge ve Dizayn bölümüne çalışmaya başladı. 2016 yılı sonunda Ar-ge ve Dizayn şefi oldu. 2017 yılı içerisinde Bilim Sanayi ve Teknoloji Bakanlığında Ar-Ge Merkezi Lisansı olarak Ar-Ge Merkezi Müdürü oldu. Ardından bazı TÜBİTAK projelerinde proje yöneticiliği yapmaktadır. 2022 yılında Kocaeli Üniversitesi Enerji Sistemleri Mühendisliği’nde Yüksek Lisansını tamamladı. İş hayatına Ünika Universal Kablo’da devam etmektedir. Evli ve bir erkek çocuk babasıdır.



Doç. Dr. Reşat Mutlu, 1973 yılında Tekirdağ’da doğdu. Lisans eğitimini Yıldız Teknik Üniversitesi Elektrik Mühendisliği bölümünde, Yüksek lisans ve doktorasını ise Rensselaer Polytechnic Enstitü’de sırasıyla 1998 ve 2004 yıllarında tamamladı. An itibarıyla Tekirdağ Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi’nde doçent olarak görev yapmaktadır. Çalışma alanları Elektronik sistemlerin modellenmesi, Memristör, Memristif sistemler, Rezistif RAM bellekler, Güç hattı haberleşme sistemleri, Rezistif sinterleme sistemleri ve Kablolardır.



Dr. Öğr. Üyesi Rabia Korkmaz Tan, 1984 yılında Erzurum’da doğdu. Lisans eğitimini Mersin Üniversitesi Bilgisayar Mühendisliği bölümünde tamamladı. Yüksek lisans ve doktorasını ise Ege Üniversitesinde sırasıyla 2010 ve 2018 yıllarında tamamladı. 2011-2018 yılları arasında Ege Üniversitesi Bilgisayar Mühendisliği bölümünde Araştırma Görevlisi olarak çalıştı. An itibarıyla Tekirdağ Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi’nde Dr. Öğr. Üyesi olarak görev yapmaktadır. Ayrıca, Fen Bilimleri Enstitüsü Müdür Yardımcısı olarak görev yapmaktadır. Çalışma alanları Optimizasyon, Parametre ayarlama, Etmen Tabanlı Modelleme, Makine Öğrenmesi ve Yapay Zekadır.

Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme

A Study on Deep Learning and Artificial Neural Network Models

 Ercan AKIN^{1,*}, Mustafa Ergin ŞAHİN¹ 

¹Recep Tayyip Erdoğan Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Rize, Türkiye
ercan_akin22@erdogan.edu.tr

Öz

Makine öğrenmesinin alt kümelerinden olan derin öğrenme, son zamanlarda gelişen teknolojiye ayak uydurmak için geliştirilen yapay zekâ uygulamalarının temelini oluşturmaktadır. Yapay zekâ ile çözüm aranan birçok problemde derin öğrenme yöntemleri kullanılmış ve birçok derin öğrenme yaklaşımı ortaya çıkartılmıştır. Görüntülerin işlenmesinde, ses tanımlamalarında, nesne tespitlerinde, mühendislik uygulamaları, ticari faaliyetler ve istatistiksel birçok çalışmaya kaynak oluşturan verilerin işlenmesinde, medikal uygulama ve doğal dil işleme gibi birçok alanda kullanılmış ve kullanılmaya devam edilmektedir. Günümüz şartlarında teknolojiye paralel olarak veriler giderek artmaktadır. Bu artan veri havuzu birçok kişi ve firmalar için inanılmaz derecede önem arz etmektedir. Google, Apple, Baidu, Tesla, Mercedes, Facebook ve Microsoft gibi birçok büyük firma bu verileri işlemek için bu konu üzerinde çalışmalar yürütmekte ve uygulamalarına derin öğrenmeyi entegre etmektedir. Teknoloji yarışı ve pazarlama stratejileri sayesinde günümüzde önemli bir noktaya gelen yapay sinir ağı modelleri ve derin öğrenme konusu, konumuza temel oluşturmaktadır. Bu çalışmada derin öğrenmenin tarihçesi, çalışma prensibi, uygulama alanları ve bu uygulama alanlarında kullanılan yapay sinir ağı modelleri hakkında bilgi verilmiştir. Son bölümde ise güncel bazı uygulamalardan bahsedilmiştir.

Anahtar Kelimeler: Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme, Yapay Sinir Ağları

Abstract

Deep learning, which is one of the subsets of machine learning, forms the basis of artificial intelligence (AI) applications developed to keep up with the developing technology. Deep learning methods have been used in many problems for which solutions are sought with artificial intelligence and many deep learning approaches have been revealed. It has been used and continues to be used in many fields such as image processing, sound identification, object detection, data processing (Engineering applications, Commercial activities, Statistical studies, etc.), medical practice, and natural language processing. In today's conditions, data is increasing in parallel with technology. This growing pool of data is incredibly important to many individuals and companies. Many large companies such as Google, Facebook, Apple, Tesla, Mercedes, Baidu, and Microsoft are working on this issue to process this data and integrate deep learning into their applications. The technology race and marketing strategies that bring artificial neural

networks and models, deep learning to such an important point today, form the basis of our subject. In this study, information is given about the history of deep learning, its working principle, application areas and artificial neural network models used in these application areas. In the last section, some current applications are mentioned.

Keywords: Artificial Intelligence, Machine Learning, Deep Learning, Artificial Neural Networks

1.Giriş

Yapay zekâ, makine öğrenmesi ve derin öğrenme mantık olarak aynı olsa da işlev bakımından birbirlerinden ayrılır. Yapay zekâ, sadece sisteme girilen yani öğretilen veriler doğrultusunda işlem yapabilirken makine öğrenmesi verilen veriler ve bu verilerden oluşturduğu ekstra bilgiler doğrultusunda çıkarım yapmaktadır. Denetimli makine öğreniminin bir alt dalı olan derin öğrenme ise beynin yapısından ve işlevinden ilham alan yapay sinir ağı algoritmalarını kullanarak işlemleri gerçekleştirmektedir [1]. Yapay zekâ ve makine öğrenmesine göre daha çok veriyi daha karmaşık bir şekilde kendi oluşturduğu algoritma zincirleri ile yinelemeli olarak öğrenebilen ve sürekli olarak öz nitelik değerlerini oluşturup oluşturduğu bu öz niteliklere göre çıkarımlar yapabilen bir sistemdir. En genel tanımıyla derin öğrenme; canlıların karmaşık problemler ve durumlar karşısında kullandığı gözlem, analiz, öğrenme ve karar verme gibi özgül davranışları, çok yüksek miktardaki verileri denetimli veya denetimsiz öğrenme algoritmalarında kullanarak öz nitelik çıkaran ve çıkardığı bu öz niteliklere dönüştürme ve sınıflandırma gibi işlemler uygulayarak taklit edebilen bir makine öğrenmesi yöntemidir [2], [3].

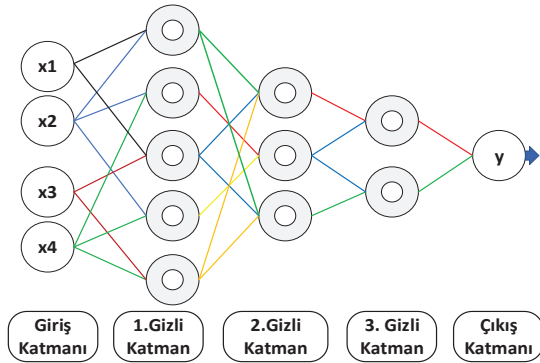
Günümüzde otonom sistemlerin daha ileri bir seviyeye ulaşabilmesi için yapay zekâ teknolojileri ile donatılmış sistemlere gereksinim duyulmaktadır [4]. Geçmişte yapay zekâ da karar verme veya tahmin oluşturma süreçlerinde sadece makine öğrenmesi algoritmaları kullanılmıştır. Fakat günümüz teknolojisinde insan faktörüne olan bağlılık git gide azalmakta ve yerini derin öğrenme tabanlı sistemlere bırakmaktadır. Buna bağlı olarak giderek artan ve karmaşık bir hal alan verilerin hızlı bir şekilde analiz edilmesi, öğrenilmesi ve uygulanmasında derin öğrenme yöntemleri kullanılmaya başlanmıştır [3], [5].

Bu çalışmada son yıllarda önemi oldukça artan derin öğrenme kavramı detaylı bir şekilde araştırılmıştır. İkinci bölümde derin öğrenmenin tanımı, çalışma prensibi ve tarihçesi anlatılmıştır. Üçüncü bölümde derin öğrenmede kullanılan yapay sinir ağı modelleri, derin öğrenme hakkında araştırma

yapan firmalar ve derin öğrenme için kullanılacak modeller anlatılmıştır. Dördüncü bölümde ise dünyada ki uygulama alanlarına kısa bir şekilde değinilmiş ve fotovoltaik sistemlerde kullanılan MPPT modelinin yapay zekâ ile modellenmesi vurgulanmıştır.

2. Derin Öğrenmenin Tarihiçesi

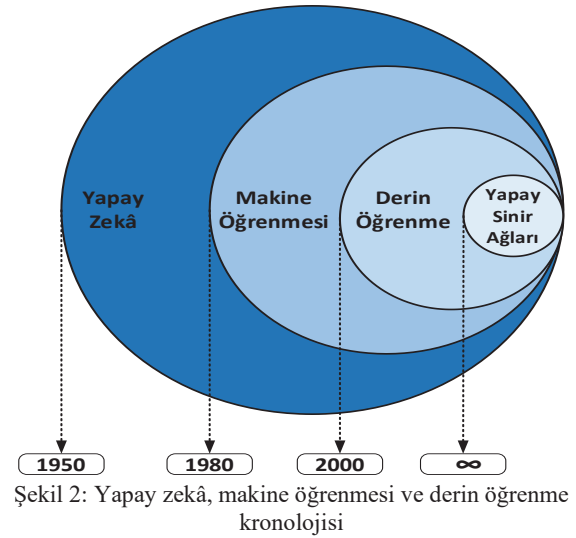
Derin öğrenmenin ilk adımı 1943 yılında Walter Pitts ve Warren McCulloch tarafından oluşturulan McCulloch-Pitts nöronları olarak adlandırılan matematiksel bir sinir ağı modelidir [6]. 1950 yılında Alan Turing ve 1952 yılında Arthur Samuel makine öğreniminin temellerini attılar. 1959 yılında David Hubel ve Torsten Wiesel basit ve karmaşık hücre yapılarını ortaya çıkartarak derin öğrenmeye özgü bir dönüm noktası olmasa bile yapay sinir ağlarının gelişimine katkıda bulunmuştur [7]. 1960 yılında Heury J. Kelley uçakların olası rotalarıyla ilgili bir kontrol kuramı oluşturmuştur. Bu kontrol kuramı geri beslemeli öğrenme algoritmalarının başlangıç noktası olarak kabul görmüştür [8]. 1965 yılında Alexey Ivakhnenko, çok değişkenli veri setlerini kullanarak bilgisayar tabanlı matematiksel bir model oluşturmuş ve bu modelini sinir ağlarına uyarlayarak çalışan ilk derin öğrenme ağlarını geliştirmiştir [9]. Alexey Ivakhnenko, V.G.Lapa ve arkadaşları tarafından eğitilen ve bilinen ilk derin ağ mimarisi Şekil 1 'de gösterilmiştir.



Şekil 1: Eğitilen ve bilinen ilk derin ağ mimarisi [9]

1979-80 senelerinde Kunihiro Fukushima tarafından geliştirilen ve Neocognitron adını verdiği yapay sinir ağı modeli ile günümüzde daha çok görüntü analizlerinde kullanılan konvüsyonel yapay sinir ağlarının temeli atılmıştır [10]. 1982 yılında ise John Hopfield tarafından, tekrarlayan sinir ağlarının temeli olarak kabul edilen, Hopfield ağı modeli oluşturulmuştur [11]. 1985 yılında İngilizce kelimeleri hemen hemen bir çocuğun öğreneceği şekilde öğrenen ve telaffuz edebilen program Terry Sejnowski tarafından geliştirildi. 1986 yılından aynı şekilde şekil tanıma programı geliştirildi [12]. 1989 yılında Yann LeCun makinelerin elle yazılmış rakamları okuyabilmesini sağlayan bir sistem geliştirdi. Bu sistem en çok çeklerin ve posta kodlarının okunmasında kullanıldı. 1993 yılında Jürgen Schmidhuber, derin öğrenme için önemli bir gelişme olan ve Çok Derin Öğrenme görevi adını verdiği çözümlenmiş yaklaşık 1000 katmandan oluşan devirli sinir ağı modelini kullanıma sunmuştur. Jürgen Schmidhuber ayrıca 1997 yılında uzun-kısa süreli hafıza (LSTM) modelini ilk kez ortaya atmıştır [13]. 1998


yılında Yann LeCun tarafından gradyan tabanlı öğrenme algoritması geliştirilmiş ve geri yayılım algoritması ile birleştirilmiştir [14]. Fei-Fei Li; araştırmacılar, eğitmenler ve öğrenciler için 2009 yılında ImageNet veri tabanını oluşturmuştur. Bu sistemde yaklaşık 15 milyon veri bulunmakta olup kullanıcılar öğrenme modellerini bu verileri kullanarak tasarlayabilmektedir [15]. 2014 yılında ise yüz algılama (DeepFace) sistemi geliştirilmiştir [16]. Günümüzde ise tıp [17]–[19], robotik [20], nesne tespiti [21], görüntü işleme, ses tanıma-işleme [22], veri tahmini, endüstri ve finansal [23] gibi birçok alanda derin öğrenme ve yapay sinir ağı modelleri kullanılmaktadır. Şekil 2 'de yapay zekânın tarihsel kronolojisi gösterilmiştir.



3. Derin Öğrenme Sistemi Nasıl Çalışır?

Derin öğrenme temel olarak veriye ait sınıflandırılmış özniteliklerin eğitilmesine dayalıdır. Bu nedenle düşük seviyeli öznitelikler birleştirilir ve daha yüksek seviye öznitelikler içeren bir öznitelik hiyerarşisi oluşturulur. Bu hiyerarşik yapıların oluşturulması sistemlerin karmaşık girdi-çıkı ilişkilerini doğrudan veriden almasını sayılarak insan yapımı özniteliklere olan bağımlılığı azaltmaktadır [24]. Örneğin bir görüntü için öznitelik denildiği zaman; piksel başına düşen yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi öznitelikler düşünülebilir. Bu özniteliklerin içinden bazıları veriyi daha iyi tanımlamaktadır. Büyük veri havuzlarından elle öznitelik sınıflandırması yapmak yerine öznitelik çıkarım algoritmalarının kullanımı da bu aşama için büyük bir avantajdır [25].

Şekil 3'te derin öğrenmenin çalışma basamakları belirtilmiştir. İlk olarak problemin tanımı ve derin öğrenmeye uygunluğu tespit edilir. İlgili veri kümeleri belirlenir ve analiz için hazırlanır. Kullanılacak algoritma modeli seçilir. Tanımlı veriler, kullanılan algoritmaya göre analitik model oluşturularak, seçilen algoritma ile eğitilir ve gerektiğinde revize edilir. Son olarak test skorları elde etmek için model çalıştırılır ve çıkan sonuca göre ileriye yönelik tahminler yapılır.



Şekil 3: Derin öğrenme çalışma basamakları

İyi bir derin öğrenme modellemesi yapılabilmesi için büyük bir veri havuzuna, bu verileri eğitecek bir algoritmaya, verilerin öznitelik sınıflandırılmasına, transfer fonksiyonu seçimine, ağ yapısının ve gizli katman sayısının belirlenmesi gibi birçok etken göz önünde bulundurulmalıdır. Derin öğrenme modellerinin yapısı genel olarak girdi katmanı, gizli katman ve çıktı katmanından oluşur. Bu katmanların her birine sayısal bir değer verilir [26]. Gizli katmandaki düğümler (nöronlar); giriş ve çıkış düğümlerinden, eğitim algoritmasından, ağ yapısından ve aktivasyon fonksiyonunun türünden etkilenir [27]. Gizli katmandaki düğümlerin sayısını belirlemek amacıyla farklı türde ağları eğiterek ve test verisindeki hatayı araştırarak bir sonuç elde etmek gerekir [28].

4. Derin Öğrenmede Kullanılan Yapay Sinir Ağı Modelleri

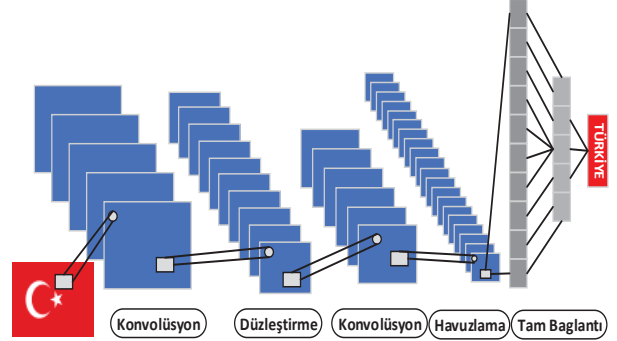
Derin öğrenmede kullanılan yapay sinir ağları modelleri insan beyninin fonksiyonel işlevlerinden esinlenerek oluşturulmuştur. Öğrenebilen bir yapısı olan bu modeller algılama, kontrol ve analiz yapma, verileri saklama ve bu verilerden çıkarım yapabilme gibi birçok yeteneğe sahiptir. Kendi öznitelik verilerini oluşturarak öğrenme sürecini matematiksel olarak modellerler. Uygulama alanına göre birçok yapay sinir ağı modeli bulunmaktadır. Temel olarak dört gruba ayrılan; tek katmanlı, çok katmanlı, ileri beslemeli ve geri beslemeli yapay sinir ağları modelleri kullanılmaktadır [29].

4.1. Konvolüsyonel (Evrışimli) Sinir Ağları

Konvolüsyonel sinir ağları, temel olarak görüntüleri sınıflandırmak, fotoğraftaki benzerliklere göre objeleri veya nesnelere belirlenen özelliklere göre kümelemek için kullanılan çok katmanlı ve ileri beslemeli bir yapay sinir ağı modelidir. Bu sistem ilk olarak 1968 senesinde Hubel ve Wiesel tarafından hayvanların görme sistemleri temel olarak oluşturulmuştur [30]. Yapay sinir ağları modelleri içerisinde en çok kullanılan modellemedir.

Konvolüsyonel sinir ağları; konvolüsyon (convolution), düzleştirme (rectified linear unit), havuzlama (pooling) ve tam bağlantı (fully connection) katmanlarından oluşur. Bu işlem basamakları elde edilecek görüntü netliğine göre farklı sayıda


ve boyutta tasarlanabilmektedir. Şekil 4'te bu işlem basamaklarının sıralaması gösterilmiştir.



Şekil 4: Konvolüsyonel sinir ağı katmanları [31]

Konvolüsyonel sinir ağları çok sayıda filtreleme ve öznitelik çıkarım işlemi yaptığından dolayı görsellerdeki farklı özelliklerin tespit edilmesine ve gruplandırılmasına olanak sağlamaktadır. Görüntülerdeki nesnelere hangi niteliklere sahip olduğu (insan, araç-gereç, hayvan, bitki vb.) basit bir şekilde tespit edilebilmektedir.

Konvolüsyonel sinir ağlarında ilk basamak konvolüsyonel katmandır. Bu basamak da Şekil 5'de görüldüğü üzere bir görüntüye ait görüntü matrisinin (9x9x3), her bir satır-sütün aralığına 3x3x3 filtreleme işlemi uygulanarak 7x7x3 boyutlarında yeni bir görüntü matrisi elde edilir. Filtreleme matrisi ve ana matrisde taranan alan satır-satır ve sütun-sütün ile çarpılır. Çarpma işlemi sonucu oluşan matrisin tüm sütun ve satır değerleri toplanarak ortalaması alınır. Elde edilen değerler Şekil 5' de belirtilen tabloya işlenir. Bu değerler veri boyutuna ve sayısına ve kullanılan filtreleme işlemine göre değişebilir.




Şekil 5: Konvolüsyonel katmanı işlem basamakları

İkinci basamak olarak uygulanan düzleştirme işleminde genel olarak Eşitlik 1' de ki Relu (Rectified Linear Unit) fonksiyonu kullanılmaktadır. Şekil 6'da gösterildiği üzere bu işlemdeki amaç sıfırdan küçük değerleri karanlık ortam olarak algılayarak sıfır değerine eşitlemektir.


$$Relu = f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

Üçüncü basamak olan havuzlama katmanının amacı konvolüsyon işlemi sonucu oluşan yeni görüntü matrisinin boyutunu azaltmaktır. Bu sayede boyutu düşürerek işlem ağınlığının hızını artırır. İki çeşit havuzlama yöntemi olup, bunlar ortalama ve en büyük değer yöntemleridir. En yaygın şekilde kullanılan en büyük değer havuzlama yönteminde NxN boyutunda matrisler seçilerek içerisindeki en büyük değer seçilir. Genel olarak 2x2 boyutlarında matris kullanılır. Şekil 6 da maksimum havuzlama yöntemi gösterilmiştir. Bu yöntemdeki amaç Relu işlemi sonucu oluşan matristeki karanlık noktaları yok etmektir. Elde edilecek görüntü matrisi istenilen seviyede netlik kazanmamışsa tekrar istenilen bir havuzlama yöntemi kullanılabilir.



Şekil 6: Relu fonksiyonu kullanarak düzeltme katmanı ve Maksimum havuzlama yöntemi

Konvolüsyon, düzeltme ve havuzlama sayısı kullanılan görüntüye veya kullanıcının amacına göre değişiklik gösterilebilmektedir. Bu işlemlerin amacı tam bağlantı öncesi tek boyutlu bir giriş verisi elde etmektir. Son basamak olan tam bağlantı katmanında nesneyi belirleyecek olan özelliklerin hangi kategoriye ait olduğu tespit edilir. Şekil 7’de gösterildiği gibi tam bağlantı katmanında elde edilen sütundaki değerlerden en yüksek değerlerin ortalaması alınarak doğruluk oranı, en düşük değerlerin ortalaması alınarak da hata oranı elde edilir.




Şekil 7: Tam bağlantı katmanı

Konvolüsyonel sinir ağları modelleri günümüzde görüntü işleme alanında öncelikli olarak kullanılmaktadır. Ayrıca ses ve video işlemede, tıbbi taramalar ile hastalıklarının teşhisinde, otonom cihazların kontrolünde ve görüntülerdeki nesnelere tanımlamada da tercih edilmektedir.

4.2. Tekrarlayan Sinir Ağları

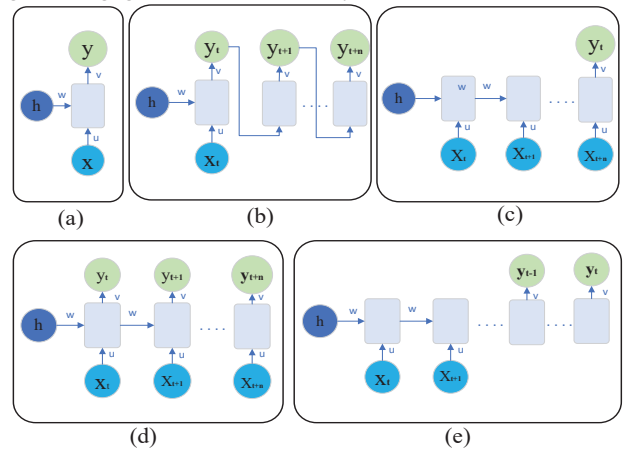
Jeffrey Elman tarafından tasarlanan tekrarlayan sinir ağları, önceki çıkışlarını bir sonraki giriş olarak kullanarak bir döngü oluşturan ve bu döngü esnasında bilgilerin sıralı olarak kullanılmasına özen gösteren öğrenme ve tahmin temelli bir yapay sinir ağı modelidir. Bu ağ yapısı ile bilgilerin kalıcı olarak döngülerde kalmasına ve gerektiği zaman kullanılmasına izin verilmektedir [32]. RNN (Recurrent Neural Network)’ler ileri beslemeli sinir ağlarının aksine kendi giriş belleklerini girdilerin keyfi sıralarını işlemek için kullanabilirler. Bu modelin asıl amacı ardışık şekilde gelen verilerin birbirleriyle ilişkilendirilerek kullanılmasıdır. Genel olarak sinir ağlarında girişler birbirlerinden bağımsızdır. Fakat RNN’ler de her verinin çıktısı önceki verinin hesaplamalarına bağlıdır.

Şekil 8’de RNN algoritmasının çalışma şekli gösterilmiştir. Burada herhangi bir t zamanında, h aktivasyonu, x girdiyi ve y çıktıyı temsil etmektedir. h’ önceki çıkış aynı zamanda bir sonraki giriştir.



Şekil 8: RNN algoritmasının çalışması

RNN’ler, bir döngü şeklinde tasarlandıkları için sıralı bir şekilde gelişen olayları birbirleriyle ilişkilendirebilmektedir. Akış içerisindeki bu ilişkilerin sınıflandırılabilmesinden dolayı da sıklıkla tercih edilmektedir. RNN algoritmasının Şekil 9’da gösterildiği gibi beş farklı çalışma yöntemi bulunmaktadır.

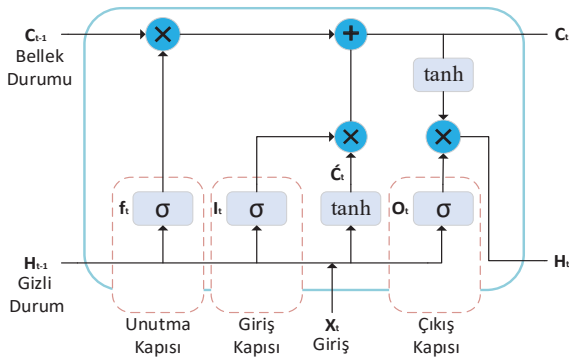


Şekil 9: RNN çalışma yöntemleri, (a) Tek giriş-tek çıkış, (b) Tek giriş-çok çıkış, (c) Çok giriş-çok çıkış, (d) Çoklu sıralı giriş-çoklu sıralı çıkış, (e) Çoklu senkronize giriş-çoklu senkronize çıkış

RNN modeli; Çevirilerde [33], altyazı oluşturmada [34], videolarda gürültü yok etmede [35], uzun metinlerin özeti çıkarılmada [36], el yazısının kime ait olduğunu tespit etmede [37], ses tanımda [38] ve daha birçok alanda kullanılabilir. RNN modeli; Çevirilerde [33], altyazı oluşturmada [34], videolarda gürültü yok etmede [35], uzun metinlerin özeti çıkarılmada [36], el yazısının kime ait olduğunu tespit etmede [37], ses tanımda [38] ve daha birçok alanda kullanılabilir.

4.3. Uzun ve Kısa Süreli Hafıza Ağları

Sepp Hochreiter ve Jürgen Schmidhuber tarafından 1997 yılında RNN modellerindeki birtakım eksiklikleri gidermek amacıyla oluşturulmuştur [13]. RNN modellemesinde zamansal dizeler arasında oluşan boşluklar bir sonraki dizenin tahmin edilmesini zorlaştırmaktaydı [39]. Mesela “Türkiye’nin ana dili **Türkçedir**” cümlesinde **Türkçe** kelimesini tahmin etmek RNN modeli için kolaydır. Fakat “Ben Türkiye de doğdum” ...” Akıcı bir şekilde **Türkçe** konuşabilirim” gibi birbirinden bağımsız iki cümleden yol çıkarak aranan metnin bir dil olacağı tahmin edilebilir, fakat **Türkçe** kelimesi olduğunu tahmin etmek imkânsız yakındır. Bu durumlarda uzun kısa süreli bellek (Long Short-Term Memory-LSTM) algoritması olarak adlandırılan RNN modellemesinin bir türü olan derin öğrenme modeli kullanılabilir. LSTM, değerleri rastgele aralıklarla hatırlayan ve ileri beslemeli sinir ağlarının aksine geri besleme bağlantıları olan yapay bir tekrarlayan sinir ağı mimarisidir. LSTM modellemesi görüntü işleme ek olarak konuşma veya video gibi tümeleşik veri dizilerini de oldukça başarılı bir şekilde işleyebilmektedir. Şekil 10’da LSTM hücresinin diyagram detayları gösterilmiştir.



Şekil 10: Herhangi bir t anında genel LSTM hücresinin diyagramı


LSTM diyagramında yer alan “Giriş Kapısı (I)” giriş verilerinin iletimini, “Unutma Kapısı (f)” önceki bloktan gelen verinin ne kadarının bellekte kalıp ne kadarının unutulacağını, “Aday bellek (Ċ)” yeni bilgi oluşumunun uyarılmasını ve son olarak “Çıkış Kapısı (O)” çıkış verisinin hesaplanmasını ve iletilmesini sağlar. Bu kapılardan [0,1] aralığında çıktı elde etmek için sigmoid, [-1,1] aralığında çıktı elde etmek için de tanjant fonksiyonlarını kullanırlar. LSTM modeli resimleri tarayarak otomatik başlık oluşturma, sessiz videolar için otomatik ses oluşturma, cümle taraması yaparak otomatik kelime üretme [40], düzensiz dillerde öğrenme [41], robotik kalp cerrahisinde [42] ve birçok alanda kullanılmıştır.

4.4. Sınırlı Boltzman Makineleri

Sınırlanmış bir Boltzmann Makinesi (Restricted Boltzmann Machines-RBM), giriş veri seti üzerindeki olasılık dağılımlarını öğrenebilen, derin öğrenme ağlarının temelini oluşturan iki katmanlı rastlantısal bir yapay sinir ağıdır. Bu katmanlar görünür katman ve gizli katman olarak adlandırılır. Görünür katman giriş verilerinin verildiği katmandır. Gizli

katman ise her düğüm için derin öğrenme hesaplamalarının gerçekleştiği katmandır. Nöron benzeri bir birimi temsil eden her bir düğüm katmanlar üzerinde bulunur ve aynı katmandaki düğümler arasında bağlantı bulunmaz. Farklı katmanlarda bulunan düğümler arası bağlantı mevcuttur [43]. Giriş ve çıkış düğümleri sayısal olarak sınırlandırılmamıştır.

Görünür katmandaki bulunan düğümlere RBM ile eğitilecek olan veri kümesinden bir öznitelik alınır. Görünür katmanda bulunan bütün katmanlara aktarılan bu öznitelik gizli katmanda bulunan bir düğüme iletilerek gerekli hesaplamalara tabi tutulur. Bu işlemler bütün katmanlarda bulunan düğümlere uygulanır. Gizli katman çıktılarına belirlenen bir aktivasyon algoritması uygulanır. Bu yapı daha detaylı bir sinir ağı parçasıysa iki katman yerine daha çok gizli katmana sahip bir RBM modellemesi yapılır. Bir numaralı gizli katmanın çıkış verileri, iki numaralı gizli katmanın giriş verileri olarak ve son sınıflama katmanına ulaşmaya kadar istenilen sayıda gizli katmandan geçirilir. Şekil 11’de RBM algoritmasının işlem adımları gösterilmiştir.




Şekil 11: RBM algoritmasının işlem adımları

RBM modeli; Boyut azaltma [44], kümeleme [45], özellik öğrenimi [46], işbirlikçi filtreleme [42] ve konu modelleme [47] gibi çeşitli uygulamalarda kullanılabilir.

4.5. Derin Oto Kodlayıcılar

Derin Oto Kodlayıcılar (Autoencoders -AE) denetimsiz öğrenme yöntemlerinde sıklıkla kullanılan, girdi katmanındaki verileri çıktı katmanına kopyalayan ve literatürde Diablo ağı olarak bilinen bir sinir ağı modelidir [24], [48]. Buradaki amaç giriş olarak verdiğimiz veriyi sıkıştırarak en az kayıp ile en iyi öğrenmeyi gerçekleştirmek ve giriş verimizi çıkış katmanında tekrar oluşturmaktır. AE modeli temel olarak girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanındaki nöron sayısı çıkış katmanındaki nöron sayısına eşit olmalıdır. Gizli katmanda bulunan nöron sayıları değişkenlik gösterebilir.

Şekil 12’de derin oto kodlayıcı algoritma şeması görülmektedir. Giriş ve çıkış katmanlarında bulunan düğümler (nöronlar) gizli katmandaki düğümlerden fazla ise veri kümesi sıkıştırılır. Bu şekilde daha az verinin ağı içerisinde yer alması sağlanır. Bu durum ağı performansını olumlu etkilemektedir. Girdi ve çıktı arasındaki benzerlik algoritmada kullanılan fonksiyonun başarılı olduğunu ispatlar [49].



Şekil 12: Derin oto kodlayıcı algoritma şeması

Bir derin oto kodlayıcının amacı, genel olarak boyutun indirgenmesi amacıyla veri kümesi için bir kodu eğitmek ve N boyutlu bir öznelik vektörünü daha küçük boyutlu bir vektöre minimum kayıpla dönüştürmektir. Boyutsal ışın azaltılmasının yanı sıra otomatik kodlayıcılar, veri sıkıştırma, gürültü giderme [50] ve bir denetimli öğrenme modeli için öznelik çıkartma algoritması olarak kullanılabilir.

5. Derin Öğrenme ve Yapay Sinir Ağı Modellerinin Kullanım Alanları

Derin öğrenme ve yapay sinir ağları modelleri gelişen teknolojiye paralel olarak hayatımızda epeyce yer edinmeye başlamıştır [29]. Doğal dil işleme, sinyal işleme, görüntü işleme, bilgisayarlı görü, sağlık ve robotik gibi birçok alanda kendine yer bulan derin öğrenme, genel olarak günümüz mühendislik uygulamalarında insan gibi düşünen, insan gibi davranışlar sergileyen uygulamalarda da tercih edilmektedir. Büyük veri tabanlarına ve bu verileri hesaplama gücüne sahip büyük teknoloji firmaları (Google, Apple, Facebook, Microsoft, Nvidia, Tesla, Bosch, Mercedes, Baidu vb.) tarafından da kullanılıp ürünlerine uygulanan derin öğrenme yaşantımızın her alanında bize eşlik etmeye devam etmektedir. Bu bağlamda Tablo 1'de günümüzde bu alana öncülük edebilecek güncel akademik çalışmalar belirtilmiştir.

Tablo 1: Güncel çalışmalar

Yıl	Konu	Yazar
2021	İş Sağlığı ve Güvenliği	[51]
2019	Cerrahi Robotlar	[52]
2023	Robotik Sistemler	[52]
2021	Güç Elektroniği Sistemleri	[53]
2020	Görüntü İşleme	[54]
2023	Batarya Yönetim Sistemleri	[55]
2020	PV Panel ve Süper Kapasitör Sistemleri	[56]
2023	Beyin Tümörlerinin Sınıflandırılması	[57]
2022	Siber Güvenlik Duvarı Sistemi	[58]
2021	Maksimum Güç Noktası Takip Sistemleri	[59]
2023	Elektrikli Araçlar	[60]

5.1. Oyun ve Eğlence

2014 yılında Google ekibine katılan Deepmind şirketinin geliştirdiği AlphaGo yazılımı Go oyununda (Çinlilere ait eski bir strateji oyunu) büyük bir başarı elde etti. 2017 yılından önce AlphaGo yazılımında bilgiler, hamleler ve analiz verileri, yazılımcı tarafından sisteme entegre ediliyordu. Fakat 2017 yılında AlphaGo'nun bir üst sürümü olan, Şekil 13'te gösterilen temsili resimde belirtilen şekilde, AlphaGo-Zero'nun piyasaya sürülmesi birçok alışılmışlığı ve bilgi için insana olan ihtiyacı ortadan kaldırdı. Temel eğitim süreçlerinden sonra asla müdahale edilmeyen bu sistem eski sürümüyle yaptığı yaklaşık 100 maçın hepsini kazandı. AlphaGo-Zero kendi kendine veri topluyor ve bu verileri işleyerek hamle yapıyor [61].



Şekil 13: AlphaGo-Zero temsili gösterimi [61]

5.2. Fotoğrafçılık ve Görüntü İşleme

Derin öğrenmenin bir diğer kullanım alanı da resim görüntü renklendirmedir. Gri tonlamalı görüntü girdi olarak alınır ve renklendirilmiş görüntü çıktı olarak elde edilir. Resmin karmaşıklığı ve renk çeşidine göre katman sayısı ve algoritmalar değişkenlik gösterebilir. Şekil 14'te ChromaGAN modeli kullanılarak yapılan bir renklendirme gösterilmiştir. Bu tarz renklendirmelerde resim kalitesi renklendirme kalitesini de arttırmaktadır. Çünkü görüntü işleme basamakları piksel boyutunda ki verileri işleyerek sonuç elde etmektedir [62].



Şekil 14: ChromaGAN modeli kullanılarak yapılan örnek çalışma [62]

ImageNet büyük ölçekli görsel tanıma yarışması (ILSVRC) 2012 yılından beri her yıl düzenlenmektedir. Bu yarışmadaki amaç en az hata oranını elde eden derin öğrenme mimarisini tasarlamaktır. Bu yarışmaya birçok büyük şirket, üniversite araştırmacıları ve tasarımcılar katılmaktadır. Tablo 2'de 2012-2021 yılları arasında gerçekleşen yarışmayı kazanan derin öğrenme mimarileri, tasarımcıları ve doğruluk oranları belirtilmiştir.

Tablo 2: Derin öğrenme modelleri ImageNet yarışma sonuçları [63]

Yıl	Derin Öğrenme Modeli	Tasarımcı	Doğruluk Oranı (%)
1998	Le Net	Yann LeCun	
2012	Alex Net	Alex Krizhevsky Geoffrey Hinton Ilya Sutskever	83,6
2013	ZF Net	Matthew Zeiler Rob Fergus	88,2
2014	Google Net	Google	94,3
2014	Vgg Net	Simonyan Zisserman	92,7
2015	Res Net	Kaiming He	96,4
2016	DRS Net	Deargen Company	96,5
2017	Se Net	Oxford	97,7
2018	PNAS Net	Johns Hopkins Google AI Standford	96,2
2019	FixPNAS Net-5	Hugo Touvron Andrea Vedaldi Matthijs Douze	96,8
2020	Harm-SE-RNX-101 64x4d	Vladimir Krylov Rozenn Dahyot Matej Ulicy	96,4
2021	NF Net-F5	Andrew Brock Samuel Smith Karen Simonyan Soham De	97,6

Bu mimarilerden AlexNet modeli 2012 yılında gerçekleştirilen ILSVRC ImageNet görsel tanıma yarışmasında %83,6 doğruluk oranı elde etmiştir [64]. Doğrusal olmayan fonksiyonlar için Tanh fonksiyonu yerine Relu kullanılarak hız altı kat artırılmış ve eğitim süresi kısaltılmıştır. 2014 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını 22 katman derinliğine ve 144 katmana sahip GoogleNet 94,3% doğruluk oranı ile kazanmıştır. GoogleNet 5 milyon parametre kullanarak AlexNet'e kıyasla 12 kat daha az işlem yüküne sahip olmuştur [65]. Aynı yarışmada VggNet 92,7% doğruluk oranı yakalamıştır. VggNet modeli için 11,13,16 ve 19 katmanlı versiyonlar tasarlanmıştır [66]. Önceki derin öğrenme mimarilerinden farklı olarak yalnızca 2x2 ve 3x3 filtreler kullanılmıştır. 2015 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını 96,4% doğruluk oranı yakalayarak Microsoft ResNet kazanmıştır (Bir insan bir görüntüyü 90-95% doğruluk oranlarıyla sınıflandırabilmektedir). ResNet daha önceki modellerde kullanılanlardan daha fazla sayıda katman kullanmıştır [67].

5.3. Araştırma ve Sohbet Robotları

Bu alanda günümüzde ön plana çıkan uygulamalar yapay zekâ tabanlı arama ve sohbet robotlarıdır. Özellikle ChatGPT, İntercom, Hubspot, Bard ve Genie gibi onlarca programlar oluşturulmuştur. Bu programlardan her biri kendi yapay sinir ağı modelini oluşturmakta ve eğitmektedir. Bu programlar sayesinde kullanıcılar araştırmalar, çeviriler, slaytlar, sunumlar, proje ödevleri ve daha nice aklımıza gelebilecek kütüphanelerde ve kitaplardan saatlerce hatta haftalarca

ulaşacağımız ya da hazırlayacağımız bilgilere saniyeler içinde ulaşabilmektedir. İnanılmaz bir veri havuzuna sahip bu sistemler her salisede bilgi dağarcığını genişletmekte ve kendi yapay zekâ tabanlarını geliştirmektedir. Özellikle Open AI tarafından geliştirilen ChatGPT sohbet robotunun popüleritesi günümüzde giderek artmaktadır. Bu sistemlerin yararlarından çok zararları olacağı da tartışılmakta ve gerekli güvenlik önlemleri alınması için uluslararası kararlar alınmaktadır.

5.4. Güvenlik ve Tespit Sistemleri

2023 yılında meydana gelen depremler ve sonrasında yapılan hasar tespit çalışmaları derin öğrenme konusunun bu alanlardaki gelişimini ve şu anki katkısını ön plana çıkarmıştır. Havadan çekilen görüntüler, konvolüsyonel yapay sinir ağında kullanılarak hasar tespit çalışmaları açısından kolaylık sağlayabilmektedir[68]. Aynı zamanda yer yapısı, sismik dalgalar, bulunulan ana kaya yapısı, iklimsel değişiklikler, yer altı ve üstü beşeri çalışmalar gibi veriler kullanılarak deprem öncesi uyarı sistemleri geliştirilebilmektedir [69], [70]. Her ne kadar depremin gerçekleşme süresi göz önüne alındığında erken uyarı sistemlerinin insanların kaçışı için zaman kazandıracak boyutta olmayacağı düşünülse de anlık olarak gelen uyarı ile doğalgaz ve elektrik gibi sistemler kapatılarak olası kayıpların azaltılması sağlanabilecektir.



Şekil 15: Türkiye'nin bazı bölgelerinin uzaydan tespit edilen deprem hasar haritası [71]

5.5. Sağlık


2020 yılında sağlık alanında yapılan bir çalışmada EKG (Elektrokardiyografi) sinyallerinin konvolüsyonel sinir ağları modellenmesine dayanan bir derin öğrenme çalışması yapılmıştır. Bu çalışma ile kalp ritminde anormallik oluşmasına sebep olan aritmi verileri kullanılmıştır. Bu veriler iki boyutlu resimlere dönüştürülerek konvolüsyonel sinir ağları ile modellenmiştir. Çalışmada LeNet mimarisi kullanılmıştır. Bu çalışma ile daha kısa zamanda aritmi tespiti yapılmıştır [72].

5.6. Ekonomi ve Finans

Çağımızın en büyük sorunlarından biri olan küresel ekonomi gerek pandemi gerek depremler ve gerekse artan enflasyon nedeniyle ağır bir yara almıştır. Gün geçtikçe artan hayat pahalılığına karşın insanlar borsa ve kripto para gibi günümüzde anlık olarak çok miktarda getirisi ve götürüsü olan sistemlere yönelmiştir. Piyasa endekslerinin tahmini ve trend tespiti için algoritmalar hazırlanarak risk analizleri yapılmıştır [73]. Aynı zamanda kripto paralar için fiyat tahmini yapan sistemler geliştirilmektedir [74]. Her ne kadar birçok başarılı çalışma bulunsada da bu şekildeki çalışmalar dikkate alınarak yatırımlar yapılmamalıdır.

5.7. Robotik Sistemler

Derin öğrenmenin en kullanışlı alanlarından biride robotik ve otonom uygulama alanlarıdır. Özellikle insansı robot tasarlamak ve derin öğrenme yöntemlerini kullanarak insana ait birçok özelliği tasarlanan bu robotlara uyarlamak birçok firma gibi Boston Dynamics adlı şirketinde ilk hedeflerinden biri haline gelmiştir. Şu ana kadar ürettiği Spot (köpek robot), Handle (tekerlekli robot), Pick (endüstriyel robot), Bigdog (büyük köpek robot) ve Atlas (insansı robot) firmanın hedeflerine ulaştığını göstermektedir. Bu çalışmaların daha ileri seviyelere getirilmesi toplum için ne tür kolaylıklar ya da tehlikeler getireceği tartışma konusu olarak gündemdeki yerini korumaktadır. En dinamik ve en gelişmiş kontrol sistemlerine sahip olan insansı robot Atlas, tasarlanan algoritmalar sayesinde hareketlerini planlayıp, tüm vücudunu ve çevreyi analiz ederek verilen görevi yerine getirebilmektedir. Şekil 16'da Boston Dynamics firmasının ürettiği robotlar gösterilmiştir.



Şekil 16: Boston Dynamics firmasının ürettiği robotlar [75]


Otonom alanında ise 2015 yılından sonra büyük araba üreticileri (Tesla, Volvo, Mercedes, Nissan, Honda, Audi) 2020'li yılları kendilerine hedef koyarak birçok çalışma yürütmüştür. Bu firmalardan en ileri düzeyde sonuçlar elde eden Tesla firması tam otonom sürüş (Full Self Driving-FSD) adını verdiği tamamen elektrikli (kamaralar, sensörler) ve yapay zekâ odaklı araçlarını günümüzde piyasaya sürmekte ve halen test çalışmaları yaparak yeni güncellemeler geliştirmektedir. 2023 yılı itibarıyla 2. ve 3. seviye (sürücü kontrolünde) sürüşleri yapılan araçların 5.seviye (tam otonom) aşamasının tamamlanması 2026 yılını bulacağı belirtilmektedir. Bu çalışmalar Tesla tarafından tamamen otonom olarak düşünülse de araç sahiplerinin her an müdahale edecek şekilde hazır olmaları gerekliliği konusunda uyarılarda da bulunmaktadır.

5.8. Yapay Zekâ Tabanlı MPPT Sistemleri

Yenilenebilir enerji kaynaklarından olan fotovoltaik sistemler son zamanlarda enerji üretimi alanında söz sahibi olmaya başlamıştır. Gerek iklimsel şartlar gerekse arazi yapısının elverişliliği bu yöntemin ülkemizde kullanımını

yaygınlaştırmıştır. Bu sistemlerin en büyük dezavantajları sıcaklık, güneşlenme, gölgelenme ve maliyet yönünden kaynaklanmaktadır. Bu olumsuzluklar ise fotovoltaik sistemler için en önemli detay olan verimi etkilemektedir. Fotovoltaik sistemlerdeki verim kontrolü geleneksel yöntemlerle yapıldığı gibi son zamanlarda günümüz uygulamalarında çoğunlukla tercih edilen yapay zekâ tabanlı yöntemlerde tercih edilmeye başlanmıştır. Yapay zekâ tabanlı MPPT sistemlerinin geleneksel yöntemlere göre en büyük avantajı değişken hava şartlarına uyum sağlayabilmesi ve yüksek verim oranı elde edebilmesidir [76].

Yapay sinir ağı (YSA) modelleri genel olarak sıcaklık, ışınım, gölgelenme ve güneşlenme sürelerini dikkate alarak bir model oluşturmayı amaçlamaktadır. Şekil 17'de de gösterildiği üzere saydığımız bu nitelikler giriş verileri olarak kullanılır ve çıkış olarak doluluk oranı elde edilir. Bu oran elde edilirken girişte kullanılan veri setleri belirlenen YSA algoritmasında, istenilen sayıda ve istenilen boyutta, belirlenen katmanlarda (girdi, gizli, bellek, fonksiyon vb. katmanlar) eğitilir ve çıkan sonuçlar test algoritmaları ile test edilir. Elde edilen sonuçlar sürekli ve anlık olarak değişen çevresel koşullarda bile sistemlerin yüksek verimlerde çalışmasını sağlamakta ve birim zamanda elde edilen enerji miktarını maksimum seviyede tutmaktadır. Aynı zamanda sistemin stabil çalışmasını sağlayarak elektronik parçaların ömrünü uzatmakta ve maliyet açısından da avantaj sağlamaktadır. Maksimum güç noktası takip sistemi ve algoritmaları güneş panellerinde kullanıldığı gibi anlık değişen rüzgar hızı koşullarında bile maksimum seviyede verim elde edebilmek için rüzgar türbinlerinde de kullanılmaktadır [77].



Şekil 17: Yapay sinir ağları ile MPPT algoritması

Bu sistemlerin genel olarak güç elektroniği tabanlı sistemlerde (dönüştürücüler, motor kontrol devreleri, makine otomasyonları, güç kaynakları ve kontrol sistemleri, iklimlendirme, enerji üretim ve iletim sistemleri, vb.[78]) tercih edilmesinin sebebi oluşabilecek arızaların tespiti, anlık dalgalanmalar, reaktif güç ve iletim kayıpları gibi hem sistemi olumsuz etkileyecek hem de ekonomik yönden kayıpların yaşanmasına sebep olacak olumsuzlukların önüne geçilmesidir.

6. SONUÇ

Bu çalışmada makine öğrenmesinin bir alt dalı olarak kullanılmaya başlanan derin öğrenme ve yapay sinir ağları modelleri ele alınmıştır. Tarihsel olarak yapay zekâ, makine öğrenmesi ve derin öğrenme aşamaları irdelenmiştir. Günümüzde kendi çalışma alanını oluşturan ve bu alanda ilgiyi hak edecek seviyede bir gelişim gösteren derin öğrenme, özellikle yapay zekâ alanının devamı olarak günümüz teknolojisiyle çok iyi bütünleşmiştir. Derin öğrenme sistemlerinde kullanılan yapay sinir ağları modellerinden CNN, RNN, RBM, LSTM ve derin oto kollayıcılarının tanımlamaları, çalışma metodları ve kullanım alanları belirtilmiştir. Bir literatür taraması yapıp en güncel uygulamalar ve çalışmalar hakkında genel bilgiler ve gelişmeler aktarılmıştır.

Sonuç olarak tüm bu gelişmeler ve çalışmalar göz önünde bulundurulduğunda hızla gelişen derin öğrenme ve yapay sinir ağları konusunun artık yaşantımızın vazgeçilmez bir parçası olmaya doğru ilerlediğini görmekteyiz. Evimizde, iş yerimizde, sokakta hemen hemen her yerde yaşantımıza dokunmaya başlayan ve geliştirilebilir olması dolayısıyla yeniliklere daima açık olan derin öğrenme tabanlı uygulamalar, insanı taklit etmeyi bırakıp tamamen insan gibi düşünmeye ve hareket etmeye başlayacağı zaman getireceği tüm olumlu-olumsuz yönler şimdiden ele alınmalıdır. Tüm bu sistemlerin tek amacının canlı yaşamını kolaylaştırma olduğu unutulmamalıdır. Aynı zamanda bu çalışmada da belirtildiği gibi uygulama alanlarının genişliği ve yapılan çalışmalardan yola çıkarak derin öğrenme ve yapay zekâ konuları her yaş grubuna ulaşmalı ve bu yönde yatırımlar yapılmalıdır.

Kaynaklar

- [1] M. Copeland, “What’s the difference between artificial intelligence, machine learning and deep learning.”, 2016. <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/> (Erişim zamanı; 10.15.2022).
- [2] L. Deng ve D. Yu, “Deep learning: Methods and applications”, *Found. Trends Signal Process.*, c. 7, sayı 3–4, ss. 197–387, 2013.
- [3] A. A. Süzen ve K. Kayaalp, *Derin Öğrenme ve Türkiye’deki Uygulamaları*, sayı September. 2018.
- [4] J. Fürnkranz, “Separate-and-Conquer Rule Learning”, ss. 3–54, 1999.
- [5] Y. Lecun, Y. Bengio, ve G. Hinton, “Deep learning”, *Nature*, c. 521, sayı 7553, ss. 436–444, 2015.
- [6] W. S. McCulloch ve W. Pitts, “A logical calculus of the ideas immanent in nervous activity”, *Adv. Intell. Syst. Comput.*, c. 867, ss. 786–798, 1943.
- [7] D. Hubel ve T. Wiesel, “Receptive fields of single neurones in the cat’s striate cortex”, *J. Physiol.*, c. 148(3), 57, sayı 12, ss. 574–591, 1959.
- [8] H. J. Kelley, “Gradient Theory of Optimal Flight Paths”, *ARS J.*, c. 30, sayı 10, ss. 947–954, 1960.
- [9] A. Ivakhnenko, “Cybernetic predicting devices”, sayı September, 1966.
- [10] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”, *Biol. Cybern.*, c. 36, sayı 4, ss. 193–202, 1980.
- [11] S. Aras, “Yapay sinir ağlarıyla zaman serisi tahminlemede yeni bir model seçim stratejisi”, 2013.
- [12] C. R. Rosenberg ve T. J. Sejnowski, “The spacing effect on NETtalk, a massively parallel network”, *Proc. Eighth Annu. Conf. Cogn. Sci. Soc.*, ss. 72–89, 1986.
- [13] S. Hochreiter ve J. Schmidhuber, “Long Short-Term Memory”, *Pak. J. Zool.*, c. 50, sayı 6, ss. 2199–2207, 1997.
- [14] Y. Lecun, L. Bottou, Y. Bengio, ve P. Haffner, “Gradient-Based Learning Applied to Document Recognition”, *Biochem. Biophys. Res. Commun.*, c. 330, sayı 4, ss. 1299–1305, 1998.
- [15] L. Fei-Fei, J. Deng, ve K. Li, “ImageNet: Constructing a large-scale image database”, *J. Vis.*, c. 9, sayı 8, ss. 1037–1037, 2010.
- [16] Y. Taigman, M. Yang, M. Ranzato, ve L. Wolf, “DeepFace: Closing the gap to human-level performance in face verification”, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, ss. 1701–1708, 2014.
- [17] Z. Yu, K. Wang, Z. Wan, S. Xie, ve Z. Lv, “Popular deep learning algorithms for disease prediction: a review”, *Cluster Comput.*, c. 26, sayı 2, ss. 1231–1251, 2023.
- [18] F. Demir, “Ultrason RF Sinyallerinden Göğüs Kanserinin Derin Öğrenme Tabanlı Yaklaşımlarla Tespit Edilmesi”, *Fırat Üniversitesi Mühendislik Bilim. Derg.*, c. 34, sayı 2, ss. 761–768, 2022.
- [19] A. M. N. Erdoğan, T. Öztürk, ve M. Talo, “Yeni bir Evrişimsel Sinir Ağı Modeli Kullanarak Bilgisayarlı Tomografi Görüntülerinden Akciğer Kanseri Tespiti”, c. 34, sayı 2, ss. 795–802, 2022.
- [20] K. A. Joseph, C. Joshua Sony, L. Rajkumar, S. Krishna, A. Francis, ve A. Babu, “Deep Learning based Beach Cleaning Robot”, *2023 2nd Int. Conf. Appl. Artif. Intell. Comput.*, sayı Icaaic, ss. 427–433, 2023.
- [21] M. Haris ve A. Glowacz, “Road object detection: a comparative study of deep learning-based algorithms”, *Multimed. Tools Appl.*, c. 81, sayı 10, ss. 14247–14282, 2022.

- [22] F. Yin, J. Du, X. Xu, ve L. Zhao, "Depression Detection in Speech Using Transformer and Parallel Convolutional Neural Networks", *Electron.*, c. 12, sayı 2, ss. 1–16, 2023.
- [23] N. Jing, Z. Wu, ve H. Wang, "A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction", *Expert Syst. Appl.*, c. 178, sayı April, s. 115019, 2021.
- [24] Y. Bengio, *Learning deep architectures for AI*, c. 2, sayı 1. 2009.
- [25] H. A. Song ve S. Y. Lee, "Hierarchical representation using NMF", *Lect. Notes Comput. Sci.*, c. 8226 LNCS, sayı PART 1, ss. 466–473, 2013.
- [26] S. Wang, "Artificial Neural Network. In: Interdisciplinary computing in java programming", *Springer Int. Ser. Eng. Comput. Sci.*, c. 743, ss. 39–55, 2003.
- [27] A. M. Alsugair ve A. A. Al-Qudrah, "Artificial neural network approach for pavement maintenance", *J. Comput. Civ. Eng.*, c. 12, sayı 4, ss. 249–255, 1998.
- [28] S. W.S., "Neural Networks FAQ's", 1997.
- [29] K. Ozturk ve M. Şahin, "Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış", *Tak. Vekayi*, c. 6, sayı 2, ss. 25–36, 2018.
- [30] D. Hubel and T. Wiesel, "Receptive fields and functional architecture of monkey striate cortex", *J. Physiol.*, c. 195, sayı 1, ss. 215–243, 1968.
- [31] W. Hu, Y. Huang, L. Wei, F. Zhang, ve H. Li, "Deep convolutional neural networks for hyperspectral image classification", *J. Sensors*, c. 2015, 2015.
- [32] E. Gavcar ve H. M. Metin, "Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) İle Tahmini", c. 10, sayı 2, ss. 1–11, 2021.
- [33] D. Bahdanau, K. H. Cho, ve Y. Bengio, "Neural machine translation by jointly learning to align and translate", *3rd Int. Conf. Learn. Represent. ICLR 2015*, ss. 1–15, 2015.
- [34] A. Karpathy ve L. Fei-Fei, "Deep Visual-Semantic Alignments for Generating Image Descriptions Andrej", *Am. Lit. Transition, 2000-2010*, ss. 152–164, 2014.
- [35] C. L. Giles, S. Lawrence, ve A. C. Tsoi, "Noisy time series prediction using recurrent neural networks and grammatical inference", *Mach. Learn.*, c. 44, sayı 1–2, ss. 161–183, 2001.
- [36] A. M. Rush, S. Chopra, ve J. Weston, "A Neural Attention Model for Sentence Summarization Alexander", *Inov. Pendiik. Fis.*, c. 5, sayı 3, ss. 379–389, 2015.
- [37] Y. Shkarupa, R. Mencis, ve M. Sabatelli, "Offline Handwriting Recognition Using LSTM Recurrent Neural Networks", *Int. J. Adv. Res.*, c. 4, sayı 2, ss. 1541–1545, 2016.
- [38] T. Mikolov, M. Karafiat, L. Burget, J. Honza, ve S. Khudanpur, "Recurrent neural network based language model", *Proc. Annu. Meet. Assoc. Comput. Linguist.*, sayı September, ss. 8093–8104, 2010.
- [39] Y. Bengio, P. Simard, ve P. Frasconi, "Learning Long-Term Dependencies with Gradient Descent is Difficult", *Pediatr. Catalana*, c. 66, sayı 2, ss. 53–61, 1994.
- [40] Z. Cao, F. Wei, L. Dong, S. Li, ve M. Zhou, "Ranking with recursive neural networks and its application to multi-document summarization", *Proc. Natl. Conf. Artif. Intell.*, c. 3, ss. 2153–2159, 2015.
- [41] J. Schmidhuber, F. Gers, ve D. Eck, "Learning nonregular languages: A comparison of simple recurrent networks and LSTM", *Neural Comput.*, c. 14, sayı 9, ss. 2039–2041, 2002.
- [42] R. Salakhutdinov, A. Mnih, ve G. Hinton, "Restricted Boltzmann Machines for Collaborative Filtering", *Nonlinear Anal. Real World Appl.*, c. 10, sayı 5, ss. 2700–2708, 2007.
- [43] G. E. Hinton, "A practical guide to training restricted boltzmann machines", *Lect. Notes Comput. Sci.*, c. 7700 LECTU, ss. 599–619, 2012.
- [44] G. E. Hinton ve R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks", c. 313, sayı July, ss. 504–507, 2006.
- [45] H. Larochelle ve Y. Bengio, "Classification using discriminative restricted boltzmann machines", *Proc. 25th Int. Conf. Mach. Learn.*, ss. 536–543, 2008.
- [46] A. Coates, H. Lee, ve A. Y. Ng, "An analysis of single-layer networks in unsupervised feature learning", *J. Mach. Learn. Res.*, c. 15, ss. 215–223, 2011.
- [47] R. Salakhutdinov ve G. Hinton, "Replicated Softmax: an Undirected Topic Model", ss. 1–8, 2009.
- [48] X. Lu, Y. Tsao, S. Matsuda, ve C. Hori, "Speech enhancement based on deep denoising autoencoder", ss. 436–440, 2013.
- [49] P. Vincent, H. Larochelle, Y. Bengio, ve P. A. Manzagol, "Stacked denoising autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion", *J. Mach. Learn. Res.*, c. 11, ss. 3371–3408, 2010.
- [50] O. Kaynar, H. Arslan, Y. Görmez, ve Y. E. Işık, "Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti", *Bilişim Teknol. Derg.*, c. 11, sayı 2, ss. 175–185, 2018.
- [51] İ. Topaloğlu ve M. E. Şahin, "Endüstri 4.0'ın İş Sağlığı ve Güvenliğine Katkıları ve Hata Türü ve Etkileri Analizi Risk Değerlendirme Metoduyla Ambulansta Bir İnceleme", *Tak. vekayi*, ss. 66–94, 2021.

- [52] M. Soori, B. Arezoo, ve R. Dastres, “Artificial intelligence, machine learning and deep learning in advanced robotics, a review”, *Cogn. Robot.*, c. 3, sayı April, ss. 54–70, 2023.
- [53] S. Zhao, F. Blaabjerg, ve H. Wang, “An overview of artificial intelligence applications for power electronics”, *IEEE Trans. Power Electron.*, c. 36, sayı 4, ss. 4633–4658, 2021.
- [54] L. Li, “Application of deep learning in image recognition”, *J. Phys. Conf. Ser.*, c. 1693, sayı 1, 2020.
- [55] V. S. R. Kosuru ve A. Kavasseri Venkitaraman, “A Smart Battery Management System for Electric Vehicles Using Deep Learning-Based Sensor Fault Detection”, *World Electr. Veh. J.*, c. 14, sayı 4, 2023.
- [56] M. E. Şahin ve F. Blaabjerg, “A hybrid PV-battery/supercapacitor system and a basic active power control proposal in MATLAB/simulink”, *Electron.*, c. 9, sayı 1, ss. 1–17, 2020.
- [57] F. Uysal ve M. Erkan, “Evrşimsel Sinir Ağları Temelli Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Manyetik Rezonans Görüntülerinin Sınıflandırılması”, ss. 19–27, 2023.
- [58] K. Baysal, “Derin öğrenme temelli yeni nesil güvenlik duvarının tasarlanması”, sayı 8.5.2017, s. 2003, 2022.
- [59] H. İ. Temel, “Yapay zeka temelli maksimum güç noktası takibi”, 2021.
- [60] A. K. Venkitaraman ve V. S. R. Kosuru, “Hybrid Deep Learning Mechanism for Charging Control and Management of Electric Vehicles”, *Eur. J. Electr. Eng. Comput. Sci.*, c. 7, sayı 1, ss. 38–46, 2023.
- [61] L. Greenemeier, “AI versus AI: Self-Taught AlphaGo Zero Vanquishes Its Predecessor”, *Scientific American*, 2017. <https://www.scientificamerican.com/article/ai-versus-ai-self-taught-alphago-zero-vanquishes-its-predecessor/> (Erişim zamanı; 11.16.2022).
- [62] P. Vitoria, L. Raad, ve C. Ballester, “ChromaGAN: Adversarial picture colorization with semantic class distribution”, ss. 2434–2443, 2020.
- [63] “Image Classification on ImageNet”, *Paperswithcode*. <https://paperswithcode.com/sota/image-classification-on-imagenet/> (Erişim zamanı; 11.15.2022).
- [64] A. Krizhevsky, I. Sutskever, ve G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, *Handb. Approx. Algorithms Metaheuristics*, ss. 1–1432, 2012.
- [65] C. Szegedy, S. Ioffe, V. Vanhoucke, ve A. A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”, *Pattern Recognit. Lett.*, c. 42, sayı 1, ss. 11–24, 2017.
- [66] K. Simonyan ve A. Zisserman, “Very deep convolutional networks for large-scale image recognition”, *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, ss. 1–14, 2015.
- [67] O. Russakovsky vd., “ImageNet Large Scale Visual Recognition Challenge”, *Int. J. Comput. Vis.*, c. 115, sayı 3, ss. 211–252, 2015.
- [68] E. E. Maraş ve H. İ. Sarıyıldız, “İHA ile Derin Öğrenme Algoritmaları Kullanılarak Hasarlı Yapıların Tespit Edilmesi”, *Afyon Kocatepe Univ. J. Sci. Eng.*, c. 23, sayı 2, ss. 427–437, May. 2023.
- [69] M. Kanber ve Y. Santur, “Time Series and Data Science Preprocessing Approaches for Earthquake Analysis”, *Eur. J. Sci. Technol.*, sayı 49, s. 12, 2023.
- [70] G. Boost, “Makine öğrenimi yöntemleri kullanılarak Türkiye ’ nin kuzeybatısı için deprem tahmini”, c. 44, sayı 2, 2023.
- [71] “Türkiye’nin uzaydan tespit edilen deprem hasar haritası”, 2023. <https://www.arkeolojikhaber.com/haber-turkiyenin-uzaydan-tespit-edilen-deprem-hasar-haritasi-36362/>
- [72] E. Izci, M. Degirmenci, M. A. Ozdemir, ve A. Akan, “Derin Öğrenme ile EKG Aritmi Tespiti”, *2020 28th Signal Process. Commun. Appl. Conf.*, ss. 1–4, 2020.
- [73] S. Perla, R. Bisoi, ve P. K. Dash, “A hybrid neural network and optimization algorithm for forecasting and trend detection of Forex market indices”, *Decis. Anal. J.*, c. 6, sayı January, s. 100193, 2023.
- [74] A. B. Wardak ve J. Rasheed, “Uzun Kısa Vadeli Bellek Tekrarlayan Sinir Ağı Kullanarak Bitcoin Kripto Para Birimi Fiyat Tahmini”, *Eur. J. Sci. Technol.*, ss. 47–53, 2022.
- [75] M. Han ve M. Sarazen, “Boston Dynamics Robodog Opens a Door, Owns the Internet”, 2018. <https://syncedreview.com/2018/02/13/boston-dynamics-robodog-opens-a-door-owns-the-internet/> (Erişim zamanı; 01.10.2023).
- [76] U. Younas, “Deep Learning LSTM-based MPPT Control of 100kW Dual Stage Grid Tied Solar PV System”, ss. 1–33, 2023.
- [77] D. Belkhiri, M. Ajaamoum, K. Cherifi, ve A. Elidrissi, “Artificial Intelligence-based MPPT Techniques in Wind Energy Systems: A Literature Review”, *2023 3rd Int. Conf. Innov. Res. Appl. Sci. Eng. Technol. 2023*, sayı May, 2023.
- [78] P. Qashqai, H. Vahedi, ve K. Al-Haddad, “Applications of artificial intelligence in power electronics”, *IEEE Int. Symp. Ind. Electron.*, c. 2019-June, ss. 764–769, 2019.

Özgeçmişler



Ercan Akın, 2017 yılında İnönü Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden, lisans eğitimini tamamlayarak, mezun olmuştur. 2017 yılından beri Çay İşletmeleri Genel Müdürlüğü kurumunda çalışmaktadır. 2022 yılında Recep Tayyip Erdoğan Üniversitesinde Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans programına başlamıştır. Başlıca araştırma alanları güç elektroniği, yapay sinir ağları ve yenilenebilir enerji sistemlerinin modellenmesi ve kullanılmasıdır.



Mustafa Ergin Şahin, 2002 yılında Karadeniz Teknik Üniversitesi (KTÜ) Elektrik-Elektronik Mühendisliği bölümünden mezun olup lisans derecesini almıştır. Yüksek Lisans eğitimini 2003-2006 yılları arasında Ankara Gazi Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalında tamamlamıştır. Doktora eğitimini ise 2008-2014 yılları arasında Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde tamamlamıştır. Aalborg Üniversitesi Enerji Teknolojileri Bölümünde TÜBİTAK 2219 doktora sonrası araştırma programı kapsamında misafir araştırmacı olarak bir yıl süreyle yer almıştır. Halen RTE Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde doçent olarak görev yapmaktadır. Başlıca araştırma alanları güç elektroniği, kontrol, elektromanyetik kirlilik ve yenilenebilir enerjinin kullanımınıdır. Devre analizi ve ölçme ile elektronik laboratuvarı üzerine iki kitabın yazarıdır. Aynı zamanda bir uluslararası derginin de kurucusu ve editörüdür.

EEG+YKS Tabanlı Beyin Bilgisayar Arayüzü Sistemlerinde Makine Öğrenme Tekniklerinin Kullanımına İlişkin İnceleme

Research on the Use of Machine Learning Techniques in EEG+YKS-Based Brain Computer Interface Systems

 Ebru Ergün¹,  Önder Aydemir²,  Onur Erdem Korkmaz³

¹Elektrik-Elektronik Mühendisliği Bölümü, Recep Tayyip Erdoğan Üniversitesi, Rize, Türkiye
ebru.yavuz@erdogan.edu.tr

²Elektrik-Elektronik Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
onderaydemir@ktu.edu.tr

³Elektrik-Elektronik Mühendisliği Bölümü, Atatürk Üniversitesi, Erzurum, Türkiye
onurerdem.korkmaz@atauni.edu.tr

Özet

Beyin-bilgisayar arayüzü (BBA), kişinin beyin aktivitesini algılayan ve bu aktiviteyi bir bilgisayar veya diğer dış cihazlarla iletişim kurmak için kullanılabilir bir formata çeviren sistemdir. BBA sistemleri için çeşitli beyin görüntüleme teknikleri, giriş işareti olarak kullanılmaktadır. Diğer alternatiflere göre birçok avantajı olmasından dolayı elektroensefalografi (EEG), BBA sistemlerinde sıkça tercih edilmektedir. Ancak, sadece EEG kullanarak yapılan çalışmalar, BBA sistemlerinin performansını tatmin edici bir seviyeye yükseltememiştir. Son yıllarda, beyin görüntüleme yöntemlerinin kendilerine özgü avantaj ve dezavantajlarından ötürü farklı sinyal kayıt yöntemlerini bir araya getirerek kullanma eğilimi artmıştır. Bu çalışmada, EEG+yakın kızılötesi spektroskopisi (YKS) tabanlı BBA sistemlerinde makine öğrenme tekniklerinin kullanımına ilişkin yapılan mevcut araştırmaların bir incelemesi sunulmaktadır. Öncelikle, EEG ve YKS sinyallerinin tekli nasıl kullanıldığı ve daha sonra bu iki sinyalin nasıl hibrit BBA sistemlerinde bir araya getirildiği ilgili literatürle sunulmuştur. Çalışmalar incelendiğinde, hibrit BBA ile EEG'ye göre sınıflandırma doğruluğu ortalama %7.58, YKS'ye göre ise %13.04 artış hesaplanmıştır. Ulaşılan sonuç, hibrit BBA sistemlerinin insan-makine etkileşimini iyileştirmeye önemli katkılar sağlayacağını göstermektedir.

Anahtar Kelimeler: Hibrit, Elektroensefalografi, Yakın Kızılötesi Spektroskopisi, Beyin Bilgisayar Arayüzü, Sınıflandırma, Öznitelik Çıkarma

Abstract

A brain-computer interface (BCI) is a system that detects a person's brain activity and translates this activity into a usable format for communicating with a computer or other external devices. Various neuroimaging techniques are used as input

signals for BCI systems. Electroencephalography (EEG) is frequently preferred in BCI systems because it has many advantages over other alternatives. However, studies using only EEG have not been able to increase the performance of BCI systems to a satisfactory level. In recent years, there has been an increased tendency to combine different signal recording methods due to the unique advantages and disadvantages of brain imaging methods. In this study, a review of current research on the use of machine learning techniques in EEG+near-infrared spectroscopy (YKS) based BCI systems is presented. First of all, how single EEG and YKS signals are used and then how these two signals are combined in hybrid BCI systems are presented with the relevant literature. When the studies were examined, an average increase of 7.58% in classification accuracy was calculated with hybrid BCI compared to EEG and 13.04% compared to YKS. The result shows that hybrid BCI systems will make significant contributions to improving human-machine interaction.


Keywords: Hybrid, Electroencephalography, Near Infrared Spectroscopy, Brain Computer Interface, Classification, Feature Extraction

1. Giriş

Beyin bilgisayar arayüzü (BBA), beyin ile bilgisayar arasında iletişim kurmayı sağlayan bir sistemdir [1]. BBA, beyinden gelen elektriksel sinyalleri algılayarak bunları bilgisayar sistemlerine dönüştürür ve kullanıcının beyin aktivitesini bilgisayar tarafından anlaşılabilir bir formata çevirmesine olanak tanır. BBA, genellikle Şekil 1'de yer alan ana bloklardan oluşur [2]. Bunlardan ilki beyin sinyallerinin alındığı kısımdır. Bu kısımda beyin aktivitesini ölçmek için sensörler veya elektrotlar kullanılır. Elektroensefalografi (EEG), yakın kızılötesi spektroskopisi (YKS), elektrokortikografi (ECoG), magnetoensefalografi (MEG), fonksiyonel manyetik

görüntüleme ve pozitron emisyon tomografisi gibi yöntemler beyin sinyallerini kaydetme yöntemlerinden bazılarıdır [3]. İkinci kısımda beyinden kaydedilen sinyallerin ön işleme ve filtrelemelerinin yapıldığı bloğa geçilir. Bu blok, sinyalleri düzeltmek, arka plan gürültüsünü azaltmak ve istenmeyen bileşenleri filtrelemek için işlemler yapar. Örneğin, sinyaller düşük frekanslı gürültüden arındırılabilir veya hareket artefaktları giderilebilir. Üçüncü kısım ise öznelik çıkarım bloğudur. Öznelik çıkarım bloğu, işlenmiş beyin sinyallerinden anlamlı özneliklerin çıkarılmasını sağlar. Bu blok, sinyalleri analiz ederek kullanıcının niyetlerini, düşüncelerini veya isteklerini yansıtan belirli örüntü tanımlar. Dördüncü blok sınıflandırma veya tahmin işlemlerinin yapıldığı bloktur. Bu blokta sınıflandırma algoritmaları ile kullanıcının niyeti veya düşüncesi belirlenmeye çalışılır. Son kısım ise kontrol çıktısı bloğudur. Bu blok, kullanıcıya beyin aktivitesine dayalı bir geri bildirim sunar. Örneğin, bir görüntü, ses veya titreşim geri bildirim sağlanabilir. Bu geri bildirim, kullanıcının beyin sinyallerini anlamasını ve kontrol etmesini kolaylaştırır.

Son yıllarda, BBA teknolojileri hızla gelişse de hala istenilen seviyeye ulaşmadığı literatürde yer alan çalışmalardan anlaşılmaktadır [4]. Bu durum araştırmacıları daha yüksek performanslı BBA çalışmaları için yeni yöntemler arayışına yöneltmiştir. Son yıllarda, bu yeni yöntemler arasında BBA sisteminin giriş işareti olarak hibrit beyin görüntüleme tekniği kullanma eğilimi artmıştır. Hibrit (multimodal) BBA, birden fazla beyin görüntüleme yöntemini kullanarak beyin aktivitesini ölçen bir sistemdir [5]. Bu tür bir arayüz, beyin sinyallerini algılamak için birden çok görüntüleme yöntemini (örneğin, EEG, fMRI, ECoG) birleştirir ve farklı duyuşal veya motor tepkileri sağlamak için çeşitli geri bildirim yöntemlerini kullanır. Multimodal BBA sistemi, daha fazla hassasiyet, doğruluk ve kullanılabilirlik sağlamak için geliştirilmeye devam etmektedir.




Şekil 1. Beyin bilgisayar arayüzü ana blokları

2. Temel Bilgiler

2.1. Elektroensefalografi

EEG, beyindeki elektriksel aktivitenin kaydedilmesi ve analiz edilmesi için kullanılan bir yöntemdir [6]. Beyindeki sinir hücrelerinin elektriksel aktiviteleri sonucunda oluşur. Sinir hücreleri veya nöronlar, bilgiyi elektriksel sinyaller halinde ileten ve iletişim kuran özelleşmiş hücrelerdir. Beyinde milyarlarca nöron bulunur ve bu nöronlar arasındaki etkileşimler elektriksel sinyallerin oluşmasına neden olur. Beyin hücreleri arasındaki iletişim, nöronların hücre zarlarındaki iyon akışlarıyla gerçekleşir. Hücre zarının iç ve dış kısımları arasında iyon konsantrasyonları farklıdır ve bu fark, bir elektrik potansiyeli oluşturur [7]. Bu potansiyel, "aksiyon potansiyeli" adı verilen

elektriksel bir uyarı şeklinde iletilir. Bir nöron uyarıldığında, hücre zarındaki iyon kanalları açılır ve iyonlar hücre zarı boyunca geçerken potansiyel değişir. Bu değişim, nöronun elektriksel aktivitesini temsil eden bir aksiyon potansiyeli olarak adlandırılır. EEG sinyalleri, elektrotlar aracılığıyla beyin yüzeyindeki elektriksel aktiviteyi ölçerken bu aksiyon potansiyellerini algılar. Elektrotlar, beyin yüzeyine yerleştirilen ve hücre zarındaki potansiyel değişikliklerini algılamak için kullanılan metal elektrotlardır. Beyin hücrelerinin elektriksel aktivitesi, elektrotlardan alınan sinyallere yansır ve amplifikatörler aracılığıyla güçlendirilir. EEG, beyindeki farklı nöron gruplarının senkronize elektriksel aktivitelerini topluca ölçer. Bu nedenle, kaydedilen EEG sinyali, genellikle birleşik bir sinyal olarak ifade edilir. EEG sinyali, belirli frekans aralıklarında ritmik desenler olarak gözlemlenebilir. Bu desenler, beyin dalgaları olarak adlandırılır ve belirli frekans bantlarına ayrılır [8]. Bazı yaygın beyin dalgaları beta, alfa, teta ve deltadır ve Şekil 2'de gösterilmiştir. Bunlar arasında beta dalgaları yüksek frekanslı (13-30 Hz) beyin dalgalarıdır. Uyanıklık, dikkat, konsantrasyon ve zihinsel aktivite ile ilişkilidir. Alfa dalgaları orta frekanslı (8-12 Hz) beyin dalgalarıdır. Dinlenme, gevşeme ve gözlerin kapatılmasıyla ilişkilidir. Teta dalgaları ise düşük frekanslı (4-7 Hz) beyin dalgalarıdır. Uykunun hafif aşamaları, rüyalar ve meditasyon ile ilişkilidir. Son olarak, delta dalgaları çok düşük frekanslı (0.5-4 Hz) beyin dalgalarıdır. Derin uyku aşamaları, restoratif dinlenme ve bazı nörolojik bozukluklarla ilişkilidir [9].



Şekil 2. EEG verileri için frekans bant aralıkları


EEG sinyalleri, beyin aktivitesini yansıtan elektriksel bir ölçüm sağlar ve bu ölçümler, beyin fonksiyonlarını incelemek, beyin aktivitesiyle ilişkili bozuklukları tanımlamak ve nörolojik araştırmalar için değerli bir kaynak olarak kullanılır. EEG, BBA sisteminin giriş işareti olarak en yaygın olarak kullanılan beyin görüntüleme tekniğidir. Bu amaçla literatürde 2 sınıflı veya çok sınıflı EEG tabanlı BBA işaretlerini sınıflandırıcı çalışmalar mevcuttur. Bunlar arasında Chai ve arkadaşları çalışmalarında sol, sağ ve ileri tekerlekli sandalye hareketi hayaline dayalı EEG veri kümesi ile çalışmışlardır. Veri kümesinden güç spektral yoğunluğu (GSY) tabanlı öznelikler çıkartmışlar ve çıkarılan öznelikleri yapay sinir ağları ile sınıflandırmışlardır. En iyi ikili sınıflandırma ile %85 sınıflandırma doğruluğuna (SD) ulaşmışlardır [10]. Verma ve arkadaşları çalışmalarında BCI Yarışması III veri kümesi ile ilgilenmişlerdir. Sağ el-sağ ayak hareketi hayaline faydalı EEG veri kümesinden ayırık dalgacık dönüşümü (ADD) tabanlı öznelikler çıkartmışlar ve bu öznelikleri en küçük kareler destek vektör makineleri (DVM) ile sınıflandırarak %99.40 SD'ye ulaşmışlardır [11]. Bhatti ve arkadaşları ise BCI Yarışması IV veri kümesi ile çalışmışlardır. Sağ-sol el, ayak ve dil motor hareketi hayaline dayalı 4 sınıflı veri kümesinden ortak uzamsal örüntü (OUÖ) tabanlı öznelikler çıkartmışlardır. Çıkarılan öznelikler DVM ile sınıflandırarak %90.57'lik SD hesaplamışlardır [12]. Bagh ve arkadaşlarının

yaptığı EEG tabanlı çalışmada ise BCI yarışma III veri kümesi analiz edilmiştir. Burada Hilbert Dönüşümü kullanılarak sağ-sol el, ayak ve dil tabanlı motor hareketi hayaline dayalı veri kümesinden öznitelikler çıkarılmıştır. Çıkarılan öznitelikler ise DVM ile sınıflandırılarak 4 sınıf için %86.11 SD hesaplamışlardır [13]. Wang ve Sourina 10 kişiden kaydedilmiş 14 kanallı zihinsel aritmetik tabanlı kaydedilen EEG veri kümesi ile çalışmışlardır. Veri kümesinden GSY, istatistiksel ve higuchi fraktal boyut spektrumu (HFBS) tabanlı öznitelikler çıkartarak bu öznitelikleri DVM ile sınıflandırmışlardır. HFBS tabanlı öznitelikler ile en iyi sonuca ulaşarak her bir kanal için %69.42 ile %84.15 arasında SD hesaplamışlardır [14]. Yi ve arkadaşları sol/sağ el, ayaklar motor hareketi hayaline (MHH) dayalı veri kümesinden OUÖ tabanlı öznitelikler çıkartmışlar ve bunları DVM ile sınıflandırarak %84 SD elde etmişlerdir [15]. Başka bir EEG ile yapılan çalışmada ise Dokare ve arkadaşları sağ ve sol el MHH dayalı veri kümesi ile çalışarak %78.57'lik SD'ye ulaşmışlardır. Burada EEG işaretlerinden ADD tabanlı öznitelikler çıkartmışlar ve öznitelikleri DVM ile sınıflandırmışlardır [16]. Lindig-Leon ve arkadaşları ise çalışmalarında sağ-sol el, iki el MHH dayalı ve dinlenmek tabanlı EEG verileri ile çalışmışlardır. İşaretten OUÖ tabanlı öznitelikler çıkartmışlar ve bu öznitelikleri doğrusal ayırım analizi (DAA) ile sınıflandırarak %51.67 SD hesaplamışlardır [17].

2.2. Yakın Kızılötesi Spektroskopisi


Yakın kızılötesi (YK), elektromanyetik spektrumun kızılötesi bölgesinde yer alan bir ışık türüdür. Kızılötesi ışık, insan gözü tarafından algılanamaz, ancak bazı özel cihazlarla görülebilir hale getirilebilir. Bu ışık, elektromanyetik spektrumun görünür ışık bölgesinin hemen ötesinde yer alır. Yaklaşık 700 nanometreden (nm) başlayarak 2.500 nm'ye kadar olan dalga boylarını kapsar. YK ışık, termal ışınım ve moleküler titreşimlerden kaynaklanır [18]. YKS, YK ışığın maddelerle etkileşimini kullanarak maddelerin kimyasal yapısını ve özelliklerini inceleyen bir analiz yöntemidir. Bu yöntemde, bir YK ışık kaynağı, bir örnek üzerine yönlendirilir ve örneğin yansımaları, absorpsiyonu veya saçılması ölçülerek spektrum elde edilir. YKS, elektromanyetik spektrumun YK bölgesindeki dalga boylarının kullanılmasına dayanır. Bu bölgedeki ışık, maddenin kimyasal bağlarındaki titreşimlerden kaynaklanan enerji emilim ve yansıma olaylarına neden olur. Her bir molekülün kendine özgü bir titreşim spektrumu vardır ve bu spektrum, örneğin içinde bulunan kimyasal bileşenlerin tanımlanması ve miktarlarının belirlenmesi gibi bilgileri sağlar. YKS birçok farklı uygulama alanında kullanılmaktadır. Örneğin, kimyasal analizde bu yöntem, birçok kimyasal bileşimin tanımlanması, niceliksel analizi ve kalite kontrolü için kullanılır. Gıda endüstrisinde, ilaç endüstrisinde, petrokimya alanında ve diğer kimyasal süreçlerde kullanılabilir. Diğer bir kullanım yeri ise tarım ve gıda sektörüdür. Tarım ürünlerinin kalite kontrolü, olgunluk seviyelerinin belirlenmesi, nem içeriğinin ölçümü ve diğer tarımsal uygulamalarda YKS kullanılır. Buna ek olarak ilaç endüstrisinde kullanılmaktadır. İlaç üretiminde, etken madde analizi, formülasyon kontrolü ve saflık tespiti gibi amaçlarla YKS kullanılır. Diğer bir önemli kullanıldığı yer ise biyomedikal araştırmalar alanıdır. YKS, biyolojik dokularda oksijenlenme düzeyini ve doku metabolizmasını ölçmek, kan analizi yapmak, kanser teşhisinde kullanılan tümör sınıflandırması gibi alanlarda kullanılır. YKS, acı vermeyen, hızlı ve hassas bir analiz yöntemi olarak bilinir. Genellikle örnek hazırlığına ihtiyaç duymaz ve gerçek zamanlı veri alımı sağlar. Bu nedenle birçok endüstriyel ve araştırma

alanında yaygın bir şekilde kullanılan bir analiz yöntemidir. YKS aynı zamanda son yıllarda beyin görüntüleme alanında kullanılması ile popüler olmuştur [19]. YKS, beyindeki oksijenlenme düzeylerini ve nöral aktivite ile ilişkilendirmeyi sağlar. Bu teknik, beyin dokusuna YK ışık verilmesi ve dokudan yansıyan veya geçen ışığın ölçülmesi prensibine dayanır. YKS, beyin aktivitesini ölçmek için iki temel prensibe dayanır: oksijenlenme durumunun ölçümü ve nöral aktivite ile bağlantılandırma durumudur. Oksijenlenme durumu, beyin dokusuna yönlendirilen YK ışığın dokuda absorbe edilip saçılması yoluyla belirlenir. Oksijenlenme durumu, oksijenli hemoglobin (HbO) ve deoksijenli hemoglobin (HbR) miktarının oranına dayanır ve absorpsiyon spektrumları Şekil 3'te gösterilmiştir.



Şekil 3. Optik penceredeki emilme spektrumu

Nöral aktiviteyle ilişkilendirme, bu oksijenlenme değişikliklerinin sinirsel aktivitenin bir göstergesi olması ilkesine dayanır. Şekil 4'te hemoglobin konsantrasyonlarının emilme ve saçılma yöntemiyle elde edilmesi gösterilmiştir. Burada ışık, yayıcıdan gelen kızılötesi ışık dokuyla temas ederek detektör yardımıyla kanallara veri sağlamaktadır, Burada görüldüğü gibi detektör ile ışık yayıcı arasında veri alımı sırasında yay şeklinde bir görüntü oluşmaktadır.



Şekil 4. Hemoglobin konsantrasyonlarının elde edilmesi

YKS'de modifiye edilmiş Beer-Lambert (MBL) yasası ile işaret HbR ve HbO hemoglobin konsantrasyonlarına ayrılır. MBL, Denklem 1'de verildiği gibi, optik yoğunluktaki ($\Delta OPDE$) değişikliklerin, bir test koşulundan önce ve sonra ışık

zayıflamasında ölçülen bir değişiklikten hesaplanabileceğini göstermektedir.

$$\Delta OPDE = \log \frac{I_E}{I_G} = \dagger \Delta cr(dPF) \quad (1)$$

Denklem 1'de, I_E ve I_G , ilgi duyulan problem için sırasıyla ortalama baz çizgisi ve aktivasyon koşulları altında ölçülen ışık yoğunluğunu temsil etmektedir. I_G , ışığı emen bileşiğin molar konsantrasyonları için sönmüleme katsayısıyla, bileşiğin konsantrasyonu (c) ve optik yolu uzunluğuyla orantılıdır. Optik yol uzunluğu, kaynak-alıcı mesafesi (r) ve dökülme ortamının sönmüleme katsayısının bir fonksiyonu olan diferansiyel yol uzunluğu faktörü (dPF) olarak bilinen bir çarpanın çarpımı olarak ifade edilir [20]. Işık sönmülemesindeki toplam değişiklikler, her bir emici bileşiğin katkılarından oluşan lineer bir toplam olarak ifade edilir. Çünkü serebral dokudaki YK ışığının temel emicileri HbO ve HbR'dir ve Denklem 1, Denklem 2 olarak genişletilebilir.

$$\Delta OPDE^\lambda = \{ \dagger_{HbO}^\lambda \Delta[HbO] + \dagger_{HbR}^\lambda \Delta[HbR] \} r(dPF^\lambda) \quad (2)$$

Denklem 2'de, $\Delta OPDE^\lambda$, λ dalga boyunda optik yoğunluğu ifade eder. \dagger_{HbO}^λ ve \dagger_{HbR}^λ sırasıyla HbO ve HbR'nin λ dalga boyundaki sönmüleme katsayılarıdır. dPF^λ ise λ dalga boyundaki yetişkin insan kafasının diferansiyel yol uzunluğu faktörüdür. Bu durumda $\Delta[HbO]$ ve $\Delta[HbR]$ değişiklikleri λ_1 ve λ_2 dalga boylarında optik yoğunluk değişikliklerini hesaplayarak belirlenebilir. Denklemler sistemi çözülerek, sırasıyla Denklem 3 ve Denklem 4 olarak verilen $\Delta[HbO]$ ve $\Delta[HbR]$ elde edilir.

$$\Delta[HbR] = \frac{\dagger_{HbO}^{\lambda_2} \left(\frac{\Delta OPDE^{\lambda_1}}{DPF^{\lambda_1}} \right) - \dagger_{HbO}^{\lambda_1} \left(\frac{\Delta OPDE^{\lambda_2}}{DPF^{\lambda_2}} \right)}{r(\dagger_{HbR}^{\lambda_1} \dagger_{HbO}^{\lambda_2} - \dagger_{HbR}^{\lambda_2} \dagger_{HbO}^{\lambda_1})} \quad (3)$$

$$\Delta[HbO] = \frac{\dagger_{HbR}^{\lambda_2} \left(\frac{\Delta OPDE^{\lambda_1}}{DPF^{\lambda_1}} \right) - \dagger_{HbR}^{\lambda_1} \left(\frac{\Delta OPDE^{\lambda_2}}{DPF^{\lambda_2}} \right)}{r(\dagger_{HbR}^{\lambda_2} \dagger_{HbO}^{\lambda_1} - \dagger_{HbR}^{\lambda_1} \dagger_{HbO}^{\lambda_2})} \quad (4)$$

YKS'nin bazı avantajları nedeniyle beyin görüntüleme alanında kullanımı, giderek artmaktadır. Avantajlarından biri acı vermeyen bir yöntem olmasıdır. Başın üzerine yerleştirilen problarla beyin aktivitesini ölçmek için cilde temas eden ışık kullanır [20]. Bu nedenle, cerrahi müdahale gerektirmez ve katılımcılar için rahattır. Diğer bir avantaj, gerçek zamanlı ölçüm sağlamasıdır. Anlık beyin aktivitesini izlemek için hızlı veri toplama ve analiz yeteneği sunar. YKS cihazlarının, taşınabilir ve hareket halinde kullanılabilir olması diğer avantajlarından biridir. Taşınabilir olması YKS'nin laboratuvar ortamının dışında, gerçek dünya koşullarında kullanılabilmesini sağlar. YKS ayrıca çocuklar ve bebekler için uygundur. Bu nedenle, pediatrik araştırmalarda ve klinik uygulamalarda yaygın olarak kullanılmaktadır. Araştırmacılar, literatürde şimdiye kadar farklı deneysel görev tanımlı YKS tabanlı BBA çalışmalarını ile ilgilenmişlerdir. Bunlar arasından Naseer ve arkadaşları 4

sınıflı sağ/sol MHH, mental aritmetik ve mental hesaplama tabanlı YKS verilerini kaydettiler. 10 kişiden kaydedilen veri kümesini DDA ile sınıflandırarak ortalama %73.30 SD hesapladılar [21]. Li ve arkadaşları sağ ve sol el hareketine dayalı 11 kişiden kaydedilen YKS veri kümesi ile çalıştılar. Öznitelikleri, HbO ve HbR'nin ortalamasını alarak çıkarttıktan sonra bu öznitelikleri DVM ile sınıflandırdılar. Tüm analizler sonucunda ise %85.55 SD elde etmişlerdir [22]. Tomita ve arkadaşları ise 13 kişiden kaydedilen YKS veri kümesinden HbO ve HbR'nin 1. ve 2. dereceden türevini alarak öznitelikler çıkarttılar. Çalışmalarında, ortak sınıflandırıcı kullanarak YKS işaretlerinden %85.00 SD hesapladılar [23]. Başka bir YKS tabanlı yapılan çalışmada ise Blokland ve arkadaşları parmakları ve başparmağı sürekli hareket ettirme hayaline dayalı 12 kişiden kaydedilen veri kümesi ile çalıştılar. Burada HbO ve HbR'nin ortalamasını alarak çıkarılan öznitelikleri doğrusal lojistik regresyon ile sınıflandırdılar. Sınıflandırma sonucu ortalama %65.00 SD elde ettiler [24]. Cicalese ve arkadaşları çalışmalarında dört, beş ve altı basamaklı sayıların ezberlenmesi ve görev kısmında söylenmesi tabanlı YKS verileri ile çalıştılar. 29 kişiden 4 sınıflı olarak kaydedilen veri kümesinden işaretin ortalaması tabanlı öznitelikler çıkarttılar. DAA ile çıkarılan öznitelikleri sınıflandırarak %58.62 SD elde ettiler [25].

2.3. Elektroensefalografi + Yakın Kızılötesi Spektroskopi


BBA sistemlerinin gelişmesi için gereken çözümlerden birisi, beyin görüntüleme tekniklerinin çoklu kullanılması, yani, bir hibrit BBA oluşturan ölçüm cihazlarının kullanılmasında yatmaktadır [26]. Hibrit BBA modelleri arasında son yıllarda EEG+YKS tabanlı sistemler önem kazanmaktadır. EEG ve YKS, beyin aktivitesini farklı ölçüm prensipleriyle algılar. EEG, elektriksel aktiviteyi algılayarak sinirsel süreçlerin zamansal özelliklerini yansıtabilirken, YKS, oksijenasyon durumu gibi metabolik süreçlerin ölçülmesinde daha etkilidir. Bu nedenle, EEG ve YKS'nin birleştirilmesi hem de yüksek zamansal çözünürlük hem de yüksek mekansal çözünürlük sunan bir multimodal görüntüleme yaklaşımı sağlar. Örnek bir EEG+YKS veri kümesi kaydetme görüntüsü Şekil 5'te verilmiştir [27]. Karadeniz Teknik Üniversitesi FHD-2020-9166 nolu BAP projesi kapsamında alınan hizmet alımı ile Atatürk Üniversitesi/ Spor Bilimleri Fakültesinde kaydedilen bu örnek EEG+YKS veri kümesine ilişkin örnek görüntüleri Şekil 6, 7 ve 8'te gösterilmiştir.




Şekil 5. Örnek EEG+YKS veri kaydetme aşaması [27]

EEG+YKS veri [27] kümesinden rasgele olarak seçilmiş tek EEG denemesini Şekil 6, HbO denemesini Şekil 7, HbR denemesini ise Şekil 8 temsil etmektedir. Şekil 6'da yer alan EEG denemesi 250 Hz örnekleme frekansı ile Şekil 7 ve 8'de yer alan YKS denemeleri ise 10.17 Hz örnekleme frekansı ile kaydedilmiştir. Tüm sinyallerin uzunluğu ise 24 saniyedir ve her


bir grafikte x eksenini zaman eksenini yani örnek sayısını y eksenini ise işaretin genliğini ifade etmektedir.



Şekil 6. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek EEG denemesi




Şekil 7. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek HbO denemesi



Şekil 8. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek HbR denemesi

[27]'deki çalışmada 8 sekiz gönüllü bireylerden sağa (sınıf 1), sola (sınıf 2), yukarıya (sınıf 3) ve aşağıya (sınıf 4) kayan yazı okumaya dayalı EEG+YKS veri kümesi kaydedilmiştir. Deney 6 seanstan oluşmaktadır ve her seansta 20 eşzamanlı EEG ve YKS denemesi kaydedilmiştir. Her seansta 60 saniyelik bir ön dinlenme süresi ve ardından 2 saniyelik bir görev tanıtımı ile başlamıştır. Görev kısmında, bilgisayar ekranının tam ortasında

görsel uyarılarla rasgele ve eşit sayıda katılımcılara görev tanıtımı sunulmuştur. Görevlerin gerçekleştirileceği 24 saniyelik bölüm, kısa bir bip sesiyle başlamış ve sonlandırılmıştır. Her bir deneme sonrasında 10 saniyelik bir dinlenme yapılmış ve ardından bir sonraki görev tanıtımına geçilmiştir. Her bir seans, seans sonu dinleme ile sona ermiştir. Her katılımcıdan toplamda 120 deneme kaydedilmiştir. Burada, 24 saniyelik görev kısmı 2.4 saniyelik zaman dilimlerine bölünerek 1200 deneme oluşturularak veri kümesi ile analiz gerçekleştirilmiştir. EEG verileri 31 elektrot, YKS verileri de 18 elektrot ile alınmıştır. EEG+YKS veri kümesinden rasgele seçilmiş bir kişiden elde edilen örnek öznelik uzayı Şekil 9'da gösterilmiştir. Burada EEG ve YKS işaretlerinin ortalaması alınarak 1200x2 (deneme sayısı x öznelik sayısı) boyutlu öznelik uzayı oluşturulmuştur. Şekil 9'da x eksenini EEG özneliklerini, y eksenini ise YKS özneliklerini ifade etmektedir.



Şekil 9. EEG+YKS veri kümesinden çıkarılan öznelik uzayı

EEG ve YKS'nin birleştirilmesi, beyin aktivitesinin daha kapsamlı bir şekilde anlaşılmasını sağlar ve birbirini tamamlayıcı avantajlarından yararlanır [26]. Bu avantajlar şu şekilde sıralanabilir:

1. *Mekânsal ve zamansal çözünürlük dengesi:* EEG yüksek zamansal çözünürlüğe sahipken, mekânsal çözünürlükte sınırlıdır. YKS ise tam tersine, daha iyi mekânsal çözünürlüğe sahipken, zamansal çözünürlüğü daha düşüktür. Bu nedenle, EEG ve YKS'nin birleştirilmesi, hem yüksek zamansal çözünürlük hem de yüksek mekânsal çözünürlük sunarak daha ayrıntılı bir görüntüleme sağlar.
2. *Farklı beyin işlevlerini yansıtma:* EEG, sinir hücrelerinin elektriksel aktivitesini doğrudan ölçerken, YKS beyindeki metabolik süreçlerin yansımalarını değerlendirir. Bu nedenle, EEG daha çok sinirsel süreçleri, YKS ise daha çok oksijenasyon durumu gibi metabolik süreçleri yansıtır. Birlikte kullanıldıklarında hem sinirsel hem de metabolik aktivitenin birbirini tamamlayan bir resmini sunarak daha kapsamlı bir anlayış sağlarlar.
3. *Optik ve elektriksel ölçümlerin karşılıklı doğrulanması:* EEG ve YKS, farklı fiziksel ölçüm prensiplerine dayanır. EEG, elektriksel aktiviteyi doğrudan ölçerken,

YKS optik ölçümler kullanır. Bu farklı ölçüm prensipleri, birbirini tamamlayan ve karşılıklı doğrulayan bilgiler sağlar. Örneğin, YKS, kafa derisi ve kafatası üzerinden geçerken sinyal kaybına uğrayabilirken, EEG'nin daha iyi zaman çözünürlüğü vardır. Birleştirildiklerinde, bu sinyal kayıplarını telafi edebilir ve daha doğru bir beyin aktivitesi tahmini sağlayabilirler.

4. *Kombine veri analizi ve yöntemler:* EEG ve YKS'nin birleştirilmesi, verilerin kombine analizi ve işlenmesi için yeni yöntemlerin geliştirilmesini sağlar. Bu, daha iyi öznitelik çıkarımı, sınıflandırma veya tahmin modelleri, desen tanıma ve beyin haritalama gibi analiz tekniklerini içerir.

Literatürde yapılan EEG+YKS çalışmaları ayrıntılı olarak birçok açıdan incelenmiştir. Yapılan çalışmalar arasında Putze ve arkadaşları 12 kişiden çevrimdışı olarak kaydedilen EEG+YKS veri kümesi ile çalıştılar. Kayıt alırken elektrot dağılımı olarak işitsel ve görsel korteksi kullandılar. Daha sonra HbO ve HbR'nin ortalamasının farkını, EEG işaretlerinin ise bant gücünü (BG) alarak öznitelikler çıkarttılar. Çıkarılan öznitelikleri DVM ile sınıflandırarak %97.80 SD elde ettiler [28]. Koo ve arkadaşları 6 kişiden kaydedilen motor korteksten kaydedilen EEG+YKS veri kümesi ile çalıştılar. Çalışmalarında HbO'nin eşik değerini EEG işaretlerinden OUÖ tabanlı öznitelikler çıkartarak bunları DVM ile sınıflandırdılar. Sağa veya sola hareket eden ok hayali tabanlı 2 sınıflı çalışmaları için %88.00 SD hesapladılar [29]. Aghajani ve arkadaşları ise zihinsel iş yükü n-geri görev tabanlı 17 kişiden kaydedilen EEG+YKS veri kümesi ile çalışmıştır. Çalışmalarında HbO ve HbR'nin tepe, eğim, standart sapma, çarpıklık ve basıklık değerini alarak EEG'nin ise BG ve faz kilitleme değerini alarak öznitelikler çıkarttılar. Çıkarılan öznitelikleri DVM ile sınıflandırarak zihinsel yorgunluk tahmini yaptılar. 2 sınıflı bu problem için %90.90 SD hesapladılar [30]. Shin ve arkadaşları parmak hareketi hayali ve zihinsel işlem-dinlenme durumu tabanlı kaydettikleri EEG+YKS veri kümesi ile çalıştılar. 8 kişiden kaydedilen bu veri kümesinin YKS işaretlerinden eğim ve varyans tabanlı EEG işaretlerinden ise OUÖ'nün logaritmik varyansı tabanlı öznitelikler çıkarttılar. Çıkarılan öznitelikleri DAA ile sınıflandırarak %82.20 SD elde ettiler [31]. Bir başka tabanlı hibrit çalışmada ise Nour ve arkadaşları sağ ve sol el açma kapama hareketi hayali 2 sınıflı EEG+YKS veri kümesi ile çalıştılar. EEG ve YKS işaretlerinden çoklu bant genişliği analizi tabanlı öznitelikler çıkartarak bu öznitelikleri evrişimsel sinir ağları ile sınıflandırdılar. Seçim çözmeye dayalı bu çalışmadan %99.85 SD hesapladılar. [32]. Zhang ve arkadaşları ise 20 kişiden kaydettikleri dinlenmek-oturma durumu tabanlı EEG+YKS veri kümesi ile çalıştılar. HbO'nun statik ve dinamik fonksiyonel bağlantısı tabanlı EEG'nin ise küresel alan gücüne dayalı mikro durum tabanlı özniteliklerini aldılar. Çıkarılan öznitelikleri k-ortalama kümeleme ile sınıflandırarak analiz gerçekleştirdiler [33]. Ergün ve arkadaşları 8 kişiden kaydedilen EEG+YKS veri kümesi ile çalışmışlardır. Sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı kaydettikleri bu veri kümesinden Hilbert Dönüşümü tabanlı öznitelikler çıkartmışlardır. Çıkarılan öznitelikleri k-EYK ile sınıflandırarak 4 sınıflı bu veri kümesi için %96.28 SD'ye ulaşmışlardır [27].

Literatürdeki bu çalışmaların tamamı EEG+YKS tabanlı BBA sistemlerindeki çeşitli eksikliklerin giderilmesi konusunda başarılı ve doğru çalışmalardır. Ancak BBA sistemlerinin performansının hâlâ iyileştirilmesi gerekmektedir. Son yıllarda evrişimsel sinir ağlar (ESA) tabanlı yöntemlerin bu alana daha fazla dokunuşu BBA sistemlerinin performansı

artırmaktadır. Bunlar arasından, Chiarelli ve arkadaşları 15 kişiden kaydedilen sağ ve sol MHH tabanlı EEG+YKS veri kümesini sınıflandırmak için derin yapay sinir ağı mimarisini kullandı. 15 kişinin ortalamasını %83.28 olarak hesapladılar [34]. Rahman ve arkadaşları sekiz sınıflı EEG+YKS veri kümesini sınıflandırmak için ESA'nı kullandılar. Çalışmalarında, gönüllü ve imgesel motor hareketi tabanlı veri kümesini sınıflandırarak %77 SD hesaplarken, MHH tabanlı veri kümesi için %90 SD elde etmişlerdir [35]. Nour ve arkadaşları çalışmalarında, optimize edilmiş ESA ile çoklu bant genişliği yöntemini kullanan yeni bir sınıflandırma çerçevesi önermişlerdir. Sağ ve sol el açma kapama MHH'e dayalı EEG+YKS sinyallerini tam bağlantılı katman optimizasyonunu içeren bir ESA mimarisi ile eğittiler. Önerilen yaklaşım ile ortalama %99.85 SD elde ettiler [36]. Başka bir çalışmada ise Rabbani ve arkadaşları, 26 (veri kümesi1) ve 29 (veri kümesi 2) kişiden kaydedilen 2 sınıflı 2 ayrı EEG+YKS veri kümesi ile çalıştılar. Veri kümesi 1'e ESA+Geçitli Tekrarlayan Birim+Uzun-Kısa Süreli Bellek (UKSB) ağlarını uygulayarak ortalama %96 SD hesaplarken, veri kümesi 2 için UKSB ağlarını kullanarak %82.76 SD elde ettiler [37].

Çizelge 1'de literatürde yapılmış EEG+YKS çalışmaları ayrıntılı olarak ayrıca ele alınmıştır. Çizelge 1 incelendiğinde deney içeriği açısından literatürde yapılan çalışmaların motor görevi ağırlıklı olduğu görülmektedir. Motor ağırlıklı görevlerin birçoğu sağa ve sola imleç, ok veya el hareketi hayali tabanlı iken motor uygulamaya (MU) dayalı görevlerde bunların uygulanması ile alakalıdır. Bunlar arasından 2 sınıflı EEG+YKS işaretlerinin sınıflandırılmasıyla %74.20-%94.20 SD hesaplamışlardır. Motor görevi tabanlı çalışmaları ise zihinsel görev tabanlı çalışmalar takip etmiştir. Çizelge 1'de yer alan çalışmalarda elektrotların pozisyonları frontal ve motor korteks ağırlıklı olsa da bazı çalışmalarda neredeyse tüm kafatasını kapsayacak şekilde yayılmıştır. Elektrot sayısı ise EEG için yaygın olarak 6-128 arasında YKS elektrot sayısının ise 6-170 arasında olduğu Çizelge 1'de görülmektedir. Deneye katılan kişi sayı ise Çizelge 1'de görüldüğü gibi 6 ila 29 kişi arasında değişmektedir.

2.4. Öznitelik Çıkartma

Öznitelikler, çeşitli sınıfları ayırt etmek için gereken ayrımcı bilginin sinyallerden elde edilmesidir. Öznitelik hesaplama, tekniklere bağlı olan ve sınıflandırıcının performansını önemli derecede etkileyen BBA basamaklarından biridir. Bu basamakta az sayıda önemli ayırt ediciliğe sahip olan öznitelikler elde etmek amaçlanır. Çıkarılan öznitelikler genellikle bir öznitelik vektörü formunda yapılandırılır. Öznitelik çıkartma aşamasında, EEG sinyallerinden zaman alanında, frekans alanında ve zaman-frekans alanında öznitelikler elde edilebilir ve bunlar arasından en popüler olanı literatürden anlaşıldığı gibi zaman-frekans tabanlı yöntemlerdir [13]. Buna ek olarak EEG için öz vektör, otoregresif, bağımsız bileşen analizi, temel bileşen analizi, ADD, hızlı Fourier dönüşümü ve korelasyon boyutu, Lyapunov üstel, çeşitli entropiler, fraktal boyut gibi öznitelik çıkartma yöntemleri de yaygın olarak kullanılmaktadır. YKS sinyallerinden ise ağırlıklı olarak sinyalin ortalaması alınarak hesaplamalar yapılmıştır. Buna ek olarak ise OUÖ, eğim, varyans, basıklık ve çarpıklık da kullanılan diğer yöntemler arasında yer almaktadır. EEG+YKS için ise yukarıda bahsedilen yöntemlerden etkin olanı ayrı ayrı olarak bu modalitelere uygulanarak analiz gerçekleştirilmektedir.

Çizelge 1: Literatürde yer alan hibrit EEG+YKS çalışmaları

Referanslar	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Elektrot sayısı	Kontrol Sayısı	SD
[38]	29	Frontal, motor ve görsel korteks	1. MHH: Sağ ve sol el hareketi hayali 2. MA: Dinlenme durumuna karşı zihinsel aritmetik	OUÖ'nün logaritmik varyansı	OUÖ'nün logaritmik varyansı	DAA	EEG: 30 NIRS:36	2	1. %74.20 (MHH) 2. %88.10 (MU)
[39]	6	Motor korteks	MHH: Farklı hızlarda sağ el sıkma hareketi hayali	HbO ve HbR'nin Farkı	Zaman Frekansı Fazı	Aşırı Öğrenme Makinesi	EEG:21 NIRS:24	2	%89.00
[40]	20	Motor korteks	MU: Sağ ve sol ayak bileği eklem hareketleri	Varyans, basıklık ve çarpıklık	Ortalama mutlak değer, dalga uzunluğu, OUÖ	DVM	EEG:20 NIRS:32	2	%93.01
[41]	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	FWHD	FWHD	k-EYK	EEG: 30 NIRS:36	2	%78.21
[42]	15	Motor korteks	MHH: Sağ ve sol el hareketi hayali	HbO Sinyal Ortalaması ve Sinyal Eğimi	OUÖ	DAA	EEG:21 NIRS:34	2	%94.20
[43]	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	Uzay-zaman korelasyonları	Uzay-zaman korelasyonları	Yapay sinir ağları	EEG: 30 NIRS:36	2	%82.11
[44]	14	Frontal, motor ve parietal korteks	1. MHH: Sağa veya sola hareket eden ok hayali 2. MU: El açma kapama hareketi	HbO ve HbR'nin ortalaması	BG	DAA	EEG:37 NIRS:24	2	1. %83.20 (MHH) 2. %93.20 (MU)
[27]	8	Frontal, motor, parietal ve görsel korteks	Sağa, sola, yukarıya ve aşağıya kayan yazı okuma	Hilbert Dönüşümü	Hilbert Dönüşümü	k-EYK	EEG:31 NIRS:18	4	%96.28
[45]	12	İşitsel ve görsel korteks	Ses ve video algısı	HbO ve HbR'nin Ortalamasının Farkı	BG	DVM	EEG:12 NIRS:170	2	%97.80
[46]	12	Motor korteks	MHH: Sağ ve sol el hareketi hayali	Hurst Üssü	OUÖ	DVM	EEG:64 NIRS: 52	2	%81.20
[47]	11	Tüm kafatası	Zihinsel yorgunluk seviyesi tahmin	HbO ve HbR'nin Genliği	BG	DAA	EEG:64 NIRS:8	2	%68.30

2.5. Sınıflandırma

Çıkarılan EEG ve YKS sinyal özniteliklerini sınıflandırmak için çeşitli teknikler bulunmaktadır. Bu sinyallerden çıkarılan özniteliklerini sınıflandırmak için yaygın olarak kullanılan algoritmalar arasında k-EYK, DVM, DAA, naive bayes (NB), karar ağacı (KA) ve rastgele ormanlar (RO) metodu bulunur. Bunlar arasından, DVM ve k-EYK, EEG ve YKS sinyallerini sınıflandırmak için BBA sistemlerinde çoğunlukla kullanılan sınıflandırma yöntemleridir [4], [48]. Her yaklaşımın ise birbirine göre avantajları ve dezavantajları vardır.

1. *k- en yakın komşuluk metodu:* Veri noktalarının birbirlerine olan benzerliğini hesaplamak için kullanılan bir makine öğrenme yöntemidir. Bu yöntemde, bir veri noktasının komşuları, veri noktasının belirli bir uzaklık metriği kullanılarak hesaplanır ve bu komşuların sınıfları veya değerleri, ilgili veri noktasının tahmin edilmesinde kullanılır.
2. *Doğrusal ayırım analizi:* Çoklu sınıflı sınıflandırma problemlerinde kullanılan bir makine öğrenme ve veri madenciliği tekniğidir. Bu yöntem, veri noktalarının özelliklerini kullanarak farklı sınıflara ait veri noktalarını birbirinden ayırmayı amaçlar. Temelde, sınıflar arasındaki farklılıkları maksimize eden ve sınıf içindeki varyansı minimize eden yeni özellikler veya boyutlar oluşturularak çalışır. Bu yeni boyutlar, veri noktalarını sınıflandırmak için kullanılır ve sınıflar arasındaki doğrusal ayrımı en iyi şekilde sağlamak için öğrenilir.
3. *Naive bayes metodu:* NB, bir veri noktasının ait olduğu sınıfı tahmin etmek için Bayes teoremini kullanır. Bayes teoremi, şartlı olasılıkları hesaplamak için kullanılır ve bu yöntemde özelliklerin sınıfı belirlemedeki etkilerini modellemek için kullanılır. Bu sayede, veri noktasının sınıfını tahmin etmek için özelliklerin olasılıkları ve Bayes teoreminin yardımıyla bir hesaplama yapılır.
4. *Karar ağacı metodu:* Bu algoritma, veri setini ağaç yapısı şeklinde temsil eder, her düğüm veri özelliklerine göre bir karar kuralı oluşturur ve bu kurala göre veriyi farklı dallara ayırır. KA oluşturulurken, veri setindeki özelliklerin en iyi bölünme kriterini kullanarak belirler. Bu şekilde, veri setini sınıflara ayırırken en fazla bilgiyi elde etmeye çalışır.
5. *Destek vektör makineleri metodu:* Veri noktalarını en iyi şekilde sınıflandırmak veya tahmin etmek için bir karar sınırı veya regresyon fonksiyonu oluşturur. Temel amaç, sınıflar arasındaki marjinal boşluğu (margin) maksimize etmek ve bu marjinal boşluğu sınıfların en yakın veri noktalarına dayanarak belirlemektir. DVM, özellikle yüksek boyutlu veri setleri üzerinde etkili çalışır ve çoklu sınıflı sınıflandırma problemlerini çözmek için de kullanılabilir. DVM, çekirdek yöntemi kullanarak veri noktalarını yüksek boyutlu uzaylarda da işleyebilir, bu da verilerin daha karmaşık yapılarını tanımlamak için kullanışlıdır. DVM, aşırı öğrenmeye karşı dirençlidir ve veri noktalarının sınıflandırılmasında yüksek performans sağlar.
6. *Rastgele ormanlar metodu:* Çok sayıda karar ağacının bir araya gelerek güçlü bir model oluşturulduğu bir tekniktir. Her bir ağaç, rastgele özelliklerin alt kümesini kullanarak veri setini sınıflandırmaya veya tahmin etmeye çalışır. Ardından, tüm ağaçların sonuçları bir

araya getirilir ve çoğunluk oyu (sınıflandırma için) veya ortalama (regresyon için) alınarak son tahmin yapılır.

3. Sonuçlar

BBA sistemleri, tıbbi, teknolojik ve bilimsel alanlarda birçok fayda ve potansiyel sunarak önemli bir gelişme ve araştırma alanı haline gelmiştir. Bu teknolojilerin ilerlemesi, daha fazla kullanım alanı ve daha geniş bir kitleye ulaşma potansiyeli taşımaktadır. Ayrıca, literatürden görülüşü gibi, BBA performansını ve evrenselliğini iyileştirmek için çeşitli ön işleme, öznitelik çıkartma, sınıflandırma, optimizasyon teknikleri ve paradigmlar önerilmiştir. Bu çalışmadan da görüldüğü gibi BBA sistemlerinin gelişmesi için ise gereken çözümlerden birisi, beyin görüntüleme tekniklerinin çoklu kullanılması, yani, bir hibrit BBA oluşturan ölçüm cihazlarının kullanılmasında yatmaktadır. Çizelge 2'de literatürde yapılan hibrit çalışmaların sınıflandırma sonuçları yalnızca EEG ve YKS ile yapılmış çalışmaların sınıflandırma sonuçlarıyla kıyaslanmıştır. EEG sınıflandırma sonuçları EEG+YKS sınıflandırma sonuçları ile kıyaslandığında SD'nin %4.60 ile %13.85 arasında arttığı görülmektedir. Tüm referans kaynaklar için ise bu artış ortalama %7.58 olarak hesaplanmıştır. YKS sınıflandırma sonuçları hibrit sınıflandırma sonuçları ile kıyaslandığında ise yalnız YKS'ye göre SD %1.91-30.04 arasında artış göstermiştir. Çizelge 2'de gösterildiği gibi tüm referans kaynaklar için bu artış ortalama %13.04 olarak hesaplanmıştır. Bu sonuçlardan açıkça görüldüğü ki hibrit BBA YKS'in düşük zamansal duyarlılığını telafi etmektedir ve SD'nin yanı sıra bilgi aktarım hızı ışığında BBA performansı iyileştirmektedir.

Çizelge 2: EEG+YKS tabanlı BBA sisteminin SD sonuçlarının tek modaliteli BBA sisteminin SD sonuçları ile kıyaslanması

Referanslar	SD Sonuçları (%)			Artış (%)	
	EEG	YKS	EEG+YKS	EEG'ye göre	YKS'ye göre
[38]	1. 65.60 2. 75.90	1. 66.50 2. 83.60	1. 74.20 2. 88.10	1. 11.59 2. 13.85	1. 10.38 2. 5.11
[39]	88.00	76.00	89.00	1.12	14.60
[40]	89.39	85.61	93.01	3.89	7.95
[41]	71.46	55.02	78.21	8.63	29.65
[42]	85.20	92.40	94.20	9.55	1.91
[43]	73.19	75.14	82.11	10.86	8.49
[44]	1. 78.20 2. 90.80	1. 71.70 2. 73.30	1. 83.20 2. 93.20	1. 6.00 2. 2.58	1. 13.82 2. 21.35
[27]	91.25	77.31	96.28	5.22	19.70
[45]	93.30	93.60	97.80	4.60	4.29
[46]	74.70	56.80	81.20	8.00	30.04
[47]	59.70	66.80	68.30	12.59	2.20
Ortalama				7.58	13.04

Bilgilendirme; Bu çalışmada kullanılan veriler Atatürk Üniversitesi Spor Bilimleri Uygulama ve Araştırma Merkezi'nde kayıt altına alınmıştır. Bu çalışma Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından FHD-2020-9166 proje numarasıyla desteklenmiştir. Ebru Ergun, 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında TÜBİTAK bursuyla desteklendi.

4. Kaynaklar

- [1] S. Aggarwal, and N. Chugh, "Review of machine learning techniques for EEG based brain computer interface", *Archives of Computational Methods in Engineering*, vol. 1, no. 20, 2022.
- [2] A. Naser, and O. Aydemir, "Classification of pleasant and unpleasant odor imagery EEG signals", *Neural Computing and Applications*, vol. 35, no. 12, pp. 9105-9114, 2023.
- [3] O. E. Korkmaz, O. Aydemir, E. A. Oral, and I. Y. Ozbek, "A novel probabilistic and 3D column P300 stimulus presentation paradigm for EEG-based spelling systems", *Neural Computing and Applications*, pp. 1-15, 2023.
- [4] E. Ergün, and O. Aydemir, "A new evolutionary preprocessing approach for classification of mental arithmetic based EEG signals", *Cognitive Neurodynamics*, vol. 14, pp. 609-617, 2020.
- [5] Z. Liu, J. Shore, M. Wang, F. Yuan, A. Buss, and X. Zhao, "A systematic review on hybrid EEG/fNIRS in brain-computer interface", *Biomedical Signal Processing and Control*, vol. 68, no. 102595, 2021.
- [6] D. Pirrone, E. Weitschek, P. Di Paolo, S. De Salvo, and M. C. De Cola, "Eeg signal processing and supervised machine learning to early diagnose alzheimer's disease", *Applied sciences*, vol. 12, no. 11, 2021.
- [7] P. C. Sharma, R. Raja, S. K. Vishwakarma, S. Sharma, P. K. Mishra, and V. S. Kushwah, "Analysis of brain signal processing and real-time EEG signal enhancement", *Multimedia Tools and Applications*, vol. 81, no. 28, pp. 41013-41033, 2022.
- [8] Ö. Aydemir, "Beyin Bilgisayar Arayüzü ve Geleceği", *Journal of Investigations on Engineering and Technology*, vol. 5, no. 2, pp. 135-141, 2022.
- [9] N. Panigrahi, and S. P. Mohanty, "Brain Computer Interface: EEG Signal Processing", CRC Press, 2022.
- [10] R. Chai, S.H. Ling, G.P. Hunter, H.T. Nguyen, "Mental non-motor imagery tasks classifications of brain computer interface for wheelchair commands using genetic algorithm-based neural network", *Proc. Int. Joint Conf, Neural Networks*, pp. 10-15, 2012.
- [11] N.K. Verma, L.S.V.S. Rao, S.K. Sharma, "Motor imagery EEG signal classification on DWT and crosscorrelated signal features", 9th Int. Conf. Indust. Inform. Syst., 2015.
- [12] M.H. Bhatti, et al., "Soft computing-based EEG classification by optimal feature selection and neural networks", *IEEE Trans. Ind. Inf.*, vol. 15, no. 10, pp. 5747-5754, 2019.
- [13] N. Bagh, M.R. Reddy, "Hilbert Transform-Based Event-Related Patterns for Motor Imagery Brain Computer Interface", *Biomedical Signal Processing and Control*, vol. 62, 2020.
- [14] Q. Wang ve O. Sourina, "Real-time mental arithmetic task recognition from EEG signals", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 21 no. 2, pp. 225-232, 2013.
- [15] W. Yi, S. Qiu, H. Qi, L. Zhang, B. Wan, D. Ming, "EEG feature comparison and classification of simple and compound limb motor imagery", *J. NeuroEng. Rehabil.*, vol. 10, no. 1, pp. 1-12, 2013.
- [16] I. Dokare, N. Kant, "Performance analysis of SVM, k-NN and BPNN classifiers for motor imagery", *Int. J. Eng. Trends Technol.*, vol. 10, no. 1, pp. 9-23, 2014.
- [17] C. Lindig-Leon, L. Bougrain, "A multi-label classification method for detection of combined motor imageries, in: *Proceedings*", IEEE International Conference on Systems, Man, and Cybernetics, 2016.
- [18] A., Koven, and S. Herschorn, "NIRS: past, present, and future in functional urology", *Current Bladder Dysfunction Reports*, vol. 17, no. 4, pp. 241-249, 2022.
- [19] T. W. L. Scheeren, P. Schober, and L. A. Schwarte, "Monitoring tissue oxygenation by near infrared spectroscopy (NIRS): background and current applications", *Journal of clinical monitoring and computing*, vol. 26, pp. 279-287, 2012.
- [20] E. Ergün, and Ö. Aydemir, "Decoding of binary mental arithmetic based near-infrared spectroscopy signals", In 2018 3rd International Conference on Computer Science and Engineering (UBMK), pp. 201-204, 2018.
- [21] N. Naseer, and K. S., Hong, "Decoding answers to four-choice questions using functional near infrared spectroscopy", *Journal of Near Infrared Spectroscopy*, vol. 23, no. 1, pp. 23-31, 2015.
- [22] R. Li, T. Potter, W. Huang, and Y. Zhang, "Enhancing performance of a hybrid eeg-fnirs system using channel selection and early temporal features", *Frontiers in Human Neuroscience*, pp. 11-462, 2015.
- [23] Y. Tomita, F. B. Vialatte, G. Dreyfus, Y. Mitsukura, H. Bakardjian, and A. Cichocki, "Bimodal BCI using simultaneously NIRS and EEG", *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 4, pp. 1274-1284, 2014.
- [24] Y. Blokland, L. Spyrou, D. Thijssen, T. Eijsvogels, W. Colier, M. Floor-Westerdijk, vd., "Combined EEG-fNIRS decoding of motor attempt and imagery for brain switch control: an offline study in patients with tetraplegia" *IEEE transactions on neural systems and rehabilitation engineering*, vol. 22, no. 2, pp. 222-229, 2013.
- [25] P. A. Cicalese, R. Li, M. B. Ahmadi, C. Wang, J. T. Francis, S. Selvaraj, ve Y. Zhang, "An EEG-fNIRS hybridization technique in the four-class classification of alzheimer's disease", *Journal of neuroscience methods*, vol. 336, pp. 108-618, 2020.
- [26] M. A. Hasan, M. U. Khan, and D., Mishra, "A computationally efficient method for hybrid EEG-fNIRS BCI based on the Pearson correlation", *BioMed Research International*, pp. 1-13, 2020.
- [27] E. Ergün, "Elektroensefalografi ve Yakın Kızılötesi Spektroskopisi Tabanlı Hibrit Model Kullanarak Beyin Bilgisayar Arayüzü Sisteminin Performansının Arttırılması", *Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon*, 2023.
- [28] F. Putze, S. Hesslinger, C. Y. Tse, Y. Y. Huang, C. Herff, C. T. Guan, vd., "Hybrid fNIRS-EEG based classification of auditory and visual perception processes", *Frontiers in Neuroscience*, vol. 8, no. 373, 2014.
- [29] B. Koo, H. G. Lee, Y. Nam, H. Kang, C. S. Koh, H. C. Shin, vd., "A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery", *Journal of Neuroscience Methods*, vol. 244, pp. 26-32, 2015.
- [30] H. Aghajani, M. Garbey, and A. Omurtag, "Measuring mental workload with EEG plus fNIRS", *Frontiers in human neuroscience*, vol. 11, no. 359, pp. 1-20, 2017.
- [31] J. Shin, J. Kwon, and C. H. Im, "A ternary hybrid EEG-NIRS brain-computer interface for the classification of brain activation patterns during mental arithmetic, motor imagery, and idle state", *Frontiers in neuroinformatics*, vol. 12, no. 5, pp. 1-9, 2018.

- [32] M. Nour, Ş. Öztürk, and K. Polat, "A novel classification framework using multiple bandwidth method with optimized CNN for brain-computer interfaces with EEG-fNIRS signals", *Neural Computing and Applications*, vol. 33, no. 22, pp. 15815-15829, 2021.
- [33] Y. Zhang, Y. Li, L. Kong, Q. Niu, ve Y. Bai, "Improved DBSCAN Spindle Bearing Condition Monitoring Method Based on Kurtosis and Sample Entropy", *Machines*, vol. 10, no. 5, 2022.
- [34] A. M. Chiarelli, P. Croce, A. Merla ve F. Zappasodi, "Deep learning for hybrid EEG-fNIRS brain-computer interface: application to motor imagery classification", *Journal of neural engineering*, 15, 3, 036028, 2018.
- [35] M. A. Rahman, M. S. Uddin ve M. Ahmad, "Modeling and classification of voluntary and imagery movements for brain-computer interface from fNIR and EEG signals through convolutional neural network", *Health Information Science and Systems*, 7, 1, 22, 2019.
- [36] M. Nour, Ş. Öztürk ve K. Polat, "A novel classification framework using multiple bandwidth method with optimized CNN for brain-computer interfaces with EEG-fNIRS signals", *Neural Computing and Applications*, 33, 15815-15829, 2021.
- [37] M. H. R. Rabbani ve S. M. R. Islam, "Deep learning networks based decision fusion model of EEG and fNIRS for classification of cognitive tasks", *Cognitive Neurodynamics*, 1-18, 2023.
- [38] J. Shin, A. von Lüthmann, B. Blankertz, D. W. Kim, J. Jeong, H. J. Hwang, and K. R. Müller, "Open access dataset for EEG+ NIRS single-trial classification", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25, 10, 1735-1745, 2016.
- [39] X. X. Yin, B. L. Xu, C. H. Jiang, Y. F. Fu, Z. D. Wang, H. Y. Li, vd., "A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching", *Journal of Neural Engineering*, vol. 12, no. 036004, 2015.
- [40] M. S. Al-Quraishi, I. Elamvazuthi, T. B. Tang, M. Al-Qurishi, S. H. Adil, ve M. Ebrahim, "Bimodal data fusion of simultaneous measurements of EEG and fNIRS during lower limb movements", *Brain Sciences*, vol. 11, no. 6, pp. 1-713, 2021.
- [41] E. Ergün ve Ö. Aydemir, "A hybrid BCI using singular value decomposition values of the fast walsh hadamard transform coefficients", *IEEE Transactions on Cognitive and Developmental Systems*, pp. 1-10, 2022.
- [42] A. P. Buccino, H. O. Keles ve A. Omurtag, "Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks", *Plos One*, vol. 11, no. 1, pp. 1-8, 2016.
- [43] Q. He, L. Feng, G. Jiang, and P. Xie, "Multimodal Multitask Neural Network for Motor Imagery Classification With EEG and fNIRS Signals", *IEEE Sensors Journal*, vol. 22, no. 21, pp. 20695-20706, 2021.
- [44] S. Fazli, J. Mehnert, J. Steinbrink, G. Curio, A. Villringer, K. R. Müller, vd., "Enhanced performance by a hybrid NIRS-EEG brain computer interface", *Neuroimage*, vol. 59, pp. 519-529, 2012.
- [45] F. Putze, S. Hesslinger, C. Y. Tse, Y. Y. Huang, C. Herff, C. T. Guan, vd., "Hybrid fNIRS-EEG based classification of auditory and visual perception processes", *Frontiers in Neuroscience*, vol. 8, no. 373, 2014.
- [46] S. Ge, Q. Yang, R. M. Wang, P. Lin, J. F. Gao, Y. Leng, vd., "A brain computer interface based on a few-channel EEG-fNIRS bimodal system", *IEEE Access*, vol. 5, pp. 208-218, 2017.
- [47] S. Ahn, T. Nguyen, H. Jang, J. G. Kim, ve S. C. Jun, "Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous EEG, ECG, and fNIRS data", *Frontiers in human neuroscience*, vol. 10, no. 219, pp. 1-14, 2016.
- [48] O. Aydemir, and E. Ergün, "A robust and subject-specific sequential forward search method for effective channel selection in brain computer interfaces", *Journal of neuroscience methods*, vol. 313, pp. 60-67, 2019.

Özgeçmişler



Dr. Ebru Ergün, 1991 yılında Trabzon'un Yomra ilçesinde doğdu. İlköğretim ve ortaöğretimi Trabzon Merkez'de tamamlamış olup, 2009 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünü kazandı. Bu öğrenimini 2014 yılında tamamlayarak aynı sene yüksek lisans eğitimine başladı. Yüksek lisans eğitimini 2017 yılında tamamlayarak aynı sene doktora eğitimine devam etti. 2015 yılında Recep Tayyip Erdoğan Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. İyi derecede İngilizce bilen Ergün, biyomedikal, beyin bilgisayar arayüzü, makine öğrenmesi alanındaki çalışmalarını sürdürmektedir.







Dr. Önder Aydemir, 2005 yılında hem Karadeniz Teknik Üniversitesi (KTÜ) Elektrik-Elektronik Mühendisliği Bölümü'nde lisans hem de KTÜ İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü'nde yandal eğitimini tamamladı. 2006-2007 Eğitim Öğretim Dönemi'nde yüksek lisans çalışması yapmak üzere Viyana Teknik Üniversitesi'ne gitti. 2008 yılında yüksek lisansını ve 2013 yılında doktora eğitimini Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. Doktora sonrası araştırmasını 2014-2015 eğitim-öğretim döneminde Viyana Tıp Üniversitesinde yapmıştır. Bilimsel araştırma alanları beyin bilgisayar arayüzü, makine öğrenmesi, biyomedikal sinyal işlemedir. 2023 yılında yapay zeka alanında yılın en etkili bilim insanları listesine de giren Dr. Aydemir, yabancı dil olarak İngilizce ve Almanca bilmektedir.



Dr. Onur Erdem Korkmaz, 2012 yılında Atatürk Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan Onur Erdem KORKMAZ, yüksek lisans eğitimini 2016 yılında, doktorasını ise 2022 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Atatürk Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünde doktor öğretim üyesi olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.

Derin Evrişimsel Sinir Ağ Mimarisi ve Zaman Frekans Gösterimini Kullanılarak Büyük Güçlü Motor Arızalarının Tespiti

Diagnosis of Large Power Motor Faults Using Deep Convolutional Neural Network Architecture and Time Frequency Representation

 İlhan AYDIN¹,  Emrullah AYDIN²,  Erhan AKIN¹,  Seyfullah KANER¹

¹Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

²Elektrik-Elektronik Mühendisliği Bölümü, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

iyadin@firat.edu.tr, emrullah.aydin@ozal.edu.tr, eakin@firat.edu.tr, seyfullah.kaner49@gmail.com

Öz

Asenkron motorlar endüstride iş gücünün sağlanması açısından birçok uygulamada kullanılmaktadır. Asenkron motorlarda oluşan arızalar mil yatağı, stator ve rotor bileşenleri ile ilgilidir. Bu bileşenlerden mil yatağı arızaları en çok karşılaşılan problemlerden biridir. Bu arızaların tespiti için genellikle titreşim sinyalleri kullanılmaktadır. Endüstriyel ortamda çalışan motor ile aynı özelliklerde bir motor bulmak zor olduğundan karşılaştırma yapılarak arızaların tespiti yapılamamaktadır. Bu çalışmada titreşim sinyallerinin zaman frekans görüntüleri oluşabilecek mil yatağı arızaları için toplanarak transfer öğrenme tabanlı bir model ile eğitilmiştir. Daha sonra endüstriyel mil arızası olan bir motordan aynı şartlarda ve benzer bir konumda alınan sinyaller kullanılarak endüstrideki büyük güçlü motordaki arıza belirlenmiştir. Yapılan testler sonucunda endüstrideki motorda oluşan kusurların %96.05 doğruluk oranı ile tespit edildiği ispatlanmıştır.

Anahtar Kelimeler: Asenkron motor, mil yatağı arızaları, arıza tespiti, derin öğrenme, transfer öğrenme.

Abstract

Induction motors are used in many applications to provide a workforce in the industry. Faults in induction motors are related to bearing, stator, and rotor components. Among these components, bearing faults are one of the most common problems. Vibration signals are generally used to diagnose these faults. Since finding a motor with the same features as the motor operating in an industrial environment is difficult, faults cannot be detected by comparison. In this study, time-frequency images of vibration signals were collected for possible bearing failures and trained with a transfer learning-based model. Then, the fault in the large-power motor in the industry was determined using the signals received from a motor with industrial bearing fault under the same conditions and in a similar location. As a result of the tests, it has been proven that the faults in the induction motor are detected with a 96.05% accuracy rate.

Keywords: Induction motor, bearing faults, fault diagnosis, deep learning, transfer learning.

1. Giriş

Karmaşık endüstriyel sistemler birçok bileşene sahip olup bu sistemlerin güvenilirliği ve kesintisiz çalışması bu bileşenlerin durumuna bağlıdır. Asenkron motorlar endüstride en çok kullanılan motorlar olup bu bileşende oluşacak bir arıza tüm sistemin durmasına neden olur [1]. Asenkron motorlarda mil yatağı ile ilgili arızalar %40'luk bir paya sahip olup en çok karşılaşılan arıza türüdür [2]. Bu arızaların tespiti için genellikle akım ve titreşim sinyalleri

kullanılmaktadır. Özellikle mil yatağı arızalarının titreşim sinyalleri üzerinde oluşturduğu örüntüler bu arıza türünü belirlemek için önemli bilgiler içermektedir.

Son yıllarda sensör teknolojisindeki gelişmeler ile büyük miktarda veri toplanmakta ve elde edilen verilerin analizi evrişimsel sinir ağı yöntemleri için oldukça uygundur. Literatürde mil yatağı arızalarının tespiti için akım ve titreşim sinyallerini temelde kullanan yöntemler önerilmiştir. Hoang ve Kang [3] mil yatağında oluşan arızaları belirlemek için akım sinyallerini derin öğrenme teknikleri ile değerlendiren bir füzyon yaklaşımı önermiştir. Önerilen yaklaşım akım sinyallerini iki boyutlu bir görüntüye dönüştürerek evrişimsel sinir ağı modeline vermekte ve arıza türü belirlenmektedir. Asenkron motorlarda oluşan dış halka, iç halka, yanlış hizalama ve kırık rotor çubuğu gibi arızaların belirlenmesi için sürekli dalgacık analizi ve dikkat mekanizması kullanan bir evrişimsel sinir ağı modeli önerilmiştir [4]. Titreşim sinyallerinden elde edilen scalogram görüntüleri ile beş farklı durum yüksek doğrulukta tespit edilmektedir. Shao ve ark. [5] farklı motor arızalarını tespit etmek amacıyla VGG16 tabanlı derin transfer öğrenme yöntemini önermişlerdir. Geliştirilen sistemde motor arızalarını tespit etmek için titreşim sinyalleri zaman-frekans görüntüsüne dönüştürülmüştür. Asenkron motorlarda oluşan mil yatağı arızalarının tespiti için dalgacık analizi ve frekans spektrumundan elde edilen özellikler destek vektör makineler, rastgele orman ve XGBoost ile sınıflandırılmıştır [6]. Önerilen yöntemin temel katkısı daha az veri kullanılarak arızaların belirlenebilmesidir. Asenkron motor arızalarının gömülü bir nesnelerin interneti modülü ile bulut ortamında belirlenmesi için makine öğrenmesi tabanlı bir yaklaşım önerilmiştir [7]. Önerilen yaklaşımda gömülü kartta bulunan işlemci programlanarak arıza durumu belirlenmekte ve bulut ortamında motor durumu iletilmektedir. Motor mil yatağı arızalarının benzerlik tabanlı tespiti için hızlı Fourier dönüşümü, istatistiksel zaman analizi ve kısa süreli Fourier dönüşümü ile özellik çıkarımı yapılarak farklı benzerlik ölçüm yöntemleri ile arızalar teşhis edilmiştir [8]. Önerilen yöntem makine öğrenmesi yaklaşımlarına göre daha az veri kullanması nedeni ile endüstride kullanılabilir yapıdadır.


Literatürde mil yatağı arızalarının tespiti için birçok yöntem önerilmiş olmasına rağmen bu çalışmaların çoğu kıyaslama veri setleri üzerinde test edilmiştir. Bu amaçla Case Western Reserve University (CWRU) bearing dataset [9], the Paderborn University (PU) bearing dataset [10] ve the University of Ottawa (uOttawa) bearing dataset [11] gibi veri setleri kullanılmıştır. Fakat her bir veri ayrı ayrı değerlendirilmiş ve geliştirilen yöntemler farklı veriler üzerinde ayrıca test edilmiştir. Bu çalışmada literatürden farklı olarak kıyaslama veri seti için oluşturulan derin sinir ağı modeli farklı çalışma hızlarında çalışan büyük güçlü bir motordaki arızaları belirlemek için uygulanmıştır. Asenkron motorlarda en çok oluşan arıza tiplerinden biri olan mil yatağı arızalarının tespiti için transfer öğrenme algoritması ile birlikte derin evrişimsel sinir ağı modeli kullanılmıştır. Önerilen yöntem ilk olarak okunan ham titreşim sinyallerine dalgacık analizi uygulayarak zaman frekans dağılımını

elde etmekte ve bu dağılım görüntü olarak kaydedilmektedir. Bu amaçla GoogleNet mimarisi tabanlı transfer öğrenme yaklaşımı kullanılmıştır. Önerilen yöntem hem literatürde kullanılan kıyaslama veri kümeleri üzerinde test edilmiş hem de gerçek bir büyük güçlü endüstriyel motordan alınan veriler ile test edilmiştir. Elde edilen sonuçlar önerilen yöntemin arıza teşhisi konusunda oldukça başarılı olduğunu göstermektedir.

2. Evrişimsel Sinir Ağları ve Sınıflandırma


Derin sinir ağları yapay zeka alanının bir alt bölümü olup insanlar gibi hedeflere ulaşma yeteneğine sahip akıllı sistemler oluşturmak için kullanılan bir bilim dalıdır [12]. Evrişimsel sinir ağları görüntü işleme ile ilgili alanlarda oldukça fazla kullanılmaktadır. Çok katmanlı

ağ mimarileri ile sınıflandırma, nesne tespiti ve bölütleme gibi birçok alanda uygulanmıştır. Bu ağ mimarisinde üst katmandaki özellikler alt katmandakilerine göre daha soyuttur. Alınan giriş görüntülerinden hiyerarşik özellikler otomatik olarak öğrenilir. Bu özellikler doğru şekilde sınıflandırma için oldukça önemlidir. Bu ağlarda her katmada giriş görüntüsünü ardışık olarak işleyip özellik haritası olarak isimlendirilen daha yüksek düzete bir soyutlama oluşturur. Modern evrişimsel sinir ağları çok derin bir katman yapısını kullanarak iyi bir performans elde edebilirler. Evrişimsel sinir ağları temelde üç tür katman içermektedir: evrişim katmanı, havuzlama ve tam bağlı katmandır. Evrişim ve havuzlama katmanları ardışık bir şekilde bağlanarak evrişim bloklarını oluştururlar. Tam bağlı katman ise genelde bir veya iki seviyeli olup sınıflandırma veya regresyon için kullanılmaktadır. Şekil 1’de evrişimsel sinir ağının yapısı verilmiştir.



Şekil 1: Evrişimsel Sinir Ağı Mimarisi

Şekil 1’de evrişimsel sinir ağında evrişim katmanlarından her biri yüksek boyutlu evrişim katmanlarından oluşmaktadır. Her bir katmanın giriş aktivasyonları, her biri kanal olarak isimlendirilen 2 boyutlu özellik haritası olarak ifade edilmektedir. Her kanal 2 boyutlu filtreler ile evrişim işlemine tabii tutulur. Evrişim sonuçları tüm kanallarda toplanır ve yeni özellik haritası oluşturulur. Şekil 2’de basit bir şekilde evrişim işlemi gösterilmiştir.



Şekil 2: Evrişimsel Sinir Ağında Konvülyasyon İşlemi


Şekil 2’de gösterildiği gibi bir görüntü için birden fazla kanal elde edilmekte ve her bir kanal için farklı filtreler kullanılarak yeni özellik haritası oluşturulmaktadır. Son yıllarda geliştirilen evrişimsel sinir ağlarında 5 evrişim katmanından 1000 evrişim katmanına kadar evrişim katmanı kullanılmaktadır. Konvülyasyon işleminden sonra genellikle sınıflandırma problemleri için 1 ile 3 arasında tam bağlı katman kullanılır. Her bir kanala konvülyasyon işlemi uygulandıktan sonra doğrusal olmayan bir aktivasyon fonksiyonu uygulanır. Aktivasyon sonucu elde edilen değerler ölçeklenip normalleştirildiğinde öğrenme hızı artırılabilir. Bu amaçla batch normalizasyonu kullanılmaktadır. Bu normalizasyon yöntemi her katmanın diğer katmanlardan biraz bağımsız olarak kendi kendine öğrenbilmesine izin verir. Batch normalizasyonu her katmana iki tane eğitilebilir parametre olan ortalama (μ) ve standart sapma parametrelerini (σ) ekler. Böylece normalize edilen çıkış standart sapma ile çarpılır ve ortalama ile toplanır. Normalleştirilen değerler

ölçekleme ve kaydırma işlemine tabii tutulur. Denklem (1)’de bu normalleştirme verilmiştir

$$\hat{y}_i = \gamma \frac{x_i - \mu\beta}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (1)$$

Denklemde γ ve β parametreleri eğitimden öğrenilmekte ve ϵ parametresi ise sıfıra bölme hatasından kurtulmak için eklenen küçük bir değerdir.

Normalizasyon işleminden sonra evrişim ile elde edilen özellik haritasının uzaysal boyutunu düşürmek için havuzlama işlemi uygulanır. Bu işlem önceki katmanda üretilen özellik haritalarının yeniden alt örneklenmesidir. Konvülyasyon işlemi sonrası elde edilen her bir kanaldaki görüntü birkaç alt bölgeye ayrılır. Daha sonra havuzlama işlemi bu bölgeler üzerinde uygulanarak yeni değerler elde edilir. Genellikle maksimum veya ortalama havuzlama kullanılır. Şekil 3’te havuzlama işleminin bir görüntü üzerinde uygulaması verilmiştir.



Şekil 3: Maksimum ve ortalama havuzlama işlemi

Şekil 3’te adım (stride) boyutu 2 olarak alınmıştır. Havuzlama işlemi birbiri ile örtüşmeyen bloklar üzerinde gerçekleşir ve stride

boyutu havuzlama boyutunu da göstermektedir. Adım boyutu 2 ve üzeri seçildiğinde özellik haritasının boyutunda bir azalma olur. Derin evrişimsel sinir ağlarının oluşturulmasında temel yapıyı evrişimsel katmanlar ile havuzlama katmanı oluşturur. Düşük katmanlardaki evrişimsel katmanlar kenar ve eğri gibi özellikleri çıkarırken daha yüksek seviyedeki katmanlar daha soyut bilgileri çıkarmaktadır. Evrişimsel sinir ağlarında havuzlama, evrişim ve normalizasyon işlemleri ardışık olarak birkaç kez uygulandıktan sonra elde edilen özellikler tam bağlı katmana verilir. Tam bağlı katman girişlerini önceki katmandan alarak yüksek seviyeli muhakeme için faydalanılır. Literatürde son yıllarda önerilen evrişimsel sinir ağları genellikle farklı ağ mimarilerine sahiptir. Evrişimsel sinir ağlarında bu farklılığı sağlayan temel faktörler katman sayısı, filtre boyutu, filtre ve kanal sayısı ve katmanlar arasındaki bağlantılardır. İlk evrişimsel sinir ağlarından biri LeNet olup 1989'da dijital sınıflandırma için önerilmiştir. Bu ağın giriş görüntüleri 28x28 piksel boyutunda olup, ağ iki adet konvolüsyon ve iki tam bağlı katmandan oluşur. Her evrişim katmanında kanal başına 5x5'lik filtreler kullanılmıştır. 2x2 boyutunda ortalama havuzlama her evrişim katmanından sonra uygulanmış ve sigmoid aktivasyon fonksiyonu seçilmiştir.

Alexnet [13] 2012 yılında ImageNet yarışması için önerilmiş bir evrişimsel sinir ağı modelidir. Bu model 5 evrişim, 3 tam bağlı katman içermektedir. Her evrişim katmanında boyutları 3x3 ten 11x11 boyutunda filtreler uygulanmaktadır. Alexnet'te toplam 60 milyon parametrenin ayarlanması gerekir. Diğer bir popüler evrişimsel sinir ağı GoogLeNet [14] 22 katmana sahiptir. Bu ağ mimarisinde paralel bağlantılara sahip başlangıç modülü bulunmaktadır. Farklı boyutlarda filtreler (1x1, 3x3, 5x5) ve takip eden 3x3'lük havuzlama katmanı her bir paralel bağlantı için kullanılır ve çıkışları modül çıkışı için bağlanır. ResNet [15] daha derine inmek için artık bağlantılar kullanır ve toplamda 34 katmandan daha fazla katmana sahiptir. ImageNet veri setinde %5'in altında bir başarımla sağlamıştır. Farklı evrişimsel sinir ağlarının ImageNet üzerindeki başarımları ve kullanılan katman, filtre ve havuzlama parametreleri ile tam bağlı katman sayıları Tablo 1'de verilmiştir.

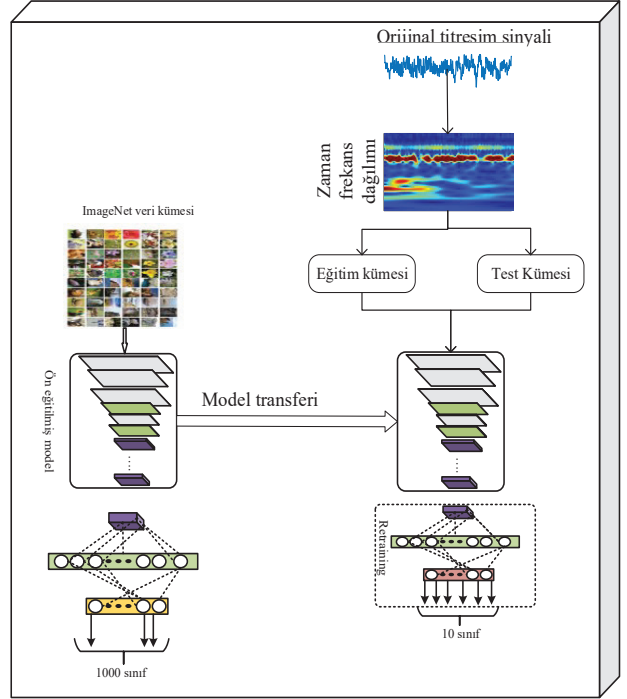
Tablo 1: Önerilen indüksiyon ısıtma sistemine ait indüksiyon sargısı ve çalışma parçasının boyutları

Metrik	AlexNet	GoogLeNet	ResNet50
İlk 5 hata	16.4	6.7	5.3
Giriş boyutu	227x227	224x224	224x224
Evrişim katman sayısı	5	57	53
Filtre boyutları	3, 5, 11	1,3,5,7	1,3,7
Kanal sayısı	3-256	3-832	3-2048

Tablo 1'de gösterildiği gibi her bir evrişimsel sinir ağı farklı boyutlarda ve sayıda evrişim katmanı, filtre ve tam bağlı katman kullanabilmektedir.

3. Mil Yatağı Arıza Teşhisi İçin Evrişimsel Sinir Ağı Topluluklarının Birleştirilmesi

Bu çalışmada asenkron motorlarda oluşan mil yatağı arızalarının tespit ve teşhisi için çoklu derin öğrenme yöntemlerinin birleştirilmesine dayalı bir teknik önerilmiştir. Önerilen yöntem ilk olarak titreşim sinyallerinin zaman frekans dağılımını elde etmektedir. Daha sonra bu dağılım görüntü olarak kaydedilmektedir. Her bir arıza durumu için elde edilen görüntüler derin evrişimsel sinir ağı modellerine verilerek arıza sınıfı belirlenmektedir. Son aşamada bu model çıktıları birleştirilerek arızalar belirlenmektedir. Şekil 4'te önerilen sistemin blok şeması verilmiştir.

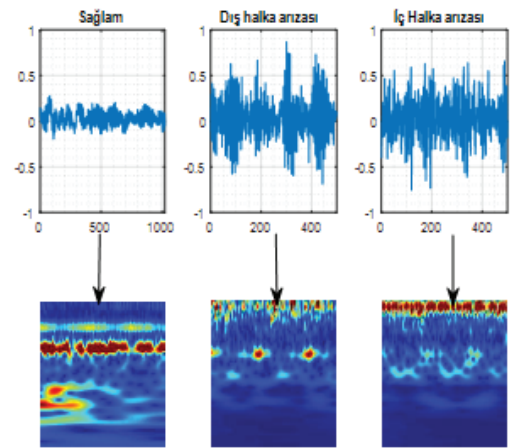


Şekil 4: Önerilen transfer öğrenme tabanlı yöntemin akış diyagramı

a. Zaman Frekans Görüntüsü

Motordan okunan titreşim sinyalleri zaman-frekans dağılım yöntemi ile görüntülere dönüştürülmüştür. Zaman frekans dağılımı zaman frekansında alınan zaman serisi sinyallerini zaman ve frekans bilgisi ile gösterilecek biçimde zaman frekans alanına dönüştürür [16]. Bu dağılım bir sinyalin farklı zamanlarda farklı frekans bileşenleri için izlemeye yardımcı olur. Zaman-frekans dağılımını elde etmek için kısa zamanlı Fourier dönüşümü, sürekli dalgacık analizi ve S- dönüşümü gibi teknikler kullanılabilir. Bu yöntemler içerisinde çoklu çözünürlüklerde sinyali en iyi şekilde modellemek için kullanılacak teknik sürekli dalgacık analizidir. Dalgacık türü olarak ölçekleme ve dönüşümü sağlayan mother dalgacığı kullanılır. Bu dönüşüm denklem (2)'de verilmiştir. Şekil 5'te, farklı durumlar için titreşim sinyalleri ve zaman frekans görüntüleri verilmiştir.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (2)$$




Şekil 5: Farklı durumlar için titreşim sinyalleri ve zaman frekans görüntüleri

b. Transfer Öğrenme

Modern evrişimsel sinir ağı modelleri çok büyük veri kümeleri üzerinde eğitilerek bir sonuç elde etmişlerdir. Bu modellerden en çok kullanılanı ImageNet olup veri kümesi 1000 sınıflı ve boyutu yaklaşık bir milyon örnekten oluşmaktadır. Fakat sınırlı bir veri kümesine sahip olduğunda bu evrişimsel sinir ağı modellerini eğitmek ve parametrelerini optimize etmek pek mümkün olmamaktadır. Bu yüzden sınırlı veri kümesi için transfer öğrenme yöntemi kullanılmaktadır. Bir evrişimsel sinir ağının daha düşük katmanları genel özellik çıkarımını sağlarken daha yüksek katmanlar orijinal sınıflandırma görevi için daha spesifik bilgi taşırlar. Bu özellik bir evrişimsel sinir ağındaki genelleştirilmiş özellik çıkarımının ve düşük katmanlardaki gösterimin yeniden kullanımını kolaylaştırırken daha yüksek katmanların orijinal problem ile ilgili özelliklere sahip ikincil problem alanına doğru ayarlanır. Böylece 1000 sınıflı bir sınıflandırma problemi için elde edilen parametreleri belirli bir problem için bir başlangıç noktası olarak seçebiliriz. Rastgele ağırlık başlatma özelliğine sahip bir

evrişimsel sinir ağı tasarlamak yerine genelleştirilmiş nesne tanıma için önceden optimize edilmiş ve ön eğitimi yapılmış bir ağ modeli kullanılarak bu ağırlıklar belirli bir sınıflandırma alanına göre ince ayar ile düzenlenir. Bu çalışmada ön eğitilmiş ağ olarak GoogleNet seçilmiştir. Bu ağ yapısında toplamda 22 katman bulunup ilk versiyonu 2014'te önerilmiştir. Toplamda 22 katmanın 3 katmanı evrişim, 9 katmanı başlangıç katmanı olup her biri 2 evrişim katmanından oluşur. Ağ bir tane tam bağlı katmana sahiptir. Şekil 7'de GoogleNet evrişimsel sinir ağındaki başlangıç modülü gösterilmiştir.


Şekil 7'de Inception modüllerindeki genişleme etkisi evrişim katmanlarındaki 1×1 , 3×3 , 5×5 filtrelerin ve 3×3 maksimum ortaklama işleminin paralel olarak gerçekleştirilmesiyle oluşturulmaktadır. Ancak burada önemli bir sorun vardır: İşlem karmaşıklığı, çıkış boyutunun büyüklüğü ve parametre sayısının paralel işlemler yüzünden çok büyümesidir. Bu problemin üstesinden 1×1 evrişim katmanları paralel Naif Inception evrişim katmanlarının öncesine eklenerek boyut azaltma işlemi gerçekleştirilmektedir.



Şekil 6: Googlenet başlangıç modülü

4. Deneysel Sonuçlar

Önerilen yöntemin doğruluğunu ispatlamak için iki farklı deney üzerinde uygulamalar yapılmıştır. İlk olarak Case Western Üniversitesi Rulman veri merkezinde farklı arıza türleri için alınan titreşim verileri ile bir derin öğrenme modeli oluşturulmuş ve mil yatağı arızaları ile ilgili farklı arıza türleri ve şiddetleri veri kümesinde kullanılmıştır. Titreşim verileri, manyetik tabanlar ile mahfazaya bağlanan ivmeölçerler kullanılarak toplanmıştır. İvmeölçerler, motor gövdesinin hem tahrik ucunda hem de fan ucunda saat 12 pozisyonuna yerleştirildi. Bazı deneyler sırasında, motor destek taban plakasına bir ivmeölçer takıldı. Titreşim sinyalleri 16 kanallı bir veri toplama kartı kullanılarak toplandı ve bir Matlab ortamında sonradan işlendi. Veriler 12 kHz örnekleme hızı ile alınmıştır. Hız ve beygir gücü verileri tork dönüştürücü kodlayıcı kullanılarak toplanmış ve elle kaydedilmiştir. Şekil 7'de deney düzeneği verileri gösterilmiştir.



Şekil 7: Titreşim sinyallerini toplamak için kullanılan deney düzeneği


Şekil 7'de gösterildiği gibi deney düzeneği 2 HP motor, tork dönüştürücü ve yüklemeye için bir dinamometre ile kontrol elektroniklerinden oluşmaktadır. Test yatakları motor şaftını desteklemektedir. Test rulmanlarına 7, 14 ve 21 mil (1 mil=0.001 inç) arıza çaplarına sahip elektro deşarj yöntemi ile arızalar oluşturulmuştur. Motor 1720-1797 rpm hızlarında çalıştırılmıştır. Tablo 2'de oluşturulan arıza bilgileri verilmiştir.

Tablo 2: Mil yatağı arıza türleri

Arıza Yeri	Arıza çapı(mils)	Veri boyutu	Motor Yüğü
İç Halka	7	1024	0, 1, 2, 3 HP
	14	1024	
	21	1024	
Dış Halka	7	1024	
	14	1024	
	21	1024	
Bilye arızası	7	1024	
	14	1024	
	21	1024	
Sağlam durum	-	1024	1,3,7

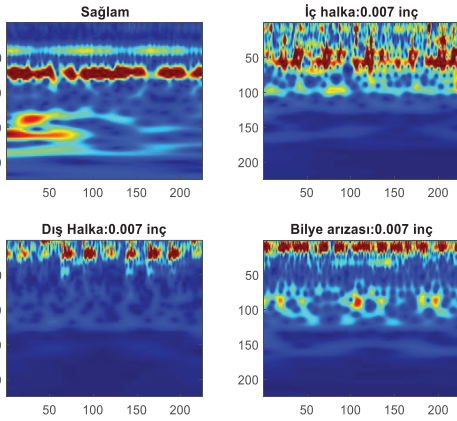
Tablo 2'de gösterildiği gibi her bir arıza durumu için üç arıza şiddeti bulunmaktadır. Ayrıca sağlam durum için de üç farklı yük durumu göz önüne alınmıştır. Dolayısıyla toplam 10 sınıflı bir veri

kümesi oluşturulmuştur. Şekil 8’de farklı arıza türleri ve sağlam durum için titreşim sinyalleri verilmiştir.



Şekil 8: Sağlam durum ve farklı arıza türleri için motor titreşim sinyalleri

Şekil 8’de gösterildiği gibi özellikle sağlam durum ile bilye arızaları birbirine oldukça benzemektedir. Titreşim sinyalleri elde edildikten sonra sürekli dalgacık analizi ile zaman frekans dağılımı elde edilmektedir. Şekil 9’da farklı arıza türleri ve sağlam durum için zaman-frekans görüntüleri verilmiştir.



Şekil 9: Sağlam durum ve farklı arıza durumları için zaman-frekans görüntüleri


Şekil 9’da gösterildiği gibi farklı arıza durumları için motor zaman-frekans dağılımları farklı çıkmaktadır. Sağlam durumda 100-50 Hz arasında bir değişim olurken, iç halka arızasında 100-0 Hz arasında, dış halka arızasında 50-0 Hz arasında ve bilye arızasında 25-0 arasında bir belirginlik oluşmaktadır. Bu amaçla zaman serisi 1024’lük parçalara bölünmektedir. Her bir parça arasındaki örtüşme sıfır olarak seçilmiştir. Bu bilgi arıza tespiti için kullanılabilir. Elde edilen zaman-frekans görüntüleri 5.808 görüntüden oluşmaktadır. Görüntü boyutları 224x224 pikselden oluşmaktadır. Oluşturulan GoogleNet modelinin parametreleri Tablo 3’te verilmiştir

Tablo 3: Kullanılan GoogleNet modelinin parametreleri

Özellik	Değer
Eğitim kümesi örnek sayısı	4066
Doğrulama örnek sayısı	1742
Mini yığın boyutu	32
Maksimum adım sayısı	7
Başlangıç öğrenme oranı	1e-4

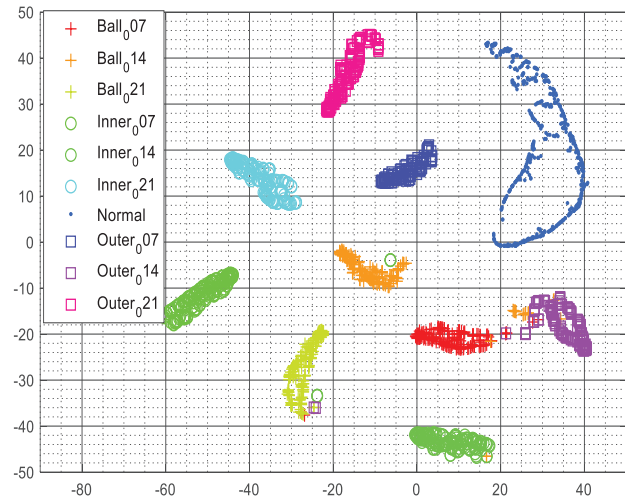
Doğrulama frekansı	50
--------------------	----

Derin evrişimsel sinir ağı için parametre ayarları yapıldıktan sonra GoogleNet ağı eğitilmiştir. Verilen adım sayısı boyunca eğitim, doğrulama veri setinin doğruluğu ve kayıp parametresinin eğitim ve doğrulama için değişimi Şekil 10’da verilmiştir.



Şekil 10: GoogleNet modelinin eğitim, doğrulama başarımları ve kayıp fonksiyonunun değişimi

Şekil 10’da görüldüğü gibi hem eğitim hem de doğrulama başarımları 700 adım sonrasında maksimum değer olan %98.9’a ulaşmaktadır. Ayrıca derin öğrenme ile görüntülerden çıkarılan özelliklerin her bir katmanda gösterimi yapılabilmektedir. Şekil 11’de, ince ayarlanmış GoogleNet’ten çıkarılan dahili özellik uzayının özellik haritalarının t-SNE (dağıtık stokastik komşuluk gömülmesi) görselleştirmesini göstermektedir.



Şekil 11: Farklı arıza türleri için GoogleNet’in son katmanının t-SNE görselleştirmesi


Şekil 11’de gösterildiği gibi doğrulama verilerininin GoogleNet’in son katmanında bir birinden doğru bir şekilde ayırt edilebildiği görülmektedir. Şekil 11’de Inner Race (iç halka), Outer race (Dış halka) ve Ball (Bilye) arızaları ile sağlam durum (normal) t-SNE gösterimleri verilmiştir. Arızalar 0.007, 0.014 ve 0.021 inç hata çaplarına sahip elektro-erozyon işleme kullanılarak test rulmanlarına tek nokta hataları uygulanarak elde edilmiştir. Sadece bazı arızalar

örneklerin diğer arıza sınıfları ile karıştığı görülmektedir. Sınıflandırma başarımını ölçmek için karmaşıklık kullanılmıştır. Şekil 12’de doğrulama verileri için karmaşıklık matrisi gösterilmiştir.

		Karmaşıklık Matrisi											
Tahmin Edilen Sınıf	Bilye_007	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.1%	0 0.0%	98.6% 1.4%	
	Bilye_014	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	99.3% 0.7%	
	Bilye_021	0 0.0%	0 0.0%	140 8.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	İçhalka_007	0 0.0%	0 0.0%	0 0.0%	143 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	İçhalka_014	0 0.0%	0 0.0%	1 0.1%	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.3% 0.7%	
	İçhalka_021	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	Normal	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	497 28.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	Dışhalka_007	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	107 6.1%	0 0.0%	0 0.0%	100% 0.0%	
	Dışhalka_014	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	139 8.0%	0 0.0%	99.3% 0.7%	
	Dışhalka_021	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	143 8.2%	100% 0.0%	
		100% 0.0%	100% 0.0%	98.6% 1.4%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	97.9% 2.1%	100% 0.0%	99.7% 0.3%	
		Bilye_007	Bilye_014	Bilye_021	İçhalka_007	İçhalka_014	İçhalka_021	Normal	Dışhalka_007	Dışhalka_014	Dışhalka_021		
		Gerçek Sınıf											

Şekil 12: Mil yatağı arızası için elde edilen karmaşıklık matrisi

Şekil 12’de 10 sınıf için hatalı sınıflandırma oranının oldukça düşük olduğu görülmektedir. Toplamda 4 adet test verisi yanlış sınıflandırılmıştır. Sınıflandırma başarımı %99.7 olarak elde edilmiştir. Bir önceki aşamada 9 farklı arıza durumu ve sağlam durum için elde edilen model kullanılarak gerçek bir tren motorundan alınan titreşim sinyalleri ile test edilmiştir. Bu amaçla motorun dört farklı noktasına titreşim sensörleri yerleştirilmiştir. Bu titreşim sensörleri ile saniyede 12.000 örnek örnekleme oranı ile veriler üç eksende toplanmıştır. Şekil 13’te kullanılan motorun üzerine sensörlerin yerleşimi gösterilmiştir.



Şekil 4: Tren motoruna sensörlerin yerleşimi


Şekil 13’te gösterildiği gibi farklı noktalara titreşim sensörleri yerleştirilerek veriler alınmıştır. Deneysel sonuçlardan eğitim için kullanılan veri setinde sürücü sonuna ve fan sonuna titreşim sensörü eklenerek veriler alınmıştır. Eğitim aşamasında fan sonuna eklenen sensörden gelen titreşim sinyalleri kullanılarak model eğitimi yapılmıştır. Motora 4 farklı sensör yerleştirilmesine rağmen model motorda alınan sinyallere benzer şekilde aynı sürücü tarafına yerleştirilmiş olan 73 nolu sensör bilgisi kullanılmıştır. Dolayısıyla bu çalışmada 73 nolu sensörün x ekseninden gelen titreşim sinyalleri kullanılmıştır. Motorun milinde arıza olduğu bilinmekte fakat

arızanın ne olduğu ile ilgili herhangi bir bilgi bulunmamaktadır. Veriler farklı çalışma hızları ve yük altında alınmıştır. Verilerin alınma biçimleri Tablo 4’te verilmiştir.


Tablo 4: Tren motoru için alınan verilerin özellikleri

Verinin Alındığı Hız	Yük Durumu
50 RPM	Boşta 150Nm
250 RPM	Boşta 150Nm
500 RPM	Boşta 150Nm
1000 RPM	Boşta 150Nm
2000 RPM	Boşta 150Nm

Fakat burada sınıf sayısı önceki modeldeki gibi 10 olarak alınmamıştır. Sadece arızanın türü belirlenmektedir. Çünkü gerçek bir motor olduğu için arızanın şiddeti ve mil yatağında ne kadarlık bir arızanın olduğu bilgisi elimizde yoktur. Dolayısıyla sağlam, iç halka, dış halka ve bilye arızası olmak üzere toplamda 4 sınıf göz önüne alınmıştır. Şekil 14’te 50 RPM’de çalışan motor için boşta çalışma durumunda titreşim sinyali ve zaman frekans görüntüsü verilmiştir.



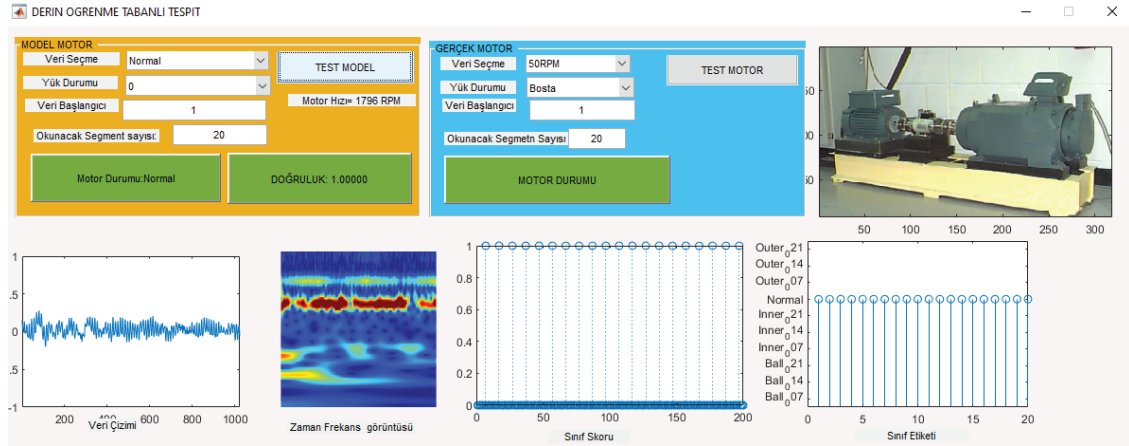
(a) Titreşim sinyali



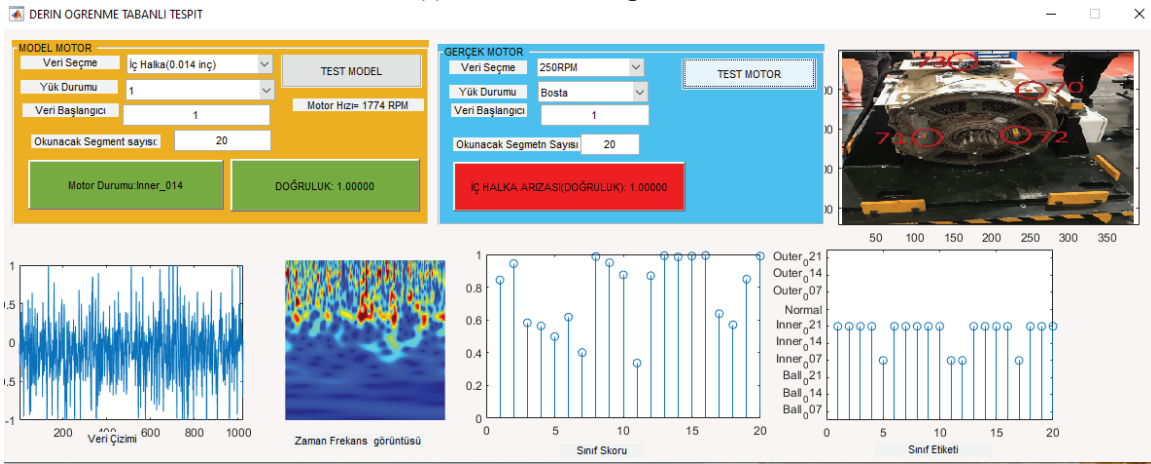
(b) Zaman Frekans dağılım görüntüsü

Şekil 14: Tren motorundan alınan titreşim sinyali ve zaman-frekans görüntüsü

Şekil 14’ten de görüldüğü gibi titreşim sinyali ve elde edilen zaman frekans görüntüsü 0.007 inç iç halka arızasına oldukça benzemektedir. Her bir çalışma hızı ve yük durumu için testler yapılmıştır. Önerilen yöntemin görsel olarak test edilmesi amacıyla hem model veriler hem de gerçek verilerin test edilebileceği bir arayüz hazırlanmıştır. Bu arayüz içerisinde eğitilmiş derin öğrenme modeli kullanılmaktadır. Derin öğrenme ağ yapısı 10 sınıf için Case Western üniversitesi Bearing Data Center’den alınan veriler ile eğitilmiştir. Şekil 15’de eğitilen model ile ara yüzde elde edilen sonuçlar verilmiştir.



(a) Referans model sağlam durum



(a) Gerçek motor 250 RPM boşta çalıştırma

Şekil 5: Farklı arıza türleri için model üzerinde sonuçların gösterimi a) sağlam, b) iç halka arızası

Şekil 16'da toplam 10 sınıftan oluşan veri kümesi kullanılarak farklı arıza türleri için elde edilen sonuçlar gösterilmiştir. Her bir durum için 4 farklı yük durumu mevcuttur. Pencere boyutu 1024 olarak alınmış ve örtüşme sıfır olarak seçilmiştir. Veri başlangıcı ve segment sayısı(okunacak pencere sayısı) kullanıcı tarafından belirlenmektedir. Buna göre sistem performansı elde edilmektedir.

Eğitim aşamasında elde edilen model büyük güçlü motorda toplanan ve arızalı olduğu bilinen motordan elde edilen titreşim verileri ile test edilmiştir. Büyük güçlü motor verilerinde yüklü ve yüksüz durumlar mevcuttur. Bu yük durumları için 6 farklı hızda veriler okunmuştur. Tablo 5'te yapılan test sonuçları verilmiştir.

Tablo 5: Ölçümlerden elde edilen test sonuçları

Veri Seti	Yük durumu	Bilye			İç Halka			Sağlam	Dış Halka			Tespit edilen arıza	Doğruluk oranı (%)
		1	2	3	1	2	3		0	1	2		
50 RPM	Boşta	0	6	4	66	5	370	1	0	0	0	İç Halka	96.46
	150 Nm	0	2	3	36	0	254	0	0	0	0	İç Halka	98.31
250 RPM	Boşta	1	1	3	53	5	248	0	0	0	0	İç Halka	96.78
	150 Nm	0	1	9	32	2	249	0	0	0	0	İç Halka	95.90
500 RPM	Boşta	1	0	13	4	1	273	0	0	0	0	İç halka	94.86
	150 Nm	1	2	11	4	1	275	0	0	0	0	İç Halka	94.90
	Boşta	3	1	17	127	0	141	0	0	0	0	İç Halka	92.66

1000 RPM	150 Nm	1	1	27	135	2	143	0	0	0	0	İç Halka	89.97
2000 RPM	Boşta	0	2	4	17	1	275	0	0	0	0	İç Halka	97.66
	150 Nm	0	1	3	20	1	267	0	0	0	0	İç Halka	98.29
2700 RPM	Boşta	0	1	3	32	0	256	0	0	0	0	İç Halka	98.63
	150 Nm	0	1	3	52	1	235	0	0	0	0	İç halka	98.29

Tablo 5'te gösterildiği gibi toplam 10 sınıflı bir model ile elde edilen veriler test edilmiştir. Tablo 5'teki 1, 2 ve 3 değerleri sırasıyla her bir durum için 0.007, 0.014, 0.021 inç arıza şiddetlerini göstermektedir. Sağlam durum sıfır etiketi ile gösterilmiştir. Tablo 5'te görüldüğü gibi bütün durumlarda iç halka arızası olduğu tespit edilmiştir. Örneğin ilk satırda 370 tane örnek 0.021 inçlik iç halka arızası olarak sınıflandırılmış ve 66 tanesi 0.007 inç iç halka arızası olarak tespit edilmiştir.

5. Sonuç

Bu çalışmada iki farklı boyuttaki asenkron motorda oluşan kusurların tespiti ve birbiri ile olan ilişkisi için derin öğrenme tabanlı bir yaklaşım önerilmiştir. Küçük güçlü motor için öğrenilen model transferi büyük güçlü motorda kullanılarak arıza türü belirlenmeye çalışılmıştır. İki motor türü için verilerin doğru alınabilmesi için örneklem oranı ve sensör yerleşiminin benzer olmasına dikkat edilmiştir. Böylece arızaların aynı titreşim noktası üzerindeki etkileri incelenmiştir. Önerilen yaklaşımda Case Western Üniversitesindeki motordan alınan sinyaller 10 farklı arıza türü için derin öğrenme ağı ile eğitilmiştir. Daha sonra mil yatağında problem olduğu bilinen büyük güçlü motordan aynı koşullarda veriler alınmış ve farklı yük ve hızlarda titreşim sinyalleri aynı örnekleme oranı ile toplanmıştır. Testler sonucunda büyük güçlü motorda da iç halka arızası olduğu %96,05'lik bir doğruluk ile belirlenmiştir. Dolayısıyla bir model transferi yapılarak farklı tipte motorlara uygulanabilirlik sağlanmıştır.

Teşekkür

Bu çalışma Türkiye Bilimsel Ve Teknolojik Araştırma Kurumu (TUBITAK) tarafından 122E412 nolu proje ile desteklenmiştir.

Kaynakça

- [1] G. Niu, X. Dong, Y. Chen, "Motor Fault Diagnostics Based on Current Signatures: A Review", *IEEE Transactions on Instrumentation and Measurement*, 72,1-9, 2023.
- [2] S. Zhang, S. Zhang, B. Wang, T. G. Habetler, "Deep learning algorithms for bearing fault diagnostics—A comprehensive review", *IEEE Access*, 8, 29857-29881, 2020.
- [3] D.T. Hoang, H. J. Kang, "A motor current signal-based bearing fault diagnosis using deep learning and information fusion", *IEEE Transactions on Instrumentation and Measurement*, 69 (6), 3325-3333, 2019
- [4] M. Q. Tran, M. K. Liu, Q.V. Tran, T. K. Nguyen, "Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors", *IEEE Transactions on Instrumentation and Measurement*, 71, 1-13, 2020.
- [5] S. Shao, S. McAleer, R. Yan, P. Baldi, "Highly accurate machine fault diagnosis using deep transfer learning", *IEEE Transactions on Industrial Informatics*, 15(4), 2446-2455, 2018.
- [6] S. A., Aburakhia, R. Myers, A. Shami, "A hybrid method for condition monitoring and fault diagnosis of rolling bearings with low system delay", *IEEE Transactions on Instrumentation and Measurement*, 71, 1-13, 2022.
- [7] A. Bapir, I. Aydin, "Cloud based bearing fault diagnosis of induction motors", *Computer Science*, (Special), 141-146, 2021.
- [8] S. Aburakhia, T. Tayeh, R. Myers, A. Shami, "Similarity-Based Predictive Maintenance Framework for Rotating Machinery", In: *2022 IEEE 5th International Conference on Communications, Signal Processing, and their Applications (ICCSPA)*, 1-6, 2022.
- [9] CWRU, Case Western Reserve University Bearing Data Center Website, Cleveland, OH, USA. Available online: <https://engineering.case.edu/bearingdatacenter>
- [10] C. Lessmeier, J. K. Kimotho, D. Zimmer, W. Sextro, "Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification", *European Conference of the Prognostics and Health Management Society*, Bilbao (Spain), 1-17, 2016.
- [11] M. Sehri, P. Dumond, M. Bouchard, "University of Ottawa constant load and speed rolling-element bearing vibration and acoustic fault signature datasets", *Data in Brief*, 49, 1-10, 2023.
- [12] S. Dong, P. Wang, K. Abbas, "A survey on deep learning and its applications", *Computer Science Review*, 40, 1-22, 2021.
- [13] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks", *Advances in Neural Information Processing Systems* 25(2), 84-90, 2012.
- [14] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, A. Rabinovich, "Going deeper with convolutions", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9, 2015.
- [15] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778, 2016.
- [16] S.G.A. Mallat, "Wavelet Tour of Signal Processing: The Sparse Way", 3rd ed. Amsterdam, Boston: Elsevier/Academic Press, 2009.

Özgeçmişler



İlhan Aydın, 1981 yılında Elâzığ'da doğdu. Lisans ve Yüksek Lisans derecelerini Fırat Üniversitesi Bilgisayar Mühendisliğinde 2001 ve 2006 yıllarında aldı. Doktora derecesini 2011 yılında Fırat Üniversitesi, Elektrik ve Elektronik Mühendisliği bölümünden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği bölümünde Profesör Doktor olarak görev yapmaktadır. Araştırma alanları arasında optimizasyon, gerçek zamanlı sistemler, hata teşhisi ve durum izleme, sinyal ve görüntü işleme ve derin öğrenme bulunmaktadır.



Emrullah Aydın, 1986 yılında Elazığ'da doğdu. Lisans eğitimini 2009 yılında Fırat Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. 2014 ve 2020 yıllarında Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde sırasıyla Yüksek Lisans ve Doktora eğitimlerini tamamlamıştır. Doktora eğitimini tamamladıktan sonra Malatya Turgut Özal Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Dr. Öğretim Üyesi olarak çalışmaya başlamış ve halen burada çalışmaya devam etmektedir. İlgili çalıştığı araştırma alanları arasında Kablosuz Güç Aktarımı, Elektrik Makinaları, Güç Elektroniği ve İndüksiyon Isıtma Sistemleri yer almaktadır.



Erhan Akin, lisans derecesini Elazığ Fırat Üniversitesi'nden elektrik mühendisliği bölümünden 1984 yılında, yüksek lisans derecesini Elazığ Fırat Üniversitesi'nden bilgisayar mühendisliği bölümünden 1987 yılında ve doktora derecesini 1994 yılında Fırat Üniversitesi elektrik mühendisliği alanından almıştır. Halen Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Profesör Doktordur. Fırat Üniversitesi Bilgisayar Mühendisliği bölüm başkanıdır. Araştırma ilgi alanları arasında yumuşak bilgi işlem, elektrik motoru sürücüleri, bulanık kümeler ve sistemler, doğrusal olmayan kontrol sistemleri, hata teşhisi ve bilgisayar görüşü yer almaktadır.



Seyfullah Kaner, 1992 yılında Muş'ta doğdu. Lisans Eğitimini 2015 yılında Yalova Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümünde tamamladı. Yüksek Lisans Eğitimini 2021 yılında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümünde tamamladı. Halen Muş Alparslan Üniversitesinde Öğretim Görevlisi olarak çalışmaktadır. Araştırma ilgi alanları Derin öğrenme, görüntü işleme, arıza teşhisi ve rastgele sayı üreteçleri üzerinedir.

Muharip İHA'ların İnsanlı Savaş Uçaklarından Yönetilmesi İçin Gerekli Otonomi Seviyelerinin Belirlenmesi Üzerine Bir Araştırma

A Research On Determining The Autonomy Levels Necessary For Managing Combatant UAVs From Manned Combat Aircraft

Güray Kasapoğlu¹, Özer Demir¹, Halil Sert¹, Tolga Türkmen¹, Haluk Gözde¹, Serkan Kurt^{1,2}

¹ Türk Havacılık ve Uzay Sanayii (TUSAŞ)
Ankara / Türkiye

² Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Elektronik ve Hab. Müh. Böl.
İstanbul / Türkiye

guray.kasapoglu@tai.com.tr, ozer.demir@tai.com.tr, halil.sert@tai.com.tr, tturkmen@tai.com.tr,
haluk.gozde@tai.com.tr, skurt@yildiz.edu.tr

Öz

Savunma sanayiinde öncü ülkeler tarafından geliştirilen ve otonom şekilde tek ya da sürü halinde görev yapabilen İHA'ların, havadaki başka bir muharip uçak tarafından yönlendirilmesi konseptinin uygulamaya geçmesi askeri havacılık alanında yeni bir çağın başlangıcı olmuştur. Silahlı bir güç olarak otonom İHA'ların daha fazla yetkiye sahip olması ve pilotun artan otonomi seviyelerinde döngünün dışına doğru çekilmesi nihai beklentidir. Ancak mevcut otonomi yaklaşımlarının henüz söz konusu konseptte kullanılacak seviyede olmadığı değerlendirilmektedir. Bu çalışmada, insanlı-insansız iş birliği konsepti (Manned UnManned – MUM-T) içinde tek başına insan veya yapay zekâ tarafından yapılması zor görevleri iş birliği içerisinde gerçekleştirirken, farklı görevler için ihtiyaç duyulan fonksiyonların hangi yetki seviyelerinde kimler tarafından yapılacağına tespit edilmesi ve bu yetkilendirmelerin standart hale getirilmesi için manuel kullanımdan tam otonomiye kadar gerekli otonomi seviyelerinin belirlenmesi amaçlanmıştır. Bu maksatla, operatif seviyede yapılacağı öngörülen 11 adet fonksiyon uzman görüşüyle incelenerek her biri için altışar seviyeli otonomi çizelgeleri özgün olarak oluşturulmuş ve literatüre sunulmuştur.

Anahtar Kelimeler: İnsansız Hava Aracı, İnsanlı Savaş Uçağı, İnsanlı-İnsansız İş birliği, Otonomi Seviyeleri.

Abstract

The implementation of the concept of UAVs, which were developed by leading countries in the defense industry, can operate autonomously alone or in groups, being guided by another combat aircraft in the air, has marked the beginning of a new era in the field of military aviation. As an armed force, the ultimate expectation is that autonomous UAVs will have more authority and the pilot will be pulled out of the loop with increasing levels of autonomy. However, it is considered that current autonomy approaches are not yet at the level to be used in this concept. In this study, while performing tasks that are difficult to do by humans or artificial intelligence alone within the concept of Manned-UnManned Teaming, it is aimed to determine who will perform the functions needed for different tasks at what authority levels and to standardize these authorizations. The aim is to determine the required autonomy levels, from manual use to full autonomy. For this purpose, 11 functions that were predicted to be performed at the operative level were examined with expert opinion, and six-level autonomy charts for each were originally created and presented to the literature.

Key Words: Unmanned Aerial Vehicle, Manned Combat Aircraft, Manned-Unmanned Cooperation, Autonomy Levels.

1. Giriş

Günümüzde insansız hava araçları ve yapay zekâ uygulamaları oldukça popülerlik kazanmıştır. Sektörde oluşan pazar potansiyeli üretici firmaların da artışına sebep olmuş, çok sayıda yapay zekâ tabanlı insansız hava aracı projesi geliştirilmeye ve sahada kullanılmaya başlanmıştır.

İHA'lar genelde üç farklı alanda hizmet edecek şekilde geliştirilmektedir:

- Savunma ve güvenlikle ilgili yeni nesil İHA geliştirilme projelerinde artış gözlenmektedir.
- Tarım, nakliye, haritalama, kontrol, görüntüleme ve eğlence gibi uygulamalar için genelde küçük ebatlı uzaktan kumandalı İHA geliştiren şirketlerde belirgin bir artış gözlenmektedir. Bu tarz şirketler savunma sanayiine yönelik hızlı ve ucuz çözümler ile bu alanda da faaliyet gösterme eğilimindedirler.
- Akademik alanda ise; havacılık, uzay, robotik, kontrol sistemlerinin geliştirilmesinin yanı sıra saha uygulamalarını gerçekleştirirken farklı alanlardaki ihtiyaçlar için özel İHA sistemlerini de geliştiren akademik kurumlar mevcuttur.

Bu insansız hava sistemleri birkaç santimetreden onlarca metreye varan kanat açıklığı ve birkaç yüz gramdan tonlarca ağırlığa ulaşabilecek kadar çok çeşitlidir. Uçuş performansları yönüyle incelendiğinde; birkaç saniyeden iki haftaya kadar havada kalabilme kabiliyeti gibi çok farklı yetenekler sergilemektedirler [1].

Artık İHA'lar önemli ölçüde otomasyon içermekte ve bu özellikleri; makine öğrenmesi ile kendini geliştirebilen yapay zekâyâ sahip sistemlere doğru evirilmektedir. Farklı amaçlar için üretilmiş bu kadar çeşitli özelliklere sahip İHA'ların yapay zekâ ile otonom olarak hem de sürü halinde görev icra ederek insana karşı kullanılacak birer silah haline dönüşmesinin başlattığı tartışmalar yakın gelecekte artarak devam edecektir. Harekât alanında bu tip örnekler görüldükçe bu konu gündemin merkezinde yer alacaktır.

Hâlihazırda tam otonomi yetkisine sahip olmayan buna benzer sistemlerin insanlarla takım halinde görev yapmaları konseptine dayalı ürünlerin test uçuşları başlamıştır [2] [3] [4]. Bu durum göz önüne alındığında insan ve yapay zekâ arasındaki işgücü ve yetki paylaşımına olanak sağlayacak otonomi seviyelerinin belirlenmesi konusu önem kazanmaktadır. Bu konuda bugüne kadar birçok çalışma yapılmış olsa da değişen ürün yelpazesi açısından söz konusu çalışmalar yetersiz kalmış veya nihayetinde bu çalışmaların yapay zekânın silah kullanma yetkisine bağlı olarak ele alındığı veya insanın gittikçe devreden çıkartılarak, tam otonomi kavramına odaklanıldığı gözlenmiştir.

Bu çalışmada, insanlı-insansız işbirliği konsepti (Manned UnManned Teaming – MUM-T) içinde tek başına insan (pilot ve/veya operatör) veya yapay zekâ tarafından yapılması zor olan görevleri işbirliği içerisinde gerçekleştirirken, farklı görevler için ihtiyaç duyulan fonksiyonların insanlı ve insansız uçaklar tarafından hangi yetki seviyelerinde kimler tarafından yapılacağıın tespit edilmesi ve bu yetkilendirmelerin standart hale getirilmesi için manuel kullanımdan tam otonomiye kadar gerekli otonomi seviyelerinin belirlenmesi amaçlanmıştır. Bu maksatla, operatif seviyede yapılacağı öngörülen hedefleme, keşif/gözetleme ve istihbarat görevleri uzman görüşüyle incelenerek her biri için altışar seviyeli otonomi çizelgeleri özgün olarak tasarlanmıştır.

2. Hedef, Hedefleme Faaliyetleri ve İstihbarat Keşif Sistemleri

İHA sistemleri için sistemin/birimin amacını ortaya koymak için kullanılan hedef terimi ile askeri kullanımı farklıdır.

Örneğin; olaylara otonom olarak tepki verebilme, tehditleri takip edebilme, çevreyi tanıyabilme ve çevre hakkında muhakeme yapabilme yeteneği (geniş alan gözetleme) otonom hava araçları için hedef olarak tanımlanmaktadır [5] [6].

Ancak askeri bakış açısı ile hakkında her türlü bilginin toplanarak istihbarat elde edilmesine ihtiyaç duyulan ve etki altına alındığında harekâtın gidişatına yönelik bir değişiklik, fayda sağlayacak tesis, kurum, karargâh, silah, sistem, araç, gereç, kişiler vb. unsurlar hedef olarak ele alınmaktadır.

Hedefleme faaliyetleri ise genel olarak; silahlı kuvvetlerde üst seviye planlamalarla oluşturulan hedef listelerinin istihbarat toplama ve değerlendirme çevrimi ile güncellendiği, barış zamanında başlayan sürekli bir faaliyettir. Hedefler belirlendikten sonra haklarında bilgi toplama, en doğru zamanda ve en uygun şekilde etki altına alınabilmeleri için taktik planlama safhalarını içeren çok kapsamlı müşterek bir çalışma gerçekleştirilir ve hedeflerin durumlarında bir değişiklik olup olmadığı sürekli kontrol edilir.

Daha henüz hedef statüsüne girmemiş bölge veya unsurlara yönelik istihbarat gözetleme ve keşif sistemleri kullanılarak bilgi toplamak, korunmasına ihtiyaç duyulan bölgelere yönelik gözetleme yaparak gelebilecek tehditleri önceden algulamak veya hakkında istihbarat elde edilen veya şüphelenilen unsurlara yönelik bilgi elde etmek amacıyla icra edilen görevlerin yanı sıra tanımlanmış hedeflere yönelik de çeşitli amaçlarla keşif ve gözetleme faaliyetleri gerçekleştirilmektedir.

Taşındıkları faydalı yükler ve kabiliyetleri nedeniyle; barış zamanı genelde istihbarat, keşif ve gözetleme görevleri icra eden İHA sistemleri, kriz ve savaş zamanlarında hedefleri etkisiz hale getirmek veya imha etmek amacıyla görevlendirilmektedirler. Askeri amaçlı kullanılan hemen tüm İHA sistemlerinde; hedef tespit ve takibi yeteneği görevin başarılması için en büyük rolü oynamaktadır. Genel olarak, sınıflandırma, tanıma ve diğer görevleri tamamlamak için insan gözünün yerini almak üzere hedef bilgilerini analiz etmek için farklı kameralar ve görsel algoritmalar kullanılmaktadır [7].

3. Otonomi ve Otomasyon

Günümüzdeki uygulamalar hem askeri hem de sivil alanlarda insansız sistemlerin faydalarını kanıtlamış olsa da bu sistemlerden sağlanabilecek maksimum fayda ancak otonom olarak görev icra edebildiklerinde ortaya çıkacaktır [8].

Otonomi ve otomasyon terimleri birbirinin yerine kullanılsa da gerçekte ikisi tamamen farklı şeylerdir. Otomasyon uzunca bir süredir var olan bir kavramdır ve bir makinenin bir işi, çalışma süresi boyunca insan faktörüne bağlı olmadan gerçekleştirmesine karşılık gelir. Yani programlanmış eylemlerden oluşur. Örneğin, ticari bir yolcu uçağındaki otopilotun belirlenen rotada uçmayı sürdürmesi bir otomasyondur. Ancak bu durumda gerçek pilotun diğer çeşitli koşulları izlemek için kokpit içindeki yerinde hazır bulunması gerekmektedir. Klasik otopilot sistemlerinin yaklaşan nesnelere veya fırtınaları tespit etmesi ve gelişen bu durumlara göre güvenli, uygun yeni bir rota belirlemeleri mümkün değildir. Ama yeni nesil İHA sistemleri insan müdahalesi olmaksızın

bağımsız düşünebilecek ve hareket edebilecek şekilde otonom olmak durumundadırlar [9]. Otonomi başka bir kişi ya da kurumdan bağımsız karar verme, kendi kendini yönetebilme yetisine denir. Otomasyon terimi çalışma süreci için kullanılmakta, otonomi terimi ise yetkinlik seviyesini göstermektedir.

Sektörde günümüze kadar tanımlanmış tüm otonomi seviyesi belirleme çalışmalarında insan müdahalesi, artan her bir seviyede kademeli olarak azalmakta ve yerine otonom sistemler geçmektedir.

4. Havada Otonomi

İnsanlı ya da insansız tüm hava araçlarında otonomi seviyeleri, uçuş emniyeti, uçuşa elverişlilik ve sertifikasyon gibi kurallar da dikkate alınarak ayrıca ele alınmalıdır. Bir insansız hava aracına yön veren yapay zekâ;

- Kendi sensörlerinin ve sistem sağlık durumunun farkında olmalı, statüsünün elverdiği ölçüde bir görevi başlatmaya veya tamamlamaya karar verebilmeli,
- İnsan yardımı olmadan çevresini algılamalı ve tepki verebilmeli,
- Görevde sürekliliği sağlamalı, görevi başarıyla yerine getirebilmeli,
- Kaynak yönetimi, optimum enerji kullanımı, arıza ve yedek parça takibi gibi konuları izleyerek yönetebilmeli,
- Aynı harekât ortamını paylaşan diğer otonom İHA'larla ortak bir görevi başarmak için aralarında koordinasyon ve hatta çok sayıda otonom İHA ile sürü oluşturabilmeli,
- Aksi belirtilmedikçe kendisini ve sürü elemanlarını zararlı durumlardan uzak tutmalı,
- Ancak öncelikle dost kuvvetleri ve sivil halkı güvende tutarak onların güvenliği için kendini feda edebilmeli,
- Tüm bunların yanı sıra; görevden göreve değişen insanlı ekiplerle birlikte ortak görev icra ederek, görev paylaşımı ile kendi üzerine düşen işleri başarıyla yapabilmeli,
- Ve en önemlisi komutası altında çalıştığı görev liderine biat ederek, verilen talimatları en uygun şekilde yerine getirmelidir [9].

5. Otonomi Seviyeleri

Birçok kurum tarafından değişik amaçlar ve farklı sistemlere yönelik olarak otonomi seviyelerinin belirlenmesine çalışılmıştır. Literatürde bu konuyla ilgili rastlanan belli başlı çalışmalara aşağıda değinilmektedir.

1992 yılında Sheridan tarafından bu konudaki ihtiyacın öngörülerek tanımlandığı 10 maddelik otonomi seviyeleri yaklaşımı Tablo-1'de gösterilmiştir [10].

ABD Hava Kuvvetleri Araştırma Laboratuvarı tarafından gerçekleştirilen 2002 tarihli çalışmada otonomi kontrol seviyeleri başlığı altında (Autonomous Control Levels-ACL) 11 seviye tanımlanmıştır [11]. 2003 tarihinde NASA tarafından tanımlanan 8 katmanlı otonomi seviyeleri (Tablo-2) ise gözle, analiz et, karar ver ve harekete geç (OODA-observ, orient, decide and act) yaklaşımı üzerine kurgulanarak ele alınmış olup üst çerçeveden görevin fonksiyonlarına yönelik otonomi seviyelerini belirlemesi açısından dikkat çekici bulunmuştur [12].

Tablo-1: Sheridan'ın otonomi seviyeleri (orijinal dilde) [10]

1	The computer offers no assistance, the human must do it all.
2	The computer offers a complete set of action alternatives, and
3	narrows the selection down to a few, or
4	suggests one, and
5	executes that suggestion if the human approves, or
6	allows the human a restricted time to veto before automatic execution, or
7	executes automatically, then necessarily informs the human, or
8	informs him after execution only if he asks, or
9	informs him after execution if it, the computer, decides to.
10	The computer decides everything and acts autonomously, ignoring the human.

İnsansız sistemler için otonomi seviyelerini tanımlamak ve otonomi seviyelerini ölçebilecek bazı metrikler ortaya koymak için 2004 yılında kurulan ALFUS (Autonomy Levels for Unmanned Systems) isimli "İnsansız Sistemler için Otonomi Seviyeleri" çalışma grubunun hazırlanmış olduğu dokümanda otonomi seviyeleri; otonom iş birliği, yarı otonomi ve tam otonomi olarak 3 seviye ile sınırlı tutulmaktadır. Buna rağmen görevde kullanılan bazı fonksiyonlar için ilgili fonksiyona yönelik 5 ayrı seviye belirlenmiştir [13]. NATO Endüstriyel Danışma Grubu tarafından 4 seviyeli bir otonomi skalası 2004 yılında yayımlanmıştır (Tablo-3) [14]. Aynı tablo daha sonra 2016 yılında NATO Bilim ve Teknoloji Organizasyonu (Science and Technology Organization - STO) Görev Grubu tarafından gerçekleştirilen çalışma da benimsenmiş ve jenerik potansiyel otonomi seviyeleri (Non-Contextual Autonomy Potential - NCAP) olarak raporlarında yer almıştır [15].

NATO STANAG 4586 (2012) dokümanında bu kez birlikte çalışabilirlik (interoperability) konusu 5 seviyede incelenmiştir. Bu dokümanda "Otonomi Seviyeleri" ismi kullanılsa da konunun ele alınış şekli çok yakındır. Tablo-4'te haberleşme konusunda belirlenen otonomi seviyeleri görülmektedir [16]. ABD Donanması Deniz Araştırma Ofisinin 2015 tarihli çalışmasında ise benzer otonomi seviyeleri 6 başlıkta incelenmiştir. (Tablo-5) [17].

Otomotiv alanındaki örneklerini duymaya başladığımız otonom araçlarla ilgili olarak otonomi seviyeleri, Otomotiv Mühendisleri Birliği (SAE) tarafından araç kullanımında insan etkisi temel alınarak derecelendirilmiştir. 2021 yılında güncel hali yayımlanan SAE sınıflandırmasına göre 6 farklı otonomi seviyesi bulunmaktadır. Buna göre; Seviye-0'da sistem insan eliyle kontrol edilirken ilerleyen seviyelerde insan etkisi giderek azalır ve Seviye-5'te araç tamamıyla otonomiye sahiptir [18].

Tablo-3: NATO Endüstriyel Danışma Grubu ve NATO STO otonomi seviyeleri (orijinal dilde) [14] [15]

Level 1	Remotely Controlled System	System reactions and behavior depend on operator input.
Level 2	Automated System	Reactions and behavior depend on fixed built-in functionality (pre-programmed).
Level 3	Autonomous non-learning system	Behavior depends upon fixed built-in functionality or upon a fixed set of rules that dictate system behavior (goal-directed reaction and behavior).
Level 4	Autonomous self-learning system	Behavior depends upon a set of rules that can be modified for continuously improving goal-directed reactions and behaviors within an overarching set of inviolate rules behaviors.

Tablo-2: NASA Otonomi Seviyeleri (orijinal dilde) [12]

Level	Observe	Orient	Decide	Act
1	Human is the only source for gathering and monitoring (defined as filtering, prioritizing and understanding) all data.	Human is responsible for analyzing all data, making predictions, and interpretation of the data.	The computer does not assist in or perform ranking tasks. Human must do it all.	Human alone can execute decision.
2	Human is the prime source for gathering and monitoring all data, with computer shadow for emergencies.	Human is the prime source of analysis and predictions, with computer shadow for contingencies. The human is responsible for interpretation of the data.	The human performs all ranking tasks, but the computer can be used as a tool for assistance.	Human is the prime source of execution, with computer shadow for contingencies.
3	The computer is responsible for gathering and displaying unfiltered, unprioritized information for the human. The human still is the prime monitor for all information.	The computer is the prime source of analysis and predictions, with human shadow for contingencies. The human is responsible for interpretation of the data.	Both human and computer perform ranking tasks, the results from the human are considered prime.	The computer executes decision after human approval. Human shadows for contingencies.
4	The computer is responsible for gathering the information for the human and for displaying all information, but it highlights the non-prioritized, relevant information for the user.	The computer analyzes the data and makes predictions, though the human is responsible for interpretation of the data.	Both human and computer perform ranking tasks, the results from the computer are considered prime.	The computer allows the human a pre-programmed restricted time to veto before execution. Human shadows for contingencies.
5	The computer is responsible for gathering the information for the human, but it only displays nonprioritized, filtered information.	The computer overlays predictions with analysis and interprets the data. The human shadows the interpretation for contingencies.	The computer performs ranking tasks. All results, including "why" decisions were made, are displayed to the human.	The computer allows the human a context-dependent restricted time to veto before execution. Human shadows for contingencies.
6	The computer gathers, filters, and prioritizes information displayed to the human.	The computer overlays predictions with analysis and interprets the data. The human is shown all results.	The computer performs ranking tasks and displays a reduced set of ranked options while displaying "why" decisions were made to the human.	The computer executes automatically, informs the human, and allows for override ability after execution. Human is shadow for contingencies.
7	The computer gathers, filters, and prioritizes data without displaying any information to the human. Though, a "program functioning" flag is displayed.	The computer analyzes, predicts, interprets, and integrates data into a result which is only displayed to the human if result fits programmed context (context dependent summaries).	The computer performs ranking tasks. The computer performs final ranking and displays a reduced set of ranked options without displaying "why" decisions were made to the human.	The computer executes automatically and only informs the human if required by context. It allows for override ability after execution. Human is shadow for contingencies.
8	The computer gathers, filters, and prioritizes data without displaying any information to the human.	The computer predicts, interprets, and integrates data into a result which is not displayed to the human.	The computer performs ranking tasks. The computer performs final ranking, but does not display results to the human.	The computer executes automatically and does not allow any human interaction.

Tablo-4: NATO, STANAG 4586'da haberleşme konusunda belirtilen otonomi seviyeleri (orijinal dilde) [16]

Level 1	Indirect receipt and/or transmission of sensor product and associated metadata, for example KLV Metadata Elements as per Attachment 2-5, from the UAV.
Level 2	Direct receipt of sensor product data and associated metadata from the UAV.
Level 3	Control and monitoring of the AUV payload unless specified as control (C) only or monitor (M) only.
Level 4	Control and monitoring of the UAV, unless specified as control (C) only or monitor (M) only, less launch and recovery.
Level 5	Control and monitoring of the UAV launch and recovery unless specified as control (C) only or monitor (M) only.

Otonom araçların trafik kazasına karışması durumunda ortaya çıkacak hukuki ve cezai sorumluluğun belirlenmesi

amacıyla gerçekleştirilen bu seviyelendirme bakış açısı, askeri otonom hava araçlarında da benzer şekilde ele alınabilir.

Hava araçları, bünyesinde barındırdığı çok sayıda sistem için çeşitli otonomi seviyelerine ihtiyaç duymaktadır. Otonom uçuşun olmazsa olmaz kabiliyetlerinden olan çevre tanıma, algılama ve engellerden kaçınma algoritmaları için ayrılan kaynaklar ile istihbarat ve keşif faaliyetini gerçekleştirmek için ihtiyaç duyulan kaynakların farklı şekilde yönetilmesine ihtiyaç duyulabilir. Bu durumda kullanıcının görev esnasında ihtiyaca yönelik farklı otonomi seviyelerinde fonksiyonları bir arada kullanabilmesi gerekecektir.

Örnek: Uçuş Fonksiyonu ile Sensör Yönetimi ve Engellerden Kaçınma Fonksiyonu için otonomi seviyeleri "Seviye-5" olarak belirlenerek Zamana Duyarlı Hedefleme (time sensitive targetting – TST) harekâtında görev icra eden sürü İHA'ların, aynı görev için Görüntü Analizi Fonksiyonu'nu Seviye-3 ile sınırlandırılabilme kabiliyetinin bulunmasına ihtiyaç duyulması.

Tablo-5: ABD Donanması Deniz Araştırma Ofisinin otonomi seviyeleri (orijinal dilde) [17]

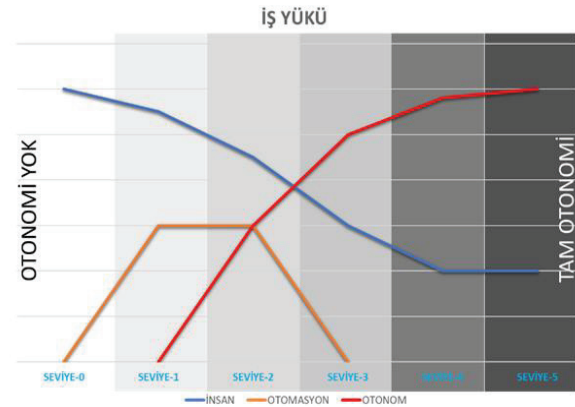
Level	Name	Description
1	Human operated	All the activity in the system is a direct result of human-initiated environment, although it may have information only responses to sensed data.
2	Human assisted	The system can perform activity in parallel with human input, acting to augment the human's ability to perform the desired activity, but has no ability to act without accompanying human input. An example is automobile automatic transmission and anti-skid brakes.
3	Human delegated	The system can perform limited control activity on a delegated basis. The level encompasses automatic flight controls, engine controls, and other low-level automation that must be activated or deactivated by a human input and act in mutual exclusion with human operation.
4	Human supervised	The system can perform a wide variety of activities given top-level permissions or direction by a human. The system provides sufficient insight into its internal operations and behaviors that it can be easily understood by its human supervisor and appropriately redirected. The system does not have the capability to self-initiate behaviors that are not within the scope of its current directed tasks.
5	Mixed initiative	Both the human and the system can initiate behaviors based on sensed data. The system can coordinate its behavior both explicitly and implicitly. The human can understand the behaviors of the system in the same way that he or she understands his or her own behaviors. A variety of means are provided to regulate the authority of the system with respect to human operators.
6	Fully autonomous	The system requires no human intervention to perform any of its designed activities across all planned ranges of environmental conditions.

Örnekle benzerlik gösterecek çok sayıda durumun oluşması olasılık dâhilindedir. Bu gibi durumlardaki iş paylaşımını başarılı bir şekilde yönetebilmek, ayrıca yapay zekânın eğitilmesi esnasında insan davranışlarını iş başında izleyebilmesini sağlamak, aynı zamanda ihtiyaç olursa yapay zekâdan da karar desteği alabilme imkânı bulabilmek için göreve yönelik ilgili bazı fonksiyonların otonomi seviyelerinin farklı şekilde ele alınmasına ihtiyaç vardır.

Platform üzerinde bulunan değişik özelliklerdeki sensörlerden toplanan verilerin, görev öncesi ilgi alanına yönelik kütüphaneye eklenen istihbarat bilgileri ile füzyon edilerek yapay zekâ tarafından analiz edilmesi sayesinde insan görüntü analizcisine destek vermesi ile başlayan süreç, yapay zekânın öğrenme kabiliyetinin artması ile otomatikleşmeye devam etmektedir. Artık otonom olarak tehditleri belirleme ve hedefleri arayarak tespit etme, hareketli hedefleri takip edebilme, hedeflerin çevresindeki dost unsurlarla olan mesafe

ve etkileşimlerinin analizi ile yan hasar tahmini, hedefin yapısız analizinin yapılması ile taarruz sonrası hasar değerlendirmelerinin yapılabilmesi gibi kabiliyetlere sahip olacak çalışmalar yürütülmektedir.

Gözetleme, analiz ve karar verme gibi çeşitli görevler için çok kullanışlı olan çoklu hedef tanıma işlemi otonom olarak gerçekleştirebilmek, akıllı sistemlerde önemli bir problemidir. Bilgisayarla görme alanında çoklu hedefleri sınıflandırma işlemi yapabilmek için derin eşzamanlı sinir ağları gibi makine öğrenimi algoritmaları geliştirilmiştir. Ancak, bu son teknoloji ürünü algoritmalar çok miktarda yüksek kaliteli etiketli veriye ihtiyaç duymaktadır. Bu durum; makine öğrenme sürecinin gerçek dünya görevlerinde (örneğin, yakın hava desteği görevinde; dost unsurları pusuya düşüren teröristlerin etkisiz hale getirilmesi esnasında) icra edilmesi kararı pratikte (özellikle başlangıçta) pek mümkün olmayacaktır. Gerçek dünyada kendi başına bir görevi icra ederken; eğitim esnasında öğretilen örneklerden farklı, dinamik ve karmaşık bir hareket alanında, hedefler veya İHA yüksek hızda olduğunda, hedeflere kamuflaj uygulandığında eğitilmiş sınıflandırıcı fonksiyonu tüm hedefleri tanımakta zorlanabilecektir.



Şekil-1: Otonomi seviyeleri ve iş yükü ilişkisi

İnsanlı-insansız sistemlerin iş birliği, tek başına insan veya yapay zekâ tarafından yapılması çok zor olan böyle görevleri çözmek için en uygun yoldur. Örneğin; engellerin İHA tarafından tespit edildiği, engelin veya tehdidin teşhis edilmesi görevini insan operatörün yaptığı, bununla birlikte rota değişikliği görevinin İHA'ya atıldığı karmaşık ve kalabalık bir hava sahasında görev icra edilebilir. Ayrıca çok hedefli gözetleme görevi esnasında bulunan hedeflerin sınıflandırılarak pozitif tanımlanmasının yapılması (positive identification - PID) işi nesne odaklı bir görev modeli kullanılarak İHA tarafından gerçekleştirilebilir ve onay için operatöre gönderilebilir.

Ortak durum farkındalığı göz önünde bulundurularak, insanlı-insansız ekip çalışması için otomotiv sektöründe olduğu gibi altı otonomi seviyesi önerilmiştir. İlk seviyede herhangi bir otonomi kabiliyeti mevcut değilken, ilerleyen seviyelerde önce otomasyon sonra otonomiye dönüşecek şekilde makine öğrenmesinin arttığı bir seviyelendirme söz konusudur.

Şekil-1'de görülebileceği gibi otonomi seviyesinin artmasıyla insan iş gücü azalacak ancak savunma sektörünün doğası gereği tamamen ortadan kalkmayacaktır. Otonom sistemleri izleme, görevlendirme, bazı kararları onaylama gibi görev lideri olarak yönetici fonksiyonu ile sorumluluk her zaman insanda olacaktır.

6. Görev Fonksiyonları ve Önerilen Otonomi Seviyeleri

Liderliğini insanın yaptığı bir görev paketinde kol uçucusu olarak, yalnız veya sürü halinde otonom uçuş gerçekleştirebilecek kabiliyete sahip, çeşitli faydalı yükler taşıyabilen, silahlı İHA sisteminin otonomi seviyelerinin belirlenmesinde ihtiyaç duyulan 11 adet fonksiyon ve tavsiye edilen otonomi seviyeleri aşağıda detaylandırılmıştır.

Konunun daha iyi anlaşılabilmesi için öncelikle birkaç tanımdan bahsetmek faydalı olacaktır. Klasik İHA sistemlerinde uçağın havadaki faaliyetleri yerden kontrol edilmektedir. Bunun için oluşturulmuş ekip tüm operasyonu icra etmekten sorumludur ve bir görev komutanı, İHA pilotu/operatörü, faydalı yük operatörü ve muhabere (haberleşme) teknikerinden oluşur.

Otonom sürü İHA sistemleri ile savaş uçaklarının birlikte insanlı-insansız iş birliği içerisinde görev icra edileceği durumda bu ekipte bazı değişiklikler olacaktır.

Görev Komutanı: Tüm görevi ve o esnada harekât alanında icra edilen diğer görevleri de yerden veya havadaki bir komuta merkezinden takip ederek, yöneten üst seviye komutandır.

Görev Lideri: Kendisiyle aynı görev paketindeki otonom İHA'ları yöneten muharip jet uçağındaki pilottur.

İHA Ekibi: Otonom İHA'nın alt sistemlerine otonomi seviyeleri ile belirlenen limitlerde müdahale ederek onu İHA sisteminin yapay zekâsıyla birlikte kontrol eden ekiptir. İHA sisteminin faydalı yük konfigürasyonuna göre ihtiyaç halinde ilgili sistemin uzmanlık alanına yönelik klasik ekiplerden farklı ilave personel görevlendirilebilir.

İHA Pilotu/Operatörü: İHA sistemini görev planlama safhası, kalkış, uçuş ve iniş işlemlerini icra eden kişi olup, otonom İHA'larda bu işlemleri kimin yapacağı otonomi seviyelerine göre belirlenir. Yerde veya havadaki bir komuta kontrol uçağından bu görevi icra eder.

Faydalı Yük Operatörü: Klasik İHA sistemlerinde faydalı yük genelde sadece optik kameralardan oluşmaktaydı. Faydalı yük operatörü bu kameraların hedefi takip etmesini sağlamak ve görüntü analizlerini görev esnasında gerçekleştiren personeldir. Bu görev otonom sistemlerde ise otonomi seviyelerinde belirlendiği şekliyle yapay zekâ ile iş birliği içerisinde gerçekleştirilecektir. Faydalı yük operatörü branşı gereği tüm kaynaklardan toplanan verileri analiz edebilecek bilgi ve tecrübeye sahiptir. Yapay zekâ desteği ile veri füzyonu için gerekli tüm sensörlerin de yöneticisi olarak çalışır, radar ve elektronik harp operatörlerinin işlerine de yön verir.

Muhabere (Haberleşme) Tekniki: İHA ekibinin harekât alanındaki tüm unsurlarla koordinasyonu, İHA sisteminin İHA ekibi ile bilgi alışverişini yöneten, muhabere sistemlerinin optimum seviyede çalışmasını sağlayan personeldir. Otonom sistemlerde bu faaliyeti otonomi seviyeleri kapsamında yapay zekâdan destek alarak gerçekleştirir.

Radar Kontrolörü: İHA sisteminde bulunan radar faydalı yükü ile ilgili işleri bu fonksiyon ile ilgili otonomi seviyeleri kapsamında yerine getirir.

Elektronik Harp Operatörü: Elektronik tedbir ve elektronik taarruz fonksiyonlarını yönetir, sistemde ilgili görevde aldatıcı/tuzak sistem (decoy system) yükü kullanılacak ise uçuş öncesi gerekli planlamayı yapar, görev esnasındaki uygulamasını gerçekleştirir. Elektronik istihbarat ve karıştırma için gerekli olan analizleri yapar ve ilgili elektronik harp sistemlerin kullanılması faaliyetlerini yapay zekâ ile iş birliği içerisinde otonomi seviyelerine göre yürütür.

Sessizlik Süreci: Sessizlik süreci ifadesi otonomi seviyeleri açıklanırken, yüksek otonomi seviyelerinde özellikle hedeflere etki etme ve silah kullanma konuları için kullanılmıştır.

Havacılığın en önemli özelliklerinden bir tanesi olan planlama faaliyeti görevde uygulanacak tüm işlerin önceden, yerdeyken planlanması anlamına gelmektedir. Yapay zekânın devreye girmesinin muhtemelen bu planlama sürecinde olumlu bir etkisi olacaktır. Ancak yine de henüz yerdeyken görevin tüm detaylarına kadar planlanması büyük önem arz edecektir.

Görev öncesi temin edilen istihbarat ölçüsünde görev esnasında karşılaşılabilecek tüm şartlar önceden hesaplanır ve olasılıklar dahilinde tüm taktikler planlanarak görevdeki hareket tarzları önceden kararlaştırılmaktadır. Bu safhanın doğru ve özenle yerine getirilmesi yapay zekâ tarafından verilen kararların görev lideri tarafından değiştirilme ihtiyacını azaltacaktır. Sessizlik süreci olarak adlandırdığımız bu kavramın işleri kolaylaştıracağı ve görevin karmaşıklığı içinde yapay zekâ davranışlarının her seferinde kompleks talimatlar ile güncelleme işlemini basite indirmek amaçlanmaktadır.

Sessizlik süreci; yapay zekâ en üst seviyede otonomi ile yetkilendirilse bile silah kullanım (elektronik karıştırma da bir tür silah kullanma usulüdür) durumlarında görev lideri tarafından takip edilecek ve davranışları kolayca onaylanabilecek veya ret edilebilecektir.

Aksi belirtilmedikçe sessizlik süreci haberleşme sorunlarının olduğu durumlarda geçerli değildir. Bu durum haberleşme sorunları giderilip görev liderinden güncel talimatları alınana kadar görevin iptali anlamına gelecektir.

6.1. Karar Verme/Kaynak Yönetimi

Doğası gereği sistemlerin sistemi olan, sürü olma durumunda takımların takımı olarak nitelendirilebilecek İHA'ları sevk idare etme konusunda eğitilmiş bir yapay zekâ ajanının, görevi esnasında karşılaştığı (sürünün tamamını veya her bir elemanı yahut bir tanesine ait alt sistemlerinden birini veya birkaçını ilgilendiren) bir olay karşısında karar verirken, etkilenecek diğer sistemler/unsurları, çevresel koşulları, zaman faktörünü, seçenekler, kısıtlar ve kararın sonuçlarını, topladığı verilerle birlikte hızlıca değerlendirecektir. İlk otonomi seviyelerinde sadece bilimsel karar desteği olacak şekilde, ancak artan otonomi seviyelerinde makine öğrenmesi ile birlikte yapay zekâyâ özgü deneysel veya sezgisel karar verme usullerini kullanması ve bir sonucu varması faaliyetidir. Kendisinin veya sürünün beka analizlerini, dolayısı ile hasardan kaçınma ve hasara dayanma değerlendirmelerini, öldürücülük ve etki analizlerini otonomi seviyelerinin elverdiği limitler dâhilinde gerçekleştirerek sonuçları karar verebilmesi için İHA ekibine ve görev liderine sunar veya kendi kararlarında kullanır.

Aynı zamanda görevin her safhasında optimum kaynak kullanımını hesaplamaları da bu fonksiyonun altında ele alınmıştır. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-6'da açıklanmaktadır.

Tablo-6: Karar Verme/Kaynak Yönetimi Fonksiyonu için önerilen otonomi seviyeleri

Karar Verme/Kaynak Yönetimi Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Yapay zekâ tüm seviyelerde yürürlükte olan angajman kurallarını algılayacak seviyededir, tüm fonksiyonlara yönelik kararlarını bu doğrultuda verir. Karar sorumluluğu görev komutanı ve İHA ekibindedir. Tüm süreç manuel olarak yönetilir.

Seviye-1	<ul style="list-style-type: none"> Yapay zekâ önceden kendi sorumluluğuna bırakılan bazı temel riskleri algılar ve bildirir. Bu risklere yönelik çözüm önerir. İHA ekibi görev için ihtiyaç olacak tüm karar sürecini kendisi yönetir.
Seviye-2	<ul style="list-style-type: none"> Yapay zekâ görevin her bir safhası için ayrı ayrı riskleri tanımlar, önceliklendirir, çözüm önerileri ile birlikte İHA ekibine bildirir. Tüm karar verme işlemlerini İHA ekibi yapar.
Seviye-3	<ul style="list-style-type: none"> Yapay zekâ görevin bütün safhalarını kapsayacak şekilde birbirlerine olan etkilerini de hesaplayarak riskleri tanımlar, önceliklendirir, çözüm önerileri ile birlikte İHA ekibine bildirir. İHA ekibi istediği konularda karar yetkisini yapay zekâya bırakabilir, kendisi önerilen çözümler arasından birini seçebilir veya çözüm önerilerini değiştirerek istediği kararı alır.
Seviye-4	<ul style="list-style-type: none"> Yapay zekâ görevin bütün safhalarını kapsayacak şekilde birbirlerine olan etkilerini de hesaplayarak riskleri tanımlar, önceliklendirir, çözüm önerileri ile birlikte İHA ekibine bildirir. İHA ekibi belli bir süre yanıt vermezse yapay zekâ en güvenli çözümü seçerek faaliyeti yürütür. İHA ekibi gerekirse görevin her safhasında devreye girerek kararları değiştirebilir.
Seviye-5	<ul style="list-style-type: none"> Görevin bütün safhalarında ortaya çıkması muhtemel tüm (öngörülemeyen durumlar da dâhil olmak üzere) durumlarda yapay zekâ tarafından karar verme fonksiyonu yerine getirilir. Yetkili İHA ekibi veya görev lideri hala izleme pozisyonundadır, görevin her safhasında devreye girebilir ancak uçuş güvenliği için bu gerekli değildir. Tam yetkili karar verme fonksiyonu, diğer alt sistemler ile ilgili yetki seviyelerinin limitlerini ortadan kaldırmaz. Örnek: Karar verme otonomi seviyesi 5; fakat silahların yönetimi fonksiyonu için belirlenen otonomi seviyesi 5'den düşükse silah kullanım yetkisi bu alandaki ilgili otonomi seviyesine göre belirlenir.

6.2. Uçuş

Görev planlama, kalkış, uçuş, iniş ve görev esnasında veya sonunda raporlama faaliyetlerini kapsar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-7'de açıklanmaktadır.

Tablo-7: Uçuş Fonksiyonu için önerilen otonomi seviyeleri

Uçuş Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> İHA pilotu tüm uçuş sürecini kendisi uygular.
Seviye-1	<ul style="list-style-type: none"> İHA pilotu tüm uçuş sürecini kendisi uygular. Sistemin sensörlerinin aldığı uyarılar İHA pilotuna aktarılır.
Seviye-2	<ul style="list-style-type: none"> İHA pilotu tüm uçuş sürecini fiili olarak yönetir. Yapay zekâ talimatlara uygun olarak uçuşun bazı safhalarını kendisi gerçekleştirerek, İHA pilotuna yardımcı olur.
Seviye-3	<ul style="list-style-type: none"> İHA pilotu teker kesene kadar süreci manuel yönetir. Bu seviyeye gelene kadar sistemlerin sağlık durumu kontrol edilerek sırasıyla ilgili sistemler yapay zekâya devredilir ve otonom kalkış için gerekli hazırlıklar tamamlanmış olur. Uçuş esnasında tek bir sistem veya sürünün birlikte uçuş fonksiyonu yapay zekâ tarafından gerçekleştirilir.

	<ul style="list-style-type: none"> Önceden belirlenmiş görevin bazı safhaları İHA pilotu tarafından manuel olarak icra edilebilir.
Seviye-4	<ul style="list-style-type: none"> İHA pilotu pist başına kadar süreci manuel yönetir. Bu seviyeye gelene kadar sistemlerin sağlık durumu kontrol edilerek sırasıyla ilgili sistemler yapay zekâya devredilir ve otonom kalkış için gerekli hazırlıklar tamamlanmış olur. Uçuş esnasında tek bir sistem veya sürünün birlikte uçuş fonksiyonu yapay zekâ tarafından gerçekleştirilir.
Seviye-5	<ul style="list-style-type: none"> Yapay zekâ tüm uçuş sürecini otonom olarak icra eder. Görev liderinden aldığı talimatlar doğrultusunda görevi gerektirdiği tüm işleri kendisi yapabilir. Görev lideri veya İHA pilotu uçuş emniyeti öncelikli olmak kaydıyla, koordine içerisinde gerektiğinde kontrolü kısmen veya tam olarak ele alabilir.

6.3. Sensör Yönetimi ve Engellerden Kaçınma

Çevre tanıma, seyrüsefer, çevresel tehditleri algılama ve engellerden kaçınma amacıyla uygun sensörlerin kullanılması, sürü halinde ise; merkezi veya dağıtık olarak sensör paylaşımı ve veri füzyonu kullanılarak gerçekleştirilen faaliyetlerdir. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-8'de açıklanmaktadır.

Tablo-8: Sensör Yönetimi ve Engellerden Kaçınma Fonksiyonu için önerilen otonomi seviyeleri

Sensör Yönetimi ve Engellerden Kaçınma Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Tüm sensörler İHA ekibi tarafından manuel olarak yönetilir ve alınan bilgiler İHA ekibi tarafından analiz edilerek uçuş için uygun davranışı gerçekleştirir.
Seviye-1	<ul style="list-style-type: none"> Sensörlerin yönetimi İHA ekibinin talimatları doğrultusunda yapay zekâ tarafından gerçekleştirilir. Alınan bilgilerin analiz sonuçları yapay zekâ tarafından İHA ekibine bildirilerek uçuş fonksiyonu ile paralel engellerden kaçınma işlemleri İHA pilotu tarafından gerçekleştirilir.
Seviye-2	<ul style="list-style-type: none"> Sensörlerin yönetimi ve alınan bilgilerin analizleri yapay zekâ tarafından gerçekleştirilir ve uçuş emniyeti öncelikli olacak şekilde engellerden kaçınma tavsiyeleri İHA ekibine bildirilir. İHA pilotu ve faydalı yük operatörü koordineli olarak tüm süreci yönetir. Yapay zekâ işleri talimatlara göre uygular. Sürünün diğer elemanlarındaki sensör verileri de analize dâhil edilir.
Seviye-3	<ul style="list-style-type: none"> Yapay zekâ işleri talimatlara göre uygulamaya devam eder. Sensör yönetimi ve engellerden kaçınma kararlarını İHA ekibine bildirerek bir süre talimat bekler. Sessizlik süreci bittiğinde bildirdiği aksiyonu uygulamaya geçer.
Seviye-4	<ul style="list-style-type: none"> Yapay zekâ uçuş fonksiyonunun kontrolü kendisinde olmasa dahi uçuş emniyeti öncelikli olacak şekilde gerekli manevraları otonom olarak uçağa yaptırır. Sürü uçuşuna uygun sensör yönetimi ve toplanan bilgilerin analizi yapay zekâ tarafından gerçekleştirilir.

	<ul style="list-style-type: none"> İHA pilotu ve faydalı yük operatörü talimat vererek süreci yönetir. Sürü sensör kaynak yönetim kararları yapay zekâ tarafından İHA ekibine ekstra iş yükü getirilmeden yerine getirilir.
Seviye-5	<ul style="list-style-type: none"> Solo ve sürü uçuşu için gerekli tüm algılama ve kaçınma işleri otonom olarak gerçekleştirilir.

6.4. Radar Faydalı Yükü

Üzerinde radar faydalı yükü bulunduran otonom İHA'nın radarının kullanımı ve radar sayesinde temin edilen bilgiler ile gerçekleştirilen faaliyetlerdir. Özellikle gelişmiş muharip uçak radar sistemleri pilota kolaylık sağlamak amacıyla bünyesinde hâlihazırda otomasyon özelliklerini barındırmaktadır. Bu fonksiyon otomasyon ile yerine getirilen işlerin haricindeki belli bazı kritik görevlere değinilerek seviyelendirilmiştir. Radar fonksiyonu için önerilen otonomi seviyeleri Tablo-9'da açıklanmaktadır.

Tablo-9: Radar Fonksiyonu için önerilen otonomi seviyeleri

Radar Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Tüm radar fonksiyonları İHA ekibi tarafından gerçekleştirilir.
Seviye-1	<ul style="list-style-type: none"> Görevin özelliğine göre radar sisteminin başlangıç ayarları otonom olarak yapay zekâ tarafından gerçekleştirilir.
Seviye-2	<ul style="list-style-type: none"> Eğer uçuş fonksiyonuna ait otonomi seviyesi özellikle düşük tutulmuş ise yapay zekâ İHA ekibine durumsal farkındalık konusunda karar desteği sağlar.
Seviye-3	<ul style="list-style-type: none"> Angajman için sürünün hangi elemanın kullanılacağı kararı kontrolöredir. Ancak yapay zekâ radarın iz kalitesine ve görev paketindeki diğer elemanların konum ve sistem sağlık durumlarını göz önüne alarak İHA ekibine tavsiye verir. Radar karartma ve sektör yoğunlaştırma kararı kontrolör sorumluluğundadır. Ancak frekans/mod seçimi otonom olarak gerçekleştirilir.
Seviye-4	<ul style="list-style-type: none"> Radar kaplaması ve iz kalitesine göre tam kapsamlı durumsal farkındalık ve tehdit analizleri otonom olarak yapılır. Hava resminin kalitesi/devamlılığı için yoğunluğu fazla olan sektörlerin frekans/mod seçimini otonom olarak yaparken, karartılacak sektörlerin kararını kontrolöre bırakır. Tehdit durumunda radar kaplamasını koruyacak şekilde uygun formasyon veya rota değişikliği kararı otonom olarak verilir.
Seviye-5	<ul style="list-style-type: none"> Yapay zekâ durumsal farkındalık ve tehdit analizleri yaparak ihtiyaç halinde kontrolündeki diğer sürü elemanlarını angajmana sevk eder, angajman maksadıyla dost SAM sistemlerine iz aktarır. Radarın belli bir sektör için karartılmasına/ odaklanmasına karar verir. Harekât alanının yoğunluğu ve meteorolojik şartlara bağlı olarak radar modu ve frekans seçimi otonom olarak yapılır. Arama/kurtarma görevlerinde radar kayıtlarına göre düşen dost unsurun tahmini yerinin işaretlenip raporlanması faaliyetlerini otonom olarak gerçekleştirir.

	<ul style="list-style-type: none"> Havada yakıt ikmal görevlerinde yakıt alacak/verecek unsurların yakın kontrolünü otonom olarak gerçekleştirir. Tehdit seviyesi yüksek ortamlarda bazı belli ön tanımlı durumlar için kendisi veya sürü elemanlarına yönelik daha güvenli olan bir bölgeye geri çekilme (retrograde) tavsiyesinde bulunur, süreli olarak görev liderinin onayını bekler. Sessizlik süreci sonrası bildirdiği bu taktiği otonom olarak uygular.
--	--

6.5. Elektronik Harp Yükü

Elektronik istihbarat ve elektronik taarruz/karıştırma kabiliyeti ile siber güvenlik, elektronik karşı tedbirlere ait yeteneklerini tanımlar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-10'da açıklanmaktadır.

Tablo-10: Elektronik Harp Fonksiyonu için önerilen otonomi seviyeleri

Elektronik Harp Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Elektronik harp faydalı yükü tüm fonksiyonları İHA ekibindeki elektronik harp operatörü tarafından yönetilir.
Seviye-1	<ul style="list-style-type: none"> Sistemin pasif antenlerinden alınan elektronik istihbarat bilgileri yapay zekâ tarafından görev kütüphanesindeki tehdit verisi ile eşleştirilerek bulunan sonuçlar EH operatörüne bildirilir. Alınan yayının süre, yön ve mesafesi otonom hesaplanarak konumu operatöre bildirilir.
Seviye-2	<ul style="list-style-type: none"> Yeri tespit edilen tehditler arasında yapay zekâ tarafından görev koluna olan uzaklıkları, hedef bölgesindeki etkisi ve oluşturduğu risk açısından bir önceliklendirme yapılarak operatöre sunulur. Yapay zekâ uygun elektronik taarruz taktiklerini önerir. Yapay zekâ kendisine yönelik bir elektronik taarruz tespit ederse elektronik karşı tedbir tavsiyelerini operatöre sunar. Diğer fonksiyonlar operatör tarafından yönetilir.
Seviye-3	<ul style="list-style-type: none"> Yapay zekâ kendisine ve sürüye yönelik elektronik taarruz tespit ettiğinde pasif tedbirleri otonom olarak yerine getirir. Elektronik karıştırma yapma kararı yapay zekânın tavsiyesi ile operatör ve görev lideri kararı ile gerçekleştirilir. Tehdit tespit edildiğinde radar ve infrared güdümlü füze aldatıcıları (chaff ve flare) veya aldatıcı/tuzak sistemlerin (decoys) kullanma kararı otonom olarak yerine getirilir.
Seviye-4	<ul style="list-style-type: none"> Yapay zekâ kendisine ve sürüye yönelik tehdit tespit ettiğinde otonom olarak elektronik taarruz ile karşılık verir. Radar ve infrared güdümlü füze aldatıcıları veya aldatıcı/tuzak sistemler gibi pasif sistemleri otonom olarak kullanabilir. Sürünün bekası için uygun elemanlarını feda edecek şekilde tehdidi bertaraf etme kararını görev liderinden süreli bekleyerek, sessizlik süreci sonunda otonom olarak yerine getirir. Kendisine veya sürüye yönelik bir tehdit olmadan planlı veya fırsat hedeflerine yönelik elektronik taarruz kararı görev liderinin yetkisindedir. Yapay zekâ taarruz taktikleri ve muhtemel sonuçlarına yönelik tavsiyede bulunur.
Seviye-5	<ul style="list-style-type: none"> Yapay zekâ hedefe yönelik en uygun elektronik taarruz taktiği ve hesapladığı muhtemel sonucu operatöre sunar.

	<ul style="list-style-type: none"> Görev liderinin talimatını süreli olarak bekler. Sessizlik süreci bittiğinde bildirdiği taarruz taktiğini uygular.
--	--

6.6. Yayın Kontrolü (EMCON)

Düşmana yerini belli etmemek, düşük görünürlük sağlamak için yapısal radar kesit alanının yanı sıra sensör ve antenler ile elektromanyetik veya optik olarak yayın yapan sistemlerin bu yayınlarının kontrolü için gerekli uygulamaları kapsar. Bir çeşit elektromanyetik kamuflaj olarak düşünülebilir. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-11'de açıklanmaktadır.

Tablo-11: Yayın Kontrolü Fonksiyonu için önerilen otonomi seviyeleri

Yayın Kontrolü Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Görev lideri ve İHA ekibi tarafından planlanarak uygulanır.
Seviye-1	<ul style="list-style-type: none"> Görev planlama safhasında otonom olarak planlanarak, görev uygulama emirlerine girmeden önce yetkili personel tarafından onaylanır. Görev esnasında görev lideri ve İHA ekibi tarafından görevin safhalarına yönelik olarak uygulanır.
Seviye-2	<ul style="list-style-type: none"> Önceden belirlenmiş yayım kontrol emirleri (EMCON-Emissions Control) gereği en uygun taktikler İHA ekibine sunulur, ilgili operatörler görevin safhalarına göre kendileri ile ilgili kararı onaylar.
Seviye-3	<ul style="list-style-type: none"> Yapay zekâ yayım kontrol tedbirleri gereği hangi antenin hangi yönde ve hangi güçte yayın yapacağına otonom olarak karar verir. Görevi en az etkileyecek şekilde tedbir alır ve hangi sistemin yayımın ne kadar süre ile kesileceğini otonom olarak uygular varsa alternatif çözümleri devreye sokar.
Seviye-4	<ul style="list-style-type: none"> Yapay zekâ en az radar kesit alanı gösterecek şekilde konumlanma tavsiyesinde bulunur. Sürünün tüm elemanlarının düşük görünürlüğünü sağlayacak en uygun uçuş formasyonunu hesaplayarak, ara yüz vasıtasıyla ve muhtemel sonucuyla birlikte süreli olarak İHA pilotunun onayına sunar, sessizlik süreci bitince otonom olarak bu kararını uygular.
Seviye-5	<ul style="list-style-type: none"> Düşük görünürlüğü sağlamak için görevin gereksinimleri de hesaplanarak optimum taktik ve uygulamalar otonom olarak gerçekleştirilir.

6.7. Haberleşme

Görev planlamanın haberleşme ile ilgili olan bölümü de dâhil olmak üzere uçuş öncesi, bireysel veya sürü haberleşmesi planının hazırlanması. Görevin icrası esnasında alınan/verilen ilgili komutların, sensörlerden toplanan bilgiler ile seyrüsefer ve sürü hareketleri için ihtiyaç duyulan anlık verinin iletilmesi, telemetri ve sistem sağlık bilgilerinin aktarılması, GNSS/INS gibi seyrüsefer bilgilerinin ve silah sistemlerinin ihtiyaç duyduğu verinin aktarılması, telsizlerin röle yolu ile birbirlerine aktarılması ve tüm bu faaliyetlerin merkezi veya dağıtık olarak sürü genelinde veya dışarıya yönelik olarak gerçekleştiren tüm haberleşme kanallarını ve bunların yönetilmesini kapsar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-12'de açıklanmaktadır.

6.8. Sürü Hareketleri Yönetimi

Farklı bölgelerden uçuşu müteakip veya kalkış sonrası havada sürü oluşturmak üzere bir araya gelen sistemlerin sürü öncesi planlamaları, sürü ile birlikte hareketleri ve sürünün ayrışması veya bireysel olarak sürüden ayrılma gibi durumların planlamaları ve yönetilmesi, sürü içerisindeki konum, birbirlerine olan mesafe takibi, hiyerarşi, formasyon kararları gibi konuları kapsar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-13'te açıklanmaktadır.

Tablo-12: Haberleşme Fonksiyonu için önerilen otonomi seviyeleri

Haberleşme Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> İHA ekibi tarafından gerçekleştirilir.
Seviye-1	<ul style="list-style-type: none"> İHA ekibi tarafından gerçekleştirilir.
Seviye-2	<ul style="list-style-type: none"> İHA ekibi veya görev lideri yönetiminde muhabere teknikleri sorumluluğunda gerçekleştirilir. Sürü haberleşmesi için merkezci sürü yönetim modeli uygulanır.
Seviye-3	<ul style="list-style-type: none"> Otonom olarak merkezci sürü yönetim modeline göre yönetilir.
Seviye-4	<ul style="list-style-type: none"> Otonom olarak dağıtık sürü yönetim modeline göre yönetilir.
Seviye-5	<ul style="list-style-type: none"> Otonom olarak yürütülür.

Tablo-13: Sürü Hareketleri Yönetimi Fonksiyonu için önerilen otonomi seviyeleri

Sürü Hareketleri Yönetimi Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Bu seviyede sürü uçuşu gerçekleştirilmez.
Seviye-1	<ul style="list-style-type: none"> Bu seviyede sürü uçuşu gerçekleştirilmez.
Seviye-2	<ul style="list-style-type: none"> Sürü içerisinde veri paylaşımı ve kaynak kullanımı sürü içerisinde ele alınarak İHA ekibinin talimatları ile uygulamaya geçilir.
Seviye-3	<ul style="list-style-type: none"> Sessizlik süreci beklenerek İHA ekibinden alınan talimatlarla, sürünün merkez elemanına uyumlu bir şekilde otonom uçuş gerçekleştirilir.
Seviye-4	<ul style="list-style-type: none"> Sessizlik süreci kullanılarak İHA ekibinden alınan talimatlarla, dağıtık sürü yönetim modeli kullanılarak otonom uçuş gerçekleştirilir.
Seviye-5	<ul style="list-style-type: none"> Görevin tüm safhalarında yapay zekânın uygun gördüğü sürü yönetim modeli kullanılarak dağıtık veya merkezci olacak şekilde otonom uçuş gerçekleştirilir.

6.9. Dost Düşman Tanıma

Dost düşman tanıma ve tespit edilen izlere teşhis verme faaliyetlerini kapsar. Bu sistem uçaklarda hâlihazırda mevcut olup aslında otomasyon özelliklerine sahiptir. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-14'te açıklanmaktadır.

Tablo-14: Dost Düşman Tanıma Fonksiyonu için önerilen otonomi seviyeleri

Dost Düşman Tanıma Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> İHA ekibi tarafından gerçekleştirilir.
Seviye-1	<ul style="list-style-type: none"> İHA ekibi tarafından gerçekleştirilir.
Seviye-2	<ul style="list-style-type: none"> Dost düşman ayırımı yapılarak görev liderine ve İHA ekibine bilgilendirme yapılır.

Seviye-3	<ul style="list-style-type: none"> Dost düşman ayırımı yapılarak, görev lideri ve diğer tüm paket elemanlarına ayrıca bağlı bulunan kontrol unsuruna otonom olarak bilgilendirme yapılır. Diğer fonksiyonların ihtiyacı olabilecek bu bilgileri veri füzyonu sayesinde diğer fonksiyonların analizlerinde kullanır.
Seviye-4	<ul style="list-style-type: none"> Otonom olarak gerçekleştirilir.
Seviye-5	<ul style="list-style-type: none"> Otonom olarak gerçekleştirilir.

6.10. Görüntü Analizi

Görüntü alınan bölgenin konumunun bulunması ve kameranın doğru hedefe bakmasının sağlanması, tehditlerin belirlenmesi, hedeflerin bulunması/tespiti, hareketli hedeflerin takip edilmesi, hedef analizini gerçekleştirme, yan hasar tahmini, etki analizleri ve taarruz sonrası hasar değerlendirme ile sahip olunan tüm istihbarat kaynakları kullanılarak gerçekleştirilecek istihbarat analiz faaliyetlerini kapsar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-15'de açıklanmaktadır.

Tablo-15: Görüntü Analizi Fonksiyonu için önerilen otonomi seviyeleri

Görüntü Analizi Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> Kamera sistemleri faydalı yük operatörü tarafından yönetilir, görüntü analizi ilgili ekip tarafından görev esnasında veya sonrasında gerçekleştirilir.
Seviye-1	<ul style="list-style-type: none"> İlk görüntü analizleri faydalı yük operatörü ve hareket merkezindeki ilgili personel tarafından uçuş esnasında gerçekleştirilir, seçilen hedef veya bölgeye kamera sistemlerinin yönlendirilmesi (hedef takibi) otonom olarak yapılır.
Seviye-2	<ul style="list-style-type: none"> Görüntülerdeki insan yapısı unsurların tespiti otonom olarak yapılır. Görüntü analizlerinin diğer faaliyetleri görev lideri, faydalı yük operatörü veya hareket merkezindeki ilgili personel tarafından yapılır.
Seviye-3	<ul style="list-style-type: none"> Görüntülenen alandaki hedeflerin tespit edilmesi otonom olarak yapılır. Görüntü analizlerinin diğer faaliyetleri görev lideri, faydalı yük operatörü veya hareket merkezindeki ilgili personel tarafından yapılır.
Seviye-4	<ul style="list-style-type: none"> Rota boyunca ve hedef bölgesindeki tehdit analizleri otonom olarak yapılır.
Seviye-5	<ul style="list-style-type: none"> Hedef analizleri, hedefin teşhisi (positive identification - PID), yan hasar tahmini (collateral damage assessment - CDE), muharebe hasar değerlendirmesi (battle damage assessment - BDA) otonom olarak gerçekleştirilir.

6.11. Silah Yönetimi

Yürürlükteki angajman kuralları gereğince; sahip olunan silah sistemlerinin belirlenen yetkiler dahilinde kullanıma hazır hale getirilmesi, kullanılması ve atıldıktan sonra hedefe gitmeleri için yerine getirilen faaliyetleri kapsar. Bu fonksiyon için önerilen otonomi seviyeleri Tablo-16'da açıklanmaktadır.

Tablo-16: Silahların Yönetimi Fonksiyonu için önerilen otonomi seviyeleri

Silahların Yönetimi Fonksiyonu	
Otonomi Seviyeleri	Açıklama
Seviye-0	<ul style="list-style-type: none"> İHA ekibi tarafından yürütülür.

Seviye-1	<ul style="list-style-type: none"> İHA ekibi tarafından yürütülür.
Seviye-2	<ul style="list-style-type: none"> Yapay zekâ hedeflere uygun mühimmatları önerir, görev liderinin onayıyla atış yapar.
Seviye-3	<ul style="list-style-type: none"> Yapay zekâ hedeflere uygun mühimmata karar verir, görev liderinin onayıyla atış yapar.
Seviye-4	<ul style="list-style-type: none"> Yapay zekâ hedeflere uygun mühimmata karar verir. Dost unsurların, sürünün ve kendisinin bekası için silah kullanılması gerektiği durumda görev liderinin talimatını süreli olarak bekler. Sessizlik süreci bittiğinde bildirdiği kararını uygular. Haberleşme sorunları yaşandığında silah kullanma görevi iptal edilir. Diğer taarruz durumlarında yani planlı hedefler ve fırsat hedefleri için görev liderinin talimatını yerine getirir.
Seviye-5	<ul style="list-style-type: none"> Yapay zekâ tam otonom seviyesindedir ancak tüm silah kullanma durumlarında yerde görev planlamasında belirtilen süre dâhilinde görev liderinin talimatını süreli olarak bekler. Sessizlik süreci bittiğinde bildirdiği kararını uygular. Haberleşme sorunları yaşandığında silah kullanma görevi iptal edilir. Silah kullanma kararları her ne sebeple olursa olsun angajman kurallarının dışına çıkamaz.

7. Sonuç ve Öneriler

İnsanlı-insansız iş birliği konseptine uygun uçar platformlar ülkemizde de ortaya çıkmaya başlamıştır [19]. Bu çalışmada, insanlı-insansız iş birliği konsepti kapsamında muharip hava platformları arasında ihtiyaç duyulan otonomi seviyeleri, bir operatif görevde yapılması öngörülen 11 adet fonksiyon özelinde incelenerek, bu konudaki araştırmacıların kullanması amacıyla özgün olarak ortaya konmuştur. Bu kapsamda;

- İnsan ile yapay zekâ iş birliği söz konusu olduğunda, yapılacak iş paylaşımının otonomi seviyeleri ile standart hale getirilmesi gerektiği,
- Görev esnasında istihbarat ve keşif sensörleri ile bir yandan hedefleme faaliyetlerine destek sağlanırken bir yandan da emniyetli uçuş için çevre algılama, engellerden kaçınma ve tehditleri algılayarak rotalama işlemleri için bilgi toplanması maksadıyla gerçekleştirilecek otonomi seviyelerinin farklı sınıflandırmaya tabi tutulmasının gerektiği,
- Otonomi seviyelerinin; sistemin sensör veya alt sistemlere göre değil, kabiliyetlerine ve fonksiyonlarına göre sınıflandırılmasının daha doğru olacağı,
- Silah kullanma otonomi seviyelerinin en yükseğinde bile insan faktörünü devreden çıkartmadan onay süreci konusunda hukuksal temelleri olan bir standardın ortaya konması, angajman kuralları kapsamına alınması ve görevlerden önce yapay zekâ silah kullanma yetkilerinin açıkça belirlenerek görev veri dosyalarına yüklenmesi gerektiği değerlendirilmiştir.

Ülkemizde insanlı-insansız iş birliği konsepti konusunda yapılacak araştırma ve geliştirme faaliyetlerinde, araştırmacıların bu çalışma kapsamında özgün olarak önerilen otonomi seviyelerini dikkate almasının ve kullanmasının, yapılan çalışmalarda standartlık sağlanması açısından önemli olduğu değerlendirilmektedir.

Sonraki çalışmada, önerilen otonomi seviyelerinin her birinin, hangi fonksiyon için hangi seviyeye kadar kullanılabileceği analiz edilecektir.

8. Kaynaklar

- [1] A.Ollero, "Introduction: Advances in Industrial Control", içinde *Aerial Manipulation*, ed. Matgo Orsag vd., Springer Cham, New York City, 2018, s. 1-18.
- [2] Boeing, "U.S. Navy, Boeing Conduct First MQ-25 Refueling Mission with F-35C", [Çevrimiçi]. Mevcut: <https://www.boeing.com/defense/mq25/>. [Erişim: Ekim, 27, 2023].
- [3] Wikipedia, "Loyal wingman", [Çevrimiçi]. Mevcut: https://en.wikipedia.org/wiki/Loyal_wingman. [Erişim: Ekim, 27, 2023].
- [4] İ.Kalınbacak, "Sürü Otonom İHA Sistemlerinin Muharebe Sahasında Uygulama Taktikleri ve Geliştirilen Yeni Teknolojiler", *Savunma Bilimleri Dergisi*, c. 1, sy. 43, s. 191-209, 2023.
- [5] X.Wu, C.Wang, Y.Niu, X.Hu ve C.Fan, "Adaptive Human-in-the-loop Multi-target Recognition Improved by Learning", *International Journal of Advanced Robotic Systems*, sy. 15, s. 1-13, 2018.
- [6] D.Ruan, W.Zhang ve D.Qian, "Feature-based autonomous target recognition and grasping of industrial robots", *Personal and Ubiquitous Computing*, sy. 27, s. 1355-1367, 2023.
- [7] M.Zhang, D.Zhao, C.Sheng, Z.Liu ve W.Cai, "Long-Strip Target Detection and Tracking with Autonomous Surface Vehicle", *J. Mar. Sci. Eng. Switzerland*, sy.11, no.106, 2023.
- [8] H.Duan ve P.Li, *Bio-inspired Computation in Unmanned Aerial Vehicles*, Springer, Berlin, Heidelberg, 2019.
- [9] Exyn Technologies, "Defining Levels of Aerial Autonomy Version 1.0", [Çevrimiçi]. Mevcut: <https://www.exyn.com/levels-of-autonomy-white-paper>. [Erişim: Ekim, 27, 2023].
- [10] T.B.Sheridan, *Telerobotics, Automation, and Human Supervisory Control*, The MIT Press, 1992.
- [11] B.T. Clough, "Metrics, Schmetrics! How The Heck Do You Determine A UAV's Autonomy Anyway?", *Performance Metrics for Intelligent Systems Workshop*, Gaithersburg, MD, 2002.
- [12] R.W.Proud, J.J.Hart ve R.B. Mrozinski, "Methods for Determining the Level of Autonomy to Design into a Human Spaceflight Vehicle: A Function Specific Approach", *Performance Metrics for Intelligent Systems*, 2003.
- [13] H.M. Huang, "Autonomy Levels for Unmanned Systems (ALFUS) Framework Volume I: Terminology", NIST Special Publication 1011, Gaithersburg, Maryland, 2004.
- [14] NATO, "Pre-Feasibility Study on UAV Autonomous Operations", NATO Industrial Advisory Group – Study Group 75, 2004.
- [15] NATO STO, "Unmanned Systems (UMS) Platform Technologies and Performances for Autonomous Operations", NATO STO Technical Report TR-AVT-175, 2016.
- [16] Standard Interfaces of UAV Control Systems (UCS) for NATO UAV interoperability, NATO Standardization Agreement (STANAG) 4586, 2012.
- [17] A.P.Williams ve P.D.Scharre, *Autonomous Systems: Issues for Defence Policymakers*, NATO Communication and Information Agency, The Hague, Netherlands, 2015.
- [18] SAE International, "SAE Levels of Driving Automation Refined for Clarity and International Audience", [Çevrimiçi]. Mevcut: <https://www.sae.org/blog/sae-j3016-update>. [Erişim: Ekim, 27, 2023].
- [19] TurDef, "TUSAŞ Prepares Turkish Loyal Wingman: OKU", [Çevrimiçi]. Mevcut: <https://www.turdef.com/article/tusas-prepares-turkish-loyal-wingman-oku-concept>. [Erişim: Ekim, 27, 2023].

Not: Bu çalışmadaki bilgiler konuyla ilgili olarak yazarların yorumunu içermekte olup, herhangi bir kuruma ait görüşleri temsil etmemektedir.

Özgeçmişler



Güray Kasapoğlu, 1973 yılında Balıkesir’de doğdu. Lisans eğitimi ni Anadolu Üniversitesi İşletme Fakültesinde yaptı. 1992-2021 yılları arasında Hv.K.K.İğında astsubay olarak görev yaptı. An itibariyle Türk Havacılık ve Uzay Sanayii A.Ş.’de uzman olarak çalışmaktadır. İstihbarat, görüntüleme ve keşif sistemleri, sinyal istihbaratı, harekât verisi, insanlı-insansız iş birliği ve harekât analizi konularında çalışmalar gerçekleştirmiştir.

Özgeçmişler



Özer Demir, 1973 yılında Ankara'da doğdu. Askeri öğrenimi sonrası 1991-2017 yıllarında Hv.K.K.lığında Hava Harekât Astsubayı olarak görev yaptı. Türk Havacılık ve Uzay Sanayii A.Ş. bünyesinde Milli Muharip Uçak Projesi için endüstride ilk defa kurulan Harekât Analizi Müdürlüğü bünyesindeki Harekât Analizi Veri Yönetimi bölümünü kurmuştur. Özel görev uçakları, askeri görev senaryoları, hava harekât alanı oyuncularını için harekât verisi ve kullanım konseptlerine yönelik uzmanlığı bulunmaktadır. NATO STO üyesi olup, halen bu alanda çalışmalar gerçekleştirmektedir.



Halil Sert, 1975 yılında Avusturya Mittelberg'de doğdu. Lisans eğitimini Anadolu Üniversitesi İktisat Fakültesinde yaptı. 1993-2023 yılları arasında Hv.K.K.lığında astsubay olarak görev yaptı. Halen Türk Havacılık ve Uzay Sanayii A.Ş.'de uzman olarak çalışmaktadır. Harekât planları, harekât verisi, harekât analizi ve NATO Standartları konularında çalışmalar gerçekleştirmiştir.



Tolga Türkmen, 1987 yılında Diyarbakır'da doğdu. Lisans eğitimini Başkent Üniversitesi İstatistik ve Bilgisayar Bilimlerinde yaptı. 2010 yılından itibaren Türk Havacılık ve Uzay Sanayii A.Ş.'de uzman olarak çalışmaktadır. Üretim planlama, proje yönetimi, harekât verisi, harekât analizi konularında çalışmalar gerçekleştirmiştir.



Haluk Gözde, 1975 yılında Mersin'de doğdu. Lisans eğitimini 1997 yılında Karadeniz Teknik Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümünde, yüksek lisans ve doktora çalışmalarını ise 2003 ve 2010 yıllarında Gazi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümünde tamamladı. 2016 yılında ÜAK'tan Doçent unvanını aldı. 2019 yılında Cardiff Üniversitesinde doktora sonrası çalışmalarda bulundu. 1998-2021 yılları arasında K.K.K.lığında mühendis subay olarak görev yaptı. Halen Türk Havacılık ve Uzay Sanayii A.Ş.'de MMU projesinde kıdemli tasarım mühendisi olarak çalışmaktadır.



Serkan Kurt, 1976 yılında Kırşehir'de doğdu. Lisans eğitimini İstanbul Üniversitesi Elektrik Elektronik Mühendisliğinde, yüksek lisansını Gebze Teknik Üniversitesi Bilgisayar Mühendisliği Bölümünde, doktora çalışmasını ise Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Bölümünde tamamladı. Yıldız Teknik Üniversitesinde öğretim üyesidir, aynı zamanda 2021 yılından itibaren Türk Havacılık ve Uzay Sanayii A.Ş.'de danışman olarak görev yapmaktadır.

Kalp Yetmezliği Tahmininin Kategorik Olarak Farklı Tip Makine Öğrenmesi Yöntemleri ile Uygulanmasına Yönelik Bir Değerlendirme Çalışması

An Evaluation Study on the Application of Heart Failure Prediction with Categorically Different Type Machine Learning Methods

İsmail ATACAK * 

* Gazi Üniversitesi, Teknoloji
Fakültesi, Bilgisayar Mühendisliği
Bölümü, 06560, Ankara, Türkiye
iatacak@gazi.edu.tr; ORCID: 0000-0002-6357-0073

Öz

Kalp yetmezliği yaşam kalitesini olumsuz etkileyen ve tedavi edilmediğinde ölümcül sonuçlar doğurabilen ciddi bir sağlık problemidir. Erken teşhis ve doğru tedavinin uygulanması bu problemleri en aza indirebilir. Bu çalışmada farklı kategorilerde yer alan makine öğrenmesi (MÖ) yöntemlerinin kalp yetmezliği tahminindeki performanslarını ölçmek için bir model geliştirilerek, kategorik ve genel olarak performans analizleri gerçekleştirilmiştir. Kategori temelinde sınıflandırma problemlerinde başarılı sonuçlar ürettiği bilinen yöntemleri içeren ağaç, meta ve fonksiyon kategorileri tercih edilmiş ve her kategoriden beş yöntem kullanılmıştır. Deneysel çalışmalarda MÖ yöntemlerinin performansı Karışıklık matrisine dayanan temel metrikler ile sınıflandırma hata metrikleri üzerinden ölçülmüştür. Deneysel sonuçlar kategorik olarak değerlendirildiğinde en iyi performansların ağaç kategorisinde Duyarlılık ve Yanlış Negatif Oranı (False Negative Rate (FNR)) dışındaki metriklerde Alternatif Karar Ağacı (Alternating Decision Tree | ADTree (ADT)) yöntemi, meta kategorisinde ROC eğrisi altında kalan alan (Area under the curve (AUC)) dışındaki metriklerde Lojistik Artırma Regresyon (Logistic Boosting Regression | LogitBoost (LBST)) yöntemi ve fonksiyon kategorisinde Kesinlik ve Yanlış Pozitif Oranı (False Positive Rate (FPR)) dışındaki metriklerde Radyal Temelli Fonksiyon Sınıflandırıcı (Radial Bases Function Classifier (RBFC)) yöntemi ile elde edildiğini göstermektedir. Sonuçlara tüm yöntemlerin performansları açısından bakıldığında Doğruluk, Duyarlılık, F-skor, FNR ve Yanlış Sınıflandırma Oranı (Misclassification Rate (MCR)) metrikleri açısından 0.8725, 0.9173, 0.8885, 0.0827 ve 0.1275 değerleri ile RBFC yönteminin, Kesinlik, AUC ve FPR metrikleri açısından 0.8718, 0.9300 ve 0.1610 değerleri ile ADT yönteminin en iyi performansa sahip olduğu görülmüştür.

Anahtar kelimeler—Makine öğrenmesi, sınıflandırma, kalp yetmezliği

Abstract

Heart failure is a severe health problem that negatively impacts the quality of life and can lead to fatal consequences if left untreated. Early diagnosis and proper treatment can minimize these problems. In this study, a model was developed to measure the performances of machine learning (ML) methods in different categories for heart failure prediction, and performance analyses were performed on both categorical and general basis. Tree, meta and function categories, which include methods known to produce successful results in classification problems, were preferred as categories, and five methods from each category were used. In the experimental studies, the performance of the ML methods was measured using basic metrics and classification error metrics based on the confusion matrix. When the experimental results were evaluated categorically, the best performances were obtained with the Alternating Decision Tree (ADT) method in the tree category for the metrics except for Recall and False Negative Rate (FNR), the Logistic Boosting Regression (LBST) method in the meta category for the metrics except for Area under the curve (AUC), and the Radial Bases Function Classifier (RBFC) method in the function category for the metrics except for the Precision and False Positive Rate (FPR). When considering the results in terms of the performances of all methods, the RBFC method exhibited the best performance with values of 0.8725 for Accuracy, 0.9173 for Recall, 0.8885 for F-score, 0.0827 for FNR, and 0.1275 for Misclassification Rate (MCR). On the other hand, the ADT method showed the best performance in terms of Precision, AUC, and FPR metrics with values of 0.8718, 0.9300 and 0.1610, respectively.

Keywords— Machine learning, classification, heart failure

1. Giriş

Kalp damar bozukluklarını içeren kardiyovasküler hastalıklar (Cardiovascular Diseases (CVDs)) küresel bazda en önemli ölüm sebepleri arasında gösterilir. 2019 yılında tüm dünyada genelinde

gerçekleşen yaklaşık 17.9 milyon ölümün (bu oran tüm küresel ölümlerin %32' sine denk düşer) CVDs kaynaklı olduğu Dünya Sağlık Örgütü (World Health Organization (WHO)) verileri ile açıklanmıştır. WHO' nun bu hastalıkla ilgili aynı yıla ait başka bir analizinde bulaşıcı olmayan hastalıklara bağlı 17 milyon erken ölümün (70 yaş altı) %38'inin CVDs' e dayandığı ifade edilmiştir [1]. CVDs sınıfında yer alan kalp yetmezliği kalbin vücuda yeterince kan pompalayamadığı durumda oluşan bir hastalık olup, tedavi edilemediği taktirde hastaneye yatışa varacak derecede önemli sağlık sorunlarını beraberinde getirebilir. Hatta ileri safhaları ölümlere neden olabilir [2], [3]. CVDs' in istatistikleri kalp yetmezliği bazında değerlendirildiğinde, onların dünya genelinde ciddiye alınması gereken oldukça önemli bir hastalık olduğu anlaşılacaktır. Bu hastalıklar Avrupa Birliği ülkeleri ve Türkiye' de de yüksek riskli hastalıklar sınıfında yer alır. Avrupa birliği ülkelerinde hastalık kaynaklı ölüm oranları %12 ve Türkiye' de %14 ile oldukça yüksek bir seviyede seyredir [4]. Bu yüzden kalp yetmezliğinin hastalık ilerlemeden tespit edilmesi hem tedavinin amacına ulaşmasında hem de ölüm oranlarının en aza indirilmesinde hayati bir önem taşır. Bu hususta klinik çalışmalar ile birlikte uzman kararına katkı sağlayacak yapay zekâ temelli araçların kullanılması sürecin takibinde önemli bir role sahiptir.

Yapay zekâ temelli yöntemler ile tıbbi veri analizleri ve görüntüler üzerinden hastalığın seyri takip edilerek tedavi süreci düzenlenebilir, hastalık teşhis edilebilirler, hastanın kişisel bilgilerini de dikkate alınarak hastalık riski tahmin edilebilir ve görüntü temelli anormallikler tanımlanabilirler. Bu anlamda bakıldığında MÖ yöntemleri tıbbi analiz ve değerlendirme süreçlerinde yaygın kullanılan bir yapay zekâ algoritması olarak karşımıza çıkar. Kalp yetmezliği tahmininde bu yöntemlerin kullanımı metodolojik olarak sırası ile veri toplama, veri temizleme ve düzenleme, veri bölme, sınıflandırma ve değerlendirme süreçlerinin yürürlüğe konmasını gerektirir. Şu ana kadar yapılan çalışmalar incelendiğinde Rasgele Orman (Random Forest (RF)), ekstremler Gradyan Artırma (eXtreme Gradient Boosting (XGBoost)), Destek Vektör Makineleri (Support Vector Machine (SVM)), Naive Bayes (NB), Lojistik Regresyon (Logistic Regression (LR)), K-En yakın komşuluk (K-Nearest Neighbors (KNN)), Karar Ağacı (Decision Tree (DT)), J48 Ağacı (J48) ve Adaptif Önyüklemeye (Adaptive Boosting (AdaBoost)) gibi MÖ yöntemlerinin kalp yetmezliği hatalığının tahmini ve teşhisi ile bu hastalığa yakalanma riskinin belirlenmesinde [5]–[8] başarılı bir şekilde kullanıldığı görülmektedir. Yapay zekâ temelli algoritmaları arasında günümüzün popüler yöntemlerinden derin öğrenme (DÖ) kalp yetmezliğinin teşhisi ve tahmininin farklı aşamalarında yaygın bir şekilde kullanılmaktadır. Bu yöntemler özellikle MRI, echokardiyografi ve CT taramaları gibi kalp yetmezliği teşhisinde kullanılan görüntüleri işleyerek kalp anormallikleri ve fonksiyonunun değerlendirmesinde etkin rol oynarlar [9]–[12]. DÖ yöntemleri elektrokardiyografi (EKG) verileri üzerinden kalp ritmi bozukluklarını da belirleyerek hastalığı tanımlayabilir. DÖ temelli yaklaşımlar olarak Evrişimli Sinir Ağı (Convolutional Neural Network (CNN)) [13], Yinelemeli sinir ağı (Recurrent Neural Network (RNN)) [14], Uzun Kısa Süreli Bellek (Long Short-Term Memory (LSTM)) [15] ve Kapı Özyinelemeli Geçit (Gated Recurrent Unit (GRU)) [16] yöntemleri bu hastalığın teşhisinde yaygın bir şekilde kullanılmıştır. Bazı derin öğrenme yapıları

hastalık teşhisi sürecinde özellik çıkarıcı gibi kullanılabilirler. Bununla çoğu zaman CNN-RNN, CNN-LSTM ve CNN-SVM gibi hibrid yaklaşımlarda karşılaşılmaktadır [17]–[19]. Bu yapıda ilk birimler özellik çıkarıcı gibi davranırken, diğerleri sınıflayıcı olarak işlev görürler. DÖ temelli yöntemler kalp yetmezliği teşhisinde yüksek performanslar sergilemeler de onlar yapısal olarak kompleksliği ve hesapsal olarak yüksek işlem yoğunluğunu içeren önemli dezavantajları da beraberinde getirirler.

Bu makalede kalp yetmezliği tahmininin kategorik olarak farklı tip MÖ yöntemleri ile uygulamasına yönelik bir çalışma sunulmuştur. Ağaç, meta ve fonksiyon olmak üzere üç kategoride toplam on beş MÖ yöntemini içeren bir kalp yetmezliği tahmin modeli oluşturularak deneysel çalışmalar yapılmış ve elde edilen sonuçlar hem kategorik temelde hem de genel performans olarak değerlendirilmiştir. Çalışmanın geri kalanı şu şekilde özetlenmiştir: Bölüm 2 çalışma ile ilgili geçmişte yapılmış güncel çalışmaları açıklar. Bölüm 3 çalışmada kullanılan veri setini, kalp yetmezliği teşhisi için oluşturulan modeli, modelde kullanılan MÖ yöntemlerini ve performans ölçüm metriklerini anlatır. Bölüm 4 deneysel sonuçları ve tartışmaları sunar. Son bölüm ise genel sonuçları değerlendirir.

2. Literatür Taraması

MÖ yöntemlerinin büyük miktardaki verileri ve örüntüleri hızlı bir şekilde işleyebilme kabiliyeti onu tıp alanındaki verilerin analizinde, hastalıkların teşhisinde ve tedavi yöntemlerinin geliştirilmesinde kullanılabilir bir araç haline getirmiştir. Bu bölüm başlığı altında ciddi tıbbi bir durum ve ölümcül bir hastalık olan kalp yetmezliğinin temel MÖ yöntemleri ve hibrid MÖ yöntemleri ile teşhisi ve tahminine yönelik yapılmış güncel literatür çalışmaları sunulmuştur.

Ali ve arkadaşları [20] etkili bir kalp yetmezliği tahmini için iki SVM' i istifleyen bir uzman sistem önerdiler. Bu bütünlük yapıda ilk SVM' i gereksiz özellikleri ortadan kaldırmak için, ikinci SVM' i ise tahmin sürecini gerçekleştirmek için kullandılar. Her iki SVM' i Hibrit Izgara Arama Algoritması (Hybrid Grid Search Algorithm (HGSA)) kullanarak optimize ettiler. Önerdikleri modelin etkinliğini Doğruluk, Duyarlılık, Kesinlik, Matthews korelasyon katsayısı (MCC) ve AUC metrikleri üzerinden test ettiler. Yaptıkları deneyler ile HGSA optimizasyonuna sahip uzman sistemin geleneksel SVM' den %3.3 daha yüksek bir performans ortaya koyduğunu ispatladılar. Ayrıca, önerdikleri yöntemi, %57,85-%91,83 aralığında doğruluk elde eden başka yöntemler ile kıyasladıklarında kendi yöntemlerinin daha iyi bir performans sergilediğini gördüler.

Chen ve arkadaşları [21], kalp yetmezliğinin olumsuz etkileri için Derin Piramit Evrişimli Sinir Ağları (Deep Pyramid Convolutional Neural Networks (DPCNN)) ile XGBoost' u birleştiren hibrid bir model önerdiler. Önerdikleri modelde DPCNN' i hastanın teşhis metinlerinden özellik çıkarmak için kullanırken, XGBoost' tan kalp yetmezliği tahmin modelini oluşturmada yararlandılar. 2014' ten 2018' e kadar kalp yetmezliği olan hastaların verilerine uygulanan modellerden elde edilen sonuçlar DPCNN- XGBoost hibrid modelinin, sade DPCNN ve XGBoost modellerine göre tahmin duyarlılığını %3 ve %31

oranında iyileştirdiğini gösterdiler.

Grgić ve arkadaşlarının yaptığı kalp hastalarının kardiyovasküler parametrelerini analiz ettiği çalışmalarında [22] RF ve LR algoritmaları kullanılarak 12 parametreye göre kardiyovasküler hastalığı olan hastalarda ölüm tahminini yaptılar. Her iki algoritmanın hiper parametrelerini Izgara Arama Algoritmasını (Grid Search Algorithm (GSA)) kullanarak optimize ettiler. Elde ettikleri sonuçların karşılaştırma analizlerinden %90 ile en yüksek doğruluğu RF algoritmasının elde ettiğini gördüler. Bu algoritma AUC performansında da %86 ile en yüksek performansı sergilediğini gözlemlədiler.

Mansur Huang ve arkadaşları [7] RF, SVM, NB ve LR' yi içeren dört popüler MÖ yöntemini Kaggle web sitesinden elde ettikleri halka açık veri setine uygulayarak deneysel çalışmalar yaptılar ve bu yöntemlerin kalp yetmezliği hastalığının tahminindeki performanslarını karşılaştırdılar. MÖ yöntemlerinin performansını Doğruluk, Kesinlik, Duyarlılık ve F-skör gibi Karışıklık matrisi metrikleri üzerinden değerlendirdiler. Deneysel sonuçları kullanarak yaptıkları analizler RF yönteminin 0.88' lik ortalama performans ile SVM, NB ve LR yöntemlerine göre daha yüksek olduğunu göstermiştir. Onlar aynı zamanda özellikler üzerine yaptıkları deneylerde 13 semptomun hepsinin sınıflandırma sürecinde önemli olduğunu gözlemlədiler.

Foziljonova ve Wasito [23] kalp yetmezliği olan hastalarda sağ kalım oranlarının tahmini için uygun MÖ tekniğinin belirlenmesi üzerine deneysel çalışmalar yaptılar ve bu çalışmalardan elde ettikleri sonuçları analiz ettiler. Bu çalışmalarında 2015 yılının Nisan-Aralık ayları arasında Pakistan'daki bir hastanede bulunan kalp yetmezliği olan hastalarından topladıkları verilere KNN, RF ve DT yöntemlerini uyguladılar. F1-skör ve AUC metrikleri ile performans değerlendirmesi yaptılar. Deneysel çalışmalarında her iki metrik açısından en iyi performansının 0.861 F1-skör ve 0.957 AUC değerleri ile RF yönteminin sağladığı görülmüştür.

Mudassar ve arkadaşları [24] 6' sınıflı topluluk öğrenmesi ve 3' ü geleneksel olmak üzere toplam 9 MÖ yöntemini UCI MÖ veri tabanından elde ettikleri 299 kalp yetmezliği hastasının kayıtlarını içeren veri setine uygulayarak bu yöntemlerin kalp yetmezliği teşhisindeki başarımlarını karşılaştırdılar. Kullandıkları veri seti veri etiketleri açısından dengesiz verileri içeren bir veri seti olduğu için aynı analizleri SMOTE işlemini uygulayarak dengeli hale getirdikleri veri seti üzerinden de gerçekleştirdiler. Deneysel çalışmalarında NB, Bagging, RF, XGBoost, LightBoost, DT, AdaBoost, LR ve ETC yöntemlerinin performanslarını Doğruluk, Kesinlik, Duyarlılık ve F1-skör metrikleri ile ölçtüler. 10 kat çapraz doğrulama ve 0.7' lik bölünme şartlarında yaptıkları deneylerde SMOTE' li ve SMOTE' siz durum için en iyi performansları sırası ile 0.926 ve 0.896' lık doğruluk değerleri ile LightBoost yönteminden elde ettiler.

Gold ve Lorshase [5] kalp yetmezliği tahmini için RF ve J48-AdaBoost olmak üzere iki tahmin modeli önerdiler. Veri seti olarak Cleveland Hastanesi veri tabanından toplanmış 13 özelliğe ve 303 örneğe sahip bir veri setini kullanarak yaptıkları deneylerden elde edilen sonuçlar J48-AdaBoost modelinin %92.3077 Doğruluk, %93.0 Kesinlik, %92.3 Duyarlılık, %92.4 F1-skör ve %97.6 AUC değerleri ile RF modeline göre daha yüksek bir performans sergilediğini ispatlamıştır.

Zeng [25] klinik özellikler ile kalp hastalığı arasındaki korelasyonları gözlemek için sıcaklık haritası çıkarmış ve DT, KNN, SVM ve XGBoost yöntemlerini kullanarak oluşturduğu MÖ temelli modeller aracılığı ile hastalık tahmini yapmıştır. Bu modeller arasından performans olarak en iyisini seçmek için Doğruluk, Duyarlılık ve F1-skör metriklerinden yararlanmıştır. Deneysel veri olarak 5 bağımsız veri setini birleştiren Kaggle web sitesinden elde edilmiş kalp yetmezliği tahmini (KYT) veri setini kullanmıştır. 0.7' lik bölünme şartlarında yapılan deneylerden elde edilen sonuçlar SVM yönteminin %88.8 Doğruluk, %89.3 Duyarlılık ve %90.7 F1-skör değerleri ile en yüksek performansa ulaştığını göstermiştir. Ayrıca ısı haritası üzerinden egzersizle indüklenen anjina (ExerciseAngina) ve ST depresyonu (Oldpeak) kalp hastalığı oluşumu ile yakın ilişkiye sahip olduğu ve bunun sonucunda kalp hastalığı riskinden kaçınmak için bu iki özelliğe çok dikkat edilmesi gerektiği de kanıtlanmıştır.

Coşkun ve Kuncan [26] NB, SVM, DT, RF ve Doğrusal Diskriminant Analizi (Linear Discriminant Analysis (LDA)) sınıflandırıcılarını kaggle web sitesinden elde ettikleri 918 örneğin oluşturduğu KYT veri setine uygulayarak MÖ temelli yöntemlerin kalp yetmezliği hastalığındaki etkinliğini araştırdılar. Veri setine etiket kodlama ve normalizasyon gibi birtakım ön işlem süreçlerini uyguladıktan sonra 0.8' lik bölünme oranında eğitim ve test verilerini oluşturdular. Bu verileri kullanarak yaptıkları deneyler RF yönteminin %90.76' lık başarımları ile en yüksek performansı elde ettiğini göstermiştir. Bu algoritmanın sınıflar düzeyindeki performansı ise kalp yetmezliği olan hastalarda %93.1 ve hastalığı olmayanlarda %87.8 olmuştur.

3. Materyal ve Metotlar

Bu bölümde, çalışmada kullanılan veri seti, kalp yetmezliği tahmini için oluşturulan model, modeli oluşturan birleşenler ve onun değerlendirilmesinde kullanılan metrikler sunulmaktadır. İlk olarak modelde kullanılan veri seti ve onu oluşturan özellikler anlatılmıştır. Sonra Kalp yetmezliği tahmini için kullanılan modelin oluşum aşamaları tüm detayları ile açıklanmıştır. Son olarak ise modelin değerlendirilmesinde kullanılan performans metriklerinden bahsedilmiştir.

3.1. Veri Seti

Çalışmamızda kalp yetmezliğini tahmin etme amaçlı kullanılan MÖ temelli yöntemlerin uygulaması Kaliforniya Üniversitesi-Irvine (University of California Irvine (UCI)) Makine Öğrenimi Veri tabanındaki "Cleveland", "Hungarian", "Switzerland", "Long Beach VA" ve "Stalog" veri setlerinin birleştirilmesi ile oluşturulmuş Kaggle web sitesinden alınan KYT veri seti üzerinden yapılmıştır [27]. 725 erkek ve 193 kadın katılımcıdan oluşan bu set 410' u normal ve 508' i kalp hastası toplam 918 veri örneği içerir. İlgili veri seti yaş, cinsiyet, kan basıncı, kolesterol seviyeleri, glikoz seviyeleri, elektrokardiyogram sonuçlarını, kalp hastalığı durumu gibi farklı nitelikleri beraberinde getiren 12 özelliğe sahiptir. Tablo 1' de KYT veri setinin özellikleri ile bu özelliklerin açıklamaları, türleri ve değer aralıklarına ait özet bir sunum gösterilmiştir.

Tablo 1. KYT veri setinin özellikleri ile onun açıklamaları, türleri ve değer aralıklarına ait özet bir sunum.

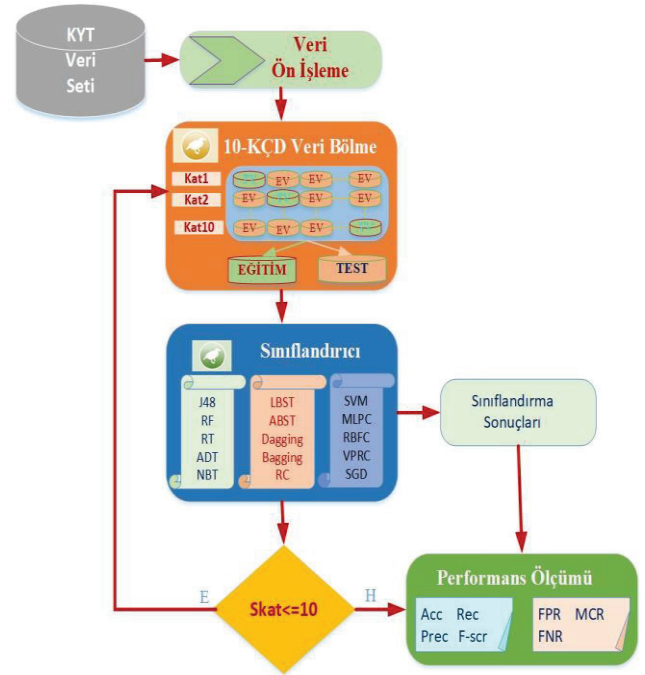
Özellik Adı	Tanımı	Türü	Değeri
Age	Hastanın yaşı	Tam sayı	28-77
Sex	Hastanın cinsiyeti	Kategorik	M: Bay F: Bayan
ChestPainType	Göğüs ağrısı tipi	Kategorik	TA: Tipik Anjin ATA: Atipik Anjin NAP: Anjinal Olmayan Ağrı ASY: Asemptomatik
RestingBP	Dinlenmiş kan basıncı	Tam sayı	80-200
Cholesterol	Serum kolesterolü	Tam sayı	0-603
FastingBS	Açlık kan şekeri	Tam sayı	1: Eğer FastingBS>120 mg/dl 0 Aksi durumda Normal: Normal ST: ST-T dalga anormalliğine sahip olmak
RestingECG	Dinlenmiş EKG sonuçları	Kategorik	LVH: Estes'in kriterlerine göre keskin sol ventrikül hipertrofisi göstermesi veya onun olasılığı
MaxHR	Maksimum kalp atış hızı	Tam sayı	60-202
ExerciseAngina	Egzersizle ilişkili anjinal	Boolean	Y: Evet N: Hayır
Oldpeak	Depresyonda ölçülen Eskitepe	Float	-2.6-6.2
ST_Slope	En yüksek egzersiz ST segmentinin eğimi	Kategorik	Up: Yukarı eğimli Flat: Düz Down: Aşağı Eğimli
HeartDisease	Çıkış sınıfı	Tam sayı	1: Kalp hastalığı 0: Normal

Tabloda verilen 11 özellik, kalp hastalığı olup olmadığını sınıflandırmak için kullanılan "HeartDisease" bağımlı değişkeni ile ilişkilendirilir. Bağımlı değişkenin 1 değerini alması kalp hastası olma durumunu, 0 değerini alması ise bu hastalığa sahip olmama (normal olma) durumunu temsil eder.

3.2. Kalp Yetmezliği Tahmini için MÖ Temelli Model

Bu çalışmada ağaç, fonksiyon ve meta kategorisinde yer alan 15 MÖ yönteminin kalp yetmezliği tahminindeki performanslarını test edebilmek için oluşturulan modele ait şema Şekil 1' de gösterilmiştir. Hem bireysel hem de kategorik bazda MÖ yöntemlerinin performansını ölçümünde kullanılan model; ön işlem, 10-kat çapraz doğrulamalı (10-KÇD) veri bölme, sınıflandırma ve performans ölçümü olmak üzere dört temel prosedürü birleştirir. Bu model ilk olarak KYT veri setinden gelen ikili ya da kategorik formattaki verileri bir veri dönüşüm ön işlem prosedürü üzerinden sayısal formattaki veriler haline dönüştürür. Sonra bu veriyi MÖ yöntemlerinin eğitim ve test süreçlerini yürürlüğe konulmasında kullanılan eğitim ve test veri setlerini oluşturabilmek için 10-KÇD veri bölme

prosedürüne göndererek aynı veri setinden elde edilmiş 10 farklı bölünmüş eğitim ve test verisini elde eder. Daha sonra bu veriler sınıflandırma prosedürüne gönderilerek her bir eğitim ve test verisi için önce eğitim sonra test süreci yürürlüğe konarak sınıflandırma tahmini sonuçları elde edilir. Bölünmüş veri indeksi 10' a ulaştığında performans ölçüm prosedürü tüm bölünmüş test verisi için elde eden sınıflandırma sonuçlarına göre MÖ sınıflandırıcıların ortalama performansını hesaplar.



Şekil 1. Kalp yetmezliği tahmini için oluşturulan MÖ temelli model.

A. Ön İşlem Prosedürü

Kaggle web sitesinden alınan KYT veri seti farklı veri setlerinin birleştirilmesi sonucu oluştuğu için eksik özellik ve değerler içermemektedir. Bununla birlikte veri setinin içerdiği özelliklerin değerleri tür olarak sayısal, kategorik ya da ikili format olarak değişmektedir. Bu yüzden ön işlem prosedüründe ikili ve kategorik formattaki özellik değerleri tam sayı formatına dönüştürülmüştür. Bu anlamda veri seti üzerinde yapılan değişimler Tablo 2' de verilmiştir.

Tablo 2. Ön işlem süreci sonunda ikili ve kategorik formattaki özellik değerlerindeki değişimler

Özellik Adı	Türü(önceki)	Türü(yeni)	Değer Değişimi
Sex	Kategorik	Tam sayı	M: 1, F: 0
ChestPainType	Kategorik	Tam sayı	TA: 3, ATA: 2 NAP: 1, ASY: 0
RestingECG	Kategorik	Tam sayı	Normal:2, ST: 1 LVH: 0
ExerciseAngina	Boolean	Tam sayı	Y: 1, N: 0
ST_Slope	Kategorik	Tam sayı	Up: 2, Flat: 1 Down: 0

B. 10-KÇD' lı Veri Bölme Prosedürü

MÖ yöntemlerinin performansını doğru bir şekilde ölçebilmek için bu süreçte 10 kat çapraz doğrulama yaklaşımı kullanılmıştır. Bu yüzden sınıflandırıcıların işlevlerini yerine getirebilmelerinde ihtiyaç duydukları eğitim ve test verilerinin elde edilmesinde 10-KÇD' lı bir veri bölme prosedüründen yararlanılmıştır. Bu prosedür veri ön işlem sürecinden gelen veriyi kullanarak birbirinden farklı 10 bölünmüş eğitim ve test veri setini oluşturur.

C. Sınıflandırma Prosedürü

Çalışmada sınıflandırıcı olarak ağaç, meta ve fonksiyon kategorisinde yer alan ve birçok sınıflandırma probleminde başarılı sonuçlar ürettiği bilinen 15 MÖ temelli yöntemden yararlanılmıştır. Bu prosedürde ilk kategori olan ağaç kategorisinde J48, RF, Rasgele Ağaç (Random Tree (RT)), ADT ve NB Ağacı (NB Tree (NBT)) kullanılırken, Meta kategorisinde Önyüklem Toplaması (Bootstrap Aggregating (Bagging)), Ayrık Toplama (Disjoint Aggregating (Dagging)), ABST, LBST ve Rasgele Komite (Random Committee (RC)) kullanılır. Fonksiyon kategorisinde ise SVM, Çok Katmanlı Algılayıcı Sınıflandırıcısı (Multilayer Perceptron Classifier (MLPC)), RBFC, Oylanan Algılayıcı (Voted Perceptron (VPRC)) ve Stokastik Dik İniş (Stochastic Gradient Descent (SGD)) yer alır. Bu yöntemler aşağıda alt başlıkla halinde anlatılmıştır.

J48: C4.5 algoritmasının bir uzantısı olup, kök düğümünü kullanarak örneklerin sınıflandırılmasını sağlayan bir karar ağacı algoritmasıdır. Etkili bir yöntem olduğu için veri madenciliği ve sınıflandırma problemlerinde yaygın bir şekilde kullanılır. Yöntem içerisinde karar ağaçlarını oluşturulmasında veri kümesindeki örnekleri özellik değerlerine göre alt gruplara ayıran ve ismi "böl ve fetet" olan bir yaklaşımdan yararlanır [28]. Örneklerin değerlendirilmesinde veri setini en iyi şekilde bölen eşik değeri kullanılır. Bu değer genel olarak Eşitlik 1' de formülü verilen bilgi kazancı ölçümünden elde edilir.

$$IG(A) = H(S) - \sum_{t \in T} p(t)H(t) \quad (1)$$

Burada $H(S)$ S kümesinin entropisini, T S' nin A tahmincisine göre bölünmesiyle oluşturulan alt kümeyi, $p(t)$ t' deki eleman sayısının S kümesindeki eleman sayısına oranı ve $H(t)$ t alt kümesinin entropisini temsil eder.

RF: Eğitim sürecinde bir dizi karar ağacı oluşturduktan sonra onların tahminlerini ortalama ya da oylama teknikleri ile birleştirerek nihai çözüme ulaşan MÖ temelli bir topluluk algoritmasıdır. RF yönteminin ormanda oluşturduğu yeteri miktarda bir ağaç topluluğu ile aşırı uyum problemlerini giderebilmesi, eksik veriler üzerinden çalışabilmesi ve kategorik değerler için modellenebilmesi gibi bir takım önemli avantajları onu veri biliminde yaygın kullanılan bir yöntem haline getirmiştir [29]. Bu yöntemde karar ormanın oluşturulmasındaki ilk adım veri setinden rasgele örnekleme yöntemi ile alt kümelerin elde edilmesidir. Sonra bu alt kümelere CART ya da ID3 gibi algoritmalar uygulanarak karar ağaçları oluşturulur. Bu ağaçlar kendisi için seçilmiş eğitim örnekleri kullanılarak büyütülür. Sonuçta büyütülmüş ve üzerinde budama yapılmamış bu ağaç yapıları bir araya getirilerek karar ormanı oluşturulur. Bu yöntem bir gözleme ait tahmin edilen çıktıyı, ormandaki ağaçların çoğunluk oyuna göre

belirler.

RT: Rasgele bir şekilde oluşturulmuş ağaçları içeren ve danışmanlı öğrenmeyi kullanan bir karar ağacı yaklaşımıdır [30]. Bu yöntem, Gini indeksi ve bilgi kazancı gibi fonksiyonları kullanmadan rasgele seçtiği bir özellik üzerinden düğüm genişlemesi yaparak karar ağaçlarını oluşturur. Rasgele oluşturduğu karar ağaçlarının budamasını gereksiz ve eksik gördüğü düğümleri kaldırarak yapar. Bu yapıda her ağaç bir sınıf olasılık dağılımı üretir ve oluşturulan ağaçlardan elde edilen sınıf dağılım çıktılarının ortalaması, nihai çıktıyı verir.

ADT: Geniş bir uygulama alanına sahip olan yöntem karar ağaçlarının, oylanan karar ağaçlarının ve oylanan karar kütüklerinin bir genellemesidir [31], [32]. ADT, bir tahmin koşulunu ve tahmin düğümlerini belirtmek için tek bir sayı içeren karar düğümlerinin bir ürünü olarak ortaya çıkar. Bu yöntemde her karar düğümünün yerini ayrıncı düğüm ve tahmin düğümü olmak üzere iki düğüm alır. Karar ağaçlarında olduğu bir örnek ağaç ile birlikte kökten başlayarak yapraklara kadar tüm yolları takip eder ve üzerinden geçilen tüm düğümleri toplar.

NBT: Naive Bayes sınıflandırıcısı ve karar ağaçlarını bileştiren hibrid bir modeldir. Yapısal olarak bu algoritma bize geleneksel J48 algoritmasının her yaprak düğümüne NB sınıflandırıcısının uygulanmış bir formunu sunar. Bu yöntem ağaç yapısını oluştururken, tıpkı J48 algoritmasında olduğu gibi bilgi kazanımını dikkate alarak düğümleri bölme ve ağaçları budama sürecini yürütür. Süreç içerisinde ağaç büyüdükten sonra yapraklara ait veriler ile her bir yaprak için bir Naive Bayes oluşturur. NBT kendisine uygulanan örnekleri sınıflandırırken yapraklar üzerindeki bu Naive Bayes' leri kullanır [33]. Düğümlerdeki Naive Bayes' lere sınıflandırma sonuçlarına aşağıdaki denklem üzerinden karar verirler [34].

$$N(x) = \arg \max_{y=0 \text{ or } 1} P(y) \prod_{n=1}^N P(x_n | y) \quad (2)$$

Burada $N(x)$ yaprak düğümlerinin ürettiği sınıflandırma sonuçlarını, x giriş örneklerini, y sınıfları, $P(y)$ sınıfların önsel olasılığını, $P(x_n | y)$, verilen x örneğinin n ' inci özelliğinin koşullu olasılığını ve N x ' in toplam özellik sayısını temsil eder.

Bagging: Öğrenci topluluğu oluşturarak bunların sonuçlarının birleştirilmesini esas alan bir topluluk algoritmasıdır. Bu yöntem sonuca ulaşmak için ilk olarak orijinal veri setinden rasgele bir şekilde aldığı örnekleri %100 olacak şekilde çoklar. Sonra oluşturduğu m adet eğitim örneğini kullanarak eğittiği modellere test veri setini uygular. Daha sonra elde ettiği test sonuçlarını ortalama yaklaşımı ile birleştirerek nihai sonuca ulaşır [35]. Sonuçların birleştirilmesi Eşitlik 3' te verilen denklem kullanılarak yapılır.

$$f(E) = \frac{1}{M} \sum_{m=1}^M f_m(E) \quad (3)$$

Burada $f_m(E)$ E girdi kümesi için modellerin skor olarak bireysel çıktılarını, M model sayısını ve $f(E)$ E girdi kümesi için Bagging yönteminin nihai çıktısını gösterir.

Dagging: Aynı veri kümesinden farklı alt küme modelleri oluşturarak eğittikten sonra sonuçlarının birleştiği başarılı bir topluluk algoritmasıdır. Yapısal olarak Bagging algoritmasına benzemekle

birlikte farklılık temel sınıflandırıcıların oluşturulmasında yararlanılacak örnek kümesinin elde edilmesinde meydana gelir. Bir başka deyişle Dagging, temel sınıflandırıcıları elde etmek için yeniden örnekleme yerine çok tabakalı örnekleme kullanır [36], [37]. Nihai sonucu temel sınıflandırıcıların çıktılarını oylayarak elde eder. Bu yonteme ait modelin oluşturulması şu şekilde özetlenebilir: ilk aşamada eğitim veri seti her örnek sadece bir defa kullanılarak k örnek içerecek şekilde L alt kümeye bölünür. Sonra her alt kümeyi temsil eden bir regresyon modeli oluşturulur. Son aşamada ise modellerin sonuçları oylanarak en çok oyu alan modelin çıktısı Dagging yönteminin nihai sonucu olarak atanır. Bu yöntemin veri setini alt örnekleme kümelerine ayırarak işlemesi, onu veri madenciliği ve makine öğrenimi alanlarında özellikle büyük veri kümeleriyle yapılan çalışmalar için kullanışlı bir yöntem haline getirmiştir.

ABST: 1995 yılında Robert Schapire ve Yoav Freund' in geliştirdiği artırılmalı tip bir topluluk algoritmasıdır. Algoritmanın esası zayıf öğrenicileri bir araya getirerek daha güçlü bir öğrenici modeli oluşturmaya dayanır [38]. Algoritmada eğitim zayıf öğrenicilerle başlar. Yanlış tahmin edilen örneklerin ağırlıkları öğrenici çıktılarının ağırlıklı hata oranlarına göre güncellenir. Süreç belirlenen sayıda öğrenici eğitime kadar sürer. Bu işlemlerin sonunda tüm öğrenicilerin ağırlığı onların performansına göre hesaplanır ve Eşitlik 4' te verilen formülde gösterildiği gibi bu ağırlıklar üzerinden bireysel sonuçlar birleştirilerek nihai sonuca ulaşılır [39].

$$H_k(x) = +/-(\sum_{k=1}^K a_k h_k(x)) \quad (4)$$

Burada K zayıf öğrenicilerin sayısını, h_k k ' nıncı zayıf öğrenicinin çıkışı ve a_k k ' nıncı zayıf öğrenicinin ağırlığını temsil eder.

LBST: Özellikle ikili sınıflandırma problemlerinde kullanılan başarılı bir MÖ yaklaşımıdır. Bu yöntem gürültülü ve aykırılıkları içeren verileri işlemede ABST' un sınırlamalarını gidermek için geliştirilmiştir. LBST' u ABST' tan ayıran en önemli özelliği onun aykırı verilere ve gürültüye karşı daha az duyarlı hale getiren kayıp fonksiyonunda vuku bulur [40]. ABST sınıflandırma sürecinde kayıp fonksiyonu olarak üssel bir fonksiyondan yararlanırken, buna karşı LBST kayıp işlevini doğrusal bir fonksiyon olan binom log olasılığını kullanarak yerine getirir. N örnek ve iki sınıfa ait bir eğitim verisi için ağırlıklar ve çalışma cevabı Eşitlik 5' de verilen formüller ile hesaplanabilir [41].

$$w_i = p(x_i)(1 - p(x_i)), \quad z_i = \frac{y_i - p(x_i)}{p(x_i)(1 - p(x_i))} \quad (5)$$

Burada x_i i ' ninci özellik vektörünü, y_i bu vektöre ait sınıf etiketini ve $p(x_i)$ x_i özelliğinin olasılığını temsil eder.

RC: Farklı temel sınıflayıcıların çıktılarını birleştirerek tahmin sonucunu üreten ve topluluk öğrenme yaklaşımını esas alan bir yaklaşımdır. Bu yöntemde her bir temel sınıflandırıcı, aynı veri kümesinden yararlanarak onların rasgele bir şekilde davranmasını sağlayan farklı tohumlar ile oluşturulur [42]. Temel sınıflandırıcıların bu şekildeki yapılandırılması bir yandan yöntem için güçlü bir tahmin kombinasyonu sağlarken, diğer taraftan sınıflayıcılarda oluşacak aşırı

uyum problemini azaltabilir. Nihai tahmin sonucuna, girdi verilerine göre bağımsız tahminler üreten temel sınıflandırıcıların çıktılarının genel ortalaması alınarak ulaşılır.

SVM: Sınıflandırma ve regresyon problemlerinin çözümünde yaygın kullanılan bir denetimli öğrenme algoritmasıdır. Bu yöntem sınıflara ait veri noktalarını en yüksek marj' a sahip bir hiper düzlem üzerinden ayırır. Hiper düzlemde marjın sınırları destek vektörleri adı verilen veri noktaları belirler. Marj sınırları arasındaki mesafe arttıkça yöntemin genelleme yeteneği artar ve bunun sonucunda daha iyi tahmin sonuçlarına ulaşır. SVM verilere ait sınıflara bölme bir başka deyişle hiper düzlem oluşturma görevini doğrusal ya da çekirdek (Kernel) fonksiyonları üzerinden yerine getirir [43]. Verilerin bir çizgi kullanılarak ikiye bölünebildiği durumlarda aşağıda verildiği gibi doğrusal tip bir fonksiyondan yararlanılabilir.

$$w_0 x + b_0 = 0 \quad (6)$$

Burada x giriş vektörünü, w_0 ağırlık vektörünü ve b_0 sapmayı gösterir. Verilerin doğrusal bir fonksiyon ile bölünemediği durumlarda ise Kernel fonksiyonları kullanılabilir [44].

$$K(x_i, x_j) = \{x_i^T x_j + c\}^d \quad (7)$$

Formülde x_i ve x_j giriş uzayı vektörü, d polinomun derecesi ve $x_i^T x_j$ ' nin transpozudur. c , en yüksek ve en düşük mertebeli polinom arasındaki denge için kullanılan bir parametredir.

MLPC: İleri beslemeli bir yapay sinir ağı modeli olan çok katmanlı algılayıcıyı (MLP) esas alan güçlü bir algoritmadır. Yapısal olarak giriş, gizli ve çıkış olmak üzere üç temel katmandan oluşur. Bu yapıda giriş katmanı dış dünyadan gelen verileri ağırlıklandırarak gizli katmana gönderir. MLP' nin hesaplama motoru olan gizli katman giriş katmanından gelen bilgileri işleyerek çıkış katmanına aktarır. Çıkış katmanı bu bilgileri eşik değerine göre işleyerek sınıflandırır [45]. Katmanlardaki işlemler işlem elemanı olarak isimlendirilen birimler üzerinden gerçekleştirilir. Onlar Eşitlik 8' de gösterildiği gibi kendilerine gelen bilgilerin ağırlıklı toplamlarını bularak net girdilerini hesaplar ve bu girdiyi bir eşik değeri ile birlikte aktivasyon fonksiyonundan geçirerek çıktılarını elde ederler.

$$net_k = \sum_{i=1}^n x_i * w_i + b_k, \quad O_k = f(net_k) \quad (8)$$

Burada net_k k ' nıncı işlem elemanı için net girdiyi, x_i işlem elemanına gelen i ' inci bilgi girişini, w_i işlem elemanına gelen i ' inci girişin bağlantı ağırlığını, $f(\bullet)$ işlem elemanı için aktivasyon fonksiyonunu ve O_k k ' nıncı işlem elemanının çıkışını gösterir.

RBFC: Sınıflandırma amaçlı kullanılan normalize edilmiş bir Gaussian tip radyal temel fonksiyon (RBF) ağıdır. Tipik bir RBF sınıflandırıcısı giriş, gizli ve çıkış olmak üzere üç katmandan oluşur. Eğitim süreci WEKA' nın optimizasyon sınıfı ile yürürlüğe konur ve bu süreçte hatayı en aza indirmede Broyden-Fletcher-Goldfarb-Shanno (BFGS) algoritması kullanılır. Başlangıç değerleri k-Means algoritması ile belirlenen merkezlerin herhangi birinin en yakın komşuna en uzak olan mesafe dikkate alınarak ayarlanır. Aşağıda Gaussian radyal temel fonksiyonu kullanılarak eğitim süreci sonunda öğrenilen modele ait çıkış temsili verilmiştir [46].

$$f(x_1, x_2, \dots, x_n) = h \left(w_{L,0} + \sum_{i=1}^m w_{L,i} \left(-\sum_{j=1}^n \frac{\alpha_j^2 (x_j - c_{L,j})^2}{2\sigma_{L,j}^2} \right) \right) \quad (9)$$

Burada x_1, x_2, \dots, x_n giriş vektörünü, $h(\bullet)$ logistik fonksiyonu, m temel fonksiyonların sayısını, $w_{L,i}$ her temel fonksiyonun ağırlığını, $c_{L,i}$ temel fonksiyon merkezlerini, α_j^2 j. özniteliğin ağırlığını ve $\sigma_{L,j}^2$ ise varyanslarını temsil eder.

VPRC: Doğrusal olmayan verilerin sınıflandırılmasında kullanılan etkili bir yaklaşımdır. Bu yöntem yapısal olarak orijinal perceptron ile Helmbold ve Warmuth' un tanıttığı çevrim içi öğrenme algoritmalarının yığın öğrenme algoritmasına uyarlanmasını esas alır [47]. O, nihai sonucu daha az hata yapan modelleri daha yüksek ağırlıklar ile etiketleyerek elde eder. Ağırlıklara, yanlış sınıflandırıldığında kaydedilen tahmin vektörleri ile doğru tahminde süreleri izlenerek karar verilir. Eğitim sürecinde de o, her hatadan sonra oluşan tahmin vektörleri kaydeder ve vektörlerin hata yapılmaya kadar geçen süresi hesaplanarak tahmin vektörlerine ağırlıklar atanır [48]. Bu süreç her veri akışında tekrar eder. Bu yüzden model deneyim kazandıkça daha iyi performans sergiler.

SGD: Dik iniş (GD) algoritmasının gelişmiş bir sürümüdür. Bu yöntem, SVM ve LR algoritmaları gibi doğrusal sınıflayıcılar altında konveks kayıp fonksiyonları ile ayırt edici öğrenmeyi destekleyebildiği için modellerin optimizasyonunda yaygın bir şekilde kullanılır. SGD' yi GD algoritmasından ayıran en önemli özelliği, onun veri kümesinin tamamının gradyanı almak yerine bu kümeden rasgele seçilmiş örnekler kullanılarak yaklaşık bir gradyan hesaplamasıdır. Bu özelliği onun hesapsal maliyetini düşürerek büyük veri kümelerinde hem kolay bir şekilde uygulanabilmesini sağlar hem de verimliliğini artırır [49]. Eşitlik 10' da verilen gradyan hesaplaması ile birlikte dikkate alınan tüm veri örneklerine ait ağırlık ve etiketler güncellenir. Bu güncelleme minimum maliyete ulaşana kadar her adımda yenilenir.

$$\nabla f(x) = \frac{1}{n} \sum_{i=1}^n \nabla f_i(x) \quad (10)$$

Formülde $f(x)$ amaç fonksiyonunu, $\nabla f(x)$ amaç fonksiyonunun gradyan inişini, n toplam veri örneği sayısını ve $\nabla f_i(x)$ ise rastgele sınırlı veri örnekleri için hesaplanan gradyan inişini gösterir. Seçilen veri örnekleri için hesaplanan gradyanlar ile ağırlıkların güncellenmesi Eşitlik 11' deki formül üzerinden yapılır [50].

$$x \leftarrow x - \alpha \nabla f_i(x) \quad (11)$$

Burada x veri örneğini, α ise öğrenme hızını açıklar.

D. Performans Ölçüm Prosedürü

Bu prosedür MÖ yöntemlerinin performansının ölçülmesinde gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi veren sayıların oluşturduğu bir matris olan Karışıklık matrisinden yararlanır. Bu matriste gerçek ve tahmin edilen değerler arasındaki sayısal ilişki; Doğru Pozitif (True Positive (TP)), Doğru Negatif (True Negative (TN)), Yanlış Pozitif (False Positive (FP)) ve Yanlış Negatif (False Negative (FN)) olmak üzere dört temel bileşen ile etiketlenir. Karışıklık matrisinde TP bileşeni gerçekte pozitif olan ve

sınıflandırma yönteminin de pozitif olarak tahmin ettiği örnek sayısını, TN bileşeni gerçekte negatif olan ve sınıflandırma yönteminin de negatif olarak tahmin ettiği örnek sayısını, FP bileşeni gerçekte negatif olmasına rağmen sınıflandırma yönteminin pozitif olarak tahmin ettiği örnek sayısı ve FN bileşeni gerçekte pozitif olmasına rağmen sınıflandırma yönteminin negatif olarak tahmin ettiği örnek sayısını temsil eder [51]. Performans ölçüm prosedüründe MÖ yöntemlerinin sınıflandırma sürecindeki performansının ölçülmesinde Doğruluk (Accuracy (Acc)), Kesinlik (Precision (Prec)), Duyarlılık (Recall (Rec)), F-skor (F-score (F-scr)), Yanlış Sınıflandırma Oranı (Misclassification Rate (MCR)), Yanlış Pozitif Oranı (False Positive Rate (FPR)), Yanlış Negatif Oranı (False Negative Rate (FNR)) ve ROC eğrisi altında kalan alan (Area Under Curve (AUC)) metriklerinden yararlanılmıştır.

Tablo 3. Performans ölçümlerinde kullanılan metriklerin formül ve tanımları

Metrik Adı	Formülü	Tanımı
Acc	$\frac{TP + TN}{TP + TN + FP + FN}$	Doğru tahmin edilen örnek sayısının toplam örnek sayısına oranı ile temsil edilen bu metrik sınıflandırma yönteminin genel doğruluğunu verir.
Prec	$\frac{TP}{TP + FP}$	Sınıflandırma yönteminin pozitif olarak tahmin ettiği örnek sayısının ne kadarının doğru tahmin edildiğini ölçer.
Rec	$\frac{TP}{TP + FN}$	Sınıflandırma yönteminin gerçek pozitif sınıfı içeren örneklerin ne kadarını doğru bir şekilde tahmin ettiğini gösteren ölçüdür.
F-scr	$2 \times \frac{Prec \times Rec}{Prec + Rec}$	Duyarlılık ve kesinlik metriklerinin harmonik ortalamalarını olarak tek bir değerde birleştiren bu metrik sınıflandırma yönteminin performansını daha geniş bir çerçeveden değerlendirme imkânı sağlar.
MCR	$\frac{FP + FN}{TP + TN + FP + FN}$	Bu metrik sınıflandırma yönteminin genel doğruluğunu veren ölçerlerden biri olup, toplam bazda yanlış tahmin edilmiş örnek oranını gösterir.
FPR	$\frac{FP}{FP + TN}$	Sınıflandırma yönteminin negatif sınıfı tahmin ederken yanlış pozitif olarak sınıflandırdığı örneklerin oranını veren bir ölçerdir.
AUC	$\int TPR.d(FPR)$	ROC eğrisinin altında kalan alanı temsil eden bu metrik, sınıflandırma yönteminin tüm olası durumlarını değerlendirebildiği için onunla ilgili genel performansı en iyi şekilde özetleyen önemli bir ölçüdür.

Doğruluk metriği özellikle dengeli veri setlerinde yöntemin tüm sınıfları eşit derecede ne kadar doğru tahmin ettiğini veren bir ölçüdür. Kesinlik ve duyarlılık metriklerini ise sırası ile yanlış pozitiflerin ve

yanlış negatiflerin tespitinin kritik öneme sahip olduğu durumlarda tercih edilir. Bununla birlikte her iki metrik arasında ters bir ilişki vardır ve bu yüzden ölçümlerde metrikler arası bir denge durumu olmasına ihtiyaç duyulabilir. Bu bağlamda ölçümlerde kesinlik ve duyarlık metrikleri açısından bir denge unsuru olan F-skor metriğinden yararlanılabilir [52]. Ölçümlerde sınıf ayırt etme yeteneğini göstergesi olan ROC alanı [53], sınıflandırma yönteminin tekbir sayısal değer üzerinden genel performansını yansıttığı için farklı yöntemlerin sınıflandırma sürecindeki performanslarını karşılaştırmada oldukça kullanışlı bir metriktir.

4. Deneysel Sonuçlar

Kalp yetmezliği tahmininde kullanılan MÖ yöntemlerinin

sınıflandırma sürecindeki performanslarını ölçme amaçlı Bölüm 3’ te oluşturduğumuz modelin uygulaması WEKA yazılımı üzerinden gerçekleştirilmiştir. Yazılımın bize hem sınıflandırma süreçlerinin analizinde MÖ yöntemleri olarak daha geniş bir algoritma yelpazesi sunması, hem de oluşturulmuş modeli daha hızlı bir şekilde yürürlüğe koyma imkânı sağlaması uygulamanın bu ortamda geliştirilmesindeki temel etkidir. Güvenilir bir performans değerlendirmesi yapabilmek için deneysel çalışmalarda 10 kat çapraz doğru tekniği kullanılmıştır. Ağaç, meta ve fonksiyon kategorisinde yer alan sınıflandırıcılar kategorik ve genel performans olarak değerlendirilmiştir. Deneysel çalışmalarda MÖ temelli yöntemlerin ayar parametrelerinde Tablo 4’ te verilen değerler ve WEKA yazılımının da ilgili yöntemlere ait default değerleri dikkate alınmıştır.

Tablo 4. Kalp yetmezliği tahmini için oluşturulan modelin deneysel çalışmalarında kullanılan MÖ temelli yöntemlerin ayarlanmış parametreleri

Yöntem	Parametre değeri	Yöntem	Parametre değeri	Yöntem	Parametre değeri
<i>J48</i>	BatchSize. 100 CoffidenceFactor. 0.45 MinNumObj. 2, NumFolds. 3 Seed. 1	<i>ABST</i>	BatchSize. 100 Classifier. DecisionStump NumDecimalPlaces. 2 WeightTreshold. 100 Seed. 1, NumIteration. 50	<i>SVM</i>	BatchSize. 100 SVMType. C-SVC CachSize. 40, cofe0. 0.0 Cost. 1.0, degree. 3, loss. 0.1 Eps. 0.001, gamma. 0.25 KernelType. RBF: exp
<i>RF</i>	BatchSize. 100 BagSizePercent. 100 Maxdepth. 2, Seed. 1 NumDecimalPlaces. 2 NumExecutionSlots. 1 NumIteration. 100	<i>LBST</i>	BatchSize. 100, Zmax. 3 Classifier. DecisionStump NumDecimalPlaces. 2 NumThreads. 1 PoolSize. 1, shrinkage. 1.0 WeightTreshold. 100 Seed. 1, NumIteration. 15	<i>MLPC</i>	BatchSize. 100 Act.Func. Appr.Sigmoid Lossfunc. Appr.AbsulateErr NumDecimalPlace. 2 PoolSize. 1, ridge. 1.0E-4 Tolerance. 1.0E-8 Seed. 1.
<i>RT</i>	BatchSize. 100, KValue.. 1 Maxdepth. 0, Seed. 1 NumDecimal Places. 2 MinVarianceProbe. 0.001	<i>Dagging</i>	BatchSize. 100 Classifier. DecisionStump NumDecimalPlaces. 2 NumFolds. 10, Seed. 1	<i>RBFC</i>	BatchSize. 100 Scale,Optm.opt. Use. Sc. Per. NumDecimalPlace. 2 PoolSize. 1, ridge. 0.1 Tolarence. 1.0E-8, Seed. 2
<i>NBT</i>	BatchSize. 100, Seed. 1 NumDecimal Places. 2	<i>Bagging</i>	BatchSize. 100 BagSizepercent. 100 Classifier. DecisionStump NumDecimalPlaces. 2 NumExecutionSlots. 1 Seed. 1, NumIteration. 10	<i>VPRC</i>	BatchSize. 100 Exponent. 2. NumDecimalPlace. 2 NumIteration. 1 Seed. 2
<i>ADT</i>	BatchSize. 100, Seed. 1 NumDecimal Places. 2 NumofBoostingIteration. 10	<i>RC</i>	BatchSize. 100 Classifier. RamdomTree NumDecimalPlaces. 2 Seed. 1, NumIteration. 10	<i>SGD</i>	BatchSize. 100, epochs. 100 Epsilon. 0, Lamda. 0.001 Learningrate. 0.0025 Lossfunc. Log loss(LR)

Tablo 5’ te 10 kat çapraz doğrulama şartlarında MÖ yöntemlerin temel metrikler açısından performansları gösterilmiştir. Deneysel sonuçlar kategorik temelde karşılaştırıldığında değerlendirmeler şu şekilde sunulabilir: Ağaç kategorisinde Duyarlılık metriği dışında 0.86383 Doğruluk, 0.8718 Kesinlik, 0.8778 F-skor ve 0.9300 AUC değeri ile en yüksek performansı ADT yöntemi elde etmiştir. Bu kategoride Duyarlılık metriği açısından en iyi performansa 0.8976 değeri ile NBT yöntemi ulaşmıştır. Ağaç kategorisinde RT; 0.70915 Doğruluk, 0.7444 Kesinlik, 0.7224 Duyarlılık, 0.7333 F-skor ve 0.7430 AUC değerleri ile en düşük performansa sahip yöntem olmuştur. Meta

kategorisinde AUC metriği dışında 0.8682 Doğruluk, 0.8617 Kesinlik, 0.9075 Duyarlılık ve 0.8840 F-skor değerleri ile LBST en yüksek performansı sergilemiştir. Bu kategoride 0.9220 ile en yüksek AUC değerine sahip ABST yöntemine göre LBST 0.0030 daha düşük bir AUC performansı ortaya koymuştur. Meta kategorisinde RC yöntemi Doğruluk, Kesinlik, Duyarlılık ve F-skor metrikleri açısından sırası ile 0.7756, 0.7786, 0.8307 ve 0.8038 değerleri ile en düşük performansa sahip olurken, AUC metriğinde bu sonucu 0.7900 değeri ile Bagging yöntemi ortaya koymuştur. Fonksiyon kategorisinde ise Kesinlik metriği dışında 0.8725 Doğruluk, 0.9173 Duyarlılık, 0.8885 F-skor ve 0.9240 AUC


değerleri ile RBFC yöntemi en yüksek performansa ulaşmıştır. Kesinlik metriğinde ise en iyi sonuç 0.8640 değeri ile SGD yönteminden elde edilmiştir. Bu kategoride Kesinlik metriği dışında tüm metrikler açısından en düşük performansı MLPC yöntemi ortaya koymuştur. MLPC bu sonucu 0.8333 Doğruluk, 0.8386 Duyarlılık, 0.8478 F-skor ve 0.8520 AUC değerleri ile elde etmiştir. Kesinlik metriğinde en düşük performansa sahip yöntem 0.8521 değeri ile VPRC olmuştur. Sonuçlar genel performans bazında değerlendirildiğinde Doğruluk, Duyarlılık ve F-skor metrikleri açısından 0.8725, 0.9173 ve 0.8885 değerleri ile RBFC yönteminin, Kesinlik ve AUC metrikleri açısından ise 0.8718 ve 0.9300 değerleri ile ADT yönteminin en yüksek performansı ortaya koyduğu gözlenmiştir.

Tablo 5. 10 kat çapraz doğrulama şartlarında MÖ yöntemlerin temel metrikler açısından performansları


Kategori	Yöntem	Acc	Prec	Rec	F-scr	AUC
Ağaç	J48	0.8203	0.8147	0.8740	0.8433	0.8110
	RF	0.8007	0.7949	0.8622	0.8272	0.8620
	RT	0.7092	0.7444	0.7224	0.7333	0.7430
	NBT	0.8508	0.8429	0.8976	0.8694	0.9100
	ADT	0.8638	0.8718	0.8839	0.8778	0.9300
Meta	ABST	0.8573	0.8590	0.8878	0.8732	0.9220
	LBST	0.8682	0.8617	0.9075	0.8840	0.9190
	Dagging	0.8192	0.8226	0.8583	0.8401	0.8750
	RC	0.7756	0.7786	0.8307	0.8038	0.8410
Fonksiyon	SVM	0.8693	0.8579	0.9154	0.8857	0.8640
	MLPC	0.8333	0.8571	0.8386	0.8478	0.8520
	RBFC	0.8725	0.8614	0.9173	0.8885	0.9240
	VPRC	0.8562	0.8521	0.8957	0.8733	0.8680
	SGD	0.8606	0.8640	0.8878	0.8757	0.9160

Şekil 2' de 10 kat çapraz doğrulama şartlarında ağaç, meta ve fonksiyon kategorisinde yer alan yöntemlerin hata ölçüm metrikleri açısından gösterdiği performanslar verilmiştir. Ağaç kategorisindeki yöntemlerin hata metrikleri açısından karşılaştırmasını gösteren Şekil 2.a' dan anlaşılacağı üzere en yüksek performansları 0.1024 değeri ile NBT yöntemi FNR metriğinden, 0.1610 ve 0.1362 değerleri ile ADT yöntemi FPR ve MCR metriklerinden elde etmişlerdir. Bu kategoride tüm metrikler açısından en düşük performansa 0.2776 FNR, 0.3073 FPR ve 2908 MCR değerleri ile RT yöntemi sahip olmuştur. Şekil 2.b' deki performans sonuçlarından LBST yönteminin FNR ve MCR metrikleri açısından 0.0925 ve 0.1318 değerleri en yüksek performansa sahip olduğu ve FPR metriğinde 0.1805 değeri ile ABST yöntemi ile birlikte en yüksek performansı sergilediği görülmektedir. Meta kategorideki yöntemler için sonuçlar en düşük performans açısından değerlendirildiğinde 0.1693 FNR, 0.2927 FPR ve 0.2244 MCR değerleri ile RC yönteminin bu sonuca ulaştığı anlaşılmaktadır. Şekil 2.c' deki performans sonuçları, fonksiyon kategorisindeki RBFC yönteminin FNR ve MCR metrikleri açısından en yüksek performansı sırası ile 0.0827 ve 0.1275 değerleri ile elde ettiğini göstermiştir. FPR metriği açısından en iyi performans ise 0.1732 değeri ile SGD ve MLPC yöntemleri arasında paylaşılmıştır. Bu kategoride en düşük performansa FNR ve MCR metriklerinde 0.1614 ve 0.1667 değerleri ile MLPC


yöntemi ve FPR metriğinde 0.1927 değeri ile VPRC yöntemi sahip olmuştur.



(a)




(b)



(c)

Şekil 2. 10 kat çapraz doğrulama şartlarında ağaç, meta ve fonksiyon kategorisinde yer alan yöntemlerin kategorik olarak hata ölçüm metrikleri açısından gösterdiği performanslar: (a) ağaç kategorisi, (b) meta kategorisi ve (c) fonksiyon kategorisi.

Genel performans olarak en iyi ve en kötü performansa sahip yöntem, her bir kategoriden iki en yüksek ve bir en düşük performansa sahip toplam dokuz MÖ yöntemi dikkate alınarak yapılan analizler sonucu belirlenmiştir. Bu kapsamda analiz edilen dokuz MÖ yönteminin hata ölçüm metrikleri açısından performanslarının karşılaştırılması Şekil 3’ te gösterilmiştir. Şekil üzerinde verilen performans sonuçları bize tüm yöntemler arasında FNR ve MCR metriklerinde 0.0827 ve 0.1275 değerleri ile RBFC yönteminin ve FPR metriğinde 0.1610 değeri ile ADT yönteminin en yüksek performansı elde ettiğini göstermiştir. Tüm metrikler açısından en düşük performansa ise 0.2776 FNR, 0.3073 FPR ve 0.2908 MCR değerleri ile RT yöntemi sahip olmuştur.



Şekil 3. 10 kat çapraz doğrulama şartlarında tüm kategoriler içerisinde en yüksek ve en düşük performansa sahip yöntemlerin hata ölçüm metrikleri açısından karşılaştırılması

5. Sonuçlar

Dünya genelinde ciddi sağlık sorunlarından biri olarak ifade edilen kalp yetmezliğinin erken teşhisi, onun seyrini değiştirerek etkin tedavi sürecini başlatabilir. Bu durum bir yandan hastanın yaşam kalitesini artırabilirken, diğer taraftan onun sağlık durumu sonuçlarına da olumlu yönde yansiyebilir. Literatürdeki çalışmalar bize büyük veri setlerinde derinlemesine analiz yapma kabiliyeti ve karmaşık ilişkileri saptama yeteneği sayesinde MÖ yöntemlerinin kalp yetmezliği hastalığı teşhisinde geleneksel yöntemlere göre ön planda olduğunu gösteriyor. Bu bağlamda bu çalışma; farklı kategoride yer alan farklı tip MÖ yöntemlerinin kalp yetmezliği teşhisindeki etkinliğini göstermek için bir modelin oluşturulması ve bu model üzerinden kategorik ve genel olarak MÖ yöntemlerinin analiz ve değerlendirmelerini içerir. MÖ yöntemleri olarak ağaç, meta ve fonksiyon kategorisinin her birinden 5 adet olmak üzere toplam 15 algoritma kullanılmıştır. Doğru bir performans ölçümü gerçekleştirebilmek için hem Doğruluk, Kesinlik, Duyarlılık, F-skör ve AUC ölçümlerini içeren sınıflandırma problemlerinin temel metrikleri hem de FNR, FPR ve MCR gibi hata ölçümünü esas alan metriklerden yararlanılmıştır. Deneysel çalışmalar kategorik temelde ele alındığında ağaç kategorisinde Duyarlılık ve FNR metrikleri dışındaki metriklerde ADT yönteminin, meta kategorisinde AUC metriği dışında metriklerde LBST yönteminin

ve fonksiyon kategorisinde Kesinlik ve FPR metrikleri dışındaki metriklerde RBFC yönteminin en yüksek performansı ortaya koyduğunu göstermiştir. Meta ve fonksiyon kategorilerinde LBST ve RBFC yöntemlerinin başarısız gözüktüğü metrikler AUC ve Kesinlik için ABST ve SGD yöntemleri daha başarılı gözükseler de bu metrikler açısından dört yöntemde de performans sonuçlarının birbirine oldukça yakın olduğu gözlenmiştir. Tüm yöntemler genelinde sonuçlar değerlendirildiğinde Doğruluk, Duyarlılık, F-skör, FNR ve MCR metriklerinde RBFC yöntemi, Kesinlik, AUC ve FPR metriklerinde ADT yönteminin en yüksek performansa sahip olduğu görülmüştür. Bu yöntemlerde Duyarlılık, F-skör, AUC ve FNR metrikleri açısından skorların birbirine oldukça yakın olduğu dikkate alındığında her iki metodunda kalp yetmezliği teşhisinde başarılı bir şekilde kullanılabileceği sonucuna varabiliriz. Gelecek çalışmamızda kalp hastalıklarının teşhisinde yüksek doğruluklu tahminler elde edebilmek için makine öğrenme ve derin öğrenme algoritmalarının avantajlarını birleştiren hibrid modellerin oluşturulması planlanmaktadır. Oluşturulan modeller ile büyük veri setlerinin özellikleri çıkartılarak etkili tahminler yapılması hedeflenmektedir.

6. Kaynaklar

- [1] WHO, “Cardiovascular Diseases (CVDs),” [Online]. Available: [https://www.who.int/news-room/factsheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/factsheets/detail/cardiovascular-diseases-(cvds)) (Accessed; Sep. 19, 2023).
- [2] S. Bozkurt Keser and K. Keskin, “Kalp Yetmezliği Hastalarının Sağ Kalım Tahmini: Sınıflandırmaya Dayalı Makine Öğrenmesi Algoritmalarının Bir Uygulaması,” *Afyon Kocatepe University Journal of Sciences and Engineering*, vol. 23, no. 2, pp. 362–369, May 2023, doi: 10.35414/AKUFEMUBID.1033377.
- [3] G. Gürgen and S. Serttaş, “Kalp Yetmezliği Hastalığının Erken Teşhisinde Makine Öğrenimi Algoritmalarının Performans Karşılaştırması,” *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, vol. 165, no. 10, pp. 165–174, 2023, doi: 10.5281/zenodo.8238065.
- [4] SBSGM, “Sağlık İstatistikleri Yıllığı 2019,” Ankara, 2019. [Online]. Available: <https://sbsgm.saglik.gov.tr/Eklenti/40564/0/saglik-istatistikleri-yilligi-2019pdf.pdf> (Accessed: Nov. 07, 2023).
- [5] O. Gold and A. Iorshase, “Heart failure prediction framework using random forest and J48 with Adaboost algorithms,” *Science World Journal*, vol. 18, no. 2, pp. 165–175, Oct. 2023, doi: 10.4314/SWJ.V18I2.1.
- [6] S. Kaushik and R. Birok, “Heart Failure prediction using Xgboost algorithm and feature selection using feature permutation,” *IEEE International Conference on Electrical, Computer and Communication Technologies*, 2021, pp.1-6, doi: 10.1109/ICECCT52121.2021.9616626.
- [7] N. S. Mansur Huang, Z. Ibrahim, and N. Mat Diah, “Machine learning techniques for early heart failure prediction / Nur Shahellin Mansur Huang, Zaidah Ibrahim and Norizan Mat Diah,” 2021, [Online]. Available: <https://mjoc.uitm.edu.my/> (Accessed: Nov. 07, 2023).

- [8] Z. Masetic and A. Subasi, "Congestive heart failure detection using random forest classifier," *Comput Methods Programs Biomed*, vol. 130, pp. 54–64, Jul. 2016, doi: 10.1016/J.CMPB.2016.03.020.
- [9] S. Kermani, M. Ghelich Oghli, A. Mohammadzadeh, and R. Kafieh, "NF-RCNN: Heart localization and right ventricle wall motion abnormality detection in cardiac MRI," *Physica Medica*, vol. 70, pp. 65–74, Feb. 2020, doi: 10.1016/J.EJMP.2020.01.011.
- [10] K. A. Lara Hernandez, T. Rienmüller, D. Baumgartner, and C. Baumgartner, "Deep learning in spatiotemporal cardiac imaging: A review of methodologies and clinical usability," *Comput Biol Med*, vol. 130, Mar. 2021, doi: 10.1016/J.COMPBIOMED.2020.104200.
- [11] N. Lessmann et al., "Deep convolutional neural networks for automatic coronary calcium scoring in a screening study with low-dose chest CT," <https://doi.org/10.1117/12.2216978>, vol. 9785, pp. 255–260, Mar. 2016, doi: 10.1117/12.2216978.
- [12] N. Zhang et al., "Deep Learning for Diagnosis of Chronic Myocardial Infarction on Nonenhanced Cardiac Cine MRI," *Radiology*, vol. 291, no. 3, pp. 606–607, 2019, doi: 10.1148/RADIOLOGY.2019182304.
- [13] M. Porumb, E. Iadanza, S. Massaro, and L. Pecchia, "A convolutional neural network approach to detect congestive heart failure," *Biomed Signal Process Control*, vol. 55, pp. 101597, Jan. 2020, doi: 10.1016/J.BSPC.2019.101597.
- [14] A. N. Shihab, M. J. Mokarrama, R. Karim, S. Khatun, and M. S. Arefin, "An iot-based heart disease detection system using rnn," *Advances in Intelligent Systems and Computing*, vol. 1200 AISC, pp. 535–545, 2021, doi: 10.1007/978-3-030-51859-2_49/COVER.
- [15] G. Maragatham and S. Devi, "LSTM Model for Prediction of Heart Failure in Big Data," *J Med Syst*, vol. 43, no. 5, pp. 1–13, May 2019, doi: 10.1007/S10916-019-1243-3.
- [16] S. Gao, Y. Zheng, and X. Guo, "Gated recurrent unit-based heart sound analysis for heart failure screening," *Biomed Eng Online*, vol. 19, no. 1, Jan. 2020, doi: 10.1186/S12938-020-0747-X.
- [17] A. Çınar and S. A. Tuncer, "Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid CNN-SVM deep neural networks," *Comput Methods in Biomech and Biomed Engin*, vol. 24, no. 2, pp. 203–214, 2021, doi: 10.1080/10255842.2020.1821192.
- [18] D. Li, X. Li, J. Zhao, and X. Bai, "Automatic staging model of heart failure based on deep learning," *Biomed Signal Process Control*, vol. 52, pp. 77–83, Jul. 2019, doi: 10.1016/J.BSPC.2019.03.009.
- [19] V. K. Sudha and D. Kumar, "Hybrid CNN and LSTM Network for Heart Disease Prediction," *SN Comput Sci*, vol. 4, no. 2, pp. 172, Mar. 2023, doi: 10.1007/S42979-022-01598-9.
- [20] L. Ali et al., "An Optimized Stacked Support Vector Machines Based Expert System for the Effective Prediction of Heart Failure," *IEEE Access*, vol. 7, pp. 54007–54014, 2019, doi: 10.1109/ACCESS.2019.2909969.
- [21] Y. Chen, X. Qin, L. Zhang, and B. Yi, "A Novel Method of Heart Failure Prediction Based on DPCNN-XGBOOST Model," *Computers Materials & Continua*, vol. 65, no. 1, pp. 495–510, Jul. 2020, doi: 10.32604/CMC.2020.011278.
- [22] V. Grgić, D. Mušić, and E. Babović, "Model for predicting heart failure using Random Forest and Logistic Regression algorithms," *IOP Conf Ser Mater Sci Eng*, vol. 1208, no. 1, pp. 012039, Nov. 2021, doi: 10.1088/1757-899X/1208/1/012039.
- [23] N. Foziljonova and I. Wasito, "Prediction of survival rate of heart failure patients using machine learning techniques," *J Theor Appl Inf Technol*, vol. 100, no. 9, pp. 2703–2714, May 2022, [Online]. Available: <https://www.jatit.org/volumes/Vol100No9/2Vol100No9.pdf> (Accessed: Nov. 07, 2023).
- [24] M. Mudassar, M. Afzal, and T. Muhammad, "A Machine Learning Based Predictive Model to Diagnose Heart Failure Patients using Imbalanced Classification Problem," In *2023 4th International Conference on Advancements in Computational Sciences, ICACS 2023 - Proceedings, 2023*, pp. 1–8, doi: 10.1109/ICACS55311.2023.10089759.
- [25] M. Zeng, "The Prediction of Heart Failure based on Four Machine Learning Algorithms," *Highlights in Science Engineering and Technology*, vol. 39, pp. 1377–1382, Apr. 2023, doi: 10.54097/HSET.V39I.6771.
- [26] C. Coşkun and F. Kuncan, "Evaluation of Performance of Classification Algorithms in Prediction of Heart Failure Disease," *KSÜ Mühendislik Bilimleri Dergisi*, vol. 25, no. 4, pp. 622–632, Dec. 2022, doi: 10.17780/KSUJES.1144570.
- [27] fedesoriano., "Heart Failure Prediction Dataset," [Online]. Available: <https://www.kaggle.com/datasets/fedesoriano/heart-failure-prediction> (Accessed: Nov. 08, 2023).
- [28] C. N. Villavicencio, J. J. E. Macrohon, X. A. Inbaraj, J. H. Jeng, and J. G. Hsieh, "Covid-19 prediction applying supervised machine learning algorithms with comparative analysis using weka," *Algorithms*, vol. 14, no. 7, pp. 1–22, Jul. 2021, doi: 10.3390/A14070201.
- [29] Ç. Cem Berke, "Rastgele Orman Algoritması," [Online]. Available: <https://medium.com/@cemthecebi/rastgele-orman-algoritmas%C4%B1-1600ca4f4784> (Accessed: Sep. 08, 2023).
- [30] S. Gayathri, A. K. Krishna, V. P. Gopi, and P. Palanisamy, "Automated Binary and Multiclass Classification of Diabetic Retinopathy Using Haralick and Multiresolution Features," *IEEE Access*, vol. 8, pp. 57497–57504, 2020, doi: 10.1109/ACCESS.2020.2979753.
- [31] J. Li, H. Peng, H. Hu, Z. Luo, and C. Tang, "Multimodal Information Fusion for Automatic Aesthetics Evaluation of Robotic Dance Poses," *Int J Soc Robot*, vol. 12, no. 1, pp. 5–20, Jan. 2020, doi: 10.1007/S12369-019-00535-W/METRICS.
- [32] Y. Zhao and Y. Zhang, "Comparison of decision tree methods for finding active objects," *Advances in Space Research*, vol. 41, no. 12, pp. 1955–1959, 2008, doi: 10.1016/J.ASR.2007.07.020.

- [33] E. Doğru, "Makine Öğrenmesi Teknikleri Kullanarak Hizmet Aksatma Saldırıları Tespiti," Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2020.
- [34] H. Yan and W. Chen, "Landslide susceptibility modeling based on GIS and ensemble techniques," *Arabian Journal of Geosciences*, vol. 15, no. 8, pp. 1–22, Apr. 2022, doi: 10.1007/S12517-022-09974-8.
- [35] Y.-S. Chen et al., "Comparable Studies of Financial Bankruptcy Prediction Using Advanced Hybrid Intelligent Classification Models to Provide Early Warning in the Electronics Industry," *Mathematics*, vol. 9, pp. 2622, vol. 9, no. 20, pp. 2622, Oct. 2021, doi: 10.3390/MATH9202622.
- [36] K. Khosravi, Z. Sheikh Khozani, and J. Hatamiafkoueih, "Prediction of embankments dam break peak outflow: a comparison between empirical equations and ensemble-based machine learning algorithms," *Natural Hazards*, vol. 118, no. 3, pp. 1989–2018, Sep. 2023, doi: 10.1007/S11069-023-06060-4.
- [37] B. T. Pham et al., "GIS-based ensemble soft computing models for landslide susceptibility mapping," *Advances in Space Research*, vol. 66, no. 6, pp. 1303–1320, Sep. 2020, doi: 10.1016/J.ASR.2020.05.016.
- [38] F. Bulut, "Simflandırıcı Topluluklarının Dengesiz Veri Kümeleri Üzerindeki Performans Analizleri," *Bilişim Teknolojileri Dergisi*, vol. 9, no. 2, pp. 153–159, 2016, [Online]. Available: <http://search.yayin/detay/220680> (Accessed: Nov. 08, 2023).
- [39] P. Ghosh et al., "Efficient prediction of cardiovascular disease using machine learning algorithms with relief and lasso feature selection techniques," *IEEE Access*, vol. 9, pp. 19304–19326, 2021, doi: 10.1109/ACCESS.2021.3053759.
- [40] B. T. Pham and I. Prakash, "Evaluation and comparison of LogitBoost Ensemble, Fisher's Linear Discriminant Analysis, logistic regression and support vector machines methods for landslide susceptibility mapping," *Geocarto Int.*, vol. 34, no. 3, pp. 316–333, Feb. 2019, doi: 10.1080/10106049.2017.1404141.
- [41] M. H. Kamarudin, C. Maple, T. Watson, and N. S. Safa, "A LogitBoost-Based Algorithm for Detecting Known and Unknown Web Attacks," *IEEE Access*, vol. 5, pp. 26190–26200, Nov. 2017, doi: 10.1109/ACCESS.2017.2766844.
- [42] M. Kaya Keleş, "Breast cancer prediction and detection using data mining classification algorithms: A comparative study," *Tehnicki Vjesnik*, vol. 26, no. 1, pp. 149–155, Feb. 2019, doi: 10.17559/TV-20180417102943.
- [43] Akca MF, "Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2)." [Online]. Available: <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makinelerimakine%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e> (Accessed: Sep. 10, 2023).
- [44] M. P. Akhter, Z. Jiangbin, I. R. Naqvi, M. Abdelmajeed, A. Mehmood, and M. T. Sadiq, "Document-Level Text Classification Using Single-Layer Multisize Filters Convolutional Neural Network," *IEEE Access*, vol. 8, pp. 42689–42707, 2020, doi: 10.1109/ACCESS.2020.2976744.
- [45] M. A. Hussain and L. Gogoi, "Performance analyses of five neural network classifiers on nodule classification in lung CT images using WEKA: a comparative study.," *Phys Eng Sci Med*, vol. 45, no. 4, pp. 1193–1204, Dec. 2022, doi: 10.1007/S13246-022-01187-3.
- [46] W. Chen et al., "Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren County, Jiangxi Province, China," *Science of the Total Environment*, vol. 626, pp. 1121–1135, Jun. 2018, doi: 10.1016/J.SCITOTENV.2018.01.124.
- [47] C. Eyüpoğlu, "Büyük Veride Etkin Gizlilik Koruması İçin Yazılım Tasarımı," *Doktora Tezi*, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2018.
- [48] A. Firdaus, N. B. Anuar, M. F. A. Razak, and A. K. Sangaiah, "Bio-inspired computational paradigm for feature investigation and malware detection: interactive analytics," *Multimed Tools Appl*, vol. 77, no. 14, pp. 17519–17555, Jul. 2018, doi: 10.1007/S11042-017-4586-0/METRICS.
- [49] J. Huang, S. Ling, X. Wu, and R. Deng, "GIS-Based Comparative Study of the Bayesian Network, Decision Table, Radial Basis Function Network and Stochastic Gradient Descent for the Spatial Prediction of Landslide Susceptibility," *Land (Basel)*, vol. 11, no. 3, pp.436, Mar. 2022, doi: 10.3390/LAND11030436.
- [50] T. Srinivas et al., "Novel Based Ensemble Machine Learning Classifiers for Detecting Breast Cancer," *Math. Probl. in Eng.*, vol. 2022, pp.1-15, May 2022, doi: 10.1155/2022/9619102.
- [51] H. Torun, "Karışıklık Matrisi (Confusion Matrix)," [Online]. Available: <https://hakan.io/karistiklik-matrisi-confusion-matrix/> (Accessed: Sep. 15, 2023).
- [52] Y. Tang, "Python Algorithms: Accuracy, Precision, Recall, and F Score." [Online]. Available: <https://pythonalgorithms.com/2022/05/16/accuracy-precision-recall-and-f-score/> (Accessed: Sep. 17, 2023).
- [53] Ş. Ay, "Model Performansını Değerlendirmek — Metrikler," [Online]. Available: <https://medium.com/deep-learningturkiye/modelperformans%C4%B1n%C4%B1de%C4%9Ferlendirmek-metrikler-cb6568705b1> (Accessed: Sep. 17, 2023).

Özgeçmiş



İsmail Atacak, 1972 yılında Konya’da doğdu, 1994 yılında Gazi Üniversitesi Elektronik ve Bilgisayar Eğitimi Bölümünden mezun oldu. 1998 ve 2005 yıllarında Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik-Bilgisayar Eğitimi Anabilim dalında sırası ile Yüksek Lisans ve Doktora eğitimlerini tamamladı. 2007-2012 yılları arasında Teknik Eğitim Fakültesi, Elektronik ve Bilgisayar Eğitimi Bölümünde Yardımcı Doçent olarak görev yaptıktan sonra, aynı üniversitenin Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümünde çalışmaya başladı ve halen bu bölümde Dr. Öğr. Üyesi olarak çalışmaya devam etmektedir. Bulanık Mantık, Makine Öğrenmesi, Derin Öğrenme, Optimizasyon Algoritmaları ve Veri Bilmi ilgi duyduğu araştırma alanları arasında yer alır.

Panoramik Radyograflarda Diş Tiplerinin Sınıflandırılması için Derin Öğrenme Yöntemlerinin Karşılaştırılması

Comparison of Deep Learning Methods for Classification of Tooth Types in Panoramic Radiographs

Berrin Çelik^{1*}, Mehmet Zahid Genç², Mahmut Emin Çelik^{2,3}

¹ Oral and Maxillofacial Radiology Department, Faculty of Dentistry, Ankara Yıldırım Beyazıt University, Ankara, Turkey

² Electrical Electronics Engineering Department, Faculty of Engineering, Gazi University, Ankara, Turkey

³ Biomedical Calibration and Research Center, Gazi University Hospital, Gazi University, Ankara, Turkey

ÖZ

Diş tipi sınıflandırması teşhis, tedavi ve planlamada rutin olarak gerçekleştirilir. Dijital diş hekimliğine doğru, zaman alan geleneksel yaklaşımlar yerine işlemlerin otomatik olarak gerçekleştirilmesi değerlidir. Bu çalışma, diş tiplerini sınıflandırmak için yeni bir derin öğrenme modeli önermektedir. Bu çalışma, diş türlerini sınıflandırmak için yeni bir model olan ZNet'i önermekte ve performansını önde gelen derin öğrenme modelleriyle karşılaştırmaktadır. Panoramik görüntülerdeki diş türleri köpek diş, kesici diş, ön azı diş ve azı diş olmak üzere 4 sınıfa ayrılmıştır. Bu çalışmada ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception ve önerilen ZNet olmak üzere 7 farklı derin öğrenme modelinin performansı incelenmiştir. Model performansları Accuracy, Precision, Recall ve F1-score metrikleri kullanılarak değerlendirilmiştir. Önerilen model ZNet için Doğruluk, Kesinlik, Duyarlılık ve F1-skoru sırasıyla %95,79, %84,10, %94,80 ve %87,60'tur.

Önerilen model diğerlerinden daha iyi performans göstermiştir. Bulgular, derin öğrenme modellerinin diş türlerinin sınıflandırılmasında doğru tahminler sağlayan güvenilir araçlar olduğunu göstermiştir.

Anahtar kelimeler: diş, sınıflandırma, yapay zeka, derin öğrenme, panoramik radyografi

ABSTRACT

Tooth type classification is routinely performed in diagnosis, treatment, and planning. Towards digital dentistry, it is valuable to perform processes automatically instead of time-consuming conventional approaches. This work suggests a novel deep learning model to classify tooth types. This study proposes a new model, ZNet, for classifying tooth types and compares its performance with the leading deep learning models. The tooth types in panoramic images are categorized into 4 classes: incisor, canine, premolar and molar. This study investigates the

performance of 7 different deep learning models, namely ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception and the proposed ZNet. Model performances are evaluated using Accuracy, Precision, Recall and F1-score metrics. Accuracy, Precision, Recall and F1-score for the proposed model ZNet are 95.79%, 84.10%, 94.80% and 87.60% respectively. The proposed model outperformed the others. Findings showed deep learning models have been shown to be reliable tools providing accurate predictions in the classification of tooth types.

Keywords: teeth, classification, artificial intelligence, deep learning, panoramic radiograph

Giriş

Diş tiplerinin belirlenmesi, günümüz diş hekimliği uygulamalarında basit ve temel bir adımdır. Diş tipleri hekimler arasında teşhis, tedavi ve ileri planlama süreçlerinde kullanılır. Diş tipi sınıflandırması, dişlerin şekil, fonksiyon ve konum gibi çeşitli özelliklerine göre kategorize edilmesi ve gruplandırılmasıdır. İnsan dişleri dört ana tipte sınıflandırılır: kesici dişler, köpek dişleri, küçük azı dişleri ve azı dişleri. Her türün kesme, yırtma, öğütme gibi belirli bir işlevi vardır. Bu diş türleri farklı şekilde konumlandırılır ve kendi özel amaçlarına hizmet etmek için farklı şekillere sahiptir.

Diş hekimliğinde yapay zeka (AI), röntgen, BT taramaları ve ağız içi görüntüler gibi tanısal görüntüleri analiz eden algoritmalar aracılığıyla manuel süreçleri otomatikleştirerek diş sorunlarını tanımlar. Ayrıca yapay zeka, hasta verilerine dayalı olarak potansiyel ağız sağlığı sorunlarının erken tespitine yardımcı olarak önleyici analitiğe katkıda bulunur ve sonuçta önleyici bakım stratejilerini optimize eder [1-3]. Benzer şekilde, tüm dişlerin tanımlanmasının geleneksel yöntemlerle manuel olarak yürütülmesi yalnızca zaman alıcı olmakla kalmaz, aynı zamanda uzman gücünün rehberliğini de etkileyebilir.

Diş hekimliğinde manuel süreçlerin otomatikleştirilmesi çeşitli avantajlar sunmaktadır: (i) otomasyonun çeşitli görevler için gereken süreyi azaltması sayesinde artan verimlilik, (ii) otomatik görevlerin manuel işlerle ilişkili işgücü maliyetlerini azaltabilmesi sayesinde maliyet tasarrufu, (iii) diş hekimleri ve personelinin diğer görevlere aşırı zaman harcamak yerine hasta bakımı ve karmaşık prosedürlere daha fazla odaklanabilmesi sayesinde artan verimlilik. Bu bağlamda, yapay zeka teknolojilerinin, özellikle de derin öğrenme alanındaki gelişmeler, diş sınıflandırma

süreçlerinin otomatikleştirilmesi ve bu alandaki verimliliğin artırılması için önemli bir fırsat sunmaktadır.

Gelişen yapay zekâ teknolojileri, çeşitli diş türlerini içeren büyük bir veri kümesi üzerinde uygulanarak sınıflandırma modellerinin gerçek dünyadaki çeşitliliğe daha etkin bir şekilde uyum sağlamasına olanak tanımıştır. Bu çalışma, diş türlerini sınıflandırmak için yeni bir derin öğrenme modeli önermektedir. Ayrıca, performanslar son teknoloji sınıflandırma modelleri ile karşılaştırılmıştır. ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception ve Znet olmak üzere yedi farklı derin öğrenme modeli bu sınıflandırma problemini çözmek için eğitilmiştir. Bu modellerin performansı doğruluk, kesinlik, duyarlılık ve F1-skor metrikleri kullanılarak değerlendirilmiştir.

Materyal Metot

Veri kümesi, Tufts Dental Dataset'in [4] panoramik radyografilerinden kırılmış 10.876 diş görüntüsünü içermektedir. Görüntüler köpek diş, kesici diş, ön azı diş ve azı diş olmak üzere 4 farklı diş türüne göre sınıflandırılmıştır. Sınıf dağılımları kesici diş, köpek dişi, ön azı diş ve azı diş için sırasıyla 3176, 1621, 2745 ve 3334'tür. Görüntüler bir ağız diş ve çene radyoloji (en az 7 yıllık deneyime sahip) uzmanı diş hekimi tarafından kırılmış ve kontrol edilmiştir. Şekil 1 bu kategorilere ait farklı örnekleri sırasıyla sunmaktadır. Veri kümesi eğitim için %70, doğrulama için %20 ve test için %10'a bölünmüştür. Görüntü boyutları eğitim sürecinden önce standartlaştırılmıştır.

Atlanan bağlantılar, U-Net mimarisinden esinlenerek düşük seviyeli özellikleri doğrudan yüksek seviyeli özelliklere ileterek performansı artırmayı amaçlamaktadır. Modelimizin düşük seviyeli özellikleri yüksek seviyeli katmanlardaki daha karmaşık özelliklere ilemesini sağladılar. Düşük seviyeli özellikler tipik olarak daha temel ve yerel bilgilere sahipken, yüksek seviyeli özellikler özet bilgileri temsil ediyordu.

Modellerin performansı doğruluk, kesinlik, duyarlılık ve F1-skoru gibi iyi bilinen sınıflandırma metrikleriyle değerlendirilmiştir. Modeller ayrıca bu metriklere göre karşılaştırılmıştır. Doğruluk, doğru tahmin edilen örneklerin toplam örneklere oranını hesaplayarak modelin genel doğruluğunu ölçer. Kesinlik, pozitif tahminlerin doğruluğuna odaklanır. Doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitiflere oranını ölçer. Yüksek hassasiyet, düşük yanlış pozitif oranını gösterir. Duyarlılık, modelin tüm pozitif örnekleri yakalama yeteneğini değerlendirir. Doğru tahmin edilen pozitif gözlemlerin toplam gerçek pozitiflere oranını ölçer. Yüksek duyarlılık, düşük yanlış negatif oranını gösterir. F1 puanı, hassasiyet ve duyarlılığın harmonik ortalamasıdır. Hassasiyet ve duyarlılık arasında bir denge sağlar. Yüksek değerlerin hassasiyet ve duyarlılık arasında daha iyi bir denge olduğunu gösterdiği 0 ile 1 arasında değişir. Tablo 1 kullanılan metriklere dair formülleri göstermektedir.

Tablo 1. Sınıflandırma performansında kullanılan değerlendirme metrikleri

Değerlendirme Metrikleri	
Doğruluk	(Doğru Tahmin Sayısı) / (Toplam Tahmin Sayısı)
Hassasiyet	(Doğru Pozitifler) / (Doğru Pozitifler + Yanlış Pozitifler)

Duyarlılık	(Doğru Pozitifler) / (Doğru Pozitifler + Yanlış Negatifler)
F1-Skor	$2 * (\text{Hassasiyet} * \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık})$

Sonuçlar

Modeller aynı eğitim, doğrulama ve test seti kullanılarak ayrı ayrı eğitilmiştir. Model tahminleri karışıklık matrisi ile hesaplanmıştır. Tablo 2'de tüm modeller için test seti, görülmeyen veriler ile çıktı metrikleri sunulmuştur.

Tablo 2. Tüm modeller için sınıflandırma performansı

Model	Doğruluk (%)	Hassasiyet (%)	Duyarlılık (%)	F1 Skor (%)
<i>DenseNet</i>	87.25	82.20	83.30	82.60
<i>EfficientNet</i>	76.03	66.70	70.20	%68.40
<i>Inception</i>	65.14	54.70	58.10	68.40
<i>ResNet-50</i>	80.05	73.80	75.90	74.60
<i>VGG-19</i>	83.99	72.20	78.90	74.30
<i>Xception</i>	81.52	70.00	76.40	73.30
<i>ZNet</i>	95.79	84.10	94.80	87.60

Sınıflandırma doğrulukları %65,14 ile %95,79 arasında değişirken F1 skoru %68,4 ile %87,6 arasındadır. 7 modelden 5'i %80'in üzerinde sınıflandırma doğruluğu sağlamıştır. En iyi performans, diğerlerine kıyasla nispeten önemli bir farkla ZNet tarafından sağlanmıştır. Bulgular ayrıca her bir sınıf bazında analiz edilmiştir. Tablo 3, ortalama doğruluğa ek olarak her sınıf için sınıflandırma doğruluğunu göstermektedir. ZNet, %98,12 ile kesici diş sınıfı için en

yüksek doğruluğu ve %88,96 ile köpek sınıfı için en düşük doğruluğu vermiştir.

Tablo 3. Her bir kategori için sınıflandırma doğruluğu (%)

Model	Ort. Doğruluk	Köpek	Kesici	Azı Diş	Ön Azı Diş
<i>DenseNet</i>	87.25	64.42	91.22	93.43	80.80
<i>EfficientNet</i>	76.03	44.17	85.58	87.46	69.93
<i>Inception</i>	65.14	18.40	77.43	81.49	58.70
<i>ResNet-50</i>	80.05	46.01	90.28	91.64	74.28
<i>VGG-19</i>	83.99	58.28	94.36	92.54	76.81
<i>Xception</i>	81.52	50.92	88.09	89.85	81.88
<i>ZNet</i>	95.79	88.96	98.12	96.12	96.74

Tartışma

Derin öğrenme modelleri diş hekimliğinin çeşitli alanlarında, özellikle de görüntü analizinde önemli başarılar göstermiştir. Dental radyolojide, konvolüsyonel sinir ağları (CNN'ler) çürükler de dahil olmak üzere çeşitli diş vakalarını tespit etme, sınıflandırma ve segmentlere ayırma, periodontal hastalıkları tanımlama ve hatta diş ve anatomik yapıları yardımcı olma gibi görevler için kullanılmıştır [5-7]. Ayrıca, derin öğrenme modellerinin teşhis süreçlerinin doğruluğunu artırmada etkili olduğu kanıtlanmıştır [8-12]. Bu modeller, karmaşık kalıpları ve özellikleri öğrenmek için büyük veri kümelerinden yararlanarak incelikli ve doğru tahminler yapmalarını sağlar.

Diş sınıflandırması ile ilgili yakın zamanda yapılmış birkaç çalışma bulunmaktadır. Sathya ve arkadaşları AlexNet kullanarak panoramik radyografları iki adımda sınıflandırmıştır [13]. Dişlerin konumu önce üst veya alt çene olarak sınıflandırılmış, daha sonra dişler kesici, köpek, küçük azı ve büyük azı olmak üzere dört sınıftan

herhangi birine sınıflandırılmıştır. Kesici, köpek, küçük azı ve büyük azı dişleri için sırasıyla %95, %94,5, %94 ve %97,5 olmak üzere bireysel doğruluk dahil genel doğruluk %95 olarak bulunmuştur. Krois ve arkadaşları, dişlerin dört farklı kategoride sınıflandırılması için küresel ortalama ve maksimum havuzlama tekniklerini içeren yedi katmanlı bir derin evrişimli sinir ağı (CNN) kullanılmasını önermiştir: molar, premolar, kanin ve kesici diş [14]. Ortalama %87 doğruluk oranı ile diğer üç çağdaş tekniğe göre üstün performanslar elde edilmiştir. Li ve arkadaşları CBCT görüntülerini kullanarak küresel ortalama ve maksimum havuzlama ile yedi katmanlı derin CNN uygulamıştır [15]. Dişler molar, kanin, premolar ve kesici diş olmak üzere dört sınıftan herhangi birine sınıflandırılmıştır. Ortalama hassasiyet %87,0 olarak bildirilmiştir. Estai ve arkadaşları 591 ortopantomogram (OPG) görüntüsü ile kalıcı diş sınıflandırması ve tespiti için evrişimli sinir ağları (CNN) kullanan otomatik bir sistemi değerlendirmeyi amaçlamıştır [16]. Tespit için U-Net ve Faster R-CNN kullanılırken, diş sınıflandırması için VGG-16 uygulanmıştır. Diş sınıflandırması, yani numaralandırma için duyarlılık ve kesinlik 0.98'dir. Muramatsu, otomatik diş çizelgeleri için bilgisayarlı bir sistem önermiştir [17]. Dişleri tespit etmek için 100 panoramik radyografi kullanılmış, daha sonra sınırlayıcı kutular kesici dişler, köpek dişleri, premolarlar ve molarlar dahil olmak üzere dört diş tipine sınıflandırılmıştır. Diş türleri için ortalama sınıflandırma doğruluğu %93,2 olmuştur. Tuzoff, 1352 panoramik radyografi kullanarak diş tespiti ve numaralandırma için CNN'leri kullanmıştır [18]. Diş önce Faster R-CNN tarafından tespit edilmiş, ardından her bir FDI numaralandırması için sınıflandırılmıştır. Sınıflandırma VGG-16 tarafından sezgisel algoritma ile gerçekleştirilmiştir. Duyarlılık ve özgüllüğün sırasıyla 0.98 ve 0.99 olduğu bildirilmiştir. Kilic ve arkadaşları 421 panoramik radyografi kullanarak çocuklar için otomatik tespit ve numaralandırma sistemi geliştirmeyi

amaçlamışlardır [19]. Faster R-CNN ve Inception v2 kullanılmıştır. Duyarlılık, kesinlik ve F1 skoru sırasıyla 0.98, 0.95 ve 0.96 olarak raporlanmıştır. Tablo 4 mevcut çalışmanın performansını daha önceki çalışmalarla amaç, kullanılan görüntü tipi, uygulanan yöntem ve elde edilen sonuçlar olmak üzere karşılaştırmaktadır.

Tablo 4. Daha önceki çalışmalar ile mevcut çalışmanın sonuçlarının karşılaştırılması

Ref	Amaç	Görüntü	Yöntem	Sonuçlar
13	Sınıflandırma	Panoramik	AlexNet	Ortalama doğruluk: %95
14	Sınıflandırma	Panoramik	Evrişimsel Sinir Ağı	Ortalama doğruluk: %87
15	Sınıflandırma	CBCT	Evrişimsel Sinir Ağı	Ortalama doğruluk: %87
16	Tespit	Ortopantom ogram	U-Net Faster R-CNN VGG-16	Duyarlılık: 0.98 Precision: 0.98
17	Tespit	Panoramik	Evrişimsel Sinir Ağı	Doğruluk: %93.2
18	Tespit	Panoramik	Faster R-CNN VGG-16	Duyarlılık: 0.98
19	Tespit	Panoramik	Faster R-CNN Inception v2	Duyarlılık: 0.98 Kesinlik: 0.95 F1 Skor: 0.96
Bu çalışmada	Sınıflandırma	Panoramik	DenseNet EfficientNet Inception ResNet-50 VGG-19	Ortalama doğruluk: 0.65-0.95

			Xception ZNet (önerilen)	
--	--	--	--------------------------------	--

Diş hekimliğinde derin öğrenme uygulamaları büyük bir potansiyel göstermekle birlikte çeşitli sınırlamaları da beraberinde getirmektedir. Derin öğrenme modelleri eğitim için büyük miktarlarda yüksek kaliteli dengeli veri gerektirir. Belirli veri kümeleri üzerinde eğitilen modeller yeni veya farklı popülasyonlara iyi genelleme yapamayabilir. Hasta demografisi, genetiği ve coğrafi konumlardaki farklılıklar derin öğrenme modellerinin performansını ve genelleştirilebilirliğini etkileyebilir. Bu nedenle, büyük veri kümeleri çok merkezli olmalıdır. Sağlık hizmetlerinde, gizlilik endişeleri, veri siloları ve açıklamalı veya etiketli verilere sınırlı erişim gibi sorunlar nedeniyle çeşitli ve kapsamlı veri kümeleri elde etmek zor olabilir. Hasta mahremiyetini ve güvenliğini sağlarken sağlık hizmetlerinde yapay zekayı uygulamak karmaşık olabilir ve dikkatli bir değerlendirme gerektirir. Derin öğrenme modelleri, değerlendirme metrikleri açısından literatürde genellikle standart raporlamadan yoksundur. Bir raporlama formatı üzerinde fikir birliğine varılmalıdır.

Sonuç

Diş sınıflandırmasında derin öğrenme tekniklerinin uygulanması, diş türlerini kategorize etme sürecini otomatikleştirmede dikkate değer bir potansiyel ve etkinlik göstermiştir. Potansiyel olarak diş hekimlerine ve araştırmacılara teşhisleri, tedavi planlamasını hızlandırmak ve genel hasta bakımını iyileştirmek için değerli bir araç sunmaktadır.

Referanslar

- [1] Mohammad-Rahimi, H, Rokhshad, R, Bencharit, S, Krois, J, & Schwendicke, F “Deep learning: a primer for dentists and dental researchers”, *J Dent* 130:104430, 2023.
- [2] Park, W, Huh, J. K, & Lee, J H, “Automated deep learning for classification of dental implant radiographs using a large multi-center dataset”, *Sci Rep* 13(1):4862, 2023
- [3] de Queiroz Tavares Borges Mesquita, G, Vieira, W A, Vidigal, M T C, Travençolo, B A N, Beaini, T L, Spin-Neto, R, ... & de Brito Júnior, R B, “Artificial Intelligence for Detecting Cephalometric Landmarks: A Systematic Review and Meta-analysis”, *J Digit Imaging* 36(3):1158-1179, 2023
- [4] Panetta, K, Rajendran, R, Ramesh, A, Rao, S P, & Agaian, S, “Tufts dental database: a multimodal panoramic x-ray dataset for benchmarking diagnostic systems”, *IEEE J Biomed Health* 26(4):1650-1659, 2021
- [5] Huang, C, Wang, J, Wang, S, & Zhang, Y, “A review of deep learning in dentistry”, *Neurocomputing* 554:126629, 2023
- [6] Çelik, B, Savaştaer, E F, Kaya, H I, & Çelik, M E, “The role of deep learning for periapical lesion detection on panoramic radiographs”, *Dentomaxillofac Rad* 52(8):20230118, 2023.
- [7] Mohammad-Rahimi, H, Motamedian, S R, Rohban, M H, Krois, J, Uribe, S E, Mahmoudinia, E, ... & Schwendicke, F, “Deep learning for caries detection: A systematic review.”, *J Dent* 122:104115, 2022.
- [8] Jung, W, Lee, K E, Suh, B J, Seok, H, & Lee, D W, “Deep learning for osteoarthritis classification in temporomandibular joint”, *Oral Dis* 29(3):1050-1059, 2023
- [9] Umer, F, Habib, S, & Adnan, N, “Application of deep learning in teeth identification tasks on panoramic radiographs”, *Dentomaxillofac Rad* 51(5):20210504, 2022.
- [10] Çelik, B, & Çelik, M E, “Automated detection of dental restorations using deep learning on panoramic radiographs”, *Dentomaxillofac Rad* 51(8):20220244, 2022.
- [11] Celik, M E, “Deep learning based detection tool for impacted mandibular third molar teeth”, *Diagnostics* 12(4):942, 2022
- [12] Çelik, B, & Çelik, M E, “Root Dilaceration Using Deep Learning: A Diagnostic Approach”, *Appl Sci-Basel* 13(14):8260, 2023
- [13] Sathya, B, & Neelaveni, R, “Transfer learning based automatic human identification using dental traits-an aid to forensic odontology”, *J Forensic Leg Med* 76:102066, 2020.
- [14] Krois, J, Garcia Cantu, A, Chaurasia, A, Patil, R, Chaudhari, P K, Gaudin, R, ... & Schwendicke, F, “Generalizability of deep learning models for dental image analysis”, *Sci Rep* 11(1):6102, 2021
- [15] Li, Z, Wang, S H, Fan, R R, Cao, G, Zhang, Y D, & Guo, T, “Teeth category classification via seven-layer deep convolutional neural network with max pooling and global average pooling”, *International Journal of Imaging Systems and Technology* 29(4):577-583, 2019
- [16] Estai, M, Tennant, M, Gebauer, D, Brostek, A, Vignarajan, J, Mehdizadeh, M, & Saha, S, “Deep learning for automated detection and numbering of permanent teeth on panoramic images”, *Dentomaxillofac Rad* 51(2):20210296, 2022
- [17] Muramatsu, C, Morishita, T, Takahashi, R, Hayashi, T, Nishiyama, W, Arijji, Y, ... & Fujita, H, “Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data”, *Oral Radiol* 37:13-19, 2021.
- [18] Tuzoff, D V, Tuzova, L N, Bornstein, M M, Krasnov, A S, Kharchenko, M A, Nikolenko, S I, ... & Bednenko, G B, “Tooth detection and numbering

in panoramic radiographs using convolutional neural networks”, Dentomaxillofac Rad 48(4):20180051, 2019.

- [19] Kılıc, M. C, Bayrakdar, I S, Çelik, Ö, Bilgir, E, Orhan, K, Aydın, O B, ... & Yılmaz, A B, “Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs”, Dentomaxillofac Rad 50(6):20200172, 2021.

Özgeçmişler



Dr. Öğr. Üyesi Berrin Çelik, doktorasını Gazi Üniversitesi’nde Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi anabilim dalında 2019 yılında tamamlamıştır. Ankara Yıldırım Beyazıt Üniversitesi Diş Hekimliği Fakültesi’nde Dr. Öğretim Üyesi olarak görev yapmaktadır. İlgili alanları ağız, diş ve çene hastalıkları, diagnostik görüntüleme, fraktal analiz ve yapay zekâ konularını kapsamaktadır.



Mehmet Zahid Genç, lisans eğitimini Gazi Üniversitesi Elektrik-Elektronik Mühendisliği’nde sürdürmektedir. Lisans eğitimi süresince çeşitli proje ve endüstriyel çalışmalara katılmıştır. İlgili alanları arasında Tıpta Yapay Zekâ ve Biyomedikal Görüntü İşleme konuları bulunmaktadır.



Dr. Öğr. Üyesi Mahmut Emin Çelik, doktorasını 2017 yılında Gazi Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Anabilim Dalında tamamlamıştır. Doktora sonrası çalışmalarını 2018 ve 2022 yılları arasında Paris Göz Araştırmaları Enstitüsü ve Michigan Üniversitesinde görsel algının geri kazanılması konularında yapmıştır. Çalışma alanları nöral sinyallerin uyartım ve kayıt süreçleri, hesaplamalı modelleme, yapay zekâ, artırılmış ve sanal gerçeklik uygulamaları olarak sıralanabilir.