

Temmuz'24

Sayı/Number: 2 / Volume: 14
Yıl/Year: 2024

Yayın Sahibi

TMMOB
Elektrik Mühendisleri Odası Adına
Mahir ULUTAŞ

Sorumlu Yazı İşleri Müdürü

Ramazan PEKTAŞ

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

Temmuz 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 Panayırçı	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 Araçlarda Otonom Batarya Yönetim Sistemi Literatür İncelemesi <i>Autonomous Battery Management System in Electric Vehicles Literature Review</i> Metin Yılmaz, Eyüp Çinar, Ahmet Yazıcı	7
Geleceğin Harekât Ortamında Otonom Sürü SİHA Konseptlerinin Stratejik Önemi ve Kullanım Taktiklerinin Örnek Bir Senaryo Üzerinden İncelenmesi <i>Strategic Importance of Autonomous Swarm UCAV Concepts in the Future Operational Environment and Investigation of Tactics through a Sample Scenario</i> Vural Avcı	23
Farklı Örneklemeye Tekniklerine ve Farklı Sınıflandırıcılara Dayanarak Kalp Yetmezliği Tanılı Hastaların Sağkalımlarının İncelenmesi <i>A Study of Survival of Patients Diagnosed with Heart Failure Based on Different Sampling Techniques and Different Classifiers</i> Rukiye Uzun Arslan, İrem Şenyer Yapıcı	35
Benzerlik Tabanlı Öğrenme Kullanarak Histopatolojik Görüntülerin Sınıflandırılması <i>Classification of histopathological images using similarity-based learning</i> Mahmut Kaya, Hasan Şakir Bilge	49
Akciğer Kanseri Tespitinde Dönüşüm ve Evrişim Tabanlı Modeller ile Açıklanabilir Yapay Zeka Uygulaması <i>Explainable Artificial Intelligence Application for Lung Cancer Detection with Transformer and Convolution Based Models</i> Delal Şeker, Mustafa Said Kartal, Abdulnasır Yıldız, İlkay Öksüz	59
Deniz Taşımacılığı İzlemek için Sualtı Kablosuz Sensör Ağlarında Otonom Sualtı Aracı ile Dayanıklı ve Enerji Farkında Yol Planlama <i>Robust and Energy-Aware Path Planning by Autonomous Underwater Vehicle in Underwater Wireless Sensor Networks for Monitoring Maritime Transportation</i> Ömer Melih Gül, Tayfun Acarer	71
Yapay Zekâ Tabanlı Hava Kalitesi İyileştirme Stratejilerinin Değerlendirilmesi <i>Evaluation of Artificial Intelligence-Based Air Quality Improvement Strategies</i> Tuğçe Pekdoğan	87
Frekans Atlamalı Sinyallerin Tespiti ve Parametre Kestirimine Genel Bir Bakış: Son Gelişmeler ve Zorluklar <i>An Overview on Detection and Parameter Estimation of Frequency Hopping Signals: Recent Advances and Challenges</i> Mutlu Aydın, Ali Kara	99
Cam İşletmesinde Enerji Verimlilik Potansiyeli ve İyileştirme Çalışmaları <i>Energy Efficiency Potential Analysis and Improvement Studies in Glass Industry</i> İrem Düzdar, Elif Akın, Tuğçe Özdemir	107
Ev Tipi Endüksiyon Isıtmalı Ocakların Analizi <i>Analysis of Household Induction Hobs</i> Metin Ozturk, Fatih Züngör, Durmuş Ersoy	117

Elektrikli Araçlarda Otonom Batarya Yönetim Sistemi Literatür İncelemesi

Autonomous Battery Management System in Electric Vehicles Literature Review

Metin Yılmaz^{1,2}, Eyüp Çınar^{1,2}, Ahmet Yazıcı^{1,2}

¹Bilgisayar Mühendisliği Bölümü
Eskişehir Osmangazi Üniversitesi
503020211005@ogrenci.ogu.edu.tr, eyupcinar@ogu.edu.tr, ayazici@ogu.edu.tr
²Center of Intelligent Systems Applications Research (CISAR)
Eskişehir Osmangazi Üniversitesi

Özet

Elektrikli araçlar hem dünya genelinde hem de ülkemizde giderek daha yaygın hale gelmektedir. Bu araçlarda, batarya en kritik bileşenlerdir. Akıllı bir batarya yönetim sistemi (Battery Management System - BMS) için doğru prognostik ve sağlık yönetimi (Prognostics and Health Management - PHM) büyük önem taşır. PHM ve BMS, elektrikli araçların güvenliği, verimliliği ve batarya ömrü açısından kritik bir rol oynamaktadır. Bu literatür incelemesi, elektrikli araçlar için PHM ve BMS konularının önemine vurgu yapmaktadır. Lityum-iyon (Li-ion) bataryaların hala en uygun seçeneklerden biridir, ancak batarya ömrü gibi bazı zorluklarla karşılaşılabilir. Bu nedenle, doğru batarya şarj durumu (State of Charge - SoC) ve bataryanın sağlık durumu (State of Health - SoH) tahminleriyle bir BMS, batarya ömrünü uzatmak ve güvenliği sağlamak için gereklidir. Bu çalışma, elektrikli araçlar için PHM ve BMS konularında gelecekteki araştırma gündemine yönelik analitik bir incelemedir. Batarya prognostiğinin önemine vurgu yapılarak, elektrikli araçların sağlıklı çalışması için daha fazla araştırmanın yapılması gerektiği vurgulanmaktadır.

Anahtar Kelimeler: Elektrikli Araç, Batarya Yönetim Sistemi, Batarya Sağlık Yönetimi, Prognostik ve Sağlık Yönetimi

Abstract

Electric vehicles are becoming increasingly prevalent worldwide, including in our country. In these vehicles, batteries are the most critical components. Accurate Prognostics and Health Management (PHM) are of great importance for an intelligent Battery Management System (BMS). PHM and BMS play a critical role in the safety, efficiency, and battery life of electric vehicles. This literature review emphasizes the significance of PHM and BMS in the context of electric vehicles. Lithium-ion (Li-ion) batteries remain one of the most suitable options, despite facing challenges such as battery life. Therefore, a BMS with accurate State of Charge (SoC) and State of Health (SoH) estimations are necessary to extend battery life and ensure safety. This study presents an analytical review of PHM and BMS for future research agendas in electric vehicles, highlighting the importance of battery prognostics and emphasizing the need for further research to ensure the healthy operation of electric vehicles.

Keywords: Electric Vehicle, Battery Management System, Battery Health Management, Prognostics and Health Management

1 Giriş

Dünyada gün geçtikte yaygınlaşan elektrikli araçlar (EA), ulusal elektrikli otomobil TOGG'un da piyasaya çıkmasıyla ülkemizde de yaygınlaşmaya başlamıştır. Bu araçların insan hayatına daha fazla girmesi ve kullanımlarının artmasıyla birlikte araçların izlenmesi, elektrikli araç özelindeki donanımsal aksamaların güvenilirliği (reliability) ve prognostiği (tahmin) de önem arz etmektedir. Benzinli araçlara göre farklı arıza modları ve prognostik ihtiyaçları olabilen elektrikli araçlar, en son teknoloji durum izleme ve tahminleme metodlarının entegrasyonu ile zenginleştirilerek günlük hayattaki yerlerini almalıdırlar. Elektrik enerjisiyle çalışan araçlar, batarya tabanlı bir güç kaynağı kullanır. Bu araçlar arasında otonom araçlar ve robotlar gibi çeşitli teknolojik sistemler bulunur. Batarya içermeleri nedeniyle, bu araçlar elektrikli araçlar sınıfına dahil edilebilmektedir.

Elektrikli araçların durum izleme ve prognostik (condition monitoring and prognostics) açıdan en kritik bileşeni batarya sistemleridir. Batarya teknolojisindeki gelişmeler, elektrikli araçların verimliliklerini de yönlendirmektedir [1]. Verimlilikleri nedeniyle Li-ion bataryalar, EA'larda enerji kaynağı olarak yaygın bir şekilde kullanıldığı bilinmektedir [2], [3], [4]. Bu nedenle de hem akademik hem de endüstriyel alanda büyük ilgi görmektedir. EA endüstrisinin daha da gelişmesiyle birlikte, batarya performansı arızalarını mümkün olduğunca önlemek veya önceden uyararak için EV bataryalarının teşhis ve sağlık yönetimi PHM sisteminin güvenilirliği işletmelerde fazlasıyla ilgi görmüştür [5], [6]. Batarya PHM'si, bataryanın sağlık durumunun SoH doğru tahmin edilmesi ve kalan kullanım ömrünün (Remaining Useful Life - RUL) tahmini ile bataryanın güvenli ve verimli çalışmasının sağlanması için gereklidir [7].

Elektrikli araçlarda akıllı bir batarya yönetim sistemi BMS için PHM gereklidir, çünkü güvenlik tehlikelerinden kaçınmak ve kullanım ömrünü uzatmak önemlidir [8], [9]. Batarya SoH'nin doğru bir şekilde tahmin edilmesi ve RUL tahmini, batarya PHM'sinin iki önemli işlevidir. Bakım maliyetlerini en aza indirmek ve batarya ömrünü en üst düzeye çıkarmak, BMS'nin optimum çalışması için önemlidir ve güvenlik, verimlilik ve güvenilirlik gibi faktörlere katkıda bulunmaktadır. Li-ion

bataryaların elektriksel performansı önemli ölçüde iyileşmiş olsa da eskimeyle birlikte kapasite düşüşlerinin üstesinden gelmek hala mümkün değildir [4].

Li-ion bataryalar için etkili bir BMS kullanmak, bataryanın güvenli bir şekilde çalışmasını, fiziksel hasarın önlenmesini ve termal bozulma ve hücre dengesizliği ile başa çıkmayı sağlar. BMS ayrıca, bataryanın farklı durumlarını ölçebilen ve değerlendirebilen, batarya şarj durumu SoC ve SoH doğruluğu için verileri kontrol eden ve güncelleyen, arızaları tespit eden, batarya voltajını eşitleyen ve aşırı şarj/aşırı deşarjı önleyen bir batarya yönetim sistemi sunar [10].

EA'lar için tekrarlanan şarj/deşarj işlemleriyle şarj kapasitesi azaldığından, batarya ömrü gibi hala çözülmesi gereken bazı zorluklar vardır. En dikkate değer olanı ise, SoC tahmini ve EV sürücülerinin batarya SoH durumudur. Doğru SoC ve SoH tahminleriyle bir batarya yönetim sistemi, bataryadaki her bir hücrenin aşırı şarj olmasını veya aşırı deşarj olmasını önleyebilir ve tüm batarya ömrünü uzatabilir [4]. Güvenlik tehlikelerinden kaçınmak ve kullanım ömrünü uzatmak için akıllı bir BMS için PHM gereklidir [6]. Batarya SoH ve RUL tahmini, bataryanın PHM'sinin iki önemli işlevidir ve bakım maliyetlerini en aza indirip, batarya ömrünü en üst düzeye çıkararak BMS'nin optimum çalışmasına katkıda bulunur [7]. Sağlıklı durum, batarya sisteminin kararlılığını, güvenilirliğini, güvenliğini ve hatta tüm EA'yı doğrudan etkileyebilir.

Bu çalışma, elektrikli araçlar için PHM ve BMS için analitik bir inceleme yaparak fırsat ve zorluklara bir giriş sunmakta ve batarya sağlığı yönetimi konusunda geleceğe yönelik bir araştırma gündemi sunmaktadır. İnceleme yayınında sunulan sorunlarla birlikte, daha fazla araştırma yapılması önemlidir.

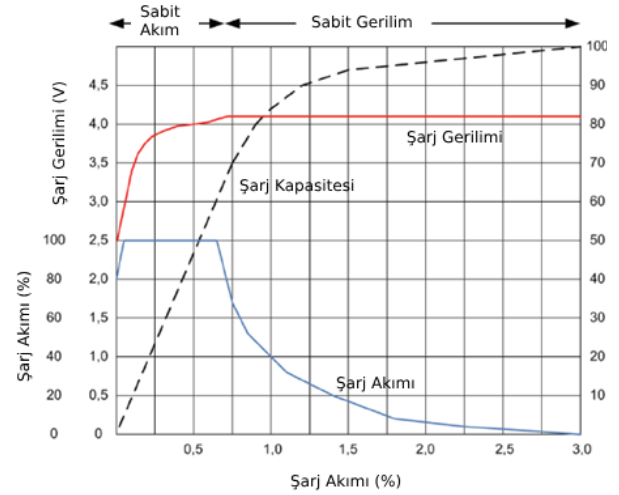
Yayın dağılımı şu şekildedir, birinci bölümde elektrik araçlar prognostik ve batarya prognostiği ile ilgili literatür çalışmaları incelenmiştir. İkinci bölümde ise batarya sağlığıyla ilgili sorunlar ve zorluklar, üçüncü bölümde batarya prognoz (öntanı) kavramları, dördüncü bölümde batarya yönetim sistemleri ve prognostik alanında yapılan çalışmalar, beşinde bölümde ise batarya alanında paylaşılan veri setleri karşılaştırmalı olarak gösterilmiştir. Son bölümde çalışmanın katkıları ve daha sonra yapılabilecek çalışmalar hakkında öneriler verilmiştir.

2 Elektrikli Araçlarda Prognostik ve Batarya Prognostiği

Li-ion bataryalar, elektrikli araçların enerji kaynağı olarak kullanılmaları için en uygun seçeneklerden biridir. Ancak, bu bataryaların ömrü sınırlıdır ve zamanla performansları azalmaktadır. Bu nedenle, batarya prognostiği elektrikli araçların sağlıklı çalışması için hayati öneme sahiptir. Batarya prognostiği, batarya ömrü, güvenilirliği ve performansını önceden tahmin etmek için kullanılan bir tekniktir. Bu teknik, bataryanın tam kapasiteye ulaşması, güvenli bir şekilde kullanılması ve araç sahiplerine uzun vadeli maliyet tasarrufu sağlaması için gereklidir. Bu nedenle, elektrikli araçların yaygınlaşması ile birlikte batarya prognostiği konusu, araştırmacıların ve endüstrinin öncelikli konularından biri haline gelmiştir.

Bataryaların şarj profilleri ve zamanları elektrikli araçlar için oldukça önemlidir. Elektrikli araçlarda kullanılan Li-ion bataryaların şarj edilmesi için üç farklı yöntem kullanılır [4]. Sabit voltaj yöntemi (Constant Voltage - CV), bataryanın şarj edilmesi için sabit bir voltaj kullanırken, sabit akım yöntemi

(Constant Current - CC), bataryanın şarj edilmesi için sabit bir akım kullanır ve bataryanın voltajı zamanla yükselir. Hızlı şarj yöntemi ise sabit akım ve sabit voltaj (Constant Current Constant Voltage - CCCV) yöntemlerinin bir kombinasyonudur ve Şekil 1.'de gösterildiği gibi hızlı şarj prosedürü, özellikle zaman kazandıran özelliği nedeniyle Li-ion bataryalar için yaygın olarak kullanılır [4].



Şekil 1. Bir Li-ion batarya için sabit akım, sabit voltaj şarj profili [4].

2.1 Batarya Sağlığıyla İlgili Sorunlar ve Zorluklar

Bataryalar için prognostik teknolojilerin geliştirilmesi ve uygulanması, bataryalarda meydana gelen elektrik-kimyasal süreçlerin doğal karmaşıklığı nedeniyle zorlu ve karmaşıktır [11]. Bu zorluklardan bazıları şunlardır:

Batarya eskimesi sorunları: Yaşlanma süreçleri, elektrolit, anot ve katodun özelliklerinde ve bataryada kullanılan bileşenlerin yapısındaki geri dönüşü olmayan değişikliklerdir. Batarya eskime süreci iki kategoriye ayrılabilir; izlenmesi mümkün olan zaman içinde kademeli bozulmayı içeren eskime süreçleri ve büyük bir sorun veya batarya performansında hızlı değişiklikler meydana gelene kadar herhangi bir özel modu veya gözlemlenebilir işareti olmayan eskime süreçleridir [12].

Bozulma faktörleri: Bu alandaki otomotiv uygulamalarındaki en önemli bozulma faktörleri; çevre sıcaklığı, boşaltma akımı oranı, şarj oranı (hızlı şarj), deşarj derinliği, tam şarj döngüleri arasındaki zaman aralıkları şeklinde tanımlanabilir [13], [14].

Batarya sağlığını izlemenin zorlukları: Batarya davranışını izlemenin en etkili ve basit yöntemi batarya voltajını, akımı, sıcaklığı ve bazı durumlarda basıncı gözlemlemeye dayanır [15]. Bu değişkenlerden bazıları, cihazın ana işlevselliği kesintiye uğramadan batarya ile çalışırken ölçülebilir; buna çevrimiçi ölçüm denir.

Batarya sağlığını izlemek için özelliklerin değerlendirilmesi: Bir bataryadan elde edilen ham verilerden birçok özellik çıkarılabilir. En kullanışlı özellikler, batarya performansı sırasında göze çarpan eğilimleri temsil etmelidir ve bataryanın içindeki elektrokimyasal reaksiyonlara dayalı bozulmanın fiziksel nedenleriyle ilişkilendirilebilir [16].


PHM, arıza olaylarını belirlemek ve sistem riskini azaltmak için gerçek yaşam döngüsü koşulları altında bileşen veya sistem güvenilirliğini değerlendirmeye yönelik araç ve tekniklerden

oluşur [11]. Batarya RUL'u, potansiyel batarya arıza süresi hakkında değerli bir tahmin sağlar. Bu, enerji depolama sistemlerinin güvenilirlik değerlendirmesi için önemlidir [7]. Bu nedenle, batarya SoH ve batarya RUL değerinin doğru tahmini, batarya çalışması için çok önemlidir.

2.2 Batarya Prognostik Kavramları

Elektrikli araçların popülaritesindeki artış, bu araçların güç kaynaklarına olan bağımlılıklarından kaynaklanan yük artışıyla birlikte elektrik şebekelerini zorlayabilir. Bu nedenle, EA'ların güç kaynaklarını tamamlamanın yenilikçi yollarına ihtiyaç vardır. Ancak, Li-ion bataryalar, yüksek kapasitelere rağmen güvenlik, dayanıklılık, tekdüzellik ve maliyetle ilgili sorunlar nedeniyle büyük seri/paralel bağlanma sayıları sınırlar. Batarya ömrünün hücre dengelemesi ile uzatılabileceği düşünülse de bunu gerçekleştirmek için zorluklarla karşılaşmaktadır. Bu nedenle, Li-ion bataryaların güvenliği ve güvenilirliği, batarya sağlık sistemlerinin etkin kontrol ve yönetimini gerektirir. Çok sayıda araştırma, teknolojinin uygulamalarda hatalara neden olmaması ve başarısızlıklarının felaketlere yol açmaması için yapılır [17].

BMS: Bir batarya takımının izlenmesi ve yönetimi için tasarlanmış, yazılım algoritmaları, sensörler, kontrolörler, iletişim ve hesaplama donanımının bir kombinasyonudur. BMS, bataryanın SoH, SoC ve RUL gibi bilgileri belirler. Ayrıca, bataryanın güvenli, verimli ve zararsız bir şekilde çalıştırılmasını sağlamak için çalışır [18], [19]. Birçok endüstriyel uygulamada, Li-ion bataryaları kullanan ana güç kaynakları için BMS'nin oldukça yararlı olduğu kanıtlanmıştır. BMS, batarya ömrü boyunca SoH, SoC, RUL tahminlerini izler ve gerçekleştirir. Bu nedenle, Li-ion bataryalar için BMS, bakım optimizasyonu desteği sağlamak için teşhis ve/veya prognostik temelinde bakım, lojistik ve sistem yapılandırma faaliyetlerini akıllıca gerçekleştirmeye yönelik bir karar sürecidir [20]. Şekil 2'te gösterildiği gibi elektrikli araçlar için BMS oluşturmak için modüler bir yaklaşımın uygun olduğu görülmüştür [21]. Her Li-ion batarya modülü, bir modüler yönetim sistemi (Modular Management System - MMS) tarafından kontrol edilir ve yönetilir. Tüm MMS'ler merkezi bir yönetim sistemi (Central Management System - CMS) tarafından kontrol edilir. BMS modülleri bağımsız bir modda çalıştığı için veri alışverişi gereklidir. BMS içinde veri alışverişi için kontrol edilebilir bir alıcı-verici gereklidir. Bu mimari esnek, ölçeklenebilir ve yaygın olarak kabul görmüştür.



Şekil 2. Batarya yönetim sisteminin modüler konsepti

Durum İzleme (Condition Monitoring - CM): Bir BMS'nin ilk ana görevi, batarya voltajı ve akımı, hücre voltajı, sıcaklık, yalıtım ve kilit (interlock) gibi bataryanın ölçülebilir durumlarını izlemektir [22]. Batarya sağlık bilgileri, belirli profillerdeki cihazların sağlığını veya durumunu gösteren

fiziksel parametreleri izleyen bir prosedür kullanılarak düzenli aralıklarla toplanır. Sıcaklık ve titreşim gibi hem dahili hem de harici parametreler bataryanın durumunu etkileyebilir. Literatür, titreşim yükünün ve sıcaklığın batarya performansını etkileyerek hücre kapasitesinde önemli azalmalara ve bozulmalara yol açtığını göstermektedir [23]. Aşırı voltaj veya aşırı ısınma gibi herhangi bir anormal durum tespit edilirse, BMS kullanıcıyı bilgilendirmeli ve önceden belirlenmiş bir düzeltici önlem almalıdır. Bu işlemlere ek olarak BMS, sistem sıcaklığını da izler ve daha iyi bir enerji tüketim sistemi sağlamak için bireysel bileşenler ve kullanıcılarla iletişim kurar [24].

RUL: Bir bataryanın çalışma gereksinimlerini karşılayabileceği kalan süre veya şarj döngüsü sayısıdır [25], [26]. RUL, azaltılmış maliyetler, geliştirilmiş doğruluk, güvenilirlik ve arızalardan kaçınma taleplerini karşılamak için araştırma ve üretim araçlarında BMS büyük önem vermiştir. RUL Eşitlik 1'deki gibi hesaplanabilir [20]:

$$RUL = T_f - T_c \quad (1)$$

Burada T_f , bozulma tespit edildiğinde arıza süresinin rastgele bir değişkenidir ve T_c , tahmin edilen sinyalin arıza süresini bir miktar geçtiği zamandır.

SoC: Kullanılabilir kapasiteyi temsil eder ve performansı optimize etmek ve batarya ömrünü uzatmak için karşılanması gereken en önemli koşullardan biridir [25].

Batarya SoC, maksimum kapasitenin yüzdesi olarak ifade edilen mevcut batarya kapasitesidir. SoC, çalışma akımı, sıcaklık ve voltaj gibi koşullara dayalı olarak tahmin edilir [27]. Batarya SoC, tam olarak şarj edildiğinde sahip olduğu enerjiye kıyasla bir hücrede kalan enerji miktarını tahmin eder ve kullanıcıya bir bataryanın şarj edilmesi gerekmeden önce ne kadar süre dayanacağına dair bir gösterge verir. SoC, zaman içinde batarya kapasitesindeki değişikliği belirlemek için geçerli entegrasyon kullanılarak tipik olarak hesaplanır ve SoC basitçe Eşitlik 2'deki şekilde ifade edilir [11]:

$$SoC(t) = \frac{\int_{t_0}^t I_b(\tau) d\tau}{Q_0} \times 100\% \quad (2)$$

Burada, şarj akımı olarak $I_b(t)$ ile tamamen boşalmış bir bataryaya iletilen şarj Q_0 'ın t zamanındaki batarya kapasitesi olduğu şarj olarak ifade edilir.

SoH: Batarya RUL ile SoH arasında ayırım yapmak önemlidir. Batarya ömrü, batarya tipi, malzemesi ve batarya üreticisinin destekleyebileceği döngülerin standart kullanımı ile tanımlanır. Kullanılmış bir bataryanın aynı türden yeni bir batarya ile karşılaştırıldığında beyan edilen performansını ve sağlık durumunu tanımlayan kavram, SoH olarak adlandırılır [11]. Batarya performansının kademeli olarak bozulması, kapasiteyi azaltan ve kalan kullanım ömrünü kısaltan geri dönüşü olmayan kimyasal reaksiyonlardan kaynaklanır. Akım ve zamanı ölçerek bir SoC tanımlamak mümkün olsa da SoH için sabit bir tanım yoktur ve her üreticinin kendi tanımı vardır. SoH'yi belirlemek için bataryanın kapasite ve iç direnç gibi çeşitli özellikleri kullanılabilir. Ancak bu kesin bir ölçümden ziyade bir değerlendirme ve tahmindir [28]. SoH; mevcut gerçek kapasitenin nominal kapasiteye oranıdır. SoH Eşitlik 3'teki şekilde gösterilebilir [6]:

$$SoH = \frac{C_t}{C_0} \times 100 \quad (3)$$

Burada C_t mevcut maksimum kullanılabilir kapasitedir ve C_0 bataryanın çalışmaya başladığı andaki kapasiteyi temsil eder.

Artımlı Kapasite (Incremental Capacity - IC): Şarj işlemi sırasında belirli bir voltaj adımı için kapasite artışı olarak tanımlanır ve Eşitlik 4'teki şekilde ifade edilir [6]:

$$IC = \frac{dQ}{dV} = \frac{I \cdot dt}{dV} \quad (4)$$


Burada I şarj akımı, dt örnekleme zaman aralığı, dV voltaj adımı olarak ifade edilir.

Ortalama Karekök Sapması (Root-Mean-Square Error - RMSE): SoH tahmin sonuçlarının RMSE'si hedeflerden biri olarak belirlenmiştir. RMSE'nin ifadesi Eşitlik 5'teki şekilde verilir [6]:

$$RMSE = \sqrt{\frac{1}{m} \sum_{j=1}^m (SOH_j - \hat{SOH}_j)^2} \quad (5)$$

Burada SOH_j ve \hat{SOH}_j , sırasıyla gerçek SoH ve tahmini SoH'dir; m doğrulama için eleman numarasıdır.

Açık devre voltajı (Open Circuit Voltage - OCV): Bir diğer SoC tahmin yöntemi, bataryanın OCV'sini ölçmektir. Bu, SoC ve OCV arasındaki statik ilişkiye dayanan basit bir yöntemdir [21]. Bununla birlikte, SoC ve OCV arasındaki ilişki batarya malzemeleri arasında değişiklik gösterdiğinden, bu yaklaşım belirli batarya türleri ile sınırlıdır [23]. Şekil 3'te görülebileceği gibi, bataryanın histerezi, batarya boşaldığında düşük OCV'ye ve batarya şarj edildiğinde yüksek OCV'ye neden olduğundan dikkate alınmalıdır [29].




Şekil 3. LiFePO4 bazlı bataryaların her adımda çeşitli dinlenme sürelerinden sonra ölçülen akım yönüne bağlı OCV eğrileri [29]

2.3 Batarya Yönetim Sistemleri ve Prognostik Alanında Yapılan Çalışmalar

Li-ion bataryalar, yüksek verimlilik, daha düşük hacim, küçük ağırlık, sıcaklık hassasiyeti ve bakım gibi avantajlar nedeniyle umut verici teknolojilerden biridir [30], [31]. Bu bataryalar, taşınabilir elektronik cihazlar, elektrikli araçlar, havacılık sistemleri ve yenilenebilir enerji kaynakları için güç depolama gibi birçok uygulamada parlak bir geleceğe sahiptir [32]. BMS, batarya ile elektrikli araçlar arasında bir bağlayıcı

görevi gördüğü için Li-ion bataryalar için RUL'un tahmininde önemli bir rol oynar. BMS'nin ana hedefleri, batarya sistemi hasarını önlemek, batarya ömrünü tahmin etmek ve artırmak ve batarya sisteminin doğru ve güvenilir bir çalışma koşulunda tutmaktır [33]. BMS, yazılım algoritmaları ile sensörler, kontrolörler, iletişim ve hesaplama donanımının bir kombinasyonudur [34].

Batarya yönetim sistemleri ve prognostik için çeşitli yöntemler bulunmaktadır. Yük akımları, uç gerilimleri ve yüzey sıcaklıkları gibi ölçülebilir değişkenlere dayalı bu yöntemleri Şekil 4'te gösterildiği gibi temel olarak aşağıdaki üç kategoride sınıflandırılabilir [7].



Şekil 4. Prognostik yöntemler

Deneysel Yöntemler: Bu yöntemler, batarya ile çalışmanın tarihsel deneysel verilerine ve bataryanın bozulmasının ana nedenleri hakkındaki önceki bilgilere bağlıdır.

Model Tabanlı Yöntemler: Deneysel yöntemlerin dezavantajlarının üstesinden gelmek için, çeşitli çalışma koşullarını ve çeşitli batarya türlerini içeren batarya sağlığı teşhis yöntemlerine ihtiyaç vardır. Bu yöntemler, fiziksel veya matematiksel modeller oluşturarak bataryanın bozulma dinamiklerini tanımlamaya ve batarya SoH'sini tahmin etmeye çalışır.

Veriye Dayalı Yöntemler: Ölçülen verilerden veya çıkarılan özelliklerden batarya bozulma dinamiklerini modellemek için bir başka çözümdür.

2.4 Model Tabanlı Yöntemler

Model tabanlı yöntemler, veriye dayalı yöntemlerden farklı olarak bir model veya matematiksel bir gösterim kullanarak sonuçlar üretirler. Bu algoritmaların avantajları şunlardır: Verilerin boyutu büyük olsa bile yüksek performans sergilerler. Bu, büyük ölçekli problemleri çözmek için idealdir. Matematiksel bir modele dayanarak sonuçlar üretirler, bu nedenle sonuçlar daha doğru ve tekrarlanabilir olabilir. Veriye dayalı yöntemlere göre daha az veri gerektirirler. Bu, küçük veri kümeleri ile çalışırken faydalıdır.

Model tabanlı yöntemlerin dezavantajları ise şunlardır: Veri dağılımındaki değişikliklere iyi uyum sağlayamaz. Modelin doğru çalışması için düzenli olarak kontrol edilmesi ve ayarlanması gerekebilir çünkü model dışında çıktıyı etkileyen anlık faktörlerin hepsini kapsayamayabilir (örn: ortam sıcaklığı, kimyasal bileşenlerin dinamiği vb.).

Model tabanlı yöntemlerde, araştırmacıların kendilerinin önerdiği özgün matematiksel modeller dışında en sık rastlanan model tabanlı yöntem KF ve EKF'dir. Plett [35] çalışmasında, hibrit elektrikli araçlarda BMS için Genişletilmiş Kalman Filtresi (Extended Kalman Filter - EKF) algoritması ile SoC tahmini yapmaktadır. Çalışma, BMS'nin batarya şarj durumu, anlık kullanılabilir güç, güç azalması ve kapasite azalması gibi sağlık durumu göstergesi olan parametreleri tahmin

edebileceğini ve zamanla hücre özelliklerine uyum sağlayabileceğini belirtmektedir. Kalman Filtresi (Kalman Filter - KF), optimum durum tahminci olarak kabul edilir ve açıklanan varsayımlara sahip doğrusal bir sistem için kullanılır. Doğrusal olmayan durumlar için zaman değişkenli (time-variant) bir yaklaşım kullanılarak sistem doğrusala yaklaştırılabilir. Yazarlar bu yaklaştırılan sistemi daha sonra KF'de kullanılarak, gerçek doğrusal olmayan sistemi EKF ile modellemişlerdir. Bu model Eşitlik 6 ve Eşitlik 7'de gösterilmiştir.

$$x_{k+1} = f(x_k, u_k) + w_k \quad (6)$$

$$y_k = g(x_k, u_k) + v_k \quad (7)$$

Burada x_k , k zaman indeksindeki sistem durum vektörünü temsil eder ve "durum denklemi" veya "süreç denklemi" olarak adlandırılır. Durum denklemi, sistem dinamiklerinin gelişimini yakalar. Sistem kararlılığı, dinamik kontrol edilebilirliği ve bozulmaya karşı hassasiyet, bu denklemden belirlenebilir. Sisteme bilinen ve belirleyici bir girdi olarak u_k , verilirken, w_k stokastik bir "süreç gürültüsü" veya "bozukluk" olarak adlandırılan, sistemin durumunu etkileyen bazı ölçülmemiş girdileri modellemektedir. Sistem çıktısı y_k olarak belirtilir ve bu çıktı, durumların ve girdinin doğrusal bir kombinasyonu olarak hesaplanır. Ancak, belleksiz bir sistem çıktısının ölçümünü etkileyen unsurlar da vardır. Bu unsurlar, "sensör gürültüsü" olarak adlandırılan v_k tarafından modellenir. $f(x_k, u_k)$ doğrusal olmayan bir durum geçiş fonksiyonu olarak tanımlanmakta ve $g(x_k, u_k)$ doğrusal olmayan bir ölçüm fonksiyonu olarak belirtilmektedir. Doğrusal olmayan sistem, her adımda, $f(x_k, u_k)$ ve $g(x_k, u_k)$ birinci dereceden bir Taylor serisi açılımı ile doğrusallaştırılır. $f(\cdot, \cdot)$ ve $g(\cdot, \cdot)$ 'nin tüm çalışma noktalarında (x_k, u_k) türevlenebilmektedir. Bu açılımlar Eşitlik 8 ve Eşitlik 9'da gösterilmiştir.

$$f(x_k, u_k) \approx f(\hat{x}_k, u_k) + \left. \frac{\partial f(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k} (x_k - \hat{x}_k) \quad (8)$$

$$\hat{A}_k = \left. \frac{\partial f(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k}$$

$$g(x_k, u_k) \approx g(\hat{x}_k, u_k) + \left. \frac{\partial g(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k} (x_k - \hat{x}_k) \quad (9)$$

$$\hat{C}_k = \left. \frac{\partial g(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k}$$

Eşitlik 8 ve 9 kullanılarak doğrusallaştırılmış sistem denklemleri Eşitlik 10 ve 11'deki gibi oluşturulabilir.

$$x_{k+1} \approx \hat{A}_k x_k + f(\hat{x}_k, u_k) - \hat{A}_k \hat{x}_k + w_k \quad (10)$$

$$y_k \approx \hat{C}_k x_k + g(\hat{x}_k, u_k) - \hat{C}_k \hat{x}_k + w_k \quad (11)$$

EKF, temel olarak standart KF'ye çok benzer. Başlatma adımı aynı kalır. Her tekrarda bir tahmin ve bir düzeltme adımı gerçekleştirilir. EKF'de, mevcut durumu tahmin etmek için yayılma adımı, KF'nin doğrusal modelini kullanırken doğrusal olmayan modele uygulanır. Hata kovaryans yayılımı ve Kalman kazanç denklemleri, KF ile aynıdır, ancak artık doğrusallaştırılmış \hat{A}_k matrisi A_k 'nin yerini alır ve \hat{C}_k matrisi de C_k 'nin yerini alır. Durum tahmini güncellemesi aynı şekilde yapılır, ancak $\hat{y}_k = g(\hat{x}_k, u_k)$ olarak hesaplanır ve hata kovaryans güncellemesi sadece C_k yerine \hat{C}_k 'nin kullanılmasıyla farklılık gösterir.

Chen ve ark. [36] çalışmasında, bir Lithium-polymer batarya şarj durumunun tahmini için sağlam bir kayan mod

gözlemcisi (Robust Sliding-Mode Observer - RSMO) sunmuştur. Bunun için, bir batarya eşdeğer devre modeli (Battery Equivalent Circuit Model - BECM) oluşturmuşlardır ve BECM, gerçek zamanlı olarak bir unutm faktörü özyinelemeli en küçük kareler (Forgetting-Factor Recursive Least Squares - FFRLS) algoritması kullanılarak tanımlamışlardır. Deneyler, elektrikli araç sürüş döngülerinde Lithium-polymer batarya üzerinde gerçekleştirilerek önerilen yaklaşım doğrulamışlardır.

He ve ark. [37] çalışmasında, SoH tahminlerinin önemi vurgulanarak, Li-ion bataryalar için bir çok ölçekli Gauss süreci regresyon (Gaussian Process Regression - GPR) modelleme yöntemi önermişlerdir. Yöntem, dalgacık analizi yöntemi kullanarak SoH zaman serilerinde küresel bozulma, yerel yenilenme ve dalgalanmaları ayırtmıştır. Zaman indeksinin dahil edildiği GPR, çıkarılan küresel bozulma eğilimine uyması için kullanılır ve gecikme vektörü girişi ile GPR, yerel yenilenmeyi ve dalgalanmaları tahmin etmek için tasarlanmıştır. Önerilen yöntem, Li-ion bataryaların bozulma testinden elde edilen deneysel verilerle doğrulanmış ve hem bir adım için SoH tahmin performansları değerlendirilmiştir.

Model tabanlı bir başka çalışmada Huang ve ark. [38], Li-ion bataryaların yaşam ömrü boyunca çevrimiçi, SoC ve SoH tahminleri için bir model geliştirmiş ve modelin sağlamlığının kanıtlandığı belirtmişlerdir. Pilin eskimesiyle birlikte gerilim değiştiğinden, pilin SOC'sini belirlemek için tek bir voltaj değeri yeterlidir. Bu nedenle, bu makale, SOC ve SOH modellemesi için birim zaman gerilim düşümü, V' olarak adlandırılan yeni bir parametre önermektedir. Eşitlik 12'de bu parametre gösterilmektedir.

$$V' = \frac{\Delta V}{\Delta t}, \quad V' = V_1 - V_2 \quad (12)$$

Burada ΔV deşarj esnasındaki gerilim düşüşüdür. Δt ise deşarj süresidir. Önerilen çalışma, boşaltma işlemindeki birim zaman voltaj düşüşü olan yeni bir değişken tanımlamakta ve bu değişkeni kullanan yeni bir model önermektedir. SoC, değişkenin belirlenmemiş katsayısı ile doğrusal bir ilişki olarak ifade edilmiştir. SoH, SoC'nin bir fonksiyonu olan bir modifikasyon faktörü ile değişken ile doğrusal olduğu bulunmuştur. Test hücrelerinden veri regresyonu, katsayıların değerlerini vermektedir. Bu türetilmiş model, bataryanın anlık SoC ve SoH'sini aynı anda tahmin edebilmekte ve çevrimiçi gerçek zamanlı uygulamalar için kullanılabilir. Ayrıca, bataryanın ömrü uzatılabilir.

Afari ve Byun [39] çalışmasında, EV bataryasının SOH ve SOC'ünü hesaplama zorluğuna bir çözüm olarak Digital Twin önerilmektedir. XGBoost modeli ve EKF kullanılarak bataryanın durumu tahmin edilir. EKF ile bataryanın durumu belirlenir ve bakım için önemli bilgiler sağlanır. Doğru SOC tahminiyle bataryanın ömrü uzatılabilir.

Wang ve ark. [40] çalışmasında, EA ve hibrit araçlar için SoC tahmini için bir yöntem önerilmektedir. Batarya yaşlanmasıyla ilgili olarak, elektrokimyasal empedans spektroskopisi (electrochemical impedance spectroscopy) tabanlı bir model güncelleme stratejisi entegre edilmiş ve bu yöntem, SoC tahmin doğruluğunu önemli ölçüde artırmaktadır, bu da şarj ve deşarj koşullarında gerçek değerlere daha yakın tahminler sağlamaktadır.

Saldaña ve ark. [41] çalışmasında, elektrikli araç teknolojisinin yaygın kullanımının önündeki engellerden biri olan batarya bozulmasının doğru bir şekilde ele alınması gerektiği vurgulanmaktadır. Ticari bir elektrikli araç bataryasının döngü yaşlanması üzerine kurulan bir

matematiksel model geliştirilmiş ve sıcaklık ile elektrik akımının hızı gibi faktörlerin batarya bozulmasında belirleyici olduğu bulunmuştur. Çalışma, farklı sürüş koşullarının batarya bozulmasına etkisini analiz eden bir model uygulaması da sunmaktadır.

Bu çalışmada incelenen model tabanlı yöntemler genel olarak bakıldığında, ortak bir algoritma ya da modeli kullanmaktan ziyade çalışmalar özgün bir matematiksel model kullandığı gözlemlenmektedir (Tablo 1).

Tablo 1. İncelenen çalışmaların model tabanlı yöneme göre sınıflandırılması

Yöntem
Matematiksel Model
Parçacık Filtresi
Kalman Filtresi
Regresyon Modeli
Bayes Modeli
Hücre Fark Modeli
Olasılık Fonksiyon Teorisi
Çok Ölçekli Entropi
Doğrusal Tahmin Hata Modeli

2.5 Veriye dayalı yöntemler


Veriye dayalı yöntemlere bakıldığında ise, Li-ion batarya hücrelerinin SoH ve RUL tahmin edebilen Rezvani ve ark. [42] çalışmasında, Uyarlanabilir Sinir Ağı (Adaptive Neural Networks - AdNN) ve Lineer Tahmin Hata Yöntemi (Linear Prediction Error Methods - L-PEM) olmak üzere iki model ile PHM geliştirmişlerdir. Çalışmada AdNN tekniği kullanılarak girdilerin ağırlıklarla çarpılması ve ardından matematiksel bir fonksiyonla hesaplanarak yapay nöronun aktivasyonu temsil edilmiştir. Yazarlar yapay sinir ağlarını, yapay nöronları birleştirerek girdiler ve çıktılar arasındaki ilişkileri bulmak için kullanmışlardır.

Dong ve ark. [7] çalışmasında, Dinamik Bayes Ağı (Dynamic Bayesian Network - DBN) kullanılarak şarj işleminden çıkarılan özelliklere dayalı olarak bataryanın bozulma modellemesi ve sağlık tahmini için olasılıksal bir yöntem sunmaktadır. Bazı CC veya CV şarj bilgilerinin olmaması durumunda bataryanın bozulma dinamiklerini karakterize etmek için CC şarjının artımlı kapasite analizi ile CV şarjının zaman sabitini birleştiren toplu bir özellik geliştirilmiştir. Benzer şekilde Hu ve ark. [8] çalışmasında, elektrikli araçlarda batarya SoH göstergesi ve prognozu için seyrek bayes tahmini modelleme (Sparse Bayesian Predictive Modeling - SBPM) metodolojisi kullanmışlardır. Yaklaşım, otomatik olarak seçilen az sayıda temel işlevi kullanarak doğru ve esnek tahminler yapan doğrusal olmayan bir model çıkarmıştır.

Elektrikli araçlarda kullanılan bir Lityum-Fer-Fosfat (LFP) bataryasında RUL ve eskime hızını tahmin etmek için Hemedani ve ark. [43] çalışmasında, Levenberg-Marquardt-Geri Yayılma Sinir Ağı (Propagation Neural Network - LM-BPNN) adlı bir AdNN algoritması kullanılmıştır. BPNN algoritması yaygın olarak kullanılan çok katmanlı sinir ağı öğrenme algoritması ve denetimli öğrenme yöntemidir. BPNN algoritmasının, nöronlar arasındaki gradyanın hesaplanması ile hata düzeltme yaparak tahmini çıktı ile istenen çıktı arasındaki farkı azalttığı ifade edilmektedir. He ve ark. [44] çalışmasında, model parametrelerini kendi kendine ayarlamak ve SoC tahmini sağlamak için Kalman filtrelemeye dayalı bir yöntem önerilmişlerdir. Önerilen yöntemin performansı, iki dinamik deşarj profili ile çevrilen LiFePO4 bataryalarından toplanan veriler kullanılarak gösterilmiştir. Yayan ve ark. [4]

çalışmasında, batarya şarj işlemi sırasında toplanan veriler kullanılarak SoH (Durum-of-Health) tahmin edilmektedir. Çalışmada, hızlı şarj işlemi sırasında toplanan veriler kullanılarak bataryanın SoH'si tahmin edilmiş ve bunun için önerilen derin sinir ağı yapısı olarak LSTM-BiLSTM (Bidirectional LSTM) kullanılmıştır. LSTM, Recurrent Neural Network (RNN)'ye benzer ancak geçmiş verileri daha etkili bir şekilde kullanabilen ve uzun süreli bağlantıları koruyabilen bir sinir ağıdır. Bu özellikleri sayesinde, zaman serilerindeki kaybolan gradyan problemi de çözülebilir. LSTM, zaman dilimleri arasındaki bağımsızlığı sağlayarak tahmin ve sınıflandırma işlemleri için ideal bir araçtır. Şekil 5'te, test veri setindeki her dizi için tahmin edilen ve gerçek SoH değerleri ve tahmin hatası gösterilmektedir. Çalışmanın RMSE değerleri ise eğitim verisetinde 2.9022, doğrulama verisetinde 5.4212 ve test veri setinde ise 5.501 olarak hesaplanmıştır. Yazarların önerdikleri yığılı BiLSTM modeli ileri ve geri verilerin birleştirilmesini içeren bir eğitim sürecine sahiptir. Model, pillerin SoH'sini diğer tekrarlayan ağlardan veya tek yönlü LSTM modellerinden daha güvenilir bir şekilde tahmin etmede başarılıdır.

Antón ve ark. [45] çalışmasında, bir lityum demir fosfat (LiFePO₄) batarya hücresinin SoC'sini tahmin etmek için otomatik öğrenme aracı olarak destek vektör makinesi (Support Vector Machine - SVM) kullanmışlardır. SVM, sınıflandırma ve regresyon problemleri için kullanılan bir dizi ilgili denetimli öğrenme yöntemidir. SVM öncelikle sınıflandırma problemlerini çözmek için tasarlanmıştır, ancak daha sonra Support Vector Regression (SVR) adı verilen bir yöntemle regresyon problemlerini çözmek için genişletilmiştir [46].



Şekil 5. BiLSTM kullanarak Yayan ve ark. [4] SoH tahmini

Farklı döngü sayıları altında batarya terminali voltaj eğrilerinin analizi ile Li-ion batarya RUL tahmini için Wu ve ark. [26] çalışmasında ileri beslemeli sinir ağı (Feed Forward Neural Network - FFNN) kullanmışlardır. FFNN, istatistiksel modelde yaygın olarak kullanılan bir makine öğrenme yöntemidir ve doğrusal olmayan simülasyon yeteneği nedeniyle tercih edilir. Çalışmada, 3 katmanlı (giriş, gizli ve çıkış) bir FFNN önerilmiştir ve ağ parametreleri eğitim sürecinden

belirlendiğinde batarya çevrim ömrünün tahmin etmek için kullanılmıştır.

Zhang [47] ise çalışmasında, bir Li-ion batarya paketi kullanarak, bataryanın şarj veya deşarj sürecindeki yerel voltaj değişimini ve kapasite değişimini SoH indeksleri olarak kullanarak, SoH'yi tahmin etmek için bir yöntem sunmuştur. Yöntem, bir partikül filtresine (Particle Filter - PF) dayalı RUL tahmini gerçekleştirir. PF olasılık dağılımı bilinmeyen ve ölçümlerden gelen gürültülü verilere dayalı olarak bir sistemin durumunu tahmin etmek için kullanılan bir filtreleme algoritmasıdır. PF, Li-ion batarya ömrü tahmininde yaygın olarak kullanılmaktadır. Song ve ark. [48] çalışmasında, Li-ion bataryalar için doğruluk düzeltmeli XGBoost algoritmasına dayalı SoH tahmin yöntemi önermişlerdir. XGBoost modeli, eğri uydurma (over-fitting) sorununu etkili bir şekilde önleyebilen Li-ion bataryada SoH tahmin etmek için kullanılmıştır. Yazarlar ayrıca XGBoost modelinin, random forest, k-nearest neighbor (KNN), SVM, lineer regresyon yöntemleri ile karşılaştırmış ve tahmin doğruluğunu Markov zinciri ile düzeltmişlerdir.

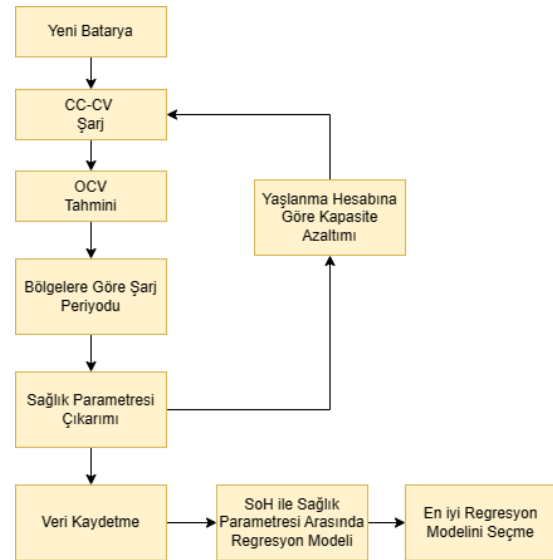
Wu ve ark. [6] çalışmasında, yeni bir özellik seçme yöntemi önermektedir. Yöntem, gerçek elektrikli araç verilerine dayalı olarak, DFA (Difficulty of Feature Acquisition) olarak adlandırılan bir özellik edinme zorluğu kullanılarak ve parçacık sürüsü optimizasyonu (Particle Swarm Optimization - PSO) algoritması kullanılarak optimize edilmektedir. Sırt (ridge) regresyonu kullanılarak seçilen özelliklerle SoH arasındaki ilişki modellemekte ve doğru özelliklerin belirlenmesine yardımcı olmaktadır. Doğru seçilmiş özellikler ve lineer model birleştirilerek güvenilir bir SoH tahmini yapılabilmektedir. Gerçek bir elektrikli araçtaki üçlü batarya üzerinde çalışan Hong ve ark. [49], Çin Elektrikli Araçlar için Ulusal İzleme ve Yönetim Platformundan geçmiş çalışma verilerini türeten gerçek senaryo tabanlı bir termal kaçak tahmini sunmaktadır. Çalışma, batarya arızalarının teşhisi için değiştirilmiş çok ölçekli entropi (Modified Multiscale Entropy - MMSE) yönteminin kullanmıştır. MMSE, örnek entropisine dayalı olarak hesaplanır ve genellikle teşhis işlemlerinde kullanılmaktadır. Örnek entropisi, zaman serisinin karmaşıklığını ölçebilmektedir. Ayrıca, gerçek araç kazası üzerinde batarya durumlarının değerlendirilmesi ve batarya termal kaçaklarına karşı koruma sağlanması için çok düzeyli anormal katsayılar belirlemeyi de ele almaktadır.

Elektrikli araç kullanımı için küresel batarya performanslarının gerçek zamanlı tahmini için Barr' ve ark. [50] çalışmasında, performans düzeyine göre batarya sinyallerinin davranışındaki değişikliklere dayalı bir model oluşturulmuşlardır. Sunulan yöntem, gerçek zamanlı batarya performanslarının tahminini mümkün kılmak için batarya sinyallerinin davranışındaki değişikliklere dayalı bir model oluşturmaktadır. Bu model, gerçek kullanımlarda belirli hızlanma profillerine karşılık gelen batarya sinyallerinin seçilmesinden oluşmuştur. Daha sonra, her bir SoH özelliği için batarya davranışını belirlemek üzere bu voltaj ve akım modelleri kullanılmıştır. İncelenen örüntüler, sinyal işleme teknikleri kullanılarak karşılaştırılmış ve batarya performansının tahmin edilmesi için istatistiksel öğrenme yöntemleri uygulanmıştır.

Jorge ve ark. [51] çalışmasında ise, yaşlanma verilerine uygulanan makine öğrenimi regresyon yöntemlerini kullanarak Li-ion bataryaların RUL tahmini yapmışlardır. Yapay sinir ağları ile yaşlanma verilerinin temsilinin nasıl oluşturulacağı araştırılmış ve tahmin performansları elde edilmiştir. Çalışma, düşük hesaplamalı yaklaşımları kullanarak veri kümesinde ilk çalışma olduğu belirtilmiştir.

Roman ve ark. [52] çalışmasında, batarya kapasitesinin tahmin edilmesi için yeni makine öğrenimi algoritmaları ve belirsizlik ölçülmesi için metrikler tanımlamışlardır. Çalışma batarya sağlığı ve belirsizlik yönetimi akışı (Battery Health and Uncertainty Management Pipeline - BHUMP) adlı yeni bir makine öğrenimi algoritması önermektedir. Bu algoritma, batarya SoH'sinin ve belirsizliğinin gerçek zamanlı tahminini yapabilen bir veri işleme yöntemi kullanılmaktadır. BHUMP, çeşitli batarya tasarımları ve kimyaları üzerinde test edilmiş ve herhangi bir hücre kimyasına ve çalışma koşuluna uyarlanabilen, ölçeklenebilir bir SoH tahmini olarak sunulmuştur. Geliştirilen algoritma, bataryaların içsel bozulmasını yakalayabilen bir dizi mühendislik özelliği kullanarak ve batarya performansını iyileştirdiği, hücre ömrünü uzattığı gözlemlenmiştir.

Jain ve ark. [53] çalışmasında, batarya SoC tahmin edilmesi için regresyon modelleri kullanarak voltaj aralığının seçimini, bataryanın CC-CV şarjı ve sağlık faktörünü kullanarak gerçekleştirmişlerdir. Sağlık parametresinin çıkarılması ve regresyon modeli yardımıyla SoH ile sağlık parametresi arasında doğrusal bir ilişki açıklanmıştır. Şekil 6, SoH tahmini için geliştirdikleri akış şemasını göstermektedir [53]. Zhang ve ark. ise [54] çalışmasında, batarya hücresi SoH'sini tahmin etmek için çarpışma deformasyon özellikleri kullanarak bir yöntem önermektedir. Yeni batarya hücreleri çarpışma etkilerinin araştırılması için test edilmiş ve deforme olmuş hücrelerin hasar karakterizasyonu gerçekleştirilerek sınıflandırılmıştır. Deformasyona uğramış batarya hücrelerinin sınıflandırılması için, 3D tarama yöntemiyle bozulma verileri elde edilmiş ve ardından bu 3D görüntü örneklerinden geometrik özellikler türetilerek örüntü tanıma yapay sinir ağı tabanlı bir yöntem kullanılmıştır.



Şekil 6. SoH tahmini için akış şeması

Deneysel veriler kullanılarak Liu ve ark. [55] çalışmasında, Li-ion bataryaların ömür özellikleri analiz etmişlerdir. Bataryaların ömrü, döngü sayısı ile değişir ve batarya kapasitesi, deşarj verimliliği, enerji verimliliği, iç direnç ve batarya ömrü ile diğer parametrelerdeki değişiklikler incelemiştir. Çalışmada, SoH'yi tahmin etmek için voltaj eğrisi uydurma yöntemi kullanılmıştır.

Yang ve ark. [56] çalışmasında, Peukert Yasası'na dayalı dinamik bir batarya SoH tahmin yöntemi önermişlerdir. Önerilen yöntem, kapasite kaybını Peukert katsayısı ile

ilişkilendirilmiş ve bozulma tutarsızlığını ortadan kaldırmıştır. Çoklu deşarj testi ile Peukert katsayısı hesaplanarak batarya sağlığı tahmin edilmiştir.

Stroe ve Schaltz [57] çalışmasında, artımlı kapasite analizi (Incremental Capacity Analysis - ICA) tekniğinin LMO/NMC ($\text{LiMn}_2\text{O}_4/\text{LiNiMnCoO}_2$) tabanlı EA Li-ion bataryaların kapasite azalmasını ve SoH'sini tahmin etmek için kullanmışlardır. ICA tekniği kullanılarak elde edilen artımlı kapasite değerlerinden birine karşılık gelen voltaj değerleri, bataryanın kapasite kaybı ile ilişkilendirilmiştir. Chowdhury ve ark. [58] çalışmasında, seri olarak bağlanan Li-ion batarya hücrelerinin SoH'sini dengelemek için DC/DC dönüştürücüler aracılığıyla bağlanan batarya hücreleri için basitleştirilmiş bir SoH dengeleme topolojisi önermişlerdir. Yöntem, tek tek hücrelerin kontrolünü birleştirerek, sistemdeki en düşük SoH batarya hücresiyle birleştirerek, genel batarya ünitesinin SoH'sini arttırdığı ve bataryanın değiştirme maliyetlerini azalttığı gözlemlenmiştir. Pang ve ark. [59] çalışmasında, (hibrit) elektrikli araçlar için kurşun asitli batarya SoC tahmini sorununu ele almaktadır. Bu sorun, sürücü ve otomatik enerji yönetimi için doğru bir şekilde kalan batarya kapasitesini tahmin etmekle ilgilidir. Çalışma, sorunun tanımını, mevcut çözüm yöntemlerini, yeni bir çözüm yöntemi önerisini ve bu yöntemin performansının deneysel analizini içermektedir.

Zhou ve ark. [60] çalışmasında, BMS ve bulut büyük veri platformunun birleşiminin mimarisini önermektedir. Ortalama voltaj düşüşü (Mean Voltage Falloff - MVF) ölçümleri kullanılarak bir kapasite ve MVF regresyon modeli kurulmuştur. Kapasite ve MVF, bulut büyük veri platformuna yüklenmiş ve MVF'nin ortalaması ve varyansı tahmin edilmiştir, böylece Li-ion batarya sağlık durumuna ilişkin aralık tahmini ve kalan faydalı ömrün belirlenmesi için olasılık yoğunluk fonksiyonu tahmini gerçekleştirilmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir.

Xu ve ark. [62] çalışmasında, Li-ion bataryaların çok tipli arıza teşhisinde kullanılabilen bir araç-bulut işbirlikçi yöntemi tanıtmaktadır. İlk olarak, normal ve arızalı batarya modüllerinin şarj-deşarj koşulları simüle edilerek batarya sisteminin simülasyon modeli oluşturulmuştur. Hücre farkı modeli kullanılarak araç tarafındaki özellik farklılıkları çıkartılmış ve karar ağacı sınıflandırıcısı eğitilerek gerçek zamanlı takip için muhakeme eşikleri belirlenmiştir. Batarya sistemleri için farklı arızaların simülasyon deneyleri sonucunda, batarya sistemleri simülasyon modeli (Battery System Simulation Model - BSSM) oluşturulmuştur. Bu model hem normal batarya modüllerinin hem de arızalı batarya modüllerinin şarj-deşarj durumlarını simüle etmek için kullanılmaktadır.

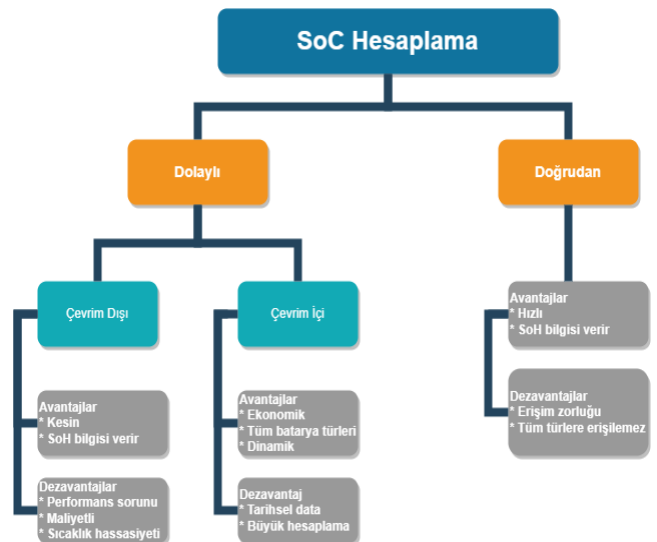
Yang ve ark. [63] çalışmasında, derin öğrenme yöntemleri kullanılarak batarya bozulma özellikleri elde edilmiş ve bataryanın kalan kullanım ömrü tahmini üzerinde deneysel sonuçlar gösterilmiştir. NASA [61] ve Oxford [64] batarya bozulma veri kümeleri kullanılarak doğrulan bir yöntem, sunulan modelin, RMSE'nin %1'den az olduğu durumlarda SoH tahmin doğruluğu ve genelliği sağladığını göstermektedir.

Sun ve ark. [65] çalışmasında, BMS çevrimiçi verilere dayanan çoklu bireysel algoritmaları önermektedir. Çalışma, ortak kapasite tahmini için indüklenmiş sıralı ağırlıklı ortalama (Induced Ordered Weighted Average - IOWA) operatörünü tanıtmaktadır. Ayrıca, genetik algoritma (Genetic Algorithm - GA) tarafından optimize edilen sinir ağı çalışması, BMS'den tarihsel durum mesajı ile güçlü sağlamlık ve doğru tahmin için büyük veri platformuna yüklenmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir. Ayrıca Chehade ve Hussein [66] çalışmasında, Li-ion batarya hücrelerinin

kapasitesini tahmin etmek için bir yöntem önermişlerdir. Yöntem, bir Gauss Süreç Regresyon modelini kullanmaktadır. Önerilen yöntem, yüksek tahmin doğruluğu ve sağlamlığın yanı sıra, farklı batarya hücreleri arasındaki kapasite eğilimlerini ilişkilendirme yeteneğine sahiptir. Farklı batarya hücrelerinin çoklu kapasite eğilimlerini işbirlikçi bir şekilde modellemek için İşbirlikçi Gauss süreci regresyonu (Collaborative Gaussian process regression - CGPR) olarak adlandırılan, kovaryans işlevine sahip çok çıkışlı bir Gauss süreci önerilmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir.

Wang ve ark. [67] çalışmasında, gelecekteki batarya yönetim sistemleri için bulut işbirlikçi ve dijital ikiz teknolojisi önermişlerdir. Batarya yönetimi için bulut tarafı iş birliğinin dört katmanlı ağ bağlantılı mimarisi sunulmuştur. Bataryanın dijital ikiz modeli oluşturulmuş ve batarya tüm yaşam döngüleri boyunca hassas ve güvenli bir şekilde yönetilmesi sağlanmıştır. Eksik veri problemlerini çözmek için, bir tahmin modeli tasarlanmıştır. Model, eksikliği sorununun üstesinden gelmek için işbirlikçi özellik çıkarıcı kullanılmış ve karmaşıklık sorunları için artırılmış gizli katmana sahip bir sinir ağı kullanılmıştır. Berghout ve ark. [68] çalışmasında, NASA batarya veri setini [61] kullanarak, doğrusal regresyon modelleri, destek vektör makinesi, Gauss süreç regresyonu, aşırı öğrenme makinesi ve yapay sinir ağları yöntemleri incelemişlerdir. Çalışmada, batarya ömrü döngülerinin bozulma modelleri ve etiketlerinin eksikliği problemlerine odaklanılmıştır.

Ayrıca BMS ve prognostik alanında yapılan gözden geçirme çalışmaları da mevcuttur. Rezvanianiani ve ark. [14], Omariba ve ark. [20] çalışmalarında, batarya PHM tekniklerinin incelemesini sunarak, batarya üreticileri, otomobil tasarımcıları ve elektrikli araç sürücülerini için bu alandaki temel ihtiyaçlara odaklanmaktadır. Literatürün analitik bir incelemesini yapan çalışmalarda, BMS fırsat ve zorluklarına giriş yapılmaktadır. Ayrıca, batarya sağlığı yönetimi konusunda geleceğe yönelik araştırma gündemi sunulmakta ve bu inceleme çalışmalarında ortaya konulan sorunlarla birlikte daha fazla araştırma yapmanın önemine dikkat çekilmektedir. BMS'inde akım, voltaj ve sıcaklık gibi doğrudan bataryadan ölçülebilen değişkenler, SoC'nin doğru bir tahminini sağlamak için kullanılabilir. Şekil 7, bazı örneklerle SoC teknikleri sınıflandırmasının özetini göstermektedir [69], [70].



Şekil 7. En önemli SoC tahmin yöntemleri

Sarmah ve ark. [28] çalışmasında, kapsamlı literatür çalışmaları yürüterek bataryaların SoH tahmini için modellerin ve yöntemlerin ilerlemesi, zorlukları, endişeleri ve fütüristik yönleri hakkında bilgi sunmaktadır. SoH tahmini için yöntemler ve modeller, avantaj ve dezavantajları ile sistematik olarak Tablo 2'de özetlenmiştir. Ayrıca, Roscher ve Sauer [21] Li-ion batarya yönetim sistemlerinin bir incelemesini yaparak, bir BMS içindeki ana ölçüm parametreleri, durum tahmin yöntemleri, hücre eşitleme sorunları, termal yönetim stratejileri ve araştırma eğilimleri ve ilerlemeleri dahil olmak üzere temel unsurları ve zorlukları önerilerle tartışmaktadır.

Tablo 2. Li-ion pilin sağlık durumu tahmini için çeşitli yöntemlerin nicel analizi

Yöntem	Tür	Gerçek SoH deneysel (%)	Tahmini SoH yaklaşık (%)	Tahmini hata yaklaşık (%)
Coulomb Sayımı	Model Tabanlı	63.85	69.78	<10
Elektrokimyasal Empedans	Model Tabanlı	85	86.27	<2.1
Spektroskopisi	Veriye Dayalı	82	82.3	<0.5
Sinir Ağı	Veriye Dayalı	60.35	59.19	<2
Destek Vektör Makinesi	Model Tabanlı	84.36	86.57	≤5
Kalman Filtresi	Model Tabanlı	90.13	90.26	<2.5
Kayan Mod Gözlemcisi	Model Tabanlı	88	91.62	1.4-9.2
Bulanık Mantık	Veriye Dayalı			

Ana batarya SoH tahmin yöntemlerinin bir incelemesini yapan Noura ve ark. [71] çalışmasında, ana avantajlarını ve gerçek zamanlı otomotiv uyumluluğu ve özellikle hibrit elektrik uygulamaları açısından sınırlamalarına işaret etmektedir. Çalışmada gerçek zamanlı fizibilitesini ve doğruluğunu göstermek için model tabanlı uyarlamalı filtreleme kullanan çevrimiçi ve yerleşik bir SoH tahmin yönteminin deneysel doğrulanması yapılmaktadır.

Bataryaların sağlık durumu ve şarj durumunu tahmin etmek, günümüzde batarya verilerinin daha fazla kullanılabilir hale gelmesi ve bilgi işlem gücü yeteneklerinin geliştirilmesi sayesinde, veriye dayalı yaklaşımların, özellikle makine öğrenimi yöntemlerinin popüler hale gelmesine neden olmuştur. Xiong ve ark. [72] çalışmasında, bu iki yaklaşımı karşılaştırmak amacıyla; ileri beslemeli sinir ağları, tekrarlayan sinir ağları, destek vektör makineleri, radyal temel fonksiyonlar ve Hamming ağları gibi makine öğrenimi yöntemlerine dayanan batarya durumu tahmin yöntemlerinin bir incelemesini sunmuşlardır. İnceleme, yöntemler arasındaki karşılaştırmaları yaparak, bataryaların şarj durumu ve sağlık durumu tahmini için makine öğrenimi yaklaşımlarını açıklamıştır. Bu karşılaştırmalar, veri kalitesi, girdiler ve çıktılar, test koşulları, batarya türleri ve belirtilen doğruluk açısından yapılmıştır.

Bataryaların şarj durumunu tahmin etmek için kullanılan tahmin yöntemleri ve algoritmaları ayrı ayrı ele alan bir başka inceleme Xiong ve ark. [73], hücre kapasitesi, direnç ve voltajdaki tutarsızlıkların mevcut olduğu batarya takımları için gelişmiş karakterize edici seçimi ve sapma düzeltme yöntemlerini tarif etmektedir. İnceleme, batarya şarj durumunun doğru tahmini için temel geri bildirim faktörlerini

de sunar ve batarya yönetim sistemleri ve enerji yönetimi stratejileri için uygun bir yöntemin seçilmesine yardımcı olmaktadır. Son olarak, inceleme, elektrikli araçlar ve batarya enerji depolama sistemleri için akıllı batarya yönetim sistemlerinin geliştirilmesi için olası öneriler sunarak, bir dizi temel faktör ve zorluğu da vurgulamaktadır.

Li-ion bataryaların güvenli ve güvenilir çalışması, BMS tarafından sağlanabilmektedir. Bu sistem, batarya SoC'sini değerlendirebilen ve aşırı şarj/aşırı deşarjdan koruyan stratejiler uygulayarak bataryanın kalan kullanılabilir enerjisini belirleyebilmektedir. SoC'nin çok önemli bir parametre olduğu için, mevcut Li-ion bataryaların SoC'lerinin şarj/deşarj kabiliyetleri, EA'ların güvenli ve verimli çalışmasına katkı sağlamaktadır. Bu nedenle, BMS'nin geliştirilmesi ve yeni nesil EA uygulamalarında SoC tahmini için olası önerilerle birlikte birçok faktörü ve zorluğu vurgulayan inceleme Hannan ve ark. [10], gelecekteki yüksek teknoloji EA uygulamaları için gelişmiş SoC tahmin yöntemlerinin ve Li-ion bataryaların enerji yönetim sistemlerinin geliştirilmesine çalışmaları göstermiştir.

Yao ve ark. [74] çalışmasında SoH'nin bozulma mekanizması ve ana tanımları, literatürler özetlenerek açıklamışlardır. Çalışmada SoH tahmini ve tahmin yöntemleri, model tabanlı yöntemler, veriye dayalı yöntemler ve füzyon teknolojisi yöntemleri tartışılmıştır. Mevcut ana akım SoH tahmin ve tahmin yöntemlerinin avantajları ve dezavantajları özetlenmiştir. Yazarlar, bulut platformu ve diğer teknolojilerle birleştirilen yenilikçi özellik çıkarma ve çoklu algoritma bağlantısının, sağlık durumu tahmini ve Li-ion batarya performansının geliştirilmesinde önemli bir rol oynadığını belirtmektedir.

Abdelaal ve ark. [75] çalışmasında, EA çekiş sistemi için Bulanık Mantık kullanarak, batarya enerji yönetimi tekniği sunmaktadır. Önerilen teknik, endirekt alan odaklı indüksiyon motoru tahrik sistemini düzenlemeyi amaçlamakta ve li-ion batarya bankasının şarj durumu azalmasını ve sağlık durumu bozulmasını en aza indirmektedir. Ayrıca sürüş profilleri veya yol bilgisi gerektirmeden çalışır ve batarya ömrünü uzatmaya yardımcı olur. Gerçek zamanlı bir prototip EV çekiş sistemi üzerinde yapılan deneyler, önerilen tekniklerin geleneksel yöntemlere kıyasla batarya SOC'unda daha az azalma ve SOH bozulması sağladığını göstermektedir.

Hong ve ark. [76] çalışmasında, EA bataryaları için gerçek zamanlı bir arıza teşhis ve izolasyon şeması sunar. Yüksek frekanslı Ayırık dalgacık ayrışımı (Discrete wavelet decomposition) kullanılarak erken arıza sinyallerinin özellikleri çıkarılır ve termal kaçış öncesinde batarya arızalarını doğru bir şekilde tespit edip izole eder. Önerilen yöntemin güvenilirliği ve stabilitesi gerçek araç işletme verileri üzerinde doğrulanmıştır. Bu, sürücülerini ve yolcuları gerçek dünya araç işletmesinde korur.

Li ve ark. [77] çalışmasında, elektrikli araç bataryalarının güvenliği için önemli olan bir batarya arıza teşhis yöntemi sunmaktadır. Bu yöntem, LSTM ve eşdeğer devre modelinin (Equivalent Circuit Model) birleşimini kullanarak, batarya arızalarını doğru bir şekilde tespit etmekte ve termal kaçış gibi ciddi olayları önceden tahmin etmektedir. Çin'deki bir araç izleme merkezinden elde edilen gerçek işletme verileri, yöntemin etkinliğini doğrulamaktadır.

Bu çalışma karşılaşılan veriye dayalı yöntemlerde ise en sık gözlemlenen algoritma Destek Vektör Makineleri olmuştur (Tablo 3).

Tablo 3. İncelenen çalışmaların veriye dayalı yöntemlere göre sınıflandırılması

Yöntem
Destek Vektör Makinesi
ANN
LSTM
İleri Beslemeli Yapay Sinir Ağı
Uyarlamalı Yapay Sinir Ağı
Rasgele Orman
Regresyon Modeli
Radyal Tabanlı Fonksiyon Ağı
Genetik Algoritmalar
DC/DC Çevirici
Anahtarlı Kapasite
Peukerts Kuralı
XGBoost
Artırımlı Kapasite Analizi
Brown Hareketi
K-En yakın Komşular
Tekrarlamalı Yapay Sinir Ağı

Tablo 4 ve Tablo 5, incelenen çalışmaların yıllara ve dergilere göre dağılımlarını göstermektedir. 2001 ile 2023 arasında incelenen çalışmalara odaklandığımızda, IEEE komitesindeki dergi ve konferanslarda yayınlanan çalışmaların batarya alanındaki araştırmalar için oldukça popüler olduğunu gözlemliyoruz. Yıllara göre yapılan bir inceleme, son dönemde yapılan çalışmaların (44 adet) eski çalışmalara göre (35 adet) daha yüksek bir yoğunlukta olduğunu ortaya koymaktadır.

Tablo 4. İncelenen çalışmaların yayınlanan yıllara göre sınıflandırılması

Yayın Yılı	Yayın Sayısı
2023	3
2022	7
2021	11
2020	12
2019	4
2018	7
Daha Eski	35


Tablo 5. İncelenen çalışmaların yayınlanan dergilere göre sınıflandırılması

Dergi Adı	Yayın Sayısı
IEEE Dergi ve Konferansları	24
Journal of Power Sources	8
Energies	5
Renewable and Sustainable Energy Reviews	3
World Electric Vehicle Journal	3
Applied Energy	2
Electronics	2
Journal of Energy Storage	2
DİĞER	29

2.6 Literatürde Kullanılan Veri Setleri

Batarya özellikleri ve performansı üzerine yapılan çalışmalarda kullanılan veri setleri literatürde sıkça karşılaşılmaktadır. Şekil 8'de genel bir batarya test sistemi blok diyagramı görülmektedir [78]. Bu çalışmada incelenen literatürde en yaygın olarak kullanılan NASA batarya veri setidir [61]. Bu veri setinin için kullanılan test tezgâhi özellikleri:

- Piyasada bulunan Li-ion 18650 boyutlu şarj edilebilir piller, (18-65-0, 18 mm çap, 65 mm uzunluk ve 0 silindirik pil)
- Programlanabilir 4 kanallı DC elektronik yük,
- Programlanabilir 4 kanallı DC güç kaynağı,
- Voltmetre, ampermetre ve termokupl sensör takımı,
- Özel ÇBS ekipmanları,
- Çeşitli çalışma koşulları empoze etmek için çevre odası,
- PXI kasa tabanlı DAQ ve deney kontrolü



Şekil 8. Batarya test sistemi blok diyagramı

Bu çalışmalarda kullanılan batarya veri setleri Tablo 6'da özetlenmiştir. Veri setleri, bataryaların farklı özellikleri ve performanslarına göre farklılık göstermektedir. Bazı veri setleri, bataryaların ömrü ve yaşlanması hakkında bilgi sağlamak amacıyla tasarlanmışken, bazıları bataryaların kapasitesi ve enerji yoğunluğu gibi performans özellikleri hakkında bilgi vermektedir. Bu veri setleri, batarya yönetim sistemleri ve batarya prognostik uygulamaları gibi batarya teknolojisi ile ilgili birçok alanda kullanılmaktadır. İnternette açık kullanıma sunulan aşağıdaki veri setleri bataryaların özellikleri ve performansı hakkında daha kapsamlı bir anlayış sağlamak için araştırmalarda yaygın olarak kullanılmaktadır. Aşağıdaki tabloda "gr", "grafit", "Cal", takvim yaşlanmasını, "Chrg" şarj protokolü ve "Dhrg" deşarjını, "E", "enerji" anlamına gelmektedir. "IR" iç direnci ve empedansı belirtir.

Tablo 6. Literatürde yaygın olarak kullanılan veri setleri

Veri seti	Batarya hücresi	Test değişkenleri	Veri içeriği	Hücre sayısı
NASA [61],[79]	18650 2 Ah	Dhrg, T	Q, IR, V, I, T	34
CALCE [80]	18650 2.2 Ah LCO	Chrg, Dhrg, T	Q, IR, V, I, T	28
	prismatic 1.1 Ah LCO	Chrg, Dhrg	Q, IR, E, V, I, T	15
	prismatic 1.35 Ah LCO	Chrg, Dhrg, T	Q, IR, E, V, I, T	12
TRI [81]	pouch 1.5 Ah LCO	Chrg, DOD	Q, V, I	16
	18650 1.1 Ah LFP/gr	Chrg	Q, IR, V, I, T	124
		Chrg	Q, V, I, T	233
Sandia [82]	18650 multiples	Dhrg, DOD, T	Q, E, V, I, T	86
Oxford [64]	18650 3 Ah NCA/gr	Chrg, Cal	Q, E, V, I, T	28
HNEI [83]	18650 2.8 Ah NMC-LCO/gr	-	Q, E, V, I	15
Berkeley [84]	18650 2.6 Ah LCO/gr	Chrg	Q, V, I, T	1
Xi'an Jiaotong [85]	pouch 27 Ah NMC/gr	-	Q, E, V, I	2
	15 Ah NMC	Chrg, Dhrg, T	Q, V, I, T	-
Automotive Li-ion Cell Usage [86]		Chrg, Dhrg, T	Q, V, I, T	-
eVTOL [87]	-			-
Cycle Life Prediction [88]	1.1 Ah	Chrg	Q, V, I, T	135
Stanford [89]	4.85 Ah NMC-LCO/gr	Chrg	Q, V, I, T	-
	1.1 Ah LFP/gr	Chrg	Q, V, I, T	
Fast-Charging [90]	1.1 Ah LFP/gr	Chrg	Q, V, I	48
Synthetic [91]	18650 2.9 Ah LFP/gr	Chrg	Q, V, I, T	-
Panasonic [92]				-

3 Sonuçlar ve Öneriler

Bu çalışma, elektrikli araçlarda akıllı bir batarya yönetim sistemi için doğru prognostik ve sağlık yönetimi konusunda literatür incelemesi yapmıştır. Bu inceleme, elektrikli araçlarda akıllı batarya yönetim sistemlerinin önemini vurgulamakta ve bu alanda çalışma yapmayı düşünen araştırmacılar ve endüstri uzmanları için sağlam bir başlangıç noktası sağlamayı amaçlamaktadır.

Mevcut çalışmalar, doğru batarya SoC ve batarya SoH tahminlerinin, batarya ömrünün uzatılması ve güvenliğinin sağlanması açısından kritik olduğunu göstermektedir. Elektrikli araç teknolojisindeki ilerlemelerle birlikte, batarya yönetim sistemlerinin doğruluğu ve güvenilirliği, araç performansı ve sürüş güvenliği açısından giderek daha büyük önem kazanmaktadır. Bu nedenle, gelecekteki araştırmaların bu alanda daha fazla odaklanması ve batarya yönetim sistemlerinin daha da iyileştirilmesi gerekmektedir. Bu bağlamda, bu çalışmanın sağladığı literatür özeti ve vurguladığı kritik noktalar, ileriki araştırmalar için önemli bir kılavuz niteliği taşımaktadır.

Ancak, bu alanda hala bazı açık problemler bulunmaktadır. Gelecekteki araştırmalar, elektrikli araçların batarya yönetim sistemlerini daha da geliştirmek için aşağıdaki konulara odaklanabilir:

Batarya Modelleri ve Prognostik Yöntemleri: Batarya davranışını daha doğru bir şekilde modelleyen ve tahmin eden yeni batarya modelleri ve prognostik yöntemlerin geliştirilmesi önemlidir. Bu, bataryanın gerçek zamanlı performansının daha iyi izlenmesini ve tahmin edilmesini sağlayacaktır.

Veri Analitiği ve Büyük Veri: Elektrikli araçlar, büyük miktarda veri üreten bir ortam oluşturur. Bu verilerin etkili bir şekilde analiz edilmesi ve kullanılması, batarya sağlık durumunun daha iyi anlaşılmasına ve gelecekteki arıza veya sorunların önceden tahmin edilmesine yardımcı olacaktır.

Optimum Şarj ve Boşaltma Stratejileri: Batarya ömrünü uzatmak için optimize edilmiş şarj ve boşaltma stratejilerinin geliştirilmesi önemlidir. Bu stratejiler, bataryanın performansını artırmak ve enerji verimliliğini optimize etmek için bataryanın çalışma koşullarını en uygun şekilde belirlemeyi hedeflemektedir.

Yeni Malzemeler ve Teknolojiler: Batarya teknolojileri sürekli olarak gelişmektedir. Gelecekteki araştırmalar, bataryaların enerji yoğunluğunu artıran ve maliyetleri düşüren yeni malzemelerin ve teknolojilerin keşfine odaklanabilir.

Bu öneriler, elektrikli araçlar için daha güvenli, daha verimli ve daha dayanıklı batarya yönetim sistemlerinin geliştirilmesine katkıda bulunacaktır.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkıları

MY literatür incelemesi, bilimsel yayının hazırlanması, EC çalışma konsepti ve tasarım, taslağın oluşturulması, revizyon, AY çalışma konsepti ve tasarım, taslağın oluşturulması, revizyon konularında katkı sağlamıştır.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TUBİTAK) 22AG040 nolu "Sürdürülebilir Kentler için İleri Teknolojiler Platformu (SÜİT)" projesi tarafından desteklenmiştir.

Yazarlardan Metin Yılmaz 100/2000 YÖK Doktora bursu öğrencisidir.

Kaynaklar

- [1] J. Deng, C. Bae, A. Denlinger, ve T. Miller, "Electric Vehicles Batteries: Requirements and Challenges", *Joule*, c. 4, sy 3, ss. 511-515, Mar. 2020, doi: 10.1016/j.joule.2020.01.013.
- [2] A. Marongiu, F. G. W. Nußbaum, W. Waag, M. Garmendia, ve D. U. Sauer, "Comprehensive study of the influence of aging on the hysteresis behavior of a lithium iron phosphate cathode-based lithium ion battery - An experimental investigation of the hysteresis", *Applied Energy*, c. 171, ss. 629-645, Haz. 2016, doi: 10.1016/j.apenergy.2016.02.086.
- [3] M. M. Hoque, M. A. Hannan, ve A. Mohamed, *Model Development of Charge Equalization Controller for Lithium-Ion Battery*. 2016.
- [4] U. Yayan, A. T. Arslan, ve H. Yucel, "A Novel Method for SoH Prediction of Batteries Based on Stacked LSTM with Quick Charge Data", *Applied Artificial Intelligence*, c. 35, sy 6, ss. 421-439, May. 2021, doi: 10.1080/08839514.2021.1901033.
- [5] B. Yu, H. Qiu, L. Weng, K. Huo, S. Liu, ve H. Liu, "A Health Indicator for the Online Lifetime Estimation of an Electric Vehicle Power Li-Ion Battery", *World Electric Vehicle Journal*, c. 11, sy 3, Art. sy 3, Eyl. 2020, doi: 10.3390/wevj11030059.
- [6] J. Wu, X. Cui, H. Zhang, ve M. Lin, "Health Prognosis With Optimized Feature Selection for Lithium-Ion Battery in Electric Vehicle Applications", *IEEE Transactions on Power Electronics*, c. 36, sy 11, ss. 12646-12655, Kas. 2021, doi: 10.1109/TPEL.2021.3075558.
- [7] G. Dong, W. Han, ve Y. Wang, "Dynamic Bayesian Network-Based Lithium-Ion Battery Health Prognosis for Electric Vehicles", *IEEE Transactions on Industrial Electronics*, c. 68, sy 11, ss. 10949-10958, Kas. 2021, doi: 10.1109/TIE.2020.3034855.
- [8] X. Hu, J. Jiang, D. Cao, ve B. Egardt, "Battery Health Prognosis for Electric Vehicles Using Sample Entropy and Sparse Bayesian Predictive Modeling", *IEEE Transactions on Industrial Electronics*, c. 63, sy 4, ss. 2645-2656, Nis. 2016, doi: 10.1109/TIE.2015.2461523.
- [9] G. Dong, Z. Chen, J. Wei, ve Q. Ling, "Battery Health Prognosis Using Brownian Motion Modeling and Particle Filtering", *IEEE Transactions on Industrial Electronics*, c. 65, sy 11, ss. 8646-8655, Kas. 2018, doi: 10.1109/TIE.2018.2813964.
- [10] M. A. Hannan, M. S. H. Lipu, A. Hussain, ve A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations", *Renewable and Sustainable Energy Reviews*, c. 78, ss. 834-854, Eki. 2017, doi: 10.1016/j.rser.2017.05.001.
- [11] S. M. Rezvanianiani, Z. Liu, Y. Chen, ve J. Lee, "Review and recent advances in battery health monitoring and prognostics technologies for electric vehicle (EV) safety and mobility", *Journal of Power Sources*, c. 256, ss. 110-124, Haz. 2014, doi: 10.1016/j.jpowsour.2014.01.085.
- [12] H. Wenzl vd., "Life prediction of batteries for selecting the technically most suitable and cost effective battery", *Journal of Power Sources*, c. 144, sy 2, ss. 373-384, Haz. 2005, doi: 10.1016/j.jpowsour.2004.11.045.
- [13] C. Armenta-Deu ve T. Donaire, "Determination of an ageing factor for lead/acid batteries. 1. Kinetic aspects", *Journal of Power Sources*, c. 58, sy 2, ss. 123-133, Şub. 1996, doi: 10.1016/S0378-7753(96)02371-3.
- [14] K. Qian, C. Zhou, M. Allan, ve Y. Yuan, "Modeling of Load Demand Due to EV Battery Charging in Distribution Systems", *IEEE Transactions on Power Systems*, c. 26, sy 2, ss. 802-810, May. 2011, doi: 10.1109/TPWRS.2010.2057456.
- [15] M. Urbain, S. Rael, B. Davat, ve P. Desprez, "State Estimation of a Lithium-Ion Battery Through Kalman Filter", içinde *2007 IEEE Power Electronics Specialists Conference*, Haz. 2007, ss. 2804-2810. doi: 10.1109/PESC.2007.4342463.
- [16] R. C. Kroeze ve P. T. Krein, "Electrical battery model for use in dynamic electric vehicle simulations", içinde *2008 IEEE Power Electronics Specialists Conference*, Haz. 2008, ss. 1336-1342. doi: 10.1109/PESC.2008.4592119.
- [17] Z. B. Omariba, L. Zhang, ve D. Sun, "Review on Health Management System for Lithium-Ion Batteries of Electric Vehicles", *Electronics*, c. 7, sy 5, Art. sy 5, May. 2018, doi: 10.3390/electronics7050072.
- [18] Y. Guo, X. Cai, S. Shen, G. Wang, ve J. Zhang, "Computational prediction and experimental evaluation of nitrate reduction to ammonia on rhodium", *Journal of Catalysis*, c. 402, ss. 1-9, Eki. 2021, doi: 10.1016/j.jcat.2021.08.016.
- [19] A. M. Andwari, A. Pesiridis, S. Rajoo, R. Martinez-Botas, ve V. Esfahanian, "A review of Battery Electric Vehicle technology and readiness levels", *Renewable and Sustainable Energy Reviews*, c. 78, ss. 414-430, Eki. 2017, doi: 10.1016/j.rser.2017.03.138.
- [20] K. Javed, R. Gouriveau, ve N. Zerhouni, "State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels", *Mechanical Systems and Signal Processing*, c. 94, ss. 214-236, Eyl. 2017, doi: 10.1016/j.ymssp.2017.01.050.

- [21] Z. Li, "Lithium-Ion Battery Management System for Electric Vehicles", *International Journal of Performability Engineering*, c. 14, Ara. 2018, doi: 10.23940/ijpe.18.12.p28.31843194.
- [22] H. Rahimi-Eichi, U. Ojha, F. Baronti, ve M.-Y. Chow, "Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles", *EEE Ind. Electron. Mag.*, c. 7, sy 2, ss. 4-16, Haz. 2013, doi: 10.1109/MIE.2013.2250351.
- [23] D. Tingting, L. Jun, Z. Fuquan, Y. Yi, ve J. Qiqian, "Analysis on the influence of measurement error on state of charge estimation of LiFePO₄ power Battery", içinde *2011 International Conference on Materials for Renewable Energy & Environment*, May. 2011, ss. 644-649. doi: 10.1109/ICMREE.2011.5930893.
- [24] Y. Xing, E. W. M. Ma, K. L. Tsui, ve M. Pecht, "Battery Management Systems in Electric and Hybrid Vehicles", *Energies*, c. 4, sy 11, Art. sy 11, Kas. 2011, doi: 10.3390/en4111840.
- [25] J. P. Rivera-Barrera, N. Muñoz-Galeano, ve H. O. Sarmiento-Maldonado, "SoC Estimation for Lithium-ion Batteries: Review and Future Challenges", *Electronics*, c. 6, sy 4, Art. sy 4, Ara. 2017, doi: 10.3390/electronics6040102.
- [26] J. Wu, C. Zhang, ve Z. Chen, "An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks", *Applied Energy*, c. 173, ss. 134-140, Tem. 2016, doi: 10.1016/j.apenergy.2016.04.057.
- [27] P. Ramadass, B. Haran, R. White, ve B. N. Popov, "Mathematical modeling of the capacity fade of Li-ion cells", *Journal of Power Sources*, c. 123, sy 2, ss. 230-240, Eyl. 2003, doi: 10.1016/S0378-7753(03)00531-7.
- [28] S. B. Sarmah vd., "A Review of State of Health Estimation of Energy Storage Systems: Challenges and Possible Solutions for Futuristic Applications of Li-Ion Battery Packs in Electric Vehicles", *Journal of Electrochemical Energy Conversion and Storage*, c. 16, sy 4, Mar. 2019, doi: 10.1115/1.4042987.
- [29] M. A. Roscher ve D. U. Sauer, "Dynamic electric behavior and open-circuit-voltage modeling of LiFePO₄-based lithium ion secondary batteries", *Journal of Power Sources*, c. 196, sy 1, ss. 331-336, Oca. 2011, doi: 10.1016/j.jpowsour.2010.06.098.
- [30] E. Raszmann, K. Baker, Y. Shi, ve D. Christensen, "Modeling stationary lithium-ion batteries for optimization and predictive control", içinde *2017 IEEE Power and Energy Conference at Illinois (PECI)*, Şub. 2017, ss. 1-7. doi: 10.1109/PECI.2017.7935755.
- [31] J. Ordoñez, E. J. Gago, ve A. Girard, "Processes and technologies for the recycling and recovery of spent lithium-ion batteries", *Renewable and Sustainable Energy Reviews*, c. 60, ss. 195-205, Tem. 2016, doi: 10.1016/j.rser.2015.12.363.
- [32] M. Dubarry, A. Devie, ve B. Y. Liaw, "The Value of Battery Diagnostics and Prognostics", *Journal of Energy and Power Sources*, c. 1, ss. 242-249, Eyl. 2014.
- [33] M. Daowd, M. Antoine, N. Omar, P. Lataire, P. Van Den Bossche, ve J. Van Mierlo, "Battery Management System—Balancing Modularization Based on a Single Switched Capacitor and Bi-Directional DC/DC Converter with the Auxiliary Battery", *Energies*, c. 7, sy 5, Art. sy 5, May. 2014, doi: 10.3390/en7052897.
- [34] A. Allam, S. Onori, S. Marelli, ve C. Taborelli, "Battery Health Management System for Automotive Applications: A retroactivity-based aging propagation study", içinde *2015 American Control Conference (ACC)*, Tem. 2015, ss. 703-716. doi: 10.1109/ACC.2015.7170817.
- [35] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background", *Journal of Power Sources*, c. 134, sy 2, ss. 252-261, Ağu. 2004, doi: 10.1016/j.jpowsour.2004.02.031.
- [36] X. Chen, W. Shen, M. Dai, Z. Cao, J. Jin, ve A. Kapoor, "Robust Adaptive Sliding-Mode Observer Using RBF Neural Network for Lithium-Ion Battery State of Charge Estimation in Electric Vehicles", *IEEE Transactions on Vehicular Technology*, c. 65, sy 4, ss. 1936-1947, Nis. 2016, doi: 10.1109/TVT.2015.2427659.
- [37] Y.-J. He, J.-N. Shen, J.-F. Shen, ve Z.-F. Ma, "State of health estimation of lithium-ion batteries: A multiscale Gaussian process regression modeling approach", *AIChE Journal*, c. 61, sy 5, ss. 1589-1600, 2015, doi: 10.1002/aic.14760.
- [38] S.-C. Huang, K.-H. Tseng, J.-W. Liang, C.-L. Chang, ve M. G. Pecht, "An Online SOC and SOH Estimation Model for Lithium-Ion Batteries", *Energies*, c. 10, sy 4, Art. sy 4, Nis. 2017, doi: 10.3390/en10040512.
- [39] S. Jafari ve Y.-C. Byun, "Prediction of the Battery State Using the Digital Twin Framework Based on the Battery Management System", *IEEE Access*, c. 10, ss. 124685-124696, 2022, doi: 10.1109/ACCESS.2022.3225093.
- [40] L. Wang, X. Zhao, Z. Deng, ve L. Yang, "Application of electrochemical impedance spectroscopy in battery management system: State of charge estimation for aging batteries", *Journal of Energy Storage*, c. 57, s. 106275, Oca. 2023, doi: 10.1016/j.est.2022.106275.
- [41] G. Saldaña, J. I. S. Martín, I. Zamora, F. J. Asensio, O. Oñederra, ve M. González, "Empirical Electrical and Degradation Model for Electric Vehicle Batteries", *IEEE Access*, c. 8, ss. 155576-155589, 2020, doi: 10.1109/ACCESS.2020.3019477.
- [42] M. Rezvani, M. AbuAli PhD, S. Lee, J. Lee, ve J. Ni PhD, "A Comparative Analysis of Techniques for Electric Vehicle Battery Prognostics and Health Management (PHM)", program adı: Commercial Vehicle Engineering Congress, Eyl. 2011, ss. 2011-01-2247. doi: 10.4271/2011-01-2247.
- [43] J. Hemdani, M. Soltani, A. J. Telmoudi, ve A. Chaari, "Prediction of aging of battery for electric vehicles based on a modified version of neural networks", içinde *2021 29th Mediterranean Conference on Control and Automation (MED)*, Haz. 2021, ss. 336-341. doi: 10.1109/MED51440.2021.9480161.
- [44] W. He, N. Williard, C. Chen, ve M. Pecht, "State of charge estimation for electric vehicle batteries under an adaptive filtering framework", içinde *Proceedings of the IEEE 2012 Prognostics and System Health Management Conference (PHM-2012 Beijing)*, May. 2012, ss. 1-5. doi: 10.1109/PHM.2012.6228849.
- [45] J. C. Álvarez Antón, P. J. García Nieto, F. J. de Cos Juez, F. Sánchez Lasheras, M. González Vega, ve M. N. Roqueñí Gutiérrez, "Battery state-of-charge estimator using the SVM technique", *Applied Mathematical Modelling*, c. 37, sy 9, ss. 6244-6253, May. 2013, doi: 10.1016/j.apm.2013.01.024.
- [46] A. Mammone, M. Turchi, ve N. Cristianini, "Support vector machines", içinde *WIREs Computational Statistics*, Kas. 2009, ss. 283-289. doi: 10.1002/wics.49.

- [47] S. Zhang, "A new method for lithium-ion battery's SOH estimation and RUL prediction", içinde *2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, May. 2018, ss. 2693-2697. doi: 10.1109/ICIEA.2018.8398166.
- [48] S. Song, C. Fei, ve H. Xia, "Lithium-Ion Battery SOH Estimation Based on XGBoost Algorithm with Accuracy Correction", *Energies*, c. 13, sy 4, Art. sy 4, Oca. 2020, doi: 10.3390/en13040812.
- [49] J. Hong *vd.*, "Thermal Runaway Prognosis of Battery Systems Using the Modified Multiscale Entropy in Real-World Electric Vehicles", *IEEE Transactions on Transportation Electrification*, c. 7, sy 4, ss. 2269-2278, Ara. 2021, doi: 10.1109/TTE.2021.3079114.
- [50] A. Barr', F. Suard, M. Gérard, ve D. Riu, "A Real-time Data-driven Method for Battery Health Prognostics in Electric Vehicle Use", *PHM Society European Conference*, c. 2, sy 1, Art. sy 1, 2014, doi: 10.36001/phme.2014.v2i1.1514.
- [51] I. JORGE, A. SAMET, T. MESBAHI, ve R. BONÉ, "New ANN results on a major benchmark for the prediction of RUL of Lithium Ion batteries in electric vehicles", içinde *2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA)*, Ara. 2020, ss. 1246-1253. doi: 10.1109/ICMLA51294.2020.00196.
- [52] D. Roman, S. Saxena, V. Robu, M. Pecht, ve D. Flynn, "Machine learning pipeline for battery state-of-health estimation", *Nat Mach Intell*, c. 3, sy 5, Art. sy 5, May. 2021, doi: 10.1038/s42256-021-00312-3.
- [53] P. Jain, S. Saha, ve V. Sankaranarayanan, "Novel method to Estimate SoH of Lithium-Ion Batteries", içinde *2021 Innovations in Energy Management and Renewable Resources(52042)*, Şub. 2021, ss. 1-5. doi: 10.1109/IEMRES2042.2021.9386881.
- [54] J. Zhang, X. Liu, A. Simeone, ve D. Lv, "A deformation-based approach to the SoH estimation of collided lithium-ion batteries", *IOP Conf. Ser.: Earth Environ. Sci.*, c. 463, sy 1, s. 012071, Mar. 2020, doi: 10.1088/1755-1315/463/1/012071.
- [55] X. Liu, J. Li, Z. Yao, Z. Wang, R. Si, ve Y. Diao, "Research on battery SOH estimation algorithm of energy storage frequency modulation system", *Energy Reports*, c. 8, ss. 217-223, May. 2022, doi: 10.1016/j.egy.2021.11.015.
- [56] A. Yang, Y. Wang, K. L. Tsui, ve Y. Zi, "Lithium-ion Battery SOH Estimation and Fault Diagnosis with Missing Data", içinde *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, May. 2019, ss. 1-6. doi: 10.1109/I2MTC.2019.8826888.
- [57] D.-I. Stroe ve E. Schartz, "SOH Estimation of LMO/NMC-based Electric Vehicle Lithium-Ion Batteries Using the Incremental Capacity Analysis Technique", içinde *2018 IEEE Energy Conversion Congress and Exposition (ECCE)*, Eyl. 2018, ss. 2720-2725. doi: 10.1109/ECCE.2018.8557998.
- [58] S. Chowdhury, M. N. Bin Shaheed, ve Y. Sozer, "An Integrated State of Health (SOH) Balancing Method for Lithium-Ion Battery Cells", içinde *2019 IEEE Energy Conversion Congress and Exposition (ECCE)*, Eyl. 2019, ss. 5759-5763. doi: 10.1109/ECCE.2019.8912932.
- [59] S. Pang, J. Farrell, J. Du, ve M. Barth, "Battery state-of-charge estimation", içinde *Proceedings of the 2001 American Control Conference. (Cat. No.01CH37148)*, Haz. 2001, ss. 1644-1649 c.2. doi: 10.1109/ACC.2001.945964.
- [60] Y. Zhou, H. Gu, T. Su, X. Han, L. Lu, ve Y. Zheng, "Remaining useful life prediction with probability distribution for lithium-ion batteries based on edge and cloud collaborative computation", *Journal of Energy Storage*, c. 44, s. 103342, Ara. 2021, doi: 10.1016/j.est.2021.103342.
- [61] "Li-ion Battery Aging Datasets | NASA Open Data Portal". Erişim: 27 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.nasa.gov/dataset/Li-ion-Battery-Aging-Datasets/uj5r-zjdb>
- [62] C. Xu, L. Li, Y. Xu, X. Han, ve Y. Zheng, "A vehicle-cloud collaborative method for multi-type fault diagnosis of lithium-ion batteries", *eTransportation*, c. 12, s. 100172, May. 2022, doi: 10.1016/j.etran.2022.100172.
- [63] X. Yang *vd.*, "Lithium-Ion Battery State of Health Estimation with Multi-Feature Collaborative Analysis and Deep Learning Method", *Batteries*, c. 9, sy 2, Art. sy 2, Şub. 2023, doi: 10.3390/batteries9020120.
- [64] C. Birkel, "Oxford Battery Degradation Dataset 1", 2017, Erişim: 27 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://ora.ox.ac.uk/objects/uuid:03ba4b01-cfed-46d3-9b1a-7d4a7bdf6fac>
- [65] T. Sun *vd.*, "A cloud-edge collaborative strategy for capacity prognostic of lithium-ion batteries based on dynamic weight allocation and machine learning", *Energy*, c. 239, s. 122185, Oca. 2022, doi: 10.1016/j.energy.2021.122185.
- [66] A. A. Chehade ve A. A. Hussein, "A Collaborative Gaussian Process Regression Model for Transfer Learning of Capacity Trends Between Li-Ion Battery Cells", *IEEE Transactions on Vehicular Technology*, c. 69, sy 9, ss. 9542-9552, Eyl. 2020, doi: 10.1109/TVT.2020.3000970.
- [67] Y. Wang, R. Xu, C. Zhou, X. Kang, ve Z. Chen, "Digital twin and cloud-side-end collaboration for intelligent battery management system", *Journal of Manufacturing Systems*, c. 62, ss. 124-134, Oca. 2022, doi: 10.1016/j.jmsy.2021.11.006.
- [68] T. Berghout, M. Benbouzid, Y. Amirat, ve G. Yao, "Lithium-ion Battery State of Health Prediction with a Robust Collaborative Augmented Hidden Layer Feedforward Neural Network Approach", *IEEE Transactions on Transportation Electrification*, ss. 1-1, 2023, doi: 10.1109/TTE.2023.3237726.
- [69] S. Piller, M. Perrin, ve A. Jossen, "Methods for state-of-charge determination and their applications", *Journal of Power Sources*, c. 96, sy 1, ss. 113-120, Haz. 2001, doi: 10.1016/S0378-7753(01)00560-2.
- [70] Y.-H. Chiang, W.-Y. Sean, ve J.-C. Ke, "Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles", *Journal of Power Sources*, c. 196, sy 8, ss. 3921-3932, Nis. 2011, doi: 10.1016/j.jpowsour.2011.01.005.
- [71] N. Noura, L. Boulon, ve S. Jemeï, "A Review of Battery State of Health Estimation Methods: Hybrid Electric Vehicle Challenges", *World Electric Vehicle Journal*, c. 11, sy 4, Art. sy 4, Ara. 2020, doi: 10.3390/wevj11040066.
- [72] C. Vidal, P. Malysz, P. Kollmeyer, ve A. Emadi, "Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art", *IEEE Access*, c. 8, ss. 52796-52814, 2020, doi: 10.1109/ACCESS.2020.2980961.
- [73] R. Xiong, J. Cao, Q. Yu, H. He, ve F. Sun, "Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles", *IEEE Access*, c. 6, ss. 1832-1843, 2018, doi: 10.1109/ACCESS.2017.2780258.
- [74] L. Yao *vd.*, "A Review of Lithium-Ion Battery State of Health Estimation and Prediction Methods", *World*

- Electric Vehicle Journal*, c. 12, sy 3, Art. sy 3, Eyl. 2021, doi: 10.3390/wevj12030113.
- [75] A. S. Abdelaal, S. Mukhopadhyay, ve H. Rehman, "Battery Energy Management Techniques for an Electric Vehicle Traction System", *IEEE Access*, c. 10, ss. 84015-84037, 2022, doi: 10.1109/ACCESS.2022.3195940.
- [76] J. Hong vd., "Fault Prognosis and Isolation of Lithium-Ion Batteries in Electric Vehicles Considering Real-Scenario Thermal Runaway Risks", *IEEE Journal of Emerging and Selected Topics in Power Electronics*, c. 11, sy 1, ss. 88-99, Şub. 2023, doi: 10.1109/JESTPE.2021.3097827.
- [77] D. Li, Z. Zhang, P. Liu, Z. Wang, ve L. Zhang, "Battery Fault Diagnosis for Electric Vehicles Based on Voltage Abnormality by Combining the Long Short-Term Memory Neural Network and the Equivalent Circuit Model", *IEEE Transactions on Power Electronics*, c. 36, sy 2, ss. 1303-1315, Şub. 2021, doi: 10.1109/TPEL.2020.3008194.
- [78] B. Jiang, Z. Chen, ve F. Chen, "Influence of Sampling Delay on the Estimation of Lithium-Ion Battery Parameters and an Optimized Estimation Method", *Energies*, c. 12, sy 10, Art. sy 10, Oca. 2019, doi: 10.3390/en12101878.
- [79] "Prognostics center of excellence - data repository", NASA Ames Progn Res Center. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <http://www.nasa.gov/intelligent-systems-division>
- [80] "Battery Data | Center for Advanced Life Cycle Engineering", CALCE battery research group. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://calce.umd.edu/battery-data>
- [81] "Experimental Data Platform", Toyota Research Institute. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.matr.io/1/>
- [82] "Data for degradation of commercial lithium-ion cells as a function of chemistry and cycling conditions", Sandia National Lab. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: https://www.batteryarchive.org/snl_study.html
- [83] Y. Preger vd., "Degradation of Commercial Lithium-Ion Cells as a Function of Chemistry and Cycling Conditions", *J. Electrochem. Soc.*, c. 167, sy 12, s. 120532, Oca. 2020, doi: 10.1149/1945-7111/abae37.
- [84] D. Gun, H. Perez, ve S. Moura, "Berkeley: eCal fast charging test data". Dryad, s. 293617695 bytes, 2015. doi: 10.6078/D1MS3X.
- [85] S. Zhang, "Data for: A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery - Mendeley Data". Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.mendeley.com/datasets/c5dxwn6w92/1>
- [86] M. Luzzi, "Automotive Li-ion Cell Usage Data Set". IEEE, 07 Eylül 2018. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://iee-dataport.org/documents/automotive-li-ion-cell-usage-data-set>
- [87] "eVTOL Battery Dataset". Carnegie Mellon University, 18 Mart 2021. doi: 10.1184/R1/14226830.v3.
- [88] "Data-driven prediction of battery cycle life before capacity degradation", Cycle Life Prediction. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.matr.io/1/projects/5c48dd2bc625d700019f3204>
- [89] G. Pozzato, A. Allam, ve S. Onori, "Lithium-ion battery aging dataset based on electric vehicle real-driving profiles", *Data Brief*, c. 41, s. 107995, Şub. 2022, doi: 10.1016/j.dib.2022.107995.
- [90] P. M. Attia vd., "Closed-loop optimization of fast-charging protocols for batteries with machine learning", *Nature*, c. 578, sy 7795, ss. 397-402, Şub. 2020, doi: 10.1038/s41586-020-1994-5.
- [91] M. Dubarry, "Graphite//LFP synthetic training diagnosis dataset", c. 1, May. 2020, doi: 10.17632/bs2j56pn7y.1.
- [92] P. Kollmeyer, "Panasonic 18650PF Li-ion Battery Data", c. 1, Haz. 2018, doi: 10.17632/wykht8y7tg.1.

Özgeçmişler



Metin Yılmaz, Eskişehir Osmangazi Üniversitesi'nde (ESOGÜ) doktora öğrencisidir. Yedi yıl boyunca Tusaş Motor Sanayii A.Ş.'de kıdemli yazılım mühendisi olarak çalıştı. 2020 yılında bilgisayar mühendisliği alanında yüksek lisans derecesini aldı. ESOĞÜ'de Akıllı Fabrika ve Robotik Laboratuvarı'nın bir parçası olarak Türkiye Bilimsel ve Teknik Araştırma Kurumu (TÜBİTAK) doktora bursiyeri öğrencisidir. Ayrıca 100/2000 Yükseköğretim Kurulu (YÖK) doktora bursiyeridir. Araştırma çalışmaları, robotik sistemler, yapay zeka ile endüstriyel sistemlerde hata tespiti ve tahmini konularına odaklanmaktadır.



Doç. Dr. Eyüp Çınar, Fulbright Bursiyeri olarak 2010 yılında New York, ABD'deki Rochester Institute of Technology'de Elektrik ve Mikroelektronik Mühendisliği alanında yüksek lisans derecesini almıştır. Aynı üniversitenin Mikrosistem Mühendisliği bölümünde doktorasına devam etmiş ve 2015 yılında doktora derecesini almıştır. Sonrasında, ABD'de yaklaşık dört yıl boyunca çeşitli şirketlerde Kıdemli Mühendis olarak endüstriyel deneyim kazanmıştır. New York eyaletindeki dünyaca ünlü GLOBALFOUNDRIES Fab8 çip üretim tesisinde Kıdemli Gelişmiş Süreç Kontrol mühendisi olarak, yarı iletken üretiminde hata tahmini, sınıflandırma ve süreç kontrolü üzerine çalışmıştır. Daha sonra, San Jose, CA'daki ASML-HMI Ar-Ge merkezinde Kıdemli Yarı İletken Desenleme Veri Bilimcisi olarak çalışmaya devam etmiştir. 2019 yılında Dr. Eyüp Çınar, 2023'ten beri Bilgisayar Mühendisliği Doçenti ve Eskişehir Osmangazi Üniversitesi'nde öğretim üyesidir. Aynı zamanda Elektrik ve Elektronik Mühendisleri Enstitüsü'nün (IEEE) kıdemli üyesidir.



Prof. Dr. Ahmet Yazıcı, 2000 ve 2005 yıllarında Eskişehir Osmangazi Üniversitesi'nde (ESOGÜ) kontrol sistemleri alanında yüksek lisans ve doktora derecelerini almıştır. 2007 Darpa Urban Challenge'da OSU-ACT Ekibi üyesiydi. 2005 yılından beri Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliği Bölümü'nde çalışmaktadır. Akıllı Fabrika ve Robotik Laboratuvarı'nın kurucusudur. Ayrıca ESOĞÜ'de Akıllı Sistemler Araştırma Merkezi'nin müdürüdür. Mevcut araştırma ilgi alanları arasında akıllı araçlar, Akıllı Fabrika ve Otonom Sistemler bulunmaktadır.

Geleceğin Harekât Ortamında Otonom Sürü SİHA Konseptlerinin Stratejik Önemi ve Kullanım Taktiklerinin Örnek Bir Senaryo Üzerinden İncelenmesi

Strategic Importance of Autonomous Swarm UCAV Concepts in the Future Operational Environment and Investigation of Tactics through a Sample Scenario

 Vural Avcı¹

¹ Harekât ve Veri Tabanı Uzmanı, Türk Havacılık ve Uzay Sanayii (TUSAŞ) Ankara, Türkiye
vural.avci@tai.com.tr

Özet

Günümüzde ülkelerin en önemli istihbarat ve harekât unsurlarını harekât ortamında destekleyen sistemler kuşkusuz ki İnsansız Hava Araçları (İHA) bağlamında geliştirilen Silahlı İHA (SİHA)'lardır. Stratejik olarak düşman üzerinde büyük bir üstünlük yaratan SİHA'lar aynı zamanda kesintisiz harekâta uzun süreli destek vererek istihbarata dayalı anlık fırsat hedeflerine karşı da büyük bir başarı ile kullanılmaktadır.

Teknolojinin gelişmesi ile birlikte Konvansiyonel harbin değişmesi, ülkelerin ve şirketlerin Ar-Ge faaliyetlerine büyük yatırımlar yapmalarına neden olmuştur. Bu gelişmeler SİHA'ların öncelikle uzaktan kontrollü yapılarının değişerek otomasyon kabiliyete, sonrasında ise otonom (bağımsız hareket edebilme) kabiliyete evrilmelerine yönelik ihtiyaçlar artmıştır.

Bu çalışmanın amacı; sürü SİHA kavramını ve bu alandaki gelişmeleri inceleyerek, örnek olarak bir harekât senaryosu ortamında otonom sürü halinde görev icra eden SİHA'ların taktiklerini incelemek ve gelecek dönemde bu taktiklerin nasıl bir katkı sunacağı konusunda değerlendirmelerde bulunmaktır.

Anahtar Kelimeler: Geleceğin Harekât Ortamı, Hava Harekâtı, Otonomi, Yapay Zekâ, İHA, SİHA.

Abstract

Today, the systems that support the most important intelligence and operational elements of countries in the operational environment are undoubtedly the Armed UAVs (UCAVs) developed in the context of Unmanned Aerial Vehicles (UAVs). UAVs, which strategically create a great superiority over the enemy, are also used with great success against intelligence-based instant opportunity targets by providing long-term support to uninterrupted operations.

The change in conventional warfare with the development of technology has led countries and companies to invest heavily in R&D activities. These developments have increased the need for UCAVs to evolve from remote-controlled structures to automation capability and then to autonomous (independent movement) capability.

The aim of this study is to examine the concept of swarm UCAVs and developments in this field, to examine the tactics of autonomous swarm UCAVs in an operational scenario, and to make evaluations on how these tactics will contribute in the future.

Keywords: Future Operational Environment, Air Operations, Autonomy, Artificial Intelligence, UAV, UCAV.

1. Giriş

İnsansız Hava Araçları (İHA) soğuk savaş döneminin sonlarına doğru, daha çok keşif ve gözetleme amacıyla geliştirilmeye başlanmıştır. 1980'li yılların sonuna doğru İHA'lar boyut olarak küçülmeye ve daha fazla fonksiyonu bir arada barındırmaya başlamış, çeşitli silahlar ile hedeflerin imhasında da kullanılmıştır [1]. İlk dönemlerde uzaktan kontrollü basit birer uçuş platformlarıyken, teknolojinin gelişimi ile sensör donanımları ve gelişmiş otonomi özellikleri sayesinde çok özellikli hava araçlarına evrilmişlerdir.

Bu İHA'lar harekât ortamında birçok farklı görevde kullanılabilirler. Ayrıca İHA'lar daha çok keşif ve gözetleme görevinde kullanılırken, Silahlı İnsansız Hava Araçları (SİHA) ise, doğrudan saldırı yeteneği eklenmiş İHA'lar olarak tanımlanmaktadır. Teknolojik olarak gelişimleri ile birlikte kullanım konseptleri de büyük oranda değişmiş, geleceğin harbinin önemli bir yön vericisi olmuşlardır.

Ülkelerin savunma stratejilerinde ve harekât alanlarında, istihbarat ve saldırı amaçlı en önemli elemanları kuşkusuz ki geliştirilen SİHA'lardır. Stratejik olarak düşman üzerinde büyük bir üstünlük yaratan SİHA'lar aynı zamanda kesintisiz harekâta uzun süreli destek vererek istihbarata dayalı anlık fırsat hedeflerine karşı da büyük bir başarı ile kullanılmaktadır.

Teknolojinin gelişmesi ile birlikte konvansiyonel harbin değişmesi, ülkelerin ve şirketlerin Ar-Ge faaliyetlerine büyük yatırımlar yapmalarına neden olmuştur. Bu gelişmeler SİHA'ların öncelikle uzaktan kontrollü yapılarının değişerek otomasyon kabiliyetine (önceden belirlenmiş iş dizinini yapabilme), sonrasında ise otonom (bağımsız hareket edebilme) kabiliyete evrilmelerine yönelik sürecin önünü açmıştır [2].

Bu çalışmanın amacı; sürü SİHA kavramını ve bu alandaki gelişmeleri inceleyerek, örnek olarak oluşturulmuş bir harekât senaryosu ortamında otonom sürü halinde görev icra eden SİHA'ların taktiklerini incelemek ve gelecek dönemde taktiklerin nasıl değişebileceği konusunda değerlendirmelerde bulunmaktır.

2. Otonom Sürü SİHA'ların Gelişimi

Savunma veya saldırı sistemleri açısından ülkeler; hata payı düşük, zor şartlara dayanıklı, insansız hava araçları geliştirmeye devam etmektedirler. Yapay zekâ destekli bu insansız hava araçlarının en özel örneği SİHA'lardır. İnsan faktörünü ortadan kaldırarak en zorlu ve karmaşık görevleri dahi yapmak üzere tasarlanan bu araçlar gelişmiş sensörlerinin yardımı ile yüksek durumsal farkındalıklarını artırmışlardır. Bir pilotun, insan fiziolojisine bağlı olarak kısıtlı sürelerle görev yapabildiği harp ortamlarında, kullanım amaçları doğrultusunda 120 saate kadar havada kalıp görev icra edebileceklerdir [3].

2.1. Konvansiyonel Harbin Değişimi

Ağ Merkezli Savaş (Network Centric Warfare) ortak bir farkındalık amacıyla, karar ve komuta hızının artırılmasına, yüksek bir operasyon temposuna, ağ sensörleri ile gelişmiş bir savaş gücü üreten, bilginin hızına da bağlı olarak etkin olduğu bir operasyon konsepti olarak tanımlanmıştır [4]. Ağ Merkezli Savaş özünde, harp alanında elde edilen bilgilerin etkili bir şekilde birbirine bağlanarak bilgi üstünlüğü ile alınan kararların savaş gücüne dönüştürülmesidir.

Ağ Merkezli Savaş kavramı ile birlikte yapay zekânın da harekât ortamlarına dahil olması ile SİHA'ların önemi daha da

artmıştır. SİHA'ların erken uyarı sistemlerine, acil istihbarat bilgisine ulaşma ve karar alma döngüsünün hızlandırılmasına, ortaya çıkan ya da bilinen hedeflerin etki altına alınmasına doğal olarak Konvansiyonel Harbin değişimine etkileri büyüktür. Harekât alanında görünmez, sessiz ve çok uzun süre havada kalarak anlık olarak hem istihbarat toplayan hem de saldırı gerçekleştirebilen bu yüksek teknoloji ürünler, geleceğin harbini de değiştirmeye başlamıştır [5]. Bu durum; orduların, ortaya çıkan gelişmelere (fırsat hedefi) anında otonom reaksiyon göstermesine, savaş kabiliyetlerinde ve stratejilerinde büyük bir değişim/dönüşüm olgusuna sebebiyet vermiştir.

2.2. Otonom Harekata Geçiş ve SİHA'ların Gelişimi


Otonomi alanındaki gelişmeler, askeri uyduların ileri seviyede ürettiği çözümler, nesnelerin interneti, özellikle 5G teknolojisindeki atılımlar ve bulut veri teknolojisi ile yapay zekâ kavramının hızla ilerlemesi, SİHA'ların sürü halinde otonom harekât icra edebilme özelliklerinin daha fazla geliştirilmesini hızlandırmıştır.

Günümüzde üretilen birçok SİHA keşif ve gözetlemeyi barındıran istihbarat amacından çok hava savunma ve taarruz görevlerini icra etmek amacıyla üretilmektedir. Kompleks görevlerin tamamı SİHA'lar tarafından icra edilebilmektedir. Havada kalış süresinin uzunluğu, yüksek irtifalara çıkabilme, motor gücü, data link uzunlukları, yüksek sürat ve yüksek manevra kabiliyeti, uzun menzilli, faydalı yük kapasitesi, otonom görev kabiliyeti, hassas vuruş, elektronik harp, sinyal istihbaratı, gelişmiş aviyonikler gibi birçok hassas sistemlerdeki gelişimleri devam etmektedir.

2000'li yıllardan itibaren çok sayıda ülke SİHA'ları geliştirme ve kullanma amaçlı projelere yatırım yapmıştır. Bu kapsamda ülkelerin SİHA'lar ile olan ilişkilerini;

- SİHA teknolojisini geliştirme kapasitesine sahip,
- Aktif olarak SİHA'ları harekât ortamında kullanan,
- SİHA'lara sahip ama aktif olarak kullanmamış ülkeler şeklinde sınıflandırmak mümkündür.

2000'li yılların başında SİHA teknolojisine sahip ülke bulunmazken, 2020 yılı verileri ile 28 ülke SİHA teknolojisini üretebilme kabiliyetine sahip olmuş, 38 ülke SİHA teknolojisine ulaşabilmiş ve 11 ülke ise harekât alanında söz konusu bu teknolojiyi kullanmıştır (Şekil-1) [6].



Şekil-1: SİHA Kullanılan, Geliştiren ve Sahip Olan Ülkeler [6].

Teknolojiye bağlı olarak otomasyon sistemleri (önceden programlanmış) ile hareket edebilen bu araçların gelecekte tam otonom olarak (kendi kendine karar alabilme) hareket edebilmelerine yönelik çalışmalar devam etmektedir [7, 8]. Harekât ortamında kullanım amaçları doğrultusunda SİHA'lar 6 kategoriye ayrılmışlardır (Tablo-1) [9].

Tablo-1: Harekât Ortamında SİHA Kategorileri [9].

Kategori	Tasarım	Görev	Örnek
Taktik SİHA	-Kısa Menzil -Sınırlı Süreli Operasyon Süresi	-Keşif -Gözetleme -Hedef tespiti -Hafif Silahlarla Saldırı	TB2 (Türkiye)
Stratejik SİHA	-Uzun Menzil -Yüksek İrtifa	-Geniş Alan Gözetleme -Gelişmiş Keşif Misyonları -Uzun Menzilli Hassas Vuruş	MQ-9 Reaper (ABD)
MALE SİHA	-Orta İrtifa -Uzun Menzil	-Keşif -Gözetleme -Saldırı	Aksungur (Türkiye) Heron (İsrail)
HALE SİHA	-Yüksek İrtifa -Uzun Menzil	-Stratejik Keşif, -Gözetleme -İletişim Aktarımı	RQ-4 Global Hawk (ABD)
Silahlı Taktik SİHA	-Orta İrtifa -Uzun Menzil	-Küçük Gövde -Hassas Vuruş -Yüksek Manevra Kabiliyeti -Mühimmat Çeşitliliği	MQ-1C (ABD) Anka-3 (Türkiye)
Kamikaze SİHA	-Alçak İrtifa -Kısa Menzil	-Tek Kullanımlık Saldırı	Harop (İsrail) Kargu, Alpago (Türkiye)

Otonom sistemler kendini tamamen veya kısmen kontrol edebilen, herhangi bir insan müdahalesine gerek kalmadan görevi seçebilen ve amaca ulaşan sistemler olarak tanımlanmıştır [10]. Amaç öncesinde işlem dizini programlanmış olan ve bu bağlamda harekete geçmiş sistemler olarak da ifade edilmiştir [11]. Otonom silah sistemleri ise kullanıcı olan insan faktörünün hiçbir etkisi ya da müdahalesi olmadan görev başarımı için gerekli hedefleri seçip imha etmek amaçlı silahlarını kullanan sistemleridir.

Otonom silahlar üzerinde yeni ve etkin çalışmalar mevcuttur. Yarı otonom ve denetimli otonom olarak tanımlanan sistemler teknolojinin yardımı ile tam otonom hale getirilmeye çalışılmaktadır. İnsan operatörün girdisine gerek duymadan hedefleri bulan, izleyen, seçen, taktikleri üreten ve gerekli hallerde saldıran otonom sistemlerin gelişimi halen son hızla devam etmektedir [12].

2.3. SİHA'larda Yapay Zekâ ve Otonom Sistemlerin Gelişimi


SİHA'lar için büyük bir öneme sahip makine öğrenmesi, yapay zekâ alanında gelişimini büyük bir hızla sürdürmektedir.

İnsansız SİHA sistemlerinin gelişmesinde; komuta ve kontrol, rota uygulaması, algılama (sensör füzyonu), engellerin tespiti, hedefin bulunması, saldırı ve kaçınma, sürü davranışı ve taktiklerin belirlenmesi, insan ile olan etkileşimi gibi konular önem taşımaktadır. Makine öğrenmesi aşamalarında yapay zekâ sistemleri; ön bilgi, eğitim verileri ve tecrübelerden faydalanarak karar alma yetisini geliştirmektedir. Bu uygulama sistemi içinde, denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) tekniklerinden yararlanılmaktadır. Sistem ilk başlarda geliştirici tarafından oluşturulmuş veri setlerinden yararlanırken, gelecekte diğer öğrenme modellerini daha fazla kullanacağı varsayılmıştır. Yapay zekâ ve makine öğrenmesi alanındaki gelişmeler kararları otonom olarak alabilecek sistemlerin geliştirilmesini mümkün kılmaktadır [13].

Harekât uzmanlarının ve mühendislerin ortak çalışmaları, gelecekte tüm savaş uçaklarının, yapay zekâ destekli ve insansız muharebeye katılacağı yönündedir. ABD menşei Northrop Grumman şirketi tarafından geliştirilen X47-B türünün ilk örneklerinden biridir. X47- B insan fizyolojisinin dayanamayacağı hız, "G" kuvveti, meteorolojik şartlar ve sürelerde, hatasız ve tam otonom olarak hava muharebesine gireceği tahmin edilmektedir [14].

Yine yapay zekâ çalışmaları kapsamında ABD Hava Kuvvetleri ve Savunma İleri Araştırma Projeleri Ajansı (The Defense Advanced Research Projects Agency (DARPA)) 17 Nisan 2024 tarihinde yaptığı açıklamada, ilk kez deneysel olarak yapay zekâ destekli uçurulan bir F-16'nın hava muharebesine katılarak, yakın hava muharebesine (dogfight) girdiği belirtilmiştir. Deneysel F-16 modeli geliştirme projesi olan X-62A VISTA'nın yapay zekâ tarafından desteklenerek tam otonom gerçek bir dogfight'ta başka bir F-16'ya karşı uçuğu açıklanmıştır [15].

Geliştirilmeye devam edilen tam otonom silah sistemlerinin günümüzde harp alanlarında kullanımından bahsetmek mümkün değildir. Kendi askeri güçlerini artırmak isteyen ülkeler yapay zekâ destekli otonom silah sistemlerine olan yatırımlarını ve Ar-Ge faaliyetlerini artırmaya devam etmektedir. Gartner'in "Gelişen Teknolojiler İçin Tırmanma Döngüsü" grafiğinde (Şekil-2) ise Yapay Zekâ Destekli Otonom SİHA'ların, "Yenilik Tetikleyici" zaman sınıfından çıkarak, "Beklentilerin Zirvesi (Peak of Inflated Expectations)" zaman sınıfına geçiş yapmaya başladığı değerlendirilmiştir [16].



Şekil-2: Gelişen Teknolojiler İçin Tırmanma Döngüsü [16].

2.4. Sürü Kavramı ve Kontrol Mimarileri

Sürü SİHA kavramı, belirlenmiş bir görevi yerine getirmek amacıyla iş birliği içinde çalışan çok sayıda SİHA'yı kapsamaktadır. Çoklu SİHA (sürü) sistemlerinde, sensör karakteristikleri, faydalı yük taşıma kapasiteleri ve otonom seviyeleri ile platform konfigürasyonları aynı ya da farklı olabilir. Birbirinden farklı donanım ve özelliklere sahip SİHA platformlarının oluşturduğu grup (heterojen sürü) karmaşık bir sisteme sahip olacaktır. Bu durum, SİHA kabiliyetlerindeki farklılıkların harp sahasında büyük önem taşıdığı durumlarda çok daha faydalı olacaktır.

Yüksek teknolojik özellikler gerektiren sensör kabiliyeti veya göreve bağlı olarak farklı özelliklerde sensörler gerektiren, ancak bu farklı büyüklükteki sensörlerin taşıma kapasitesi kısıtlaması yüzünden tek bir SİHA tarafından taşınmadığı durumlarda sürü kavramı kullanım kolaylığı ve görevde etkinlik sağlayacaktır [17].

Sürü SİHA sistemlerinin kontrolü (rota planlamaları, taktik belirlenmesi ve görev paylaşımı) konusunda literatürde çok farklı yaklaşımlar mevcuttur [18]. Temel olarak bu yaklaşımlar merkezi (centralized) ve merkezi olmayan (decentralized) kontrol mimarileri olarak tanımlanmaktadır. Merkezi kontrol mimarisinde düşük seviyeli bir otonomiye sahip sürü SİHA'lar arasında karşılıklı bir iletişim bulunmamaktadır. Kullanıcı operatör sürü içindeki farklı SİHA elemanlarından bilgiyi alır, koordine eder ve sürü sistemi içinde görev tanımlamalarını ve atamalarını önceden yapar. Bu yaklaşımla, otonominin düşük olması yüzünden daha basit ve kolay optimize edilebilir görevler icra edilmekle birlikte geleceğin harbi açısından yetersiz kalmaktadır. Merkezi olmayan kontrol mimarisinde, sürü SİHA elemanları arasında yüksek bir otonomi ve karşılıklı iletişim mevcuttur. Her bir eleman iletişim halinde olup bilgiyi paylaşabilmeli ve gerekli kararları verebilir. Gerek çok daha karmaşık yapıda olmaları gerekse yüksek seviyeli yapay zekaya dayalı bir otonomiye ihtiyaç duymaları nedeniyle son yıllara kadar kullanılmamıştır [19].

2.5. Geleceğin Harbi, Sürü SİHA Operasyonlarında Kullanım Konseptleri

Boyut ve özelliklerine göre SİHA'ların farklı harp alanlarında daha etkin olduğu bilinmektedir. Savunma sistemleri tarafından bulunmaları ve tespit edilmeleri çok zor olan küçük ölçekli SİHA'ların sürü saldırılarda merkezi kontrollü olarak kullanılmaktadır. Yüksek irtifa ve uzun süre havada kalabilen sensör füzyonu ile donatılmış radar kesiti (RCS), bir nesnenin radarla ne kadar algılanabilir olduğunun ölçüsü) düşük, tam otonom SİHA'lar ise genelde coğrafi olarak uzaktaki hedeflere taktik saldırı açısından ön plana çıkmaktadır.

Son insanlı savaş uçakları olarak tanımlanan 5'inci Nesil uçaklar yapılarına kadar savaş uçakları, genelde karmaşık görevleri paket halinde icra etmektedir. Paket içindeki uçakların bir kısmı elektronik karıştırma uygulamaları, bazıları havadan yere atılan mühimmatları ile hedeflere taarruz eder bazıları da taşıdıkları havadan havaya mühimmatlar ile düşman hava unsurlarına karşı önleme ya da himaye görevleri yapmaktadır. Gelecekte insan fizyolojisi ve güvenlik kısıtlarından dolayı hareket ortamında karar verici rolde görev yapma ihtimali yükselen 5'inci Nesil uçaklarla birlikte bu komutaya bağlı ve/veya görev ataması ile bağımsız sürü halinde görev yapacak SİHA'ların geliştirilmesiyle ilgili çalışmalar devam etmektedir.

Savunma Sanayii Başkanlığı tarafından Hava Kuvvetleri Komutanlığının ihtiyacı olan ve TUSAŞ (Türk Havacılık ve Uçay Sanayii) tarafından geliştirmekte olan Milli Muharip Uçak KAAN'da herhangi bir hareket alanında görev yaparken yalnız uçmayacaktır. TUSAŞ tarafından IDEF-2023'de duyurulan Otonom Kol Uçuşu (OKU) proje çalışmaları kapsamında KAAN uçağı gelişmiş sensörleri ve füzyon yeteneği sayesinde birden fazla SİHA'yı (ANKA-III) kontrol merkezi olarak yönlendirme görevini yürütebilecektir. KAAN uçağı, pilotu tarafından uçurulurken, icra edilmesi gereken görev için hedefe yanında uçan ve farklı otonomi seviyelerine sahip ve sürü halinde hareket edebilen ANKA-III (Loyal Wingman) bulunacaktır. KAAN füzyon sensörü, iletişim, görev tahsis edebilme ve planlama özellikleri ile görev sahasında ANKA-III'lerin görev paylaşımını yapmış ve onları harp alanına göndererek, düşman topraklarına girmeden güvenli alanda komuta etmeye başlamış olacaktır. Görev paylaşımının ardından ANKA-3'ler gerekirse elektronik sinyalleri ile KAAN'ı taklit ederek aldatma yapacak, tehditlere karşı insanlı KAAN'ı koruyacak, bir kısmı düşman hava kuvvetleri unsurlarından gelebilecek tehditlere karşı önleme görevi icra edecektir. Bu görevi icra eden ANKA'lar havadan havaya füzeleriyle donatılmış ve hava muharebesi görevlerine odaklanmış olacaklardır. Diğer grup üzerlerinde bulunan elektronik harp imkânları ile düşmanın aktif radar istasyonlarını köreltecek, düşman hava savunma sistemlerinin KAAN'ı ve ANKA'ları hedef almasını önleyecektir. Son grup ise taşıdıkları havadan yere atılabilen mühimmatları ile önceden belirlenmiş düşman hedeflerine atışlarını yapabilecektir. Bu taktik konseptin amacı; insanlı ve yüksek maliyetli KAAN uçağının tahrip olmamasıdır [20].

Literatüre "Loyal Wingman" olarak geçen, düşük maliyeti ile hızlı üretilebilir ve sadık kol uçucusu olarak tanımlanan SİHA'lar gelecekte dinamik veri paylaşımı ve merkezi olmayan mimaride koordineli tam otonom ortak görev yapabileceklerdir. Tehlikeli görevler için insan faktörünü ortadan kaldırırken, gelişmiş sensörlerden toplanan çok sayıda bilginin insan gücü tarafından derlenemeyecek kadar çok ve hızlı akışından doğacak durumsal farkındalığı çok üst seviyeye çıkaracaklardır. Bu maksatla TUSAŞ OKU Konsept çalışması ile insanlı ve insansız sistemlerin otonom görev yapabilme yetkinliklerinin geliştireceği çatı ontoloji standardizasyonun sağlanmasını da hedeflenmektedir.

3. Senaryolaştırılmış Muharebe Ortamında Sürü Otonom SİHA'ların Karmaşık Hava Operasyonu Örneği

3.1. Senaryo Planlamalarının Önemi

Senaryo planlama, bir organizasyonun misyonuyla ilgili olarak geleceği öngörmeye yönelik disiplinli bir çalışmadır. Geleceklere ilişkin tahminler ve belirsizlikler çok sayıda değişkene bağlıyken, senaryo çalışmaları geleceği yönetilebilir şekilde basitleştirir. Organizasyonlar, tahmin etme yeteneği ile büyük belirsizlik koşulları altında faaliyet gösterirken, senaryo planlamasından yararlanırlar. Yeni gelişmeleri ve fırsatları algılama veya yaratma kabiliyetinin sınırlı olması, stratejik olarak zayıf düşünme, sektörde meydana gelen önemli

gelecekteki askeri gücün planlanmasıyla ilgili hususlardır. Dolayısıyla senaryo analizleri, savunma ve taarruz strateji açısından büyük bir öneme sahiptir [21, 22].

Senaryo stratejileri, öngörülebilirlik düzeyi göz önüne alınarak optimum çözümlere dayanan gerçekçi çalışmalar olmalıdır. Daha önceki deneyimlere dayanarak kazanma stratejisi daima geliştirilmelidir. Süreç uzmanı tarafından, senaryonun değişen koşullara uyum sağlamasına yardımcı olacak organizasyonel süreçler geliştirilmelidir [23].

Sun Tzu'nun "düşmanı tanıma" ilkesi, gelecekteki çatışmalarda daha da kritik olmaya devam edecektir [24]. Gelecekte yaşanması muhtemel bilgi yoğun savaşlarda, düşmanın potansiyel stratejilerine ilişkin sahip olunacak bilgiler, silah sistemlerinin yeteneklerine ilişkin farkındalık kadar önemli olacaktır [25].

Hava hareketleri için senaryo planlamanın temel amacı gelecekte muhtemel kuvvet yapısına ilişkin karar almayı desteklemektir. Senaryo planlamanının yürütülmesi aynı zamanda organizasyon içindeki uyum yeteneğinin geliştirilmesine de yardımcı olacaktır.

3.2. Senaryonun Amacı ve Varsayımlar

Şekil-3'de gösterilmiş olan bu senaryoda amaç; gelecekte hava hareketlerinin ayrılmaz bir parçası olacak yapay zekâ destekli sürü otonom SİHA grubunun, görev formasyonu içindeki hareketlerini ve olası taktiklerini incelemektir.

Bu kapsamda; senaryolaştırılmış harp sahası aşağıda maddeler halinde sunulmuş olup varsayımların çerçevesi bu maddelere göre belirlenmiştir.

- Sürü otonom SİHA'lar harp alanında farklı görevler icra edeceği için, görevin gerektirdiği donanım, silah ve taşıma kapasitelerine sahiptir.
- Bölgede bir adet AWACS (Havadan Erken İhbar ve Kontrol) uçağı ve bir adet HYİ (Havada Yakıt İkmali) uçağı görev yapmaktadır.
- Tüm unsurlarda 5G teknolojisi mevcuttur. Ağ Merkezli Harp için uygun donanım ve alt yapı kullanılmaktadır.
- Taarruzlarda akıllı mühimmat kullanılmaktadır.
- Hedef stratejik bir düşman komuta kontrol merkezidir. Orta (MRSAM) ve Uzun (LRSAM) menzilli hava savunma sistemleri ile korunmaktadır.
- Havada CAP görevi için bekleyen düşman uçakları mevcuttur.

3.3. Sürü SİHA Elemanlarının Açılımı

Karmaşık Kuvvet Hava Harekâtı (Composite/Combined Air Operations, COMAO), özellikle büyük ve karmaşık hava görevleri için bir ya da birkaç meydandan havalanan, farklı özelliklerde ve farklı görev kabiliyetine sahip uçaklar tarafından oluşturulmuş görev paketine verilen isimdir. Paketin bir görev komutanı varken her bir alt görev grubunun da bir lideri bulunmaktadır. Görev farklılıkları, paket kolunun üyelerinin belirli görevleri üstlenmesini sağlamaktadır. Bunlar, keşif, koruma, saldırı ve diğer görevleri içerebilir. Her hava aracı, yetenekleri ve görev gereksinimleri göz önünde bulundurulurken belirli bir rolde yer alır. Gelişmiş teknolojiler ile

[26].

Bu kapsamda senaryo amacıyla oluşturulmuş COMAO paket içinde bulunan Sürü SİHA'lar ve diğer görev elemanları aşağıda olduğu gibidir.

Tablo-2: COMAO Paketi Görev Elemanları

Uçak	Görev	Yük	Açıklamalar	
1xTanker Uçağı	AAR (HYİ)	-	Dost topraklarda Havada Yakıt İkmali için kullanılacaktır.	
1xAWACS	Erken İhbar ve Komuta Kontrol	-	Dost topraklarda Komuta Kontrol ve Radar görevi icra edecektir.	
SÜRÜ	2xSİHA	Strike (HYT)	Hava-Yer Mühimmatı	Stratejik hedefe havadan yere taarruz görevi icra edecektir.
	2xSİHA	Escort (HİM)	Hava-Hava Mühimmatı	COMAO paketinin hava savunmasını yapacaktır.
	2xSİHA	SEAD/DEAD	Anti Radyasyon Füzesi	SEAD (Düşman Savunma Sistemlerinin Bastırılması) ve DEAD (Düşman Savunma Sistemlerinin İmha Edilmesi) görevlerini icra edecektir.
	2xSİHA	E/H (Elekt. Harp)	E/H Podu	Elektronik Harp Podu ile savunma sistemlerine elektronik sinyal karıştırması yapacaktır.

3.4. Örnek Harekât Ortamı Senaryosu


Sürü otonom SİHA'ların muharebe sahasında hangi görevleri nasıl yapabileceklerine dair bir öngörü sahibi olabilmek amacıyla özgün bir hava harekâtı senaryosu oluşturulmuştur. Bu amaçla sürü halinde tam otonom hareket edebilen büyük gövde ve faydalı yük taşıma kapasitesine sahip, yüksek irtifalara çıkabilen, alçak irtifada arazi maskeleyesi için gelişmiş sensör teknolojisi ile donatılmış, SİHA'lar kullanılmıştır.

Mavi Ülke ve Kırmızı Ülke arasında yaşanan politik ve jeopolitik tarihsel anlaşmazlıklar sonucunda önce karşılıklı gerginlikler yaşanmış, daha sonra küçük çaplı askeri çatışmalar ve nihayetinde kaçınılmaz olarak topyekün harbe başlanmıştır. Harbin ilk günlerinde COMAO harekâtı icra edebilmek amacıyla Mavi Ülkeye ait sürü SİHA'lar iki farklı meydandan (A ve B Meydanları) havalanmışlardır. COMAO paketini oluşturmak amacıyla Randevu Noktasında buluşan Mavi Ülkeye ait kollar taarruz öncesi planlanan formasyon düzenine geçmiştir. Hedef olarak Kırmızı Ülke derinliklerinde bulunan

stratejik bir komuta kontrol merkezi, kalkış öncesi planlamalarda SİHA'lara hedef olarak atanmıştır. SİHA'ların ana görevi Komuta Kontrol Merkezinin imhası amacıyla paket içinde bulunan havadan yere taarruz görevini icra edecek grubun hedefe ulaşmasını ve emniyetli pozisyonunda silahlarını salmak olarak belirlenmiş ve minimum kayıp verecek şekilde RTB (Return to Base – Üsse Dönüş) yapmaları beklenmiştir.


Lider olarak atanmış SİHA tarafından yönlendirilen sürü, Kırmızı Ülkeye ait önceden belirlenmiş hedefe yapılacak havadan yere taarruz için taktiğine ve havada karşılaşılabilecek durumlara otonom olarak karar verecektir.

Mavi Ülkenin saldırılarını havada önlemek amacıyla Kırmızı ülke toprakları üstünde görev yapan CAP (Combat Air Patrol) görev kolları mevcuttur. Ayrıca sınırı korumak amacıyla bir hat üstünde orta menzilli hava savunma sistemleri (MR-SAM Medium Range Surface to Air Missile) bulunmaktadır. Yine aynı şekilde hedef komuta kontrol merkezi de MR-SAM ve uzun menzilli hava savunma sistemleri (LR-SAM Long Range Surface to Air Missile) tarafından korunmaktadır (Şekil-3).



Şekil-3: Örnek Harekât Ortamı Senaryosu.


Randevu noktasında taarruz için gerekli formasyonu oluşturan COMAO paketin lideri, tüm SİHA'lar ile iletişim halindedir. Paket sınıra doğru uçarken lider SİHA sensörleri yardımı ile SAR (Sentetik Açıklık Radarı) taraması yapmaktadır. Potansiyel hedeflerin tespit ve takibinde kullanılan Hareketli Hedef Tespiti, her hava durumunda yüksek çözünürlüklü radar görüntüsü, hedef sınıflandırma ve arazi topografyası üretme için kullanılmaktadır. Lider SİHA Kırmızı Ülke MR-SAM'larının konumunu ve kaplama diyagramını çıkararak sınırı geçme taktiğini belirlemiştir. Senaryoda toplamda 4 adet MR_SAM sistemi tespit eden SİHA'lar, orta noktada kaplama bindirmesi olmayan ve arazi maskeleyesi için kullanılabilecek bir geçiş yolu tespit etmiştir. Yapay zekâ destekli yapılan analizde, SİHA'lar SAM'lara taarruz ederek koridor açmak yerine, zaiyat vermeden geçiş yapılabileceğini analiz etmiş ve rota planlamasını otonom oluşturmuştur. Paket kol, Escort kollarının himayesinde arazi maskeleyesi yapmak amacıyla alçak irtifadan profiline devam etmiş ve sınırı geçmeye başlamıştır (Şekil-4).



Şekil-4: Sınır Geçiş.


Sınırdaki SAM kaplama zafiyetinin bilincinde olan Kırmızı Ülke, vadi içinde alçak irtifadan gelebilecek tehditlere karşı iki uçaktan oluşan bir CAP kolunu uygun pozisyonunda konuşlandırmıştır. COMAO paketin Escort SİHA radarları ve

AWACS uçağından gelen bilgiler ile tespit edilen Kırmızı CAP kolları için hedef tahsisi lider tarafından yapılmıştır. Bir ve iki numaralı uçaklar kendi aralarında tahsis edilen hedeflere BVR (Beyond Visual Range - Görüş Ötesi) Füzeleri ile angajmana girmiş ve tehditleri ortadan kaldırmıştır. Bu esnada Paketin (Elektronik Harp (E/H) SİHA'ları güvenli geçiş amacıyla, geçişe başlamadan ve geçiş esnasında (yanal radar yardımı ile) MR-SAM'lara E/H Karıştırması uygulamıştır (Şekil-5). E/H, düşman radarlarının elektronik karıştırma kullanılarak kullanılmaz hale gelecek şekilde körleştirilmesi ve haberleşmelerinin engellenmesidir. Harekât esnasında savaş uçaklarının tehdit radarlar ve hava savunma sistemlerine karşı güvende olmasını sağlamaktadır [27].




Şekil-5: Kırmızı CAP Kollarına Angajman ve E/H Karıştırması.

Bölgede bulunan Escort kol, pakete tehdidin Kırmızının "C" Meydanından kalkabilecek Scramble kollarından gelebileceği analizini yapmıştır. Bu maksatla hem meydanı gelişmiş radar ve sensörleri ile tarayacak hem de paketin korumasına uygun bekleme paternini kuracak şekilde konuşularak, sıcak-soğuk bacadaki CAP bekleyecektir. CAP kollarının yerini alması ile birlikte E/H kolu SEAD/DEAD kolunun işini kolaylaştırmak için düşman SAM'larına çoklu hedef karıştırma kabiliyeti ile E/H karıştırması yapabileceği en uygun konumu yapay zekâ analizi ile belirleyecek ve karıştırmasına başlayacaktır. Kırmızı Komuta Kontrol Merkezinin koruması için yerleştirilmiş MR-SAM ve LR-SAM tehditlerinin, taarruz koluna olan etkisini ortadan kaldırmak amacıyla SEAD (Düşman Savunma Sistemlerinin Bastırılması) ve DEAD (Düşman Savunma Sistemlerinin İmha Edilmesi) görevlerini icra edecek iki adet SİHA en uygun taarruz analizinin belirlenmesini sağlayacaktır. Birinci eleman sağa ikinci eleman sola manevralar ile SAM tehdit mesafesinin kendilerine angajman olamayacak (SAM tehdidinde göre değişmekle birlikte genelde %30'luk bir alan) kısmına kadar girerek her 30 sn.'de bir füzeyi bindirmeli olarak atacaklar ve düşman SAM tehditlerinin bu süre zarfında kapatılmasını başaracaklardır (Şekil-6).




Şekil-6: LR-SAM'lara E/H Karıştırması ve SEAD/DEAD Görevi.

MR-SAM ve LR-SAM'ların inha edilmesini takiben havadan yere güdümlü bombalar ile taarruz edecek elemanlar, en uygun taarruz taktiğini ve irtifayı analiz edecek, yüksek sürat ve eş güdümlü bombalarını hedefe göndererek kaçınma manevrasına başlayacaklardır. Tüm paketten toplanan veriler ile hedefin imhasının başırlamadığının anlaşıldığı durumlarda ve tehdit durumuna bağlı olarak paket lideri re-attack (yeniden taarruz) planlayabilecektir. (Şekil-7)

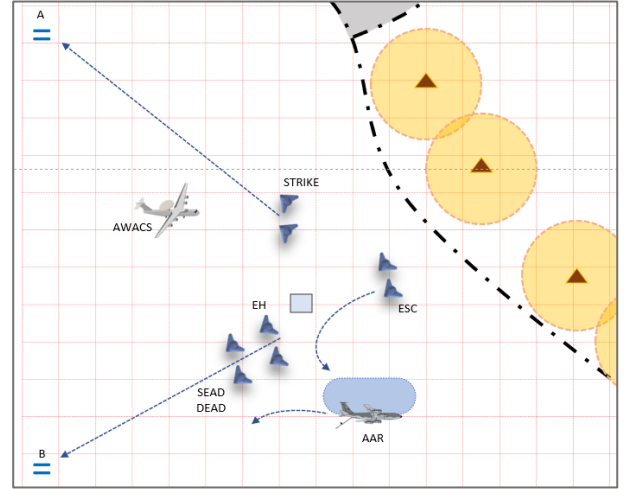


Şekil-7: Komuta Kontrol Merkezinin İmhası.

Görev başarılı paketin dönüşü lider tarafından diğer SİHA'lara iletilecek, alçak irtifa yüksek sürat ile arazi maskeleyesinden de yararlanan paket en kısa zamanda Mavi Ülke topraklarına dönüş yapacaktır. Sınır geçiş esnasında E/H kolu sınırdaki MR-SAM'lara karıştırma yapmaya devam edecek, Escort kol tüm paketin arkasında pakete gelebilecek tehditlere AWACS'tan aldığı bilgileri de kullanarak hazırlıklı olmaya devam edecektir. Bölgeden son ayrılan kol olarak, gelişmiş sensörlerinin yardımı ve uydu görüntülerinin analizi ile keşif görevini de yerine getirecektir. (Şekil-8)




Şekil-8: Kaçınma ve Sınır Geçiş.



Şekil-9: Meydana Dönüş.

Sınırı geçiş takiben paket randevu noktasında toplanacak, görevde harcanan yakıtı bağli olarak yakıtı azalan eleman havada yakıt ikmal uçağından yakıt alabilecektir. Yapay zekâ tarafından yakıt ikmal planlaması, meydana dönüş yakıtı azalan SİHA'lar için yapılacaktır. Tüm SİHA'ların meydanlara inişlerini takiben görev sona erecektir (Şekil-9).

Mavi'ye ait "A" ve "B" meydanlarından planlı kalkışlarını yapan ve randevu noktasında bulunan sürü SİHA'ların bu noktadan itibaren tam bir otonom görev kabiliyeti ile icra ettikleri çalışmalarına ait akış diyagramı Şekil-10'da olduğu gibidir.



Şekil-10: Sürü SİHA Akış Diyagramı

4. Değerlendirme

Geleceğin hava savaşları düşünüldüğünde SİHA'ların muharebe sahalarında tam otonom olarak bulunmaları, tüm taktik ve stratejileri değiştirecektir. SİHA'lar öncelikle savaş ortamlarında olmak üzere birçok silahlı organizasyonda etkinlikle kullanılabilir (Tablo-3) [28].

Tablo-3: Silahlı Organizasyonlarda SİHA Kullanımı [24]

SİHA	
Amaç	Beceri
-Keşif -Gözetleme -İstihbarat -Hava Yer Görevi -Hava Hava Görevi -Elektronik Harp -Deniz Görevleri	-Nokta Görev Kabiliyeti -Yönetme ve Yönlendirme -Deniz Alanında Hakimiyet -Hava Üstünlüğü -Hızlı ve Etkili Taarruz -Nihai Amaç
Fayda	Ortam
-Risklerin Azaltılması -Maliyet -Terörle Mücadele -Kuvvet Çarpanı -Meteorolojik Koşullara Uyum -Uzun Süreli Havada Kalış -Ağ Merkezli Yapılanmayı Güçlendirme	-Savaş -Terörle Mücadele -Ülke Savunması

Teknolojinin gelişmesi ve yapay zekâ alanındaki gelişmelere bağlı olarak öncelikle Hava-Hava görevleri, sonrasında ise en kritik ve karmaşık görevlerde kullanılmaları beklenmektedir. Özellikle Hava-Hava görevinde pilota düşen uçuş yükünün fazlalığı, angajmanların anlık olarak değişken analize dayanması, hızlı muhakeme ve refleksler gerektirmesi gibi zorluklar, SİHA'ların bu görevlerde kullanılmasını zorlaştırmaktadır. Bu alanda yarı otonom ve insanlı uçaktan gelen komutlara göre hareket eden Loyal Wingman kavramı ile otonom SİHA gelişim süreci devam etmektedir.

SİHA'ların çok daha ucuz ve gözden çıkarılabilir olmaları nedeniyle, insanlı uçak ile karşılaştırıldığında savaş alanında ülkeler üzerinde maddi ve manevi kayıp yaratmayacaktır. İnsanlı uçağın, üretim maliyetinin yanı sıra pilotun hayatının korunması açısından da bu durum önemlidir. Düşmanın belirlenmiş yüksek değerlikli stratejik hedeflerine taarruz etmek için SİHA'ları gözden çıkarmanın daha rasyonel olacağı değerlendirilmektedir. Bu şartlar altında kullanılacak taktikler, insanların doğrudan içinde bulunduğu savaşlardan kesinlikle farklı ve zorlu olacaktır [4].

Örnek senaryo üzerinde de görüldüğü üzere az sayıda gelişmiş SİHA ile karmaşık görevler, insan kaynaklı hataların ve kısıtların önüne geçerek yerine getirilebilecektir. SİHA'lar tüm görev boyunca, kol uçuşu, toplanma, kalkış, iniş gibi otonom kabiliyetlerinin yanı sıra;

- Randevu noktasında buluşma,
- Paket kol düzenini oluşturma,
- Kırmızı ülke arazisinin taranması ve SAM'ların tespiti,
- Sınır geçiş usulleri ve geçiş için kullanılacak taktik,
- SAM'lara karşı E/H karıştırmaları yapılması,

- Angajmana giriş ve silah salma,
- CAP, E/H ve SAM'ların bastırılması, taktiklerinin belirlenmesi,
- Ana hedefin tespiti ve taarruz taktiğinin belirlenmesi,
- Re-attack ve kaçınma,
- Sınır geri geçiş ve havada yakıt ikmali gibi çok sayıda konuda anlık değerlendirme yapması ve karar alması beklenmiştir.

Bu görevin insanlı muharip uçaklar tarafından yapılması gerektiği düşünüldüğünde, çok sayıda uçak ve tecrübeli pilot tarafından gerçekleştirilmesinin beklenmesi muhtemeldir. Bunun yanında;

- Bu görevleri yapacak pilotların uzmanlık alanlarına ve görev tipine göre yetiştirilmesi ile bunun getirdiği eğitim maliyetleri,
- Göreve katılması muhtemel uçak sayısının artması sonucu oluşacak uçak kullanım maliyetleri,
- Görevin farklı zorluk derecelerine göre, çok alçak irtifada ya da gece şartlarında icra edilmesi gibi durumlarda daha da artacak farklı uçak kategorilerine olan ihtiyaç,
- Yetiştirilmesi uzun zaman alan ve meşakkatli olan savaş pilotu kaybı,
- İnsanlı Uçak sistemlerinin insan fizyolojisi açısından ortaya çıkan kısıtlar (Max 9G),
- NCW'ine gelecekte getireceği çok sayıda verinin, anlık analiz edilmesindeki problemler gibi zorluklarla dolu alanların da çözümlenmesi gerekecektir.

5. Sonuç

Askeri havacılık; ülke bekası için üretilecek güvenlik ihtiyaçları ve savunma endüstrisi yönündeki ekonomik katkıları açısından stratejik öneme sahiptir. Devletler, mevcut silahlı hava araçlarını korumak ve geliştirmek zorundadır. Tehdidin sayısının ve çeşidinin her gün arttığı günümüzde, ülke savunması için yüksek kabiliyetli ve gelişmiş hava araçlarına sahip olunması kaçınılmaz bir zorunluluktur.

Yeni teknolojiler ve geliştirilmeye çalışan yapay zekâ destekli otonom sistemler, hava taarruz ve savunma stratejilerinin ve kabiliyetlerinin güçlendirilmesine ve çeşitlendirilmesine neden olmaktadır. Muharip savaş uçakları daha da gelişmiş, yüksek manevra kabiliyetlerine ulaşmış ve radarlar tarafından daha geç tespit edilebilir yetenekler kazanmış olup durumsal farkındalıkları çok artmıştır. Bunların yanında teknolojiye gelişmeler ile birlikte Tablo-3'de gösterilen tüm kullanım alanları için özel olarak yetiştirilmesi ve tecrübe kazanması gereken insan faktörü ise risk temelli yaklaşımlar ile zaman içinde denklemden çıkarılması gerekmektedir.

Maliyet etkin yaklaşımın bir sonucu olarak da üretilmeye ve geliştirilmeye çalışılan SİHA'lar, savaş uçaklarından farklı olarak birden fazla görevi üstlenebilmesi beklenmektedir. Geçmişte her bir görev misyonu için farklı tipte uçak geliştirilmesi ve pilot yetiştirilmesi gerekirken, günümüzde ve gelecekte geliştirilen platformlar ile yapay zekâ destekli sistemler sayesinde bu misyonların büyük bir kısmı tek bir gövdede gerçekleştirilebilecektir. Ancak, İHA ve SİHA gibi araçların yapısal ve teknik özellikleri bazı görevleri sınırlandırabilir. Geliştirilen sistemlerin gelecekte mutlak hava hâkimiyetini sağlaması, yeni teknolojilerin hızla platformlara

adapte edilebilir olması ve bunların ülke savunmasında çok uzun yıllar kullanılabilmesi öne çıkan beklentiler arasındadır.

Sonuç olarak, Sürü Otonom SİHA'ların yakın gelecekte savaş stratejilerini köklü bir şekilde değiştireceği, maliyet etkin bütçeler ile sürdürülebilir savunma desteğine katkıda bulunacağı ve bu teknolojiye sahip güçler için belirgin ve stratejik üstünlükler sağlayacağı açıkça görülmektedir.

6. Kaynaklar

- [1] T. Kök, “İnsansız Hava Araçlarının Güvenli Kullanımı için Spektrum İhtiyaçlarının Belirlenmesi ile İlgili Öneriler”, Teknik Uzmanlık Tezi, Bilgi Teknolojileri ve İletişim Kurumu, 2012.
- [2] İ. Kalınbacak, “Sürü Otonom İha Sistemlerinin Muharebe Sahasında Uygulama Taktikleri ve Geliştirilen Yeni Teknolojiler” Savunma Bilimleri Dergisi, 1(43), 191-209, 2023.
- [3] Tekinay, O. N., & Batı, G. B. (2022). Askeri Alanlarda Kullanılmak Üzere İnsansız Hava Aracı (İHA) Sistemleri Seçiminde Topsis ve Bulanık Topsis Yönteminin Kullanılması. Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi, 44(1), 78-103]
- [4] DS.Alberts, J. Garstka, ve FP Stein, Ağ merkezli savaş: Bilgi Üstünlüğünü Geliştirmek ve Kullanmak, Washington DC Ulusal Savunma Üniversitesi Yayınları, (s. 2-16), 1999
- [5] C. Karakuş, F. Katman, “Male Sınıfı İnsansız Hava Aracı (İHA) Teknolojisi ve Konvansiyonel (geleneksel) Savaştaki Yeri” Akademik Tarih ve Düşünce Dergisi, 6(2), 882-897, 2019
- [6] Çağlar, M. T., & Gülmez, L. (2023). Savaşın Yeni Araçları: Silahlı İnsansız Hava Araçlarının (SiHA) Yayılması ve Büyük Güçlerden Devlet Dışı Aktörlere SiHA Kullanımı. Social Review of Technology and Change, 1(2), 23-47.
- [7] Boeing, “U.S. Navy, Boeing Conduct First MQ-25 Refueling Mission with F-35C”, <https://www.boeing.com/defense/mq25/> (Erişim Tarihi 27,04,2024).
- [8] Wikipedia, “Loyal wingman”, https://en.wikipedia.org/wiki/Loyal_wingman. (Erişim Tarihi 27,04,2024).
- [9] Hubsan Havacılık ve Uzay Bilimleri, <https://www.hubsan.com.tr/genel/silahlı-insansız-hava-araçları> (Erişim Tarihi 27,04,2024).
- [10] J.S. Thurnher, “The Law That Applies to Autonomous Weapon Systems, American Society of International Law, 17(4)” 2013.
- [11] K. Cass, “Autonomous Weapons and Accountability: Seeking Solutions in the Law of War” Loyola of Los Angeles Law Review, 48(3), 1017-1068, 2015
- [12] A. Özer, “Savaşlarda Üçüncü Devrim Otonom Silah Sistemleri ve İnsancıl Hukuk” https://tasam.org/trTR/Icerik/52518/savaslarda_ucuncu_devrim_otonom_silah_sistemleri_ve_insancil_hukuk, (Erişim Tarihi 27,04,2024).
- [13] Unmanned Systems Integrated Roadmap FY 2017-2042
- [14] Wikipedia, Northrop Grumman X-47B, https://tr.wikipedia.org/wiki/Northrop_Grumman_X-47B, (Erişim Tarihi 27,04,2024).
- [15] The Defense Advanced Research Projects Agency (DARPA), ACE Program Achieves World First for AI in Aerospace, <https://www.darpa.mil/news-events/2024-04-17>, (Erişim Tarihi 27,04,2024).
- [16] Gartner, Top trends in the gartner hype cycle for emerging technologies, 2017. <https://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-foremerging-technologies-2017/> (Erişim Tarihi 27,04,2024).
- [17] STM Teknolojik Düşünce Merkezi, SÜRÜ İHA SİSTEMLERİ Modern Harp İçin Bir Gelecek Öngörüsü, https://thinktech.stm.com.tr/uploads/docs/1608905682_stm-suru-ih-sistemleri.pdf (Erişim Tarihi 27,04,2024).
- [18] Frantz N. R. “Swarm Intelligence For Autonomous UAV Control” Naval Postgraduate School
- [19] Özer, M. M., & Bakırıcı, M. İnsansız Hava Araçlarına Kontrol Sistemi ve İletişim Ağı Entegrasyonu İle Sürü Davranışı Kazandırılması, TMMOB Makina Mühendisleri Odası XII. Ulusal Uçak, Havacılık ve Uzay Mühendisliği Kurultayı, 13-14 Ekim 2023
- [20] TurDef - Global Defence News, TUSAŞ, Türk Sadık Kanat Adamını Hazırlıyor : OKU, <https://turdef.com/article/tusas-prepares-turkish-loyal-wingman-oku-concept> (Erişim Tarihi; 27.04.2024).
- [21] P.J.H. Schoemaker, “Scenario Planning: A Tool for Strategic Thinking,” Sloan Management Review, Cilt 36, no. 2, 25–40, 1995.
- [22] Australia’s Defence Science and Technology Group, “Understanding Future Robustness being a theme for the 2020 call for Operations Research Network proposals”.
- [23] Chermack, Lynham, and Ruona, “A Review of Scenario Planning Literature.”
- [24] Yoldaş, Ç. (2019). Yeni savaşlarda istihbarat teşkilatlarını rolü: Hibrit Savaş örneği (Doctoral dissertation, Sakarya Üniversitesi (Turkey))
- [25] A. Dowse, “Scenario planning methodology for future conflict”, The Journal of Indo-Pacific Affairs, 4(2), 18-31, 2021.
- [26] North Atlantic Treaty Organization (NATO) “Glossary of Abbreviations Used in NATO Documents and Publications”, 2008.
- [27] DEMİR, M. (2022). Milli savunma teknolojileri ve Türk silahlı kuvvetleri. Eurasian Academy of Sciences Social Sciences Journal, 73-85.
- [28] S. Aydoğan, “Bir İnovasyon Olarak İnsansız Hava Araçlarının Silahlı Organizasyondaki Kullanımının İncelenmesi: Bir Betimsel Analiz Çalışması”, Journal of Aviation Research, 4(1), 129-145, 2022.

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

Özgeçmiş



Vural Avcı, Anadolu Üniversitesi İktisat Fakültesi Kamu Yönetimi bölümünden lisans derecesi almıştır. Ayrıca Hoca Ahmet Yesevi Üniversitesi'nde Yönetim ve Organizasyon alanında yüksek lisans yapmıştır. Vural Avcı, kariyerine Hava Teknik Okullar Komutanlığı'nda Harekât Astsubayı olarak başlamış, çeşitli Hava Kuvvetleri Komutanlığı Jet Filolarında Harekât Astsubayı olarak görev almış ve birçok önemli projeye katılmış olup 34 yıllık tecrübesi bulunmaktadır. Vural Avcı, NATO ve diğer uluslararası sertifikalara sahip olup, Taktik Lider Yetiştirme Eğitimlerine, NATO tatbikatına ve Anadolu Kartalı tatbikatlarına katılmıştır. Ayrıca, Afganistan'da ISAF operasyonunda kıdemli astsubay danışmanlığı yapmıştır.

Katıldığı projeler arasında, F-16 uçaklarının AIDEWS Elektronik Harp sistemi entegrasyonu, Gece Görüş Gözlüğü (GGG) kullanımı için planlama grubu çalışmaları ve birçok uluslararası tatbikatta görev planlama ve harekât faaliyetleri bulunmaktadır.

Türk Hava Kuvvetleri'nde görev yaparken uçuş görevlerini planlama, harekât merkezlerini sevk ve idare etme, tatbikat planlama ve koordinasyonu gibi birçok görevi yerine getirmiştir. Halen Türk Havacılık ve Uzay Sanayii AŞ (TUSAŞ)'de Milli Muharip Uçak Projesinde Harekât ve Veri Tabanı Uzmanı olarak görevine devam etmektedir.

Farklı Örneklem Tekniklerine ve Farklı Sınıflandırıcılara Dayanarak Kalp Yetmezliği Tanılı Hastaların Sağkalımlarının İncelenmesi

A Study of Survival of Patients Diagnosed with Heart Failure Based on Different Sampling Techniques and Different Classifiers

^{ID} Rukiye Uzun Arslan¹, İrem Şenyar Yapıcı² ^{ID}

¹Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak
rukiyeuzun67@gmail.com, ORCID: 0000-0002-2082-8695

²Bilgisayar Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak
senyerirem@gmail.com, ORCID: 0000-0003-0655-340X

Öz

Kalp yetmezliği (KY), insanların yaşam kalitesini etkileyen ve ciddi komplikasyonlara yol açabilen bir sağlık sorunudur. Hastalığın karmaşıklığı ve bireysel faktörlerin çeşitliliği, hastaların sağkalımlarının tahminini oldukça zorlaştırmaktadır. Ancak günümüzde, KY tanılı hastaların sağkalımlarını tahmininde makine öğrenimine (MÖ) dayalı karar destek sistemleri önemli bir rol oynamaktadır. Bu sistemler, hastaların genetik profilleri, klinik özellikleri ve tedavi yanıtları gibi birçok bilgiyi birleştirerek daha doğru tahminler yapılmasına yardımcı olmaktadır. Gerçekleştirilen çalışmada, KY hastalarının sağkalımını öngörmek için MÖ temelli bir model önerilmiştir. Model korelasyon temelli özellik seçimine göre belirlenen anlamlı özelliklerle oluşturulmuş ve yedi farklı MÖ sınıflandırıcısının performansı, on üç farklı yeniden örnekleme tekniği kullanılarak değerlendirilmiştir. Modellerin performansını belirlemek adına 80:20 hold-out tekniği kullanılmış ve başarımları beş farklı performans metriğine göre değerlendirilmiştir. Yapılan analizlerde doğruluk metriği açısından en yüksek başarımlar %82 ile EditedNearestNeighbours az örnekleme tekniğinin uygulanması durumunda XGBoost algoritmasıyla elde edilmiştir. Bu bulgular, MÖ algoritmalarının yanı sıra örnekleme tekniklerinin de KY hastalarının sağkalım tahmininde kritik bir rol oynadığını vurgulamaktadır.

Anahtar Kelimeler – kalp yetmezliği, yeniden örnekleme teknikleri, sınıflandırma

Abstract

Heart failure (HF) is a health problem that affects people's quality of life and can lead to serious complications. The

complexity of the disease and the diversity of individual factors make the prediction of patient survival very difficult. However, nowadays, decision support systems based on machine learning (ML) play an important role in predicting the survival of patients with HF. These systems help to make more accurate predictions by combining many information such as genetic profiles, clinical characteristics and treatment responses of patients. In this study, a model based on ML is proposed to predict the survival of HF patients. The model is built with significant features determined by correlation-based feature selection and the performance of seven different ML classifiers is evaluated using thirteen different resampling techniques. The 80:20 hold-out technique is used to determine the performance of the models and their performance is evaluated according to five different performance metrics. In the analyses, the highest performance in terms of accuracy metric has been achieved with 82% with the XGBoost algorithm when the EditedNearestNeighbors undersampling technique was applied. These findings emphasize that besides ML algorithms, sampling techniques also play a critical role in HF patient survival prediction.

Keywords – heart failure, resample feature techniques, classifier

1. Giriş

Kalp yetmezliği (KY), kalbin vücuda yeterli miktarda kan pompalayamaması nedeniyle vücut işlevlerinde meydana gelen bozulmalarla karakterize edilen önemli bir sağlık sorunudur. KY, dünya genelinde en sık karşılaşılan morbidite ve mortalite nedenleri arasında yer almaktadır. Günümüzde, KY vakalarının dünya genelinde yaklaşık 64,34 milyon

olduğu ve bu sayının hızla arttığı bilinmektedir [1]-[3]. Ölüm oranları endişe verici olmasına rağmen KY vakalarının tamamı ölümle sonuçlanmamaktadır. KY vakalarında hastanın hayatta kalma olasılığını doğru bir şekilde tahmin edebilen belirli özellikler bulunmaktadır. Bu özellikler arasında serum sodyumu, ejeksiyon fraksiyonu, serum kreatinini, kan basıncı, yaş gibi faktörler yer almaktadır [3], [4].

KY geçiren hastalar genellikle olaydan sonraki birkaç gün boyunca hastanede gözlem altında tutulmakta ve sağlık durumları daha yakından takip edilmektedir. Bu süreçte, hastalardan düzenli kan örnekleri alınarak hematolojik parametrelerin yanı sıra yaş, cinsiyet, tütün kullanımı gibi hastaya ait bilgiler de değerlendirilmektedir. Ancak, bu verilerin analizi ve aralarındaki ilişkilerin belirlenmesi, hastaların iyileşme veya kötüleşme olasılığını tahmin etme zorluğunu beraberinde getirmektedir. Doğru sonuçlar elde etmek için analitik yöntemlerin ve modelleme tekniklerinin titizlikle uygulanması gerekmektedir. Bu çerçevede yararlanılan makine öğrenimi (MÖ) algoritmaları, kullanıcı verileri işleyerek sonuçları otomatik olarak öğrenmekte ve tahmin etmektedir. Yanı sıra farklı durumlara uyum sağlayabilmekte ve önceki öğrenmelerine dayanarak kararlar alabilmektedir. Bu algoritmalar, günümüzde sağlık sektöründe özellikle hastalık teşhisinde yaygın olarak kullanılmaktadır [5]. KY sonrası hastalardan alınan takip verilerinin analiz edilmesi, hastalığın mortalitesinin öngörülmesi açısından büyük önem taşımaktadır. Son yıllarda, sağlık sistemlerine entegre edilen MÖ algoritmaları KY tanısı ve prognoz değerlendirmesinde etkili bir çözüm sunmaktadır [3], [6], [7].

Chicco ve Jurman KY hastalarının olası sağlık durumlarını saptamak amacıyla 13 özellik içeren bir veri seti kullanarak farklı MÖ algoritmalarının başarımlarını değerlendirmişlerdir. Tüm özelliklerin kullanıldığı çalışmada Lojistik Regresyon (LR) algoritmasıyla en yüksek başarımlar elde edilmiştir [7]. Erdaş ve Ölçer KY hastalarının takip verilerini içeren bir veri seti üzerinde hastaların hayatta kalma tahmine yönelik MÖ temelli bir model önermişlerdir. Önerdikleri modelde beş farklı MÖ algoritmasının başarımları hem veri setindeki tüm özelliklere hem de korelasyon temelli öznelik seçim yöntemiyle çıkarılan özelliklere göre ayrı ayrı karşılaştırmışlardır. En yüksek başarımlar tüm özelliklerin kullanılması durumunda bir kural sınıflandırıcısıyla elde edilmiştir [8]. Başka bir çalışmada;

hastaların ameliyat öncesi ve ameliyat sırasındaki tıbbi verilerinden yararlanılarak ameliyat sonrası KY riskini tahmin etmeye yönelik Derin Piramit Evrişimli Sinir Ağları ve Aşırı Gradyan Artırma (XGBoost) yöntemleri içeren hibrid bir model önerilmiştir. Yapılan analizlerde önerilen modellerde daha yüksek başarımlar elde edilebileceği ortaya koyulmuştur [9]. Ishaq ve arkadaşları KY tanılı hastaların sağkalım durumlarının tespitinde dokuz farklı MÖ algoritmasının sınıflandırma başarımlarını araştırmışlardır. Analizlerde en yüksek sınıflandırma başarımlarını Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) uygulanan Ekstra Ağaç Sınıflandırıcısı (ETC) için elde edilmiştir [10]. Mansur Huang ve arkadaşları 13 özellik (semptom) içeren açık erişimli bir veri seti kullanarak KY'ni tahmin etmek için dört popüler MÖ algoritmasının performansını karşılaştırmıştır. Deneysel analizler sonucunda Rasgele Orman (RO)'nın en yüksek performans skorunu verdiği tespit edilmiştir. Yanı sıra KY tahmininde 13 semptomun tamamının önemli olduğu ortaya koyulmuştur [11]. Mamun ve arkadaşları KY ile ilişkili patofizyolojik parametrelerden hasta sağkalımını tahmin etmek için en önemli risk faktörlerine karşılık gelen özellikleri korelasyon matrisine göre tespit ederek, sekiz farklı MÖ algoritmasının performansları analiz etmişlerdir. Analizlerde LightGBM'nin diğer MÖ algoritmalarına kıyasla daha yüksek performansa sahip olduğu belirlenmiştir [12]. Muntasir Nishat ve arkadaşları hastaların KY'den kurtulma olasılıklarını tahmin etmek için üç farklı yaklaşım kullanarak 6 farklı MÖ algoritmasının performanslarını analiz etmişlerdir. İlk yaklaşımda veri seti üzerinde standart ve min-max ölçekleme yöntemlerini içeren bir veri ön işleme adımı uygulanmıştır. İkinci yaklaşımda algoritmaların hiperparametreleri optimize etmek adına ızgara arama çapraz doğrulama ve rastgele arama çapraz doğrulama teknikleri kullanılmıştır. Üçüncü yaklaşım olarak veri setine SMOTE ve düzenlenmiş en yakın komşu veri yeniden örnekleme tekniği (SMOTE-ENN) uygulanmıştır. Gerçekleştirilen analizlerde tüm yaklaşımlar için MÖ algoritmalarının performansları kapsamlı bir şekilde karşılaştırılmıştır. Yapılan karşılaştırmalar sonucunda, SMOTE-ENN ve standart ölçekleme tekniği birlikte uygulandığı durumda RO sınıflandırıcısının diğer tüm algoritmaları geride bıraktığı tespit edilmiştir [13]. Özbay ve Özbay açık erişimli dengesiz bir veri setine SMOTE tekniği uygulayarak, on farklı MÖ algoritmasının KY tahmin başarımlarını farklı performans metriklerine göre


kıyaslamışlardır. Tüm algoritmalar arasında en yüksek başarımlar bütün performans metrikleri açısından RO algoritmasıyla elde edilmiştir [14]. Sachdeva ve arkadaşları KY tanılı 299 hastanın tıbbi özelliklerini içeren bir veri seti üzerinden dört farklı MÖ algoritmasının hastaların hayatta kalma olasılıklarını tahminindeki başarımlarını analiz etmişlerdir. Yapılan analizlerle destek vektör makinesi (DVM) kullanılması durumunda en yüksek başarıma ulaşabileceği ortaya koyulmuştur [15]. Mudassar ve arkadaşları tarafından dengesiz bir veri seti üzerinde SMOTE tekniği uygulanarak dokuz farklı MÖ algoritmasının başarımları çeşitli performans metrikleri açısından değerlendirilmiştir. 10-kat çapraz doğrulama ve %70-%30 hold-out tekniğiyle eğitilen modelde en yüksek performans SMOTE uygulanma durumuna bakılmaksızın LightBoost algoritması için elde edilmiştir [16]. Keser ve Keskin gerçek bir veri seti kullanarak KY tanılı hastaların sağ kalımlarının tahmininde üç farklı MÖ algoritmasının performanslarını karşılaştırmıştır [17]. 2024 yılında yapılan bir çalışmada KY tahmininde farklı kategorilerde yer alan çeşitli MÖ algoritmalarının performansları hem kategorik hem de genel performans bakımından irdelenmiştir [5]. Yapıcı ve arkadaşları tarafından yapılan çalışmada SMOTE tekniğinin uygulanma durumuna göre KY teşhisinde farklı MÖ algoritmalarının başarımları iki farklı çapraz doğrulama tekniği kullanarak karşılaştırılmıştır [3].

Yukarıda değinilen çalışmalar, KY tanılı hastaların sağkalımlarının tahmininde MÖ temelli karar destek sistemlerinin etkili bir şekilde kullanılabileceğini göstermektedir. Ancak bu sistemlerde kullanılan MÖ algoritmalarının hangisinin başarımının daha yüksek olduğu hususunda kesin bir sonuca varılamamıştır. Bu doğrultuda, gerçekleştirilen çalışmada KY tanılı hastaların sağkalımlarını belirlemeye yönelik MÖ temelli üç aşamalı hibrit bir model önerilmiştir. Çalışmanın ilk aşamasında korelasyon temelli bir özellik seçim yöntemi kullanılarak veri setindeki belirleyici özellikler tespit edilmiştir. İkinci aşamada bu özellikler kullanılarak yedi farklı MÖ algoritmasına dayanan modelin performansları analiz edilmiştir. Üçüncü aşama da ise modellerin başarımlarını arttırmak adına eğitim veri seti üzerinde 13 farklı yeniden örnekleme tekniği uygulamanın etkileri analiz edilmiştir. Çalışmada modellerin doğruluğu hold-out (80:20) tekniğine göre değerlendirilirken, modellerin performansları yeniden örnekleme tekniğinin uygulanıp uygulanmama durumları için test verisi üzerinden

hesaplanan beş farklı metriğe (doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC gibi) göre karşılaştırılmıştır.

2. Materyal ve Metotlar

KY tanılı hastaların hayatta kalma durumlarını belirlemek için önerilen modelin blok diyagramı Şekil 1’de gösterilmiş olup bu bölümde uygulanan yöntemler anlatılmıştır.



Şekil 1. Önerilen modelin akış diyagramı.

2.1 Veri Seti

Bu çalışmada, 299 tane KY tanılı hastanın tıbbi kayıtlarını içeren açık erişimli bir veri seti kullanılmıştır. Veri seti sınıf değişkenleri de dahil olmak üzere 13 özelliği içermekte olup, Ahmad ve arkadaşları tarafından Pakistan'ın Pencap eyaletindeki Faisalabad Kardiyoloji Enstitüsü Hastanesi'nden toplanmıştır. Tablo 1’de veri seti hakkında ayrıntılı açıklama sunulmuştur [4].

Veri seti, hastaların yaşları, tütün kullanımı, çeşitli kan tahlili sonuçları ile diyabet, tansiyon ve anemi gibi hastalıklara dair bilgileri içermektedir. Kreatinin fosfokinaz, trombosit, ejiksiyon fraksiyonu, kreatinin ve sodyum gibi değerler sürekli değişkenlerken; sigara kullanımı, diyabet, anemi, kan basıncı ve cinsiyet gibi bilgiler kategorik değişkenler olarak tanımlanmıştır. Hastaların sağkalım süreleri gün cinsinden belirtilmiştir. Veri setinde eksik değer olmamakla birlikte 130 günlük ortalama takip sürecinde hastaların 96’sı hayatını kaybetmiştir. Bu durum veri setinin dengesiz bir dağılıma sahip olduğunu göstermektedir. Bununla birlikte veri setinde ölüm Olayı=1 hayatını kaybeden hastayı, ölüm olayı=0 ise hayatta kalan hastayı ifade etmektedir. Bu çalışmada KY tanılı hastaların sağ

kalımlarının tahmininde MÖ sınıflandırıcıları ile birlikte yeniden örnekleme tekniklerinin birlikte kullanılması durumunda sınıflandırıcı performansları irdelenmiştir.

2.2 Veri Ön İşleme

MÖ dayalı modellerin performansları kullanılan verilerin kalitesiyle yakından ilintilidir. Bu nedenle modellerde, veri ön işleme süreci büyük önem arz etmektedir. Veri ön işleme süreci; verilerin dönüştürülmesini, yeniden örnekleme yapılmasını ve özellik seçiminin uygulanmasını içermekte olup, aynı zamanda bozuk veya eksik veri noktalarını ve aykırı değerleri tespit ederek verilerin temizlenmesini sağlamaktadır. Bu kapsamda çalışmada ilk olarak veri setinde kategorik formatta olan özelliklerin değerleri tam sayı formatına dönüştürülmüş ve ardından min-max yöntemi uygulanarak veriler normalize edilmiştir. Daha sonra korelasyon temelli bir özellik seçim yöntemi olan CfsSubsetEval algoritmasıyla en iyi ilk arama yöntemine dayanarak veri setindeki anlamlı (belirleyici) özellikler tespit edilmiştir. Buna göre veri setindeki en anlamlı özellikler yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre olarak belirlenmiştir.

2.3 Yeniden Örnekleme Teknikleri

Gerçek veri setlerinde sınıf dağılımlarının dengesiz olduğu durumlar oldukça yaygındır. Bu dengesizlik, çoğu zaman bazı sınıfların diğerlerine kıyasla daha fazla veya daha

az örneğe sahip olması durumunda ortaya çıkmaktadır. Dengesiz veri problemi, bu tür veri setlerinde modellerin sınıflandırma performansını olumsuz yönde etkileyebilmektedir. Özellikle çoğunluk sınıfının daha fazla örneğe sahip olması, azınlık sınıfının doğru bir şekilde öğrenilmesini zorlaştırabilmektedir. Bu durum, geleneksel sınıflandırma modellerinin azınlık sınıfını ihmal etmesine veya yanlış sınıflandırmasına yol açabilmektedir. Sonuç olarak, dengesiz veri setleriyle çalışırken, sınıflandırıcıların performans ölçütleri (doğruluk, hassasiyet, geri çağırma gibi) olumsuz etkilenebilmektedir. Dengesiz veri probleminin üstesinden gelmek adına literatürde birçok yaklaşım geliştirilmiştir. Bu yaklaşımlardan biri olan örnekleme tabanlı yaklaşım, azınlık sınıftaki örnekleri artırarak (aşırı örnekleme, oversampling) veya çoğunluk sınıftaki örnekleri azaltarak (az örnekleme, undersampling) sınıf dengesizliğini azaltmayı ve dolayısıyla sınıflandırma performansını iyileştirmeyi amaçlamaktadır [18], [19]. Gerçekleştirilen bu çalışmada veri setindeki dengesizliği gidermek ve böylece sınıflandırıcıların performanslarını artırmak amacıyla on üç farklı yeniden örnekleme tekniğinden yararlanılmıştır.

Tablo 1. Veri setindeki özelliklerinin genel bir tanımı [3]

Özellik	Tanımı ve Aralığı
Yaş	Hastanın yaşı (Yıl)
Cinsiyet	Hastanın cinsiyet bilgisi (Kategorik)
Tütün kullanımı	Hastanın tütün kullanma durumu (Kategorik)
Anemi	Sağlıklı kırmızı kan hücrelerinin eksikliği (Kategorik)
Yüksek kan basıncı	Hastanın kan basıncı durumu (Kategorik)
Kreatinin Fosfokinaz (CPK)	Kandaki Kreatinin Fosfokinaz enzimi miktarı (mcg/L)
Diyabet	Hastanın diyabetik durumu (Kategorik)
Ejeksiyon Fraksiyonu	Kalp kasılırken kalpten çıkan kan miktarı (%)
Trombositler	Kandaki trombosit sayısı (kiloplateletler/mL)
Serum Kreatinin	Kandaki kreatinin düzeyi (mg/dL)
Serum Sodyum	Kandaki sodyum seviyesi (mEq/L)
Zaman	Takip süresi (Gün)
(Hedef) Ölüm Olayı	Takip süresi boyunca hayatta kalan hasta sayısı (Kategorik)

2.4. Sınıflandırıcılar

Sınıflandırma problemlerinde, veri setindeki desenler ve ilişkiler üzerinden öğrenilen bilgiler kullanılarak, yeni gelen

veri noktalarının hangi sınıfa ait olduğu belirlenmektedir. Bu tür problemlerde, veri noktalarının hangi kategorilere ait olduğunu belirlemek için farklı yöntemler kullanılabilir. Bu yöntemler, veri setinin özelliklerine, problem alanına ve gereksinimlere bağlı olarak değişiklik göstermektedir. Sınıflandırma problemlerinde önemli olan, uygun bir sınıflandırma algoritması seçmek ve modelin doğruluğunu değerlendirmek için uygun metrikleri kullanmaktır. Gerçekleştirilen bu çalışma kapsamında KY tanılı hastaların sağkalımlarının tahmini için literatürde sıklıkla tercih edilen RO, DVM, Gradyan artırma (Gradient Boosting, GB), XGBoost, LightGBM, Adaptif Arttırma

(AdaBoost, Adaptive Boosting) ve ETC algoritmaları kullanılmıştır. Kullanılan sınıflandırıcı algoritmaları Tablo 2’de açıklanmıştır.

2.5 Model Doğrulama ve Performans Değerlendirme Kriterleri

Çapraz doğrulama, istatistiksel analiz sonuçlarının bağımsız bir veri kümesinde ne ölçüde genelleştirildiğini değerlendirmek için uygulanan bir model doğrulama tekniğidir. Bu çalışmada veri setini rastgele eğitim seti (%80) ve test seti (%20) olarak ayıran hold-out yöntemi kullanılarak modellerin doğruluğu değerlendirilmiştir. Yeniden

Tablo 2. Kullanılan sınıflandırma algoritmaları

Algoritma	Tanımı
RO	RO, birden fazla zayıf öğrenenin bir araya gelerek doğru tahminler ürettiği ağaç tabanlı bir topluluk öğrenme modelidir. Bu model, torbalama tekniği kullanılarak çeşitli önyükleme örnekleriyle çeşitli karar ağaçlarını eğitmek için kullanılmaktadır. Her bir ağaç, örneğin boyutunun eğitim veri kümesine eşit olduğu, ancak eğitim veri kümesinden rastgele örnekleme yapılarak türetilen bir önyükleme örneğiyle eğitilmektedir. Bu şekilde, her bir ağaç farklı bir alt örneklemeyle eğitilmekte ve topluluk olarak bir araya getirilmektedir. Böylece daha güçlü ve genelleştirilebilir bir sınıflandırıcı elde edilmektedir [3].
DVM	DVM, veriler arasında bir ayrım yapmak için karar düzlemleri olarak adlandırılan yüksek boyutlu hiperdüzlemler oluşturmaktadır. Bu hiperdüzlemler, farklı sınıflara ait verileri birbirinden ayırmak için en iyi şekilde yerleştirilmektedir. Temel prensibi, veri noktalarını en iyi şekilde sınıflandıran bir hiperdüzlemi bulmaktır. Bu hiperdüzlem, veri noktalarının en yakınları arasındaki mesafeyi maksimize etmeye çalışmaktadır, böylece sınıflar arasındaki marjı maksimize etmektedir [20].
GB	GB, birçok zayıf sınıflandırıcının bir araya gelerek güçlü bir öğrenme modeli oluşturduğu bir topluluk öğrenme algoritmasıdır. Genellikle karar ağacı prensibiyle çalışır ve her bir bağımsız ağacı yaratırken maliyetli ve zaman alıcı bir seçim yapmaktadır. Algoritma, bir dizi ince ayarın ardından zayıf öğrenme algoritmalarını geliştirerek gücünü artırmaktadır. Yaklaşık olarak doğru öğrenme olasılığı adı verilen özelliğe dayanan GB, işlenmemiş veriler üzerinde iyi çalışırken, veri eksik değerlerini verimli bir şekilde ele almaktadır [21].
XGBoost	XGBoost, optimize edilen bir kayıp fonksiyonu ve çeşitli düzenlemelerle desteklenen yüksek performanslı bir güçlendirme tekniğidir. GB algoritmasıyla çalışan XGBoost, modelin zor durumlara odaklanmasını sağlamak ve bu durumları önceki modellerden daha iyi ele almasını sağlamaktadır. Bu, gözlemlerin dağılımını çarpıtarak zor örnekleri daha fazla vurgulayarak gerçekleştirilmektedir. Böylece, her bir zayıf öğrenen model daha iyi performans göstermekte ve sonunda tüm bu modeller birleştirilerek güçlü bir tahminci elde edilmektedir [22].
LightGBM	LightGBM, GB’e dayanan yüksek performanslı ve dağıtılmış bir MÖ algoritmasıdır. Bu algoritma, özellikle büyük veri kümeleriyle çalışırken hızlı eğitim süreleri ve yüksek tahmin doğruluğu sağlamaktadır. LightGBM, ağaç tabanlı bir model oluştururken, diğer GB modellerine kıyasla daha hızlı eğitim süreleri sunmaktadır. Bu, büyük veri kümeleri veya yüksek boyutlu özelliklerle çalışırken avantajlıdır. LightGBM ayrıca bellek kullanımını optimize etmekte ve özelleştirilmiş kayıp fonksiyonları ve metrikler kullanarak modelin performansını artırma esnekliği sunmaktadır. Bu nedenle, birçok MÖ uygulamasında tercih edilmektedir [23].
AdaBoost	AdaBoost, genellikle diğer algoritmalarla birlikte kullanılarak performansını artırmak için tercih edilen bir algoritmadır. Zayıf öğrencileri güçlü öğrencilere dönüştürmek için güçlendirme (boosting) üzerinde çalışmaktadır.

	Her ağaç, AdaBoost sınıflandırıcısında önceki ağaçların hata oranına bağlı olarak oluşturulmaktadır. Bu şekilde, hatalı sınıflandırılan örnekler daha fazla vurgulanmakta ve yeni eklenen ağaçlar bu hatalara odaklanmaktadır, böylece daha doğru bir sınıflandırıcı elde edilmektedir [24].
ETC	ETC, çalışma prensibi bakımından RO'a oldukça benzeyen bir çalışma prensibine sahiptir, ancak ağaçların inşaa yöntemi açısından farklılık göstermektedir. Her bir KA, orijinal eğitim veri örneklerinden oluşturulmaktadır. Karar vermek için en iyi k özelliğin rastgele örneklere uygulandığı ve Gini indeksinin kullanıldığı en üst özellik seçilmektedir. Bu rastgele örnek özellikler, korelasyonsuz birçok KA'nın oluşturulmasını sağlamaktadır. Bu sayede, daha genel ve çeşitli bir modele olanak tanımaktadır [25].

örnekleme yöntemlerinin sadece eğitim setine uygulandığı çalışmada modellerin performansları test verisi üzerinden karmaşıklık matrisinden hesaplanan dört farklı metriğe göre değerlendirilmiştir. Karmaşıklık matrisi gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi göstermektedir. Genellikle dört ana kategoriden oluşmaktadır: Doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN). Bu kategoriler, modelin sınıfları ne kadar doğru tahmin ettiğini ve ne kadar hata yaptığını göstermektedir [26]. Eğer veri tıbbi bir uygulamayla ilişkilendirilmişse, yanlış negatif tahminler en kritik olanlardır çünkü hastalığı kaçırmak veya yanlış teşhis koymak ciddi sonuçlara yol açabilmektedir.

Karmaşıklık matrisinden hesaplanan performans metrikleri Tablo 3'de kısaca açıklanmıştır. Çalışmada modellerin performansları Tablo 3'de verilen metriklerin

haricince ROC eğrisinin altında kalan alan (AUC) metriği kullanılarak da değerlendirilmiştir. AUC-ROC eğrisi metriği, farklı sınıflandırma eşiklerindeki duyarlılık ve özgüllük değerlerini görselleştirerek sınıflandırıcının performansını geniş bir perspektiften değerlendirmektedir. Böylelikle, sınıflandırıcıların farklı veri kümesi veya koşullar altında nasıl performans göstereceği hakkında kapsamlı bir bilgi sağlamaktadır. Bu bağlamda çalışma kapsamında modellerin performanslarını daha geniş bir açıdan değerlendirmek adına AUC-ROC eğrisi metriği de göz önünde bulundurulmuştur.

3. Deneysel Sonuçlar

Bu çalışmada açık erişime sahip gerçek bir veri seti kullanılarak, KY tanılı hastaların sağ kalımlarının tahmini için

Tablo 3. Performans metrikleri.

Metrik Adı	Formülü	Tanımı
Doğruluk	$\frac{DP + DN}{DP + DN + YP + YN}$	Doğruluk, bir modelin doğru tahmin ettiği örneklerin oranını ifade etmektedir.
Duyarlılık	$\frac{DP}{YN + DP}$	Duyarlılık, gerçek pozitiflerin tüm pozitif örnekler içindeki oranını ifade etmekte ve modelin gerçek pozitifleri ne kadar iyi tanıdığını ölçmektedir.
Kesinlik	$\frac{DP}{YP + DP}$	Kesinlik, doğru pozitiflerin toplam pozitif tahminlere oranını ifade etmekte olup, modelin doğru pozitif tahminlerinin ne kadarını doğru bir şekilde gerçek pozitif olarak belirlediğini göstermektedir.
F-Skor	$\frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}}$	F-skor kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır.
AUC-ROC	$\int DPR \cdot d(YPR)$	ROC eğrisinin altında kalan alanı ifade etmekle birlikte; doğru pozitif oranının (DPR) yanlış pozitif oranının (FPR) fonksiyonu olarak tanımlanmaktadır.

CfsSubsetEval algoritmasıyla veri setindeki belirleyici olan özellikler (yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre) tespit edilmiştir. İkinci aşamada bu özellikleri kullanan yedi farklı MÖ algoritmasına dayanan (RO, AdaBoost, XGBoost, LightGBM, DVM, GB ve ETC) modeller oluşturularak başarımları karşılaştırılmıştır. Üçüncü

aşamada ise modellerin performanslarını iyileştirmek amacıyla on üç farklı yeniden örnekleme yönteminin uygulanmasının etkileri analiz edilmiştir. Çalışmada kullanılan algoritmaların parametreleri Spyder programının kendi varsayılan değerleri olacak şekilde bırakılmış, model başarımına olumlu ya da olumsuz etki edebilecek

değişikliklerden kaçınılmıştır. Ayrıca modellerin doğruluğu için 80:20 hold-out tekniği kullanılırken, performansları yeniden örnekleme tekniklerinin uygulanıp uygulanmama durumları için test verisi üzerinden hesaplanan beş farklı

parametreye (doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC) göre değerlendirilmiştir. Buna göre RO, Adaboost, XGBoost, LightGBM, DVM, GB ve ETC için elde edilen sonuçlar sırasıyla Tablo 4'den Tablo 10'a kadar sunulmuştur.

Tablo 4. RO algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,59	0,68	0,52	0,70	0,83
Fazla Örnekleme	SMOTE	0,68	0,68	0,68	0,73	0,84
	RandomOverSampler	0,64	0,74	0,56	0,73	0,84
	ADASYN	0,67	0,75	0,60	0,75	0,86
	Bonderlinesmote	0,67	0,75	0,60	0,75	0,84
	SVMSMOTE	0,67	0,70	0,64	0,73	0,80
Az Örnekleme	EditedNearestNeighbours	0,74	0,69	0,80	0,77	0,85
	AIKNN	0,74	0,69	0,80	0,77	0,86
	InstanceHardnessThreshold	0,72	0,61	0,88	0,72	0,87
	NearMiss	0,65	0,67	0,64	0,72	0,85
	NeighbourhoodCleaningRule	0,73	0,67	0,80	0,75	0,85
	OneSidedSelection	0,65	0,71	0,60	0,73	0,85
	RandomUnderSampler	0,72	0,72	0,72	0,77	0,84
	TomekLinks	0,65	0,71	0,60	0,73	0,86

Tablo 5. Adaboost algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,59	0,75	0,48	0,72	0,84
Fazla Örnekleme	SMOTE	0,70	0,83	0,60	0,78	0,86
	RandomOverSampler	0,70	0,83	0,60	0,78	0,87
	ADASYN	0,73	0,84	0,64	0,80	0,79
	Bonderlinesmote	0,67	0,75	0,6	0,75	0,84
	SVMSMOTE	0,71	0,80	0,64	0,78	0,80
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,88
	AIKNN	0,75	0,71	0,80	0,78	0,86
	InstanceHardnessThreshold	0,73	0,63	0,88	0,73	0,86
	NearMiss	0,64	0,68	0,60	0,72	0,83
	NeighbourhoodCleaningRule	0,73	0,70	0,76	0,77	0,83
	OneSidedSelection	0,71	0,88	0,60	0,80	0,87
	RandomUnderSampler	0,68	0,73	0,64	0,75	0,86
	TomekLinks	0,70	0,83	0,60	0,78	0,87

Tablo 6. XGBoost algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,68	0,79	0,60	0,77	0,86
Fazla Örnekleme	SMOTE	0,72	0,77	0,68	0,78	0,87
	RandomOverSampler	0,71	0,80	0,64	0,78	0,88
	ADASYN	0,67	0,82	0,56	0,77	0,85
	Bonderlinesmote	0,74	0,81	0,68	0,80	0,85
	SVMSMOTE	0,72	0,77	0,68	0,78	0,83
Az Örnekleme	EditedNearestNeighbours	0,78	0,77	0,80	0,82	0,88
	AIKNN	0,73	0,70	0,76	0,77	0,87
	InstanceHardnessThreshold	0,75	0,64	0,92	0,75	0,88
	NearMiss	0,73	0,70	0,76	0,77	0,85
	NeighbourhoodCleaningRule	0,72	0,68	0,76	0,75	0,86
	OneSidedSelection	0,70	0,83	0,60	0,78	0,88
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,89
	TomekLinks	0,63	0,81	0,52	0,75	0,87

Tablo 7. LightGBM algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örnekleme	-	0,68	0,88	0,56	0,78	0,88
Fazla Örnekleme	SMOTE	0,65	0,71	0,60	0,73	0,87
	RandomOverSampler	0,63	0,81	0,52	0,75	0,88
	ADASYN	0,68	0,79	0,60	0,77	0,87
	Bonderlinesmote	0,68	0,79	0,60	0,77	0,84
	SVMSMOTE	0,75	0,78	0,72	0,80	0,82
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,87
	AIKNN	0,73	0,70	0,76	0,77	0,88
	InstanceHardnessThreshold	0,74	0,62	0,92	0,73	0,87
	NearMiss	0,72	0,72	0,72	0,77	0,86
	NeighbourhoodCleaningRule	0,78	0,79	0,76	0,82	0,85
	OneSidedSelection	0,73	0,94	0,60	0,82	0,86
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,86
	TomekLinks	0,67	0,82	0,56	0,77	0,88

Tablo 8. DVM algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örnekleme	-	0,65	0,78	0,56	0,75	0,82
Fazla Örnekleme	SMOTE	0,71	0,74	0,68	0,77	0,82
	RandomOverSampler	0,71	0,69	0,72	0,75	0,81
	ADASYN	0,75	0,73	0,76	0,78	0,83
	Bonderlinesmote	0,76	0,76	0,76	0,80	0,83
	SVMSMOTE	0,75	0,78	0,72	0,80	0,80
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,83
	AIKNN	0,71	0,69	0,72	0,75	0,83
	InstanceHardnessThreshold	0,76	0,70	0,84	0,78	0,84
	NearMiss	0,69	0,71	0,68	0,75	0,85
	NeighbourhoodCleaningRule	0,72	0,72	0,72	0,77	0,83
	OneSidedSelection	0,67	0,75	0,60	0,75	0,83
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,81
	TomekLinks	0,67	0,75	0,60	0,75	0,82

Tablo 9. GB algoritması için performans metrikleri.

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örnekleme	-	0,54	0,83	0,40	0,72	0,86
Fazla Örnekleme	SMOTE	0,67	0,82	0,56	0,77	0,87
	RandomOverSampler	0,67	0,82	0,56	0,77	0,88
	ADASYN	0,62	0,76	0,52	0,73	0,86
	Bonderlinesmote	0,67	0,93	0,52	0,78	0,85
	SVMSMOTE	0,68	0,88	0,56	0,78	0,81
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,87
	AIKNN	0,70	0,66	0,76	0,73	0,87
	InstanceHardnessThreshold	0,71	0,62	0,84	0,72	0,85
	NearMiss	0,63	0,65	0,60	0,70	0,84
	NeighbourhoodCleaningRule	0,71	0,69	0,72	0,75	0,85
	OneSidedSelection	0,71	0,88	0,60	0,80	0,86
	RandomUnderSampler	0,73	0,75	0,72	0,78	0,88
	TomekLinks	0,67	0,93	0,52	0,78	0,88

Tablo 10. ETC algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemez	-	0,65	0,78	0,56	0,75	0,88
Fazla Örnekleme	SMOTE	0,67	0,75	0,60	0,75	0,87
	RandomOverSampler	0,67	0,93	0,52	0,78	0,86
	ADASYN	0,68	0,73	0,64	0,75	0,85
	Bonderlinesmote	0,68	0,73	0,64	0,75	0,88
	SVMSMOTE	0,65	0,71	0,60	0,73	0,83
Az Örnekleme	EditedNearestNeighbours	0,75	0,73	0,76	0,78	0,87
	AIKNN	0,75	0,73	0,76	0,78	0,86
	InstanceHardnessThreshold	0,78	0,72	0,84	0,80	0,87
	NearMiss	0,64	0,68	0,60	0,72	0,87
	NeighbourhoodCleaningRule	0,69	0,71	0,68	0,75	0,86
	OneSidedSelection	0,70	0,83	0,60	0,78	0,86
	RandomUnderSampler	0,73	0,75	0,72	0,78	0,86
	TomekLinks	0,70	0,83	0,60	0,78	0,87

Elde edilen sonuçlar incelendiğinde, bazı yeniden örnekleme yöntemlerinin belirli sınıflandırıcıların başarısını, örnekleme yapılmayan duruma kıyasla azalttığı gözlemlenmiştir. XGboost algoritmasını kullanarak yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %77 iken, InstanceHardnessThreshold, NeighbourhoodCleaningRule ve TomekLinks gibi az örnekleme yöntemlerinin uygulanmasıyla bu başarı oranı %75'e düşmüştür. LightGBM algoritmasıyla yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %78 iken, bu değer SMOTE ve InstanceHardnessThreshold yöntemlerinin uygulanmasıyla %73'e, RandomOverSampler yönteminin uygulanmasıyla %75'e ve son olarak ADASYN, Bonderlinesmote, EditedNearestNeighbours, AIKNN, NearMiss ve TomekLinks yöntemlerinin uygulanmasıyla %77'ye düşmüştür. GB algoritması kullanılarak yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %72 iken, algoritmaya NearMiss örnekleme yöntemi uygulanması durumunda başarı oranı %70'e inmiştir. ETC algoritmasıyla yapılan sınıflandırmalar için ise örnekleme yapılmayan durumda %75 olan başarı oranı SVMSMOTE örnekleme yöntemi uygulanması durumunda %73 ve NearMiss örnekleme yöntemi uygulanması durumunda ise %72'ye düşmüştür. Elde edilen sonuçlar genel olarak irdelendiğinde, yeniden örnekleme tekniklerinin genel anlamda sınıflandırma başarısını artırdığı tespit edilmiştir.

Sınıflandırma başarımı açısından bakıldığında, yeniden örnekleme tekniklerinin kullanılmasıyla RO algoritmasında %10'luk, LightGBM algoritmasında %4'lük, XGboost, DVM

ve ETC algoritmalarında %7'lik ve Adaboost ile GB algoritmalarında %12'lik bir performans artışı elde edilmiştir. Örnekleme tekniklerinin başarı durumları değişkenlik gösterse de, bu çalışmada az örneklemenin daha başarılı sonuçlar verdiği ve InstanceHardnessThreshold, ADASYN ve OneSidedSelection tekniğinin genel anlamda daha yüksek başarı artışı (%12) sağladığı belirlenmiştir.

Örnekleme tekniklerinin uygulanıp (fazla örnekleme ve az örnekleme) uygulanmama (örneklemez) durumlarının MÖ algoritmalarının performansına olan etkileri farklı metrikler açısından Tablo 11'de karşılaştırılmıştır. Burada her bir durum için farklı başarı metrikleri açısından model performansları ayrı ayrı değerlendirilerek, elde edilen en yüksek değerler özetlenmiştir. Tablo 11'den de açıkça görüldüğü üzere, farklı örnekleme teknikleri uygulanan MÖ algoritmalarının performansı F1 skoru açısından değerlendirildiğinde en yüksek başarıyı az örnekleme tekniği kullanıldığında XGBoost, LightGBM ve ETC (%78) algoritmaları sergilemiştir. Duyarlılık metriği açısından en yüksek başarı değeri az örnekleme tekniğiyle LightGBM algoritmasıyla (%94) elde edilmiştir. Kesinlik metriği açısından en yüksek başarı değeri XGboost ve LightGBM algoritmalarına (%92) az örnekleme tekniğinin uygulanması durumunda ulaşılmıştır. AUC metriği açısından elde edilen en yüksek değer az örnekleme tekniği uygulanan XGboost algoritmasında (%89) görülmüştür. Son olarak doğruluk metriği açısından ise en yüksek doğruluk değeri %82 ile az örnekleme teknikleri uygulanan XGBoost ve LightGBM elde edilmiştir. Genel olarak, XGBoost ve LightGBM algoritmaları farklı metriklerde benzer performans

sergilemiştir. Ancak XGBoost, F1 skoru ve AUC metriği açısından biraz daha iyi bir performans göstermiştir. Bu nedenle, F1-skor, doğruluk ve AUC metriklerine dayanarak, XGBoost'un LightGBM'den daha yüksek performansa sahip olduğu belirlenmiştir.

Literatürde benzer veri seti kullanarak yapılan çalışmalar Tablo 12'de verilmiştir. Tablodan da görüldüğü üzere KY tanılı hastaların sağkalımlarının tahmininde daha yüksek başarımlar elde edilen çalışmalar mevcuttur. Ancak gerçekleştirilen çalışma dengesiz veri setlerinde örnekleme tekniklerinin model başarımı üzerindeki etkilerinin ele alınması açısından mevcut çalışmalardan ayrılmaktadır.

Dengesiz veri setlerinde örnekleme tekniklerinin uygulanması önem arz etmektedir. Çünkü çoğunluk sınıfı odaklanan modeller, azınlık sınıfı göz ardı edebilmekte, bu da model performansını etkilemektedir. Örnekleme teknikleri, sınıflar arasındaki dengesizliği azaltarak daha doğru ve adil tahminler yapılmasını sağlamaktadır. Elde edilen bulgular dengesiz veri setlerinde örnekleme yönteminin kullanılmasının performans üzerinde etkili olduğu gösterilmiştir.

Tablo 11. Kullanılan algoritmalar için elde edilen en iyi sonuçlar

Algoritma	Örnekleme Yöntemi	En İyi F1Skoru	En İyi Duyarlılık	En İyi Kesinlik	En Doğruluk	En İyi AUC
RO	Örneklemez	0,59	0,68	0,52	0,70	0,83
	Fazla Örnekleme	0,68	0,75	0,68	0,75	0,86
	Az Örnekleme	0,74	0,72	0,88	0,77	0,87
Adaboost	Örneklemez	0,59	0,75	0,48	0,72	0,84
	Fazla Örnekleme	0,73	0,84	0,64	0,80	0,87
	Az Örnekleme	0,75	0,88	0,88	0,80	0,88
XGboost	Örneklemez	0,68	0,79	0,60	0,77	0,86
	Fazla Örnekleme	0,74	0,82	0,68	0,80	0,88
	Az Örnekleme	0,78	0,83	0,92	0,82	0,89
LightGBM	Örneklemez	0,68	0,88	0,56	0,78	0,88
	Fazla Örnekleme	0,75	0,81	0,72	0,80	0,88
	Az Örnekleme	0,78	0,94	0,92	0,82	0,88
DVM	Örneklemez	0,65	0,78	0,56	0,75	0,82
	Fazla Örnekleme	0,76	0,78	0,76	0,80	0,83
	Az Örnekleme	0,76	0,75	0,84	0,78	0,85
GB	Örneklemez	0,54	0,83	0,40	0,72	0,86
	Fazla Örnekleme	0,68	0,93	0,56	0,78	0,88
	Az Örnekleme	0,73	0,93	0,84	0,80	0,88
ETC	Örneklemez	0,65	0,78	0,56	0,75	0,88
	Fazla Örnekleme	0,68	0,93	0,64	0,78	0,88
	Az Örnekleme	0,78	0,83	0,84	0,80	0,87

Tablo 12. Literatürde aynı veri seti kullanılarak yapılan çalışmaların karşılaştırılması

Yazarlar	Yöntem	Doğruluk (%)
Chicco ve Jurman [7]	LR	83.8
Mamun ve ark [12]	LightGBM	85
Awan ve ark. [27]	RO	76
Princy ve ark. [28]	KA	73
Bharti ve ark. [29]	KNN	84.8
Önerilen model	XGboost+ EditedNearestNeighbours	82

4. Sonuç ve Tartışma

KY, yüksek ölüm oranlarına sahip ve son yıllarda artış gösteren ciddi bir kalp hastalığıdır. Bu çalışmada, KY tanılı hastalarının sağkalımlarının doğru bir şekilde tahmin

etmek amacıyla MÖ temelli hibrid bir model önerilmiştir. Model korelasyon temelli özellik seçimiyle tespit edilen anlamlı özelliklerle oluşturulmuş ve yedi farklı MÖ algoritmasının performansı on üç farklı yeniden örnekleme

tekniki kullanılarak değerlendirilmiştir. Tüm örnekleme teknikleri ve sınıflandırma algoritmaları arasında farklı başarımları açısından yapılan genel değerlendirmeler neticesinde en iyi performansı EditedNearestNeighbours az örnekleme tekniğiyle uygulanan XGBOOST algoritmasının sergilediği tespit edilmiştir. Literatürde aynı veri seti üzerinde daha yüksek başarımlar elde eden çalışmalar bulunmaktadır. Ancak bu çalışmada mevcuttakilerden farklı olarak veri seti 80:20 oranında bölünerek yeniden örnekleme tekniklerinin KY hastalarının sağkalımlarının tahminin üzerindeki etkileri irdelenmiştir. Elde edilen bulgular ışığında dengesiz veri setlerinde örnekleme yönteminin kullanılmasının performans üzerinde etkili olduğu tespit edilmiştir. Ancak çalışmamızda veri setinin sınırlı olması gibi bazı sınırlılıklar bulunmaktadır. Bu nedenle gelecekte yapılması planlanan çalışmalarda farklı sınıflandırıcıları bir araya getiren bir topluluk öğrenme modeli oluşturulması ve daha yüksek başarımların elde edilmesi konuları ele alınacaktır. Bunun için daha geniş bir veri seti kullanılarak, farklı model doğrulama teknikleri, farklı veri ön işleme aşamaları ve özellik seçme yöntemlerinin kullanılması planlanmaktadır.

5. Kaynaklar

- [1] G. Lippi, and F. Sanchis-Gomar, "Global epidemiology and future trends of heart failure", AME Medical Journal, vol. 1, no.15, pp.1-6, 2020.
- [2] A. Feher, B. Bednarski, R. J. Miller, A. Shanbhag, M. Lemley, L. Miras, Miras, Albert J. Sinusas, Edward J. Miller and P. J. Slomka, "Artificial intelligence predicts hospitalization for acute heart failure exacerbation in patients undergoing myocardial perfusion imaging", Journal of Nuclear Medicine, vol. 65, no. 5, pp. 768-774, 2024.
- [3] İ.Ş. Yapıcı, R. U. Arslan, and O. ErKaymaz, "Kalp yetmezliği tanılı hastaların hayatta kalma tahmininde topluluk makine öğrenme yöntemlerinin performans analizi", Karaelmas Fen ve Mühendislik Dergisi, vol. 14, no. 1, pp. 59-69, 2024.
- [4] T. Ahmad, A. Munir, S. H: Bhatti, M. Aftab, and M. A. Raza, "Survival analysis of heart failure patients: A case study", PloS One, vol. 12, no. 7, p.e0181001, 2017.
- [5] İ. Atacak, "Kalp yetmezliği tahmininin kategorik olarak farklı tip makine öğrenmesi yöntemleri ile uygulanmasına yönelik bir değerlendirme çalışması", EMO Bilimsel Dergi, vol. 14, no. 1, pp. 73-85, 2024.
- [6] F.S. Alotaibi, "Implementation of machine learning model to predict heart failure disease", International Journal of Advanced Computer Science and Applications, vol. 10, no. 6, pp.261- 268, 2019.
- [7] D. Chicco, and G. Jurman, "Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone", BMC Medical Informatics and Decision Making, vol. 20, no. 1, pp.1-16, 2020.
- [8] Ç. B. Erdaş and D. Ölçer, "A Machine Learning-Based Approach to Detect Survival of Heart Failure Patients," 2020 Medical Technologies Congress (TIPTEKNO), Antalya, Turkey, 2020, pp. 1-4, doi: 10.1109/TIPTEKNO50054.2020.9299320.
- [9] 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, 2020.
- [10] A. Ishaq, S. Sadiq, M. Umer, S. Ullah, S. Mirjalili, V. Rupapara, and M. Nappi, "Improving the prediction of heart failure patients' survival using SMOTE and effective data mining techniques", IEEE access, vol. 9, pp. 39707-39716, 2021.
- [11] N. S. Mansur Huang, Z. Ibrahim, and N. Mat Diah, "Machine learning techniques for early heart failure prediction", Malaysian Journal of Computing, vol. 6, no. 2, pp. 872-884,2021.
- [12] M. Mamun, A. Farjana, M. A. Mamun, M. S. Ahammed and M. M. Rahman, "Heart failure survival prediction using machine learning algorithm: am I safe from heart failure?," 2022 IEEE World AI IoT Congress (AIIoT), Seattle, WA, USA, 2022, pp. 194-200, doi: 10.1109/AIIoT54504.2022.9817303.
- [13] M. Muntasir Nishat, F. Faisal, I. Jahan Ratul, A. Al-Monsur, A. M. Ar-Rafi, S. M. Nasrullah, M. T. Reza and M. R. H. Khan, "A comprehensive investigation of the performances of different machine learning classifiers with SMOTE-ENN oversampling technique and hyperparameter optimization for imbalanced heart failure dataset", Scientific Programming, vol. 2022, pp. 1-17, 2022.
- [14] F. A. Özbay, and E. Özbay, "Makine öğrenmesi algoritmalarının kalp yetmezliği hastalarının hayatta kalma tahmini üzerindeki performans karşılaştırılması", 2. International Mediterranean Scientific Research and Innovation Congress, pp. 503-515, Girne, KKTC, 2022.
- [15] R. K. Sachdeva, K. D. Singh, S. Sharma, P. Bathla and V. Solanki, "An Organized Method for Heart Failure Classification," 2023 International Conference on Emerging Smart Computing and Informatics (ESCI), Pune, India, 2023, pp. 1-6, doi: 10.1109/ESCI56872.2023.10099809.
- [16] M. Mudassar, M. Afzal and T. Muhammad, "A Machine Learning Based Predictive Model to Diagnose Heart Failure Patients using Imbalanced Classification Problem," 2023 4th International Conference on Advancements in Computational Sciences (ICACS), Lahore, Pakistan, 2023, pp. 1-8, doi: 10.1109/ICACS55311.2023.10089759.
- [17] S. B. Keser, and K. Keskin, "Kalp yetmezliği hastalarının sağ kalım tahmini: Sınıflandırmaya dayalı makine öğrenmesi algoritmalarının bir uygulaması", Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, vol. 23, no. 2, pp. 362-369, 2023.
- [18] R. Ghorbani and R. Ghousi, "Comparing Different Resampling Methods in Predicting Students' Performance Using Machine Learning Techniques," in IEEE Access, vol. 8, pp. 67899-67911, 2020, doi: 10.1109/ACCESS.2020.2986809.

- [19] M. A. Aydın, "Müşteri Kaybı Tahmininde Sınıf Dengesizliği Problemi", *Politeknik Dergisi*, vol. 25, no. 1, pp. 351 - 360, 2020.
- [20] R. Uzun, Y. Isler and M. Toksan, "Use of Support Vector Machines to Predict the Success of Wart Treatment Methods," 2018 Innovations in Intelligent Systems and Applications Conference (ASYU), Adana, Turkey, 2018, pp. 1-4, doi: 10.1109/ASYU.2018.8554010.
- [21] S. Gündoğdu, "Efficient prediction of early-stage diabetes using XGBoost classifier with random forest feature selection technique", *Multimedia Tools and Applications*, vol. 82, no. 22, pp. 34163-34181, 2023.
- [22] N. Q. K. Le, D. T. Do, and Q. A. Le, "A sequence-based prediction of Kruppel-like factors proteins using XGBoost and optimized features", *Gene*, vol. 787, pp. 145643, 2021.
- [23] K. Karthick, S. K., Aruna, R. Samikannu, R. Kuppusamy, Y. Teekaraman, and A. R. Thelkar, "Implementation of a heart disease risk prediction model using machine learning", *Computational and Mathematical Methods in Medicine*, vol. 2022, pp. 6517716, 2022.
- [24] W. Wang, and D. Sun, "The improved AdaBoost algorithms for imbalanced data classification", *Information Sciences*, vol. 563, pp. 358-374, 2021.
- [25] L. Abhishek, "Optical Character Recognition using Ensemble of SVM, MLP and Extra Trees Classifier," 2020 International Conference for Emerging Technology (INCET), Belgaum, India, 2020, pp. 1-4, doi: 10.1109/INCET49848.2020.9154050.
- [26] R. Uzun, Y. Isler, and M. Toksan, "Prediction of the Success of Wart Treatment Methods", *Karaelmas Fen Ve Mühendislik Dergisi*, vol. 10, no. 1, pp. 44-52, 2020.
- [27] S. E. Awan, M. Bennamoun, F. Sohel, F. M. Sanfilippo, and G. Dwivedi, "Machine learning-based prediction of heart failure readmission or death: implications of choosing the right model and the right metrics," *ESC heart failure*, vol. 6, no. 2, pp. 428-435, 2019.
- [28] R. J. P. Princy, S. Parthasarathy, P. S. H. Jose, A. R. Lakshminarayanan, and S. Jeganathan, "Prediction of cardiac disease using supervised machine learning algorithms," In 2020 4th International Conference on Intelligent Computing and Control Systems, pp. 570-575.
- [29] R. Bharti, A. Khamparia, M. Shabaz, G. Dhiman, S. Pande, and P. Singh, "Prediction of heart disease using a combination of machine learning and deep learning," *Computational intelligence and neuroscience*, vol. 2021, 8387680, 2021.

Özgeçmişler



Dr. Rukiye Uzun Arslan, 2004 yılında Sivas Cumhuriyet Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan Rukiye UZUN ARSLAN, yüksek lisans eğitimini 2010 yılında, doktorasını ise 2014 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünde doçent 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.



Dr. İrem Şenyer Yapıcı, 2012 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan İrem ŞENYER YAPICI, yüksek lisans eğitimini 2016 yılında, doktorasını ise 2021 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Bilgisayar 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.

Benzerlik Tabanlı Öğrenme Kullanarak Histopatolojik Görüntülerin Sınıflandırılması

Classification of histopathological images using similarity-based learning

 Mahmut Kaya¹, Hasan Şakir BİLGE^{2,3} 

¹Yapay Zeka ve Veri Mühendisliği Bölümü, Mühendislik Fakültesi,
Fırat Üniversitesi, Elazığ, Türkiye
mahmutkaya@firat.edu.tr

²Elektrik Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi

³Biyomedikal Kalibrasyon ve Araştırma Merkezi
Gazi Üniversitesi, Ankara, Türkiye
bilge@gazi.edu.tr

Öz

Benzerlik metriği öğrenme, bir uzaklık öğrenme yaklaşımı olup aynı sınıfa ait örnekler arasındaki benzerliği arttırmayı, farklı sınıflar arasındaki benzerliği ise azaltmayı hedeflemektedir. Son yıllarda derin öğrenmenin elde ettiği başarıyla beraber benzerlik metriği öğrenmenin derin ağ modellerinde başarıyla uygulanabileceği görülmüştür. Bu çalışmada derin metrik öğrenme modellerinden olan Siamese ve Triplet ağ modelleri kullanılarak histopatolojik görüntülerde bir sınıflandırma işlemi gerçekleştirilmiştir. Histopatolojik görüntüler radyologlar tarafından tanı amacıyla kullanılırken sağlıklı ve sağlıklı olmayan görüntülerini birbirinden ayırmak oldukça zorlayıcıdır. Bu çalışmada literatürde başarısını kanıtlamış olan transfer öğrenme yöntemleri derin metrik öğrenme modellerine entegre edilmiştir. Yapılan çalışma sonucunda Siamese+VGG19 ağ modelinde %95,39 başarı elde edilirken, Triplet+VGG19 ağ modelinde ise %96,92 sınıflandırma başarısı elde edilmiştir.

Anahtar kelimeler: Benzerlik metriği öğrenme, siamese, triplet, sınıflandırma

Abstract

Similarity metric learning is a distance learning approach that aims to increase the similarity between instances of the same class and decrease the similarity between instances of different classes. With the success of deep learning in recent years, it has been seen that similarity metric learning can be successfully applied in deep network models. In this study, a classification process was performed on histopathologic images using Siamese and Triplet network models, which are deep metric learning models. While histopathologic images are used by radiologists for diagnostic purposes, it is very challenging to distinguish between healthy and unhealthy images. In this study, transfer learning methods that have proven their success in the literature are integrated into deep metric learning models. As a result of the study, the Siamese+VGG19 network model achieved 95.39% success, while the Triplet+VGG19 network model achieved 96.92% classification success.

Keywords: Similarity metric learning, siamese, triplet, classification

1. Giriş

Teknolojinin hızla geliştiği günümüz dünyasında, insanlar yaşamlarını kolaylaştırmak ve teknolojik ilerlemelere ayak uydurmak amacıyla karşılaştıkları problemleri, dijital ortamlara aktararak çözümler bulma eğilimindedir. İnsanın özünde bulunan öğrenme yeteneği, bilgisayarlara nesnelere öğretme kabiliyetini beraberinde getirmiştir [1]. Günümüzde, birçok alanda insanların yaşamlarını kolaylaştırmak için makine öğrenmesi yaklaşımlarından yararlanılmaktadır. Makine öğrenmesi kavramı, hayatımızın çeşitli alanlarında kendine yer bulmuş durumdadır. Makine öğrenmesi ile yüz tanıma, sağlık verileri, saldırı tespit sistemleri, konuşma ve ses tanıma, metin madenciliği, örüntü tanıma gibi farklı görevlerde çeşitli amaçlar için çözümler sunulmaktadır. Bu tür problemleri değerlendirmek amacıyla makine öğrenmesinde verileri sınıflandırma veya kümeleme yaklaşımlarıyla çözüm önerileri geliştirilmektedir.

Veri boyutunun artması ve problemlerin çeşitlenmesi, gerçek dünya problemlerinde makine öğrenmesi teknikleriyle en etkili çözümü bulmayı karmaşık bir hale getirmiştir [2]. Şu aşamada, mevcut yaklaşımlar ve yenilikler, problemin amacına odaklanarak maksimum doğruluk oranına ulaşmayı amaçlamaktadır. Makine öğrenme algoritmaları kullanarak, mevcut verilere dayalı yüksek başarıya sahip sınıflandırma modelleri geliştirilebilir. Öğrenme modelinin, öncelikle eğitim sürecinde kullanılan örnekler üzerinde başarı sağlamanın yanında test örnekleri üzerinde de başarılı sonuçlar elde etmesi hedeflenmektedir. Ancak öğrenme modeli her zaman doğru çalışmayabilir, çünkü her veri kümesinin kendisine ait bazı benzersiz zorlukları bulunmaktadır.

Metrik esaslı öğrenme, veri ögeleri arasındaki benzerlik veya farklılık ilişkilerini tespit etmek için, doğrudan metrikten öğrenmeyi temel alan bir makine öğrenmesi yaklaşımıdır. Bu yaklaşım, birbirine benzeyen veri ögeleri arasındaki mesafeyi azaltmayı hedeflerken, farklı veri ögeleri arasındaki uzaklığı arttırmayı amaçlamaktadır. Metrik temelli öğrenmede yeni bir dönüşüm uzayına veriler taşınırken temelde bir W projeksiyon matrisinden yararlanılmaktadır. Metrik esaslı öğrenme Mahalonobis uzaklık metriğinin dönüşümü ile ilgili olup, dönüşüm sürecinde simetrik ve pozitif tanımlı matrislere dayalı

bir yaklaşım ele alınmaktadır [3-5].

Gelişen teknolojik araçların kullanımıyla beraber veri hacmi her geçen gün artmaktadır. Bu artış, daha doğru bir sınıflandırma elde etmek için büyük avantajlar sağlamaktadır. Ancak, veri artışı problemde yüksek başarımlar elde etmede pozitif katkı sunarken, çok büyük hacimli verilerin işlenmesi ve yüksek hesaplama maliyeti problemini beraberinde getirmektedir. Günümüzde, yoğun hesaplama ihtiyacı nedeniyle işlemlerin sıralı olmak yerine parça parça işlenmesi ve bu parçalı işlemlerin paralel olarak yapılması, önemli hesaplama avantajları sunmaktadır. Son yıllarda GPU (Graphics Processing Unit) teknolojisindeki gelişmelerle birlikte, verilerin paralel bir şekilde işlenmesi mümkün hale gelmiştir. Bu gelişme, yapay zekaya yeni bir soluk getirerek günümüzün en popüler konularından biri olan derin öğrenme kavramını ortaya çıkarmıştır [6].

Derin öğrenme, doğrudan ham verilerden yeni bir temsil oluşturarak, daha yüksek soyutlama seviyelerine ulaşmayı hedefler ve ayırt edici özellikleri otomatik olarak çıkarmayı sağlar [7]. Derin öğrenme, doğrudan veriden öğrenme amacındadır. Bu süreçte ham veriden yeni dönüştürülmüş özellikler elde edilir ve son aşamada sınıflandırma süreciyle birleştirilerek kompakt bir yapı sunulur. Son yıllarda derin öğrenme ile metrik öğrenmenin kesişimi, derin metrik öğrenme kavramını ortaya çıkarmıştır [8, 9]. Derin metrik öğrenme, uzaklığa dayalı benzerlik esaslı bir yaklaşımdır. Bu yaklaşımda, aynı sınıfa ait örneklerin yeni temsilini elde etmek, nesnelere arasındaki benzerliği artırmak ve aynı zamanda farklı nesnelere arasındaki benzerliği azaltmak hedeflenmektedir. Literatürde genellikle Siamese [10] ve Triplet [11] ağlarından esinlenilerek metrik esaslı derin öğrenme yapılmaktadır. Bu metrik esaslı derin ağ öğrenme modelleri, örnek verileri paylaşımlı bir ağda ikili ya da üçlü olarak ağ modeline sunulmaktadır. Ağ modelinde bir arada sunulan örneklerin ağırlıkları paylaşarak kullanılır. Bu paylaşılan ağırlıklar, verilerin benzerliğini ya da benzersizliğini optimize etmeyi amaçlar. Kullanılan bu paylaşımlı ağırlıklar ile veriyi daha iyi temsil yeteneğine sahip bir uzaklık metriği öğrenilmesi hedeflenmektedir.

Dijital görüntüleme teknikleri, mikroskopik seviyede patolojik görüntüler elde ederek hastalıklar hakkında daha net bilgiler sağlamayı mümkün kılmaktadır [12]. Bu patolojik veriler, tanı sürecini kolaylaştırmanın yanı sıra elektronik olarak depolanabilir ve yapay zeka yaklaşımlarıyla analiz edilebilir. Histopatolojik görüntülere sahip veri kümeleri genel olarak iki ana problemle karşı karşıyadır. İlk olarak, bu tür veri kümelerinde genellikle sınırlı sayıda örnek bulunmaktadır. İkinci bir problem ise bu veri kümelerinde sağlıklı örneklerin daha yoğun olmasına rağmen, sağlıklı örneklerin daha az olması durumudur. Derin metrik öğrenme, bu tür problemleri çözmek için oldukça başarılı bir yapıya sahiptir. Çünkü derin metrik öğrenme ağ yapısında aynı anda iki ya da daha fazla örnek ağa sunulabilir, bu da ağın başarılı bir şekilde eğitilebilmesi için sınıf içi veya sınıflar arası kombinasyonların daha iyi bir örnekleme yaklaşımı sunmasına olanak tanır. Ayrıca, ağa sunulan örnek eğitim veri kombinasyonlarıyla, ağın sağlıklı ve sağlıklı örneklerinin bir arada değerlendirilmesiyle dengelenmesi mümkündür.

Bu çalışmada, histopatolojik veriler üzerinde derin metrik öğrenme ile sınıflandırma işlemi gerçekleştirilmiştir.

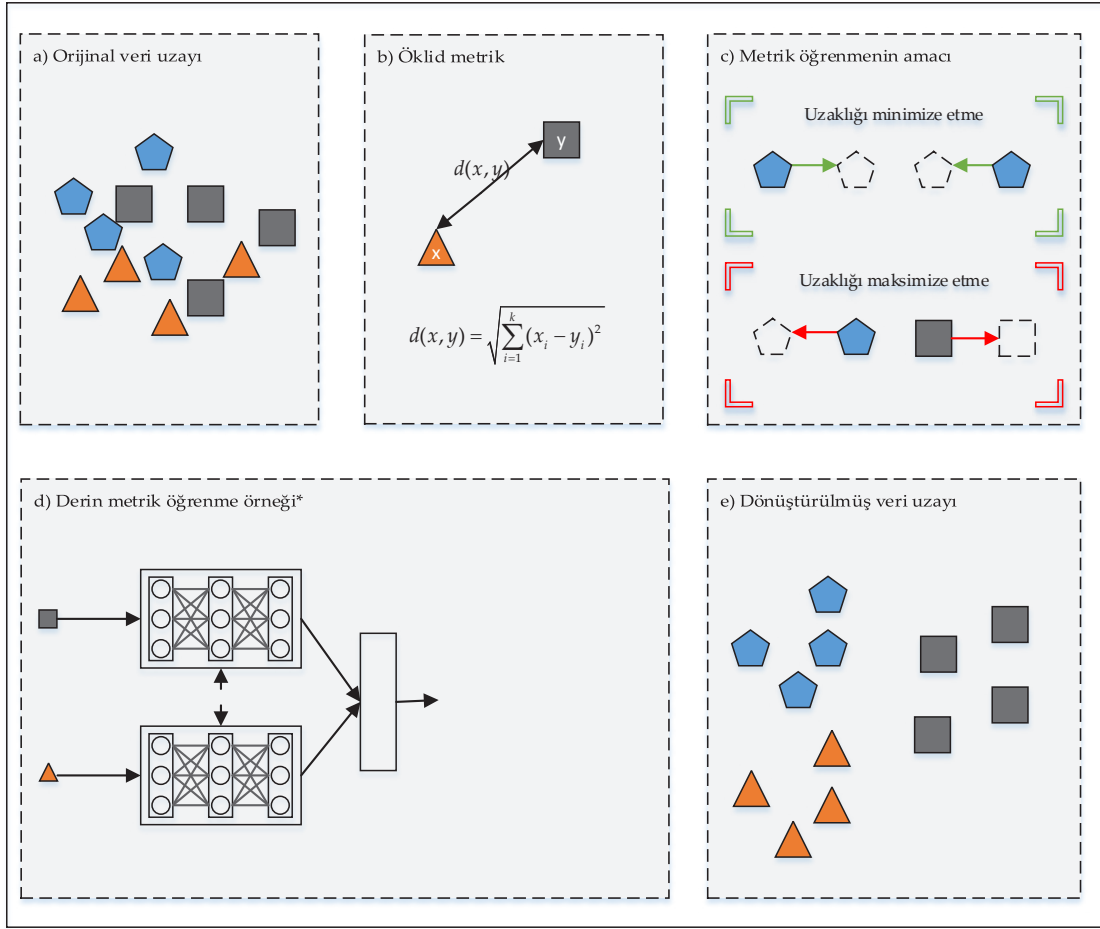
Çalışmanın sonraki bölümünde, derin metrik öğrenme hakkında detaylı bilgiler sunulmuştur. Daha sonra, histopatolojik veri kümesinde derin metrik öğrenme uygulaması açıklanmıştır. Son olarak, yapılan çalışmanın deneysel sonuçlarına yer verilmiştir. Önerilen yöntemde, derin metrik öğrenme yaklaşımları ve transfer öğrenme yaklaşımı bir arada kullanılmıştır. Elde edilen sonuçlara göre derin metrik öğrenmenin histopatolojik veri kümelerinde oldukça başarılı sonuçlar elde ettiği sonucuna varılmıştır.

2. Derin Metrik Öğrenme

Dijital çağın getirdiği kolaylıklar ve avantajlarla birlikte, günümüzde dijital verilerin hacmi ve çeşitliliği önemli ölçüde artmış durumdadır. Bugünün en kıymetli ürünü olarak nitelendirilen verinin işlenmesi, hayatımıza bir dizi yenilik ve pratiklik sağlamaktadır. Yapay zeka algoritmaları için her bir veri büyük anlamlar içermesine rağmen, verilerin işlenmesi ve hesaplama maliyetleri en önemli sorunlardan biridir. Gelişen teknolojiyle birlikte, verileri çok daha hızlı ve küçük parçalara ayrılarak paralel bir şekilde işleme imkanı, sinir ağlarında daha "derin" yapıların oluşturulabilmesine olanak tanımaktadır. İnsan beynindeki sinir hücrelerinin yapısından ilham alan derin öğrenme, derin yapılar veya katmanlar sayesinde veriden öğrenme yeteneğini artırmayı hedeflemektedir [13]. Derin sinir ağları, karmaşık gibi görünen zor problemleri daha iyi anlamlandırabilme kapasitesine sahiptir. Derin öğrenme, doğrudan ham veriden sınıflandırma yapmak yerine, veriyi daha iyi temsil yeteneğine sahip olduğu yüksek soyutlama seviyesine taşıyarak sınıflandırma yapmayı amaçlamaktadır [7].

Derin öğrenmenin popülerliğinin artmasıyla birlikte, benzerlik esasına dayalı metrik öğrenme odaklı derin öğrenme çalışmalarının önemli ölçüde arttığı gözlemlenmektedir [14-16]. Bu tür yaklaşımlar, örnekler arasındaki benzerlik veya benzersizlik ilişkisine dayanarak, örnekler arasındaki uzaklık ilişkisini doğru bir şekilde anlamak için derin bir metrik öğrenmeyi amaçlamaktadır. Bu öğrenme yaklaşımında, bilinen derin öğrenme sinir ağları yapısından farklı olarak, aynı ya da farklı sınıflardan veri örnekleri, aynı anda ağ yapısına giriş örnekleri olarak sunulur. Bu da ağ yapısında aynı kategoride bulunan sınıf örneklerinin birbirine yaklaştırılmasını, farklı kategorilerde bulunan ağ örneklerinin ise öğrenilen metrikle birbirinden uzaklaştırılmasını sağlar [17].

Derin metrik öğrenme çalışma yapısı Şekil 1'de gösterilmiştir. Şekil 1'i incelediğimizde, bu ağ yapısında verilerin yeni bir temsil uzayına yerleştirildiğini görebiliriz. Bu temsil uzayındaki yapı, bir metrik uzaklığından faydalanır. Öğrenilecek olan metrik, benzer örnekler arasındaki uzaklığı minimize etmeye çalışırken, farklı örnekler arasındaki uzaklığı maksimize etmeye çalışır. Şekil 1'de temsili bir ağ yapısı olarak sunulan Siamese ağlarında, ağa aynı anda iki örnek veri girişi sunulur. Bu ikili örnekler, aynı sınıftan veya farklı sınıflardan örnekler olabilir. Her iki ağ örneği için aynı W ağırlık değerleri kullanılır ve öğrenilecek metrik, örnekler arasındaki benzerlik veya benzersizlik ilişkisini kurar. Temsili dönüştürülmüş veri uzayında da görüleceği üzere, oluşturulan yapıyla nesnelere birbirinden mümkün olabildiğince ayrılabilmesi sağlanır.



Şekil 1. Derin metrik öğrenme [8]

Derin metrik öğrenme güncel birçok uygulama alanında elde ettiği başarılarla dikkatleri çekmektedir. Öğrenme yaklaşımında, gerçek hayat problemlerini ele alırken doğrusal olmayan verileri anlama yeteneği ve benzerlik esaslı bir yaklaşım kullanarak; ham veriyi daha soyut veri seviyelerine indirmeyi amaçlamaktadır. Kişiyi yeniden tanımlama görevlerinde [18-20], histopatolojik görüntüleri anlamlandırma [21-23], röntgen görüntülerinden hastalık tanımlama [24-25], imza doğrulamada [26-27], ağ saldırı tespit sistemlerinde [28-29], duygu tanımlama [30], ses sinyallerini işlemede derin metrik öğrenme yaklaşımları oldukça başarılı çözümler sunmaktadır.


3. Materyal ve Yöntem

Günümüzde mikroskopik ortamda incelemeleri gerçekleştirilen patolojik görüntülerle çeşitli hastalıklara ait tıbbi tanımlar konulmaktadır. Tanımlama işlemi öncesinde, mikroskopik bir doku görüntüsünü doğrudan incelemek yerine anlamlı bir görüntü elde etmek amacıyla çeşitli boyama teknikleri kullanılmaktadır. Bu bağlamda, Hematoxylin ve Eosin kimyasallarının birlikte kullanıldığı H & E boyama tekniği, bu amaçla en sık başvurulan yöntemlerden biridir [33].

1. Veri Kümesi

Yapılan çalışmada, Hematoxylin ve Eosin kimyasalları ile boyanmış olan histopatolojik görüntüler veri kümesi

kullanılmaktadır [34]. Veri örnekleri, iki farklı gruptan örnekler içermektedir. İlk grup, sağlıklı örneklerden oluşan görüntülerdir. İkinci grup ise, 100 mg/kg/gün intraperitoneal Alüminyum Klorür (AlCl₃) enjekte edilmiş örneklerden oluşan hasarlı görüntülerdir. Histopatolojik bir görüntüde mavi, beyaz ve pembe bileşenler bulunmaktadır. Mavi bileşenler, görüntüde hücre çekirdeğini temsil etmektedir. Beyaz ve pembe bileşenler ise görüntüdeki diğer doku yapılarına karşılık gelmektedir. Veri kümesinde toplamda 360 hasarlı görüntü ve 779 sağlıklı görüntü örneği bulunmaktadır. Görüntüler, 2560x1920 boyutlarına sahip RGB renk uzayına aittir. Çalışmada kullanılan histopatolojik veri kümesindeki sağlıklı ve hasarlı görüntü örnekleri içeren görseller Şekil 2'de sunulmaktadır.



Şekil 2. Histopatolojik veri kümesinden örnek görüntüler

3.2. Transfer Öğrenme

Transfer öğrenmenin temel motivasyonu, önceden öğrenilmiş bilginin aktarılması ve bu bilgi sayesinde daha etkili ve hızlı bir şekilde sonuca ulaşılmasıdır [35]. Derin sinir ağlarında, transfer öğrenme yöntemleriyle yüksek derecede ayırt edici öznelikler kazanılmaktadır [36]. Bu öğrenme yaklaşımında daha önce başarıyla uygulanan öğrenme sürecinin, farklı bir alandaki probleme başarılı bir şekilde uygulanarak bilginin aktarılması süreci önem arz etmektedir. Bu alandaki çalışmalarda, kullanılan sinir ağı modelinin uygulanabilirliği, modelin daha önce benzer ağlarda elde ettiği öğrenme yeteneğine dayanmaktadır. Zira transfer öğrenme uygulamalarında kullanılan sinir ağı modelleri, çok sayıda kategoriye sahip milyonlarca görüntüden oluşan, nitelik ve nicelik bakımından zengin veri kümelerine başarılı bir şekilde uygulanmaktadır.

Özellikle öğrenme verisinin az olduğu durumlarda, transfer öğrenme önemli bir araç haline gelmektedir. Literatürde başarıyla test edilmiş birçok sinir ağı modeli bulunmaktadır. Bu sinir ağı modelleri, geniş bir kategori yelpazesi ve yeterli sayıda örnek içeren veri kümelerinde güvenilir transfer öğrenme stratejileri olarak öne çıkmaktadırlar. AlexNet [37], VGG16 [38], VGG19 [38], ResNet [39], DenseNet [40] ve MobileNet [41] gibi sinir ağı modelleri literatürde transfer öğrenme amacıyla sıkça kullanılmaktadır.

3.3. Histopatolojik Görüntülerde Derin Metrik Öğrenme ile Sınıflandırma

Bu çalışmada, histopatolojik görüntülerde sağlıklı ve sağlıklı olmayan örnekleri ayırt etmek amacıyla derin metrik öğrenme yöntemleri kullanılmıştır. Siamese ve Triplet ağları, histopatolojik görüntüleri sınıflandırma amacıyla kullanılarak; benzer nesnelere birbirine yaklaştırma ve farklı nesnelere birbirinden uzaklaştırma hedeflenmiştir. Bu ağ modelleri, örnekler arasındaki benzerlik ilişkisini analiz etmek üzere

tasarlanmıştır. İki örnek arasındaki benzerlik durumuna bağlı olarak sinir ağına eğitim işlemi gerçekleştirilmektedir. X_1 ve X_2 olarak sinir ağına sunulacak iki tane örnek olduğu kabul edelim. Bu örnekler arasındaki uzaklık hesabı Denklem 1'de verilmektedir:

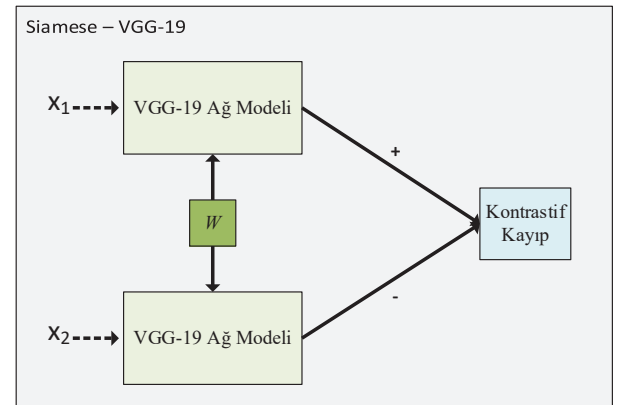
$$D_W(X_1, X_2) = \|G_W(X_1) - G_W(X_2)\|_2 \quad (1)$$

Burada $G_W(X_1)$ ve $G_W(X_2)$, X_1 ve X_2 örneklerinin temsili dönüşüm uzayındaki yeni gösterimlerini ifade etmektedir. D_W ise, temsili dönüşüm uzayındaki örnekler arasındaki uzaklığı hesaplayan bir fonksiyondur. Denklem 1'de D_W benzer örnekler arasındaki uzaklığı azaltmayı, farklı örnekler arasındaki uzaklığı ise arttırmayı amaçlamak için kullanılmaktadır. Bu denklemi kullanarak bir uzaklık değeri hesaplanır. Daha sonra, Siamese derin sinir ağı modelindeki kayıp fonksiyonuna ($L_{Contrastive}$) ait hesaplama Denklem 2'de sunulmaktadır:


$$L_c = (1 - Y) \frac{1}{2} (D_W)^2 + (Y) \frac{1}{2} \{\max(0, m - D_W)\} \quad (2)$$

Denklemden kullanılan Y sembolü kategori etiketlerini temsil etmektedir. $L_{Contrastive}$ 'deki m değeri ön tanımlı bir marjın değeridir. Triplet sinir ağı modelleri, Siamese ağ modelinden farklı olarak üç giriş örneği içerir. Çapa örneği X , çapayla aynı sınıfa ait örnek içeren X^p ve çapadan farklı sınıfa ait örnek içeren X^n örneğidir. Denklem 3'te verilen Triplet kayıp fonksiyonuna ($L_{Triplet}$) ait hesaplama Denklem 3'te şu şekilde hesaplanmaktadır:

$$L_{Triplet} = \max(0, \|G_W(X) - G_W(X^p)\|_2 - \|G_W(X) - G_W(X^n)\|_2 + \alpha) \quad (3)$$



Şekil 3. Siamese-VGG19 ağ modeli



Şekil 4. Triplet-VGG19 ağ modeli

Klasik evrişimli sinir ağında her bir örnek, evrişim, örnekleme, tam bağlı katman süreçlerinden geçerek bir sınıflandırma işlemine tabi tutulur. Ancak, derin metrik öğrenme süreci biraz daha farklıdır. Örnekler, sinir ağına paylaşımlı ağırlıklar kullanılarak birden fazla örnek içerecek şekilde bir arada paralel olarak sunulur. Bu sinir ağı yapısı içinde evrişim, örnekleme ve tam bağlı katman gibi özel katmanlar yer almakla birlikte aynı ağ yapısı paralel olarak yer alabilmektedir. Katmanlarda gerçekleştirilen işlemlerin ardından, odaklanılan şey iki örnek arasındaki benzerlik ilişkisidir. Bu benzerlik ilişkisi için kayıp metrik fonksiyonları kullanılarak işlem gerçekleştirilir. Şekil 3'te bu çalışmada önerilen Siamese – VGG19 ağ modeli görülmektedir. Bu derin sinir ağı modelinde X_1 ve X_2 olarak histopatolojik görüntüler ağa sunulmakta ve ağa sunulan görüntüler aynı sınıfa ait ise görüntüler birbirine yaklaştırılmakta, farklı sınıfa ait görüntüler ise örnekler birbirinden uzaklaştırılmaktadır. Böylece daha iyi bir temsil elde edilmesi amaçlanmaktadır. Şekil 4'te görülen Triplet ağında ise Pozitif ve Çapa aynı sınıfa ait örnekler iken, Negatif ise farklı sınıfa ait bir örnek görüntüyü temsil etmektedir. Burada amaç Pozitif ile Çapa örneklerini birbirine yaklaştırmak olup, Negatif örnek görüntü ise bu örneklerden uzaklaştırılmaktadır.

4. Deneysel Sonuçlar

Çalışmada kullanılan histopatolojik veri kümesinde 911 görüntü eğitim örneği olarak ve 228 görüntü ise test örneği olmak üzere başlangıçta rasgele olarak ayrılmıştır. Eğitim veri kümesindeki örneklerin 623 tanesi sağlıklı görüntüler olup, 288 tanesi ise hasarlı görüntülerden oluşmaktadır. Test örneklerinin ise, 156'sı sağlıklı ve 72'si hasarlı görüntülerden oluşmaktadır.

Siamese ağ modelinde veriler, iki farklı görüntünün aynı ağa sunulması şeklinde olmaktadır. Deneysel çalışmada ağ modeli, eğitim süreci öncesinde ikili görüntüler oluşturarak


sınıfta dengeli bir dağılımı sağlamak için tasarlanmıştır. Bu ikili görüntüler, minimum ikili maksimum fayda prensibi kullanılarak 911 eğitim görüntüsü kullanılarak toplamda 1148 tane ikili görüntü örnekleri oluşturulmuştur. Oluşturulan görüntüler hem aynı sınıfların birbiriyle hem de farklı sınıfların birbiriyle bulunması şeklinde dengeli bir şekilde eşleştirilmiştir. Ağa en az bir kez sunulan ikililer, tüm eğitim örneklerini içermektedir. Ağın performansını değerlendirmek için yapılan çalışmalarda sunulacak görüntüler rasgele seçilmiştir. Bununla birlikte, ağ modelinde her bir aşamada kullanılacak olan ikili görüntülerin dengeli bir şekilde yer alması amaçlanmıştır. Bu amaçla, ağda her sınıf için hem kendi sınıfından hem de diğer sınıftan görüntüler yer alması hedeflenmiştir.

Eğitim aşamasında ikili görüntülerde, aynı sınıftan örnekler birbirine yaklaştırılırken, farklı sınıftan örnekler birbirinden uzaklaştırılma ilkesiyle hareket edilmektedir. Test işleminde farklı bir bakış açısı kullanılırken, eğitim örneklerinin başarısı buna odaklanır. Bu durumda, sorunu bir sınıflandırma sorunu olarak ele almak istediğimizde, her bir test örneği bir eğitim örneği ile karşılaştırılır. Test örneğini X_1 veya X_2 'ye yerleştirmek önemli değildir. Çünkü eğitilmiş ağ modeli üzerinde veriler test edilirken iki örneğin benzerlik veya benzersizlik durumuna odaklanılmaktadır. Bu sebeple ortada bir benzerlik varsa veriler aynı sınıfla etiketlenirken; benzersizlik varsa farklı sınıfla etiketlenmektedir. Bu sebeple giriş verilerinin hangisine yerleştirildiğinin bir önemi yoktur. Çift taraflı test aşamasında da aynı ağırlıklar kullanılmaktadır. Deneylerde 228 test görüntüsünün her biri en az bir kez eğitim görüntüleriyle eşleştirilmektedir. Deneylerin test aşamasında 228 test görüntüsünden 4560 ikili test görüntüsü oluşturulmuştur. Bu kapsamda önerilen yöntemin başarısını test etmek için 4560 ikili görüntünün sınıflandırma performansı incelenmiştir.

Yapılan deneyler sonucunda Siamese ağ modeline ait eğitim aşamaları sonucu Şekil 5'te görülmektedir. Şekil 5'te görüldüğü üzere süreç içerisinde ağa ikili görüntülerin sunulmasıyla eğitim modelinin nasıl bir başarı elde ettiği görülmektedir. Her bir aşamada yeni dönüşüm uzayında veriler daha iyi temsil edilirken, veri öğelerinin birbirinden ayrışması net bir şekilde görülmektedir. Ağ modelini eğitmede Siamese ağ modelinde VGG19 transfer öğrenme yaklaşımının yanında ResNet50 modeli de denenmiştir. Tablo 1'de görüldüğü üzere Siamese+VGG19 ağ modeli ile test verilerini tahmin etmede %95,39 başarı elde edilmiştir.

Tablo 1. Siamese derin metrik ağ modelinin test başarısı

Ağ Modeli	Doğruluk
Siamese – VGG19	0,9539
Siamese – ResNet50	0,8541



Şekil 5. Siamese derin metrik ağ modelinin eğitim aşaması sonuçları

Triplet eğitim örnekleri, her bir örneğin en az bir kez kullanılması koşuluyla 911 eğitim görüntü verisi kullanarak toplamda 2000 farklı üçlü görüntü örneği oluşturulmuştur. Burada 2000 farklı üçlü görüntü oluşturulurken rasgele olarak pozitif ve çapa örneği aynı sınıfa ait örnek görüntüler olurken, negatif ise diğer sınıfa ait görüntü örneğidir. Yapılan deneylerde yeterli başarıya 2000 farklı kombinasyonla ulaşıldığı için bu sebeple derin sinir ağının eğitim sürecinde bu kadar üçlü kombinasyon yeterli bulunmuştur. Bu üçlü görüntülerde, aynı sınıftan örnekler birbirine yakınlaştırılırken, farklı sınıftan örnekler birbirinden uzaklaştırılır. Bu kapsamda çapa ile aynı sınıftan olan pozitif örnekler birbirine

yaklaştırılırken; çapa ile farklı sınıftan olan negatif örnek ise bu iki örnekten (pozitif ve çapa) uzaklaştırılmaktadır. Eğitim örneklerinin başarısını belirlemede bu duruma odaklanılırken, test başarısını belirlemede farklı bir yaklaşım kullanılmaktadır. Bu durumda, sorunu bir sınıflandırma sorunu olarak ele almak istediğimizde, her bir test örneği bir çapa örneğine eşittir. Test sürecinde 228 test örneğinin her biri çapaya yerleştirilmiş ve pozitif ve negatif örnekler ise eğitim kümesindeki örneklerden alınmıştır. Test örneğinden bağımsız olarak pozitif ve negatif örnekler farklı sınıflardan birer örnektir. Böylece çapaya yerleştirilen test örneği hangi sınıftan (pozitif veya negatif) bir örneğe yakınsa o örneğe olan benzerliğinden dolayı aynı sınıfta


olarak tahmin edilmiştir. Testin sınıflandırma doğruluğu ise test verisinin gerçek kategorisiyle karşılaştırılması sonucunda elde edilmektedir.

Triplet ağ modeline ait eğitim aşamaları adım adım Şekil 6'da sunulmuştur. Ağ modeline üçlü görüntülerin sunulmasıyla eğitim modelinin nasıl bir başarı elde ettiği Şekil 6'da görülmektedir. Başlangıç aşamasında ham verilerin birbirinden ayıramadığı görülürken, dönüşüm uzayına taşınma ile veri örneklerinin daha iyi bir temsil yeteneğine ulaştığı görülmektedir. Eğitim örnekleri arasında ayrışma çok iyi olup son aşamada bu durum gözlemlenebilmektedir. Ağ modelini eğitmek için Triplet ağ modelinde VGG19 transfer öğrenme

yaklaşımının yanında ResNet50 modeli de test edilmiştir. Tablo 2'de görüldüğü üzere Triplet+VGG19 ağ modeli ile test verilerini tahmin etmede %96,92 sınıflandırma başarısı elde edilmiştir.

Tablo 2. Triplet derin metrik ağ modelinin test başarısı

Ağ Modeli	Doğruluk
Triplet – VGG19	0,9692
Triplet – ResNet50	0,9429



Şekil 6. Triplet derin metrik ağ modelinin eğitim aşaması sonuçları

5. Sonuç

Uzaklık metriğine dayalı öğrenme örüntüler arasındaki benzerlik bilgisini ele almada önemli bilgi sunmaktadır. Bu çalışmada aynı sınıftan örnekler arasındaki benzerliği maksimize etme (uzaklığı azaltma), farklı sınıflar arasındaki benzerliği minimize etme (uzaklığı artırma) için derin metrik öğrenme yaklaşımından yararlanılmıştır. Derin metrik öğrenme yaklaşımında birden fazla örnek ağı aynı anda sunulurken örneklerin birbirine benzerliği incelenmektedir.

Bu çalışmada benzerlik öğrenme amacıyla Siamese ve Triplet ağ modelleri temel alınmıştır. Ayrıca ağ modellerindeki başarıyı maksimize etmede sıradan bir model yerine literatürde başarısını kanıtlamış olan transfer öğrenme yaklaşımlarından yararlanılmıştır. Yapılan çalışma sonucunda histopatolojik görüntülerde derin metrik öğrenme amacıyla Siamese+VGG19, Siamese – ResNet50, Triplet – VGG19 ve Triplet – ResNet50 modelleri kullanılmıştır. Eğitim süreçlerinde çok iyi bir öğrenme gerçekleştirilmiştir. Siamese ağ modelinde VGG19 kullanımı ile %95,39 sınıflandırma test başarısı elde edilirken, Triplet ağ modelinde VGG19 kullanımı ile %96,92 sınıflandırma test başarısı elde edilmiştir.

Triplet ağ modelinde başarının daha yüksek olmasında ağın eğitim modelinin etkisi önemlidir. Triplet ağında Siamese ağından farklı olarak aynı anda üç giriş verisi ağı sunulmaktadır. Ağın eğitim sürecinde birinci sınıfa ait örnek, ikinci sınıfa ait örnek ve çapa örneği sunulan örneklerdir. Çapa örneğinin sınıfına bakılarak aynı anda hem benzerlik hem benzersizlik ilişkisinin bir arada öğrenilmesi özelliği ile daha kararlı ve sağlam bir metrik öğrenimi sağlanmaktadır.

Klasik derin öğrenme yaklaşımlarında eğitim sürecinde giriş verileri birer birer ağı sunulmaktadır. Derin metrik öğrenmenin paylaşımlı ağırlıklı yapısında çok sayıda ikili ya da üçlü görüntü örneği ağı sunulurken ağın öğrenme yeteneği de artırılmaktadır. Veri örnekleri az olsa bile oluşturulacak ikili üçlü örnek kombinasyonlarıyla daha fazla ve farklı veri ikili veya üçlüleriyle öğrenme gerçekleştirilmektedir. Böylece daha iyi temsile sahip özneliklerin elde edilebilmesi mümkün olabilmektedir. Bu durum ağın öğrenme performansını yükseltmede önemli bir etken olmuştur.

Teşekkür

Bu makale çalışması Prof. Dr. Hasan Şakir BİLGE danışmanlığında Mahmut KAYA'nın "Derin Metrik Öğrenme ile Histopatolojik Görüntülerin Sınıflandırılması" isimli doktora tezi kapsamında gerçekleştirilmiştir. Ayrıca yazarlar Prof. Dr. Mehmet GÜL'e destekleri için teşekkür etmektedir.

Çıkar Çatışması

Yazarlar bu makaleyle ilgili herhangi bir çıkar çatışması olmadığını bildirir.

Araştırma ve Yayın Etiği Beyanı

Yazarlar bu çalışmanın araştırma ve yayın etiğine uygun olduğunu beyan eder.

Kaynaklar

- [1] T. M. Mitchell, "Machine learning and data mining". Communications of the ACM, 42(11), 30-36, 1999.
- [2] A. Géron, Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow, O'Reilly Media, Inc., 205, 2022.

[3] A. Globerson ve S. Roweis. "Metric learning by collapsing classes", Advances in neural information processing systems, 1-8, 2005.

[4] F. Wang ve J. Sun, "Survey on distance metric learning and dimensionality reduction in data mining", Data mining and knowledge discovery, 29(2), 534-564, 2015.

[5] K. Q. Weinberger ve L. K. Saul, "Distance metric learning for large margin nearest neighbor classification", Journal of machine learning research, 10, 207-244, 2009.

[6] J. Schmidhuber, "Deep learning in neural networks: An overview", Neural networks, 61, 85-117, 2015.

[7] Y. LeCun, Y. Bengio ve G. Hinton, "Deep learning", Nature, 521(7553), 436-444, 2015.

[8] M. Kaya, ve H. Ş. Bilge, "Deep metric learning: A survey", Symmetry, 11(9), 1066, 2019.

[9] J. Lu, J. Hu ve J. Zhou, "Deep metric learning for visual understanding: An overview of recent advances". IEEE Signal Processing Magazine, 34(6), 76-84, 2017.

[10] R. Hadsell, S. Chopra ve Y. LeCun, "Dimensionality reduction by learning an invariant mapping", IEEE computer society conference on computer vision and pattern recognition, 1735-1742, 2006.

[11] E. Hoffer ve N. Ailon, "Deep metric learning using triplet network", Similarity-Based Pattern Recognition: Third International Workshop, 84-92, 2015.

[12] M. Peikari, M. J. Gangeh, J. Zubovits, G. Clarke ve A. L. Martel, "Triaging Diagnostically Relevant Regions from Pathology Whole Slides of Breast Cancer: A Texture Based Approach," IEEE Transactions on Medical Imaging, 35(1), 307-315, 2016.

[13] I. Goodfellow, Y. Bengio ve A. Courville, Deep learning. MIT press, 2016.

[14] Y. Duan, J. Lu, J. Feng, ve J. Zhou, "Deep localized metric learning", IEEE Transactions on Circuits and Systems for Video Technology, 28(10), 2644-2656, 2017.

[15] G. Dai, J. Xie ve Y. Fang, "Deep correlated holistic metric learning for sketch-based 3D shape retrieval", IEEE Transactions on Image Processing, 27(7), 3374-3386, 2018.

[16] B. Harwood, V. Kumar BG, G. Carneiro, I. Reid, ve T. Drummond, "Smart mining for deep metric learning", In Proceedings of the IEEE international conference on computer vision, 2821-2829, 2017.

[17] E. Hoffer, ve N. Ailon, "Semi-supervised deep learning by metric embedding", arXiv preprint arXiv:1611.01449, 2016.

- [18] S. Liao ve L. Shao, "Graph sampling based deep metric learning for generalizable person re-identification", *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 7359-7368, 2022.
- [19] K. A. Duncanson, S. Thwaites, D. Booth, G. Hanly, W. S. Robertson, E. Abbasnejad, ve D. Thewlis, "Deep metric learning for scalable gait-based person re-identification using force platform data", *Sensors*, 23(7), 3392, 2023.
- [20] S. S. Faghih Imani, K. Fouladi-Ghaleh, ve H. Aghababa, "Generalizable and efficient cross-domain person re-identification model using deep metric learning", *IET Computer Vision*, 17(8), 993-1004, 2023.
- [21] S. M. Alizadeh, M. S. Helfroush, ve H. Müller, "A novel Siamese deep hashing model for histopathology image retrieval", *Expert Systems with Applications*, 225, 120169, 2023.
- [22] X. Li, B. Yang, T. Chen, Z. Gao, ve H. Li, "Multiple instance learning-based two-stage metric learning network for whole slide image classification", *The Visual Computer*, 1-16, 2023.
- [23] N. Hashimoto, Y. Takagi, H. Masuda, H. Miyoshi, K. Kohno, M. Nagaishi, ... & I. Takeuchi, 2023, "Case-based similar image retrieval for weakly annotated large histopathological images of malignant lymphoma using deep metric learning", *Medical image analysis*, 85, 102752, 2023.
- [24] Y. Jin, H. Lu, Z. Li, ve Y. Wang, "A cross-modal deep metric learning model for disease diagnosis based on chest x-ray images", *Multimedia Tools and Applications*, 82(21), 33421-33442, 2023.
- [25] A. Zhong, X. Li, D. Wu, H. Ren, K. Kim, Y. Kim, ... ve Q. Li, "Deep metric learning-based image retrieval system for chest radiograph and its clinical applications in COVID-19", *Medical Image Analysis*, 70, 101993, 2021.
- [26] L. Liu, L. Huang, F. Yin ve Y. Chen, "Offline signature verification using a region based deep metric learning network", *Pattern Recognition*, 118, 108009, 2021.
- [27] T. B. Viana, V. L. Souza, A. L. Oliveira, R. M. Cruz ve R. Sabourin, "A multi-task approach for contrastive learning of handwritten signature feature representations", *Expert Systems with Applications*, 217, 119589, 2023.
- [28] G. Andresini, A. Appice ve D. Malerba, "Autoencoder-based deep metric learning for network intrusion detection", *Information Sciences*, 569, 706-727, 2021.
- [29] Z. Wang, Z. Li, D. He ve S. Chan, "A lightweight approach for network intrusion detection in industrial cyber-physical systems based on knowledge distillation and deep metric learning", *Expert Systems with Applications*, 206, 117671, 2022.
- [30] B. Mocanu, R. Tapu ve T. Zaharia, "Multimodal emotion recognition using cross modal audio-video fusion with attention and deep metric learning", *Image and Vision Computing*, 133, 104676, 2023.
- [31] X. Chen, L. He, C. Xu, ve J. Liu, "Distance-dependent metric learning". *IEEE Signal Processing Letters*, 26(2), 357-361, 2019.
- [32] V. S. Narayanaswamy, J. J. Thiagarajan, H. Song ve A. Spanias, "Designing an effective metric learning pipeline for speaker diarization", *IEEE International Conference on Acoustics, Speech and Signal Processing*, 5806-5810, 2019.
- [33] M. Titford, *The long history of hematoxylin. Biotechnic & histochemistry*, 80(2), 73-78, 2005.
- [34] F. Serin, M. Erturkler, ve M. Gul, "A novel overlapped nuclei splitting algorithm for histopathological images", *Computer methods and programs in biomedicine*, 151, 57-70, 2017.
- [35] S. J. Pan, ve Q. Yang, "A survey on transfer learning", *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359, 2009.
- [36] J. Lu, V. Behbood, P. Hao, H. Zuo, S. Xue, ve G. Zhang, "Transfer learning using computational intelligence: A survey", *Knowledge-Based Systems*, 80, 14-23, 2015.
- [37] A. Krizhevsky, I. Sutskever ve G. Hinton, "Imagenet classification with deep convolutional neural networks", *Advances in neural information processing systems*, 25, 2010.
- [38] K. Simonyan ve A. Zisserman, "Very deep convolutional networks for large-scale image recognition", *arXiv preprint arXiv:1409.1556*, 2014.
- [39] K. He, X. Zhang, S. Ren ve J. Sun, "Deep residual learning for image recognition", *IEEE conference on computer vision and pattern recognition*, 770-778, 2016.
- [40] G. Huang, Z. Liu, L. Van Der Maaten ve K. Q. Weinberger, "Densely connected convolutional networks", *IEEE conference on computer vision and pattern recognition*, 4700-4708, 2017.
- [41] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, ... ve H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications", *arXiv preprint arXiv:1704.04861*, 2017.

Özgeçmişler



Dr. Mahmut Kaya, Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü lisans programını 2010 yılında tamamladı. Yüksek lisans ve Doktora Programlarını Gazi Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında 2014 ve 2019 yıllarında tamamlamıştır. Lisansüstü çalışmaları esnasında 2012-2019 yılları arasında Gazi Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde Araştırma Görevlisi olarak çalışmıştır. 2020-2024 yılları arasında Siirt Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde Dr. Öğr. Üyesi olarak çalışmıştır. 2024 yılından itibaren Fırat Üniversitesi Mühendislik Fakültesi Yapay Zekâ ve Veri Mühendisliği Bölümünde Dr. Öğr. Üyesi olarak çalışmaktadır. Bilimsel araştırma alanları arasında örüntü tanıma, makine öğrenmesi ve derin öğrenme yer almaktadır.



Prof. Dr. Hasan Şakir Bilge, Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü lisans programından 1992 yılında mezun oldu. Yüksek lisans programını Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında 1997 yılında tamamladı. Doktora programını Başkent Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında 2003 yılında tamamladı. 2003-2012 yılları arasında Gazi Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde yardımcı doçent kadrosunda çalıştı. 2012 yılında Elektrik Elektronik Mühendisliği alanında doçentlik unvanını aldı. 2012-2015 yılları arasında Bilgisayar Mühendisliği Bölümünde ve 2015-2020 yılları arasında Elektrik Elektronik Mühendisliği Bölümünde doçent olarak çalıştı. 2020 yılından itibaren Gazi Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümünde profesör olarak çalışmaktadır. FPGA programlama ve doğrulama, görüntü işleme, ultrason görüntüleme, örüntü tanıma, derin öğrenme gibi konularda bilimsel çalışmalar yapmaktadır.

Akciğer Kanseri Tespitinde Dönüşüm ve Evrişim Tabanlı Modeller ile Açıklanabilir Yapay Zeka Uygulaması

Explainable Artificial Intelligence Application for Lung Cancer Detection with Transformer and Convolution Based Models



Delal Şeker¹,



Mustafa Said Kartal²,



Abdulnasır Yıldız³, İlkay Öksüz⁴

¹Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye, delalkabak93@gmail.com

²Tip Fakültesi, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye, md.mustafasaidkartal@gmail.com

³Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye, abnayil@dicle.edu.tr

⁴Istanbul Technical University, İstanbul, Türkiye

Faculty Of Computer And Informatics Engineering, Department Of Computer Engineering
oksuzilkay@itu.edu.tr

Özetçe— Günümüzde dijital patoloji, tümörlerin teşhisi ve tahminleme konusunda önemli bir rol oynamaktadır. Derin Öğrenme (DÖ) yöntemlerinin geniş ölçekli uygulamalarla başa çıkma yeteneği göz önüne alındığında, bu tür modeller, histopatolojik görüntülerde doku sınıflandırma için cazip bir çözüm olarak kullanılmaktadır. Bu çalışma, histopatolojik görüntülerden akciğer kanserinin otomatik sınıflandırması için doğru ve yorumlanabilir bir makine öğrenimi tekniği oluşturmayı amaçlamaktadır. Mevcut yöntemde Evrişimsel Sinir Ağları (ESA), Vision Transformer (ViT) ve EfficientNet-B1 mimarisi karşılaştırılarak LIME (Local Interpretable Model-agnostic Explanations) açıklanabilirlik metoduyla patoloji görüntüleri üzerinde kanser tespit sistemi önerilmiştir. ViT ve EfficientNet-B1 mimarisinin evrişim tabanlı ESA mimarisine göre f1-skoru, hassasiyet ve duyarlılık oranının daha başarılı sonuçlar verdiği gözlemlenmiştir. En yüksek başarımların ViT mimarisi ile yaklaşımlı olup en ayrıntılı LIME sonuçlarına ise EfficientNet-B1 mimarisi ile ulaşılmıştır.

Anahtar Kelimeler — Evrişimsel Sinir Ağları, EfficientNet-B1, Vision Transformer, Histopatoloji, Açıklanabilir Yapay Zeka

Abstract— In today's context, digital pathology plays a significant role in the diagnosis and prediction of tumors. Given the capability of Deep Learning (DL) methods to handle large-scale applications, such models are being increasingly employed as an attractive solution for tissue classification in histopathological images. This study aims to establish an accurate and interpretable machine learning technique for the automatic classification of lung cancer from histopathological images. In the current approach, a cancer detection system on pathology images is proposed by comparing Convolutional Neural Networks (CNNs), Vision Transformer (ViT), and EfficientNet-B1 architectures, utilizing the Local Interpretable Model-agnostic Explanations (LIME) interpretability method. It has been observed that the ViT and EfficientNet-B1 architectures outperform the convolution-based CNN architecture in terms of f1-score, precision, and recall rates. The ViT architecture approaches the highest performance rate, while the most detailed LIME results are achieved with the EfficientNet-B1 architecture.

Keywords — Convolution Neural Network, EfficientNet-B1, Vision Transformer, Histopathology, Explainable Artificial Intelligence

GİRİŞ

Akciğer kanseri dünya genelinde geniş bir kesimi ilgilendiren sağlık sorunlarının başında gelir. Ölüm oranı yüksek ve kritik bir sağlık sorunudur. Akciğer kanseri hastalığına başlıca yakalanma sebebi sigara ve alkol tüketimidir. Bunun yanı sıra coğrafi bölgelere, yaş gruplarına, kalıtsal özelliklere ve diğer değişkenlere bağlı olarak farklılık gösterebilmektedir [1]. Kanser belirtileri arasında bitkinlik, mide bulantısı, kronik öksürük, nefes darlığı, kilo kaybı, kas ağrıları, kanama ve morluklar yer almaktadır. Fakat her kanser hastasında bu gibi durumlar görülmemektedir. Çoğu zaman akciğer kanser tanısı Pozitron Emisyon Tomografi (PET), Manyetik Rezonans (MR) veya Bilgisayarlı Tomografi (BT) ile görüntülenip ardından kesin tanı için patolojik teşhise ihtiyaç vardır [2]. Genel olarak, akciğer kanseri erkeklerde daha yaygın görülürken, kadımlar arasında da son yıllarda artış gözlemlenmektedir [3]. 2020 WHO raporlarına göre dünya genelinde akciğer kanseri vakaları 2.21 milyon iken ölü sayısı 1.8 milyonu aşmaktadır [4].

Sistematik ve standartlaştırılmış tanı yöntemlerinin eksikliği, erken evre kanserlerin (1. veya 2. evre) ve belirsiz tümörlerin teşhisini zorlaştırmaktadır. Bu durumda, klinisyenler genellikle klinik tanı için dokulardan girişimsel biyopsi yöntemiyle örnekler alma yoluna başvurmurlar. Patolojik doku örneklerinin histolojik veya hücresel seviyede nihai tümör türü ve evresi belirlenebilmektedir [5]. Gelişen teknoloji ve yapay zeka modelleri sonucu komplikasyona sebep olan girişimsel yöntemlerin seyreltilmesi amaçlanmaktadır [6].

Günümüzde bilgisayar tabanlı görüntü işleme teknikleri, patolojik görüntülerin analizini otomatikleştirmektedir. Bu sayede süreci hızlandırmakla birlikte yüksek teşhis oranları elde edilmektedir [7]. Bu teknikler arasında görüntü bölütlemesi, özellik çıkarma ve sınıflandırma gibi yöntemler bulunmaktadır. Gelişmiş bilgisayar algoritmaları ve yapay zeka mimarileri, patoloji uzmanlarının hastalıkları daha iyi tanımlamasına ve tedavi planlarını belirlemesine yardımcı olabilmektedir.

Bu çalışmada, akciğer histopatoloji görüntülerine baz model olarak Evrişimsel Sinir Ağları (ESA), dönüşüm tabanlı Vision

nimarileri uygulanmıştır. Derin Öğrenme (DÖ) modellerinin uygulanmasıyla elde edilen kestirim sonuçları karşılaştırılmıştır. Ardından tüm modellere ait sonuçlar çıkarılabilir yapay zeka yöntemi olan LIME (Local Interpretable Model-agnostic Explanations) ile ilişkilendirilmiştir. LIME uygulaması sonucu elde edilen görüntülerin ilgili bölgeleri çalışmada gösterilmiştir.

Mevcut Çalışmalar

Histopatolojik doku örneklerinin analizi ve sınıflandırılmasında farklı yaklaşımlar göze çarpmaktadır. Literatür incelendiğinde bu çalışmaların ağırlıklı olarak dönüşüm ve evrişim tabanlı olduğu gözlemlenmektedir. Aitazaz ve ekibi (2023), akciğer görüntülerini teşhis etmede ViT ve önceden eğitilmiş ESA mimarilerinin etkinliğini karşılaştırılmıştır. Deneyin sonuçları, ViT mimarisinin önceden eğitilmiş ESA mimarilerini performans bakımından aştığını göstermiştir. Ayrıca, daha fazla katmana sahip olan ViT-L32'nin ViT-B32'ye nazaran daha doğru sonuçlar ürettiği bulunmuştur [8]. Ali ve Ali (2021), geleneksel katmanlar, ayrılabilir evrişim katmanları ve kapsül geçiren çok girişli bir hibrit model oluşturmuşlardır. Bu model akciğer kanserini sınıflandırmak için kullanılmışlardır. Ön işleme aşamasında, gama düzeltme, renk dengeleme, görüntü keskinleştirme ve çok ölçekli birleştirme uygulanmıştır. Önerilen model iki giriş alır: i) standart evrişim katmanları aracılığıyla birinci giriş bloğundan ham görüntüler ve ii) ayrılabilir evrişim katmanları kullanılarak ikinci giriş bloğundan işlenmiş görüntülerin her ikisi de sınıflandırma için bir kapsül ağına bağlıdır. Deneysel analiz, önerilen modelin tüm sınıflarda dikkate değer bir başarı elde ettiğini ve akciğer kanseri için genel doğruluğun %99.58 olduğunu göstermişlerdir [9]. Kumar ve ark. (2022), akciğer histopatoloji görüntülerini sınıflandırmak için elle çıkarılan (hand-crafted) özelliklerin performansını derin özelliklerle karşılaştırmışlardır. Elde edilen özellikler dört makine öğrenimi algoritmasına uygulanmıştır: Gradient Boosting (GB), Çok Katmanlı Algılayıcı (ÇKA), Rastgele Orman (RO) ve Radyal Fonksiyon tabanlı Destek Vektör Makinası (DVM-RBF). Analiz sonrasında, derin özelliklere sahip sınıflandırıcıların manuel özellikleri aştığını gözlemlenmişlerdir [10]. Ibrahim ve Alaattin (2022), özellik çıkarmak için EfficientNet-B7 kullanarak akciğer kanseri için çoklu sınıflandırma yapmak amacıyla Modifiye Edilmiş Sinir Ağları (MNNs) kullanarak DÖ tabanlı bir sistem önermişlerdir. Sonuçlara göre, bu sistem ile %99.5 doğruluk elde etmişlerdir [11]. Fan vd. (2021), akciğer kategorizasyonu için softmax ve DVM tabanlı bir transfer öğrenme mimarisi önermişlerdir. Sınıflandırma doğruluğunu artırmak için softmax sınıflandırıcısının tam bağlı katmanı, DVM sınıflandırıcısına bağlanmıştır. Önerilen modelin LC25000 veri kümesi için %99.4 doğruluğa sahip olduğunu göstermişlerdir [12]. Mehmood ve ekibi (2022), akciğer kanseri histopatolojik görüntülerinin otomatik olarak teşhisi için etkili bir transfer öğrenme stratejisi önermişlerdir. Bu yaklaşımda, hesaplama maliyetini azaltmak ve doğruluğu artırmak amacıyla kontrast artırma yöntemi tüm görüntülere değil, sadece performansı düşük olan sınıfa uygulanmıştır (%89'dan %98.4'e kadar artış). Talukder ve ark. (2022), akciğer kanserini tespit

için MobileNet kullanılıp sınıflandırma amacıyla birleşik yumuşak oylama sınıflandırıcısı kullanılmışlardır. Araştırma bulgularına göre, önerilen teknik ile akciğer kanserini sınıflandırmada %99.3 doğruluk sonucuna varılmıştır [13]. Mangal vd. (2020), akciğer kanserini tanımlamak amacıyla geliştirilmiş sığ bir ESA tabanlı teknik kullanmış ve akciğer kanseri için %97, doğruluk elde edilmiştir [14]. Adu ve ark. (2021), akciğer kanserini otomatik olarak tespit etmek ve sınıflandırmak için kapsül tabanlı bir metodoloji önermiştir. Bu çalışmada, kodlayıcı tabanlı benzersiz bir özellik birleştirme yaklaşımı ve özellik vektörünü bastırma için yeni bir yata sıkıştırma fonksiyonu geliştirilmiştir. Önerilen strateji ile %99.23 doğruluk oranı yakalanmıştır [15]. Hage Chehad ve ark. (2022), akciğer histopatolojik görüntülerin çoklu sınıflandırılması için özellik mühendisliğine dayalı yeni bir makine öğrenimi modeli önermiştir. Bu yöntem, birinc dereceden istatistikler, GLCM ve Hu değişmez momentle kullanılarak 37 manuel çıkarılmış özellik hesaplamışlardır. Akabinde bunları sınıflandırma işlemi için XGBoost sınıflandırıcısına uygulanmıştır. İlgili modelin LC25000 veri kümesi üzerinden test başarımının doğruluk performansı %99 olarak tespit edilmiştir.

MATERYAL VE METOT

A. Veri seti

Bu çalışmada, Kaggle platformundan LC25000 adlı veri seti kullanılmıştır. İlgili veri, Florida'da bulunan Jame Hastanesinde görev yapan Andrew Borkowski ve ekibi tarafından oluşturulmuştur. Veri seti, akciğer ve kolon kanseri histopatolojik görüntülerini içermektedir. Akciğer kanseri ü farklı sınıftan oluşmaktadır. Orijinal görüntü boyutları (1024,768) olup görüntüler (768,768) şeklinde yeniden boyutlandırılmıştır. Veri seti toplamda 750 adet akciğer kanseri ve 500 adet kolon histopatolojik görüntü barındırmaktadır. Veri artırma metodu sayesinde (sağ ve sol rotasyonlar- yatay ve dikey döndürmeler) her sınıftan 5000 adet olmak üzere toplamda 25000 adet görüntü elde edilmiştir. Önerilen çalışmada 15000 adet akciğer histopatolojik görüntüde faydalanılmıştır. Çalışmada kullanılan açık erişim veri setinde akciğer ve kolon kanseri görüntüleri ayrı ayrı sınıflandırılmıştır. Fakat önerilen metod sadece akciğer verisine uygulanmıştır. Verinin kapladığı alan bilgisi ve LC25000 adı kullanılması sebebiyle 2 sınıflı kolon görüntülerini de barındırdığı bilinmemektedir. Tüm veri setinin kapladığı alan 1.85 GB büyüklüğündedir [16]. Akciğer kanseri için akciğer normal dokusu (ND), akciğer adenokarsinomu (ADK) ve akciğer skuamöz hücreli karsinom (SHK) olarak adlandırılan sınıflarda çalışmada irdelenmiştir. Akciğer adenokarsinomu bronşlarda görülen ikinci en yaygın kanser türüdür. Akciğerdeki bu hücrelerin ortaya çıkar. Skuamöz hücreli karsinom, tıpkı adenokarsinom gibi akciğerin alveol ve bronş epitelinde kaynaklanan habis tümörlerdir ve öncül lezyonlardan gelişirler. Patoloji rutininde girişimsel karsinom diyebilmek için hücreye düzeyde anormal görünümün yanında bu hücrelerin yapıya olarak da anormal davranışını saptamak gerekmektedir. Hücresel atipi daha çok hücrenin çekirdek özelliklerini

eğerlendirilmektedir [17]. Son olarak kontrol grubu olan ening hücreler ise normal doku olup vücudun diğer ölgelerine yayılmamaktadır.

1. Metod

İlgili görüntüler (128,128,3) şeklinde yeniden boyutlandırılmış, EfficientNet-B1 mimarisi hariç, ESA ve ViT mimarisindeki [0-55] piksel değerleri normalize edilerek [0-1] arasına indirgenmiştir. Toplam görüntülerin %80'i eğitim, %20'si test ümesine ayrılmıştır. Geri kalan eğitim kümesinin %20'si ise öğülama kümesini oluşturmaktadır. Her sınıftan 5000 örutü alınarak eğitim-test kümeleri dengeli oluşturulmuştur. Bu bağlamda üç farklı DÖ modeli kullanılmıştır. Model sonrası şhis edilen görüntülere açıklanabilir bir yöntem uygulanıp sonuçlar karşılaştırılmıştır. Çalışmada izlenen metod Şekil 1.'de özetlenmiştir.



Şekil 1. Mevcut çalışmada takip edilen metodoloji


-Derin Öğrenme Modelleri

Evrişimsel Sinir Ağları (ESA):

ESA, özellik çıkarımı ve sınıflandırma işlemlerini eş zamanlı olarak gerçekleştiren bir DÖ algoritmasıdır. Bu yöntem, ham verilerden özelliklerin otomatik olarak çıkarılması için evrişim şamaları, aktivasyon fonksiyonları ve havuzlama katmanlarını kullanır. Evrişim işleminin özü, bir veya daha fazla filtre uygulanarak gerçekleştirilen bir matematiksel operasyona dayanmaktadır. Filtrelerin görüntü üzerinde seçilen piksel sayısı adımları ile kaydırılması sonucu özellik haritaları çıkarılır. Filtreleme adımına ait bağıntı Denklem (1)'de verilmiştir. 'b' bias (yanlılık) değerini, 'x' yerel bölgeyi, 'y' ise özellik haritasını temsil etmektedir [18].

$$y_j = \sum(x_i * k_j + b_j) \quad (1)$$


Önerilen ESA mimari yapısı Şekil 2'de gösterildiği gibidir. Bu çalışmada önerilen 3 katmanlı ESA modelinde katmanlardaki sinir hücresi sayısı sırası ile (8,16,32) şeklindedir. Her katmandaki kernel boyutu (3,3) olarak belirlenmiştir. Tüm evrişim işlemleri ardına (2,2) maksimum havuzlama uygulanmıştır. Mimariye (256,128) sinir hücresi sayılarında öğünlük katmanı eklenmiştir. Hiper parametreler açısından batch boyutu 32, seyreltme oranı 0.3, öğrenme oranı 0.001, optimizasyon metodu olarak 'Adam', kayıp fonksiyonu olarak 'categorical_crossentropy', aktivasyon fonksiyonu olarak 'softmax' ve son olarak eğitim boyunca epok sayısı 50 seçilmiştir.



Şekil 2. Önerilen ESA mimarisi yapısı

EfficientNet-B1:

Google araştırma ekibinden Tan ve Le (2019), ConvNet istemlerinin ölçeklendirme yöntemlerini inceleyerek temel yapıyı oluşturmuşlardır [19]. Araştırmacılar, ConvNet'e daha fazla katman ekleyerek onları daha geniş ve derin hale getirip yüksek çözünürlüklerle uğraşmak oldukça zahmetli olabileceği için saniye başına kayan nokta işlemi (FLOPS) kullanıp temel bir ConvNet oluşturmak adına EfficientNet modeli kullanmışlardır. Bu mimari EfficientNet-B0 olarak adlandırılmıştır. Bu aşamadan sonra, EfficientNet-B1, EfficientNet-B0'ı ölçeklendirerek oluşturulmuştur. Ölçekleme görevini daha sonra EfficientNet-B7'ye uygulamışlardır. ImageNet veri kümesi üzerinde EfficientNet-B7 modelini kullanarak üst düzey doğruluk elde etmişlerdir. EfficientNet, diğer birçok derin öğrenme mimarisinden farklı olarak, ağırlık paylaşımı, genişliği ve çözünürlüğünü dengelemektedir. Bu dengeleme, daha iyi performans sağlamak için optimize edilmiştir. EfficientNet mimarisi daha sonra nesne tespiti için farklı çözünürlüklerde kaynaştırılmış özellikler kullanan EfficientNet (B0,B1,B2,B3,B4,B5,B6,B7) ailesini oluşturmak için kullanılmıştır [20]. Bu nedenle ilgili çalışmada, analiz edilen görüntülerin boyutu ve eğitim kolaylığı göz önünde bulundurularak EfficientNet-B1 ağ mimarisi tercih edilmiştir. İriş görüntüleri (128,128,3) için normalizasyon işlemi uygulanmayıp görüntülerin orijinal piksel değerleri ile giriş nöronları oluşturulmuştur. Mevcut çalışmada transfer öğrenme tabanlı EfficientNet-B1 derin öğrenme mimarisinin özellik çıkarıcı olarak kullanılıp dense (yoğun) katmanı ile birleştirilerek yapılan sınıf tahmini Şekil 3.'de gösterilmiştir. EfficientNet-B1 mimarisindeki katmanlar dondurularak ImageNet ağırlıklarının kullanımı ile önerilen görüntü sınıflandırma problemi, önceden eğitilmiş bir derin öğrenme modelinin özelliklerinin alınıp, yeni veri kümesindeki örnekler için sınıflandırma yapılmasını sağlar. Böylelikle büyük miktarda veriye ihtiyaç duymadan etkili bir şekilde yeni bir çevre için modelin uyarlanması gerçekleştirilir. İlgili mimariye kavuzlama olarak 'average pooling' seçilmiştir. Tam bağlantılı katmandaki sinir hücresi sayıları (2048, 1024, 512, 256, 128) eklindedir. Bunun dışındaki hiper parametreler önerilen ESA nodeli ile benzerlik göstermektedir.



Şekil 3. EfficientNet-B1 derin öğrenme mimarisinin akciğer patolojik görüntü tahminlenmesinde kullanımı

Vision Transformer (ViT):

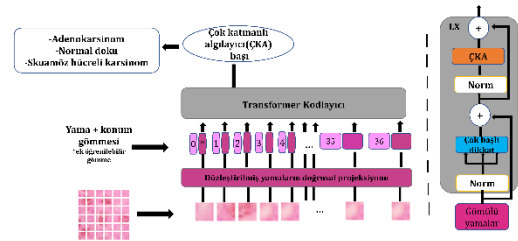
Dehghani vd. (2015), DÖ mimarilerinin kodlayıcı ve çözücü bloklarından oluşan karmaşık evrişimli modellerin dikkat mekanizmaları ile entegre olmasını sağlamışlardır. Böylece derinlemeli ve evrişimsel blokları tamamen ortadan kaldırmayı hedeflemişlerdir [21]. Bu çalışmaya dayanarak Dosovitskiy ve arkadaşları (2021), geleneksel Transformer modelinin görüntü

[22]. ViT, girdi olarak bir görüntüyü alıp önceden belirlenmiş belirli bir boyut ve piksel çözünürlüğüne sahip görüntüleri küçük yamalara böler. Daha sonra, bu görüntü yamalarını dikkat katmanına dönüştürür ve bir dizi dikkat katmanı üzerinden işler. ViT modelinin mimari yapısı Şekil 4.'de gösterilmiştir. Görüntüyü vektöre dönüştüren bağlantı Denklem (2)'de verilmiştir. Bu denklemde her bir görüntü için elde edilen terimler şu şekildedir: n yama sayısı, h yükseklik, w genişlik ve p piksel netliği. Ardından görüntü yamaları $p^2 \times h \times w$ boyutunda vektörlere çevrilir.

$$n = (hw)/p^2 \quad (2)$$

Modelde (128,128,3) olan girdi görüntüleri (72,72,3) şeklinde yeniden boyutlandırılmıştır. Daha sonra her bir kenar 6 adet yamaya bölünmüştür. Böylelikle bir görüntüden toplam (6x6) 36 adet yama elde edilmiştir. Modele ait diğer hiper parametreler şu şekildedir: Kayıp fonksiyonu seyrek kategori ağırlık azalması 0.0001, projeksiyon boyutu 64, dönüşüm birimindeki projeksiyon boyutu 2, dönüşüm katmanının boyutu 8, son sınıflandırıcı olan çok katmanlı algılayıcının sinir hücresi sayıları (2018,1024) olarak belirlenmiştir.

Önerilen ViT mimarisinde büyük veri gereksiniminden dolayı eğitim kümesinde veri artırımı yoluna gidilmiştir. Mimarini iç yapısı gereği ilgili değişimler belirli oranda görüntülerin eksenine göre simetrisinin alınması, 0.02 faktörü ile döndürülmesi ve hem yatay hem düşeyde 0.2 faktörü ile yakınlaştırma şeklindedir. Bu işlemin amacı olası test görüntülerine karşı sistemi gürbüz bir şekilde eğitmeyi amaçlar.



Şekil 4. Çalışmada kullanılan ViT mimarisine ait genel iç yapısı [22].

2-Performans Metrikleri

Makine öğrenimi ile ilgili performans metrikleri, hassasiyet, geri çağırma, F1 skoru ve doğruluk değerleri dahil olmak üzere ölçülecektir. Kesinlik, doğru pozitiflerin (DP) doğru pozitif ve yanlış pozitifler (YP) toplamına oranı olarak hesaplanır. Yani, doğru pozitiflerin toplam pozitif tahminlere oranıdır. Duyarlılık, doğru pozitiflerin toplam doğru pozitifler ve yanlış negatifler (YN) toplamına oranı olarak hesaplanır. Yani, doğru pozitiflerin toplam pozitif gerçekler ile oranıdır. F1 skoru kesinlik ve duyarlılığın harmonik ortalamasıdır. Dengesi sınıflandırma problemlerinde sıklıkla tercih edilir. Doğruluk bir model tarafından yapılan tahminlerin genel doğruluğunu ölçer. Doğruluk, doğru tahminlerin (DN, YP) toplam tahminlere oranı olarak hesaplanır. Performans metrikleri hesaplamasının özeti Tablo 1'de bulunmaktadır.

Tablo 1. Performans metrikleri matematiksel hesabı

Kesinlik	Duyarlılık
DP	DP
DP + YP	DP + YN
F1-skor	Doğruluk
$\frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$	$\frac{\text{DP} + \text{DN}}{\text{DP} + \text{YP} + \text{YN} + \text{DN}}$

-Açıklanabilir Yapay Zeka Metodu:

IME (Local Interpretable Model-agnostic Explanations):

Ö modelleri, genellikle karmaşık yapısı ve yüksek boyutlu eriler üzerindeki etkin performansı dikkat çekmektedir. İlgili modeller literatür çalışmalarında ‘kara kutu’ modeller olarak adlandırılmaktadır [23]. Bu terim, DÖ modellerinin iç işleyişi ve karar süreçlerinin anlaşılmasının zorluğunu ifade eder. Bu durum kritik uygulamalarda DÖ kullanımını ısıtlamaktadır. Tıbbi teşhis gibi kritik disiplinlerde makine öğrenimi kullanımında tahminlere tamamen güvenilmez, çünkü sonuçlar yanıltıcı olabilir. Bireysel tahminlere güvenmekten aşka, modelin saha koşullarında kullanılmadan önce bütün olarak değerlendirilmesi de gerekmektedir. Bu kararı vermek için, kullanıcıların modelin gerçek dünya verilerinde iyi performans göstereceğine ve ilgi çeken ölçütler doğrultusunda eğlendirileceğine güvenmeleri gerekmektedir. Bu sebeple DÖ algoritmalarının iç işleyişini anlamak ve şeffaf hale getirmek amacıyla açıklanabilir modeller kullanılmaktadır. Çalışmada eğitim ve test işlemi sonrasında açıklanabilir modellerden biri olan LIME metodu kullanılmıştır. LIME metodunda amaç seçilen örnekleme DÖ metodunda alınan giriş ve tahminlerin neden yaptığını anlamak ve bu tahminlere yakını eni tahmin bölgeleri belirlemektir. Yeni ağırlıklar elde edilen tahminlere göre ağırlıklandırılmaktadır. Görüntüler tahmin için (1,128,128,3) olarak yeniden boyutlandırılmıştır. Test örneğinden doğru olarak sınıflandırılan rastgele seçilmiş görüntü örnekleri ile modelin görüntü üzerinden özellik çıkardığı ilgili bölgeler kestirilmeye çalışılmıştır. LIME metodu kararlarını belirli bir örnek veya örnek kümesi üzerinde tanımlandırır. Model agnostik bir yaklaşım benimseyip herhangi bir makine öğrenmesi modeli ile uyumlu çalışır. Bu çalışmada temel bir açıklayıcı yapay zeka modeli olarak sıklıkla kullanılmaktadır [24].

$$\text{çıklama}(x) = \underset{g \in G}{\text{argmin}} L(f, g, \pi_x) + \Omega(g) \quad (3)$$

Denklem (3)’de x açıklanmak istenen görüntü, g vekil model, f orijinal model, π_x ise x görüntüsüne yakınlık ölççeği, L kayıp fonksiyonu minimum yapan fonksiyon ve $\Omega(g)$ vekil modelin özellik miktarını az sayıda tutabilmek için kullanılan bir düzenleyicidir.

BULGULAR VE TARTIŞMA


Çalışmada kullanılan veri seti ve mevcut yöntem, patolojik görüntülerin işlenmesinde ve yorumlanmasında literatüre katkı sağlamaktadır. 50 epok boyunca alınan eğitim validasyon

ait karmaşıklık matrisleri Şekil 5.’de verilmiştir. Karmaşık matrislerinden çıkarılan metrikler ise Tablo 2.’de bir arad hesaplanmıştır. ViT mimarisinin evrişim tabanlı ESA v EfficientNet-B1 mimarisine göre daha başarılı sonuçlar verdiği gözlemlenmiştir. ESA mimarisi %87.93, EfficientNet-B1 mimarisi %96.97 ve ViT mimarisi %98.40 doğruluk değerlerine ulaşmıştır. Derin mimariler sonucu farklı doküman örneklerinden çıkarılan özelliklere ait doku konumları LIME metodu ile belirlenerek Şekil 6.’da gösterilmiştir.

Önerilen çalışmanın bulgularına göre, ViT mimarisi doğruluk hassasiyet ve duyarlılık gibi performans metrikleri açısından incelendiğinde akciğer kanseri özelliği taşıyan histopatoloji dokuları sağlıklı görüntülerden ayırma amacıyla EfficientNet-B1 ve ESA mimarisine kıyasla daha az parametre sayısı ile daha etkili bir sonuç ulaşılmıştır. Evrişim tabanlı ESA ve transfe öğrenmeye dayalı EfficientNet-B1 mimarileri dikkat mekanizmasına dayalı dönüşüm tabanlı ViT mimarisini performans olarak gerisinde kalmıştır. Önerilen evrişim tabanlı mimariler arasında EfficientNet-B1 mimarisi patolojik görüntü sınıflandırma uygulamalarında daha başarılı performans sergilemiştir. Ek olarak EfficientNet-B1 mimarisi transfe öğrenme ile kullanılırken ESA mimarisi rastgele parametreler başlatılarak eğitilmiştir. Her iki mimari de evrişim tabanlı olmasına rağmen bu durum ESA mimarisi için dezavantajlı bir durum olarak kabul edilebilir. Önceden öğrenilmiş ağırlıkları yeni veri setlerindeki kullanımına ait yüksek başarımlar transfe öğrenmenin getirdiği en önemli kazançlardan biridir [25]. Ayrıca derin katmanlı EfficientNet-B1 modelinin LIME gibi model agnostik yaklaşımlarda görüntüdeki detayları çok sayıda kümelemesi patolojik görüntü uygulamalarında önem taşıdığı göstermektedir ancak ilgili mimarinin efektif kullanımı için tür slayt görüntülerden faydalanmak daha doğru bir yaklaşım olacaktır. İlgilenilen kanserli kısımlar ve önerilen derin öğrenme mimarileri arasındaki ilişki açısından şu şekilde bir yorumdan bahsedilebilir: i) ESA mimarisi akciğer kanserine ait ilgili yerlerden özellik çıkarırken bu bölgeyi daha geniş tuttuğu ilgisiz yerlerden de özellik toplamıştır. ii) EfficientNet-B1 algoritmasında kümelene alanlar çok sayıdadır. Bu bağlamda tüm slaytlardan yararlanmak daha doğru olacaktır. İlgili görseller yama görüntülerini temsil etmektedir. iii) ViT mimarisinde ise hem sınıflandırma başarımı en yüksek olurken hem de en anlamlı bölgelerden özellik çıkarılmıştır. Sonuç olarak ViT akciğer kanserine ilişkin patolojik kesitleri analizinde en doğru ve anlamlı sonuçlar üretmiştir. Çalışmada LIME açıklanabilirlik yöntemi kullanılarak ViT, ESA v EfficientNet-B1 mimarilerinin eğitildiği görüntülerde öğrenile bölgelerin belirgin bir şekilde işaretlenmesi, araştırmaya önemli bir katkı sağlamıştır. Bu yaklaşım, DÖ mimarilerini içsel öğrenme mekanizmalarını daha anlaşılır ve yorumlanabilir hale getirerek modelin hangi özellikleri ve bölgeleri vurgulayarak öğrendiğini açıklığa kavuşturmuştur. Görüntü üzerinde işaretlenen kümeler ilgili bölgeleri teşhis etmek için kullanılmıştır. Bu bağlamda öğrenilen bölgelerin vurgulanması modelin kararlarını ve öğrenme süreçlerini daha şeffaf bir şekilde anlaşılmasına yardımcı olarak önerilen çalışmanın genel etkisini arttırmaktadır. Bu çalışmada kullanılan


Boyutları için de denenmiş olup benzer sonuçlar vermiştir. Bu bağlamda GPU ve zaman kısıtından ötürü çalışmada küçük boyutlu görüntüler tercih edilmiştir. Çalışmada önerilen 3 katmanlı ESA modelinde seçilen eğitim parametrelerinin belirlenmesinde hiper-parametre optimizasyonu yapılmamıştır. Ayrıca tek bir açıklanabilir metot kullanıldığından bu uygulamaları destekleyecek farklı açıklanabilir metotlarının ortaya konmaması çalışmanın eksik görülen noktalarından bazılarıdır. Gelecek çalışmalarda histopatolojik görüntülerdeki kanser teşhisini geliştirmek amacıyla farklı DÖ modellerinin geliştirilmesi ve birden fazla açıklana bilirlik yöntemlerinin karşılaştırmalı analizinin yapılması hedeflenmektedir. Seçilen yöntemin hüresel ve dokusal bakımdan uzmanlık gerektiren görüntüler olması sebebiyle ileride yapılacak histopatolojik görüntü analizlerinin uzman bir patolog eşliğinde sonuçları yorumlaması çalışmaya katkı sunacaktır.


Mevcut çalışmanın yenilikçi yanları *Mevcut Çalışmalar* başlığı altında verilen literatür özeti ile kıyaslandığında şu şekilde sıralanabilir: **Çoklu Model Karşılaştırması:** ESA, ViT ve EfficientNet-B1 mimarileri karşılaştırılarak kapsamlı bir analiz yapılmıştır. Farklı derin öğrenme mimarilerini aynı veri kümesi üzerinde sistematik olarak karşılaştıran çalışmalar sınırlıdır. Bu çalışma, farklı modellerin performansını aynı veri seti ve aynı metrikler kullanarak doğrudan karşılaştırmaktadır. **Açıklanabilirlik Metodolojisi:** LIME metodunu kullanarak modellerin çıktılarının açıklanabilirliği değerlendirilmiştir. Literatürde açıklanabilirlik metotları genellikle sınırlı kullanılmıştır. Bu çalışmada, LIME ile modelin karar verme süreçlerinin görselleştirilmesi, modelin güvenilirliğini ve klinik uygulamadaki kullanım potansiyelini artırmaktadır. **Yüksek Doğruluk Oranları:** ViT mimarisinin %98.40 doğruluk oranına ulaşması ve EfficientNet-B1'in %96.97 doğruluk oranı ile yakın sonuçlar vermesine bulgular kısmında yer verilmiştir. Literatürdeki diğer çalışmalarla karşılaştırıldığında, önerilen yöntemlerin daha yüksek doğruluk oranlarına ulaşması, çalışmanın başarısını göstermektedir. **Detaylı Performans Değerlendirmesi:** Performans değerlendirmesinin sadece doğruluk oranıyla sınırlı kalmaması, diğer önemli metriklerin de kapsamlı bir şekilde analiz edilmesi, çalışmanın derinliğini ve geçerliliğini artırmaktadır. **Farklı Mimari Yapıların Kullanımı:** Literatürdeki çalışmaların çoğu ya sadece ESA ya da tek bir model mimarisi üzerine odaklanmıştır. Bu çalışmanın farklı mimarileri bir araya getirmesi ve karşılaştırması yenilikçi bir yaklaşım sunmaktadır. **Açıklanabilir makine öğrenmesi ile ayrıntılı ve şeffaf sonuçlar:** Literatürde LIME metodunun kullanımı yaygın değildir ve bu metodun özellikle EfficientNet-B1 ve ViT ile entegrasyonu, model çıktılarının daha iyi anlaşılmasını ve yorumlanmasını sağlamaktadır.



Şekil 5. ESA, ViT ve EfficientNet-B1 derin öğrenme mimarilerine ilişkin eğitim/validasyon kümelerine ait epoklar boyunca doğruluk-kayıp değerleri ile test kümesi karmaşıklık matrisleri

Tablo 2. Önerilen derin öğrenme mimarileri sonucu elde edilen performans metrikleri					
Derin Öğrenme Mimarisi	Sınıflar	Kesinlik	Duyarlılık	f1 skor	Genel Doğruluk
ESA	ADK	0.99	0.64	0.78	0.8793
	SHK	0.74	1.00	0.85	
	ND	0.99	1.00	1.00	
ViT	ADK	0.97	0.99	0.98	0.9840
	SHK	0.99	0.97	0.98	
	ND	1.00	1.00	1.00	
EfficientNet-B1	ADK	1.00	0.92	0.96	0.9697
	SHK	0.92	1.00	0.96	
	ND	1.00	0.99	1.00	





ekil 6. Adenokarsinom, skuamöz hücreli karsinom ve normal doku örnek görüntülerine ilişkin uygulanan derin mimariler sonucu LIME açıklanabilir yapay zek metoduna ait gösterimler

EŞEKKÜR

Yazarlar ilgili çalışmada Dicle Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'nün (DÜBAP), sağladıkları finansal destek için (Proje No: MÜHENDİSLİK.17.019) teşekkürlerini unmaktadır. Ayrıca Acıbadem Maslak Hastanesi Mehmet Ali Aydınlar Üniversitesinde patolog olarak görev yapan Cavit İcerem Kayhan'a sonuçların yorumlanmasındaki değerli katkıları için teşekkürlerimizi sunarız.

KAAYNAKLAR

- [1] M. B. Schabath and M. L. Cote, "Cancer progress and priorities: Lung cancer," *Cancer Epidemiol. Biomarkers Prev.*, vol. 28, no. 10, pp. 1563–1579, 2019, doi: 10.1158/1055-9965.EPI-19-0221.
- [2] M. C. Staff, "Cancer." Accessed: May 06, 2024. [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/cancer/symptoms-causes/syc-20370588>
- [3] L. L. Zullig *et al.*, "Cancer incidence among patients of the U.S. veterans affairs health care system: 2010 update," *Mil. Med.*, vol. 182, no. 7, pp. e1883–e1891, 2017, doi: 10.7205/MILMED-D-16-00371.
- [4] World Health Organization, "Cancer." Accessed: May 02, 2024. [Online]. Available: <https://www.who.int/news-room/factsheets/detail/cancer>
- [5] W. D. Travis, "Pathology of Lung Cancer," *Clin. Chest Med.*, vol. 32, no. 4, pp. 669–692, 2011, doi: 10.1016/j.ccm.2011.08.005.
- [6] L. Succony, D. M. Rassl, A. P. Barker, F. M. McCaughan, and R. C. Rintoul, "Adenocarcinoma spectrum lesions of the lung: Detection, pathology and treatment strategies," *Cancer Treat. Rev.*, vol. 99, no. May, p. 102237, 2021, doi: 10.1016/j.ctrv.2021.102237.
- [7] S. Huang, J. Yang, S. Fong, and Q. Zhao, "Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges," *Cancer Lett.*, vol. 471, no. December 2019, pp. 61–71, 2020, do 10.1016/j.canlet.2019.12.007.
- [8] T. Aitazaz, A. Tubaishat, F. Al-Obeidat, B. Shah, T. Zia, and I. Tariq, "Transfer learning for histopathology images: an empiric study," *Neural Comput. Appl.*, vol. 35, no. 11, pp. 7963–7974, 2022, doi: 10.1007/s00521-022-07516-7.
- [9] M. Ali and R. Ali, "Multi-Input Dual-Stream Capsule Network for Improved Lung and Colon Cancer Classification," *Diagnostics*, vol. 11, no. 8, 2021, doi: 10.3390/diagnostics11081485.
- [10] N. Kumar, M. Sharma, V. P. Singh, C. Madan, and S. Mehandia, "An empirical study of handcrafted and dense feature extraction techniques for lung and colon cancer classification from histopathological images," *Biomed. Signal Process. Control*, vol. 7, p. 103596, 2022, doi: <https://doi.org/10.1016/j.bspc.2022.103596>.
- [11] N. yahia Ibrahim and A. S. Talaat, "An Enhancement Technique to Diagnose Colon and Lung Cancer by using Double CLAHE and Deep Learning," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 8, 2022, doi: <https://doi.org/10.14569/IJACSA.2022.0130833>.
- [12] J. Fan, J. Lee, and Y. Lee, "A Transfer Learning Architecture Based on a Support Vector Machine for Histopathology Image Classification," *Appl. Sci.*, vol. 11, no. 14, 2021, doi: 10.3390/app11146380.
- [13] M. A. Talukder, M. M. Islam, M. A. Uddin, A. Akhter, K. F. Hasa and M. A. Moni, "Machine learning-based lung and colon cancer detection using deep feature extraction and ensemble learning," *Expert Syst. Appl.*, vol. 205, p. 117695, 2022, doi: <https://doi.org/10.1016/j.eswa.2022.117695>.
- [14] S. Mangal, A. Chaurasia, and A. Khajanchi, "Convolution Neural Networks for diagnosing colon and lung cancer histopathological images." 2020.
- [15] K. Adu, Y. Yu, J. Cai, K. Owusu-Agyemang, B. A. Twumasi, and J. Wang, "DHS-CapsNet: Dual horizontal squash capsule networks for lung and colon cancer classification from whole slide

- 4, pp. 2015–2092, 2021, doi: <https://doi.org/10.1002/ima.22569>.
- 16] A. A. Borkowski, M. M. Bui, L. B. Thomas, C. P. Wilson, L. A. DeLand, and S. M. Mastorides, “Lung and Colon Cancer Histopathological Image Dataset (LC25000),” pp. 1–2, 2019.
- 17] J. M. JR Goldblum, LW Lamps, *Rosai and Ackerman’s Surgical Pathology*. 2017.
- 18] C. Ieracitano, N. Mammone, A. Bramanti, A. Hussain, and F. C. Morabito, “A Convolutional Neural Network approach for classification of dementia stages based on 2D-spectral representation of EEG recordings,” *Neurocomputing*, vol. 323, pp. 96–107, 2019, doi: 10.1016/j.neucom.2018.09.071.
- 19] S. Han, H. Mao, and W. J. Dally, “Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding,” *4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc.*, pp. 1–14, 2016.
- 20] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- 21] A. Vaswani, N. Shazeer, and N. Parmar, “Attention is All You Need,” in *31st Conference on Neural Information Processing Systems* [22] A. Dosovitskiy, L. Beyer, A. Kolesnikov, and D. Weissenborn, “A Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” in *ICLR 2021*, 2021.
- [23] B. H. M. van der Velden, H. J. Kuijf, K. G. A. Gilhuijs, and M. A. Viergever, “Explainable artificial intelligence (XAI) in dee learning-based medical image analysis,” *Medical Image Analysis*, vol. 79. Elsevier B.V., Jul. 01, 2022. do 10.1016/j.media.2022.102470.
- [24] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You’: Explaining the Predictions of Any Classifier,” *NAACL-HLT 2016 2016 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang Technol. Proc. Demonstr. Sess.*, pp. 97–101, 2016, do 10.18653/v1/n16-3020.
- [25] G. Marques, D. Agarwal, and I. de la Torre Díez, “Automate medical diagnosis of COVID-19 through EfficientNet convolution neural network,” *Appl. Soft Comput.*, vol. 96, p. 106691, 2020, do <https://doi.org/10.1016/j.asoc.2020.106691>.

Özgeçmişler



Delal Şeker, Diyarbakır Rekabet Kurumu Anadolu Lisesi'nden mezun olduktan sonra (2011) lisans (2012-2016) ve yüksek lisans (2018-2020) eğitimini Dicle Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde tamamladı. 2021 yılından beri doktora eğitimi aynı bölümde devam etmektedir. TÜBİTAK 1001 Projesi kapsamında 'Kantitatif Sentetik Prostat Manyetik Rezonans Görüntüleme Makina Öğrenmesi ile Prostat Kanserinin Değerlendirilmesi' başlıklı projesinde doktora bursiyeri olarak araştırmalarını sürdürmektedir.



Mustafa Said Kartal, 1998 yılında Afyonkarahisar'da doğdu. İlköğretim ve ortaöğretim eğitimini Afyonkarahisar'da tamamladı. 2018 yılında Sivas Cumhuriyet Üniversitesi Tıp Fakültesi'ne başladı. 2021 yılında hastane yazılımları üreten bir şirkette Veri Bilimci olarak çalışmaya başladı. Nisan 2023'ten beri tıp eğitimine devam ederken Hevi Al'da Makine Öğrenimi Mühendisi olarak görev yapmaktadır.



Abdulnasır Yıldız, Lisans Eğitimini 9 Eylül Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde tamamladıktan sonra (1997) yüksek lisans (2002) ve doktorasını (2011) Fırat Üniversitesinde bitirmiştir. Şu anda Dicle Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde Doçent olarak görev yapmaktadır. Ana araştırma ilgi alanları işaret işleme ve örüntü sınıflandırmadır.



İlkay Öksüz, İstanbul Alman Lisesinden mezun olduktan sonra lisans eğitimini İstanbul Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde tamamlamıştır. Daha önce, King's College London Biyomedikal Mühendisliği Bölümü'nde araştırma görevlisi olarak çalışmıştır. Doktora eğitimini, İTÜ İleri Araştırmalar Okulu'nda Bilgisayar, Karar ve Sistem Bilimleri alanında tamamlamıştır. Ana araştırma ilgi alanları görüntü segmentasyonu, görüntü kaydırma ve makine öğrenimidir. Şu anda İstanbul Teknik Üniversitesi Bilgisayar Mühendisliği bölümünde Doçent olarak görev yapmaktadır.

Deniz Taşımacılığı İzlemek için Sualtı Kablosuz Sensör Ağlarında Otonom Sualtı Aracı ile Dayanıklı ve Enerji Farkında Yol Planlama

Robust and Energy-Aware Path Planning by Autonomous Underwater Vehicle in Underwater Wireless Sensor Networks for Monitoring Maritime Transportation

Ömer Melih Gül 

Bilişim Enstitüsü

İstanbul Teknik Üniversitesi, İstanbul

Email: omgul@itu.edu.tr

 Tayfun Acarer

Denizcilik, Ulaştırma ve İşletme Yüksekokulu

Piri Reis Üniversitesi, İstanbul,

tacarer@hotmail.com

Özetçe—Daha ucuz olması nedeniyle uluslararası ve kıtalararası ticarete deniz yolu en yoğun kullanılan taşıma şeklidir. Ancak deniz kazaları gemiler için olağan tehlikelerdir. Bu amaçla sualtı kablosuz sensör ağları (SKSA), deniz trafiği risklerini azaltmak ve deniz ortamını izlemek için geliştirilmiştir. Bu sistemlerin enerjisi, sınırlı güce sahip olumsuz bölgelerdeki SKSA'lar için hayati öneme sahiptir. SKSA'nın uzun süre dayanabilmesi için, sürekli çevresel izleme ve gözetleme verilerinin toplanması ve iletişimini sağlamak amacıyla enerji kısıtlamalarının ele alınması gerekmektedir. Su altı sensör düğümleri için yol planlama ve enerji tasarruflu otonom su altı aracı (OSA) şarjı, SKSA enerji ve pil değiştirme sorunlarını çözmek için kullanılmaktadır. Bu makalede, OSA ile enerjiye duyarlı yol planlama problemini çözmek için en yakın komşu algoritması kullanılmaktadır. OSA yol planlama simülasyonları, en yakın komşu algoritmasının genetik algoritmaya ve Grey-Wolf eniyileştirme algoritmasına göre daha hızlı yakınsadığını ve daha iyi bir çözüm ürettiğini göstermektedir. Yapılan çalışmada sensör verilerini daha az enerjiyle hızlı bir şekilde toplamak için sağlam ve enerji açısından verimli yol planlama algoritmaları sunarak izleme sisteminin gemilerin maruz kalabilecekleri tehlikelere daha hızlı yanıt vermesi hedeflenmektedir. Temin edilen veriler sensörlerin daha yakından iletişim kurması sonucu enerji kullanımının en aza indirildiğini ve SKSA ağının ömrünü artırdığını göstermektedir.

Anahtar Kelimeler —otonom su altı aracı; su altı kablosuz sensör ağları; enerjiye duyarlı yol planlaması deniz haberleşmesi; gemi yönetim sistemleri; denizcilik otoritesi için güvenli seyir planlaması; denizcilik endüstrisi; deniz ticareti.

Abstract—Since it's cheaper, sea transportation has been preferred for international and intercontinental trade. However, ship mishaps are possible dangers. Underwater wireless sensor networks (UWSN) can monitor the maritime environment to reduce maritime traffic risks. Energy is crucial for UWSNs in adverse areas with limited power. So

UWSN can last, energy constraints must be handled to enable continuous environmental monitoring and surveillance data gathering and communication. Path planning and energy-saving autonomous underwater vehicle (AUV) charging for underwater sensor nodes can solve UWSN energy and battery replacement issues. This paper uses nearest neighbour algorithm to solve the energy-aware path planning problem with AUV. AUV path planning simulations show that the nearest neighbour algorithm converges faster and produces a better solution than the genetic algorithm and grey wolf optimizer algorithm. We offer robust and energy-efficient path planning algorithms to swiftly collect sensor data with less energy, allowing the monitoring system to respond faster to ship disaster hazards. Communicating sensors closer minimises their energy usage and improves UWSN network lifetime.

Keywords —autonomous underwater vehicle; underwater wireless sensor networks; energy-aware path planning; water monitoring; ship management systems; safe sailing planning for maritime authority; maritime industry; maritime commerce

I. GİRİŞ

Tarihsel olarak denizcilik ve uluslararası ticaret birbiriyle doğrudan ilişkili kavramlardır. Bunun temel nedeni, deniz taşımacılığının uluslararası ticaretin ve kıtalararası geçişin birincil tercihi olmasıdır [1]. Deniz taşımacılığının en büyük özelliği demiryolundan 3,5 kat, karayolundan 7 kat, havayolundan ise 22 kat daha ucuz olmasıdır. Deniz taşımacılığının maliyet avantajı, artan ilgisini ve hacmini de artırmaktadır [2]. Uluslararası Deniz Ticaret Odası (ICS), küresel trafiğin %90'ının deniz yoluyla gerçekleştirildiğini bildirmektedir [3]. Birleşmiş Milletler Ticaret ve Kalkınma Konferansı, küresel deniz ticaretinde 2018'den 2023'e kadar yıllık %3,8'lik bir büyüme olacağını öngörmektedir.[4]. Artan dünya deniz ticareti, deniz yolu kaza riskini artıran yoğun deniz trafiğine neden olmaktadır. Geçmiş veriler, kazaların

genellikle en yoğun deniz rotası yollarında meydana geldiğini göstermektedir [5].



Şekil 1. Dünya Denizcilik Ticaretinin Ana Rotası ve Bağlantı noktaları için Harita [6]

Günümüzde kargo hacmi ve değeri arttıkça deniz taşımacılığı kazaları daha fazla zarara yol açmaktadır. Ölümcül kazaların maliyetini ise parasal değerlerle ölçülemek mümkün değildir [7]. Günümüzde Süveyş Kanalı ulaşımının aksaması ve meydana gelen gemi kazaları [8]–[10], Çin filosunun nakliye masrafları da dahil olmak üzere dünya çapındaki tedarik zincirleri üzerinde önemli olumsuz ekonomik etkileri olmaktadır [11]. [12]'de kısıtlı Süveyş Kanalı vaka çalışması, senaryo analizi yoluyla gözlemlenen sonuçları açıklamaktadır. Süveyş Kanalı'nın tıkanması gibi kazaları önlemek amacıyla hazırlanan bulguların kaza soruşturması için geriye dönük risk kaynaklarını değerlendirmesi ve sınırlı su yolu kazalarının önlenmesine yönelik ileriye yönelik riskleri tahmin etmek için kullanılması mümkündür.

Son dönemde endüstride temin edilen gelişmeler birçok sektöre de yansımaktadır. Bu gelişmeler geleneksel yapıları önemli ölçüde değiştirmekte, iş süreçlerini ve personel rollerini dönüştürmektedir [13]. Bu değişiklikler birçok sektörde olduğu gibi denizcilik şirketlerini ve gemi işletmeciliğini de etkilemektedir. Bu gelişmeler son yıllarda gemilerin uluslararası sularda yönetimi ve güvenli geçişine yönelik pek çok önemli verinin elde edilmesini mümkün kılmıştır. Güvenli navigasyon büyük ölçüde deniz durumu verilerine dayanmaktadır. Günümüzde deniz verileri yüzey verilerinin yanı sıra deniz tabanı verilerini de içermektedir. Güvenli deniz yolculuğu için, deniz yatağı hareketlerinin ve verilerinin anında tespit edilip önemli denizcilik kuruluşlarına iletilmesi çok önemlidir. Bu veriler aynı zamanda güvenli deniz yolu taşımacılığı ve gemi navigasyonu için de gereklidir. Bu amaçla alınacak önlemler için de bu veriler çok önemlidir.

Deniz haberleşmesi, deniz araçlarını desteklemek için gemiler, kara birimleri ve uçaklar arasındaki iletişimi içermektedir [14]. Son dönemde veri taşıma ve iletişim teknolojileri ve gemi sistemleri, deniz tabanı ve yüzey verilerini çok uzak mesafelerden izleyebilecek ve gerektiğinde müdahale edebilecek noktaya gelmiştir.

A. Güdüleme

Sualtı kablosuz sensör ağlarının (SKSA), hızlı gelişimlerinden dolayı okyanus verilerinin toplanması,

kaynak keşfi ve navigasyon için çok önemlidir [15]. Son veriler, çeşitli kullanımlara sahip akıllı okyanus sualtı Nesneleri İnterneti'nin (Nİ) [16] potansiyelini öne çıkarmaktadır. Bu konuda yapılan bir çalışmada birkaç su altı sensör düğümü çevresel verileri bir veri merkezine göndermektedir. Zorlu deniz ortamlarında pille çalışan düğümler pahalı ve karmaşık pil değişimini gerektirmektedir. Bu nedenle Sınırlı enerji ve kısa ömür nedeniyle enerji verimliliğinin artırılması SKSA performansı ve güvenilirliği için çok önemlidir [17].

SKSA'da yol planlaması için önerilen yapay zeka tabanlı meta-sezgisel algoritma, bir yandan enerji tasarrufu sağlarken sensör verilerinin toplanmasını hızlandırmakta, diğer yandan sistemin gemi kazaları tehlikelerine karşı daha hızlı tepki vermesini sağlar. Sensörlerin daha yakın iletişim kurması enerji tüketimini en aza indirmekte, bu durum ise gemi kazalarını önlemek için su altı ortamını izleyen SKSA'nın ömrünü uzatmaktadır.

Yapılan çalışmada bunu düzeltmek için çeşitli deneyimlerde bulunuldu. İlk olarak, SKSA'ların veri iletimi için çok fazla enerjiye ihtiyacı olduğu görüldü. Bu amaçla sensör verilerinin, iletimi ve enerji tüketiminin azaltılması için sıkıştırma ve optimize yapılmıştır [18]. İkinci olarak da ve yönlendirme ile, SKSA enerji verimliliğini artırabildiği tespit edildi. Dağıtım ve yönlendirme yaklaşımlarının iyileştirilmesi sonucu enerji tüketiminin azaltılabildiği ve sensör düğümleri arasındaki eşit olmayan mesafe ve enerji harcaması nedeniyle ağ ömrünün artırabildiği görüldü [19].

Bu yaklaşımlarda dahi pilin ömrü bittiğinde değiştirilmesi gerektiği tespit edilmiştir. Günümüzde Su altı sensörlerinin, pil değişimine gerek kalmadan uzun süreli izleme ve veri iletimi için enerji aktarım teknolojileri kullanılarak şarj edilebilmesi mümkün hale gelmiştir [20]. DeMauro ve ark. [21], su altında kullanıma yönelik, yüksek su basıncını ve kısa devreleri ele alan şarj edilebilir bir lityum iyon pil modülü geliştirmiştir. Yapılan çalışma sonucunda enerji aktarım mesafesi sınırlamaları nedeniyle, otonom sualtı araçlarının (OSA) şarj edilmesine yardımcı olması ve rota planlaması yapılmasının gerekli olduğu görülmüştür.

OSA, insan müdahalesi olmadan orta düzeyde faaliyetler gerçekleştirebilen, kendinden tahrikli bir denizaltıdır [22]. OSA'lar deniz yatağı araştırması, arama, tanımlama ve kurtarmada ekonomik olmaları ve güvenlikleri nedeniyle deniz altı araştırmalarında, çevresel izlemede ve deniz güvenliğinde yaygın olarak kullanılmaktadır [23]. OSA'nın sınırlı güç taşıma kapasitesi ve şarj alanı, ardışık düğümlerden veri kaybını sorunlu hale getirmektedir. Bu, OSA'nın özellikle deniz koşullarında daha geniş tespit bölgeleri için kullanılabilirliğini garanti etmeyi zorlaştırmaktadır.

Kablosuz şarj edilebilir sensör ağları için manyetik olarak şarj edilmiş arabalar [24]'te önerilmektedir. SKSA'lar, yer tabanlı kablosuz şarj edilebilir sensör

ağlarından farklı olarak üç boyutlu bir yapıya sahiptir ve su altı mesafesiyle iletim gücünü artırmaktadır.

Bu makalede yol planlama problemine en kısa yolla çözüm arayarak, daha kısa yoldan çözüm daha az enerji tüketimini sağladığı için 'enerji farkında' tasarım hedeflenmektedir. Su altı cihazlarının hesaplama kapasitesi ve enerji tüketimini de gözönünde bulundurarak hesaplama yükü az olan her koşulda çalışabilecek yani her koşula 'dayanıklı' çözümler hedeflenmektedir.

B. Önemli Katkıları

Bu makalenin literatüre ana katkıları şu şekildedir:

- Bu çalışma, SKSA'daki veri toplama sorunlarına yönelik bir OSA tarafından 3 boyutlu yol planlamasına yönelik bir problemi incelemiş ve yapay zeka tabanlı algoritmaları uygulamıştır.
- Bu çalışmada incelenen probleme uygulanan algoritmaların başardığı en az yol uzunluklarının yanında hesaplama sınırlamalarını ve çözüme ulaşma süreleri de dikkate alınmaktadır.
- Bu yol planlama problemi için diğer algoritmalara göre daha pratik bir algoritma olan en yakın komşu algoritması uygulanmış, özellikle sensör sayısı arttıkça diğer algoritmalarından daha kısa yolu çok daha hızlı sunduğu görülmüştür.

C. Teşkil

Bu makalenin geri kalanı şu şekilde teşkil edilmiştir. Bölüm II ilgili literatürü sunmaktadır. Bölüm III sistem modelini sunup problemi tanımlamaktadır. Bölüm IV, üç boyutlu yol planlama problemini gezici satıcı problemi olarak ele alıp çeşitli algoritmalar önermektedir. Bölüm V'te önerilen algoritmaların performansları değerlendirmektedir. Bölüm VI makaleyi sonlandırmakta ve gelecekteki araştırma yönlerini sunmaktadır.

II. İLGİLİ LİTERATÜR

Bu bölümde SKSA'daki yol planlama problemine yönelik ilgili literatür ele alınmaktadır.

İletişim teknikleri pil gücü limitleri nedeniyle enerji tasarrufu sağlamaktadır. Lee ve ark. ağ topolojisi tabanlı enerji tasarruflu SKSA MAC teknikleri üzerinde çalışmıştır. [25]. [26]'da enerji verimli ve güvenilir SKSA MAC ve yönlendirme algoritmaları incelenmiştir. [27] Kanal kalitesini iyileştirmek ve fazlalığı azaltmak için bir paket gönderme yöntemi sunmaktadır. Su ve diğerleri tarafından sualtı akustik sensör ağları (SASA) için hibrit kodlamaya duyarlı bir yönlendirme şeması. [28] iletim yükünü azaltmakta ve güvenilirliği artırmaktadır.

Kümeleme su altı sensör ağlarında enerji verimliliğini, veri toplamayı, kaynak yönetimi ve ömrünü artırmaktadır [29]. Ağ, gereksiz aktarımları azaltmak için her biri bilgi aktaran bir küme başına (KB) sahip kümeler halinde düzenlenmiştir [30]. Sınırlı iletişim kaynaklarına sahip sualtı alanında enerji ve bant genişliği tasarrufu vardır [31].

Güneş ve ark. [32] kümeleme tabanlı iletişim protokolü, sensör düğümü enerji kullanımını azaltmaktadır. [33]'te SYTA'lar için topoloji yönetimi çözümü, kapsamı ve uzun ömürlülüğü geliştirerek güvenilir bağlantı sağlamaktadır. [34], SKSA ağ kapsamını geliştirmek için sanal kuvvet tabanlı dağıtılmış düğüm konuşlandırma stratejisi sunmaktadır. [35]'teki ağ topolojisi kontrol modeli, veri iletimini optimize etmekte ve sağlamlık, enerji tüketimi dengesi ve topoloji gibi su altı yönlerini dikkate alarak SKSA ömrünü uzatmaktadır.

Sensör donanımlı OSA'lar jeoloji, su kalitesi ve deniz yaşamı verilerini toplamaktadır. [36]'da, OSA'nın enerji tasarrufu verilerini gezerek toplamasıyla OSA destekli iletişim test edilmiştir. [37]'de, OSA veri toplama ve yol planlaması için K-ortalama önerilmiştir [38]. OSA'lar veri toplama ve su altı tespiti için kullanılmaktadır [39], [40].

OSA'lar su altında ağ kurabilmekte ve iletişim yapabilmektedir. OSA'lar veya merkezi istasyonlar, mobil veya sabit sensörlerden veri alabilmektedir. Böylece su altı aktivitelerini canlı olarak koordine edilebilmektedirler. Kan ve ark. [41] sahada konuşlandırılabilir üç fazlı kablosuz şarj sistemi, OSA'lari hızlı ve kolay bir şekilde şarj etmektedir. 0-100 m okyanus derinliklerinde OSA navigasyonu için dinamik sistem teorisinin kullanılması, pil ömrünün daha hızlı tüketilmesine yol açmaktadır [42].

Otonom yerleştirme ve pil şarj eden OSA oluşturma işlevi insan müdahalesi olmadan uzun süreli çalışmaya izin vermektedir. Bağlantı istasyonu, sensör düğümlerini ve OSA pillerini şarj etmektedir. Verimlilikleri ve bağımsızlıkları, yeniden şarj edilmeden artmaktadır.

Bu şekilde OSA yol planlama kullanılarak verimliliğin artırılması mümkün hale gelmiştir. Cheng ve diğerleri, OSA rotalarını planlamak, engellerden kaçınmak ve enerji tasarrufu ve ağ ömrü için enerji kullanımını değerlendirmek için kinematik ve dinamik modelleri uygulamıştır [43]. Kumar ve meslektaşları [44], OSA menzillerini önemli ölçüde kısıtlayan hibrit bir su altı keşif tekniği önermektedir. [45]'de keşif bölgesi veri alma noktaları ile daha küçük parçalara ayrılmıştır. Bu şekilde hazırlanan yollar veri toplarken OSA enerjisini korumakta ve şarj edilebilir bir SKSA yol planlama yöntemi [46] ile ağ ömrü uzatılmaktadır.

SKSA enerji kısıtlamalarının ve pil değiştirme zorluklarının, OSA'ları kullanan su altı sensör düğümü şarjı için bir yol planlaması ve enerji tasarrufu stratejisi ile ele alınması mümkündür [47]. Ağ boyutunu ve iletim güvenilirliğini en üst düzeye çıkarmak için, çok sayıda OSA sensör ağ düğümlerini şarj ederken bir genetik algoritma optimum OSA yolunu belirlemektedir. Simülasyon, OSA yol planlama yönteminin standart yöntemlere göre daha hızlı yakınsadığını ve enerji dengeleyici düğüm yoğunluğunu ve ağ boyutunu kullanırken SKSA ömrünü artırdığını göstermektedir. Yol planlamamız, yüksek yoğunluklu ağlarda keşif amaçlı OSA enerjisinden %15 tasarruf sağlamaktadır.

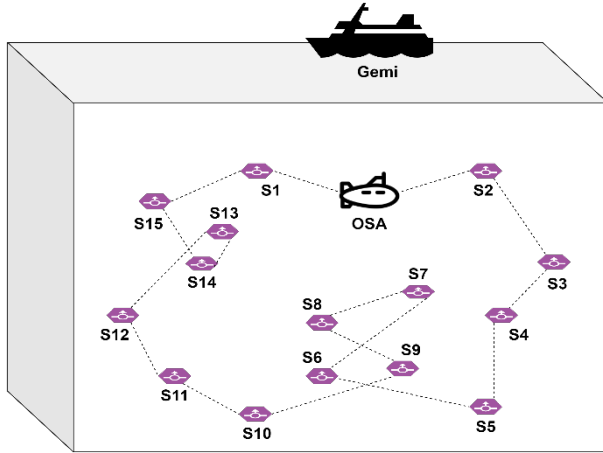
[48]'de bu problemin çözümü için farklı metasezgisel algoritmalar uygulanmıştır. Ayrıca sensörler arası iletişim ve ulaşımın çok zor olduğu bir durum da incelenip güvenlik farkında genetik algoritma metasezgisel algoritması önerilmiştir.

III. SİSTEM MODELİ VE PROBLEM TANIMI

Bu çalışma, su altı OSA sensör ziyaretleri için enerji bilinçli yol planlama sorununu ele almaktadır. Bu bölüm motive edici bir senaryo vermekte ve probleme buna göre çözüm getirmektedir. Burada öncelikle SKSA sistem modeli incelenmiştir. Enerji bilinçli yol planlama problemi daha sonra daha açık bir şekilde tanımlanmıştır.

A. Sistem Modeli

Şekil 2'de Ağ modeli gösterilmiştir. Her sensör düğümü, bir su altı akustik ağı aracılığıyla gemi düğümlerine veri göndermektedir. Manyetik rezonans kuplaj OSA'ları dinlenmek üzere bir şarj istasyonuna dönmeden önce her bir sensör düğümünü şarj etmektedir. Verileri mobil olarak toplanmaktadır. Su altı sensörlerinin enerji tüketimi dengesi bir SKSA sorunudur. Çeşitli araştırmalarda [34, 35, 36], su altı verilerini toplayan OSA'lar farklı enerji kullanımını ele almıştır. OSA, enerji kullanımını dengeleme stratejisine göre her sensör düğümünü ziyaret etmektedir.



Şekil 2. OSA'nın, gemi kazalarını önlemek amacıyla anormallik/risk tespiti için denizi izleyen on beş sensörden (S1, S2, ..., S15) veri topladığı SKSA sistem modeli. Tüm verileri topladıktan sonra gemideki veri merkezine iletilir.

B. Problem Tanımı

OSA kullanımı yoluyla enerji bilinçli yol planlama problemi, gezici satıcı problemi (GSP) [49]–[51] olarak sınıflandırılmaktadır. Akıllı Evrimsel Algoritma ve Klasik Arama Algoritması, GSP'nin çözümlenmesi sürecinde genellikle kullanılan iki temel yaklaşımdır. Açgözlü algoritma, yapay potansiyel alan yaklaşımı ve hızlı ilerleme algoritmasının tümü, daha önce bahsedilen kategoriye giren algoritma örnekleridir. Genetik algoritma

gibi biyolojik algoritma ve en yakın komşu algoritması gibi yöntemler ikinci kategoriye girmektedir.

Bu bölümde, her bir sensör düğümü çifti arasındaki mesafeyi içeren OSA'nin enerji bilinçli yol planlama problemi ele alınmıştır. En belirgin NP-zor optimizasyon problemi GSP'dir [50], [51]. GSP, bir satıcı için evden başlayan, bir dizi lokasyonu ziyaret eden ve her şehir bir kez ziyaret edildiğinde minimum yolculuk mesafesiyle orijinal yere dönen bir rota bulur [52].

m tane sensör düğümünün olduğu bir GSP probleminde i . düğümün j . düğüme uzaklığı c_{ij} ile gösterilsin. Ayrıca, x_{ij} i . Düğümün ardından j . Düğümün ziyaret edilirse 1, ziyaret edilmezse 0 değeri alabilen ikili (binary) bir değişken olsun. Bu durumda bu makalede incelenen enerji farkında yol planlaması problemi, NP-zor bir GSP problemi olarak şu şekilde ele alınabilir [53]:

$$\min_{x_{ij}} \sum_{j=1}^m \sum_{i=1}^m c_{ij} x_{ij}$$

öyleki

$$\sum_{i=1}^m x_{ij} = 1, j = 1, \dots, m$$

$$\sum_{j=1}^m x_{ij} = 1, i = 1, \dots, m$$

$$\sum_{i \in K} \sum_{j \in K} x_{ij} \leq |K| - 1, \forall K \subset \{1, \dots, m\}$$

IV. ÖNERİLEN ENERJİ FARKINDA YOL PLANLAMASI

Bu problemi bir GSP problemi olarak ele alarak şu algoritmalar sunulmuştur. Bunlar; En Yakın Komşu (EYK) Tabanlı Yaklaşım, Grey Wolf Optimizer (GWO) Tabanlı Yaklaşımı ve Genetik Algoritma (GA) Tabanlı Yaklaşımıdır.

A. En Yakın Komşu (EYK) Tabanlı Yaklaşımı

Bu problem bir TSP olarak ele alınmakta ve bir yaklaşım (approximation) algoritması olan En Yakın Komşu Algoritmasına dayalı bir 3 boyutlu yol planlama çözümü önerilmektedir [54].

B. Grey Wolf Optimizer (GWO) Tabanlı Yaklaşımı

Bu problem bir TSP olarak ele alınmakta ve Grey Wolf Optimizer Algoritmasına dayalı bir 3 boyutlu yol planlama çözümü önerilmektedir [55]. GWO, GA'ya göre daha sadedir fakat zayıf yakınsama hızı, düşük çözüm hassasiyeti ve yerel en iyi eğilim dezavantajları da vardır.

C. Genetik Algoritma (GA) Tabanlı Yaklaşımı

Bu problem bir GSP olarak ele alınmıştır ve Genetik Algoritmayı [56], [57] temel alan bir 3 boyutlu yol planlama çözümü önerilmektedir. Genetik algoritmaların temel prensibi karmaşık optimizasyon problemlerini biyolojik evrimi taklit ederek çözmektir. GSP sorunlarının üstesinden gelmek için genetik algoritmanın uygulanmasındaki ilk adımlar, GSP çözümünün bireylerini tanımlamak ve popülasyonu başlatmaktır. Popülasyonun her üyesi bir uygunluk fonksiyonuna göre

derecelendirilmekte ve seçim, çaprazlama ve mutasyon gibi genetik süreçler için en uygun bireyler seçilmektedir. Genetik algoritmanın sonlandırma kriteri seçilen maksimum yineleme sayısıdır. Bu işe bireysel uygunluk, toplam rota boyutu veya toplam OSA enerji tüketimidir. Tüm algılama düğümlerinin mesafelerini toplayarak, bu durumda her bireyin uygunluğunu belirlenebilir.


V. SAYISAL SONUÇLAR

Bu bölümde, her sensör düğümü çifti arasındaki mesafeyi içeren OSA'nın 3 boyutlu enerji duyarlı yol planlama problemi için algoritmaların performansını değerlendirilmektedir. Simülasyonlar için sensör düğümlerini rastgele konumlandırarak $500\text{ m} \times 500\text{ m} \times 500\text{ m}$ 'lık bir alan oluşturulmuştur (İlgili çalışmalarda benzer boyut uzunluğu ve mesafe aralığı seçilmektedir).

İlk alt bölümde OSA ve 25 sensörden oluşan bir senaryoyu ele alınmaktadır. İkinci alt bölümde OSA ve 50 düğüm içeren bir senaryoyu ele alınmaktadır. Üçüncü alt bölümde OSA ve 75 sensörden oluşan bir senaryoyu ele alınmaktadır. Son alt bölümde OSA ve 100 düğüm içeren bir senaryoyu ele alınmaktadır.

A. 25-sensörlü senaryo

Bu alt bölümde 25 düğüm ve tek bir OSA içeren bir senaryoyu ele alacağız. Şekil 3, $500\text{ m} \times 500\text{ m} \times 500\text{ m}$ alandaki 25 düğümün konumunu göstermektedir.



Şekil 3. Sensör düğümlerinin koordinatları


25 düğümün konumları şu şekildedir: $\{(147, 269, 390), (164, 118, 455), (251, 330, 191), (59, 29, 453), (369, 66, 148), (449, 419, 445), (484, 66, 2), (361, 465, 36), (400, 152, 307), (483, 294, 43), (25, 448, 469), (428, 393, 104), (41, 342, 453), (314, 42, 468), (300, 159, 393), (163, 388, 168), (373, 297, 241), (391, 227, 292), (260, 417, 73), (294, 324, 457), (451, 392, 259), (474, 150, 42), (204, 17, 114), (55, 350, 249), (3, 483, 171)\}$

Bu parametrelerin farklı alt kümelerini dikkate alarak elde edilen rota bulma sorununu bir GSP problemi olarak ele alarak; aşağıdaki “En Yakın Komşu (EYK) Tabanlı Yaklaşım, Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım ve Genetik Algoritma (GA) Tabanlı Yaklaşım” algoritmalarının başarımları incelenmektedir.

1. En Yakın Komşu (EYK) Tabanlı Yaklaşım

Bu alt bölümde, 3D GSP problemi için EYK tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 4, Şekil 3'teki 25 düğümü ziyaret etmek için EYK'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 4. En Yakın Komşu (EYK) tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 4407 m 'dir. 0.080580 saniyede bu çözüme ulaşılmaktadır.

2. Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GWO tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 5, Şekil 3'teki 25 düğümü ziyaret etmek için GWO'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 5. Grey Wolf Optimizasyon Algoritması tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 4663 m'dir. 9.028811 saniyede bu çözüme ulaşılmaktadır.

3. Genetik Algoritma (GA) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GA tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 6, Şekil 3'teki 25 düğümü ziyaret etmek için GA'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 6. Genetik Algoritma tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 3934 m'dir. 2.321449 saniyede bu çözüme ulaşılmaktadır.

4. Karşılaştırma

Şekil 7, Şekil 3'te verilen 25 sensör düğümü ziyaret etmek için OSA'nın farklı algoritmalarla (EYK Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım ve GA Tabanlı Yaklaşım) kat ettiği toplam mesafeyi göstermektedir. Şekil 7'den 25 düğüm senaryosu için hazırlanan algoritmaların performansı amacıyla aşağıdaki gözlemler yapılabilmektedir. Genel eğilim göz önüne alındığında, EYK tabanlı yaklaşım ve GA Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım göre daha iyi performans göstermektedir. EYK tabanlı yaklaşım, GA tabanlı Yaklaşım göre biraz daha uzun bir yol önerse de, EYK tabanlı Yaklaşım, GA tabanlı yaklaşımın çözüme ulaşma süresine (2.321449 sn) göre çözüme çok daha kısa sürede (0.080580 sn) ulaşmaktadır (28.8 kat hızlı).



Şekil 7. 25 düğümün tüm algoritmalar (GWO tabanlı Yaklaşım ve GA tabanlı Yaklaşım) tarafından 1000 yinelemede ziyaret edilmesi için elde edilen yol uzunlukları (EYK tabanlı yaklaşım yinelemeli olmasa da diğer algoritmaların farklı yineleme sayılarında performansı ile ilgili kıyaslama için bu şekle eklendi)

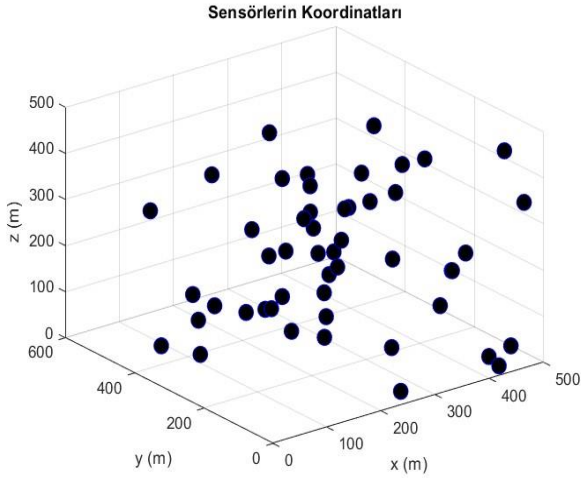
Tablo 1'den aşağıdaki gözlemlerin yapılması mümkündür. İlk yinelemede GA ve GWO 8 km gibi yüksek yol uzunlukları ile başlarken EYK 4.41 km civarı çözümü çok hızlı elde etmiştir. 100.ncü yinelemede GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan önemli ölçüde daha iyi sonuçlar elde etmektedir (0.88 Km, yani GWO tabanlı yaklaşımdan %17 daha az). 100.ncü yinelemeden itibaren, GA tabanlı yaklaşım, GWO ve EYK tabanlı yaklaşımlardan daha iyi sonuçlar elde etmektedir. 1000.nci yinelemede de, GA tabanlı yaklaşım GWO tabanlı yaklaşımlardan önemli ölçüde daha iyi bir performans sergilerken (730 m, yani GWO tabanlı yaklaşımdan %15.7 daha az), EYK'dan kısa bir yolu elde etmekte iken EYK çok daha hızlı ve pratik bir çözüm sunmaktadır.

TABLO I. YİNELEME SAYISINA GÖRE ALGORİTMALAR (GWO TABANLI YAKLAŞIM VE GA TABANLI YAKLAŞIM) TARAFINDAN 25 DÜĞÜMÜN ZİYARET EDİLMESİ İÇİN (KM CİNSİNDEN) TOPLAM MESAFE (EYK TABANLI YAKLAŞIM YİNELEMELİ OLMASA DA DİĞER ALGORİTMALARIN FARKLI YİNELEME SAYILARINDA PERFORMANSI İLE İLGİLİ KIYASLAMA İÇİN BU ŞEKLE EKLENDİ)

yine	100	200	300	400	500	600	700	800	900	1000
GWO	5.14	4.74	4.66	4.66	4.66	4.66	4.66	4.66	4.66	4.66
GA	4.26	3.97	3.97	3.93	3.93	3.93	3.93	3.93	3.93	3.93
EYK	4.41	4.41	4.41	4.41	4.41	4.41	4.41	4.41	4.41	4.41

B. 50-sensörlü senaryo

Bu alt bölümde 50 düğüm ve tek bir OSA içeren bir senaryoyu ele alacağız. Şekil 8, 500 m × 500 m × 500 m alandaki 50 düğümün konumunu göstermektedir.



Şekil 8. Sensör düğümlerin koordinatları


50 düğümün konumları şu şekildedir: { (440, 20, 472), (500, 57, 325), (283, 289, 65), (292, 309, 106), (55, 147, 388), (452, 20, 45), (236, 381, 178), (423, 9, 16), (157, 461, 36), (75, 28, 450), (141, 72, 153), (290, 354, 346), (2, 213, 111), (146, 175, 125), (156, 207, 283), (447, 261, 360), (106, 139, 228), (448, 482, 170), (426, 110, 221), (487, 279, 21), (257, 240, 184), (323, 160, 225), (139, 20, 384), (294, 106, 400), (412, 353, 409), (437, 60, 12), (239, 5, 27), (256, 270, 219), (317, 388, 242), (207, 297, 388), (167, 154, 441), (148, 463, 94), (185, 103, 278), (270, 445, 26), (346, 261, 303), (387, 232, 380), (397, 414, 211), (29, 368, 61), (150, 118, 369), (205, 65, 489), (116, 350, 124), (223, 359, 458), (458, 201, 137), (13, 98, 242), (338, 186, 18), (58, 445, 314), (428, 152, 166), (212, 156, 281), (208, 330, 93), (100, 333, 420) }

Bu parametrelerin farklı alt kümelerini dikkate alarak elde edilen rota bulma sorununu bir GSP problemi olarak ele alarak; aşağıdaki “En Yakın Komşu (EYK) Tabanlı Yaklaşım, Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım ve Genetik Algoritma (GA) Tabanlı Yaklaşım” algoritmalarının performansları değerlendirilmektedir.

1. En Yakın Komşu (EYK) Tabanlı Yaklaşım

Bu alt bölümde, 3D GSP problemi için EYK tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 9, Şekil 8'deki 50 düğümü ziyaret etmek için EYK'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 9. En Yakın Komşu (EYK) tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 6358 m'dir. 0.107617 saniyede bu çözüme ulaşılmaktadır.

2. Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GWO tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 10, Şekil 8'deki 50 düğümü ziyaret etmek için GWO'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 10. Grey Wolf Optimizasyon Algoritması tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 8837 m'dir. 9.689545 saniyede bu çözüme ulaşılmaktadır.

3. Genetik Algoritma (GA) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GA tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 11, Şekil 8'deki 50 düğümü ziyaret etmek için GA'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 11. Genetik Algoritma tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 6421 m'dir. 3.689545 saniyede bu çözüme ulaşılmaktadır.

4. Karşılaştırma

Şekil 12, Şekil 8'te verilen 50 sensör düğümü ziyaret etmek için OSA'nın farklı algoritmalarla (EYK Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım ve GA Tabanlı Yaklaşım) kat ettiği toplam mesafeyi göstermektedir. Şekil 12'den 50 düğüm senaryosu için hazırlanan algoritmaların performansı amacıyla aşağıdaki gözlemler yapılabilmektedir. Genel eğilim göz önüne alındığında, EYK tabanlı yaklaşım ve GA Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım göre daha iyi performans göstermektedir. EYK tabanlı yaklaşım, 500.ncü yinelemeye kadar GA tabanlı Yaklaşım'dan daha iyi sonuç vermeye kalmamakta, aynı zamanda EYK tabanlı Yaklaşım, GA tabanlı yaklaşımın çözüme ulaşma süresine (3.689545 sn) göre çözüme çok daha kısa sürede (0.107617 sn) ulaşmaktadır (34.3 kat hızlı).



Şekil 12. 50 düğümün tüm algoritmalar (GWO tabanlı Yaklaşım ve GA tabanlı Yaklaşım) tarafından 1000 yinelemede ziyaret edilmesi için elde edilen yol uzunlukları (EYK tabanlı yaklaşım yinelemeli olmasa da diğer algoritmaların farklı yineleme sayılarında performansı ile ilgili kıyaslama için bu şekle eklendi)

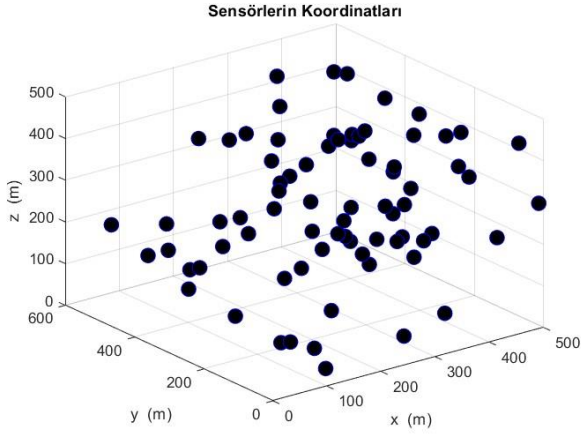
Tablo 2'den aşağıdaki gözlemlerin yapılması mümkündür. İlk yinelemede GA ve GWO 14-15 km gibi yüksek yol uzunlukları ile başlarken EYK 6.36 km civarı çözümü çok hızlı elde etmiştir. 100.ncü yinelemede GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan önemli ölçüde daha iyi sonuçlar elde etmektedir (3.00 Km, yani GWO tabanlı yaklaşımdan %32 daha az). 300.ncü yinelemede, EYK tabanlı yaklaşım, GWO ve GA tabanlı yaklaşımlardan daha iyi sonuçlar elde etmektedir. 600.ncü yinelemede, GA tabanlı yaklaşım, EYK tabanlı yaklaşımdan daha iyi sonuçlar elde etmektedir. 1000.ncü yinelemesinde, GA tabanlı yaklaşım GWO tabanlı yaklaşımlardan önemli ölçüde daha iyi bir performans sergilerken (2610 m, yani GWO tabanlı yaklaşımdan %29,5 daha az), EYK'dan kısa bir yolu elde etmekte ve EYK çok daha hızlı ve pratik bir çözüm sunmaktadır.

TABLO II. YİNELEME SAYISINA GÖRE ALGORİTMALAR (GWO TABANLI YAKLAŞIM VE GA TABANLI YAKLAŞIM) TARAFINDAN 50 DÜĞÜMÜN ZİYARET EDİLMESİ İÇİN (KM CİNSİNDEN) TOPLAM MESAFE (EYK TABANLI YAKLAŞIM YİNELEMELİ OLMASA DA DİĞER ALGORİTMALARIN FARKLI YİNELEME SAYILARINDA PERFORMANSI İLE İLGİLİ KIYASLAMA İÇİN BU ŞEKLE EKLENDİ)

yine	100	200	300	400	500	600	700	800	900	1000
GWO	11.9	11.3	11.1	10.7	10.2	9.97	9.25	8.98	8.84	8.84
GA	8.09	7.38	6.71	6.42	6.33	6.33	6.31	6.28	6.27	6.23
EYK	6.36	6.36	6.36	6.36	6.36	6.36	6.36	6.36	6.36	6.36

C. 75-sensörlü senaryo

Bu alt bölümde 75 düğüm ve tek bir OSA içeren bir senaryoyu ele alacağız. Şekil 13, 500 m × 500 m × 500 m alandaki 50 düğümün konumunu göstermektedir.



Şekil 13. Sensör düğümlerinin koordinatları


75 düğümün konumları şu şekildedir: {(307, 202, 142), (75, 84, 235), (206, 180, 222), (126, 45, 16), (477, 324, 396), (357, 335, 129), (277, 224, 211), (160, 490, 71), (405, 98, 382), (412, 298, 190), (363, 392, 359), (299, 168, 218), (357, 330, 387), (137, 27, 342), (218, 494, 164), (497, 278, 354), (429, 394, 278), (293, 270, 420), (443, 46, 218), (252, 373, 291), (436, 116, 339), (497, 10, 295), (475, 33, 438), (357, 445, 111), (256, 42, 276), (374, 476, 164), (133, 185, 22), (107, 276, 60), (10, 318, 236), (268, 95, 336), (309, 218, 455), (470, 412, 403), (9, 375, 202), (250, 41, 457), (125, 27, 162), (346, 293, 401), (91, 92, 74), (338, 324, 189), (412, 430, 475), (413, 470, 464), (105, 147, 410), (286, 189, 179), (123, 189, 345), (54, 296, 187), (414, 422, 157), (456, 340, 103), (164, 137, 16), (61, 190, 345), (366, 346, 363), (193, 428, 394), (81, 434, 230), (322, 489, 326), (117, 101, 238), (181, 498, 375), (311, 438, 262), (22, 278, 154), (445, 298, 239), (298, 88, 17), (433, 270, 89), (322, 492, 477), (335, 89, 232), (147, 375, 175), (230, 340, 495), (323, 158, 375), (108, 173, 471), (443, 234, 156), (220, 415, 165), (118, 262, 499), (455, 169, 419), (323, 9, 93), (297, 304, 390), (4, 473, 240), (353, 456, 268), (327, 132, 305), (412, 238, 401) }

Bu parametrelerin farklı alt kümelerini dikkate alarak eldeki rota bulma sorununu bir GSP problemi olarak ele alarak; aşağıdaki “En Yakın Komşu (EYK) Tabanlı Yaklaşım, Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım ve Genetik Algoritma (GA) Tabanlı Yaklaşım” algoritmalarının performansları değerlendirilmektedir.

1. En Yakın Komşu (EYK) Tabanlı Yaklaşım

Bu alt bölümde, 3D GSP problemi için EYK tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 14, Şekil 13'teki 75 düğümü ziyaret etmek için EYK'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 14. En Yakın Komşu (EYK) tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 7372 m'dir. 0.133651 saniyede bu çözüme ulaşılmaktadır.

2. Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GWO tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 15, Şekil 13'teki 75 düğümü ziyaret etmek için GWO'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 15. Grey Wolf Optimizasyon Algoritması tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 12879 m'dir. 10.610287 saniyede bu çözüme ulaşılmaktadır.

3. Genetik Algoritma (GA) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GA tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 15, Şekil 13'teki 75 düğümü ziyaret etmek için GA'nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 16. Genetik Algoritma tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 8844 m'dir. 4.879424 saniyede bu çözüme ulaşılmaktadır.

4. Karşılaştırma

Şekil 17, Şekil 13'te verilen 75 sensör düğümü ziyaret etmek için OSA'nın farklı algoritmalarla (EYK Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım ve GA Tabanlı Yaklaşım) kat ettiği toplam mesafeyi göstermektedir. Şekil 17'den 75 düğüm senaryosu için hazırlanan algoritmaların performansı amacıyla aşağıdaki gözlemler yapılabilmektedir. Genel eğilim göz önüne alındığında, EYK tabanlı yaklaşım ve GA Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım göre daha iyi performans göstermektedir. EYK tabanlı yaklaşım, yalnızca GA tabanlı Yaklaşım'dan daha iyi sonuç vermekle kalmamakta, aynı zamanda EYK tabanlı Yaklaşım, GA tabanlı yaklaşımın çözüme ulaşma süresine (4.879424 sn) göre çözüme çok daha kısa sürede (0.133651 sn) ulaşmaktadır (36.5 kat hızlı). Tüm bunlar göz önüne alındığında sensör düğüm sayısının 50 düğümde 75 düğüm çıkarılması, EYK yaklaşımında önemli bir fark yaratmaktadır.



Şekil 17. 75 düğümün tüm algoritmalar (GWO tabanlı Yaklaşım ve GA tabanlı Yaklaşım) tarafından 1000 yinelemede ziyaret edilmesi için elde edilen yol uzunlukları (EYK tabanlı yaklaşım yinelemeli olmasa da diğer algoritmaların farklı yineleme sayılarında performansı ile ilgili kıyaslama için bu şekle eklendi)

Tablo III'den aşağıdaki gözlemlerin yapılması mümkündür. İlk yinelemede GA ve GWO 22 km gibi yüksek yol uzunlukları ile başlarken EYK 7.37 km civarı çözümü çok hızlı elde etmiştir. 100.ncü yinelemede GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan önemli ölçüde daha iyi sonuç elde etmektedir (6.10 Km fark, yani GWO tabanlı yaklaşımdan %30 daha az). 300.ncü yinelemede, GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan neredeyse iki kat iyi sonuç elde etmektedir (8.80 Km fark, yani GWO tabanlı yaklaşımdan %46 daha az). 600.ncü yinelemede, GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan daha iyi sonuç elde etmektedir (5.83 Km fark, yani GWO tabanlı yaklaşımdan %39 daha az). 1000.ncü yinelemede, GA tabanlı yaklaşım GWO tabanlı yaklaşımlardan önemli ölçüde daha iyi bir performans sergilemektedir (4.06 km, yani GWO tabanlı yaklaşımdan %31,5 daha az).


Diğer yandan, GA, 1000. Yineleme sayısında dahi EYK'nın başardığından (7.37 km) kısa bir yolu elde edememiştir. Bunun yanında, EYK GA'ya ve GWO'ya göre de çok daha hızlı ve pratik bir çözüm sunmaktadır.

TABLO III. YİNELEME SAYISINA GÖRE ALGORİTMALAR (GWO TABANLI YAKLAŞIM VE GA TABANLI YAKLAŞIM) TARAFINDAN 75 DÜĞÜMÜN ZİYARET EDİLMESİ İÇİN (KM CİNSİNDEN) TOPLAM MESAFE (EYK TABANLI YAKLAŞIM YİNELEMELİ OLMASA DA DİĞER ALGORİTMALARIN FARKLI YİNELEME SAYILARINDA PERFORMANSI İLE İLGİLİ KIYASLAMA İÇİN BU ŞEKLE EKLENDİ)

yine	100	200	300	400	500	600	700	800	900	1000
GWO	20.0	19.6	19.1	18.1	17.8	15.1	14.5	13.3	12.9	12.9
GA	13.9	11.0	10.3	9.67	9.44	9.27	9.05	8.96	8.89	8.84
EYK	7.37	7.37	7.37	7.37	7.37	7.37	7.37	7.37	7.37	7.37

D. 100-sensörlü senaryo

Bu alt bölümde 100 düğüm ve tek bir OSA içeren bir senaryo ele alınmıştır. Şekil 18, $500\text{ m} \times 500\text{ m} \times 500\text{ m}$ alandaki 100 düğümün konumunu göstermektedir.



Şekil 18. Sensör düğümlerinin koordinatları

100 düğümün konumları şu şekildedir:


{ (408, 82, 323), (453, 398, 190), (64, 156, 406), (457, 265, 267), (317, 83, 176), (49, 301, 470), (140, 132, 438), (274, 328, 276), (479, 345, 312), (483, 375, 294), (79, 226, 104), (486, 42, 151), (479, 115, 236), (243, 457, 116), (401, 77, 423), (71, 413, 98), (211, 270, 113), (458, 499, 86), (397, 40, 114), (480, 222, 218), (328, 54, 156), (18, 481, 462), (425, 3, 216), (467, 388, 93), (340, 409, 453), (379, 435, 490), (372, 43, 220), (197, 200, 56), (328, 130, 130), (86, 401, 205), (354, 216, 298), (16, 456, 132), (139, 91, 302), (24, 132, 356), (49, 73, 111), (412, 69, 59), (348, 435, 149), (159, 290, 160), (476, 275, 213), (18, 73, 254), (220, 427, 43), (191, 312, 132), (383, 176, 401), (398, 257, 15), (94, 201, 465), (245, 38, 366), (223, 120, 245), (324, 62, 290), (355, 92, 119), (378, 120, 230), (139, 209, 482), (340, 25, 274), (328, 452, 261), (82, 473, 116), (60, 246, 245), (250, 245, 313), (480, 169, 340), (171, 451, 198), (293, 185, 184), (112, 56, 494), (376, 391, 19), (128, 195, 443), (253, 121, 457), (350, 202, 399), (446, 49, 50), (480, 66, 131), (274, 472, 168), (70, 479, 340), (75, 288, 69), (129, 30, 361), (421, 118, 54), (128, 177, 327), (408, 411, 248), (122, 8, 390), (465, 22, 358), (175, 85, 452), (99, 325, 446), (126, 366, 168), (309, 324, 350), (237, 226, 99), (176, 274, 16), (416, 149, 373), (293, 373, 251), (275, 95, 240), (459, 344, 453), (143, 92, 305), (379, 185, 309), (377, 313, 430), (191, 391, 403), (284, 41, 289), (38, 465, 92), (27, 388, 120), (266, 244, 444), (390, 218, 15), (468, 224, 245), (65, 154, 84), (285, 255, 490), (235, 256, 357), (6, 409, 251), (169, 398, 236) }

Bu parametrelerin farklı alt kümeleri dikkate alınarak bu problemi bir GSP problemi olarak ele alınmış ve “En Yakın Komşu (EYK) Tabanlı Yaklaşım ve Genetik Algoritma (GA) Tabanlı Yaklaşım” algoritmalarının performansı kriterlerine göre değerlendirilmiştir.

1. En Yakın Komşu (EYK) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için EYK tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 19, Şekil 18’deki 100 düğümü ziyaret etmek için EYK’nin 1000.nci yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 19. En Yakın Komşu algoritması tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 9045 m’dir. 0.173103 saniyede bu çözüme ulaşılmaktadır.

2. Grey Wolf Optimizasyon Algoritması (GWO) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GWO tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 20, Şekil 18’teki 100 düğümü ziyaret etmek için GWO’nin 1000 yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 20. Grey Wolf Optimizasyon Algoritması tarafından 1000 yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 17794 m'dir. 11.294668 saniyede bu çözüme ulaşılmaktadır.

3. Genetik Algoritma (GA) Tabanlı Yaklaşım

Bu alt bölümde, 3 boyutlu GSP problemi için GA tabanlı bir çözümün performansını değerlendirilmektedir.

Şekil 21, Şekil 18'deki 100 düğümü ziyaret etmek için GA'nin 1000.nci yinelemede elde ettiği yol planlama çözümünü göstermektedir.




Şekil 21. Genetik Algoritma tarafından 1000.nci yinelemede elde edilen yol planlama çözümü

Bu çözüme göre toplam yol uzunluğu 10837 m'dir. 6.294668 saniyede bu çözüme ulaşılmaktadır.

4. Karşılaştırma

Şekil 20, Şekil 17'de verilen 100 sensör düğümü ziyaret etmek için OSA'nın farklı algoritmalarla (EYK Tabanlı Yaklaşım, GWO Tabanlı Yaklaşım ve GA Tabanlı Yaklaşım) kat ettiği toplam mesafeyi göstermektedir. Şekil 20'den, 100 sensör senaryosu için algoritmaların performansını aşağıdaki gözlemleri yapabiliriz. Genel eğilim göz önüne alındığında, EYK Tabanlı Yaklaşım, GWO ve GA Tabanlı Yaklaşım göre daha iyi performans göstermektedir. EYK tabanlı yaklaşım, yalnızca GWO tabanlı yaklaşımdan ve GA Tabanlı Yaklaşımdan daha iyi sonuç vermemekle kalmaz, aynı zamanda EYK tabanlı Yaklaşım, GA tabanlı yaklaşımın çözüme ulaşma süresine (6.294668 sn) göre çözüme çok daha kısa sürede (0.173103 sn) ulaşmaktadır (36.4 kat hızlı). Tüm bunlar göz önüne alındığında sensör düğüm sayısının 100 düğüme çıkarılması, EYK yaklaşımında önemli bir fark yaratmaktadır.



Şekil 22. 100 düğümün tüm algoritmalar (GWO tabanlı Yaklaşım ve GA tabanlı Yaklaşım) tarafından 1000 yinelemede ziyaret edilmesi için elde edilen yol uzunlukları (EYK tabanlı yaklaşım yinelemeli olmasa da diğer algoritmaların farklı yineleme sayılarında performansı ile ilgili kıyaslama için bu şekle eklendi)

Tablo IV'den aşağıdaki gözlemleri yapabiliriz. İlk yinelemede GA ve GWO 28-30 km gibi yüksek yol uzunlukları ile başlarken EYK 9.05 km civarı çözümü çok hızlı elde etmiştir. 100.ncü yinelemede GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan önemli ölçüde daha iyi sonuçlar elde etmektedir (8.00 Km, yani GWO tabanlı yaklaşımdan %29 daha az). 300.ncü yinelemede, EYK tabanlı yaklaşım, GWO ve GA tabanlı yaklaşımlardan daha iyi sonuçlar elde etmektedir. 600.ncü yinelemede, GA tabanlı yaklaşım, EYK tabanlı yaklaşımdan daha iyi sonuçlar elde etmektedir. 1000.nci yinelemesinde, GA tabanlı yaklaşım, GWO tabanlı yaklaşımdan önemli ölçüde daha iyi bir performans sergilerken (7.00 km, yani GWO tabanlı yaklaşımdan %39,3 daha az), EYK tabanlı yaklaşım, GWO ve GA'dan kısa bir yolu elde ederken çok daha hızlı ve pratik bir çözüm önermektedir.

TABLO IV. YİNELEME SAYISINA GÖRE ALGORİTMALAR (GWO TABANLI YAKLAŞIM VE GA TABANLI YAKLAŞIM) TARAFINDAN 100 DÜĞÜMÜN ZİYARET EDİLMESİ İÇİN (KM CİNSİNDEN) TOPLAM MESAFE (EYK TABANLI YAKLAŞIM YİNELEMELİ OLMASA DA DİĞER ALGORİTMALARIN FARKLI YİNELEME SAYILARINDA PERFORMANSI İLE İLGİLİ KIYASLAMA İÇİN BU ŞEKLE EKLENDİ)

yine	100	200	300	400	500	600	700	800	900	1000
GWO	27.5	27.5	27.5	27.5	27.5	27.5	24.4	21.6	19.5	17.8
GA	19.5	16.9	14.5	13.2	12.7	12.1	11.8	11.3	11.2	10.8
EYK	9.05	9.05	9.05	9.05	9.05	9.05	9.05	9.05	9.05	9.05

VI. SONUÇ

Günümüzde araştırmalar daha uzun menzile ve daha geniş keşif aralıklarına odaklanmaktadır. Bu araştırmada, sualtı kablosuz sensör ağı (SKSA) şarj etmek için sınırlı batarya gücüne sahip otonom bir su altı aracı kullanarak verimli bir yol planlama yaklaşımı sunulmakta ve toplam enerji kullanımını teorik olarak analiz edilmektedir.

SKSA'nın sınırlı enerji tedariki nedeniyle sorun şarj perspektifinden ele alınmıştır. Birkaç OSA, keşif ağını genişletmek ve SKSA'yı şarj etmek için iyi bir yaklaşımdır. Ayrıca, uygun dalış bölgeleri seçilerek düğümün konumu ve veri akışını dikkate alan bir yol tasarlanarak şarj verimliliği ve keşif menzilinönemli ölçüde artırılabilmesi mümkündür. Otonom sualtı araçlarına (OSA) ilişkin veri toplama sorunları, Genetik Algoritma Tabanlı Yaklaşım, Grey Wolf Optimizer Tabanlı Yaklaşım, En Yakın Komşu Temelli Yaklaşım algoritmalarıyla çözülebilmektedir. Benzetimler, özellikle de sensör sayısı arttıkça OSA rota planlama sisteminin En Yakın Komşu Algoritması tabanlı bir yaklaşım kullanarak önceki algoritmalara göre daha iyi bir çözümü çok daha kısa bir sürede bulduğunu göstermektedir.

KAYNAKLAR

- [1] Acarer T., The Turkish Model For Improving Imo Survey Results And Reducing Ship Accidents, Dokuz Eylül University Maritime Faculty Journal, Vol:11, Issue:1, Year:2019.
- [2] Aygün, C. (2012). Türkiye ile Avrupa Birliği'nde Uygulanan Deniz Ulaştırma Politikaları ve Ekonomiye Etkileri, T.C: İstanbul Üniversitesi Deniz Bilimleri ve İşletmeciliği Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- [3] International Chamber of Shipping, (2020). Description of the Subject International Chamber of Shipping (ICS). <http://en.reingex.com/Chamber-Shipping.shtml#:~:text=The%20purpose%20of%20the%20International,transporting%20all%20types%20of%20cargo>
- [4] UNCTAD/ RMT/ 2018: REVIEW OF MARITIME TRANSPORT 2018, United Nations publication issued by the United Nations Conference on Trade and Development, ISBN 978-92-1- 112928-1, UNCTAD: Geneva, Switzerland, 2018, https://unctad.org/en/PublicationsLibrary/rmt2018_en.pdf.
- [5] Butt N., Johnson D., Pike K., Pryce-Roberts N., Vigar., N., (2012): 15 Years of Shipping Accidents: A review for WWF, Southampton Solent University
- [6] Rodrigue J.P., (2017): The Geography of Transport Systems, The spatial organization of transportation and mobility, Chapter 5 – Transportation Modes, Maritime Transportation, Main Maritime Shipping Routes, 2017. https://transportgeography.org/?page_id=2067
- [7] Kodak, G., Acarer, T. (2021). İstanbul Boğazı'nda deniz trafik düzenlemelerinin kaza oranına etkisinin değerlendirilmesi. Aquatic Research, 4(2), 181-207. <https://doi.org/10.3153/AR21015>
- [8] BBC News, "Egypt's Suez Canal blocked by huge container ship", 24 March 2021, available at <https://www.bbc.com/news/world-middle-east-56505413>
- [9] J. M. Lee, E. Y. Wong. Suez Canal blockage: an analysis of legal impact, risks and liabilities to the global supply chain. MATEC Web Conf. 339 01019 (2021).
- [10] O. Ozkanlısoy, E. Akkartal, The Effect of Suez Canal Blockage on Supply Chains. Dokuz Eylül Üniversitesi Denizcilik Fakültesi Dergisi. Haziran 2022;14(1):51- 79.
- [11] Tianhang Gao & Jing Lu (2019). The impacts of strait and canal blockages on the transportation costs of the Chinese fleet in the shipping network, Maritime Policy & Management, 46:6, 669-686.
- [12] S. Fan, Z. Yang, J. Wang, J. Marsland, "Shipping accident analysis in restrictedwaters: Lesson from the Suez Canal blockage in 2021", Ocean Engineering, vol. 266, Part 5, 2022, 113119.
- [13] T. Acarer. Endüstri'deki Gelişmelerin Denizcilik İşletmelerine Ait Gemilerin Yönetiminde Temin Ettiği Yeni Olanaklar ve İnsansız Gemiler, Mersin Üniversitesi Denizcilik ve Lojistik Araştırmaları Dergisi, Cilt:5 Sayı:2 Yıl:2023, Sayfa:122-153.
- [14] Acarer Tayfun, VHF Kısa Mesafe Deniz Haberleşmesinin Data İletişimine Dönüşmesinin Deniz İşletmelerinin Gemi Yönetimleri İçin Temin Edeceği Olanaklar, Denizcilik Araştırmaları Dergisi: Amfora, Cilt 2 – Sayı 3 – Haziran 2023 / Volume 2 - Issue 3 - June 2023.
- [15] Felemban, E.; Shaikh, F.K. Underwater sensor network applications: A comprehensive survey. Int. J. Distrib. Sens. Netw. 2015, 11, 896832–896845.
- [16] Qiu, T.; Zhao, Z. Underwater Internet of Things in Smart Ocean: System Architecture and Open Issues. IEEE Trans. Ind. Inform. 2020, 16, 4297–4307.
- [17] Akyildiz, I.F.; Pompili, D. Underwater acoustic sensor networks: Research challenges. Ad Hoc Netw. 2005, 3, 257–279.
- [18] Li, Q.; Du, X. Energy-efficient data compression for underwater wireless sensor networks. IEEE Access 2020, 8, 73395–73406.
- [19] Cheng, F.; Wang, J. Energy-efficient routing protocols in underwater wireless sensor networks: A survey. IEEE Commun. Surv. Tutor. 2014, 16, 277–294.
- [20] Khan, A.U.; Somasundaraswaran, K. Wireless charging technologies for underwater sensor networks: A comprehensive review. IEEE Commun. Surv. Tutor. 2018, 20, 674–709.
- [21] Pendergast, D.R.; DeMauro, E.P. A rechargeable lithium-ion battery module for underwater use. J. Power Sources 2011, 196, 793–800.
- [22] Blidberg, D.R. The development of autonomous underwater vehicles (AUV); a brief summary. In Proceedings of the IEEE ICRA, Seoul, Republic of Korea, 21–26 May 2001; Volume 4, pp. 122–129.
- [23] Ghafoor, H.; Noh, Y. An overview of next-generation underwater target detection and tracking: An integrated underwater architecture. IEEE Access 2019, 7, 98841–98853.
- [24] Xie, L.; Shi, Y. Rechargeable sensor networks with magnetic resonant coupling. Recharg. Sens. Netw. Technol. Theory Appl. Introd. Energy Harvest. Sens. Netw. 2014, 9, 31–68.
- [25] Lee, J.; Yun, N. A focus on comparative analysis: Key findings of MAC protocols for underwater acoustic communication according to network topology. In Proceedings of the Multimedia, Computer Graphics and Broadcasting: International Conference, Jeju Island, Korea, 8–10 December 2011.

- [26] Zenia, N.Z.; Aseeri, M. Energy-efficiency and reliability in MAC and routing protocols for underwater wireless sensor network: A survey. *J. Netw. Comput. Appl.* 2016, 71, 72–85.
- [27] Khan, M.T.R.; Ahmed, S.H. An energy-efficient data collection protocol with AUV path planning in the internet of underwater things. *J. Netw. Comput. Appl.* 2019, 135, 20–31.
- [28] Su, Y.; Xu, Y. HCAR: A Hybrid-Coding-Aware Routing Protocol for Underwater Acoustic Sensor Networks. *IEEE Internet Things J.* 2023, 10, 10790–10801.
- [29] Kumar, V.; Sandeep, D. Multi-hop communication based optimal clustering in hexagon and voronoi cell structured WSNs. *AEU-Int. J. Electron. Commun.* 2018, 93, 305–316.
- [30] Xie, R.; Jia, X. Transmission-efficient clustering method for wireless sensor networks using compressive sensing. *IEEE Trans. Parallel Distrib. Syst.* 2013, 25, 806–815.
- [31] Yadav, S.; Kumar, V. Hybrid compressive sensing enabled energy efficient transmission of multi-hop clustered UWSNs. *AEU-Int. J. Electron. Commun.* 2019, 110, 152836–152851.
- [32] Sun, Y.; Zheng, M.; Han, X.; Li, S.; Yin, J. Adaptive clustering routing protocol for underwater sensor networks. *Ad Hoc Netw.* 2022, 136, 102953–102965.
- [33] Fan, R.; Jin, Z. A time-varying acoustic channel aware topology control mechanism for cooperative underwater sonar detection network. *Ad Hoc Netw.* 2023, 149, 103228.
- [34] Liu, C.F.; Zhao, Z. A distributed node deployment algorithm for underwater wireless sensor networks based on virtual forces. *J. Syst. Archit.* 2019, 97, 9–19.
- [35] Wei, L.; Han, J. Topology Control Algorithm of Underwater Sensor Network Based on Potential-Game and Optimal Rigid Sub-Graph. *IEEE Access* 2020, 8, 177481–177494.
- [36] Zhu, R.; Boukerche, A. A trust management based secure routing protocol with AUV-aided path repairing for Underwater Acoustic Sensor Networks. *Ad Hoc Netw.* 2023, 149, 103212–103225.
- [37] Yan, Z.; Li, Y. Data collection optimization of ocean observation network based on AUV path planning and communication. *Ocean Eng.* 2023, 282, 114912–114927.
- [38] Shen, G.; Zhu, X. Research on phase combination and signal timing based on improved K-medoids algorithm for intersection signal control. *Wirel. Commun. Mob. Comput.* 2020, 2020, 3240675.
- [39] Gjanci, P.; Petrioli, C. Path finding for maximum value of information in multi-modal underwater wireless sensor networks. *IEEE Trans. Mob. Comput.* 2017, 17, 404–418.
- [40] Yan, J.; Yang, X. Energy-efficient data collection over AUV-assisted underwater acoustic sensor network. *IEEE Syst. J.* 2018, 12, 3519–3530.
- [41] Kan, T.; Mai, R. Design and analysis of a Three-Phase wireless charging system for lightweight autonomous underwater vehicles. *IEEE Trans. Power Electron.* 2018, 33, 6622–6632.
- [42] Ramos, A.G.; García-Garrido, V.J. Lagrangian coherent structure assisted path planning for transoceanic autonomous underwater vehicle missions. *Sci. Rep.* 2018, 8, 4575.
- [43] Cheng, C.; Sha, Q. Path planning and obstacle avoidance for AUV: A review. *Ocean Eng.* 2021, 235, 109355–109368.
- [44] Kumar, S.V.; Jayaparvathy, R. Efficient path planning of AUVs for container ship oil spill detection in coastal areas. *Ocean Eng.* 2020, 217, 107932–107945.
- [45] Golen, E.; Mishra, F. An underwater sensor allocation scheme for a range dependent environment. *Comput. Netw.* 2010, 54, 404–415.
- [46] Yi, Y.; Yang, G.S. Energy balancing and path plan strategy for rechargeable underwater sensor network. In *Proceedings of the 2022-4th International Conference on Advances in Computer Technology, Suzhou, China, 22–24 April 2022*. 8
- [47] Cui Y, Zhu P, Lei G, Chen P, Yang G. Energy-Efficient Multiple Autonomous Underwater Vehicle Path Planning Scheme in Underwater Sensor Networks. *Electronics*. 2023; 12(15):3321.
- [48] Acarer, T. (2024). Energy-Aware Path Planning by Autonomous Underwater Vehicle in Underwater Wireless Sensor Networks for Safer Maritime Transportation. *International Journal of Interactive Multimedia and Artificial Intelligence*.
- [49] P. C. Pop, O. Cosma, C. Sabo, C. P. Sitar, "A comprehensive survey on the generalized traveling salesman problem", *European Journal of Operational Research*, Volume 314, Issue 3, 2024, pp. 819-835.
- [50] Davendra, D.: Travelling Salesman Problem, Theory and Applications. InTech (2010)
- [51] Johnson, D.S., McGeoch, L.A.: The Traveling Salesman Problem: A Case Study, Local Search in Combinatorial Optimization, pp. 215–310. JohnWiley & Sons (1997)
- [52] Gutin, G., Punnen, A. (eds.): The Traveling Salesman Problem and Its Variations. *Combinatorial Optimization*, vol. 12. Kluwer, Dordrecht (2002)
- [53] Hoffman, K.L., Padberg, M. (2001). Traveling salesman problem . In: Gass, S.I., Harris, C.M. (eds) *Encyclopedia of Operations Research and Management Science*. Springer, New York, NY. https://doi.org/10.1007/1-4020-0611-X_1068
- [54] G. Gutin, A. Yeo and A. Zverovitch, Exponential Neighborhoods and Domination Analysis for the TSP, in *The Traveling Salesman Problem and Its Variations*, G. Gutin and A.P. Punnen (eds.), Kluwer (2002) and Springer (2007)
- [55] Mirjalili, S.; Mirjalili, S.M.; Lewis, A. grey wolf optimizer. *Adv. Eng. Softw.* 2014, 69, 46–61.
- [56] D.E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison- Wesley Longman Publishing Co., Inc., 1989.
- [57] Bonabeau, E., Dorigo, M., & Theraulaz, G. (1999). *Swarm intelligence: from natural to artificial systems* (No. 1). Oxford university press.

Özgeçmişler



Ömer Melih Gül (S'17, M'21), Orta Doğu Teknik Üniversitesi (ODTÜ) Elektrik ve Elektronik Mühendisliği Bölümü'nden lisans, yüksek lisans ve doktora derecelerini sırasıyla 2012, 2014 ve 2020 yıllarında aldı. Bu esnada aynı bölümde araştırma görevlisi olarak da görev yaptı. Uluslararası yayınları 11 dergi makalesi, 16 konferans bildirisi ve 4 kitap bölümünü kapsarken ulusal yayınları 3 dergi makalesi ve 3 konferans bildirisini kapsamaktadır.

IEEE Computer Society tarafından 2019 Lance Stafford Larson Üstün Öğrenci Makale Ödülü'nde (2019 Lance Stafford Larson Outstanding Student Paper Award) üçüncülük ödülüne layık görülmüştür. 2021 IEEE Rising Stars Global Konferansı'nda poster yarışmasında üçüncülük ödülüne layık görülmüştür. 2022 yılında Kanada'da Ottawa Üniversitesi Elektrik Mühendisliği ve Bilgisayar Bilimleri Okulu'nda doktora sonrası araştırmacı olarak çalıştı. 2022 yılında 48. Kablosuz Dünya Araştırma Forumu'nda (WWRF) en iyi konferans bildirisi ödülünü aldı. Mevcut durumda, İstanbul'da Bahçeşehir Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Dr. Öğr. Üyesi olarak görev yapmaktadır.

2021'den bu yana IEEE Computer Society'de Region 8 (Avrupa, Orta Doğu ve Afrika Bölgesi) Koordinatörü olarak görev yapmaktadır. Nisan 2023'ten beri IEEE Computer Society Member & Geographic Activities (MGA) Board'da Özel Üye (Member-at-Large) olarak görev yapmaktadır. 2022 IEEE MGA Genç Profesyoneller Başarı Ödülü'ne (2022 IEEE MGA Young Professionals Achievement Award) layık görülmüştür. 2020-2021 yıllarında başkanlığını yaptığı IEEE Türkiye Genç Profesyonel Grup ile 2021 IEEE Region 8 Outstanding Young Professionals Affinity Group Award ve 2022 IEEE MGA Young Professionals Hall of Fame Honorable Mention ödülleri kazanmıştır.



Tayfun Acarer, İstanbul Teknik Üniversitesi Elektronik ve Haberleşme Bölümünden 1980 yılında mezun olan Tayfun ACARER yaklaşık iki yıl özel bir Şirket de Elektronik Mühendisi olarak çalıştıktan sonra sırasıyla PTT Telsiz İşletme Müdürlüğü'nde Müdür, Türk Telekom AŞ'de Müstakil Ünite Müdürü, Kıyı Emniyeti Genel Müdürlüğü'nde Yönetim Kurulu Üyesi ve Genel Müdür Yardımcısı, Bilgi Teknolojileri ve İletişim Üst Kurulunda (BTK) 2 dönem Kurul Başkanı olarak görev yapmıştır.

Tayfun ACARER 1990 yılında İstanbul Üniversitesi İşletme İktisadi Enstitüsünde İhtisas, daha sonra aynı Üniversitede Yüksek Lisans ve Doktora eğitimlerini tamamlayarak 1995 yılında Dr. Müh., 2016 yılında İstanbul Bilgi Üniversitesi'nde Dr. Öğretim Üyesi ünvanını almıştır. Bu tarihten itibaren başta İstanbul Teknik Üniversitesi, İstanbul Üniversitesi, İstanbul Bilgi Üniversitesi, Piri Reis Üniversitesi, Galatasaray Üniversitesi, Bahçeşehir Üniversitesi, İstanbul Sabahattin Zaim Üniversitesi ve İstanbul Aydın Üniversitelerinde Deniz Haberleşme (GMDSS), Elektronik Seyir, Gemi Elektroniği, Bilişim Sistemleri Alt Yapıları, Bilişim Sektöründe Eğilim, Yeni Nesil Bilişim Teknolojileri ve Bilişim Sektöründe Düzenlemeler konularında Yüksek Lisans ve Lisans Dersleri vermiştir. Bu derslerin önemli bir kısmı halen devam etmektedir.

Bilişim Sektörü ve Deniz Haberleşme (GMDSS) alanlarında yayınlanmış 7 adet Kitabı olan Tayfun ACARER'in yurt içi ve yurt dışındaki konferans, seminer ve dergilerde yayınlanmış çok sayıda makale ve bildirisi bulunmaktadır.

Halen Piri Reis Üniversitesinde Dr. Öğr. Üyesi, Ulaştırma Altyapı Bakanlığında Ulaşım Emniyeti İnceleme Komisyonu Üyesi ve İstanbul Teknik Üniversitesi Arı Teknopark Değerlendirme Kurulu Üyesi olarak görev yapmaktadır. Bugüne kadar Piri Reis Üniversitesi dışında bir çok üniversitede Yüksek Lisans ve Lisans Dersleri de veren Tayfun ACARER bu derslerine devam etmektedir. Tayfun ACARER evli ve 2 çocuk sahibi olup, iyi derece İngilizce bilmektedir.

Yapay Zekâ Tabanlı Hava Kalitesi İyileştirme Stratejilerinin Değerlendirilmesi

Evaluation of Artificial Intelligence-Based Air Quality Improvement Strategies

 Tugce Pekdogan¹

¹ Doktor Öğretim Üyesi, Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mimarlık ve Tasarım Fakültesi, Mimarlık Bölümü, Çukurova/Adana
tpekdogan@atu.edu.tr

Özet

Günümüzde hava kirliliği, kentsel ve sanayi bölgelerinde yaşayan milyonlarca insan için ciddi sağlık riskleri oluşturmaktadır. Bu makalede, yapay zekâ (AI) teknolojileri ve makine öğrenimi algoritmalarının hava kalitesini izleme ve iyileştirme stratejilerinin geliştirilmesinde nasıl kullanılabileceği ele alınmıştır. Bu araştırma, özellikle kentsel alanlarda hava kalitesi üzerinde etkili olan ana kirleticilerin dinamiklerini modellemek için makine öğrenmesi yaklaşımlarını kullanmaktadır.

Bu çalışmada, çeşitli yapay zekâ modelleri (RF, SVM, ANN, CNN, RNN, GAN) kullanılarak hava kalitesi verilerinin analiz, tahmin ve simüle edilmesi süreçleri detaylı bir şekilde incelenmiştir. Ayrıca, bu modellerin hava kalitesi yönetimi için stratejik karar verme süreçlerinde nasıl entegre edilebileceği üzerinde durulmuştur. Yapay zekâ tabanlı modeller, gerçek zamanlı veri akışını analiz ederek, hava kalitesi üzerinde olumlu etkiler yaratabilecek müdahaleler önermektedir.

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

Abstract

Today, air pollution causes serious health risks for millions living in urban and industrialized areas. This paper discusses how artificial intelligence (AI) technologies and machine learning algorithms can be used to develop air quality monitoring and improvement strategies. This research uses machine learning approaches to model the dynamics of the main pollutants that influence air quality, especially in urban areas.

In this study, the processes of analyzing, predicting and simulating air quality data using various artificial intelligence models (RF, SVM, ANN, CNN, RNN, GAN) are examined in detail. Furthermore, how these models can be integrated into strategic decision-making processes for air quality management is emphasized. By analyzing the real-time data flow, AI-based models suggest interventions that can positively impact air quality.

Keywords: Air Quality, Deep Learning, Artificial Intelligence, Machine Learning, Artificial Neural Networks.

1. Giriş

Hava kirliliği, dünya çapında büyük bir çevresel ve sağlık sorunu olarak öne çıkmaktadır. Kentleşme ve sanayileşme, hava kalitesi sorunlarını daha da artırmaktadır. Çin'in büyük şehirlerinde PM2.5 seviyeleri, Dünya Sağlık Örgütü'ne (WHO)'nun belirlediği sınır değerlerinin çok üzerinde olup ciddi sağlık riskleri yaratmaktadır [1]. Hindistan'da da benzer şekilde, yüksek hava kirliliği seviyeleri milyonlarca erken ölüme neden olmaktadır [2]. Gelişmiş ülkelerde bile, hava kirliliği önemli bir halk sağlığı sorunu olmaya devam etmektedir [3]. WHO'ya göre, her yıl yaklaşık 7 milyon insan hava kirliliğine bağlı hastalıklar nedeniyle yaşamını yitirmektedir [4]. Hava kirliliği, özellikle PM2.5 ve PM10 gibi ince partiküller, astım, bronşit ve diğer solunum yolu hastalıklarının yanı sıra kalp hastalıkları ve felç gibi ciddi sağlık problemlerine neden olmaktadır [5]. Ayrıca, çocuklar, yaşlılar ve kronik hastalığı olan bireyler gibi savunmasız gruplar, hava kirliliğinden daha fazla etkilenmektedir [6]. Hava kirliliğinin insan sağlığı üzerindeki zararlı etkileri birçok çalışmada tartışılmaktadır. PM10 öncelikle üst solunum yollarında birikir. Bununla birlikte, ince (PM2.5 ve PM1, çapı 2.5'ten küçük ve sırasıyla 1µm'den küçük parçacıkları oluşturur) ve ultra ince (PM0.1) parçacıklar akciğer alveollerine ulaşabilir [5], [7]. Kardiyovasküler [8], [9] ve solunum [10], [11] etkileri ile ilgili olarak, ince ve ultra ince parçacıklar PM10'dan daha tehlikelidir [12]. İnsan sağlığı üzerindeki etkiler mide bulantısından [13] nefes almada zorluğa [14] ve akciğer kanserine [15] kadar değişebilir.

Avrupa Birliği, Avrupa'yı 2050 yılına kadar net sera gazı emisyonu olmayan ilk kıta yapmak için 2030 yılına kadar net sera gazı emisyonlarını 1990 seviyelerine kıyasla en az %55 oranında azaltmayı hedefleyen Avrupa Yeşil Anlaşması'nı imzalamıştır. Böylece, 2050 için hava, su ve toprak kirliliğini insan sağlığı ve ekolojik sistemler için tehlikeli sayılmayan seviyelere düşürme hedefi belirlenen bu anlaşma ile çevresel hedeflere önemli ölçüde katkıda bulunacağı ön görülmektedir [16].

Halk sağlığına etkisinin yanı sıra hava kirliliğinin ekonomik maliyetleri de oldukça yüksektir. OECD'nin raporuna göre, hava kirliliği küresel ekonomiye her yıl trilyonlarca dolara mal olmaktadır [17]. Bu maliyetler, sağlık harcamaları, iş gücü kaybı ve üretim düşüşlerini içermektedir. Ekolojik açıdan bakıldığında, hava kirliliği bitki örtüsünü tahrip etmekte, su kaynaklarını kirletmekte ve biyolojik çeşitliliği azaltmaktadır [18]. Kentsel ve sanayi bölgeleri, hava kirliliğinin yoğun olarak görüldüğü alanlardır. Kentsel alanlarda, trafik yoğunluğu ve sanayi faaliyetleri, hava kirliliğinin başlıca kaynaklarını oluşturur. Şehirlerde artan motorlu taşıt sayısı, egzoz gazları yoluyla atmosfere zararlı maddelerin salınmasına neden olmaktadır [19]. Sanayi bölgelerinde ise fabrikalar ve enerji santralleri, sülfür dioksit (SO₂), karbon monoksit (CO) ve uçucu organik bileşikler (VOC) gibi kirleticileri atmosfere salar [20]. Bu kirleticiler, sadece yerel hava kalitesini düşürmekle kalmaz, aynı zamanda uzun mesafeler kat ederek geniş alanlarda kirliliğe yol açar.

Bu nedenle hava kalitesini iyileştirmenin ilk ve en önemli adımı, düzenli olarak hava kalitesi ölçümlerinin yapılması ve mevcut durumu doğru bir şekilde tespit edilmesidir. Bu ölçümler, kentsel ve endüstriyel alanlarda hava kirliliğinin seviyesini ve kaynaklarını belirlemek için kritik bir rol oynamaktadır. Hava kalitesi sensörleri ve izleme istasyonları, partikül madde (PM2.5, PM10), ozon (O₃), azot dioksit (NO₂), kükürt dioksit (SO₂) ve karbon monoksit (CO) gibi kirleticilerin

konsantrasyonlarını belirlemektedir. Bu veriler, hava kirliliği seviyelerindeki değişimleri izlemek, kirlilik kaynaklarını tespit etmek ve bu kaynakların etkilerini değerlendirmek için kullanılır. Elde edilen veriler, çevre politikalarının geliştirilmesi, acil durum müdahalelerinin planlanması ve halk sağlığını koruyacak stratejilerin oluşturulması için önemli bir temel sağlar.

Günümüzde yapay zekâ ve makine öğrenimi teknolojileri, hava kalitesi analizinde ve iyileştirilmesinde büyük bir potansiyele sahiptir. Bu teknolojiler, büyük veri kümelerini işleyerek ve modelleyerek hava kalitesi tahminlerinde yüksek doğruluk sağlarlar. Yapay zekâ, hava kirliliği kaynaklarını belirleme, kirlilik seviyelerini tahmin etme ve iyileştirme stratejileri geliştirme süreçlerinde kritik bir rol oynar [21]. Ülkemizde, T.C. Çevre ve Şehircilik Bakanlığı tarafından kurulan "Ulusal Hava Kalitesi İzleme Ağı" (UHKİA) hava kalitesini sürekli olarak izleyerek, hava kirliliği seviyelerini ve kaynaklarını belirlemekte ve bu verileri kullanarak iyileştirme stratejileri geliştirmektedir. UHKİA'nın faaliyetleri kapsamında, çok kriterli karar verme (multi-criteria decision making-MCDM) ve yapay zekâ teknikleri kullanılarak, hava kalitesi yönetiminde daha etkili ve verimli kararlar alınması sağlanmaktadır [22].

Yapay zekâ tabanlı yaklaşımlar, hava kalitesi izleme ağlarından gelen verileri analiz ederek gerçek zamanlı tahminler yapabilmektedir. Literatürde Random Forests (RF), Support Vector Machines (SVM), Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), ve Generative Adversarial Networks (GAN) gibi farklı yapay zekâ modelleri kullanılarak karmaşık hava kalitesi verilerini işlenmiştir.

Bu çalışmanın amacı, literatürdeki yapay zekâ tabanlı hava kalitesi iyileştirme stratejilerini incelemek ve bu alandaki uygulamaları değerlendirmektir. Çalışma, yapay zekâ ve makine öğrenimi teknolojilerinin hava kalitesi analizindeki rolünü, çeşitli modellerin performansını ve farklı yaklaşımların etkinliğini ele alacaktır. Özellikle, bu çalışmada irdelenmiş olan hibrit yapay zekâ modelleri ve büyük veri kümelerinin entegrasyonu gibi yenilikçi yaklaşımlar, mevcut literatüre önemli katkılar sağlamaktadır. Ayrıca, hava kalitesi yönetimi ve iyileştirme stratejileri için yapay zekâ tabanlı çözümlerin potansiyeli ve gelecekteki araştırma alanları tartışılacaktır.

2. Yapay Zekâ Modelleri ve Hava Kalitesi


Yapay zekâ ile hava kalitesi tahmini yapan birçok çalışma bulunmaktadır. Yapay zekânın hava kalitesi izleme sistemlerine dahil edilmesi birçok sektörde yaygın olarak kullanılmakta ve büyük avantajlar sağlamaktadır. Bu sistemler, şehir planlama, halk sağlığı, sanayi ve tarımda hava kalitesini izlemek ve yönetmek için gerekli verileri sağlamaktadır. Kentsel planlamada, yapay zekâ modelleri kullanılarak hava kalitesi haritaları oluşturulmakta ve kirlilik kaynakları belirlenmektedir. Bu tür uygulamalar, kentsel alanlarda hava kalitesini iyileştirme çabalarına büyük katkı sağlamaktadır. Pekdoğan vd. [16] tarafından yapılan çalışmada Adana'da 3 farklı sensör aracılığıyla il bazında kirlilik tespit edilmiştir. Şehirlerdeki hava kalitesini takip eden bu sistemler, kullanıcıların bu verilerle anlık olarak etkileşime geçmesini de sağlamaktadır. Bu uygulamalar, bireylerin günlük aktivitelerini hava kalitesine göre planlamalarına ve kirlilik konusunda farkındalık kazanmalarına yardımcı olmaktadır. Başka bir kentsel bağlamda yapılmış olan çalışmada ise; yapay zekâ tabanlı optimizasyon algoritmaları, trafik yönetimi ve

endüstriyel emisyon kontrolü gibi alanlarda hava kalitesini iyileştirme stratejileri geliştirmek için kullanılmaktadır [23]. Bu stratejiler, hava kirliliği seviyelerini düşürmeye yönelik pratik çözümler sunar. Endüstriyel tesislerde ise hava kalitesi izleme sistemleri emisyonları izlemek ve mevcut politika ve düzenlemelere uymak için kullanılır. Bu sistemler, emisyonları en aza indirmek ve çevresel etkileri azaltmak için gerçek zamanlı veriler sağlar. Bu teknolojiler, özellikle kimya, petrol ve gaz endüstrileri gibi yüksek emisyonlu sektörlerde kritik öneme sahiptir [20]. Ayrıca hava kalitesi izleme sistemleri, halk sağlığını tehdit eden unsurların tespit edilebilmesi için öneme sahiptir. Makine öğrenmesi algoritmaları ile hava kirliliği seviyelerindeki değişimler tahmin edilebilir ve bu tahminlere göre önleyici tedbirler politika yapıcılar tarafından alınabilir [24]. Yapay zekâ tabanlı hava kalitesi izleme sistemleri, tarım alanlarında da oldukça büyük bir yer edinmiştir. Özellikle Tarım 4.0 dönüşümü ile bilgisayar destekli kontrol sistemleri, çeşitli yazılım ve donanım araçları, dijital sensörlerle donatılmış tarım makineleri, görüntü işleme teknolojileri gibi akıllı sistemlerin kurulması ve yaygınlaştırılması son derece önemli hale gelmiştir [25]. Bu tip hava kalitesi izleme sistemleri akıllı tarımda çeşitli kirlenmelerin ve çevresel parametrelerin izlenmesini sağlar. Bu sistemler, bitkilerin büyüme koşullarını optimize etmek ve çevresel stres faktörlerini en aza indirmek için kullanılır [26].

2.1. Yapay Zekâ ve Makine Öğrenimi Temelleri

Yapay zekâ ve makine öğrenimi, büyük veri kümelerini analiz etmek ve tahminler yapmak için kullanılan güçlü teknolojilerdir. Bu teknolojiler, veri toplama, işleme ve modelleme süreçlerinde kullanılarak hava kalitesi tahminlerinde yüksek doğruluk sağlar. Yapay zekâ, karmaşık veri yapılarını analiz ederek hava kirliliği seviyelerini tahmin etme, kirlilik kaynaklarını belirleme ve iyileştirme stratejileri geliştirme süreçlerinde önemli bir rol oynar [27].

Makine öğrenimi, özellikle büyük veri analizinde etkili olan algoritmalar kullanarak hava kalitesi tahminlerinde doğruluğu artırmaktadır. Bu algoritmalar, tarihsel verileri kullanarak gelecekteki kirlilik seviyelerini tahmin edebilir ve böylece hava kalitesi yönetiminde proaktif önlemler alınmasına olanak tanır [28]. Şekil 1 makine öğrenmesi algoritmalarını ve bunların kategorilerini göstermektedir. Şekil üç ana bölüme ayrılmıştır: Denetimli Öğrenme, Denetimsiz Öğrenme ve Derin Öğrenme [29]. Denetimli öğrenme, etiketlenmiş veriler kullanılarak modellerin eğitildiği bir öğrenme yöntemidir. Bu kategoride, Destek Vektör Makineleri (SVM), En Yakın Komşu (KNN), Sinir Ağları, doğrusal regresyon, destek vektör regresyonu (SVR), Gaussian süreç regresyonu (GPR), karar ağaçları gibi çeşitli algoritmalar yer almaktadır. Denetimsiz öğrenme, etiketlenmemiş veriler kullanılarak yapılır. Bu kategoride, K-Ortalama, Gaussian Karışımı, Gizli Markov Modeli gibi algoritmalar kullanılmaktadır. Derin öğrenme ise yapay sinir ağları kullanarak daha karmaşık veri işlemleri yapan bir öğrenme yöntemidir. Bu kategoride de Çok Katmanlı Algılayıcılar (MLP), Evrimsel Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN) kullanılmaktadır.



Şekil-1: Yapay zekâ tabanlı makine öğrenmesi ve derin öğrenme teknikleri [29]

2.2. Hava Kalitesi Tahmininde Kullanılan Yapay Zekâ Modelleri

Gelişmekte olan ülkelerde kentleşme ve endüstriyel faaliyetler artmaya devam ettikçe, doğru ve güvenilir hava kalitesi tahminlerine duyulan ihtiyaç giderek daha önemli hale gelmektedir. Son yıllarda yapay zekâ tekniklerinin yaygınlaşması, hava kalitesi tahmini alanında da yer edinmiştir. Bu modeller veriye dayalı olmakla birlikte gelişmiş tahmin doğruluğu ve verimliliği sunar. Hava kalitesi tahmininde yaygın olarak kullanılan çeşitli yapay zekâ modelleri bulunmaktadır. Tablo 1 literatürde yer alan farklı modellerin uygulamalarını, amaçlarını ve sonuçlarını vurgulayarak hava kalitesi tahmininde AI teknolojilerinin kullanımına dair genel bir bakış sunmaktadır.

Tablo-1: Hava kalitesi tahmini çalışmaları

Ref.	Konum	Yöntem	Amaç
[30]	Türkiye	ANN	ANN modelleri kullanarak ortam SO ₂ seviyelerini tahmin etmek
[31]	Hindistan	ANN	Hava kalitesini tahmin etmek için YSA ve GPR modellerini karşılaştırmak
[32]	Kuveyt	RF	Eksik verileri ele alarak hava kalitesi tahminlerini iyileştirmek
[33]	Tayvan	SVM	Zaman ve mekansal özellikleri kullanarak hava kalitesini tahmin etmek


Tablo-1: Hava kalitesi tahmini çalışmaları (devam)

Ref.	Konum	Yöntem	Amaç
[34]	Endonezya	SVM	Hava kalitesini tahmin etmek için SVM ve Karar Ağacı modellerini karşılaştırmak
[35]	Hindistan	SVM, Hibrit	Çeşitli ML algoritmalarını kullanarak hava kalitesini tahmin etmek
[36]	Taipei, Tayvan	SVM, Hibrit	Meteorolojik verileri ve kirlilik kaynaklarını entegre ederek hava kalitesini tahmin etmek
[37]	Uruguay	GAN	Gerçek veri eksikliğini gidermek için sentetik veri üretmek
[38]	Hindistan	CNN, GAN	Farklı modelleri birleştirerek hava kalitesini tahmin etmek

2.2.1. Rastgele Orman

Rastgele Orman (RF-Random Forest) modelleri, verilerdeki karmaşık ve doğrusal olmayan ilişkileri ele alma yetenekleri nedeniyle hava kalitesi tahmini için bir araçtır. Bu modeller, düşük maliyetli sensör kalibrasyonu, kentsel hava kalitesi tahmini, iç mekân hava kalitesi izleme ve büyük ölçekli hava kirlenme tahmini dahil olmak üzere çeşitli hava kalitesi tahmin uygulamalarında kullanılır. Zimmerman vd. [39] tarafından yapılan çalışmada, RF modelleri kullanılarak düşük maliyetli hava kalitesi sensörleri için kalibrasyon stratejilerinin geliştirilmiştir. RF modelleri, altı aylık bir süre boyunca CO, NO₂, CO₂ ve O₃'ü ölçen birden fazla kirlenme için geliştirilmiş ve doğrulanmıştır. Bu çalışmanın sonucuna göre, RF modellerinin doğruluk ve sağlamlık açısından doğrusal regresyon gibi geleneksel kalibrasyon yöntemlerinden önemli ölçüde daha iyi performans gösterdiğini göstermiştir.

Yu vd. [40] kentsel algılama sistemlerinde hava kalitesi tahmini için kullanmıştır. Bu yaklaşım, hava kalitesini tahmin etmek için meteorolojik veriler, trafik durumu gibi çeşitli veri kaynaklarını kullandı. Bu çalışmaya göre, RF tabanlı modelin, destek vektör makineleri ve çoklu doğrusal regresyon gibi diğer algoritmalarından daha iyi performans göstererek yüksek doğrulukta hava kalitesi tahminleri sağladığı görülmüştür. Alsaber vd. [32] tarafından yapılan çalışmada RF modelleri, Kuveyt genelinde hava kirlenme maddelerinin tahminini geliştirmek ve eksik veri sorunlarını gidermek için kullanılmıştır. Çalışma, RF modellerinin büyük ve çeşitli veri kümelerini işleme konusundaki ve geniş alanlarda gerçek zamanlı hava kalitesi tahmini konusundaki performansını değerlendirmiştir. Şekil 2 Rastgele Orman (RF) modelinin akış şemasını göstermektedir. Bu yöntem ile modelin doğruluğu artırılır ve aşırı öğrenme azaltılır, böylece daha güvenilir ve genelleştirilebilir tahminler elde edilir [41].




Şekil-2: RF Model Mimarisi [41]

2.2.2. Destek Vektör Makinesi

Destek Vektör Makinesi (SVM- Support Vector Machines) modellerinin, yüksek boyutlu verileri ve karmaşık ilişkileri ele alma yetenekleri nedeniyle hava kalitesi tahmininde oldukça etkili olduğu kanıtlanmıştır. Bu modeller, geleneksel yöntemlerden ve diğer bazı makine öğrenimi algoritmalarından daha iyi performans göstererek hava kalitesini tahmin etmede yüksek doğruluk göstermektedir. Liu vd. [33] zamansal ve mekansal özellikleri birleştirerek bilinmeyen konumlardaki hava kalitesini tahmin etmek için bu modeli kullanmıştır. Çalışma, yerel verilere dayalı olarak farklı alanlara uyarlanabilecek, kentsel planlama ve hava kalitesi yönetimi çabalarını geliştirebilecek bir tahmin çerçevesi oluşturmuştur.


Rafif vd. [34] Jakarta'daki Hava Kalitesi Endeksi'ni tahmin etmek için SVM ve Karar Ağacı algoritmalarını karşılaştırmıştır. Bu model karar ağacı modelinden daha iyi performans göstermiştir. Kumar ve Pande [35] tarafından yapılan çalışmada çeşitli çevresel ve meteorolojik parametreleri birleştirerek Delhi'deki hava kalitesini tahmin etmek için SVM modelleri kullanılmıştır. Sonuç olarak bu model geleneksel yöntemlere göre önemli ölçüde daha iyi, yüksek tahmin doğruluğu sağlamıştır. Liu vd. [33] yapılan bu çalışma meteorolojik verileri ve kirlilik kaynaklarını entegre ederek kentsel ölçekte hava kalitesini tahmin etmek için SVM modellerini kullanmıştır. Gelişmiş tahmin performansı için birden fazla veri kaynağını birleştirmenin önemini vurgulayarak bu model hava kalitesini yüksek doğrulukla etkili bir şekilde tahmin etmiştir. Şekil 3, bir Destek Vektör Makinesi (SVM) mimarisini göstermektedir. Buradaki süreç, SVM'nin veri sınıflandırmasını veya regresyonunu gerçekleştirmesini sağlamaktadır [42].



Şekil-3: SVM Model Mimarisi [42]

2.2.3. Yapay Sinir Ağları

Yapay Sinir Ağları (ANN- Artificial Neural Networks): Çeşitli çevresel faktörler ve kirlenici konsantrasyonları arasındaki karmaşık, doğrusal olmayan ilişkileri modelleme yetenekleri nedeniyle hava kalitesi tahmininde kullanılan önemli bir yapay zekâ yöntemidir. Sofuoğlu vd. [30], Türkiye'deki dış ortam SO₂ konsantrasyonlarını tahmin etmek için bir yapay zekâ modeli geliştirdi. Bu çalışma, sınırlı girdi değişkenlerine sahip kentsel ortamlardaki hava kirlenici madde konsantrasyonlarının modellenmesinde bu metodun etkinliğini göstermektedir. Suri vd. [31] Hindistan'ın altı şehrinde hava kalitesi endekslerini tahmin etmek için ANN modellerini kullanmıştır. Bu çalışmaya göre, ANN hava kalitesini tahmin etmede yüksek doğruluk sağlamıştır. Gao vd. [43], ozon konsantrasyonlarını tahmin etmek için Monte Carlo analiziyle birleştirilmiş bir ANN modeli kullanmıştır. Bu yaklaşım ile hem geçmiş hava kalitesi verilerini hem de meteorolojik değişkenleri birleştirilerek tahmin doğruluğunu artırmıştır. Ordieres-Meré vd. [44], ABD-Meksika sınır bölgesindeki ince partikül madde (PM_{2.5}) seviyelerini tahmin etmek için ANN modelini kullanmıştır. Bu model, geçmiş verilere dayanarak PM_{2.5} konsantrasyonlarını doğru bir şekilde tahmin ederek geleneksel istatistiksel modellerden daha iyi performans göstermiştir. Şekil 4 bir Yapay Sinir Ağı modelinin hava kalitesi indeksini tahmin etme sürecinin örneğidir. Bu yapı, farklı kirlenici konsantrasyonlarından gelen bilgilerin işlenerek tek bir hava kalitesi değerine dönüştürülmesini sağlamaktadır.




Şekil-4: ANN Model Mimarisi [45]

2.2.4. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (CNN): CNN'ler, özellikle görüntü ve uzamsal veri analizi için kullanılır. Hava kalitesi tahmininde, uydu görüntülerinden elde edilen veriler CNN'ler ile işlenerek kirlilik seviyeleri tahmin edilebilir. CNN'ler, hava kirliliği haritalarını ve dağılım modellerini oluşturarak, kirlilik kaynaklarının mekansal analizini yapmaktadır. Bu model görüntü ve mekansal veri analizinde oldukça etkilidir ve bu da hava kalitesi tahmini için uygun hale getirir. Bu modeller, kentsel alanlardaki hava kalitesi sorunlarının belirlenmesi ve yönetilmesinde büyük avantaj sağlar. Özellikle CNN'ler, uydu görüntülerinden ve diğer kaynaklardan gelen verileri işleyerek kirlilik seviyelerini tahmin etmek için kullanılmaktadır.


Bai ve Peng [46] tarafından yapılan çalışma, CNN'lerin PM_{2.5} konsantrasyonlarını azaltmak için kentsel tasarımı nasıl destekleyebileceğini araştırırken eğitilen bu model ile kentsel tasarım önerilerine dayanarak PM_{2.5} konsantrasyonlarının hızlı bir şekilde tahmin edilebilir olmasına olanak tanımıştır. Bu mimari, giriş zaman serisi verileriyle başlar ve özellikleri çıkarmak ve özetlemek için çoklu evrişim ve havuzlama katmanlarından geçirir [47]. Daha sonra veriler düzleştirilir ve nihai tahmini üretmek için tam bağlı bir katmandan geçirilir. CNN mimarisi, sıralı zaman serisi verilerinden kalıpları verimli bir şekilde işlemek ve öğrenmek için tasarlanmıştır, bu da onu hava kalitesi tahmini gibi görevler için uygun kılmaktadır. Bu mimari, verilerdeki yerel örüntüleri ve bağımlılıkları yakalamak için evrişimli katmanların gücünden yararlanırken, havuzlama katmanları veri boyutunu ve hesaplama gereksinimlerini azaltmaya yardımcı olur. Sonundaki tam bağlantılı katman, nihai bir tahmin yapmak için öğrenilen özellikleri sentezlemektedir [48]. Şekil 5 hava kalitesi ve meteorolojik parametreleri kullanarak saatlik hava kalitesi tahmini yapan bir CNN modelinin yapısını göstermektedir. Bu yapı, çeşitli hava kalitesi ve meteorolojik parametreleri işleyerek yüksek doğrulukla hava kalitesi tahminleri yapabilen bir CNN modelinin temel işleyişini göstermektedir [47], [48].



Şekil-5: CNN Model Mimarisi [47], [48]

2.2.5. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (RNN): RNN'ler, zaman serisi verilerinin analizi için idealdir. Hava kalitesi tahmininde, geçmiş hava kalitesi verileri kullanılarak gelecekteki kirlilik seviyeleri tahmin edilebilmektedir. Ramachandraarjunan vd. [49] hava kalitesi seviyelerini otomatik olarak tahmin etmek ve havalandırma sistemlerini kontrol etmek için IoT cihazları ve RNN'leri kullanan bir Akıllı İç Hava Kalitesi İzleme sistemi geliştirmiştir. Nurcahyanto vd. [50] ise endüstriyel bir temiz oda ortamında PM10 konsantrasyonlarını tahmin etmek için çok seviyeli bir RNN modeli uygulamıştır. Zhao vd. [51], Amerika Birleşik Devletleri'ndeki üç endüstriyel şehirde günlük Hava Kalitesi Sınıflandırmasını tahmin etmek için derin bir RNN modeli kullanmıştır. Athira vd. [38] meteorolojik ve hava kalitesi verilerini içeren AirNet veri kümesini kullanarak hava kalitesi tahmini için RNN ve uzun kısa süreli bellek (LSTM) modellerini uygulamıştır. [52], yağış ve hava kalitesini tahmin etmek için konvülsiyonel LSTM ile birleştirilmiş RNN'lerin kullanımını araştırmıştır. Çalışma, meteorolojik verilerin RNN modelleriyle entegre edilmesinin hava kalitesi parametrelerinin tahmin doğruluğunu önemli ölçüde artırdığını ortaya koymuştur. Livingston vd. [53] tarafından yapılan bir çalışmada, hava kalitesi tahmini için RNN'leri diğer modellerle birleştiren bir toplu makine öğrenimi yaklaşımı önerilmiştir. Çalışma, modeli test etmek için Pekin'den alınan verileri kullanmış ve birleştirilmiş yaklaşımın tahmin doğruluğunu artırabileceğini ve sağlam hava kalitesi izleme çözümleri sağlayabileceğini göstermiştir. Şekil 6, RNN modelin temel yapısını ve bilgi akışını göstermektedir [54].




Şekil-6: RNN Model Mimarisi [54]

2.2.6. Çekişmeli Üretken Ağlar

Generative Adversarial Networks (GAN): GAN'ler, veri üretimi ve simülasyonlar için kullanılan çekişmeli üretici ağıdır. Hava kalitesi modellerinde, eksik veya az sayıda veri olduğunda GAN'ler kullanılarak bu veri açığı kapatılabilir.

GAN'ler, iki sinir ağı modelinin (generatör ve diskriminatör) rekabetçi bir şekilde çalışmasıyla, gerçekçi veri üretir. Toutouh vd. [37] tarafından yapılan çalışma, kentsel hava kirliliğini modellemek için Koşullu Üretken Çekişmeli Ağların (CGAN'ler) kullanılmasına odaklanmaktadır. Modelde alınan veriler eğitilmiş ve daha az hesaplama kaynağı gerektiren doğru ve çeşitli kirlilik verileri üretmede umut verici sonuçlar göstermiştir [55], aerosol ve Hava Kalitesi Endeksi değerlerini tahmin etmek için bir nöral Turing makinesini bir GAN ile birleştiren DAerosol.GAN.NTM (Deep Aerosol Generative Adversarial Networks Neural Topic Modeling) çerçevesini önermiştir. Bu model, eksik verileri doğru bir şekilde tahmin ederek ve gelecekteki hava kalitesi ölçümlerini tahmin etmeyi amaçlamaktadır. Wu vd. [56] tarafından yapılan çalışmada ise, şehir planlaması ve hava kalitesi izleme dahil olmak üzere yapıllı çevrede GAN'ların uygulanmasının bir incelemesini sunmaktadır. Bu çalışmanın sonucuna göre, GAN'ların yüksek çözünürlüklü görüntüler oluşturmada ve anlamsal verileri hava kalitesini izlemek ve tahmin etmek için uygulanabilecek gerçekçi görselleştirmelere dönüştürmede etkili olduğunu göstermektedir. Şekil 7 GAN modelinin işleyişini göstermektedir. Bu döngü, Generator'un daha gerçekçi veriler üretmesini ve Ayrıştırıcının bu verileri ayırt etme yeteneğinin sürekli gelişmesini sağlamaktadır [57].



Şekil-7: GAN Model Mimarisi [57]

3. Yapay Zekâ Tabanlı Yöntemlerin Karşılaştırılması ve Değerlendirilmesi

Yapay zekâ tabanlı hava kalitesi tahmin yöntemleri üzerine yapılan çalışmalar, bu yöntemlerin etkinliğini ve doğruluğunu karşılaştırmalı olarak analiz etmiştir. RF, SVM, ANN, CNN, RNN ve GAN gibi modeller, hava kalitesi tahmininde kullanılan yöntemler arasında bulunmaktadır.

Kullanılan algoritmalar izlendiğinde ise; mevcut literatürde, RF modelleri yaygın olarak kullanılırken çevresel koşullar ve sensör performansında geleneksel yöntemlere göre yüksek doğruluk sağladığı görülmüştür [32]. SWM modelleri, yüksek boyutlu veri setlerini ve karmaşık ilişkileri işleyebilme yetisine sahiptir. Bu nedenle karmaşık hava kalitesi verilerinde yüksek doğruluk sağladığı görülmüştür [34]. ANN ise hava kalitesi tahmininde sıkça kullanılan en etkili modellerden biridir. Kumar vd. [35] çalışmasında çevresel ve meteorolojik parametreleri kullanarak farklı parametreler arasındaki karmaşık ilişkileri yakalama yeteneğini göstermiştir. CNN'ler kullanılarak yapılan çalışmalarda yüksek doğruluk elde edildiği gözlenmiştir [58]. CNN'ler, Çin'deki hava kalitesi tahmininde kullanılmış ve yüksek doğruluk oranları elde edilmiştir [58]. Benzer şekilde, RNN'ler kullanılarak yapılan bir çalışmada,

Hindistan'daki hava kalitesi tahminleri başarıyla yapılmıştır [29]. Bu çalışmalar, yapay zekânın hava kalitesi tahmininde etkili olduğunu göstermektedir. Farklı yapay zekâ modellerinin karşılaştırmalı analizi de literatürde yer almaktadır. Bir çalışma, CNN ve RNN modellerini karşılaştırarak, CNN'lerin uzamsal verilerde daha iyi performans gösterdiğini, RNN'lerin ise zaman serisi analizlerinde üstün olduğunu belirtmiştir [59]. GAN modelleri ise veri üretimi ve simülasyonlar için kullanılır. GAN modelleri, eksik verilerin doldurulmasında ve gerçekçi veri üretiminde etkili olup, hava kalitesi tahmininde kullanılmaktadır.

Bu modeller, hava kalitesi tahmininde çeşitli avantajlar ve zorluklar sunar (Tablo 2).

Tablo-2: Hava Kalitesi Tahmininde Kullanılan Yapay Zekâ Modelleri

Model	Kullanım Alanları	Avantajlar	Dezavantajlar
RF	Sınıflandırma ve regresyon problemleri	Gürültüye dayanıklılık, büyük veri setleriyle başa çıkma	Parametre ayarlaması ve sonuçların yorumu zor olabilir
SVM	Sınıflandırma ve regresyon	Küçük örneklem setlerinde yüksek performans, gürültüye dayanıklılık	Büyük veri setlerinde yavaş çalışabilir
ANN	Çeşitli veri analizi ve tahmin	Karmaşık doğrusal olmayan ilişkileri modelleme	Optimum ağ yapısını belirlemek zor, aşırı öğrenme riski
CNN	Görüntü ve uzamsal veri analizi	Yüksek doğruluk, mekânsal analiz	Veri yoğunluğu, yüksek hesaplama maliyeti
RNN	Zaman serisi verilerinin analizi	Uzun dönem bağımlılıkları modelleme, zaman serisi analizinde doğruluk	Uzun dönem bağımlılıkları modelleme zorluğu
GAN	Veri üretimi ve simülasyonlar	Eksik verilerin doldurulması, gerçekçi veri üretimi	Generatör ve diskriminatör modellerinin eğitim zorluğu

3.1. Gelecek Araştırmalar İçin Öneriler ve Yapay Zekâ Teknolojilerinin Rolü

Gelecek araştırmalarda, yapay zekâ teknolojilerinin hava kalitesi yönetimindeki rolü daha da artacaktır. Yapay zekânın bütünleştirildiği hava kalitesi izleme teknolojileri önemli faydalar sağlarken, bu teknolojilerin tam potansiyellerine ulaşabilmesi için çözülmesi gereken çeşitli zorlukları da beraberinde getirmektedir. Yapay zekâ modellerinin

bütünleştirildiği cihazlar tarafından oluşturulan büyük veri hacimlerini yönetmek, depolamak ve gerçek zamanlı olarak analiz etmek, sağlam bir bulut altyapısı ve gelişmiş veri analizi araçları gerektirir. Bu nedenle veri kalitesi, doğruluğu ve bütünlüğü büyük önem taşır.

Hibrit modellerin geliştirilmesi ile hem mekânsal hem de zamansal bağımlılıkları yakalayarak daha kapsamlı tahminler yapılabilir. RF ve SVM'nin güçlü yönlerinin ve CNN ve RNN gibi derin öğrenme modellerinin güçlü yönlerini birleştirmek farklı yapay zekâ modellerini birleştirmek, yapay zekânın sağlamlığını ve doğruluğunu artırabilir.

Değişen çevre koşullarına sahip farklı coğrafi bölgelere uygulanabilecek ölçeklenebilir ve aktarılabilir yapay zekâ modellerinin geliştirilmesi ile etkinliği artırılabilir. Böylece, bir bölgenin verileri üzerinde eğitilebilecek ve diğerine başarılı bir şekilde uygulanabilecek uyarlanabilir modeller oluşturarak daha geniş alanlarda uygulanabilir.

Verilerin kalitesinin ve kullanılabilirliğinin sağlanması bu modellerin doğru açılarından önemlidir. Bu alandaki sürekli iyileştirmeler, yapay zekâ tabanlı cihazların doğruluğu, güvenilirliği ve maliyet etkinliğini artırmasını sağlayacaktır. Yapay zekâ ve makine öğrenimi gibi teknolojilerin hızla gelişmesi ve yapay zekânın entegrasyonu, veri analizi ve tahmin yeteneklerini önemli ölçüde artırabilir.

Yapay zekâ teknolojileri, yapay zekâ tabanlı sensörlerin ve gelişmiş veri işleme tekniklerinin entegrasyonu yoluyla hava kalitesinin gerçek zamanlı izlenmesine olanak tanımaktadır. Bu durum, kirlilikteki ani artışların zamanında tespit edilmesine ve politika yapıcıların kirlilik kaynaklarını azaltmak için stratejiler geliştirmesine olanak tanıyarak hava kalitesinin halk sağlığı üzerindeki olumsuz etkilerini azaltabilir.

4. Sonuç

Bu çalışma, yapay zekâ tabanlı hava kalitesi tahmin ve iyileştirme stratejilerini kapsamlı bir şekilde incelemektedir. RF, SVM, ANN, CNN, RNN ve GAN gibi modern yapay zekâ modellerinin hava kalitesi tahmininde nasıl kullanıldığı ve bu modellerin avantajları ile dezavantajları ele alınmıştır. Literatürdeki bulgular, bu modellerin hava kalitesi tahmininde yüksek doğruluk sağladığını ve çeşitli çevresel koşullarda da etkili olduğunu göstermektedir.

Gelecek araştırmalarda, yapay zekâ teknolojilerinin hava kalitesi yönetiminde daha geniş bir rol oynayacağı öngörülmektedir. Gelişmiş algoritmalar ve daha büyük veri kümeleri, daha hassas tahminler ve etkili iyileştirme stratejileri geliştirilmesine olanak tanıyacaktır. Ayrıca, yapay zekâ tabanlı modellerin gerçek zamanlı izleme sistemlerine entegrasyonu, proaktif hava kalitesi yönetimi için kritik bir adım olacaktır.

Sonuç olarak, yapay zekâ teknolojilerinin hava kalitesi tahmini ve yönetiminde büyük bir potansiyele sahip olduğu açıkça görülmektedir. Bu teknolojiler, hava kirliliği ile mücadelede etkili stratejiler geliştirilmesine yardımcı olabilir ve çevresel sürdürülebilirliği destekleyebilir. Gelecek araştırmalarda, yapay zekâ ve hava kalitesi ilişkisinin daha derinlemesine incelenmesi ve bu alandaki yeniliklerin yakından takip edilmesi önemlidir.

5. Kaynaklar

- [1] S. Sharma, M. Zhang, Anshika, J. Gao, H. Zhang, S.H. Kota, "Effect of Restricted Emissions During COVID-19 on Air Quality in India," *The Science of the Total Environment*, 2020
- [2] K. Balakrishnan, S. Dey, T. Gupta, R.S. Dhaliwal, M. Brauer, A.J. Cohen, J.D. Stanaway, G. Beig, T.K. Joshi, A.N. Aggarwal, Y. Sabde, H. Sadhu, J. Frostad, K. Causey, W. Godwin, D.K. Shukla, G.A. Kumar, C.M. Varghese, P. Muraleedharan, A. Agrawal, R.M. Anjana, A. Bhansali, D. Bhardwaj, K. Burkart, K. Cercy, J.K. Chakma, S. Chowdhury, D.J. Christopher, E. Dutta, M. Furtado, S. Ghosh, A.G. Ghoshal, S.D. Glenn, R. Guleria, R. Gupta, P. Jeemon, R. Kant, S. Kant, T. Kaur, P.A. Koul, V. Krish, B. Krishna, S.L. Larson, K. Madhipatla, P.A. Mahesh, V. Mohan, S. Mukhopadhyay, P. Mutreja, N. Naik, S. Nair, G. Nguyen, C.M. Odell, J.D. Pandian, D. Prabhakaran, P. Prabhakaran, A. Roy, S. Salvi, S. Sambandam, D. Saraf, M. Sharma, A. Shrivastava, V. Singh, N. Tandon, N.J. Thomas, A. Torre, D. Xavier, G. Yadav, S. Singh, C. Shekhar, T. Vos, R. Dandona, K.S. Reddy, S.S. Lim, C.J.L. Murray, S. Venkatesh, L. Dandona, "The impact of air pollution on deaths, disease burden, and life expectancy across the states of India: the Global Burden of Disease Study 2017," *The Lancet Planetary Health*, vol. 3, no. 1, 2019
- [3] C.A. Pope, D.W. Dockery, "Health effects of fine particulate air pollution: Lines that connect," *Journal of the Air and Waste Management Association*, vol. 56, no. 6, 2006
- [4] WHO, "WHO global air quality guidelines: particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide, and carbon monoxide." [Online]. Available: <https://apps.who.int/iris/handle/10665/345329>
- [5] M.A. Zoran, R.S. Savastru, D.M. Savastru, M.N. Tautan, "Assessing the relationship between surface levels of PM_{2.5} and PM₁₀ particulate matter impact on COVID-19 in Milan, Italy," *Science of the Total Environment*, vol. 738, 2020
- [6] J.O. Anderson, J.G. Thundiyil, A. Stolbach, "Clearing the Air: A Review of the Effects of Particulate Matter Air Pollution on Human Health," *Journal of Medical Toxicology*, vol. 8, no. 2, 2012.
- [7] A. Ratajczak, A. Badyda, P.O. Czechowski, A. Czarnecki, M. Dubrawski, W. Feleszko, "Air pollution increases the incidence of upper respiratory tract symptoms among Polish children," *Journal of Clinical Medicine*, vol. 10, no. 10, p. 2150, 2021.
- [8] T. Bourdrel, M.A. Bind, Y. Béjot, O. Morel, J.F. Argacha, "Cardiovascular effects of air pollution," *Archives of Cardiovascular Diseases*, vol. 110, no. 11, 2017.
- [9] R.B. Hamanaka, G.M. Mutlu, "Particulate matter air pollution: effects on the cardiovascular system," *Frontiers in endocrinology*, vol. 9, p. 680, 2018.
- [10] M. Laeremans, E. Dons, I. Avila-Palencia, G. Carrasco-Turigas, J.P. Orjuela, E. Anaya, T. Cole-Hunter, A. De Nazelle, M. Nieuwenhuijsen, A. Standaert, "Short-term effects of physical activity, air pollution and their interaction on the cardiovascular and respiratory system," *Environment international*, vol. 117, pp. 82–90, 2018.
- [11] C. Spix, H.R. Anderson, J. Schwartz, M.A. Vigotti, A. Letertre, J.M. Vonk, G. Touloumi, F. Balducci, T. Piekarski, L. Bacharova, "Short-term effects of air pollution on hospital admissions of respiratory diseases in Europe: a quantitative summary of APHEA study results," *Archives of Environmental Health: An International Journal*, vol. 53, no. 1, pp. 54–64, 1998.
- [12] M. Kampa, E. Castanas, "Human health effects of air pollution," *Environmental pollution*, vol. 151, no. 2, pp. 362–367, 2008.
- [13] L. Schinasi, R.A. Horton, V.T. Guidry, S. Wing, S.W. Marshall, K.B. Morland, "Air pollution, lung function, and physical symptoms in communities near concentrated swine feeding operations," *Epidemiology*, vol. 22, no. 2, 2011
- [14] A.J. Elliot, S. Smith, A. Dobney, J. Thornes, G.E. Smith, S. Vardoulakis, "Monitoring the effect of air pollution episodes on health care consultations and ambulance call-outs in England during March/April 2014: A retrospective observational analysis," *Environmental pollution*, vol. 214, pp. 903–911, 2016.
- [15] Y. Xue, L. Wang, Y. Zhang, Y. Zhao, Y. Liu, "Air pollution: A culprit of lung cancer," *Journal of Hazardous Materials*, vol. 434, 2022.
- [16] T. Pekdogan, M.T. Udriștioiu, H. Yildizhan, A. Ameen, "From Local Issues to Global Impacts: Evidence of Air Pollution for Romania and Turkey," *Sensors*, vol. 24, no. 4, p. 1320, 2024.
- [17] G. Başdoğan, Ç. Arzu, "Ecological-social-economical impacts of vertical gardens in the sustainable city model," *Yuzuncu Yıl University Journal of Agricultural Sciences*, vol. 26, no. 3, pp. 430–438, 2016.
- [18] X. Lu, S. Zhang, J. Xing, Y. Wang, W. Chen, D. Ding, Y. Wu, S. Wang, L. Duan, J. Hao, "Progress of Air Pollution Control in China and Its Challenges and Opportunities in the Ecological Civilization Era," *Engineering*, vol. 6, no. 12, 2020.

- [19] M. Angelidou, A. Psaltoglou, N. Komninos, C. Kakderi, P. Tsarchopoulos, A. Panori, “Enhancing sustainable urban development through smart city applications,” *Journal of Science and Technology Policy Management*, 2018
- [20] L. García, A.J. Garcia-Sanchez, R. Asorey-Cacheda, J. Garcia-Haro, C.L. Zúñiga-Cañón, “Smart Air Quality Monitoring IoT-Based Infrastructure for Industrial Environments,” *Sensors*, vol. 22, no. 23, 2022
- [21] Y. Yang, “IoT-based air pollution monitoring system,” *Highlights in Science, Engineering and Technology*, vol. 17, pp. 299–307, Nov.2022
- [22] Ö. Zeydan, M. Pekkaya, “Evaluating air quality monitoring stations in Turkey by using multi criteria decision making,” *Atmospheric Pollution Research*, vol. 12, no. 5, p. 101046, 2021.
- [23] A. Suleiman, M.R. Tight, A.D. Quinn, “Applying machine learning methods in managing urban concentrations of traffic-related particulate matter (PM10 and PM2.5),” *Atmospheric Pollution Research*, vol. 10, no. 1, 2019
- [24] M. Taştan, “A low-cost air quality monitoring system based on Internet of Things for smart homes,” *Journal of Ambient Intelligence and Smart Environments*, vol. 14, no. 5, 2022
- [25] A. Gacar, H. Aktas, B. Ozdogan, “Digital agriculture practices in the context of agriculture 4.0,” *Pressacademia*, vol. 4, no. 2, 2017
- [26] M.S. Farooq, S. Riaz, A. Abid, T. Umer, Y. Bin Zikria, “Role of iot technology in agriculture: A systematic literature review,” *Electronics (Switzerland)*, vol. 9, no. 2. 2020.
- [27] B. Bahmei, E. Birmingham, S. Arzanpour, “CNN-RNN and Data Augmentation Using Deep Convolutional Generative Adversarial Network for Environmental Sound Classification,” *IEEE Signal Processing Letters*, vol. 29, 2022
- [28] X. Li, L. Peng, X. Yao, S. Cui, Y. Hu, C. You, T. Chi, “Long short-term memory neural network for air pollutant concentration predictions: Method development and evaluation,” *Environmental Pollution*, vol. 231, 2017
- [29] P.W. Tien, S. Wei, J. Darkwa, C. Wood, J.K. Calautit, “Machine Learning and Deep Learning Methods for Enhancing Building Energy Efficiency and Indoor Environmental Quality – A Review,” *Energy and AI*, vol. 10. 2022.
- [30] S.C. Sofuoglu, A. Sofuoglu, S. Birgili, G. Tayfur, “Forecasting ambient air SO2 concentrations using artificial neural networks,” *Energy Sources, Part B: Economics, Planning and Policy*, vol. 1, no. 2, 2006
- [31] R.S. Suri, A.K. Jain, N.R. Kapoor, A. Kumar, H.C. Arora, K. Kumar, H. Jahangir, “Air Quality Prediction-A Study Using Neural Network Based Approach,” *Journal of Soft Computing in Civil Engineering*, vol. 7, no. 1, pp. 93–113, Jan.2023
- [32] A.R. Alsaber, J. Pan, A. Al-Hurban, “Handling complex missing data using random forest approach for an air quality monitoring dataset: A case study of kuwait environmental data (2012 to 2018),” *International Journal of Environmental Research and Public Health*, vol. 18, no. 3, pp. 1–26, Feb.2021
- [33] C.C. Liu, T.C. Lin, K.Y. Yuan, P. Te Chiueh, “Spatio-temporal prediction and factor identification of urban air quality using support vector machine,” *Urban Climate*, vol. 41, Jan.2022
- [34] M.A. Rafif, G. Sanjaya Indrajaya, M.K. Al-Ghazi, J. Johnny, N.T.M. Sagala, “Comparison of Decision Tree and Support Vector Machine for Predicting Jakarta Air Quality Index,” in *ICCoSITE 2023 - International Conference on Computer Science, Information Technology and Engineering: Digital Transformation Strategy in Facing the VUCA and TUNA Era*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 381–385.
- [35] K. Kumar, B.P. Pande, “Air pollution prediction with machine learning: a case study of Indian cities,” *International Journal of Environmental Science and Technology*, vol. 20, no. 5, pp. 5333–5348, May2023
- [36] W.-T. Tsai, Y.-Q. Lin, “Trend Analysis of Air Quality Index (AQI) and Greenhouse Gas (GHG) Emissions in Taiwan and Their Regulatory Countermeasures,” *Environments*, 2021
- [37] J. Toutouh, S. Nesmachnow, D.G. Rossit, “Generative adversarial networks to model air pollution under uncertainty,” in *CEUR Workshop Proceedings*, 2021.
- [38] V. Athira, P. Geetha, R. Vinayakumar, K.P. Soman, “DeepAirNet: Applying Recurrent Networks for Air Quality Prediction,” in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 1394–1403.
- [39] N. Zimmerman, A.A. Presto, S.P.N. Kumar, J. Gu, A. Hauryliuk, E.S. Robinson, A.L. Robinson, R. Subramanian, “A machine learning calibration model using random forests to improve sensor performance for lower-cost air quality monitoring,” *Atmospheric Measurement Techniques*, vol. 11, no. 1, pp. 291–313, 2018
- [40] R. Yu, Y. Yang, L. Yang, G. Han, O.A. Move, “RAQ–A random forest approach for predicting air quality in urban sensing systems,” *Sensors (Switzerland)*, vol. 16, no. 1, Jan.2016

- [41] K. Zhang, J. Yang, J. Sha, H. Liu, "Dynamic slow feature analysis and random forest for subway indoor air quality modeling," *Building and Environment*, vol. 213, 2022
- [42] A. Moradibaad, R. Mashhoud, "Use Dimensionality Reduction and SVM Methods to Increase the Penetration Rate of Computer Networks." 2018.
- [43] M. Gao, L. Yin, J. Ning, "Artificial neural network model for ozone concentration estimation and Monte Carlo analysis," *Atmospheric Environment*, vol. 184, 2018
- [44] J. Ordieres-Meré, E. Vergara, S. Capuz-Rizo, R. Salazar, "Neural network prediction model for fine particulate matter (PM2.5) on the US–Mexico border in El Paso (Texas) and Ciudad Juárez (Chihuahua)," *Environmental Modelling & Software*, vol. 20, pp. 547–559, May 2005
- [45] M.J. Moradi, M.A. Hariri-Ardebili, "Developing a library of shear walls database and the neural network based predictive meta-model," *Applied Sciences*, vol. 9, no. 12, p. 2562, 2019.
- [46] Z. Bai, C. Peng, "Convolutional Neural Network (CNN) Supported Urban Design to Reduce Particle Air Pollutant Concentrations," in *Proceedings of the 28th Conference on Computer Aided Architectural Design Research in Asia (CAADRIA) [Volume 1]*, 2023.
- [47] Y. Mao, S. Lee, "Deep Convolutional Neural Network for Air Quality Prediction," in *Journal of Physics: Conference Series*, 2019.
- [48] E. Akin, M.E. Şahin, "Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme," *EMO Bilimsel Dergi*, vol. 14, no. 1, pp. 27–38, 2024 [Online]. Available: <https://dergipark.org.tr/tr/pub/emobd/issue/83029/1338066>
- [49] S. Ramachandraarjunan, V. Perumalsamy, B. Narayanan, "IoT based artificial intelligence indoor air quality monitoring system using enabled RNN algorithm techniques," *Journal of Intelligent and Fuzzy Systems*, vol. 43, no. 3, 2022
- [50] H. Nurcahyanto, A.T. Prihatno, M.M. Alam, M.H. Rahman, I. Jahan, M. Shahjalal, Y.M. Jang, "Multilevel RNN-Based PM10 Air Quality Prediction for Industrial Internet of Things Applications in Cleanroom Environment," *Wireless Communications and Mobile Computing*, vol. 2022, 2022
- [51] X. Zhao, R. Zhang, J.L. Wu, P.C. Chang, "A deep recurrent neural network for air quality classification," *Journal of Information Hiding and Multimedia Signal Processing*, vol. 9, no. 2, pp. 346–354, Mar. 2018.
- [52] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, W. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," *Advances in neural information processing systems*, vol. 28, 2015.
- [53] S.J. Livingston, S.D. Kanmani, A.S. Ebenezer, D. Sam, A. Joshi, "An ensemble method for air quality monitoring and control using machine learning," *Measurement: Sensors*, vol. 30, 2023
- [54] K. Gaurav, B.K. Singh, V. Kumar, "Intelligent fault monitoring and reliability analysis in safety-critical systems of nuclear power plants using SIAO-CNN-ORNN," *Multimedia Tools and Applications*, 2024
- [55] Z.S. Asaci-Moamam, F. Safi-Esfahani, S. Mirjalili, R. Mohammadpour, M.H. Nadimi-Shahraki, "Air quality particulate-pollution prediction applying GAN network and the Neural Turing Machine," *Applied Soft Computing*, vol. 147, 2023
- [56] A.N. Wu, R. Stouffs, F. Biljecki, "Generative Adversarial Networks in the built environment: A comprehensive review of the application of GANs across data types and scales," *Building and Environment*, vol. 223, 2022.
- [57] S. Sarwar, G. Aziz, D. Balsalobre-Lorente, "Forecasting Accuracy of Traditional Regression, Machine Learning, and Deep Learning: A Study of Environmental Emissions in Saudi Arabia," *Sustainability*, vol. 15, no. 20, 2023
- [58] W. Huang, T. Li, J. Liu, P. Xie, S. Du, F. Teng, "An overview of air quality analysis by big data techniques: Monitoring, forecasting, and traceability," *Information Fusion*, vol. 75, 2021.
- [59] M. Méndez, M.G. Merayo, M. Núñez, "Machine learning algorithms to forecast air quality: a survey," *Artificial Intelligence Review*, vol. 56, no. 9, 2023

Özgeçmiş





Dr. Öğr. Üyesi Tuğçe Pekdoğan, İzmir Yüksek Teknoloji Enstitüsü'nden mimarlık alanında doktora derecesine sahiptir ve aynı üniversitede yüksek lisans yapmıştır. Lisans eğitimini Doğu Akdeniz Üniversitesi'nde fakülte birincisi olarak tamamlamıştır.

Şu anda Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesinde çalışmakta olan Dr. Pekdoğan'ın araştırma alanları arasında bina enerji performansı, ısı transferi, bina enerji modellemesi ve simülasyonu, termal konfor, iç mekan hava kalitesi ve iç çevre kalitesi gibi konular bulunmaktadır. Bu konular üzerine birçok uluslararası ve ulusal makale yayınlamıştır. Science Citation Index (SCI) ve SCI Expanded (SCI-E) indekslerinde yer alan dergilerde 10'dan fazla makalesi yayımlanmış olup, SCOPUS ve diğer mimarlık indekslerinde de çeşitli makaleleri bulunmaktadır.

Ayrıca, TÜBİTAK ve Erasmus+ tarafından desteklenen projelerde de yer almıştır. Öne çıkan projeleri arasında TÜBİTAK 1002 projesi olan "İç Mekan Çevre Kalitesine Çok Yönlü Bir Yaklaşım: Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi Mimarlık Tasarım Stüdyosu Örneği" ve Erasmus+ projesi olan "Hava Kirliliği ile İlgili Bazı İleri Teknolojilerin Öğretim ve Araştırmada Uygulanması" bulunmaktadır. Bina cepheleri için faz değiştiren malzeme ile entegre edilen ısı geri kazanım ünitesinin deneysel ve sayısal araştırması üzerine doktora tezini tamamlamış olup ulusal patenti bulunmaktadır.

Frekans Atlamalı Sinyallerin Tespiti ve Parametre Kestirimine Genel Bir Bakış: Son Gelişmeler ve Zorluklar

An Overview on Detection and Parameter Estimation of Frequency Hopping Signals: Recent Advances and Challenges

 Mutlu Aydın¹, Ali Kara² 

¹Fen Bilimleri Enstitüsü, ²Elektrik-Elektronik Mühendisliği Bölümü
Gazi Üniversitesi, Ankara, Türkiye
mutlu.aydin@gazi.edu.tr, akara@gazi.edu.tr

Öz

Frekans atlamalı yayımlı spektrum (İng. Frequency Hopping Spread Spectrum (FHSS)) ya da kısaca frekans atlamalı (FA), taşıyıcı frekansı değiştiren yaygın bir haberleşme yöntemidir. Frekans atlamalı haberleşme yöntemi, anti-karıştırma kabiliyetinin güçlü olması gibi çeşitli yararlarından dolayı güvenli iletişim bağlantısı için yaygın olarak kullanılmaktadır. Frekans atlama kullanan sistemler arttıkça, frekans atlayan sinyallerinin tespiti ve parametre kestirimine olan ihtiyaç daha da artmış ve bu yöntemlerin geliştirilmesi, güvenlik açısından kritik bir araştırma alanı haline gelmiştir. Bu çalışmada frekans atlamalı sinyalleri tespit ve parametre kestirimi alanındaki son çalışmalar tek ve çoklu hedefler için iki ayrı kategoride incelenmiştir. Ayrıca gelecek araştırma alanları ve zorlukları tartışılmıştır. Böylece gelecekteki çalışmalara yol gösterilmiştir.

Anahtar Kelimeler: Frekans Atlamalı, FHSS, Tespit, Parametre Kestirimi

Abstract

Frequency hopping spread spectrum (FHSS) or simply frequency hopping (FH) is a common communication method that changes the carrier frequency. Frequency hopping communication method is widely used for secure communication link due to its various benefits such as strong anti-jamming ability. As systems using frequency hopping increase, the need for detection of frequency hopping signals and parameter estimation has increased, and the development of these methods has become a critical research area in terms of security. In this study, recent studies in the field of detection and parameter estimation of frequency hopping signals are examined in two separate categories for single and multiple targets. Additionally, future research areas and challenges are discussed. Thus, future studies are guided.

Keywords: Frequency Hopping, FHSS, Detection, Parameter Estimation

1. Giriş

Frekans atlamalı haberleşme yönteminde taşıyıcı frekans belirli bir düzende değiştirilerek iletişim sağlanmaktadır. Bu taşıyıcı frekans değişimlerinin her biri "atlama" olarak isimlendirilmektedir. Frekans atlamalı haberleşme yöntemi,

karıştırmaya karşı dirençli olması gibi çeşitli yararlarından dolayı hem sivil hem de askeri sistemlerde sıklıkla kullanılmakta ve kullanan sistemlerin sayısı giderek artmaktadır [1]. Bu nedenle FA sinyallerin tespiti ve parametre kestirimi yöntemlerinin geliştirilmesi çalışmaları da artmaya devam etmektedir. Bu yöntemlerin özellikle alan güvenliğinin sağlanması açısından hayati bir araştırma alanı haline geldiği görülmektedir.

Frekans atlamalı haberleşmenin güvenli bağlantı amacıyla insansız araçlar tarafından sıklıkla kullanıldığı bilinmektedir [2]. Bundan dolayı FA tespiti ve parametre kestirimine ilişkin çalışmalar özellikle ISM bantlarında çalışan insansız hava araçları (İHA, İng. drone) sinyallerine odaklanmaktadır. Bu durum nedeniyle, FA tespiti ve parametre kestirimine ilişkin gerçek dünya deneylerinin tipik olarak sivil İHA kumanda sinyalleri kullanılarak gerçekleştirildiği görülmektedir [3-7].

Gerçek dünyadaki sivil İHA uygulamalarında, FA sinyallerinin frekans dizisi genellikle sabittir [4]. Bununla birlikte, yeni ve gelişmiş sistemler sözde rastgele atlamalı diziler gibi gelişmiş diziler de kullanılabilmektedir. Ayrıca hızlı frekans atlama yapabilen ve dar atlama bant genişliğine sahip FA sinyalleri de olabilmektedir. Bu nedenlerle FA sinyallerinin tespiti ve parametre kestirimi halen oldukça zorlu bir işittir.

FA sinyal parametre kestiriminde zaman frekans analizi için kısa zamanlı Fourier dönüşümü (STFT) [3-4, 8-10, 18-20, 25] ve Wigner-Ville dağılımı (WVD) kullanılmaktadır [15, 20-21]. WVD yönteminin çözünürlüğü yüksek olmasına rağmen çapraz terim girişimi nedeniyle hesaplaması karmaşıktır. STFT çapraz terim girişiminden etkilenmemesi ve hesaplama basitliği nedeniyle tercih edilmektedir.

Bu çalışmada FA tespit ve sınıflandırma alanındaki güncel çalışmalar incelenmiştir. Ayrıca karşılaştırma için tek ve çoklu hedeflere yönelik iki ana kategorideki çalışmaların özet tabloları oluşturulmuştur. Son olarak gelecek araştırma yönlendirmeleri yapılmış ve alandaki zorluklar tartışılmıştır.

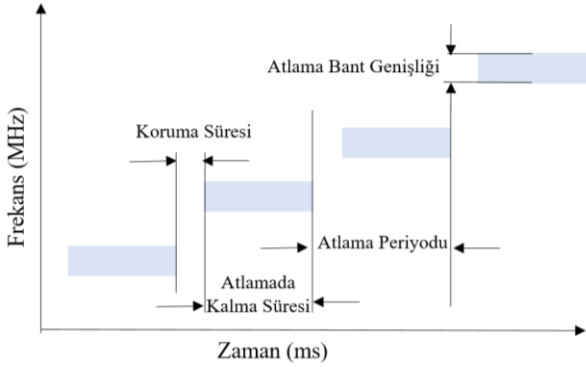
2. FA Sinyal Parametreleri

FA sinyali taşıyıcı frekansını zamanla değiştirmektedir. Bu değişim nedeniyle spektrumda durağan olmayan bir sinyaldir.

Atlama periyodu, atlamada kalma ve koruma (frekans değiştirme) sürelerinin toplamına eşittir. Atlama hızı ise bir saniyedeki atlama sayısıdır ve aşağıdaki gibi hesaplanmaktadır:

$$\text{Atlama Hızı} = \text{Atlama Periyodu}^{-1} \quad (1)$$

Atlama bant genişliği her atlamanın spektrumda kullandığı frekans aralığıdır. Atlama merkez frekansı ise bu aralığın orta noktasıdır. FA sinyali parametreleri Şekil 1'de gösterilmektedir.



Şekil 1: FA sinyali parametreleri gösterimi

3. Güncel FA Sinyal Tespit ve Parametre Kestirimi Çalışmaları

FA tespit ve parametre kestirim yöntemleri iki ayrı kategoriye ayrılmaktadır. İlki, bir defada tek FA sinyali hedefi için çalışan parametre kestirim ve tespit yöntemleridir. İkincisi ise aynı anda çok sayıda FA sinyallerinin tespiti ve parametre kestirimi için tasarlanmış yöntemlerdir. Bu bölümde, bu iki kategorideki güncel çalışmalar incelenecektir.

3.1. Tek FA Sinyal Tespit ve Parametre Kestirimi Çalışmaları

[3]'deki çalışma, STFT yöntemini kullanmış ve eşik hesaplaması yapmıştır. Hesaplanan eşik değeriyle ikileştirilmenin ardından bant genişliği, merkez frekansı ve atlamada kalma süresi parametrelerinin kestirimleri yapılmaktadır. Daha sonra morfolojik genişleme ve erozyon görüntü işleme yöntemleri kullanılmıştır. Atlama periyodu parametresi normalde bir FA sinyalinin tüm atlamaları için eşittir. Ancak çalışmada analiz edilen 2.4 GHz ISM bandındaki İHA'nın FHSS sinyalinin atlamaları için koruma süresi ve bundan dolayı atlama periyodu parametreleri farklıdır. Koruma süresi parametreleri STFT'nin otokorelasyon fonksiyonu (ACF) ile hesaplanır. İHA mesafelerine göre atlama zamanı hataları hesaplanmıştır.

[4]'de STFT, Gaussian filtreleme ve Parametrik Olmayan Genlik Niteleme Yöntemi (NPAQM) gerçekleştirilmiştir. Literatürden farklı olarak algoritmalar bir SDR'nin FPGA'sı içinde çalışacak şekilde dijital tasarım yapılmıştır. Sonuçlar [1]'deki gibi 2.4 GHz ISM bandındaki İHA'nın alıcıya mesafesine göre bekleme süresi parametresinin hatası olarak verilmiştir.

[5]'teki çalışmada işbirlikçi olmayan bir durum için 2.4 GHz ISM bandındaki Gaussian FSK İHA iletişim sinyallerine bir sıkıştırılmalı örnekleme yöntemi uygulanmıştır. Önerilen yöntemin Bluetooth sinyallerine de uyarlanabilir olduğu belirtilmektedir. İHA kumandası tarafından iletilen bit

dizilerini doğrudan tespit etmek amaçlanmakta ve sinyal yeniden yapılandırma aşaması atlanmaktadır. Veri bit dizileri, azaltılmış spektral bilginin (RSI) çıkarılması ve yumuşak algılama algoritması ile elde edilmektedir. RSI, ortogonal eşleştirme takibi (OMP) algoritmasıyla yeniden yapılandırılmıştır.

[8]'de AWGN ve OFDM modülasyonlu girişim sinyallerinin olduğu ortamlarda 2.4 GHz ISM bandı FA sinyallerinin sınıflandırılması için yapay sinir ağı (ANN) tabanlı bir yöntem önerilmektedir. İlk olarak STFT ile elde edilen spektrogramdan merkez frekansı ve atlama periyodu gibi parametre kestirimleri yapılmıştır. Daha sonra çıktı verileri eğitim aşamasına gönderilir. Eğitim sonrasında, ANN tabanlı önerilen yöntem, doğrusal diskriminant (LD) yönteminden daha iyi performans gösterdiği sonucuna ulaşılmıştır.

[9]'daki çalışmada STFT'den elde edilen spektrogramın segmentasyonu için DeepLabv3+ ağı kullanılmıştır. Merkez frekansları sürerlilik (persistence) spektrumundan elde edilir. Frekans atlama dizisi finalde tespit edilir. Bundan sonra sonuçlar, sabit yanlış alarm oranı (CFAR) tespiti ile karşılaştırılır.

[10]'daki çalışmada atlama parametrelerini elde etmek için CenterNet tabanlı bir derin ağ uygulanmıştır. İlk olarak STFT, spektrogram elde etmek için kullanılmıştır. Daha sonra önerilen yöntemin yeteneklerini test etmek için karmaşık elektromanyetik girişim (EMI) ortamı simüle edilmiştir. Son olarak piksel koordinatlarının miritalanmasıyla atlama parametreleri elde edilmiştir. CenterNet tabanlı yöntem, tüm gürültü sinyal oranlarında kestirim performansı açısından YOLOv7 ve YOLOX metodlarından daha iyi performans göstermiştir.

[11]'deki makalede spektrum matrisinin spektral yakınsama özelliklerinin analiz edilmesiyle sembol periyodu kestirimi yapılmaktadır. Sembol-frekans dağılımı ve atlama periyodu başına sembol sayısı elde edilir. Atlama periyodu ve merkez frekans parametreleri, öngörülen spektruma göre kestirilir. Bu yöntem PSK modülasyonlu FHSS sinyalleriyle test edilmiştir. Sonuçlar bu yöntemin düşük sinyal güç oranı koşullarında TFA yönteminden daha iyi performans gösterdiğini göstermektedir.

[12]'de analog bilgi dönüştürücüsüne (AIC) dayalı temel bant parametre kestirimi (BPE) yöntemi adı verilen bir FA parametre kestirimi algoritması gerçekleştirilmiştir. Yöntem, parametre kestirimi için Nyquist frekansının yeniden yapılandırılmasını gerektirmemektedir. Test sonuçları önerilen yöntemin 140.000 atlama/sn'ye kadar kestirim yapabileceğini göstermektedir.

[13]'deki makalede çift pencere spektrogram farkı (DWSD) yöntemi iki farklı pencere uzunluğu kullanılarak gerçekleştirilmiştir. Böylece merkez frekans ve atlama periyodu parametreleri daha doğru kestirilebilmektedir.

[14]'de FA sinyalinin spektral korelasyon fonksiyonundan (SCF) döngüsel özellikler çıkarılmakta ve özellik sınıflandırması, eğitilmiş bir destek vektör makinesi (SVM) sınıflandırıcısı ile gerçekleştirilmektedir. İkili ve bir-sınıflı SVM sınıflandırıcıları eğitilmiştir. İkili olan önceden mevcut etiketli FA sinyallerine sahipken bir-sınıf olan ise sahip değildir.

[15]'de çalışmada herhangi bir ön bilgi olmaksızın kuadratik zaman-frekans dağılım yöntemleri Genişletilmiş değiştirilmiş B-dağılımı (EMBD) ve uyarlanabilir düzleştirilmiş Wigner-Ville (SWWVD) yöntemleri uygulanmıştır.

[16]'daki makalede hibrit CNN/RNN (HCRNN) yöntemi uygulanmıştır. Hibrit CNN/RNN tabanlı yöntem, çeşitli pencere boyutlarındaki spektrogramlardan çıkarılan özellik haritalarını kullanarak yetersiz zaman-frekans çözünürlüğü sorununu azaltmaktadır. Simülasyonlarda, hibrit CNN/RNN tabanlı yöntem, CNN tabanlı ve geleneksel tespit yöntemlerinden daha iyi performans göstermiştir.

[17]'de FA sinyalleri tespit etmek için kalıntı (residual) ağ ve optimize edilmiş genelleştirilmiş S dönüşümü yöntemi önerilmektedir. ResNet, performansı artırmak için derinliğe dayanan CNN modellerinin kaybolan gradyan ve patlayan gradyan sorunlarını çözmek üzere tasarlanmıştır. HCRNN yöntemiyle karşılaştırılmıştır. Önerilen algoritmanın ve HCRNN'nin farklı sinyal güç oranları altındaki sonuçları incelenmiş ve önerilen yöntemin HCRNN'den daha iyi performans gösterdiğini sonucuna varılmıştır.

Tablo 1'de tek FA sinyali tespiti ve parametre kestirimi için olan çalışmalar özetlenmiştir.

Tablo 1: Tek FA Sinyali Tespit ve Parametre Kestirimi Çalışmaları Özet Tablosu

Kaynak	FA Parametreleri	Kullanılan Metotlar	Test Bandı	FA Sinyal Yapısı
[3]	Atlama merkez frekansı Atlamada kalma süresi Koruma süresi Atlama periyodu	STFT Eşik hesaplaması Görüntü İşleme ACF	2.4 GHz ISM	İHA kumandası Aynı atlamada kalma süresi Farklı koruma süresi
[4]	Atlamada kalma süresi	STFT FPGA ile Dijital Tasarım Gaussian filtreleme NPAQM	2.4 GHz ISM	İHA kumandası Aynı atlamada kalma süresi
[5]	Bit dizisi	CS OMP ile RSI çıkarımı	2.4 GHz ISM	İHA kumandası GFSK modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[8]	Atlama merkez frekansı Atlama periyodu	STFT ANN	2.4 GHz ISM	BPSK modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[9]	Atlama periyodu Merkez frekansı Atlama bant genişliği Atlama dizisi	STFT DeepLabv3+ ağı Spektrogram segmentasyonu	-	MSK modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[10]	Atlama merkez frekansı Atlama bant genişliği Atlamada kalma süresi	STFT CenterNet	-	Aynı atlamada kalma süresi Aynı atlama periyodu
[11]	Atlama merkez frekansı Atlama periyodu Sembol periyodu	Spektral yakınsama karakteristiği analizi Sembol-frekans dağılımı	-	PSK modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[12]	Atlama merkez frekansı Atlama periyodu	AIC BPE	-	QPSK modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[13]	Atlama merkez frekansı Atlama periyodu	Çift pencere spektrogram farkı	-	Aynı atlamada kalma süresi Aynı atlama periyodu
[14]	Atlama bant genişliği	SVM SCF	-	QPSK ve QAM modülasyon Aynı atlamada kalma süresi Aynı atlama periyodu
[15]	Atlama merkez frekansı Atlama periyodu Atlama dizisi	EMBD ve SWWVD	-	Yavaş atlama hızı QPSK modülasyon
[16]	Atlama merkez frekansı Atlama bant genişliği Atlama periyodu	Hibrit CNN/RNN	-	Aynı atlamada kalma süresi Aynı atlama periyodu
[17]	Atlama merkez frekansı Atlama bant genişliği Atlama periyodu	ResNet Optimize genelleştirilmiş S-dönüşümü	-	Aynı atlamada kalma süresi Aynı atlama periyodu

3.2. Çoklu FA Sinyal Tespit ve Parametre Kestirimi Çalışmaları

[6]'daki çalışmada geliştirilmiş bir K-ortalama kümeleme yöntemini kullanarak 2.4 GHz ISM bandındaki birden fazla frekans atlamalı İHA sinyallerini tespit eden bir yöntem önerilmektedir. Ayrıca adaptif eşikleme ve kronolojik sınıflandırma yöntemleri kullanılmıştır. Test sonuçları önerilen yöntemin aynı anda çalışan farklı İHA kumanda sinyallerinin parametrelerini kestirmek için kullanılabileceğini göstermektedir.

[7]'de, birden fazla FA sinyalini tespit etmek için Goodness-of-Fit (GoF) ve Derin Kalıntı Sinir Ağı (DRNN) ile iki aşamalı bir tespit ve sınıflandırma önerilmiştir. Ayrıca YOLO-lite yöntemiyle birleştirilmiş bir tespit ve sınıflandırma yöntemi de kullanılmıştır. 2.4 GHz ISM bandında 9 İHA ve 2 Wi-Fi sinyali ile gerçekleştirilen testlerde frekans domaininde örtüşme olsa dahi başarılı tespit yapılabildiği doğrulanmıştır.

[18]'deki makalede birden fazla FA sinyalinin kör tespiti için FA Sinyal Parametre Çıkarıcısı (FHExt) olarak adlandırılan derin öğrenmeye dayalı bir parametre kestirim yöntemi önerilmektedir. STFT kullanılmıştır. 1.9-2.1 GHz bandında gerçekleştirilen deney sonuçlarına göre FHExt'in tamamen kör senaryolarda çalışabildiğinin doğrulanmasının yanı sıra yarı kör senaryolara da uyarlanabildiği gösterilmiştir.

[19]'da sinyallerin frekans atlama tanımlama kelimelerini (HDW) sınıflandırmak için sinir ağı (NN) tabanlı bir sinyal sınıflandırma algoritması önerilmektedir. STFT ve geri-yayılım tabanlı eşlenik gradyan algoritması kullanılmıştır. Simülasyon sonuçlarına göre önerilen algoritmanın hızlı olduğu ve düşük sinyal güç oranı koşullarında iyi sınıflandırma doğruluğu sağladığı gösterilmiştir.

[20]'deki çalışmada STFT ve düzeltilmiş sözde Wigner-Ville dağılımı (SPWVD) birleştiren bir yöntem kullanılarak birden fazla FA sinyalinin kör parametre kestirimi gerçekleştirilmiştir. Farklı ağ modları için atlama periyodu, zamanlama ve merkez frekans parametrelerinin kestirilebileceği gösterilmiştir.

[21]'deki makalede çoklu FA sinyalleri için birkaç-adımlı (İng. few-shot) öğrenmeye dayalı bir kör parametre kestirim yöntemi önerilmektedir. Derin öğrenme temelli zaman frekans sırt (İng. ridge) tespiti ve öznitelik üretimi gerçekleştirilmiştir. Test sonuçları önerilen yöntemin çeşitli gürültü sinyal oranı koşulları altında sadece birkaç ek açıklama ile bile doğru parametre kestirimi yapabildiğini göstermektedir.

[22]'de, bilinmeyen birden fazla sayıdaki FA sinyallerinin sıkıştırılmalı spektrum algılama ve maksimum olasılık (CSML) bazlı frekans ve atlama süresi parametre kestirimi önerilmektedir. Önerilen algoritmanın birden fazla FA sinyal frekansını hızlı ve doğru bir kestirimini gerçekleştirebildiği gösterilmiştir. Ayrıca koruma (frekans değiştirme) süresine sahip birden fazla FA sinyal için de kullanılabileceği doğrulanmıştır.

[23]'teki çalışmada düşük sinyal-gürültü oranı koşulları altında birden fazla FA sinyalini tespit etmek için tek atış dedektörü (SSD) derin sinir ağına (DNN) dayalı bir yöntem

önerilmektedir. Yüksek güçlü gürültü koşulları için zaman-frekans grafiği düzeltme yöntemi olan K-ortalama kümelemesi kullanılmıştır.

[24]'te, uzay-zaman frekans dağılımına (STFD) ve müşterek köşegenleştirme matrisine (JDM) dayalı bir kör parametre kestirim algoritması önerilmektedir. Yön parametresi (DOA) kestirimi için root-MUSIC algoritması kullanılmıştır. Önerilen algoritmanın, birden fazla FA sinyalinin parametrelerini seyrek doğrusal regresyon (SLR) yöntemine göre daha doğru bir şekilde kestirebildiği belirtilmektedir.

[25]'deki makalede zaman frekans parametrelerini hesaplama maliyetini azaltmak amacıyla bir hayalet modül kullanan YOLOv5 modelini temel alan geliştirilmiş bir nesne dedektörü önerilmiştir. Tekdüze dairesel dizideki birden fazla FA sinyalinin 2 boyutlu DOA parametresi STFD yöntemiyle kestirilmektedir. STFT ve hüzmeuzay (İng. beam-space) dönüşümü yöntemleri kullanılmıştır.

Yukarıda incelenen ilgili çalışmaların özeti Tablo 2'de gösterilmektedir.

4. Gelecek Araştırma Yönlendirmeleri ve Araştırma Zorlukları

Tablo 1 ve Tablo 2'den anlaşılacağı üzere çalışmaların sadece birkaçı, önerdikleri yöntemin etkinliğini doğrulamak için 2 GHz civarında bir test bandını özellikle de 2.4 GHz ISM bandını kullanmıştır. Test sinyalleri frekans atlamalı İHA kumandası, Wi-Fi ve çeşitli modülasyonlara sahip sinyalleri içermektedir. Farklı tipteki FA sinyallerin de gerçek dünya testlerinde kullanılabileceği değerlendirilmektedir. Bu nedenlerle önerilen yöntemlerin gerçek dünya testleri konusunda eksik olduğu görülmektedir. Test edilmemiş yöntemlerin gerçek dünyada test edilmesi, test edilenlerin ise farklı frekans bantlarında farklı hedef sinyalleri ile test edilmeleri önerilmektedir.

Çok geniş bantlarda atlama yapabilen özellikle askeri FA iletişim sistemleri olabilmektedir. Bu da gerçek zamanlı (anlık) bant genişliği parametresinin önemini ortaya koymaktadır. Literatürde en fazla 200 MHz bant genişliği ile gerçek dünya testleri gerçekleştirilmiştir. Daha geniş bant genişlikleri sistem maliyetlerini ve ayrıca hesaplama maliyetini oldukça artırmaktadır. Ayrıca sistem boyutlarının büyümesine sebep olduğundan taşınabilirliği olumsuz etkilemektedir. Ayrıca gürültünün gücü bant genişliği ile doğru orantılı olarak artmakta ve dar bant almaçların gürültü figürü düşük olmaktadır. Etkin güvenliğin sağlanabilmesi için hedef sistemlerin kullanılabileceği tüm bantları kapsayacak şekilde algılama yapılması gerektiğinden yüksek frekans bantlarını da kapsayacak çok kanallı almaç sistemleri tasarımının gelecek sistemlerde çok daha önemli olacağı değerlendirilmektedir.

FA sinyallerinin doğru bir şekilde tespit edilmesi ve parametrelerinin kestirilmesi kadar bu işlemin hızlı bir şekilde yapılması da güvenlik açısından kritiktir. Bu nedenle önerilen yöntemlerin FPGA gibi gerçek zamanlı platformlara taşınabilir olmasının büyük önem taşıdığı değerlendirilmektedir.

Tablo 2: Çoklu FA Sinyali Tespit ve Parametre Kestirimi Çalışmaları Özet Tablosu

Kaynak	Kullanılan FA Parametreleri	Kullanılan Metotlar	Test Bandı	FA Sinyallerinin Yapısı	FA Sinyal Sayısı
[6]	Bant genişliği Dalga Şekli Tepe Enerji Atlamada kalma süresi	Adaptif eşikleme Gelişmiş K-ortalama kümeleme Kronolojik sınıflandırma	2.4 GHz ISM	İHA kumandası Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi	1-2
[7]	Atlama merkez frekansı Atlama bant genişliği Atlamada kalma süresi Modülasyon	GoF ve DRNN YOLO-lite	2.4 GHz ISM	9 İHA kumandası 2 Wi-Fi Frekansta örtüşme	11
[18]	Atlama merkez frekansı Atlama bant genişliği Atlamada kalma süresi Atlama periyodu	STFT K-ortalama kümeleme FHExt ResNet-50	1.9 – 2.1 GHz	23 modülasyon Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta kısmi örtüşme	2,3,4
[19]	Atlama merkez frekansı Atlama zamanı Güç	STFT NN BP-Eşlenik gradyan algoritması	-	Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Farklı atlama zamanı Frekansta örtüşmeme	4
[20]	Merkez frekansı Atlama periyodu Koruma süresi	STFT SPWVD	-	Tek FA sinyalinde aynı atlamada kalma süresi ve farklı koruma süresi Frekansta örtüşmeme	2
[21]	Atlama merkez frekansı Atlamada kalma süresi Atlama hızı	SPWVD DL temelli TF sırt tespiti Few-shot öğrenme	-	AM, FM, BPSK, QPSK ve 16QAM modülasyon Bir FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta örtüşmeme	1-6
[22]	Atlama merkez frekansı Atlama zamanı	Segmentasyon CSML Ortalama ve sıfır-düzenleme	-	Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta örtüşmeme	2
[23]	Atlama merkez frekansı Atlama zamanı Atlama periyodu Atlama bant genişliği	DNN SSD K-ortalama kümeleme	-	BPSK, QPSK, QAM modülasyon Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta örtüşmeme	1-2
[24]	Atlama merkez frekansı Atlama zamanı Atlama periyodu DOA	STFD JDM Root-MUSIC	-	Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta örtüşmeme	3
[25]	Atlama merkez frekansı Atlama bant genişliği Atlama zamanı Atlama periyodu 2-D-DOA	STFT STFD YOLOv5 Hüzmeuzay dönüşümü	-	Tek FA sinyalinde aynı atlama periyodu ve atlamada kalma süresi Frekansta örtüşmeme	5

5. Sonuç

Bu makalede frekans atlamalı sinyallerin tespiti ve parametre kestirimi alanındaki son çalışmalar tek ve çoklu hedefler için iki ayrı kategoride incelenmiştir. Karşılaştırma için özet tabloları oluşturulmuştur. Ayrıca gelecek araştırma alanları ve bu alanlardaki zorlukları incelenen çalışmalar üzerinden tartışılmıştır. Dolayısıyla gelecekteki çalışmalara yol gösterme açısından önemli bir çalışma ortaya çıkmıştır.

6. Kaynaklar


- [1] D. Torrieri, *Principles of Spread-Spectrum communication systems*. Springer, 2018.
- [2] V. V. D. Knaap, M. Mouri, ve P. Zwamborn, “MSG-SET-183 – Detection and Characterization of a UAS RF FHSS Communication Link,” *NATO S&T Organization*, 2021.
- [3] B. Kaplan, I. Kahraman, A. Gorcin, H. A. Cirpan, ve A. R. Ekti, “Measurement based FHSS-type drone controller detection at 2.4GHz: An STFT approach,” *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, 2020.
- [4] P. Flak, “Drone detection sensor with continuous 2.4 ghz ISM band coverage based on cost-effective SDR platform,” *IEEE Access*, vol. 9, pp. 114574–114586, 2021.
- [5] D. Mototolea, R. Youssef, E. Radoi, ve I. Nicolaescu, “Non-cooperative low-complexity detection approach for FHSS-GFSK drone control signals,” *IEEE Open Journal of the Communications Society*, vol. 1, pp. 401–412, 2020.

- [6] J. Ye, "A new frequency hopping signal detection of civil UAV based on improved K-means clustering algorithm," *IEEE Access*, vol. 9, pp. 53190–53204, 2021.
- [7] S. Basak, S. Rajendran, S. Pollin, ve B. Scheers, "Combined RF-based drone detection and classification," *IEEE Transactions on Cognitive Communications and Networking*, vol. 8, no. 1, pp. 111–120, 2022.
- [8] M. T. Khan, A. Z. Sha'ameri, ve M. M. Zabidi, "Classification of FHSS signals in a multi-signal environment by Artificial Neural Network," *International Journal of Computing and Digital Systems*, vol. 11, no. 1, pp. 775–789, 2022.
- [9] Z. Deng, ve J. Lei, "Spectrogram-based frequency hopping signal detection in a complex electromagnetic environment," *2022 7th International Conference on Signal and Image Processing (ICSIP)*, 2022.
- [10] Z. Chen, "Unlocking signal processing with image detection: A frequency hopping detection scheme for complex EMI environments using STFT and CenterNet," *IEEE Access*, vol. 11, pp. 46004–46014, 2023.
- [11] H. Zhu, H. Lv, Z. Dai, M. Tan, ve W. Song, "A novel parameter estimation method of fhss signal with low snr," *IEEE Transactions on Electrical and Electronic Engineering*, vol. 18, no. 6, pp. 891–900, 2023.
- [12] L. Zhi, Z. Jianhua, C. Hao, G. Xu, ve L. Jian, "Parameter estimation of frequency hopping signals based on analogue information converter," *IET Communications*, vol. 13, no. 13, pp. 1886–1892, 2019.
- [13] Y. He, Y. Su, Y. Chen, Y. Yu, ve X. Yang, "Double window spectrogram difference method: A blind estimation of frequency-hopping signal for battlefield communication environment," *2018 24th Asia-Pacific Conference on Communications (APCC)*, 2018.
- [14] Md. Z. Hasan, D. J. Couto, M. A. Abdel-Malek, ve J. H. Reed, "Frequency hopping signal detection in low signal-to-noise ratio regimes," *2023 IEEE 34th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2023.
- [15] A. Kanaa ve A. Z. Sha'ameri, "A robust parameter estimation of FHSS signals using time–frequency analysis in a non-cooperative environment," *Physical Communication*, vol. 26, pp. 9–20, 2018.
- [16] K.-G. Lee ve S.-J. Oh, "Detection of Frequency-Hopping signals with deep learning," *IEEE Communications Letters*, 24(5), 1042–1046, 2020.
- [17] C. Li, Y. Chen, ve Z. Zhao, "Frequency hopping signal detection based on optimized generalized S transform and ResNet," *Mathematical Biosciences and Engineering*, vol. 20, no. 7, pp. 12843–12863, 2023.
- [18] Y. Wang, H. Liao, S. Yuan, ve N. Liu, "A Learning-Based signal parameter extraction approach for Multi-Source Frequency-Hopping signal sorting," *IEEE Signal Processing Letters*, vol. 30, pp. 1162–1166, 2023.
- [19] Z. Wang, B. Zhang, Z. Zhu, Z. Wang, ve K. Gong, "Signal sorting algorithm of hybrid frequency hopping network station based on neural network," *IEEE Access*, vol. 9, pp. 35924–35931, 2021.
- [20] D. Zhang, Y. Shang, X. Liang, ve J. Lin, "Efficient blind estimation of parameters for multiple frequency hopping signals via single channel," *2022 IEEE 5th International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)*, 2022.
- [21] K. Lu, Z. Qian, M. Wang, ve D. Wang, "Few-shot learning based blind parameter estimation for multiple frequency-hopping signals," *Multidimensional Systems and Signal Processing*, vol. 34, no. 1, pp. 271–289, 2023.
- [22] Y. Li, F. Wang, G. Fan, Y. Liu, ve Y. Zhang, "A fast estimation algorithm for parameters of multiple Frequency-Hopping signals based on compressed spectrum sensing and maximum likelihood," *Electronics*, vol. 12, no. 8, p. 1808, 2023.
- [23] Y. Wang, "Detection and parameter estimation of frequency hopping signal based on the deep neural network," *International Journal of Electronics*, vol. 109, no. 3, pp. 520–536, 2021.
- [24] J. Wan, D. Zhang, W. Xu, ve Q. Guo, "Parameter estimation of multi frequency hopping signals based on space-time-frequency distribution," *Symmetry*, vol. 11, no. 5, p. 648, May 2019.
- [25] M. Lin, Y. Tian, X. Zhang, ve Y. Huang, "Parameter estimation of Frequency-Hopping signal in UCA based on deep learning and spatial Time–Frequency distribution," *IEEE Sensors Journal*, vol. 23, no. 7, pp. 7460–7474, 2023.

Özgeçmişler



Mutlu Aydın, Elektrik-Elektronik Mühendisliği lisans derecesini 2020 yılında Türk Hava Kurumu Üniversitesi'nde tamamladı. 2020 yılından itibaren TÜBİTAK BİLGEM İLTAREN'de Radyo Frekans (RF) elektronik harp sistem ve algoritma geliştirme alanında çalışmaktadır. Muhabere ve radar elektronik harp sistemleri ve algoritmaların tasarımı, laboratuvar ve açık saha ölçüm, analiz, test ve doğrulamasının gerçekleştirilmesi konularında tecrübe sahibidir. Özellikle yazılım tanımlı radyolar (Software Defined Radio) ve açık kaynak GNU Radio kütüphanesi üzerine odaklanmaktadır. Şu anda, Gazi Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde frekans atlamalı sinyallerin tespiti konusunda yüksek lisans çalışmalarına devam etmektedir.



Ali Kara, 2002 yılında Hacettepe Üniversitesi'nden Elektrik-Elektronik Mühendisliği alanında Doktor unvanını aldı. 1999-2000 yılları arasında Symbol Technologies/Motorola ile ortak sanayi projesinde New York Üniversitesi, Brooklyn kampüsünde araştırma görevlisi olarak çalıştı. 2000 yılında Atılım Üniversitesi Elektrik-Elektronik Mühendisliği bölümüne katıldı ve çeşitli görevlerde bulundu. 2021 yılına kadar Atılım Üniversitesi Fen Bilimleri Enstitüsü müdürü olarak görev yaptı. Aynı zamanda 2006-2012 yılları arasında TÜBİTAK BİLGEM'de danışman ve baş araştırmacı olarak çalışarak ulusal savunma ve güvenlik projelerine katkıda bulundu. Devlet ve sanayi tarafından finanse edilen birçok projede aktif olarak yer aldı. Genel olarak elektromanyetik dalgalar, kablosuz haberleşme, radar ve elektronik harp sistemleri ile mühendislik eğitimi alanlarında birçok araştırma projesine liderlik etti. Bir eğitim projesinde, Avrupa üniversitelerinden araştırmacıların yer aldığı Sanal ve Uzak Laboratuvar (VRL) platformu (ERRL- Avrupa Uzak Radyo Laboratuvarı) geliştirilmesine öncülük etti. Bu platform Avrupa Komisyonu tarafından finanse edildi. Dr. Kara'nın beş adet patent tescili bulunmaktadır. Son yıllarda yapay zekanın (ML/DL) uzmanlık alanlarındaki sorunları çözmek için kullanımına odaklanmaktadır.

Cam İşletmesinde Enerji Verimlilik Potansiyeli ve İyileştirme Çalışmaları

Energy Efficiency Potential Analysis and Improvement Studies in Glass Industry

 İrem DÜZDAR *,  Elif AKIN* ve  Tuğçe ÖZDEMİR**

*Düzce University, Industrial Engineering, Duzce, Turkey
akinnelif9@gmail.com , ORCID: 0000-0001-7463-5410
iremduzdar@duzce.edu.tr , ORCID: 0000-0002-7642-8121
**Düzce Cam San. ve Ltd., R&D Department, Duzce, Turkey
tugcee1508@gmail.com , ORCID: 0000-0001-9716-4770

ÖZ

Enerjinin kullanımı nüfus artışı, sanayileşme, gelir artışı ile tüm dünya ülkelerinde artarken, bu kullanım artışı ile birincil enerji kaynaklarımız tükenmekte, enerji maliyetleri artmakta ve doğanın kirlenmesi gibi büyük problemlere yol açmaktadır. Bu problemlerin önüne geçmek amacıyla gelişmiş ve gelişmekte olan ülkeler enerji verimliliği konusuna çok fazla önem vermektedir. Tüm dünyada enerjinin yoğun olarak kullanıldığı sektörlerin başında sanayi gelmektedir. Bu çalışmada ise float cam üretimi yapan bir işletmede enerji verimliliği ve maliyetleri üzerinde durulmuştur. İşletmenin 2022 yılındaki Kasım ayına kadar olan üretim ve enerji tüketim verileri regresyon analizi yöntemi ile standart denklem ve hedef denklem oluşturularak enerji tasarruf potansiyeli incelenmiştir. İşletmenin tasarruf potansiyeli 7594,7 TEP/yıl olarak bulunmuştur. 2022 yılı için tasarrufun mali değeri 17,334 €/yıl olarak hesaplanmıştır. İşletmedeki yapılacak iyileştirme çalışmalarının mali katkısı incelendiğinde ise banyo alt kasa değişimi ile 403.737 €, aydınlatma değişimi ile ise 8.851 € tasarrufu sağlanacağı belirlenmiştir.

Anahtar sözcükler: Enerji Verimliliği, Verimlilik, Maliyet Analizi, Regresyon, Enerji Tasarruf Potansiyeli

Abstract

While the use of energy is increasing in all countries of the world with population growth, industrialization and income increase, this increase in use leads to major problems such as depletion of our primary energy resources, increase in energy costs and pollution of nature. In order to prevent these problems, developed and developing countries attach great importance to energy efficiency. Industry is one of the leading sectors where energy is used intensively all over the world. This study focuses on energy efficiency and costs in a float glass manufacturing company. The production and energy consumption data of the enterprise until November 2022 are analyzed by regression analysis method by creating standard equation and target equation and energy saving potential is analyzed. The saving potential of the enterprise was found to be 7594.7 TOE/year. For the year 2022, the financial value of the savings was calculated as 17,334 €/year. When the financial contribution of the improvement works to be carried out in the enterprise is analyzed, it is determined that 403.737 €, will be

saved with the replacement of the bathroom bottom case and 8.851 € will be saved with the lighting replacement.

Key words: Energy Efficiency, Efficiency, Cost Analysis, Regression, Energy Saving Potential

1. Giriş

Ülkelerin toplumsal olarak gelişmesini sağlayan unsurlarının başında enerjinin kullanımı gelmektedir. Enerji hem günlük yaşamımız için hem de enerji ve sanayi ürünlerinin üretilmesi için en önemli yaşamsal girdilerden birisidir. Hayatın devamlılığı için enerjiyi kesinti yaşamadan, güvenli, zamanında, temiz ve düşük fiyatlı yollardan temin etmek tüm dünya ülkeleri için en önemli konulardan birisidir [1].

Ancak gelecek yıllarda dünyada kullanılan başlıca enerji kaynakları olan doğal gaz, kömür ve petrol rezervlerinin zamanla azalacağı ve bununla birlikte fiyatlarının yükseleceği öngörülebilir bir gerçektir. Bu nedenle gelişmiş ve gelişmekte olan ülkelerin önceliği yeni ve yenilenebilir enerji kaynaklarının kullanımı, enerji maliyetlerini düşük tutmak, enerjiyi verimli kullanabilmek için enerji tasarruf çalışmalarına önem vermektir [2].

Enerji verimliliği; enerjinin üretilmesi, iletilmesi ve dağıtılması için yapılan tüm çalışmaları kapsamaktadır. Yapılan işin kalitesinde herhangi bir azalma olmadan, daha az enerji tüketilerek işin yapılması anlamına gelmektedir. Enerji verimliliği çalışmaları, ekonomik olarak büyüme ve sosyal kalkınma hedeflerinin sürdürülebilir olması ile birbiriyle ilişkilidir, ayrıca doğaya verilen zararları da minimum düzeye indirmeye çalıştığı için, önemle dikkat edilmesi gereken konuların başındadır [3].

Enerji verimliliği ile:

- Fosil kaynakların hızla tükenmesi,
- Alternatif ve yeni enerji kaynaklarının maliyetinin yüksek olması,
- Artan enerji talebi dolayısı ile enerji fiyatlarının artışı,
- Kullanılan yerli enerji kaynaklarının ithal bağımlılığın önüne geçememesi,
- İklim değişikliklerine yol açması,

- Enerji üretildiğinde ortaya çıkan gazların hem insan sağlığı hem de çevreye zarar vermesi

Gibi tüm dünyaya zarar veren sorunların önüne geçmek mümkündür [4].

Dünyada tüketilen enerjinin büyük bir kısmı ise sanayi sektöründe tüketilmektedir. Bundan kaynaklı enerji verimlilik çalışmalarında en çok yoğunlaşılması gereken alan sanayi sektörüdür. Gelişmiş ülkelerde de enerji tasarrufu çalışmaları özellikle sanayi sektöründe yoğunlaşmaya başlamıştır. Çalışmaların bu alanda artmasının birtakım sebepleri vardır. Bunlar:

- Enerjide tasarruf edilebilme potansiyeli, örneğin konut sektöründen daha az olsa da bu tasarruf çalışmaları daha az maliyetle gerçekleştirilebilmektedir ve enerji yatırım ortalama üç sene de geri ödeme süresini doldurmaktadır.
- Sanayideki enerji verimlilik çalışmaları, genellikle sanayi sektöründe modernleşme ve sektörde rekabet koşullarının gelişmesinde etkin bir rol oynamaktadır.
- Enerji muhasebesi ve tüketim maliyetlerinin hesaplanabilirliği, diğer sektörlere oranla sanayide daha profesyonelce bilinen bir konudur [5].

Bu çalışmada, float cam üretim sektöründe faaliyet gösteren Düzce Cam'da enerji kaynağı olarak kullanılan GES ve ORC sistemleri incelenmiştir. Atık ısı kazanımlı ORC sistemi ve işletme çatısının uygun olan kısımlarına kurulan güneş enerji sistemi ile tüm işletmede kullanılan enerjinin bir kısmı bu sistemlerden karşılanmaktadır. Sanayi işletmesinde 2022 Kasım ayına kadar olan enerji tüketimi, işletmede kullanılan enerji kaynakları incelenmiştir. İşletmenin üretim miktarı ve enerji tüketim miktarı verileri incelenerek regresyon analizi ile enerji tasarruf potansiyeli tespit edilmiştir. İşletmede enerji ile ilgili yapılan çalışmalar incelenerek sağladıkları mali katkı bulunmuştur. Projedeki amaç işletmedeki enerji verimliliğine katkı sağlayabilmektir.

2. Literatür Araştırması

Çalışmanın bu bölümünde literatür incelenerek enerji verimliliği konusunda yapılan çalışmalara değinilecektir. Kıyılmaz ve arkadaşları (2021), bu çalışmada gıda sektöründe faaliyetini sürdüren dondurma tesisinde enerji etüdü çalışması yapılarak enerji yönetiminde yapılabilecek iyileştirme olanakları ve verimlilik artırıcı projelerden bahsedilmiştir. Etüt çalışmasıyla tesisin enerji tüketim kaynakları ve maliyetleri verilerine ulaşılmış, yıllık enerji tüketimi ve SET değerleri karşılaştırılmıştır. Yapılan etüt çalışmasıyla kısa zamanda geri dönüş alınabilecek üç nokta bulunmuş ve öncelikle bu alanlarda çalışma yapılması önerilmiştir. Bu üç verimlilik artırıcı projeye yılda 1 GW'a yakın enerji tasarrufu sağlandığını söylemektedirler. Bu tasarrufla beraber 1200733 kg CO₂ salınımı önüne geçilecektir [6].

Turgut (2008), bu çalışmada Denizli ilinde faaliyet gösteren altı tekstil fabrikasında gerçekleştirilmiştir. Her bir fabrikanın tesis bilgilerine, kullanılan makinalara, iş akış semalarına, buhar kazanı özellikleri, analiz sonuçlarına ve baca gazı ölçüm sonuçlarına ulaşılmıştır. Ardından regresyon analiziyle bu fabrikaları gruplayarak üretim ve enerji tüketim ilişkisi incelenmiştir. Bu altı fabrikanın baca gazı analizleri sonucunda

yapılacak verimlilik oranı bulunmuş ve yıllık TL bazında enerji tasarruf imkânı bulunmuştur [7].

Söğüt ve arkadaşları (2019), bu çalışmada tekstilde kullanılan boyalar konusunda üretim gerçekleştiren bir işletmenin enerji verimlilik potansiyeli değerlendirilmiştir. İşletmede enerji taraması yapılarak toplam enerji tüketim dağılımları incelenmiştir. Verimlilik değerlendirilmesi için ise iki yöntem kullanılmıştır. Üretim üzerinden regresyon analizine bağlı tasarruf %28,03 çıkmıştır, histograma ile hedef enerji tüketimi ise %13,51 olarak bulunmuştur [8].

Akkurt ve Taşdemir (2021), bu çalışmada muhtelif altyapı ürünleri üreten bir işletmede enerji etüt çalışması yapılmıştır. İşletmenin son üç yılın enerji tüketim miktarı ve maliyet verileri alınmıştır. Bu veriler ton eşdeğer petrol (TEP) değerine dönüştürülmüştür. İşletmenin enerji tasarruf potansiyelinin belirlenmesi için standart denklem ve hedef denklem bulunmuştur [9].

Yüksel (2020), çalışmasını petro- kimya fabrikasında enerji verimliliği etüdü yapmıştır. İşletmenin 2015-2017 yıllarına ait enerji tüketimi ve maliyeti verileri toplanmış. Üretim ile enerji arasındaki ilişkiyi incelenmiş ve enerji tasarrufu yapılabilecek noktaları belirlemiştir. Enerji verimliliği artırıcı projeler geliştirilmiş ve geri ödeme sürelerini hesaplamıştır [10].

Işık ve Akan (2018), çalışma kürk-süet üretimi gerçekleştiren bir işletmede enerji tasarruf projelerine yardımcı olmak amacıyla gerçekleştirilmiştir. İşletmenin 2016 yılı enerji taraması yapılmıştır. Kullanılan enerji kaynaklarının enerji tüketim ve maliyet değerleri, üretim adedi verileri toplanmıştır. İşletmenin enerji verimliliği ve performansını inceleyebilmek için Spesifik Enerji Tüketimi (SET) yöntemi kullanılmıştır. Standart ve hedef eğrileri bulunarak enerji tüketim değerleri hesaplanmıştır. Hesaplanan bu verilere göre tasarrufun 2017 yılı için yaklaşık 180000 TL olacağını söylemişlerdir [11].

Söğüt ve Oktay (2006), bu çalışma çimento üretim sektöründe olan bir işletmede enerji taraması yapmış ve yapılan enerji taraması ile mevcut enerji tasarruf projelerine katkı sağlamayı hedeflemişlerdir. Fabrikanın 2004 yılına ait üretim ve enerji tüketim verileri incelenmiştir. Regresyon analizi ile tüketim eğrisi elde edilmiş ardından tüketim eğrisinin altında kalan noktalar ile hedeflenen eğri elde edilmiştir. Hesaplanan değerler ile Kümülatif Toplam Değerler (CUSUM) grafiği çizilmiştir. İşletmenin 2005 yılı hedef enerji tüketimine ulaşması için önerilerde bulunulmuştur [12].

Çakal (2006), çalışma Tekirdağ'da tarım makinesi imalatı yapan 3 firmada enerji yönetimi incelenmiştir. Bu firmalarda enerji yönetimi ile ilgili çalışma yapılmamıştır. 2 işletmenin son 5 yılına, 1 işletmenin ise son 4 yılına ait elektrik tüketim değerleri ve 3 işletmenin 2005 yılı için üretim değerleri incelenmiştir. Enerji tüketim miktarı- üretilen tarım makinesi adedi arasındaki ilişkiler, enerji tüketim miktarı- üretilen tarım makinesi ağırlığı arasındaki ilişkiler, SET değerleri incelenmiştir. İşletmelerin elektrik tüketimine göre en yüksek enerji tüketimini Firma-3, en düşük enerji tüketimini ise Firma-2 yapmaktadır [2].

CO₂ emisyonunu önleme hedeflerinden yararlanmak için enerji verimliliği iyileştirmesinin devreye girdiği yerde enerjinin verimli kullanımı yoluyla enerji israfının azaltılması, iklim değişikliğiyle enerji talebi yönlü kanallardan mücadele etmenin etkili bir yolu olabilir [13].

Cam imalatında enerji verimliliğinin artırılmasına çeşitli yönlerden yaklaşılmalıdır. Güçlü, kurumsal çapta bir enerji yönetimi programı ile tesis, operasyonlar, çevre, sağlık ve

güvenlik ve yönetim personelini içerecektir. Enerji tasarruflu motorların kullanımı ve basınçlı hava sistemlerinin optimizasyonu gibi teknolojilerdeki enerji verimliliği iyileştirmeleri, enerji tasarrufu için iyi fırsatlar sunmaktadır. Proses atık ısı geri kazanımını en üst düzeye çıkarmak gibi sistem tasarımını ve operasyonlarını optimize etmek de enerji kullanımında önemli azalmalara yol açabilir [14].

Üretimde çoğu işlemin yüksek sıcaklık ve basınç koşulları altında gerçekleştiği ürünlerde, süreçler arasındaki ısı transferinin yönetimi ve optimizasyonu, genel enerji verimliliğini artırmanın anahtarıdır [15].

Atık ısı geri kazanımı (WHR), aynı miktarda yakıt ve aynı miktarda sera gazı emisyonu ile mevcut gücü artırmaya izin verdiği için genel enerji verimliliğini iyileştirmek için uygun bir çözüm olabilir. Egzozlardan atık ısı geri kazanımı, süper kritik koşullarda karbondioksitin çalışma sıvısı olduğu Organik Rankine Çevrimleri (ORC) gibi daha ilginç ve daha yenilikçi çözümler için olanaklar sunuyor. ORC sistemleri, öncelikle ısı kaynağı sıcaklığının 100 °C ile 400 °C arasında olması durumunda, atık ısı geri kazanımı için geçerli bir teknik çözümdür. Reale ve ark. (2023) tarafından yapılan çalışmada bileşen sayısı açısından artan bir karmaşıklığa sahip ancak aynı zamanda artan bir verimlilikle altı farklı WHR düzeni ele alınmış ve incelenmiştir. Bunlardan beşi süper kritik CO₂ (sCO₂) gaz türbinlerini temel alırken, altıncısı daha karmaşık bir sCO₂ GT-ORC kademeli düzenidir. Genel net verimlilik, Basit atık ısı geri kazanımı şeması durumunda yaklaşık %45'e ve hibrit sistemde yaklaşık %49'a kadar yükseldiği sonuçlarda görülmüştür [16].

3. Materyal ve Yöntem

Üretilen enerjinin büyük bir kısmı sanayi sektöründe tüketilmektedir. Bu nedenle enerji verimlilik çalışmalarda yoğunlaşılması gereken sektördür.

Çalışma, float cam üretimi yapan bir işletmede gerçekleştirilmiştir. 2022 Kasım ayına kadar olan enerji tüketim ve üretim verileri arasındaki ilişki incelenerek tasarruf potansiyeli bulunmuştur. Bu çalışmada toplanan verilere bağlı olarak regresyon analizi ile enerji tasarruf potansiyeli tespit edilmiştir.

Enerji tüketimi standartı, mevcut enerji tüketimli, hedef enerji tüketimi ve enerji performans indeksi ile tanımlanmaktadır. Enerji tüketimi, birçok nedene bağlı olarak haftalık veya aylık değişebilmektedir. Bu faktörler, Spesifik Değişkenler ve Kontrol Edilebilir Değişkenlerdir. Spesifik değişkenler; işletmenin belirli bir bölümünde üretim adedine göre enerji ihtiyacı belirlenir. Enerji ihtiyacının bulunabilmesi için standart denklemler bu değişkenlerde kullanılır. İşletme çalışmaları, sistemin kontrol edilmesi, üretimin planlanması ve bakım standartı gibi değişkenler kontrol edilebilir değişkenlerdir. Enerji tüketimini minimum seviyeye düşürebilmek için değişkenler yönetim tarafından belirlenmektedir.

3.1. Standart Denklem Tipleri

$$E = a \quad (1)$$

a sabittir. Denklem 1 de enerjinin kullanımı hep sabittir. Spesifik değişken bulunmamaktadır. Enerji tüketimi ile üretim birbirinde bağımsızdır. Üretim miktarı ne kadar olursa olsun makinalar maksimum kapasiteli çalışmalıdır. Bu durumda standart denklem geçmiş verilerin ortalamasıdır [2].

$$E = a + bP \quad (2)$$

Denklem 2'de ise a ve b sabit değerlerdir. P üretimi ifade eden spesifik değişkendir. Enerji tüketimi ve üretim arasında bir ilişki vardır. Standart denklem regresyon analizi ile bulunabilir [2].

$$E = a + bP1 + cP2 + dP3 + \dots \quad (3)$$

a, b, c, d sabittir. P1, P2 ve P3 spesifik değişkendir. Denklem 3'te enerjinin tüketimi farklı sayılarda spesifik değişkenlere bağlıdır ve bunlar üretim, hava, çalışma süreleri olabilir. Standart denklemi bulmak için, çoklu lineer regresyon ile gerçekleştirilen istatistik analizi kullanılabilir gibi, bilgisayar programı ile de hesaplanabilmektedir [2].

Veriler ile bulunan standart denklemlerden sonra bu doğru altında kalan veriler ile tekrar bir denklem bulunur. Bu hedef denklemdir. Bu hedef denklem standartla denklem ile aynı formda olan bir denklemdir. Standart ve hedef denklem karşılaştırmasıyla iyileştirme incelenmektedir [2].

Performans değerlendirmesi için ise hedef enerji kullanımı ve mevcut tüketilen enerji değerleri karşılaştırılmalıdır. Bunu yapmak için ise Spesifik enerji tüketim (SET) değerleri bulunmalıdır. SET değeri, birim ürünün için tüketilen enerji miktarı demektir [17].

$$SET = \frac{\text{Enerji Tüketimi (Enerji Birimi)}}{\text{Üretim (Üretim Birimi)}} \quad (4)$$


Spesifik enerji tüketimi (SET) değeri, herhangi bir koşulun fabrikadaki üretime olan etkisini gözlemlene açısından oldukça önemlidir. Denklem 4'ün değeri büyür ise performans düşmüştür ve enerji tüketim oranının gereksiz olarak artmış olduğunu göstermektedir [17].

4. Bulgular ve Tartışma


Araştırma, float cam üretim sektöründe faaliyet gösteren Düzce Cam'da gerçekleştirilmiştir. Düzce Cam 1 ve Düzce Cam 2 isimli iki üretim hattına sahiptir. Düz cam, füme cam, lamine cam ve ayna üretimi yapılmaktadır. İşletmede enerjinin ana kullanımını üretim hattında gerçekleştirmektedir. Yüksek sıcaklıklarda üretim yapılan endüstriyel fırınlar, işletmelerde yakıt kullanımında ve atmosfere verdiği zararlar nedenleri ile mümkün olduğunca etkin ve verimli olarak kullanılması gerekmektedir. İşletme incelendiğinde enerji kaynağı olarak ORC ve GES (Güneş Enerjisi Sistemi) kullanıldığı görülmüştür. İşletmede ORC sistemi 2019 yılından bu yana faaliyete göstermekte, GES sistemi ise Eylül ayı itibarı ile bu yıl faaliyete geçmiştir. Araştırmada 2022 enerji verileri incelenmiştir.

GES sisteminin faaliyete geçmesiyle iki aylık enerji üretim yüzdeleri Şekil 1 ve Şekil 2'de görülmektedir;

Şekil 1. Eylül ayı enerji verileri



Şekil 2. Ekim ayı enerji verileri



4.1 Veri Toplanması

İşletmenin enerji tasarruf potansiyelinin incelenmesi için enerji tüketim-üretim arasındaki ilişki regresyon analizi ile tespit edilecektir. 2022 Kasım ayına kadar olan enerji tüketim ve üretilen camın m^2 cinsinden verileri Tablo 1 ve Tablo 2'de görülmektedir. M^2 cinsinden alınmasının sebebi cam adet sayımı yapılmamış veriler m^2 cinsinden tutulmuştur.

Tablo 1. 2022 yılının ekim ayına kadar olan fabrika net enerji tüketimi(kWh).

Ay	Tüketilen Net Enerji
Ocak	5164
Şubat	4871
Mart	5412
Nisan	5293
Mayıs	5270
Haziran	5038
Temmuz	4946
Ağustos	5445
Eylül	4876
Ekim	5509

Tablo 2. M^2 cinsinden toplam üretilen cam miktarı.

Ay	Toplam M^2
Ocak	2.896.462,57
Şubat	2.791.764,48
Mart	2.922.225,14
Nisan	2.353.291,53
Mayıs	2.873.624,73
Haziran	2.752.797,61
Temmuz	2.193.709,06
Ağustos	2.154.069,24
Eylül	2.442.667,24
Ekim	4.228.715,82
Toplam	27.609.327,42

4.2. Enerji Tüketim-Üretim Arasındaki İlişkinin İncelenmesi

Tablo 1 ve Tablo 2 verileri kullanılarak enerji tüketim miktarı ile üretilen cam arasındaki ilişkinin tespiti için bağımlı ve bağımsız değişkenler belirlendi ve regresyon doğrusu denklemi bulunacaktır.


Öncelikle işletmeden m^2 cinsinde alınan veriler ton hesabına çevrilmiştir.

Tablo 3. Enerji tüketim- üretim verileri.

Ay	X	Y
Ocak	42577	5164
Şubat	41038	4871
Mart	42956	5412
Nisan	34593	5293
Mayıs	42242	5270
Haziran	40466	5038
Temmuz	32247	4946
Ağustos	31664	5445
Eylül	35907	4876
Ekim	62162	5509

Tablo 3'te X ile üretim miktarı (ton/Ay) olarak ifade edilirken Y ile Toplam enerji tüketimi (kWh) ifade edilmektedir. Elektrik tüketimi bağımlı değişken (y), üretilen cam ise bağımsız değişkendir(x). Regresyon eğrisi temsil ettiği noktalara mümkün olduğunca yakın mesafeden geçmeye çalışmalıdır. Yani tüm noktaların eğriye olan mesafesi

hesaplanır ve toplam uzaklığı en küçük olan regresyon doğrusu olmaktadır. Bütün noktalar doğru üzerinde olsaydı mükemmel bir regresyon eğrisi olurdu ama bu mümkün değildir.



Şekil 3. Enerji tüketimi ile üretilen cam arasındaki ilişkinin regresyon doğrusu ve denklemi.

Şekil 3 'te belirlilik katsayısının 0.18 çıkması işletmenin 2022 Kasım ayına kadar enerji tüketimindeki değişimin %18'inin üretilen cam ile açıklanmaktadır.


4.3. Standart Denkleme Bağlı Hedef Denklem Tespit Edilmesi

Standart denklem belirlendikten sonra hedef denklem de belirlenmelidir. Hedef denklem de standartla aynı formda bir denklemdir. O bölümün performansındaki iyileşmeyi göstermektedir.

Hedef denklemin oluşturulması için bağımlı ve bağımsız değişkenler değişmektedir. Standart regresyon doğrusunda eğim altında kalan noktalar işletmenin üretimine bakıldığında enerji tüketiminin en düşük olduğu yerlerdir. Bu noktadaki değerler firmanın şu anki koşullarında sağladığı en iyi enerji tüketim değerleridir. Firmanın tasarruf potansiyelini bulmak amacı ile standart doğrunun altında kalan noktaların verileri Tablo 4'te verilmiştir. Bu veriler kullanılarak hedef denklem ve doğru oluşturulur.

Tablo 4. Standart doğrunun altında kalan veriler.

X	Y
42577	5164
41038	4871
40466	5038
32247	4946
35907	4876




Şekil 4. Enerji tüketimi ile üretilen cam arasındaki ilişkinin hedef doğrusu.

Şekil 4'te regresyon uyumluluk katsayısı R^2 0,26 olarak bulunmuştur. Belirlilik katsayısı 0.26 çıkması işletmenin 2022 Kasım ayına kadar enerji tüketimi değişiminin %26'sının üretilen cam ile açıklanmaktadır.

4.4. SET Değerlerinin Bulunması

Denklem 4'te bulunan formül ile aylık SET değerleri Şekil 5'te gösterilmiştir.



Şekil 5. Aylara göre SET değerleri.

SET değeri en düşük 0,08 TEP/ton ile Ekim ayı olarak bulunmuştur. Bu durum birim üretim gerçekleştirmek için enerji tüketiminin performans açısından en iyi olduğu zaman aralığını göstermektedir. 0,017 TEP/ton değeri ile ağustos ayı ise enerji tüketim performansında en kötü olan zaman aralığını göstermektedir.

Tablo 5. Aylara göre hedef iyileştirme potansiyeli değerleri.

Ay	Üretim (Ton)	Toplam Enerji Tüketimi (TEP)	Hedef (TEP)	TEP	€
Ocak	42.577	5.164	4.423	741	169,424
Şubat	41.038	4.871	4.423	448	102,466
Mart	42.956	5.412	4.423	989	226,156
Nisan	34.593	5.293	4.422	871	199,331
Mayıs	42.242	5.270	4.423	847	199,679
Haziran	40.466	5.038	4.423	615	140,698
Temmuz	32.247	4.946	4.421	525	120,092
Ağustos	31.664	5.445	4.421	1024	234,275
Eylül	35.907	4.876	4.422	454	103,854
Ekim	62.162	5.509	4.428	1081	247,379

Tablo 5'te hedef denklemden faydalanarak işletmede üretilen camın ton miktarına göre hedef enerji tüketim miktarları TEP olarak hesaplanmıştır. Toplam enerji tüketimi TEP değerleri ve hedef TEP değerleri arasında oluşan fark, firmanın ay bazında tasarruf potansiyelini vermektedir. Bulunan aylık tasarruf potansiyellerinin toplamı ise 7594,7 TEP olup işletmenin yıllık tasarruf potansiyelini göstermektedir. 2022 Aralık ayı için birim enerjinin maliyeti 0,229 €'dur. Yıllık tasarruf potansiyeli ve birim enerji maliyetinin çarpılması ile işletmenin 2022 yılı kasım ayına kadar olan değerlere göre 17.373 €/Yıl tasarruf potansiyeline sahip olduğu görülmüştür.

4.5. Banyo Alt Kasa Fanları Frekans İvertörü Revizyonu

Düzce Cam 1 no'lu float cam hattında banyo bölümünde kalay banyosunun alt kasını soğutmak için 132 kW gücünde 3 adet fan motoru kullanılmaktadır. Bu fanlar soft starter ile çalıştırılmaktaydı. Frekans inverteri değişimine gitmekteki amaç ihtiyaca göre fan motorlarının frekanslarını değiştirerek hava debisini ayarlamaktır. Bu sayede aynı iş için daha az elektrik tüketimi gerçekleşmektedir. Telemecanique ATS48C250 model soft starter'lar yerine üç adet ABB ACS800-04-0165-3 model frekans inverteri devreye alınmıştır.

Tablo 6. Toplam tasarruf miktarı.

Fan No	Tasarruf Miktarı (kWh)	Elektrik Birim Fiyatı (€)	Tasarruf Miktarı (€)
Fan 1	763616	0,228	174.682
Fan 2	745264	0,228	170.484
Fan 3	398640	0,228	91.191

TOPLAM	1907520	0,228	436.357
--------	---------	-------	---------

Aralık 2022 için elektrik kWh fiyatı 0,228 €'dur. Tasarruf miktarları ve elektrik birim fiyatı çarpımı sonucu tasarrufun mali değeri bulunmaktadır.

Tablo 6'da 2013'ten 2022'ye kadarki geçen 9 senedeki toplam tasarruf miktarı 1.907.520 kWh olduğu görülmektedir.

Günümüz elektrik birim fiyatına göre maddi kazanım 436.357 € olmaktadır.

Bir adet frekans inverterinin maliyeti ise günümüz fiyatıyla 10.874 €'dur. Yıllık tasarruf miktarına göre geri ödeme süresi hesaplandığında yatırımın 246 günde kendisini geri ödediği sonucuna Tablo 7'de ulaşılmaktadır.

Tablo 7. İyileştirmenin geri ödeme süresi.

Fan No	Frekans İvertörü Maliyeti (€)	Yıllık Tasarruf Miktarı (€)	Geri Ödeme Süresi (Yıl)	Geri Ödeme Süresi (Gün)
Fan 1	10.874	19.409	0,56	204
Fan 2	10.874	18.942	0,57	210
Fan 3	10.874	10.132	1,07	392
TOPLAM	32.622	48.483	0,67	246

Maddi kazanımdan iyileştirme yatırımının maliyetini çıkardığımızda işletmenin 403.736 € net kazancı vardır.

4.6. Aydınlatma Değişimi

Kesim hatları ve Banyo-2 altındaki floresan armatürler sökülerek LED armatür dönüşümüne gidilmiştir. Eski mevcut 2x58 watt etanj armatürler yerine 1x36 W IP65 bant armatür tercih edilmiştir. IP65 LED armatürler tozlu ortamda daha uzun süre çalışmaktadır ve su geçirmez özelliğe sahiptir.

Tablo 8. Konveyör ve banyo alt LED armatür dönüşümleri.

Konveyörler ve Banyo Altı LED armatür dönüşümleri						
Bölge	Eski Durum			Yeni Durum		
	Güç watt	Adet	Toplam Güç	Güç watt	Adet	Toplam Güç
B1	116	11	1,276	36	11	0,396
B2	116	5	0,58	36	5	0,18
B3	116	4	0,464	36	4	0,144
B4	116	4	0,464	36	4	0,144

5. Sonuç

B4	116	1	0,116	72	1	0,072
B1	116	9	1,044	36	9	0,324
B2	116	8	0,928	36	8	0,288
B3	116		0			0
B4	116	1	0,116	36	1	0,036
B4	116	1	0,116	72	1	0,072
B5	116		0			0
B2	116	17	1,972	36	17	0,612
			7,076			2,268

Tablo 8’de eski ve yeni armatürlerin saatlik harcadıkları güç miktarları bulunmaktadır. Sürekli çalışma durumu göz önüne alındığında toplam saatlik tasarruf miktarı $7,076 - 1,008 = 4,808$ kWh olmaktadır.

Tablo 9. Aydınlatma sisteminden sağlanan tasarruf miktarları.

	Tasarruf kWh	Elektrik kWh fiyatı	Tasarruf (€)
Saatlik	4,808	4,4516	1,099
Günlük	115,392	4,4516	26,396
Aylık	3461,76	4,4516	791,899
Yıllık	42118,08	4,4516	9.634

Tablo 9’da ise yıllık tasarruf miktarı 42.118 kWh olarak hesaplanmıştır. Günümüz elektrik birim fiyatına göre maddi kazanım 9.634 € olmuştur.

Tablo 10. İyileştirmenin geri ödeme süresi.

	LED Armatür Maliyeti (€)	Yıllık Tasarruf Miktarı (€)	Geri Ödeme Süresi (Yıl)	Geri Ödeme Süresi (Gün)
LED Armatür	783,658	9.634	0,0813368	29,69

Projenin geri ödeme süresi Tablo 10’da 30 gün olduğu görülmektedir. Armatür maliyeti de çıkarıldığında net kazanç 8.851 €’dur.

Bu çalışma fabrikanın mevcut tasarruf çalışmalarına katkı sağlamak amacıyla 2022 yılı Kasım ayına kadar olan enerji verileri ile enerji verimliliği çalışmasını kapsamaktadır. Aylık üretilen cam ve enerji tüketim verilerine bağlı standart denklem oluşturulmuştur. Standart doğrunun altında kalan veriler ile hedef denklem belirlenmiştir. Hedef denklemde firmanın aylık olarak yaptığı üretime bağlı hedef enerji tüketim miktarları TEP olarak hesaplanmıştır. Aylık TEP değerleri ile hedef TEP değerleri arasında oluşan fark işletmenin aylık tasarruf potansiyelini vermektedir. İşletmenin toplam tasarruf potansiyeli 7594,7 TEP/yıl olarak hesaplanmıştır. Enerji tasarruf potansiyeli 2022 yılı için bir TEP enerjinin maliyetine göre 17.374 €/yıl olarak hesaplanmıştır.

İşletmede gerçekleştirilen iyileştirmeler incelendiğinde banyo alt kasa fanları frekans invertörü revizyonu ve aydınlatma değişimi projeleri incelenmiştir. Banyo alt kasa değişimi ile 403.736 €, aydınlatma değişimi ile ise 8.851 € tasarrufu sağlanacağı belirlenmiştir.

Enerji tasarrufu yaparak işletmede üretim maliyetlerini düşürülebilir, ülke enerji ihtiyacını azaltıp dışa bağımlılığı azalabilir ve çevre kirliliğinin önüne geçebiliriz. Bunun için enerji tasarrufunu sanayi sektörü gibi yoğun enerji tüketimi olan alanlarda yapmak oldukça önemlidir.

6. Kaynaklar

- [1]. Pamir ve Necdet, 2005. “Enerji Politikaları ve Küresel Gelişmeler”, Küreselleşmenin Enerji Sektöründe Yapısal Değişim Programı ve Enerji Politikaları, Elektrik Mühendisleri Odası, 5. Enerji Sempozyumu Bildiriler Kitabı, s.67
- [2]. Çakal, 2006. Tarım Makinaları İmalatında Enerji Yönetimi Üzerine Bir Araştırma, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Tarım Makinaları Anabilim Dalı, Yüksek Lisans Tezi
- [3]. Enerji ve Tabii Kaynaklar Bakanlığı, 1995. “Sanayi Kuruluşlarının Enerji Tüketiminde Verimliliğin Arttırılması için Alacakları Önlemler Hakkında Yönetmelik”
- [4]. Elektrik Mühendisleri Odası; İzmir Şubesi, Ege Bölgesi Enerji Forumu Bildiri Kitabı, İzmir, Mart 2007, s.73
- [5]. Kavak K., 2005. Dünyada ve Türkiye’de Enerji Verimliliği ve Türk Sanayiinde Enerji Verimliliğinin İncelenmesi, Uzmanlık Tezi, İktisadi Sektörler ve Koordinasyon Genel Müdürlüğü
- [6]. Kıyılmaz ve ark, Sanayide Enerji Yönetimi Sistemi için Bir Gıda Tesisinin Enerji Verimliliğinin İyileştirilmesi, International Journal of Pure and Applied Sciences, 7(1):51-62 (2021)
- [7]. Çınar, 2008. Tekstil Sanayisinde Enerji Yönetimi ve Enerji Verimlilik Analizi, Pamukkale Üniversitesi, Fen Bilimleri

Enstitüsü, Yüksek Lisans Tezi, Makina Mühendisliği Anabilim Dalı, Denizli

[8]. Söğüt ve ark, 2019. Bir Tekstil İşletmesinin Enerji Tüketimi ve Verimlilik Analizi, 14. Ulusal Tesisat Mühendisliği Kongresi Bildiriler Kitabı, sf. 1790-1801, 17-20 Nisan

[9]. Akkurt ve Taşdemir, 2020. Muhtelif Altyapı Ürünleri Üreten Bir Döküm Fabrikasının Enerji Etüdü, Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi

[10]. Yüksel, 2020. Bir Petro-Kimya Fabrikasının Enerji Verimliliği Etüdü, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi

[11]. Işık ve Akan, Bir Kürk – Süt Üretim Fabrikasının Spesifik Enerji Tüketim Yöntemi ile Enerji Tasarruf Potansiyelinin Araştırılması, Avrupa Bilim ve Teknoloji Dergisi Sayı 12, S. 22-26, Nisan 2018

[12]. Söğüt ve Oktay, 2006. Sanayi Sektöründe Enerji Taramasının Enerji Verimliliğine Etkisi ve Bir Uygulama

[13]. Trotta, G., 2020. Assessing energy efficiency improvements and related energy security and climate benefits in Finland: An ex post multi-sectoral decomposition analysis. Energy Economics, 86, p.104640.

[14]. Worrell, E., Galitsky, C. and Price, L., 2008. Energy efficiency improvement and cost saving opportunities for cement making. LBNL-54036-Revision. Ernest Orlando Lawrence Berkeley National Laboratory, University of California, March.

[15]. Worrell, E. and Galitsky, C., 2005. Energy efficiency improvement and cost saving opportunities for petroleum refineries.

[16]. Reale, F., Calabria, R. and Massoli, P., 2023. Performance Analysis of WHR Systems for Marine Applications Based on sCO₂ Gas Turbine and ORC. Energies, 16(11), p.4320.

[17]. Bozkurt, 2008. Yenilenebilir Enerji Kaynaklarının Enerji Verimliliği Açısından Değerlendirilmesi, Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Yüksek Lisans Tezi

Özgeçmişler



İrem Düzdar, 2006 yılında İstanbul Ticaret Üniversitesi'nden endüstri mühendisliği Yüksek Lisans derecesini, 2015 yılında Marmara Üniversitesi Endüstri Mühendisliği doktora derecesini almıştır. İstanbul Ticaret Üniversitesi'nde Avrupa Birliği 6. Çerçeve kapsamında genç araştırmacı olarak görev yapmıştır. Daha sonra İstanbul'daki çeşitli vakıf üniversitelerinin endüstri mühendisliği bölümlerinde 7 yıl öğretim görevlisi olarak görev yapmıştır. 2015 yılından bu yana Düzce Üniversitesi Endüstri Mühendisliği Bölümü'nde görev yapmaktadır. 2023 yılında Üniversiteler Arası Kurul tarafından Nicel Karar Yöntemleri alanında Doçent ünvanını almıştır. Başlıca araştırma alanları arasında endüstriyel uygulamalar ve enerji alanlarında verimlilik, kalite iyileştirme, veri madenciliği ve karar verme yöntemleri yer almaktadır.



Tuğçe Özdemir Cihan, 2018 yılında Afyon Kocatepe Üniversitesi'nden Malzeme Bilimi ve Mühendisliği lisans derecesini almış, 2022 yılında Düzce Üniversitesi'nde Disiplinlerarası Tezli Yüksek Lisans programına başlamıştır. Kariyerine 2016 yılında Tatçelik'te stajyer olarak başlamış ve ardından Erdemir'de 2. Sıcak Haddehane Mühendisliği stajını tamamlamıştır. 2019 yılında Model Granit ve Mermer İmalat Sanayi Ticaret Limited Şirketi'nde Ar-Ge Mühendisi olarak çalışmıştır. 2020-2021 yıllarında Pharma Pazarlama Gıda Kozmetik İç ve Dış Ticaret Anonim Şirketi'nde Seramik Mühendisi olarak görev yapmış, müşteri taleplerine göre seramik ürünlerin Ar-Ge çalışmalarını yürütmüştür. 2021-2022 yıllarında MF Seramik İmalat Pazarlama Sanayi Ticaret Limited Şirketi'nde Ar-Ge ve İşletme Uzmanı olarak çalışmış ve çeşitli seramik ürünlerinin geliştirilmesinde rol almıştır. 2022-2023 yıllarında Düzce Cam Sanayi ve Ticaret Anonim Şirketi'nde Ar-Ge Mühendisi ve Proje Yöneticisi olarak çalışmış, enerji yönetimi ve verimlilik projeleri üzerinde çalışmıştır. Düzce Cam San. ve Tic. A.Ş. Düzce'de bulunan fabrikasında AR-GE Merkezi oluşum aşamasında ki süreçleri takip ederek, yapılmakta olan projelerin yönetim sürecini ele almıştır. Aynı zamanda Enerji Yönetim Biriminde üyeliği bulunmaktadır. 2023 Kasım ayından itibaren Ar-Ge ve Teknokent Serbest Muhasebeci Mali Müşavirlik Limited Şirketi'nde Proje Uzmanı olarak devam etmiştir. Teknoloji ve Sanayi Kuruluşları için Ar-Ge, Tasarım, Yatırım ve İhracat Destekleri Danışmanlık, Teknokent süreçleri, Eğitim Hizmetleri ve Proje Yönetimi ve Hibe/Fon Kaynakları Eğitim hizmetleri konusunda danışmanlık vermiştir. 2024 Mayıs ayından itibaren ATEL Teknoloji ve Savunma Sanayi A.Ş. firmasında Ar-Ge proje mühendisi olarak devam etmektedir. Başlıca araştırma alanları arasında malzeme bilimi, kompozit malzemeler, seramik üretim süreçleri, Ar-Ge Merkezi Faaliyetleri ve enerji verimliliği yer almaktadır.



Elif Akın, 2023 yılında Düzce Üniversitesi Endüstri Mühendisliği bölümünden mezun olmuştur. Üniversite hayatı boyunca iki staj görevi gerçekleştirmiştir. İlk stajını cam endüstrisinde Ar-Ge bölümünde gerçekleştirerek lisans bitirme tezini yazmıştır. İkinci stajını bir otomotiv yan sanayi firmasında üretim, kalite ve üretim planlama departmanlarında görev alarak gerçekleştirmiştir. 2023 yılından itibaren Kocaeli'nde bulunan bir ambalaj firmasında üretim planlama mühendisi olarak görev yapmaktadır. Günlük ve haftalık üretimin planlanması, malzeme ihtiyaç planının oluşturulması ve raporlanması, makine verimliliklerinin korunması ve raporlanması, üretim fire oranlarının raporlanması görevlerini üstlenmektedir.

Ev Tipi Endüksiyon Isıtma Ocaklarının Analizi

Analysis of Household Induction Hobs

Metin Ozturk^{1,2}, Fatih Züngör^{1,2}, Durmuş Ersoy^{1,2}

¹Mühendislik ve Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

İstanbul Esenyurt Üniversitesi, İstanbul, Türkiye

metinozturk@esenyurt.edu.tr, fatihzungor@esenyurt.edu.tr, durmusersoy@esenyurt.edu.tr

²Mamur Teknoloji Sistemleri Sanayi A.Ş., İstanbul, Türkiye

metin.ozturk@mamurtech.com, fatih.zungor@mamurtech.com, durmus.ersoy@mamurtech.com

Özet

Endüksiyonla ısıtma (EI) teknolojisinin, ev uygulamalarında yaygın olarak tercih edilen bir yöntem olmasının nedeni verimlilik ve güvenli çalışma özellikleri sunmasıdır. Rezonans evirici devreleri, yüksek verimlilikleri ve yumuşak anahtarlama yetenekleri nedeniyle EI sistemlerinde sıkça kullanılmaktadır. Ürün maliyeti ve verim arasında bir denge sağlamak amacıyla endüksiyonlu ısıtma sistemlerinde, tek anahtarlı kısmi rezonanslı dönüştürücüler ve yarım köprü seri rezonanslı dönüştürücüler sıklıkla tercih edilmektedir. Son çalışmalar, endüksiyon teknolojisi alanında çok bobinli ve AA-AA tasarımların öne çıktığını göstermektedir. AA-AA rezonanslı dönüştürücülerin kullanılmasının temel nedeni, iletimdeki aktif yarı iletken anahtar adedini azaltabilmektir. Bir üreticiden bir bobinin çalıştırıldığı topolojilerin yanı sıra, bir üreticiden birden fazla bobinin çalıştırılabildiği modern tasarımlar yardımıyla ısı dağılımları iyileştirilebilir. Bu çalışmada, endüksiyon ısıtma ocaklarında kullanılan güncel uygulamalar hakkında genel bilgiler verilmiş, özellikle tek anahtarlı kısmi rezonanslı dönüştürücüler ile yarım köprü seri rezonanslı dönüştürücüler için detaylı devre analizleri yapılmıştır.

Anahtar kelimeler: AA-AA dönüştürücü, çok bobinli endüksiyonlu pişirme sistemleri, ev türü endüksiyonlu ocak, yarım köprü seri rezonanslı dönüştürücü, tek anahtarlı kısmi rezonanslı dönüştürücü.

Abstract

Induction heating (IH) technology is widely preferred in household applications due to its efficiency and safe operation features. Resonant inverter circuits are commonly used in IH systems for their high efficiency and soft-switching capabilities. To strike a balance between product cost and efficiency in induction heating systems, single-switch quasi-resonant converters and half-bridge series resonant converters are often preferred. Recent studies highlight the prominence of multi-coil and AC-AC designs in the field of induction technology. The use of AC-AC resonant converters is primarily motivated by the ability to reduce the number of active semiconductor switches in the transmission. Modern designs allow for the operation of multiple coils from a single generator, improving heat distribution. In this study, general information about current applications in induction heating cooktops is provided, and detailed circuit analyses are conducted, particularly for single-switch quasi-resonant converters and half-bridge series resonant converters.

Keywords: AC-AC converter, multiple coil induction cooking systems, household induction cookers, single ended quasi resonant converters, half bridge serial resonant converters.


1 Giriş

Endüksiyonla ısıtma teknolojisi, günümüz endüstrisinde özellikle metal ısıtma, eritme ve sertleştirme işlemlerinde geniş bir şekilde tercih edilmektedir [1]–[3]. Ayrıca, metal içeren malzemelerin yapılandırılması, eritilmesi, pişirme, ısıtma ve türevi alanlarda endüksiyon teknolojisinin geniş bir kullanım alanı bulunmaktadır. Şekil 1'de endüksiyon teknolojisini kullanan alanlar gösterilmektedir. Bu kullanım alanları, endüstriyel tip kullanım, medikal tip kullanım ve evsel tip kullanım olmak üzere üç temel grupta toplanmaktadır.

Tablo 1'de, endüksiyon teknolojisi alanında yapılan çalışma konularına ve uygulama alanlarına dayalı gereksinimler sunulmuştur. Endüksiyon temelli teknolojilerin elektronik içeriği devre tasarımı, manyetik eleman tasarımı ve kontrol teknikleri açısından belirgin bir şekilde ortaya çıkmaktadır [4].

Ana çalışma ilkeleri benzer olmasına rağmen, tüm endüksiyonlu uygulamaların değişik özelliklere ve gereksinimlere sahip olduğu göz önünde bulundurulmalıdır. Endüstriyel tip kullanımlar diğer uygulamalara göre daha yüksek güç talep ederken, medikal tipte kullanımlar daha düşük güç ve hassas kontrol gerektirmektedir. Ev tipi endüksiyon ısıtma ocakları incelendiğinde akademik çalışmalar ve endüstriyel araştırmaların odaklandığı başlıca konular olarak geniş bir yük aralığına uygunluk (farklı tencere ve tavalar), yüksek verimlilik ve düşük maliyet beklentileri bulunmaktadır.

Şekil 2'de, ev tipi kullanım için geliştirilmiş klasik bir endüksiyon ısıtma sisteminde, gücün üretimden tencereye aktarılma sürecindeki güç akışı gösterilmektedir. AA gerilim, doğrultucu ünite kullanılarak DA gerilime çevrilir. Rezonans evirici yardımı ile üretilebilen yüksek frekanslı AA akımlar, bobin elemanında oluşturulan manyetik alan aracılığıyla tencereyi ısıtmak için kullanılır.



Şekil 1. Endüksiyon teknolojisinin kullanıldığı alanlar [4].


Tablo 1. Kullanıma bağlı olarak endüksiyon uygulamalarından beklenen özellikler [4].

Uygulama	Güç Elektronikliği	Modülasyon ve Kontrol	Manyetik
Endüstriyel	-Yüksek güç. -Geliştirilmiş güvenilirlik. -Montaj hattı uygulaması. -Düşük/yüksek frekans uygulamaları.	-Geliştirilmiş ara yüz ve haberleşme. -Değişken güç ve yük aralığı. -Sıcaklık kontrolü.	-Yüksek verim. -Değişken şekil. -Optimize edilmiş ısı dağılımı.
Ev Tipi	-Düşük maliyet. -Yüksek verim. -Sınırlı soğutma kapasitesi. -Orta çalışma frekansı.	-Güç faktörü ve harmonik kontrolü. -Değişken yük ve güç aralığı. -Akustik gürültüyü giderme ihtiyacı. -Sıcaklık kontrolü.	-Yüksek verim. -Ferromanyetik olmayan metallerin de ısıtılması. -Esnek ve çok bobinli ısıtma yüzeyi.
Medikal	-Düşük maliyet. -Yüksek kalite faktörlü rezonans. -Yüksek çalışma frekansı.	-Tam güç ve sıcaklık kontrolü. -Frekans seçimi.	-Bölgesel ve kısmi ısıtma. -Kontrollü manyetik alan etkileşimleri. -Ferromanyetik akışkanlar.


Rezonanslı eviriciler, geleneksel endüksiyon ısıtma sistemlerinin temel bileşenleridir [5]–[7]. Maliyet, verim ve performans arasındaki ilişki göz önüne alındığında literatürde farklı rezonanslı eviriciler önerilmiştir [8]–[10]. Endüksiyonla ısıtma uygulamalarında rezonanslı eviricilerin tercih edilmesinin en önemli nedeni sinüzoidal dalga şekillerinin sonucu olarak yarı iletkenlerin sıfır gerilim ve sıfır akımda anahtarlanmasıdır [11], [12].

Endüksiyonla ısıtma sistemlerinde en sık kullanılan rezonanslı dönüştürücüler genel devre şemaları Şekil 3'te verilen yarım köprü seri rezonanslı (YKSR) ve tek anahtarlı kısmi rezonanslı (TAKR) dönüştürücülerdir. TAKR dönüştürücüler ile karşılaştırıldığında, YKSR dönüştürücüler yüksek güçlü uygulamalarda kullanılmalarının yanı sıra tasarım ve kontrol kolaylığı açısından da avantajlıdır. Tüm avantajlarına rağmen YKSR dönüştürücüler TAKR dönüştürücülerden daha maliyetlidir. YKSR dönüştürücü ile TAKR dönüştürücülerin çeşitli açılardan karşılaştırılması amacıyla Tablo 2 hazırlanmıştır. Tablo 2'de verilen tüm değerler çeşitli üreticilere ait ölçüm sonuçlarıdır. YKSR evirici için BSH ve Whirlpool firmalarının ürünleri referans alınırken, TAKR evirici için E.G.O, Copreci, Femaş, Midea ve benzeri firmalarının ürünleri kullanılmıştır.

Son dönem endüksiyonlu ocak çalışmaları dikkatlice incelendiğinde, devre tasarımına yönelik olarak birden fazla bobin içeren ve (veya) köprü doğrultucu içermeyen AA-AA rezonanslı dönüştürücülerin kullanıldığı görülmektedir [5], [13], [14]. AA-AA dönüştürücülerin temel amacı kullanılan yarı iletken sayısını azaltmaktır [5], [15]. Endüksiyonlu ocak uygulamalarında kullanılan AA-AA dönüştürücülere örnek Şekil 4'te gösterilmektedir.



Şekil 2. Endüksiyonla ısıtma sistemleri için güç akışı.



Şekil 3. (a) YKSR dönüştürücü için genel devre şeması (b) TAKR dönüştürücü için genel devre şeması.

Tablo 2. YKSR ve TAKR eviricili çözümlerin karşılaştırılması.

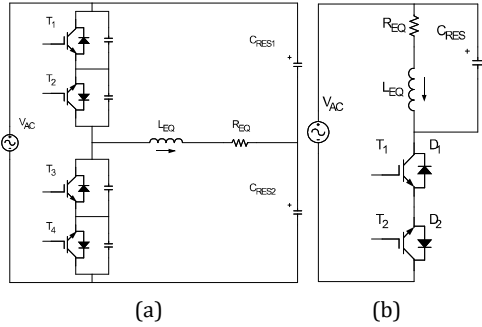
	YKSR Evirici	TAKR Evirici
Maksimum Güç	3600 W	2000 W
Minimum Güç	50 W	1000 W
Tasarım Kolaylığı	Kolay	Zor
Akım Dalga Şekli Simetrikliği	Simetrik	Değil
Tasarım Pahalılığı	Pahalı	Ucuz
Kullanılan Anahtar Sayısı	Bobin x 2	Bobin x 1

Diğer taraftan AA-AA YKSR eviricilerin verimi düşürdüğüne yönelik çalışmalar literatürde yer almaktadır [8]. Önerilen devrede verimi arttırabilmek amacıyla doğrultucu ve evirici eşzamanlı ve birbirlerine bağımlı olarak kullanılmak amacıyla tasarlanmıştır. Böylelikle yarı iletkenlere paralel bağlı diyotların kullanılmasına gerek kalmamıştır. Önerilen çözümün dezavantajı yarı iletkenler anahtarların, kaynak gerilimi ve rezonans kondansatör gerilimlerinin toplamına maruz kalmaları ve iletme girme anında anahtar uçlarında bu gerilim değerinin bulunmasıdır [8].

Standart TAKR eviriciye alternatif olarak önerilen AA-AA dönüştürücünün [16] özellikle sistem verimi açısından avantaj sağlarken, verimi arttırmak için SiC temelli JFET yarı iletken kullanımını, toplam tasarım maliyetinde artışa neden olmaktadır.

YKSR evirici devresinden elde edilen AA-AA YKSR yükseltici dönüştürücü çalışması [17], mevcut YKSR eviriciden daha verimli bir çözüm önermektedir. İlgili dönüştürücüde verimi arttırmak için SiC temelli JFET yarı iletkeni kullanılması toplam tasarım maliyetinde artışa neden olmaktadır.

Endüksiyon ısıtma ocaklarında kullanılan her bir bobin, birbirinden bağımsız üreteçler yardımıyla çalıştırılabildiği gibi, tek üreteç yardımıyla birden fazla bobinin çalıştırılabildiği uygulamalar geliştirilmektedir [15], [18]–[21]. Endüksiyonlu ocaklarda tek üreteçle birden fazla bobinin çalıştırılabildiği ilk uygulamalarda, elektromekanik anahtarlar sayesinde paralel bağlanabilen bobinler bulunmaktadır [22]. Önerilen devrede tam köprü seri rezonanslı evirici devresi kullanılmış, her bobin için ayrı bir kontrol rölesi eklenmiştir. Önerilen çözümde her bir bobin için ayrı bir röle kullanılması, hem elektronik maliyetini arttırmakta hem de anahtarlama anlarında ilave elektriksel gürültüye neden olmaktadır. Ancak özellikle tek bobin çalıştırıldığında yarı iletken kayıplarının azaltılması hedeflenmektedir.




Şekil 4. (a) YKSR Eviricili AA-AA dönüştürücünün devre şeması (b) TAKR Eviricili AA-AA dönüştürücü devre şeması [23].

Literatürde, iki adet bobini kontrol edebilmek amacıyla dört yerine üç adet yarıiletkenin kullanıldığı yeni bir YKSR evirici önerilmiştir [24]. Önerilen çözümde her iki bobin aynı frekansta çalıştırılarak bir adet yarı iletken kazanç sağlansa da her iki bobin birbirlerine bağımlı olarak çalışmak zorunda kalmıştır.

Dört adet bobinin iki adet YKSR evirici yardımıyla birbirlerinden bağımsız olarak çalıştırılabildiği uygulamalar bulunmaktadır [25]. Isıtılacak tencerenin konumu belirlenerek hangi bobinin hangi üreteç yardımıyla kontrol edileceği tespit edilmiş, bu sayede verim ve performans avantajı amaçlanmıştır. Önerilen çözümde rölelerin kullanılması, hem elektronik maliyetini arttırmakta hem de anahtarlar anahtarlarında ilave elektriksel gürültülere neden olmaktadır.

Bir dönüştürücünden birden fazla bobinin çalıştırılması konusunda yapılan ilk çalışmalar, ısıtılacak tencere başına çok sayıda bobinin düştüğü çok bobinli ürünler adına başlangıç niteliğindedir. Böylece, tek üreteçten çok adetli ve standart bobinlere göre çok daha küçük bobinlerin kullanılabilirdiği yeni bir endüksiyon teknolojisi geliştirilmiştir [4], [24]. Şekil 5'de, yeni nesil çok bobinli bir YKSR dönüştürücü örneği gösterilmektedir. Önerilen çözümde, kullanılacak bobin adedi kadar ilave yardımcı yarı iletken kullanılmakta ve bunun sonucu olarak bobin sayısı arttıkça kayıplar artarak verim düşmektedir.



Şekil 5. Çok bobinli AA-AA dönüştürücü devre şeması [4].

2 Ev Türü Endüksiyonlu Ocaklar

Özellikle son dönemlerde elektrikli ev aletlerindeki kullanımın artması ve de elektriksel gereksinimlerin özellikle mutfakta



Şekil 6. Ankastré türü endüksiyon ısıtılmalı ocak modelleri (a) 30 cm (b) 60 cm [26].



Şekil 7. Portatif endüksiyon ısıtılmalı ocak modelleri (a) üst yüzeyden görünüş (b) örnek tasarım [26].

yoğunlaşması sonucu, tercih edeceğimiz elektrikli ev aletinin maksimum güç değerini limitlenmektedir. Diğer taraftan tükenir enerji kaynaklarından olan gazın, hem güvenlik hem de yerel standartların zorlamaları sonucu kullanım alanlarının azalması, elektrikle çalışan pişirici ocakları zorunlu bir tercih haline getirmiştir. Bunun sonucu olarak evlerde kullanılan elektrik şebekesinin güç limitlerine uygun olacak şekilde, endüksiyon ısıtılmalı ocaklar tek ya da iki fazlı çalıştırılacak şekilde tasarlanırlar. Genel olarak ankastré ve 30,60 ve 90cm ölçülerinde tasarlanan endüksiyon ocaklara ilişkin örnekler Şekil 6'da gösterilmektedir. Kontrol ünitesi yardımıyla endüksiyon ocağı kontrol edebilen kullanıcı, genellikle 1-10 aralığındaki seviyelerde tencereyi son derece hassas bir şekilde ısıtabilir.


Bunula birlikte Uzakdoğu'da oldukça yaygın şekilde kullanılan ve Şekil 7'de gösterilen taşınabilir endüksiyonlu ocaklar, mevcut ocaklarından vazgeçmeden endüksiyon ocağın avantajlarını kullanmak isteyen kullanıcılar için alternatif bir çözüm olarak karşımıza çıkmaktadır.

2.1 Ev Türü Endüksiyon Isıtılmalı Ocaklar İçin Bobin Modelleri

Ev türü endüksiyon ısıtılmalı ocaklar için tasarlanan bobinler, eviriciler tarafından beslenen ve geometrik olarak ocak yüzeyine uyumlu düzlemsel bobinlerdir [27]. Bahsedilen düzlemsel bobinler ile ilgili olarak yapılan akademik çalışmalar, bobinlerin elektromanyetik modellenmesi [28], [29] bobin kayıp dağılımlarının analizi [30], bobin kayıplarının analizi [31]-[33] ve benzeri konularda yoğunlaşmaktadır.

Şekil 8'de alüminyum plakaya yerleştirilmiş halde bulunan ferit, bobin ve tencere kesiti detaylarının ayrıntılı olarak verildiği bir bobin kesiti gösterilmektedir. Alüminyum plaka feritleri taşımanın yanı sıra manyetik yönlendirme ve soğutma amaçlarıyla da kullanılmaktadır. Ayrıca pratik uygulamalarda bobin ve ısıtılacak tencere arasında 4mm kalınlığında, yalıtımcı ve sıcaklık dayanımı 700C'lere ulaşan seramik temelli bir cam kullanılmaktadır.

Uygulama alanı, performans beklentisi ve talep edilen çıkış gücüne bağlı olarak, ev türü endüksiyon ısıtılmalı ocaklarda kullanılan bobinler, iletken sargılar ve ferit çekirdekler plastik taşıyıcıya



Şekil 8. Endüksiyon bobini kesiti [30], [34].



Şekil 9. Plastik karkaslı bobin örneği.


monte edilecek şekilde tasarlanabilir. Bu yöntem ile tasarlanan ve Şekil 9'da bir uygulaması gösterilen bobinler, ilave bir alüminyum plaka ile kullanılmayacaklar ise genellikle < 2000W mertebesinde düşük güç gerektiren uygulamalarda kullanılırlar. Bu bobinlerde kullanılan ferit nüvelerin BS doyum değerleri de düşük seçilerek maliyet avantajı sağlanmaya çalışılmaktadır. Ancak düşük BS değerine sahip nüvelerin kullanılması sonucu bobinlerin de soğutulması zorunlu hale gelmektedir.

2.1.1 Tencere, üreteç ve bobin sayısı arasındaki ilişki


Endüksiyon ısıtmalı ocaklarda kullanılan bobinler, ısıtmak istenen tencerenin türü, boyutu, çıkış gücü, kullanım kolaylığı ve benzeri nedenlerden ötürü çok çeşitli geometrik ölçülerde tasarlanmaktadır. Tek üreteç ile tek bir bobin çalıştırılabileceği gibi, tek üreteçten birden fazla bobinin çeşitli sürme teknikleri ve devre topolojileri yardımıyla çalıştırılabileceği uygulamalar da tercih edilmektedir [35]–[38].

2.1.1.1 Tencerenin tek bir bobin ile ısıtıldığı uygulamalar

Hem Şekil 10'de ve hem de Şekil 11'de her bir bobin için bağımsız bir üreteç içeren standart ev tipi endüksiyon ısıtmalı ocaklar gösterilmektedir. Standart endüksiyon ocaklarda, ısıtmak istenen tencere, cam üzerinde işaretlenmiş bölgeye yerleştirildiğinde en verimli pişirme sağlanmaktadır. Aksi halde ya ısıtma sağlanmaz ya da daha az verimli bir ısıtma yapılmış olur.



Şekil 10. Endüksiyon ısıtmalı ocak üst yüzey görüntüsü (a) ankastre (b) taşınabilir [26].




(a) (b)

Şekil 11. Ankastre türü endüksiyon ısıtmalı ocağın içten görünüşü (a) iki ısıtıcılı ocak (b) dört ısıtıcılı ocak [26].


2.1.1.2 Tencerenin birden fazla bobin ile ısıtıldığı uygulamalar

Diğer taraftan, yalnızca cam yüzeyinde işaretlenmiş bölgede ısıtma yapmak, ocak yüzeyinin yalnızca belirli bir kısmında pişirme yapılabilmesine neden olmaktadır. Bu nedenle son dönemde ocak yüzeyinin tamamını kullanmaya yönelik ve tencere başına birden fazla bobin kullanarak homojen ısıtma yapmayı amaçlayan çalışmalar artmaktadır [38]. Standart uygulamalar ile kıyaslandığında çok bobin içeren bu yöntem sayesinde kullanıcı tencereyi ocak yüzeyinde bulunan herhangi bir bölgeye yerleştirebilir. Elektronik kontrol yöntemleri yardımıyla tencerenin yeri tespit edilerek ilgili bobinler enerjilendirilir ve tencerenin ısıtılması sağlanır. Bununla birlikte çok bobinli yapılarda kullanılan bobinler çok farklı geometrik şekillerde tasarlanabilir. Yuvarlak formu, kare formu ya da dikdörtgen formu tasarlanabilen bu bobinlere ilişkin örnekler Şekil 12'te gösterilmektedir.



Şekil 12. Çok bobinli yapılarda kullanılan bobin örnekleri [24] (a) yuvarlak formu bobin örneği (b) kare formu bobin örneği (c) dikdörtgen formu bobin örneği.

Endüksiyon ısıtmalı ocak sistemlerinde ısıtmak istenen tencerenin türünün tespiti güvenli ve verimli ısıtma için son derece kritiktir. Ayrıca çok bobinli sistemlerde tencere türüne ek olarak tencere konumunun kontrolü tarafından tespit edilmesi, aktifleştirilecek bobinlerin belirlenebilmesi için son derece kritiktir. Şekil 13'te kare bobinlerden oluşan endüksiyonlu ocak uygulamasında tencerenin konumuna bağlı olarak aktif hale getirilen bobinler gösterilmektedir.




Şekil 13. Tümüyle aktifleştirilmiş yüzey [24].




Şekil 14. Tek tencere ısıtma için çoklu bobin uygulama örnekleri.

Uygulamada kullanılan çok bobinli endüksiyonlara örnek olarak Şekil 14 gösterilebilir. Şekil 15’de, hem standart hem de kare bobinlerin birlikte kullanıldığı bir uygulama gösterilmektedir. Bu ve benzeri uygulamaların amacı ise hem ürün maliyetini düşürmek hem de kullanıcı alışkanlıklarıdır. Şekil 16’de 90cm endüksiyonlu ocakta 40 adet bobin, Şekil 17’de 90cm endüksiyonlu ocakta 12 bobin kullanılmaktadır.



Şekil 15. Siemens firmasına ait çok bobinli endüksiyon ısıtılmalı ocak (a) içten görünüşü (b) genel görünüşü.



Şekil 16. Bosch firması çok bobin içeren endüksiyon ısıtılmalı ocak [39] (a) içten görünüşü (b) genel görünüşü.



Şekil 17. De Dietrich firması çok bobin içeren endüksiyon ısıtılmalı ocak (a) içten görünüşü (b) genel görünüşü.

Özellikle çok bobinli endüksiyon ısıtılmalı ocak uygulamalarında, kullanılacak bobin adedi, eviricinin türü, güç kontrol yöntemi ve yük tanıma yöntemleri arasındaki detaylı ilişki, pratik uygulamada çok çeşitli çözümlerin ve ürünlerin oluşmasına neden olmaktadır.


3 Endüksiyon Isıtılmalı Ocak Tasarımları İçin Dönüştürücü Modelleri

Endüksiyon ısıtılmalı ocaklarda ısıtılmak istenen tencerenin türü ve boyutuna bağlı olarak elektronik devredeki eşdeğer direnç ve endüktans değişmektedir. Güç elektroniği devreleri yardımıyla elde

edilebilen yük frekanslı (20kHz-100kHz) akımlar yardımıyla değişken manyetik alan oluşturularak tencere tabanının ısıtılması hedeflenmektedir. Bahsedilen güç elektroniği devreleri sıklıkla YKSR ve TAKR eviriciler olarak karşımıza çıkmaktadır.

3.1 Yarım Köprü Seri Rezonanslı Evirici (YKSR)

1959 yılından beri kullanılmakta olan YKSR evirici devresi, DA akımı AA akıma çevirebilmek için farklı uygulamalarda sıklıkla tercih edilmektedir. [1], [12]. YKSR eviricide rezonans anında devreden geçen akım sinüzoidaldir. Diğer taraftan yarı iletken anahtarlardan geçen akım yarım dalga sinüs, gerilim ise kare dalgadır [1], [40]. Şekil 3(a)’da verilen L_{EQ} eşdeğer endüktans değerini ve R_{EQ} eşdeğer direnci tanımlarken, C_{RES1} ve C_{RES2} ise rezonans kondansatörlerini tanımlamaktadır. T_1 ve T_2 yarı iletkenler anahtarlar iken V_{DC} değeri ise DA gerilimi tanımlamaktadır. YKSR için devre analizi yapılırken, Q kalite faktörü yeterince büyük seçildiğinde rezonans devresi akımının sinüzoidal olduğu düşünülmüştür. Bu kabul, seri RLC devresinin doğal sonucu olarak ortaya çıkmaktadır [41].



Şekil 18. Q parametresi ile frekansa bağlı akım değişimi grafiği [42].

YKSR devre analizinde kullanılacak temel değişkenler sırasıyla, rezonans frekansını tanımlayan ω_0 , devrenin karakteristik empedansını tanımlayan Z_0 ve kalite faktörünü tanımlayan Q değerleri olarak karşımıza çıkmaktadır. Şekil 18’de frekans ve akıma bağlı Q grafiği gösterilmektedir.

$$\omega_0 = 1/\sqrt{L_{EQ}C_{RES}} \quad (1)$$


$$Z_0 = \sqrt{L_{EQ}/C_{RES}} = \omega_0 L_{EQ} = 1/(\omega_0 C_{RES}) \quad (2)$$

$$Q = \omega_0 L_{EQ}/R_{EQ} = 1/(\omega_0 C_{RES}R_{EQ}) = Z_0/R \quad (3)$$


YKSR eviricili ndüksiyonlu ocak uygulamalarında çalışma frekansı f , f_0 rezonans frekansının üzerinde bir noktada seçilerek güç kontrolü yapılır [1]. Endüktif bölgede çalışılmanın temel nedeni, hem iletim hem de kesim anında yumuşak anahtarlama yapılabilmesi ve iletim ve anahtarlama kayıplarının ters orantılı olarak değişmesidir. YKSR dönüştürücü için tanımlanmış 6 farklı çalışma evresi Şekil 19’de gösterilmektedir.

Şekil 20’de ise simülasyon çalışmaları sonucunda bulunan gerilim ve akım dalga şekilleri detaylı bir şekilde gösterilmektedir.

Başlangıçta; T_1 ve T_2 yarı iletken anahtarları kesim durumundadır. V_{DC} giriş gerilimi V kabul edildiğinde C_{RES1} ve C_{RES2} rezonans kondansatörlerinin gerilim değeri $V/2$ ’dir. L_{EQ} ile gösterilen endüktör elemanından akım geçmemektedir.




Şekil 19. YKSR eviriciye ait çalışma evreleri [42].




Şekil 20. YKSR eviriciye ait gerilim ve akım dalga şekilleri [42].

Evre I ($t_1 < t < t_2$); Şekil 20 ve Şekil 21’ de detaylı olarak gösterildiği gibi, D₁ diyodu kesime girerken, T₁ yarı iletkeninin iletme girmesiyle ilgili evre başlayacaktır. Girişten çekilen akım I_{DC}, T₁ - L_{EQ} - R_{EQ} - C_{RES2} devre elemanlarından geçerek çevrimini tamamlayacaktır. C_{RES1} rezonans kondansatörü, I_{CRES1} akımı ile



Şekil 21. $t_0 < t < t_2$ evresine ait gerilim dalga şekilleri.



Şekil 22. $t_2 < t < t_4$ evresine ait gerilim ve akım dalga şekilleri.

deşarj olurken C_{RES2} kondansatörü I_{CRES2} akımı ile şarj olacaktır. L_{EQ} endüktöründen geçen akım değerinin yarısı C_{RES1} kondansatörünündeşarj akımı I_{CRES1}, diğer yarısı ise giriş şebekesinden çekilen kaynak akımı I_{DC}’dir.

$$V_{DC} = v_{LEQ}(t) + v_{REQ}(t) + v_{CRES2}(t) \quad (4)$$

$$v_{LEQ}(t) + v_{REQ}(t) - v_{CRES1}(t) = 0 \quad (5)$$

Evre II ($t_2 < t < t_3$); Şekil 22’te detaylı olarak gösterildiği gibi T₁ yarı iletken anahtarının kesime girmesiyle başlayacaktır. T₁ yarı iletken anahtarının kesime girmesiyle, bastırma kondansatörü C_{S1} DA gerilim ile şarj olurken (I_{CS1}) aynı zamanda bastırma kondansatörü C_{S2}deşarj olacaktır (I_{CS2}). Çalışma evresi sonlanıncaya kadar kaynaktan çekilen I_{DC} akımı devreden geçmeye devam edecektir. T₁ yarı iletkeni kesime girdiğinde C_{S1} bastırma kondansatörünün şarj olması sonucu, T₁ uç gerilimi bir anda yükselmez. Böylece T₁ yarı iletken anahtarının yumuşak anahtarlama ile (ZVS) kesime girmesi sağlanacaktır.

Evre III ($t_3 < t < t_5$); Bastırma kondansatörü C_{S1}’in I_{CS1} akımı ile şarj olması ve bastırma kondansatörü C_{S2}’nin I_{CS2} akımı iledeşarj olması sonucu D₂ diyotu üzerinden I_{D2} akımı geçmeye başlayacaktır. D₂ diyotundan I_{D2} akımının geçmesi sonucu kaynak akımının yönü değişir. L_{EQ} ile gösterilen endüktör elemanı kaynak gibi davranarak devreden geçen akımın hızlıca sifira inmesine izin vermeyecektir. Bunun sonucu olarak rezonans devre akımının tamamı D₂ diyot elemanı üzerinden geçecektir (I_{LEQ} = I_{D2}). İlk iki evrede olduğu gibi üçüncü evrede de C_{RES1} kondansatör elemanıdeşarj olmaya devam ederken C_{RES2} kondansatör elemanı şarj olmaya devam edecektir.

Evre IV ($t_5 < t < t_6$); D₂ diyot elemanı kesime girerken T₂ yarı iletken anahtarı iletme girecektir. D₂ diyot elemanı iletimdeyken T₂ yarı iletken anahtarına sürme sinyali uygulanarak anahtarlama

kaybının azaltılması amaçlanmaktadır. Bunun nedeni D_2 diyodu iletimde olduğu sürece T_2 yarı iletken anahtarının iletime giremeyecek olmasıdır. Rezonans akımının yön değiştirmesi sonucu T_2 anahtarı sıfır gerilimde iletime girecektir (ZVT). Girişten çekilen akım I_{DC} , $C_{RES1} - R_{EQ} - L_{EQ} - T_2$ devre elemanları üzerinden çevrimini tamamlarken C_{RES2} kondansatör akımı I_{CRES2} , $R_{EQ} - L_{EQ} - T_2$ devre elemanları üzerinden çevrimini tamamlayacaktır. IV. evrede C_{RES1} kondansatör elemanı şarj olmaya başlarken C_{RES2} kondansatör elemanı deşarj olmaya başlayacaktır. L_{EQ} endüktöründen geçen I_{LEQ} akımının yarısı C_{RES2} kondansatörü deşarj akımı I_{CRES2} sağlarken, diğer yarısı ise DA kaynak akımı I_{DC} sağlayacaktır. IV. evre için tanımlanmış devre denklemleri alta verilmektedir.

$$V_{DC} = v_{CRES1}(t) - v_{REQ}(t) - v_{LEQ}(t) \quad (6)$$

$$v_{CRES2}(t) + v_{LEQ}(t) + v_{REQ}(t) = 0 \quad (7)$$

Evre V ($t_6 < t < t_7$); T_2 anahtarının kesime girmesi sonucu paralel bağlı bastırma kondansatörü C_{S2} kaynaktan çekilen I_{CS2} akımı ile şarj olurken, bastırma kondansatörü C_{S1} , I_{CS1} akımı ile deşarj olacaktır. T_2 yarı iletkeni kesime girdiğinde C_{S2} bastırma kondansatörünün şarj olması sonucu, T_2 uç gerilimi bir anda yükselemez. Böylece T_2 yarı iletkenin anahtarının yumuşak anahtarlama ile (ZVS) kesime girmesi sağlanacaktır.

Evre VI ($t_7 < t < t_1$); Bastırma kondansatörü C_{S1} 'nin I_{CS1} akımı ile deşarj olması sonucu D_1 diyotu üzerinden I_{D1} akımı geçmeye başlayacaktır. L_{EQ} ile gösterilen endüktör elemanı kaynak gibi davranarak devreden geçen akımın hızlıca sıfıra inmesine izin vermeyecektir. Bunun sonucu olarak rezonans devre akımının tamamı D_1 diyot elemanı üzerinden geçecektir ($I_{LEQ} = I_{D1}$). İlk iki evrede olduğu gibi altıncı evrede de C_{RES1} kondansatör elemanı şarj olmaya devam ederken C_{RES2} kondansatör elemanı deşarj olmaya devam edecektir.

3.2 Tek Anahtarlı Kısmi Rezonanslı Evirici (TAKR)

TAKR eviriciye ait devre şeması Şekil 3 (b)'de gösterilmektedir. T_1 yarı iletken anahtarının iletime girmesi ile birlikte DA kaynak gerilimi bobine uygulanır. L_{EQ} endüktörünün akım değeri yükselerek endüktörde enerji depo edilir. Anahtarın kesime girmesinin sonucu olarak endüktör ve kondansatör arasında rezonans başlar. Kondansatörün deşarj olmasının sonucu olarak diyot iletime girecek ve V_{CE} geriliminin sıfırın altına inmesini önleyecektir [43]-[46].


Şekil 23'te TAKR eviricinin dört temel çalışma evresi, Şekil 24'te ise bu evrelere ait gerilim ve akım dalga şekilleri gösterilmektedir. $t_1 < t < t_2$ evresinde T_1 anahtarı iletimdedir ve bu evrede devre seri RL devresi şeklinde çalışır. Diğer taraftan $t_2 < t < t_4$ evresinde L_{EQ} ve C_{RES} arasında rezonans oluşacak ve devre seri RLC devresi şeklinde çalışacaktır.

Evre I ($t_1 < t < t_2$); yarı iletken anahtarın ters paralel bağlı diyot sayesinde sıfır gerilimde iletime girmesiyle başlayacak (ZVT), T_1 yarı iletken anahtarı kesime girdiğinde sona erecektir. I_{DC} kaynaktan akımı, $T_1 - L_{EQ} - R_{EQ}$ devre elemanlarından geçerek çevrimini tamamlayacaktır. RL devresi şeklinde modellenen bu evre süresince endüktör akımı I_{LEQ} , T_1 yarı iletkeninden geçmektedir. İlgili evreye ait devre denklemleri aşağıda gösterilmektedir.


$$i_{LEQ}(0) = 0 \quad (8)$$

$$i_{LEQ} = i_T = \frac{V_{DC}}{R_{EQ}} \left(1 - e^{-\left(\frac{R_{EQ}}{L_{EQ}}\right)t}\right) \quad (9)$$

$$V_{DC} = v_{LEQ} + v_{REQ} \quad (10)$$




Şekil 23. TAKR eviricinin çalışma evreleri [43], [44].




Şekil 24. TAKR eviriciye ait gerilim ve akım dalga şekilleri.


Evre I için kaydedilen gerilim dalga şekilleri Şekil 25'te ayrıntılı olarak gösterilmektedir. Yarı iletken anahtarın kesime girmesinden hemen sonra V_{CE} gerilim değeri, V_{DC} gerilim değerine ulaşana kadar rezonans devresi akımı artmaya devam edecektir. Ancak rezonans akımındaki artış değeri analiz için ihmal edilebilecek düzeyde olduğundan dolayı RL devresi olarak çalışılan evrede ölçülen maksimum I_{LEQ} akımı, TAKR devresinde dolaşan maksimum $I_{LEQ MAX}$ değerine eşit kabul edilerek analiz yapılmaktadır.




Şekil 25. $t_0 < t < t_2$ evresine ait gerilim dalga şekilleri.



Şekil 27. $t_2 < t < t_4$ evresine ait gerilim ve akım dalga şekilleri.



Şekil 26. $t_2 < t < t_4$ evresine ait gerilim dalga şekilleri.



Şekil 28. $t_3 < t < t_4$ evresine ait gerilim ve akım dalga şekilleri.

Evre II ($t_2 < t < t_3$); yarı iletken anahtarın kesime girmesi ile birlikte başlayacaktır. Bobinden geçen akım ani olarak sıfıra düşmeyecek, endüktör bir kaynak haline dönüşerek devreyi beslemeye başlayacaktır. Bobinin tam anlamıyla deşarj olması ile birlikte Evre II sona erecektir. Evre II için geçerli devre denklemi aşağıda verilmektedir. Şekil 26’de gösterildiği gibi i_{LEQ} bobin akımının azaldığı ve bunun sonucu olarak di_{LEQ}/dt değerinin negatif olduğu Evre II süresi boyunca yarı iletken anahtarın maruz kaldığı V_{CE} gerilimi artacaktır.

$$V_{CRES} = V_{LEQ} + V_{REQ} \quad (11)$$

$$V_{CE} = V_{DC} - V_{LEQ} - V_{REQ} \quad (12)$$

Evre III ($t_3 < t < t_4$); Şekil 27’de detaylı akım ve gerilim dalga şekilleri ile gösterildiği gibi endüktör enerjisinin kondansatöre tamamen aktarılması sonucu rezonans devresi akımının yönünün değişmesi ile başlayacaktır. Evre III boyunca kondansatör devre elemanında biriken enerji rezonans devresine geri aktarılacaktır. Evre III’e ilişkin devre denklemi aşağıda gösterildiği şekilde ifade edilmektedir.

$$V_{CE} = V_{DC} - V_{LEQ} - V_{REQ} \quad (13)$$

Anahtarın kesim anında maruz kaldığı en yüksek gerilim olan $V_{CE MAX}$ gerilimi, rezonans akımının yön değiştirdiği anda oluşmaktadır. Her koşulda anahtar uç gerilimi V_{CE} , yarı iletkeni anahtarın gerilim dayanım sınırını aşmamalıdır. V_{DC} DA gerilim, $I_{LEQ MAX}$ maksimum endüktör akımı, Z_0 karakteristik empedans ve $V_{CE MAX}$ T_1 yarı iletken anahtarının maksimum uç gerilimi olarak düşünüldüğünde, $V_{CE MAX}$ değeri aşağıdaki denklemle ifade edilmektedir [41].

$$V_{CE MAX} = V_{DC} + I_{LEQ MAX} Z_0 \quad (14)$$

Diğer taraftan, TAKR evirici devresi $t_2 < t < t_4$ evresinde seri RLC devresi olarak analiz edilecektir. Bu nedenle Evre II ve Evre III için geçerli olacak şekilde bobin akımı i_{LEQ} denklemleri aşağıda gösterildiği şekliyle ifade edilir.

$$i_{LEQ}(t) = e^{-\alpha t} [B_1 \cos(\omega_d t) + B_2 \sin(\omega_d t)] \quad (15)$$

$$di_{LEQ}(t)/dt = -e^{-\alpha t} [(B_1 \omega_d + B_2 \alpha) \sin(\omega_d t) + (B_1 \alpha - B_2 \omega_d) \cos(\omega_d t)] \quad (16)$$

$$i_{LEQ}(t_2) \Rightarrow B_1 = I_0 \quad (17)$$

$$di_{LEQ}(t_2)/dt \Rightarrow$$

$$B_2 = ((V_{DC} - R_{EQ} I_0) / (L_{EQ} \omega_d) + (\alpha I_0) / \omega_d \quad (18)$$

İlgili denklemler yardımıyla hem devre analizi [43] hem de devre tasarımı [44] yapmak mümkün hale gelmektedir.

Aynı şekilde yarı iletken anahtar gerilimi V_{CE} nin elde edilebilmesi için ilgili gerilim denklemleri aşağıda gösterildiği şekliyle ifade edilir.

$$v(t) = V_{DC} + e^{-\alpha t} [A_1 \cos(\omega_d t) + A_2 \sin(\omega_d t)] \quad (19)$$

$$dv(t)/dt = -e^{-\alpha t} [(A_1 \omega_d + A_2 \alpha) \sin(\omega_d t) + (A_1 \alpha - A_2 \omega_d) \cos(\omega_d t)] \quad (20)$$

$$v(t_0) \Rightarrow A_1 = -V_{DC} \quad (21)$$

$$dv(t_0)/dt \Rightarrow A_2 = (I_0 / C_{RES} - \alpha V_{DC}) / \omega_d \quad (22)$$

Evre IV ($t_4 < t < t_1$); Şekil 28'da detaylı gerilim ve akım dalga şekilleriyle gösterildiği gibi v_{CE} geriliminin sıfıra ulaşması sonucu yarı iletken anahtara ters paralel bağlı D_1 diyot elemanının iletme girmesiyle başlayacaktır. D_1 diyotu iletimde olduğu sırada T_1 anahtarına sürme sinyali uygulanarak (t_0) ZVT sağlanmaktadır. T_1 anahtarının iletme girmesi sonucu yeniden ($t_1 < t < t_2$) ile sınırlandırılan Evre I başlayacaktır. Evre IV için geçerli devre denklemi aşağıdaki şekilde ifade edilmektedir.

$$V_{DC} = v_{REQ} + v_{LEQ} \quad (23)$$

Ayrıca Evre IV için detaylı devre denklemleri altta verilmektedir. İlgili denklemlerde diyot akımı iletim süresi t_D ve diyot tepe akımı I_{Dmax} olarak ifade edilmektedir.

$$i_{LEQ}(t) = \frac{V_{DC}}{R_{EQ}} + (I_{Dmax} - \frac{V_{DC}}{R_{EQ}})e^{-\frac{R_{EQ}}{L_{EQ}}t} \quad (24)$$

$$i_{LEQ}(t_D) = 0 = \frac{V_{DC}}{R_{EQ}} + (I_{Dmax} - \frac{V_{DC}}{R_{EQ}})e^{-\frac{R_{EQ}}{L_{EQ}}t_D} \quad (25)$$

$$t_D = \ln \left[\frac{V_{DC}/R_{EQ}}{V_{DC}/R_{EQ} - I_{Dmax}} \right] \left(-\frac{L_{EQ}}{R_{EQ}} \right) \quad (26)$$

$$t_D = -\frac{L_{EQ}}{R_{EQ}} \cdot \ln \left(1 + \frac{I_{Dmax}}{V_{DC}/R_{EQ} - I_{Dmax}} \right) \quad (27)$$

4 Uygulama Sonuçları

Çalışmanın bu bölümünde, III. bölümde ayrıntılı olarak analizi yapılan YKSR [42] ve TAKR [44] eviriciler ile ilgili uygulama sonuçları paylaşılmaktadır.

Şekil 29'da endüksiyon ısıtmalı ocak uygulamalarında sıklıkla kullanılan tencere modelleri gösterilmektedir. Turuncu renkli olan **Döküm**, kırmızı renkli olan Silit marka **Silargan**, diğer tencere ise ferromanyetik **Çelik** tencedir.



Şekil 29. Uygulamada kullanılan genel tencere modelleri [44].



Şekil 30. YKSR İnvter için uygulama devresi [42].

4.1 YKSR Evirici İçin Uygulama Devresi

Şekil 30'da tencere, ocak, ve test düzeneğinden oluşan ve YKSR evirici içeren uygulama devresi örneği gösterilmektedir.

Ana besleme gerilimi 230 VAC olduğundan dolayı DC bara gerilimi 320 VDC'dir. Doğrultucu devresinde GSIB2560 diyot köprüsü kullanılmıştır. Yarı iletken anahtar olarak gövde diyotlu IHW30N60R5 IGBT kullanıldığından devrede ilave bir diyota ihtiyaç duyulmaz. YKSR uygulamasında kullanılan bobinin teknik özellikleri Tablo 3'te verilmektedir.

Tablo 3. YKSR eviricili endüksiyon uygulamasında kullanılan bobine ilişkin teknik özellikler.

Parametre	Sembol	Değer	Birim
Bobin sarım sayısı	n	28	
Bobinin dış çapı	$a_{n=28}$	83.4	mm
Bobinin iç çapı	a_1	25	mm
Bir litz telinin tel miktarı		66	
Tek telin tel çapı	r_0	0.135	mm
CCA telin iletkenliği	σ_{cca}	3.37×10^7	S/m

YKSR eviricinin bir sonucu olarak C_{RES} rezonans kapasitör değeri C_{RES1} ve C_{RES2} olacak şekilde iki eş parçaya bölünmüş ve 340 nF olarak seçilmiştir. C_F filtre kondansatörü 5 μF , L_F filtre bobini ise 250 μH olarak seçilmiştir. Bastırma kapasitörleri C_{S1} ve C_{S2} 11 nF olarak seçilmiştir. Diğer tüm devre parametreleri Tablo 4'te verilmektedir.


Tablo 4. YKSR eviricili endüksiyon devresi parametre değerleri.

Parametre	Sembol	Değer	Birim
Mak. rezonans devresi akımı	$I_{ResInmax}$	42.26	APEAK
Rezonans frekansı	f_{Res}	20.65	kHz
Minimum anahtarlama frekansı	f_{SWmin}	21	kHz
Tenceresiz eşdeğer endüktans	$L_{EQNoLoad}$	103	μH
Tenceresiz eşdeğer direnç	$R_{EQNoLoad}$	0.085	Ω
Döküm tencereli eşdeğer endük.	L_{EQPan}	88.27	μH
Döküm tencereli eşdeğer direnç	R_{EQPan}	4.876	Ω
Toplam rezonans kapasitesi	C_{RES}	680	nF
Kalite faktörü	Q_L	4.69	
Toplam bastırma kondansatörü	C_S	22	nF
Ölü zaman	T_{Dead}	1.5	μs

YKSR eviricili endüksiyon ocak ile yapılan uygulama sonucunda Tablo 5'te verilen değerler elde edilmiştir.

Tablo 5. YKSR eviricili endüksiyon devresi sonuçları.


Parametre	Uygulama Sonucu
Maksimum bobin akımı	43.6A @21kHz
Minimum kesme akımı	9.65A @21kHz
Maksimum kesme akımı	22.48A @ 24.1kHz
Ortalama Giriş Gücü	2197W



Şekil 31. Prototip devre kullanılarak elde edilen ayrıntılı dalga biçimleri. Mavi sinyal: IGBT kolektör emitör voltajı V_{CE} (90V/div), Sarı sinyal: IGBT Akımı (10A/div).


Şekil 31’de YKSR eviricili uygulama devresi yardımıyla elde edilen ve yarı iletken akımı ve gerilimini gösteren osiloskop görüntüsü gösterilmektedir.

Şekil 32’de uygulama devresinden elde edilen Conducted EMI sonuçları gösterilmektedir. Sonuçlar dikkatli bir şekilde incelendiğinde sonuçların her zaman standardın belirlediği limitlerin altında olduğu kolaylıkla gözlemlenebilir.



Şekil 32. Uygulama devresinin yapılan emisyon testi sonuçları.


Şekil 33’te uygulama devresi ile 10 dakikalık ısıtma sonunda yapılan ısıl ölçümlerde, üst anahtarın sıcaklığının 55 C, alt anahtarın sıcaklığının 52 C derece, köprü doğrultucu sıcaklığının ise 76 C olduğu görülmektedir.



Şekil 33. Uygulama devresinin termal görüntüleri.

4.2 TAKR Evirici İçin Uygulama Devresi

Şekil 34’te tencere, ocak, ve test düzeneğinden oluşan ve TAKR evirici içeren uygulama devresi gösterilmektedir.



Şekil 33. TAKR İnvter için uygulama devresi [44].

Tablo 6’da pratik uygulama devresinde kullanılan endüksiyon bobininin fiziksel ve elektriksel özellikleri gösterilmektedir.

Tablo 6. Endüksiyon bobininin fiziksel ve elektriksel özellikleri.

Parametre	Sembol	Değer	Birim
Bobin sarım sayısı	n	28	
Bobinin dış çapı	a_n	180	mm
Bobinin iç çapı	a_1	30	mm
Bir litz telinin tel miktarı		66	
Tek telin tel çapı		0,27	mm
Ferit için manyetik geçirgenlik	μ_r	800	

Tablo 7’de ise Şekil 29’da verilen üç farklı tencere ve tenceresiz durumlar için ölçülen eşdeğer endüktans ve direnç değerleri gösterilmektedir.

Tablo 7. 3 farklı tencere ve tenceresiz durumlara ait eşdeğer endüktans ve direnç değerleri.


Parametre	Sembol	Değer	Birim
Tenceresiz eşdeğer endüktans	$L_{EQNoLoad}$	110	μH
Tenceresiz eşdeğer direnç	$R_{EQNoLoad}$	0,12	Ω
Döküm tencere için eşdeğer endüktans	$L_{EQ-Döküm}$	89,76	μH
Döküm tencere için eşdeğer direnç	$R_{EQ-Döküm}$	4,21	Ω
Çelik tencere için eşdeğer endüktans	$L_{EQ-Çelik}$	81,81	μH
Çelik tencere için eşdeğer direnç	$R_{EQ-Çelik}$	3,36	Ω
Silargan tencere için eşdeğer endüktans	$L_{EQ-Silit}$	69,07	μH
Silargan tencere için eşdeğer direnç	$R_{EQ-Silit}$	2,48	Ω

Tablo 7’den anlaşılacağı üzere, pratik ev uygulamalarında kullanılan döküm, çelik ve silit silargan benzeri tencereler, farklı ferromanyetik ve elektriksel özelliklere sahiptir. Bu tencere türleri endüksiyonlu ocakta kullanıldığında, farklı bobin akımları ve anahtarlama gerilimleri ortaya çıkar. Üç farklı tencere modeli kullanıldığında elde edilen bobin akımı, anahtar gerilimi ve çıkış gücü değerleri Tablo 8’de gösterilmektedir.

Tablo 8. Üç farklı tencere modeli için elde edilen akım, gerilim ve güç değerleri.

Giriş Değerleri			Çıkış Değerleri		
R_{EQ}	L_{EQ}	C_{RES}	I_{LEQMAX}	V_{CEMAX}	P
4,21 Ω	89,76 μH	270 nF	42,4 A	928 V	1276 W
3,36 Ω	81,81 μH	270 nF	42,8 A	968 V	1270 W
2,48 Ω	69,07 μH	270 nF	45,6 A	920 V	1255 W

Şekil 35'te ilgili uygulama devresi yardımıyla elde edilen yarı iletken akımı, gerilimi ve sürme işaretleri gösteren osiloskop görüntüsü gösterilmektedir.



Şekil 34. Prototip devre kullanılarak elde edilen ayrıntılı dalga biçimleri. Mavi sinyal: IGBT kolektör emitör voltajı V_{CE} (200V/div), Mor sinyal: bobin akımı I_{LEQ} (10A/div), Sarı sinyal: IGBT geçit kontrol sinyali (5V/div).

5 Sonuçlar

Bu çalışmada endüksiyon ısıtmalı ocaklarda kullanılan güncel uygulamalar hakkında bilgi verilmiş, endüksiyon ısıtmalı ocaklarda yaygın olarak kullanılan tek anahtarlı kısmi rezonanslı dönüştürücüler ve yarım köprü seri rezonanslı dönüştürücüler için detaylı devre analizleri yapılmıştır. Sonrasında YKSR ve TAKR evirici içeren uygulama devresi sonuçları paylaşılmıştır. YKSR ve TAKR eviriciler için yapılan ilgili devre analizleri kullanılarak her iki yöntemin avantaj ve dezavantajları hakkında bilgiler paylaşılmış ve sonraki çalışmalara ışık tutulmaya çalışılmıştır.

6 Kaynaklar

- [1] S. Zinn and S. L. Semiatin, *Elements of Induction Heating Design, Control and Applications*, Second Edi. California, Ohio: EPRI, ASM International, 1988.
- [2] I. R. Valery, L. Don, C. Raymond, and M. Black, *Handbook of Induction Heating: Manufacturing Engineering and Materials Processing*, Second Edi. New York, Basel: Marcel Dekker, Inc., 2002.
- [3] M. K. Salih NACAR, Selim ÖNCÜ, "Induction Heated Metal Hydride Tube for Hydrogen Storage System," *Pamukkale Univ. J. Eng. ...*, vol. 28, no. 5, pp. 676–680, 2022, doi: 10.5505/pajes.2021.97692.
- [4] O. Lucia, P. Maussion, E. Dede, and J. M. Burdío, "Induction heating technology and its applications: Past Developments, current Technology, and future challenges," *IEEE Trans. Ind. Electron.*, vol. 61, no. 05, pp. 2509–2520, 2014, doi: 10.1109/TIE.2013.2281162.
- [5] H. Sarnago, O. Lucia, A. Mediano, and J. M. Burdío, "A Class-E Direct AC-AC Converter With Multicycle Modulation for Induction Heating Systems," *IEEE Trans. Ind. Electron.*, vol. 61, no. 5, pp. 2521–2530, May 2014, doi: 10.1109/TIE.2013.2281164.
- [6] H. Sarnago, O. Lucia, A. Mediano, and J. M. Burdío, "Direct AC-AC Resonant Boost Converter for Efficient Domestic Induction Heating Applications," *IEEE Trans. Power Electron.*, vol. 29, no. 3, pp. 1128–1139, Mar. 2014, doi: 10.1109/TPEL.2013.2262154.
- [7] S. Aslan, M. Ozturk, and N. Altintas, "A comparative study of SiC and Si power devices in induction cookers," in *2018 5th International Conference on Electrical and Electronic Engineering (ICEEE)*, May 2018, pp. 297–301, doi: 10.1109/ICEEE2.2018.8391350.
- [8] H. Sarnago, O. Lucia, A. Mediano, and J. M. Burdío, "Efficient and cost-effective ZCS direct AC-AC resonant converter for induction heating," *IEEE Trans. Ind. Electron.*, vol. 61, no. 5, pp. 2546–2555, 2014, doi: 10.1109/TIE.2013.2262752.
- [9] M. Öztürk and N. Altıntaş, "Ev Tipi İndüksiyon Ocaklar İçin Çok Bobinli AC-AC Dönüştürücü Tasarımı," *EEMKON 2017*, pp. 118–123, 2017, [Online]. Available: http://eemkon.org.tr/wp-content/uploads/2017/12/eemkon2017_bildirilerkitabiv3.pdf.
- [10] M. A. Dzienciakowski, "Power Electronics Converters in Induction Heating – the survey," *2017 Prog. Appl. Electr. Eng.*, 2017, doi: 10.1109/PAEE.2017.8009013.
- [11] R. W. Erickson and D. Maksimovic, *Fundamentals of Power Electronics*, Second edi. New York ,Boston, Dordrecht, London, Moscow: Kluwer Academic Publishers, 2004.
- [12] I. Nagy, *Inverters-Resonant Converters*. CRC, 2002.
- [13] S. Sakamoto, T. Mishima, and C. Ide, "A Phase-Shift PWM-Controlled ZVS Boost Full-Bridge AC-AC Converter for Metal-Surface High-Frequency Induction Heating Applications," *2016 IEEE Energy Convers. Congr. Expo.*, pp. 0–6, doi: 10.1109/ECCE.2016.7854755.
- [14] K. S. Zachariah, M. Vennila, M. E. Madhusudhanan, and M. E. Mahavishnu, "High Power Frequency Parallel Resonance Inverter With Bridgeless Rectifier For Induction Heating Application," *2016 Int. Conf. Electr. Electron. Optim. Tech.*, pp. 4847–4852, doi: 10.1109/ICEEOT.2016.7755641.
- [15] M. Pérez-tarragona, S. Member, H. Sarnago, and Ó. Lucia, "Design and Experimental Analysis of PFC Rectifiers for Domestic Induction Heating Applications," *IEEE Trans. Power Electron. (Vol. 33, Issue 8, Aug. 2018)*, vol. 8993, no. c, doi: 10.1109/TPEL.2017.2755367.
- [16] H. Sarnago, O. Lucia, A. Mediano, and J. M. Burdío, "A class-e direct AC-AC converter with multicycle modulation for induction heating systems," *IEEE Trans. Ind. Electron.*, vol. 61, no. 5, pp. 2521–2530, 2014, doi: 10.1109/TIE.2013.2281164.
- [17] J. M. Sarnago, H. ; Lucia, O. ; Mediano, A. ; Burdío, "Direct AC – AC Resonant Boost Converter for," *IEEE Trans. Power Electron.*, vol. 29, no. 3, pp. 1128–1139, 2014, doi: 10.1109/TPEL.2013.2262154.
- [18] H. Sarnago, O. Lucia, S. Member, J. M. Burdío, and S. Member, "Multiple-Output ZCS Resonant Inverter for Multi-Coil Induction Heating Appliances," doi: 10.1109/APEC.2017.7931010.
- [19] W. Han, K. T. Chau, Z. Zhang, and C. Jiang, "Single-Source Multiple-Coil Homogeneous Induction Heating," *IEEE Trans. Magn. (Vol. 53, Issue 11, Nov. 2017)*, vol. 53, no. 11, doi: 10.1109/TMAG.2017.2717867.
- [20] P. Taylor and B. S. Sazak, "A Capacitor Voltage Clamped Dual Half-Bridge Series-Resonant Inverter for Home

- Cooking Applications,” no. October 2014, pp. 37–41, 2006, doi: 10.1080/00207210410001712165.
- [21] B. S. S. Sevilay ÇETİN, “Mutfak Tipi Isıtma Uygulamaları İçin İki Çıkışlı Bir İndüksiyon Isıtma İnverteri Tasarımı,” *Pamukkale Univ. J. Eng. ...*, vol. 12, no. 3, pp. 397–401, 2006.
- [22] F. Monterde, P. Hernández, J. M. Burdío, J. R. García, and A. Martínez, “Multiple-Output Series-Resonant Inverter for Induction Cookers Previous state-of-the-art F1,” *EPE 99 - Lausanne*, pp. 1–8.
- [23] H. Sarnago, O. Lucia, A. Mediano, and J. M. Burdío, “A class-e direct AC-AC converter with multicycle modulation for induction heating systems,” *IEEE Trans. Ind. Electron.*, vol. 61, no. 5, pp. 2521–2530, 2014, doi: 10.1109/TIE.2013.2281164.
- [24] F. Forest, S. Faucher, J. Y. Gaspard, D. Montloup, J. J. Huselstein, and C. Joubert, “Frequency-synchronized resonant converters for the supply of multiwinding coils in induction cooking appliances,” *IEEE Trans. Ind. Electron.*, vol. 54, no. 1, pp. 441–452, 2007, doi: 10.1109/TIE.2006.888797.
- [25] M. Saoudi, D. Puyal, H. Sarnago, D. Anton, and A. Mediano, “A new multiple coils topology for domestic induction cooking system,” *Proc. 2011 14th Eur. Conf. Power Electron. Appl.*, pp. 1–7, 2011.
- [26] M. Öztürk, “MS061 İndüksiyonlu Cam Ocak - Ferre Türkiye - Ferre Ankastr,” <https://www.ferreturkiye.com/>, 2020. <https://www.ferreturkiye.com/product/ms061-induksiyonlu-cam-ocak/7101/>.
- [27] J. Acero, R. Alonso, J. M. Burdío, L. A. Barragán, and C. Carretero, “A model of losses in twisted-multistranded wires for planar windings used in domestic induction heating appliances,” *Conf. Proc. - IEEE Appl. Power Electron. Conf. Expo. - APEC*, pp. 1247–1253, 2007, doi: 10.1109/APEX.2007.357674.
- [28] J. Acero, J. M. Burdío, L. A. Barragán, and R. Alonso, “A model of the equivalent impedance of the coupled winding-load system for a domestic induction heating application,” *IEEE Int. Symp. Ind. Electron.*, no. 1, pp. 491–496, 2007, doi: 10.1109/ISIE.2007.4374646.
- [29] F. Tourkhani and P. Viarouge, “Accurate analytical model of winding losses in round Litz wire windings,” *IEEE Trans. Magn.*, vol. 37, no. 1, pp. 538–543, 2001, doi: 10.1109/20.914375.
- [30] P. Hernandez, F. Monterde, and J. M. Burdío, “About the power losses distribution in inductors for induction cooking appliances,” *Epe*, pp. 1–7, 1999, [Online]. Available: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle>About+the+power+losses+distribution+in+inductors+for+induction+cooking+appliances#0>.
- [31] A. D. Podoltsev, I. N. Kucheryavaya, and B. B. Lebedev, “Analysis of Effective Resistance and Eddy-Current Losses in Multiturn Winding of High-Frequency Magnetic Components,” *IEEE Trans. Magn. VOL. 39, NO. 1, JANUARY 2003*, vol. 39, no. 1, pp. 539–548, 2003.
- [32] C. R. Sullivan, “Computationally Efficient Winding Loss Calculation Geometry,” *IEEE Trans. POWER Electron. VOL. 16, NO. 1, JANUARY 2001*, vol. 16, no. 1, pp. 142–150, 2001.
- [33] P. Hernandez, F. Monterde, J. M. Burdi, J. R. Garcia, and S. Llorente, “Power Losses Distribution in the Litz-wire Winding of an Inductor for an Induction Cooking Appliance,” *IEEE 2002 28th Annu. Conf. Ind. Electron. Soc. IECON 02, 2002*, doi: 10.1109/IECON.2002.1185432.
- [34] J. Acero, C. Carretero, R. Alonso, and J. M. Burdío, “Quantitative Evaluation of Induction Efficiency in Domestic Induction Heating Applications,” *IEEE Trans. Magn. VOL. 49, NO. 4, April 2013*, vol. 49, no. 4, pp. 1382–1389, 2013.
- [35] M. Saoudi, D. Puyal, D. Antón, and A. Mediano, “Domestic induction cooking with a new loads multiplexing topology using mechanical switches,” *Proc. - ISIE 2011 2011 IEEE Int. Symp. Ind. Electron.*, pp. 233–238, 2011, doi: 10.1109/ISIE.2011.5984163.
- [36] T. Hirokawa, E. Hiraki, T. Tanaka, M. Imai, K. Yasui, and S. Sumiyoshi, “Dual-frequency multiple-output resonant soft-switching inverter for induction heating cooking appliances,” *IECON Proc. (Industrial Electron. Conf.)*, vol. 2, pp. 5028–5033, 2013, doi: 10.1109/IECON.2013.6699950.
- [37] L. C. Meng, K. W. E. Cheng, and P. C. K. Luk, “Field analysis of an induction cooker with square 9-coil system by applying diverse exciting patterns,” *6th IET Int. Conf. Power Electron. Mach. Drives (PEMD 2012)*, pp. F21–F21, 2012, doi: 10.1049/cp.2012.0359.
- [38] O. Lucia, J. M. Burdío, I. Millán, and J. Acero, “Multiple-output resonant inverter topology for multi-inductor loads,” *Conf. Proc. - IEEE Appl. Power Electron. Conf. Expo. - APEC*, no. c, pp. 1328–1333, 2010, doi: 10.1109/APEC.2010.5433401.
- [39] Ó. Lucia, J. M. Burdío, L. A. Barragán, J. Acero, and I. Millán, “Series-resonant multiinverter for multiple induction heaters,” *IEEE Trans. Power Electron.*, vol. 25, no. 11, pp. 2860–2868, 2010, doi: 10.1109/TPEL.2010.2051041.
- [40] “Mutfak Uygulamaları İçin Yarım Köprü Seri Rezonans İntertörlü İndüksiyon Isıtma Sistemi Tasarımı,” *Pamukkale Univ. J. Eng. ...*, vol. 8, no. 2, pp. 167–172, 2002, [Online]. Available: <http://pajes.pau.edu.tr/jvi.aspx?un=PAJES-80963&volume=>.
- [41] Marian K. Kazimierczuk and C. Dariusz, *Resonant Power Converters*, Second. New Jersey, Canada: A JOHN WILEY & SONS, INC., PUBLICATION, 2011.
- [42] F. Zungor, H. Bodur, M. Ozturk, and H. Obdan, “Design Methodology of Series Resonant Half Bridge Inverter for Induction Cooker,” *IEEE Access*, vol. 11, no. November, pp. 135476–135492, 2023, doi: 10.1109/ACCESS.2023.3338542.
- [43] M. Ozturk, F. Zungor, B. Emre, and B. Oz, “Quasi Resonant Inverter Load Recognition Method,” *IEEE Access*, vol. 10, no. August, pp. 89376–89386, 2022, doi: 10.1109/ACCESS.2022.3201355.
- [44] M. Ozturk, “A Simplified Design Method for Quasi-Resonant Inverter Used in Induction Hob,” *Electronics*, vol. 12, no. 19, p. 4145, Oct. 2023, doi: 10.3390/electronics12194145.
- [45] B. S. Sazak and S. Cetin, “Reducing the number of measurements in induction cooker design,” *ICEMI 2009 - Proc. 9th Int. Conf. Electron. Meas. Instruments*, no. 1, pp. 1450–1454, 2009, doi: 10.1109/ICEMI.2009.5274832.
- [46] B. S. Sazak, “Design of a 500W Resonant Induction Heater,” *Pamukkale Univ. J. Eng. ...*, vol. 5, no. 1, pp. 871–878, 1999, [Online]. Available: https://www.researchgate.net/publication/267858491_DESIGN_OF_A_500W_RESONANT_INDUCTION_HEATER.

Özgeçmişler



Metin Ozturk, 1981 yılında Kastamonu’da doğmuştur. 2004 yılında Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü’nden Lisans Derecesi ile mezun olmuştur. 2007 yılında “Üç Fazlı Asenkron Motorun Farklı Modülasyon Teknikleriyle Kontrol Edilmesi” üzerine yaptığı Tez çalışmasıyla Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Makinaları ve Güç Elektronik Anabilim Dalından Yüksek Lisans Derecesi ile mezun olmuştur. 2018 yılında “Ev Türü Endüksiyonlu Ocaklar İçin Yeni Bir AC-AC Dönüştürücünün Tasarımı ve Gerçekleştirilmesi” üzerine yaptığı Tez çalışmasıyla Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Makinaları ve Güç Elektronik Anabilim Dalından Doktora Derecesi ile mezun olmuştur. 2006-2016 yılları arasında Arçelik A.Ş. Ar-Ge Merkezi’nde sırasıyla Mühendis, Uzman Mühendis ve Kıdemli Uzman Mühendis olarak görev yapmıştır. 2016 yılından günümüze kadar geçen süreçte Mamur Teknoloji Sistemleri A.Ş. Ar-Ge Merkezi’nde Elektrik ve Elektronik süreçlerin kurulması sürecini yönetmiş ve halen Elektronik projelerden Sorumlu Ar-Ge Yöneticisi olarak görev yapmaktadır. Ayrıca 2019 yılından günümüze kadar geçen süreçte İstanbul Esenyurt Üniversitesi’nde (IESU) Dr. Öğr. Üyesi olarak görev yapmakta, 2023-2024 ders yılı itibarıyla IESU Elektrik-Elektronik Mühendisliği Bölümü’nde Bölüm Başkanı olarak görev yapmaktadır. Araştırma ilgi alanları arasında ev tipi endüksiyonla pişirme ve endüksiyonla ısıtma amacıyla kullanılan yarım köprü seri rezonans evirici ve tek anahtarlı kısmi rezonanslı eviricinin geliştirilmesi konuları yer almaktadır.



Fatih Zungor, 1994 yılında İstanbul’da doğdu. 2016 yılında Sakarya Üniversitesi’nde Elektrik-Elektronik Mühendisliği Alanından Lisans derecesini aldı. 2018 yılında “Yeni Bir İleri Yönlü Dönüştürücü Tasarımı” üzerine yaptığı tez çalışmasıyla Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Makinaları ve Güç Elektronik Anabilim Dalından Yüksek Lisans Derecesi ile mezun olmuştur. 2024 yılında “Seri Rezonanslı Yarım Köprü İnverterli Ev Türü Endüksiyon Ocaklarının Analizi Ve Yeni Bir Tasarım Metodolojisinin Geliştirilmesi” üzerine yaptığı Tez çalışmasıyla Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Makinaları ve Güç Elektronik Anabilim Dalından Doktora Derecesi ile mezun olmuştur. 2016-2018 yılları arasında Gedik Kaynak Ar-Ge Merkezi’nde sırasıyla Mühendis ve Uzman Mühendis olarak görev yapmıştır. 2018 yılından günümüze kadar olan geçen süreçte Mamur Teknoloji Sistemleri A.Ş. Ar-Ge Merkezi’nde Elektrik ve Elektronik süreçlerin kurulmasında, Elektronik projelerden sorumlu Takım Lideri olarak görev yapmaktadır. Ayrıca 2023 yılından günümüze kadar geçen süreçte İstanbul Esenyurt Üniversitesi’nde (IESU) Öğr. Gör. olarak görev yapmaktadır. Araştırma ve ilgi alanları arasında güç faktörü düzeltme, anahtarlama güç kaynakları, yüksek frekans güç dönüşümü, endüksiyon ısıtma ve güç elektroniklerinde aktif ve pasif bastırma hücreleri bulunmaktadır.



Durmuş Ersoy, 2014 yılında İstanbul Üniversitesi’nden elektrik ve elektronik mühendisliği alanında lisans derecesini ve 2020 yılında Yıldız Teknik Üniversitesi’nden elektronik ve haberleşme mühendisliği alanında yüksek lisans derecesini aldı. Şu anda İstanbul Üniversitesi-Cerrahpaşa, Elektrik ve Elektronik Mühendisliği Programı’nda doktora derecesini sürdürmektedir. 2021 yılından bu yana İstanbul Esenyurt Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü’nde Öğretim Görevlisi olarak çalışmaktadır. 2022 yılından bu yana Mamur Teknoloji A.Ş.’nin Araştırma ve Geliştirme Departmanında Elektrik Mühendisi olarak görev yapmaktadır. Mevcut araştırma ilgi alanları arasında gömülü sistemler, elektronik devrelerde optimizasyon teknikleri ve yapay zeka bulunmaktadır.