

Mayıs'25

Sayı/Number: 2 / Volume: 15
Yıl/Year: 2025

Yayın Sahibi

TMMOB

Elektrik Mühendisleri Odası Adına
Mahir ULUTAŞ

Sorumlu Yazı İşleri Müdürü

Ender KELLEÇİ

Yayın İdare Merkezi

İhlamur 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
4 ayda bir yayınlanır

Basım Adedi

500

Basım Tarihi

Mayıs 2025

EMO BİLİMSEL DERGİ

Elektrik, Elektronik, Bilgisayar, Biyomedikal
Mühendisliği Bilimsel Dergisi

The Journal of Electrical, Electronics, Computer and
Biomedical Engineering

YAYIN KURULU

BAŞ EDITÖR/EDITOR IN CHIEF

Prof. Dr. Arif NACAROĞLU
Gaziantep Üniversitesi

EDİTÖRLER/EDITORIAL BOARD

Prof. Dr. M. Timur AYDEMİR
Kadir Has Üniversitesi

Prof. Dr. Erhan Akın
Fırat Üniversitesi

Prof. Dr. Aydoğan ÖZDEMİR
İstanbul Teknik Üniversitesi

Prof. Dr. Muhittin GÖKMEN
MEF Üniversitesi

Prof. Dr. Tayfun AKGÜL
İstanbul Teknik 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	Gazi Üniversitesi
Prof. Dr. Ali Hikmet Doğru	Orta Doğu Teknik Üniversitesi
Prof. Dr. Arif Nacaroglu	Gaziantep 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 Panayircı	Kadir Has Üniversitesi
Prof. Dr. Erkan Afacan	Gazi Üniversitesi
Prof. Dr. Ferit Acar Savacı	İzmir İleri Teknoloji Enstitüsü
Prof. Dr. H. Bülent Ertan	Atılım 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	İstanbul Teknik Üniversitesi
Prof. Dr. Muhittin Gökmen	MEF Üniversitesi
Prof. Dr. Murat Aşkar	İzmir Ekonomi Üniversitesi
Prof. Dr. Osman Eroğlu	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 Koltuksuz	Yaşar Üniversitesi
Doç. Dr. Osman Abul	TOBB Ekonomi ve Teknoloji Üniversitesi
Prof. Dr. Ece Olcay Güneş	İstanbul Teknik Üniversitesi
Prof. Dr. Hülya Gökarp	Ondokuz Mayıs Üniversitesi
Prof. Dr. Bilal Gümüş	Dicle Üniversitesi
Prof. Dr. Alkan Alkaya	Mersin Üniversitesi
Doç. Dr. Ömer Melih Gül	İstanbul Teknik Üniversitesi
Doç. Dr. Mustafa Berke Yelten	İstanbul Teknik Üniversitesi
Doç. Dr. Oğuzhan Ceylan	Marmara Üniversitesi
Doç. Dr. Mete Çubukçu	Ege Üniversitesi
Bora Güngören	Portakal Teknoloji
Fikret Küçükdeveci	TEPA
Hasan Ali Pazar	Siemens

İÇİNDEKİLER / CONTENTS

VNA İçin Belirsizlik Hesaplama Yöntemlerinin İncelenmesi
Investigation of Uncertainty Calculation Methods for VNA
Erkan Danacı
Araştırma Makalesi

7

Yüksek Hızlı AC Sürücülerde Çok Ölçütlü Karar Verme Yöntemleri ile Topoloji ve Anahtar Seçimi Uygulanması
Semiconductor Switch Selection in the High Speed Drives Using Multi-Criteria Decision Making Methods
Gülsüm Yıldırım
Araştırma Makalesi

21

Görüntü ve Sinyal İşleme İçin Adaptif Daire Yerleşimi Yoluyla Geometrik Maskeleye
Geometric Masking via Adaptive Circle Placement for Image and Signal Processing
Rıdvan Fırat Çınar
Araştırma Makalesi

31

Lityum-iyon Pil Bozulma Testlerinin Hızlandırılması İçin Yeni Bir Yaklaşım
New Approach to Acceleration of Li-ion Battery Degradation Testing
Cansu İçöz, Mehmet Aksoy, Çiğdem Ezgi Arer
Araştırma Makalesi

39

SCADA Sistemlerinde Dijital Dönüşüm: Endüstri 4.0 Çağında WinCC Unified
Digital Transformation In SCADA Systems: WinCC Unified In The Era of Industry 4.0
Ömer Önümlü, Birol Arifoğlu
Araştırma Makalesi

51

Bireylerin Çevresel Tutumlarını Tahminde Makine Öğrenmesi: ANOVA ve Ki-Kare Temelli Özellik Seçimi ile
Algoritma Performanslarının Karşılaştırılması
Predicting Individuals' Environmental Attitudes Using Machine Learning: Comparison of Algorithm Performances with ANOVA and Chi-Square-Based Feature
Rukiye Uzun Arslan, İrem Şenyer Yapıcı, Fuat Alkan
Araştırma Makalesi

61

Telekomünikasyon Sektöründe Müşteri Kaybı Tahmini İçin Açıklanabilir Makine Öğrenmesi
Explainable Machine Learning for Customer Churn Prediction in Telecommunication Industry
M. Aslı Aydın
Araştırma Makalesi

71

Türkçe Görüntü Altyazılama: Mevcut Çalışmalar, Uygulamalar, Veri Setleri, Metrikler ve
Gelecekteki Olası Eğilimler Üzerine Bir İnceleme
Turkish Image Captioning: A Review of Current Studies, Applications, Datasets, Metrics and Potential
Future Trends
Abbas Memiş
Derleme Makalesi

81

VNA İçin Belirsizlik Hesaplama Yöntemlerinin İncelenmesi

Investigation of Uncertainty Calculation Methods for VNA

Erkan Danacı

ID 0000-0001-6358-8807

RF ve Mikrodalga Laboratuvarı
TÜBİTAK UME, Kocaeli Türkiye
erkan.danaci@tubitak.gov.tr

Özet

Yansıma ve iletim katsayısı ölçümlerinin Vektör Ağ Analizörleri (VNA) ölçümleri önemli olduğu kadar ölçümlerin hangi hata bantları içinde olduğunu belirten belirsizlik hesaplamaları da önemlidir. VNA ölçümlerinin belirsizlik hesaplamalarında Ripple ve Rigorous denen iki yöntem kullanılmaktadır. Her iki yöntemin birbirlerine göre avantaj ve dezavantajları mevcuttur. Bu çalışmada, Rigorous ve Ripple belirsizlik hesaplama yöntemlerinin nasıl yapıldığı açıklanırken, her bir yöntemin belirsizlik hesaplama bileşenleri de açıklanmıştır. Bunun yanında her iki yöntemdeki metrolojik izlenebilirlik zincirinin nasıl sağlandığına da bu çalışmada yer verilmiştir. Ayrıca iki hesaplama yöntemi ile yapılan iki kapılı pasif bir devre elamanın yansıma ve iletim katsayısı ölçümlerine ait belirsizlik hesaplamalarının karşılaştırılması da bu çalışmada verilmiştir. Bu çalışma, VNA belirsizlik hesaplaması yapacak başta kalibrasyon ve deney laboratuvarları olmak üzere tüm VNA kullanıcılarına rehber olması açısından hazırlanmıştır. Anahtar kelimeler: Vektör Ağ Analizörü, İzlenebilirlik, Ripple Yöntemi, Rigorous Yöntemi, Yansıma Katsayısı, İletim Katsayısı, Belirsizlik Hesaplama.

Abstract

Reflection and transmission coefficient measurements with Vector Network Analyzers (VNA) are important as well as uncertainty calculations that indicate which error bands the measurements are in. Two methods called Ripple and Rigorous are used in uncertainty calculations of VNA measurements. Both methods have advantages and disadvantages compared to each other. In this study, the rigorous and ripple uncertainty calculation methods are explained, and the uncertainty calculation components of each method are described. And, how the metrological traceability chain is provided in both methods is also included in this study. In addition, the comparison of uncertainty calculations of reflection and transmission coefficient measurements of a two-port passive circuit element performed with the two calculation methods is also given in this study. This study has been prepared to be a guide for all VNAs, especially calibration and testing laboratories that will perform VNA uncertainty calculations. Keywords: Vector Network Analyzer, Traceability, Ripple Method, Rigorous Method, Reflection Coefficient, Transmission Coefficient, Uncertainty Calculation.


1. Giriş

Yüksek frekanslı elektromanyetik sinyalleri ileten iletim hatlarında konum ve zamana göre değişiklik gösteren elektromanyetik sinyaller var olduğundan elektrik devre teorisinde ana ölçüm büyüklükleri olan elektromanyetik akım ve elektromanyetik gerilim ölçümleri yapılamamaktadır. Yüksek frekanslarda elektro manyetik akım ve gerilim ölçümü yerine elektro manyetik sinyalin gücü ölçülmektedir [1], [2], [3], [4]. Elektro manyetik sinyalin gücü ölçümlerinde ise, elektro manyetik sinyal kaynağından çıkan güç, elektro manyetik sinyalin yüke ulaşmasından sonra yansıyan güç, yükte harcanan güç ve yükte algılanan güç gibi ölçümler yapılmaktadır. Bu güç ölçümlerinde birçok frekansta ardışıl ve tekrarlı olmasını sağlamak için birçok ölçüm cihazı ve birçok yazılımlar geliştirilmiştir. Yüksek frekanslı sistemlerde kullanılan elektriksel devre elemanlarının karakterizasyonun için ise gönderilen gücü, yansıyan gücü ve iletilen gücün ölçümünü kolaylaştıran ağ analizörü (network analyzer- NA) adı verilen ölçüm cihazları geliştirilmiştir [5], [6], [7]. Sadece elektro manyetik sinyallerin güçlerini ölçen ağ analizörlerine skalar ağ analizörü adı verilirken, güç ile birlikte elektro manyetik sinyalin faz değişimlerini ölçebilen cihazlara Vektör Ağ Analizörü (Vector Network Analyzer – VNA) adı verilmektedir.

VNA'ların diğer yüksek frekanslı ölçüm cihaz ve sistemlerine göre kullanımı kolay ve ölçümlerin pratik yapılmasını sağlamasından dolayı, modern haberleşme teknolojilerinin geliştirilmesinde kullanılan elektrik devre bileşenlerini karakterize etmekte kullanılan önemli bir test cihazı olmuştur. VNA'lar, radyo frekansı ve mikrodalga sistemlerinde kullanılan cihazların ve devre elemanlarının karakterizasyonunu sağlamakla birlikte, ürün geliştirmenin çeşitli aşamalarında antenler, yükselteçler, kablolar, zayıflatıcılar, bağlayıcılar ve benzeri birçok aktif veya pasif cihazın performansını ölçmek için kullanılabilirler.

VNA'lar 10 yıl öncesine kadar pasif devre elemanlarının karakterizasyonu için kullanılabilir olduğu bilinmekteydi. Transistor analizlerinde kullanılan giriş çıkış sinyal ölçümleri, yükselteçlerin doğrusal olmayan davranışlarının ölçümleri gibi doğrusal olmayan parametreleri ölçebilen VNA'ların üretilmesi ile RF yükselteç, RF transistor ve entegre devreler gibi aktif devre elemanların ölçümleri VNA ile yapılmaya başlanmıştır. Üreticiler, doğrusal olmayan parametre ölçümünü yapabilen VNA'lara, non-linear VNA veya VNA-X adı vermişlerdir. [8], [9].

VNA'ların önemli bir özelliği de, hem bilinen bir uyarıcı işareti üretmek için kullanılan bir kaynağın çıkışını, hem de test edilen cihazın (Device Under Test - DUT) neden olduğu bu uyaranda meydana gelen değişiklikleri ölçmek için bir dizi algılayıcı içermesidir. Şekil 1'de, bir VNA'nın ölçüm sistematığı verilmiştir.



Şekil 1: İki kapılı dört süper heterodin alıcılı ve dört güç algılayıcılı VNA iç yapısı


VNA tarafından üretilen işaret DUT'a enjekte edilirken, hem giriş tarafından (Yönlü bağlayıcı 1 tarafı) yansıtılan sinyal, hem de DUT'un çıkış tarafına (Yönlü bağlayıcı 2 tarafı) geçen sinyal VNA tarafından ölçülür. VNA içindeki güç alıcıları Şekil 1'deki RX TEST1, RX TEST2, RX REF1, RX REF2 süper-heterodin alıcı bloklarının içindedir ve kendisine gelen sinyalleri ölçerken bilinen üretilmiş işaretle karşılaştırırlar. Ölçülen sonuçlar daha sonra dahili merkezî işlemci tarafından işlenir ve VNA ekranında görüntülenir [10], [11].

VNA iç donanımında, frekansı yükseltmek ve düşürmek için karıştırıcılar, güç algılayıcıları, işaret üreteçleri, güç dağıtıcıları, yönlü bağlayıcılar, ayarlı/sabit zayıflatıcılar, kuvvetlendiriciler ve anahtarlar da bulunmaktadır [10], [12]. Bu cihazların uyumlu bir şekilde bir araya getirilip bir merkezî işlemci birimi tarafından kontrol edilmesiyle, son derece karmaşık fakat kullanışlı bir ölçüm sistemi ortaya çıkmaktadır. VNA'nın ölçümlerini ve çalışma prensibini anlamak amacıyla güç algılayıcı bazında basitleştirilmiş VNA blok diyagramı Şekil 2'de gösterilmiştir.


VNA'lar, ölçülmek istenen cihaz veya numunenin karakterizasyonu yaparken, frekans domeninde saçılma parametreleri adı verilen S parametrelerini ölçmektedirler. İki kapılı bir devrenin dört (4) adet S parametresi vardır. Şekil 3'te iki kapılı bir devre elemanının S parametreleri gösterilmiştir.

Şekil 3'te gösterilen S-parametreleri, Şekil 2'de verilen algılayıcılarda ölçülen güçlerle aşağıdaki gibi tanımlanır.

$S_{11} = A/R1$	DUT giriş kapısı (Port1) yansıma katsayısı
$S_{21} = B/R1$	DUT'nin ileriye doğru (Port1'den Port2'ye) iletim katsayısı
$S_{12} = A/R2$	DUT'nin geriye doğru (Port2'den Port1'e) iletim katsayısı
$S_{22} = B/R2$	DUT'nin çıkış (Port2) yansıma katsayısı



Şekil 2: Dört güç algılayıcılı VNA'nın blok diyagramı



Şekil 3: İki kapılı bir devrenin S parametreleri

Temelde iki kapılı bir devre için yapılan S parametre ölçümlerinden elde edilen dört ölçümü, yansıma katsayısı ölçümleri (S_{11} ve S_{22}) ve iletim katsayısı (S_{12} ve S_{21}) olmak üzere iki gruba ayırabiliriz. S-Parametre ölçümlerinde sadece RF güç değerinin kendisi değil, uygulanan ve ölçülen güç değerlerinin faz bilgileri de dikkate alınır. Böylelikle ölçülen S-parametreleri, sadece genlik değil faz bilgisi de içeren vektörel büyüklüklerdir.

VNA'nın iç yapısının karmaşıklığı, ölçümlerde birçok hata ile karşılaşılmasına neden olmaktadır. Her gün çalıştırılan VNA'nın çalışma süresi ve uygulanan güç seviyelerindeki farklılıklara göre, içinde var olan mikrodalga devre elemanlarının davranışları farklılık göstermektedir. Her ne kadar üreticiler bu davranış farklılıklarının en aza indirgenmesi için birçok önlem almış olsalar da (güç algılayıcı sayısı artırılması, performansı artırılmış yeni VNA'ların üretilmesi, vb) ölçüm hatalarının önüne geçememektedirler [8], [9]. VNA ile doğru ve güvenilir bir ölçüm yapabilmek için ölçüm öncesinde bu hataların iyi belirlenmesi gerekmektedir [13], [14].

VNA'lar ile ölçümler öncesinde hata terimlerinin belirlenmesi için SOLT, SOL, QSOLT, TRL, LRL gibi birçok kalibrasyon yöntemi geliştirilmiştir. Hata terimlerini belirlemek amacıyla geliştirilen yöntemlere göre de üreticiler kalibrasyon kitleri de geliştirmişlerdir. Günümüzde yaygın olarak kullanılan hata terimleri belirleyen kalibrasyon yöntemlerini SOLT (Short, Open, Load, Thru) ve TRL (Thru, Reflect, Line) olarak gösterebiliriz. [14], [15], [16]. Bu çalışmada iki kapılı bir devre elemanının S parametrelerinin ölçümleri öncesinde, SOLT hata terimleri belirleme kalibrasyon yöntemine göre ölçümler ve hata terimi hesaplamaları ele alınmıştır.

Temelde yansıma ve iletim katsayısı olarak sınıflandırılan iki farklı ölçüm gerçekleştiren VNA'ların belirsizlik hesaplamaları

için de değişik yöntemler geliştirilmiştir. Bunlar Ripple ve Rigorous yöntemi olarak isimlendirilmiştir [17]. Literatürde bu iki hesaplama yöntemleri için birçok kılavuz doküman üretilmiş olmasına rağmen, bu iki yöntemin model fonksiyonlarının aynı anda kullanıldığı bir Türkçe yayına rastlanılmamıştır.

Bu çalışmada VNA ile yapılan yansıma ve iletim katsayılarının belirsizlik hesaplamaları için önerilen Ripple ve Rigorous yöntemleri ve hesaplamalarda kullanılan belirsizlik bileşenleri hakkında bilgi verilirken, yöntemlerin karşılaştırmaları da yapılmıştır. Belirsizlik hesaplama yöntemlerinde farklı referans ölçüm cihazları kullanılarak izlenebilirlik zincirleri oluşturduğundan, bu çalışmada her iki belirsizlik hesaplama yönteminin izlenebilirlik zincirleri de açıklanmıştır. Ayrıca iki hesaplama yöntemi ile yapılan iki kapılı pasif bir devre elemanın yansıma ve iletim katsayısı ölçümlerine ait belirsizlik hesaplamalarının karşılaştırılması da bu çalışmada verilmiştir. Bu çalışma, VNA belirsizlik hesaplaması yapacak başta kalibrasyon ve deney laboratuvarları olmak üzere tüm VNA kullanıcılarına Türkçe rehber olması açısından hazırlanmıştır.

2. VNA Ölçümlerinin Belirsizlik Hesaplama Yöntemleri

Ölçüm belirsizliği, yapılan ölçümlerin belirlenen bir duyarlılık aralığında ne kadar güvenilir olduğunu gösteren hesaplama ile elde edilen pozitif bir sayı değeridir. VNA ile yapılan vektörel S-parametre ölçümlerinin belirsizlik hesaplamaları için literatürde tanımlanmış Ripple ve Rigorous adında iki yöntem mevcuttur. 2018 yılına kadar Ripple yöntemi S-parametre ölçümleri için tek kabul edilmiş belirsizlik hesaplama yöntemi idi. Ripple yönteminde, VNA hata terimleri belirlemede kullanılan kalibrasyon kitlerinin güncel verilerinin VNA içine yüklenmemesi gibi VNA’da S-parametre ölçümlerini etkileyen tüm parametrelerin belirsizlik hesaplamalarına katılmaması gibi bazı eksiklikler vardı. Ripple yöntemindeki bu eksiklikleri ve hesaplama problemlerini gidermek amacıyla Rigorous yöntemi geliştirilmiştir. 2018 yılında, S-parametre ölçüm belirsizlik hesaplamaları için kullanılan her iki hesaplama yöntemini içeren rehber doküman İsviçre Ulusal Metroloji Enstitüsü (METAS) tarafından güncellenerek “Guidelines on the Evaluation of Vector Network Analyzers” (EURAMET Calibration Guide No 12 (CG-12), Ver. 3.0) adıyla yayınlanmıştır. Bu rehber doküman, ulusal metroloji enstitülerinin, kalibrasyon laboratuvarının akreditasyon denetimlerinde ve laboratuvarların öz beyanlarında kabul edilen rehber doküman olmuştur [17]. EURAMET CG-12 numaralı kalibrasyon rehberi, önce Avrupa Bölgesel Metroloji Organizasyonu (EURAMET) üyelerince kabul görmüş, daha sonra Uluslararası Ölçüler ve Ağırlıklar Bürosu (BIPM) Elektrik ve Manyetizma Danışmanlar Komitesi (CC-EM) RF Alt Komitesi (GT-RF) toplantılarında rehber doküman olarak kabul edilerek tüm bölgesel metroloji organizasyonlarında kullanılan rehber doküman hüviyeti kazanmıştır.

Her iki belirsizlik hesaplama yönteminin belirlenen bazı parametrelere göre karşılaştırılması Tablo 1’de verilmiştir. VNA ile iki kapılı bir devre elemanı için gerçekleştirilen her bir frekanstaki S-parametre ölçümlerinden yansıma ve iletim katsayıları karmaşık sayı olarak elde edilmektedir. S-parametrelerinin belirsizlik hesaplamalarında, karmaşık sayı olarak ölçülen yansıma ve iletim katsayısı büyüklüklerinin hem gerçek hem de sanal bileşenlerinin belirsizliklerinin ayrı ayrı

hesaplanması gerekmektedir. EURAMET CG-12 numaralı kalibrasyon rehberine göre, gerçek ve sanal bileşenler için hesaplanan belirsizliklerin en büyüğü her iki bileşene uygulanacağı belirtilmiştir. Bu çalışmada, Ripple ve Rigorous belirsizlik hesaplama yöntemleri, yansıma ve iletim katsayılarının gerçek ve sanal bileşenlerinden elde edilen genlik ve faz değeri için ayrı ayrı ele alınarak açıklanmıştır.

Tablo 1: VNA belirsizlik hesaplama yöntemlerinin karşılaştırılması

Karşılaştırma Parametresi	Ripple Yöntemi	Rigorous Yöntemi
İzlenebilirlik Standartları	Birincil seviye ölçüm sistemleri ile izlenebilirliği sağlanmış her konnektör tipine uygun verifikasyon kitleri	Performans testleri yapılarak izlenebilirliği sağlanmış VNA ve birincil seviye sistemler ile izlenebilirliği sağlanmış konnektör tipine uygun hata terimi belirleme amaçlı kalibrasyon kitleri
Belirsizlik Hesaplama Parametreleri	VNA dalgalanma (Ripple) ölçümlerinden elde edilen parametreler	VNA performans test sonuçlarından ve kalibrasyon kiti sertifikası değerlerinden gelen parametreler
Hesaplama Aracı	Operatöre uygun olarak geliştirilmiş bir yazılımlar veya bir MS Excel makroları	VNA Tools benzeri yazılımlar

2.1. Ripple Yöntemi ile VNA Ölçümlerinin Belirsizlik Hesaplamaları

Ripple yöntemi 1985 yılından beri kabul görmüş, VNA verifikasyonlarına dayalı olarak kullanılmakta olan bir yöntem iken, belirlenen model fonksiyonlarının yüksek frekanslarda iyi sonuçlar vermediği bilinmektedir. Bu yöntemde, verifikasyon kiti adı verilen ölçüm referans standartları, VNA ile birlikte kullanılmaktadır. Verifikasyon kitlerinin içinde birincil seviye ölçüm sistemleri ile karakterize edilmiş değişik elektrik uzunluklara sahip Hesaplanabilir Empedans Standartları (HES ya da Airline) ve sabit zayıflatma değerlerine sahip zayıflatıcı setleri vardır.


Değişik uzunluklardaki Airline’lar, VNA ile empedans ve yansıma katsayısı ölçümleri için ölçüm referansı olarak kullanılırken, zayıflatıcı setleri ise iletim katsayısı ölçümleri için ölçüm referansı olarak kullanılırlar.

Ripple yönteminde ölçümlere başlamadan önce VNA’nın kullanılacağı konnektör tipine uygun bir kalibrasyon kiti ile hata terimlerinin belirlenmiş olması gerekir. Ardından yansıma ve iletim katsayısı için belirsizlik hesaplamalarında kullanılacak parametrelerin belirlenmesi için ölçümlere geçilir.

Ripple yönteminde Şekil 4’teki gibi ölçüm düzeneği ile yansıma katsayısı belirsizliklerini belirlemek için ölçümler yapılmaktadır.

VNA ile tek kapılı DUT'nin yansıma katsayısı ölçülmesi durumunda Ripple yöntemine göre yansıma katsayısı belirsizliği Denklem (1)'deki gibi hesaplanır [17].

$$u^2(S_{xxM}) = [\delta D^2 + (\delta T \cdot S_{xxM})^2 + (\delta L \cdot S_{xxM})^2 + (\delta M \cdot S_{xxM}^2)^2 + \delta ResN^2 + \delta Con^2 + \delta Cab^2 + \delta Amb^2] \quad (1)$$



Şekil 4: Yansıma katsayısı belirsizlikleri için Ripple Yöntemi için ölçüm düzeneği


Denklem (1)'deki S_{xxM} DUT'nin ölçülen yansıma katsayısını ifade eder ve XX notasyonu VNA'nın kullanılan birincil portu için 11 ve ikinci portu için 22 olarak alınır. Model fonksiyondaki; δD ölçülen etkin yönlendiriciliğini, δT tahmini frekans izlemesini, δL VNA'nın doğrusal olmamasından kaynaklı etkiler toplamını, δM ölçülen etkin test port uyumsuzluğunu, $\delta ResN$ sistem çözünürlük ve gürültü etkilerini, δCon konnektör tekrarlanabilirliği nedeniyle oluşan etkileri, δCab kablo hareketleri nedeniyle oluşan etkileri ve δAmb çevre şartları nedeniyle oluşan etkileri ifade etmektedir. Ölçüm yapılan her frekans adımı için yansıma katsayısının hem gerçek hem de sanal bileşenlerine ait belirsizlikler denklem (1) kullanılarak hesaplanmalıdır. Her frekanstaki gerçek ve sanal belirsizlik değerlerinden en büyüğü, o frekansta gerçek ve sanal bileşenleri her ikisi için de belirsizlik değeri olarak sertifikalandırılır.

Ripple yönteminde VNA'nın hata terimleri öğrenildikten sonra belirsizlik hesabında kullanılacak parametrelerin belirlenmesi için işlemlere geçilir. Etkin yönlendiricilik (δD) parametresini belirlemek için Şekil 4'deki düzeneğe 50 ohm Yük airline arkasına bağlanır ve frekans VNA ekranındaki dalgalanmaların büyüklüğü dikkate alınarak dalgalanma oranları frekans bölgelerine göre kaydedilir. Tahmini frekans izleme (δT) parametresi ölçülen yansıma katsayısının 1/1000'i olarak hesaba katılır. VNA'nın doğrusal olmamasından kaynaklı etki (δL) parametresi VNA'nın Şekil 5'te verilen ölçümlerinden elde edilir. Etkin test port uyumluluğu (δM) parametresini belirlemek için Şekil 4'teki düzeneğe Yük yerine Kısa Devre elemanı airline arkasına bağlanır ve VNA ekranındaki dalgalanmalar, frekans bölgelerine göre büyük değişim gösterdiği yerlerde ayrıştırılarak dalgalanma oranları not edilerek tespit edilir. VNA sistem çözünürlüğü ve gürültü etkileri ($\delta ResN$) parametresi, VNA'nın bir saatten az bir sıklıkta, bir günden fazla ardaşık yapılan gürültü ölçümleri ile tespit edilir. Konnektör tekrarlanabilirlik etkisi (δCon) parametresi, S parametresi ölçümlerinde konnektörlerin farklı oryantasyonlarda (0°, 120°, 240° gibi) bağlantısı yapılarak yapılan ölçümlerden tespit edilir. VNA kablolarının hareketi ve bükülmelerinden gelen etki (δCab) parametresi VNA

kablolarının değişik açılarda bükülmeleri sağlanarak yapılan S-Parametre ölçümlerinden elde edilir. Ortam şartlarının etkisi (δAmb) parametresi, ölçülen yansıma katsayısının 2/1000 değeri olarak alınır.

$\delta ResN$, δCon , δCab ve δAmb değerlerinin hesaplanamadığı durumlarda, VNA'nın ve kalibrasyon kitinin genel değerlendirmesi yapılarak bunların hepsi yerine 0,0016 gibi sabit bir değer kabul edilebilir.

Şekil 5'teki gibi ölçüm düzeneği ile iletim katsayısı belirsizlikleri için ölçümler yapılmaktadır.



Şekil 5: İletim katsayısı belirsizlikleri için Ripple Yöntemi için ölçüm düzeneği

VNA ile iki kapılı DUT'nin iletim katsayısı ölçülmesi durumunda Ripple yöntemine göre ileriye doğru iletim katsayısı belirsizliği denklem (2) 'deki gibi hesaplanır [17]. Geriye doğru iletim katsayısının belirsizlik hesaplaması için belirsizlik bileşen ve S-parametre notasyonları değiştirilerek hesaplama tekrarlanmalıdır.

$$u^2(S_{21M}) = [\delta I^2 + (\delta L \cdot S_{21M})^2 + (\delta M_1 \cdot S_{11M} \cdot S_{21M})^2 + (\delta M_2 \cdot S_{22M} \cdot S_{21M})^2 + (\delta T \cdot S_{21M})^2 + (\delta Cab1 \cdot S_{21M})^2 + (\delta Cab2 \cdot S_{22M} \cdot S_{21M})^2 + \delta ResN^2 + \delta Con^2 + \delta Amb^2] \quad (2)$$

Denklem (2)'teki S_{xxM} DUT'nin ölçülen birincil ve ikinci portlarının yansıma katsayılarını, S_{xyM} ise DUT'nin ölçülen ileri ve geri yöndeki iletim katsayılarını ifade eder. Model fonksiyondaki; δI izolasyon nedeniyle oluşan etkileri, δL sistemin doğrusal olmaması nedeniyle oluşan etkileri, δM_1 ve δM_2 portların empedans uyumsuzluğunda gelen etkilerini, δT tahmini frekans izlemesini, δCab_1 birinci porttaki kablo hareketliliğinden gelen etkiyi, δCab_2 ikinci porttaki kablo hareketliliğinden gelen etkiyi, $\delta ResN$ sistem çözünürlüğü ve sistem gürültü seviyesi etkilerini, δCon konnektör tekrarlama bilirliliği nedeniyle oluşan etkileri ve δAmb çevre şartları nedeniyle oluşan etkileri ifade etmektedir. Yansıma katsayısının gerçek ve sanal bileşen belirsizliklerinde olduğu gibi, iletim katsayısı belirsizliğinde de, hem gerçek hem de sanal bileşenin belirsizliği hesaplanır ve en büyük belirsizlik hem gerçek hem de sanal bileşene verilerek sertifikalandırılır.

Denklem (2)'deki VNA'nın doğrusal olmamasından kaynaklanan etkileri (δI) belirlemek için Şekil 5'teki düzenekte değişik zayıflatma değerlerine sahip zayıflatıcılar VNA'ya bağlanıp ölçümler alındıktan sonra, ölçümlerin sertifika değeri de dikkate alınarak nominal zayıflatma değerinden kaçıklığına bakılarak belirlenir.

Denklem (2)'deki izolasyon değeri ise, VNA'ya zayıflatıcılar bağlı iken yapılan ölçümlerden Denklem (3) kullanılarak hesaplanır.

$$dA = \pm 20 \cdot \log_{10} \left[1 + 10^{\frac{(I-A)}{20}} \right] \quad (3)$$

Denklem (3)'teki A zayıflatma değerini, I izolasyon değerini ve dA zayıflatıcının belirsizlik değerini ifade etmektedir. Rasgele oluşan durumlar için VNA'nın performansına bağlı olarak ölçülen iletim katsayısının $1/100$ 'ü gibi sabit bir değer hesaba katılabilir.

İletim katsayısı ölçümünde VNA'nın iki kapısı da DUT'a bağlanacağından iki adet empedans uyumsuzluğu ($\delta M_{1/2}$) söz konusu olacaktır. Her kapı için empedans uyumsuzluğu da yine iki kapılı ölçümlerden Denklem (4)'teki gibi hesaplanır.


$$M_i = 20 \cdot \log_{10} \left(\frac{I + |M \cdot S_{11}| + |T_y \cdot S_{22}| + |M \cdot T_y \cdot S_{11} \cdot S_{22}|}{I - |M| |T_y|} + \frac{|M \cdot T_y \cdot S_{12} \cdot S_{21}|}{I - |M| |T_y|} \right) \quad (4)$$

Denklem (4)'teki M DUT'ın ilgili kapısının bağlandığı VNA etkin test port uyumluluğunu, T_y VNA'nın diğer kapısının etkin yük uyumluluğunu ve S_{xx} ve S_{xy} ölçülen S parametrelerini ifade eder.

Ripple yöntemindeki hesaplamalarda frekanslara göre değişimler söz konusu olduğundan her frekans bölgesinde ölçümlerden elde edilen parametrelerin değiştiği dikkate alınarak belirsizliği hesaplamak gerekmektedir. Bundan dolayı MS Excel uygulamasında yapılmış bir makro veya kullanıcıya özel bir yazılım ile yapılması önerilmektedir. VNA ile yapılan yansıma ve iletim katsayıları ölçümleri sonucunda vektörel büyüklükler okunduğundan, her frekanstaki hem yansıma hem de iletim katsayısı ölçümlerinin gerçek ve sanal bileşenleri için belirsizlik hesaplamalarının ayrı ayrı yapılması gereklidir. Hesap edilen iki belirsizlikten en büyük olanı hem gerçek hem de sanal bileşen belirsizliği olarak kalibrasyon sertifikalarında verilmelidir.

Ripple yöntemi ile belirsizlik hesaplaması yapan laboratuvarlarda VNA'ların izlenebilirliği en hızlı ve kolay şekilde Verifikasyon Kitleri ile sağlanmaktadır. Bu hesaplama yönteminde VNA'nın izlenebilirliği yansıma ve iletim katsayısı için iki ayrı koldan sağlanır. Yansıma katsayısı izlenebilirliğinde, verifikasyon kitlerinin içindeki yer alan 50 ohm ve 25 ohm empedanslardaki airline'ların birim uzunluktaki iç iletken dış çap, dış iletken iç çap ölçümleri ve yapıldığı malzemenin Dielektrik (permittivity) ve Manyetik Geçirgenlik (permeability) parametreleri kullanılarak birim uzunluklardaki empedans ve S-parametre değerlerinin hesaplaması yapılır. Hesaplama yöntemi ile elde edilen S-parametreleri VNA ile ölçülerek VNA'nın verifikasyonu yapılarak yansıma katsayısı

izlenebilirliği sağlanmış olur. İletim katsayısı izlenebilirliği ise, verifikasyon kitinin içinde yer alan 3 dB ile 20 dB zayıflatma değerlerine sahip zayıflatıcıların, birincil seviye zayıflatma ölçüm sistemlerinde yapılan kalibrasyonları ile sağlanır. Ripple yönteminin dayalı olduğu bu izlenebilirlik zincirlerinin doğru olarak kabul edilebilmesi için, VNA'yı izlenebilirlik zincirine dahil edecek kalibrasyon laboratuvarının elinde VNA'nın her bir konnektör tipi için (N, 3.5 mm, 2.92 mm, 2.4 mm gibi) uygun verifikasyon kitinin olması gereklidir. Ripple yöntemine göre izlenebilirlik zinciri Şekil 6'da görselleştirilmiştir.



Şekil 6: Ripple yöntemine göre VNA izlenebilirlik zinciri

2.2. Rigorous Yöntemi ile VNA Ölçümlerinin Belirsizlik Hesaplamaları

Rigorous yöntemi 2018 yılında tanımlanmıştır. Temel prensipte VNA'nın kendisinin performansının yapılması ve günlük hata terimleri belirlemede kullanılan kalibrasyon kitlerinin izlenebilirliğinin birincil seviye ölçüm sistemleri ile sağlanması prensibine dayalıdır.

VNA'ların performansının belirlenmesi işlemlerinde aşağıda sıralanan parametrelerin ölçülmesi ve raporlanması gereklidir. Bu raporlamalar VNA Tools programı kullanılarak kolayca yapılabilir [18].

- S Parametre Gürültü Seviyesi (Noise Floor) (logaritmik)
- S Parametre İz Gürültü Seviyesi (Trace Noise) genlik (logaritmik) ve fazı (°)
- Test Alıcısı Gürültü Seviyesi (Test Receiver Noise Floor)
- Test Alıcısı İz Gürültüsü Seviyesi (Test Receiver Trace Noise) genlik (logaritmik) ve fazı (°)
- Referans Alıcısı Gürültü Seviyesi (Reference Receiver Noise Floor)
- Referans Alıcısı İz Gürültüsü Seviyesi (Reference Receiver Trace Noise) genlik (logaritmik) ve fazı (°)
- Doğrusallık (Linearity)
- Kayma (Drift)

S-parametre Gürültü Seviyesi (Noise Floor), S-parametre İz Gürültü Seviyesi (Trace Noise), Test Alıcısı Gürültü Seviyesi (Test Receiver Noise Floor), Test Alıcısı İz Gürültüsü Seviyesi (Test Receiver Trace Noise), Referans Alıcısı Gürültü Seviyesi (Reference Receiver Noise Floor) ve Referans Alıcısı İz Gürültüsü Seviyesi değerleri VNA Tools yazılımı kullanılarak ölçülebilmektedir. Gürültü değerlerinin ölçülebilmesi için VNA Tools yazılımının kalibrasyonu yapılan VNA ile iletişim kurmuş olması gereklidir. Bilgisayar ve VNA iletişimi GPIB adaptörler veya bilgisayar iletişim portlarından biri kullanılarak yapılabilir. VNA'nın doğrusalılık değeri ise Ripple yöntemindeki gibi; Şekil 4'teki düzeneğe değişik zayıflatma değerlerine sahip zayıflatıcılar VNA'ya bağlanıp ölçümler alındıktan sonra, ölçümlerin sertifika değeri de dikkate alınarak nominal zayıflatma değerinden kaçıklığına bakılarak belirlenir. Kayma değeri ise, VNA'nın hata terimleri öğretildikten sonra iki portunun birbirine bağlanarak, Sii ve Sij parametrelerinin 24 saatlik dilim içinde her 15 dk da yapılan ölçümlerin sonundaki değişim değerleri kaydedilerek elde edilir. Kayma değerinin belirlenmesi için otomatik ölçüm sisteminizin olması önerilmektedir.

Rigorous yönteminin hesaplamalarının yapılabilmesi için VNA performansından gelen parametrelerin VNA Tools yazılımına girilmesi gereklidir.

Rigorous yönteminde, izlenebilirliği sağlanmış kalibrasyon kitlerinden ise aşağıdaki sıralanmış parametreler yansıma ve iletim katsayısı ölçümlerine göre belirlenmiş olması ve VNA Tools yazılımına girilmiş olması gereklidir.

- Yansıma Katsayısı için kablo kararlılığından (Cable Stability) gelen belirsizlik bileşeni
- İletim Katsayısı için kablo kararlılığından (Cable Stability) gelen belirsizlik bileşeni
- Kalibrasyon Standartlarından (Open, Short, Load) gelen belirsizlik bileşeni
- Giriş ve Çıkış kapısı konnektör tekrarlanabilirliği belirsizlik bileşeni

VNA Tools yazılımına kalibrasyon kitlerinin sertifika değerlerinin girilmesi ile yukarıda bahsedilen Kalibrasyon kiti parametrelerinin VNA Tools yazılımı tarafından hesaplara dahil edilmesini sağlamaktadır. Operatörün özel bir hesaplama yapmasına ihtiyaç yoktur. Ancak VNA Tools yazılımının veri tabanı özel bir formatta dosya istediğinden, operatörün Kalibrasyon standart olarak Kalibrasyon kiti verilerini istenen formatta VNA Tools'a yüklemesi gereklidir.

VNA ile tek kapılı DUT'nin yansıma katsayısı ölçülmesi durumunda Rigorous yöntemine göre yansıma katsayısı belirsizliği Denklem (5)'teki gibi hesaplanır [17]. Belirsizlik hesaplamasında ölçüm yapılan VNA'nın portuna ait parametreler kullanılmalıdır.

$$u^2(S_{xxM}) = [(\delta STB_{Cab})^2 + (\delta TD_{Cal})^2 + (\delta REP_{Con})^2 + (\delta DVNA)^2 + (\delta LVNA)^2 + (\delta NVNA)^2] \quad (5)$$

Denklem (5)'teki, S_{xxM} DUT'nin ölçülen Yansıma Katsayısını ifade etmektedir. δSTB_{Cab} kablo kararlılığından (Cable Stability) gelen belirsizlik bileşenini, δSTD_{Cal} kalibrasyon Standartlarından (Open, Short, Load) gelen belirsizlik bileşenini, δREP_{Con} konnektör tekrarlanabilirliği belirsizlik

bileşenini, $\delta DVNA$ VNA kaymasından (Drift) gelen belirsizlik bileşenini, $\delta LVNA$ VNA doğrusalılığından (Linearity) gelen belirsizlik bileşenini ve $\delta NVNA$ VNA gürültüsünden (Noise) gelen belirsizlik bileşenlerini ifade etmektedir. Kablo konum kararlılığı, konnektör tekrarlanabilirliği, VNA doğrusalılığı gibi etkiler Ripple yönteminde açıklandığı gibi belirlenebilmektedir. VNA kayması ve gürültü değerlerinin belirlenmesi için VNA Tools yazılımı kullanılabilir.


VNA ile iki kapılı DUT'nin iletim katsayısı ölçülmesi durumunda Rigorous yöntemine göre iletim katsayısı belirsizliği Denklem (6)'daki gibi hesaplanır [17].

$$u^2(S_{xyM}) = [(\delta STB_{Cab_{refl}})^2 + (\delta STB_{Cab_{trans}})^2 + (\delta TD_{Cal})^2 + (\delta REP_{Con_{12}})^2 + (\delta DVNA_{P1P2})^2 + (\delta LVNA_{P1P2})^2 + (\delta NVNA)^2] \quad (6)$$

Denklem (6)'daki, S_{xyM} DUT'nin ölçülen İletim Katsayısını ifade eder. $\delta STB_{Cab_{refl}}$ yansıma katsayısı için kablo kararlılığından (Cable Stability) gelen belirsizlik bileşenini, $\delta STD_{Cal_{trans}}$ iletim katsayısı için kalibrasyon Standartlarından (Open, Short, Load) gelen belirsizlik bileşenini, $\delta REP_{Con_{12}}$ giriş çıkış kapısı konnektör tekrarlanabilirliği belirsizlik bileşenini, $\delta DVNA_{P1P2}$ VNA'nın her iki kapısındaki kaymasından (Drift) gelen belirsizlik bileşenini, $\delta LVNA_{P1P2}$ VNA'nın her iki kapısındaki doğrusalılığından (Linearity) gelen belirsizlik bileşenini ve $\delta NVNA$ VNA gürültüsünden (Noise) gelen belirsizlik bileşenlerini ifade etmektedir. İleri ve geri iletim katsayısı belirsizlik hesaplamalarında hesaplamada kullanılan parametrelerin notasyonları değiştirilerek hesaplamalar yapılmalıdır.

Rigorous yönteminde VNA performans testleri, kablo kararlılık testleri ve izlenebilirlik zincirinde kalibrasyonu yapılmış kalibrasyon kitlerinin sertifika verileri haricinde özel bir ölçüme ihtiyaç yoktur.

Rigorous yöntemi ile belirsizlik hesaplaması yapan laboratuvarlarda VNA'ların izlenebilirliği, VNA'nın performans testinden elde edilen parametreler ve VNA'nın günlük ölçümlerinde hata terimlerini öğretmek amacıyla kullanılan kalibrasyon kitlerinin güncel sertifika verileri üzerinden sağlanmaktadır. VNA performans testlerinde, VNA'nın gürültü ölçümleri, doğrusalılık ölçümleri, frekans kararlılıkları, test portlarının güç değişimleri ve kullanılan kabloların kararlılıkları ve ölçüme etkilerinin yapılması gereklidir. Kalibrasyon kitlerinin ise, birincil seviye ölçüm sistemleri ile karakterize edilmiş TRL kalibrasyon kitlerinin olması veya TRL kalibrasyon kiti ile izlenebilirliği sağlanmış VNA sistemleri ile karakterize edilmiş ve son sertifika verilerinin olması gereklidir. Hem VNA performans test değerlerinin, hem de güncel kalibrasyon kiti değerlerinin VNA Tools yazılımına girilmesi sonunda VNA Tools yazılımı, ölçümlerden sonra standart ve genişletilmiş belirsizlik değerlerini hesaplamakta ve operatöre analiz yapması için fırsat tanımaktadır. Rigorous yöntemine göre izlenebilirlik zinciri Şekil 7'de görselleştirilmiştir.



Şekil 7: Rigorous yöntemine göre VNA izlenebilirlik zinciri

3. Ripple ve Rigorous Yöntemi Belirsizliklerinin Karşılaştırılması

Belirsizlik hesaplama yöntemlerinin karşılaştırması için Tablo 2’de listesi verilen ölçüm cihazları kullanılarak Agilent 8491B model 20 dB sabit zayıflatıcının 10 MHz - 9 GHz frekans aralığındaki ölçümleri kullanılmıştır.

Tablo 2: Deneysel ölçümler için kullanılan ölçüm cihazları listesi

Cihaz Adı	Model	Çalışma Aralığı
VNA	Keysight E5080A	9 kHz- 9 GHz
Kalibrasyon Kiti	Keysight 85054D	DC-18 GHz
Ölçülen Cihaz (Zayıflatıcı)	Agilent 8491B	20 dB, DC-18 GHz

Bu deneysel çalışmada değişik konnektör tipi ve değişik frekanslardaki ölçümlerde karşılaşılabilecek belirsizlik hesaplamalarına değil, sadece belirsizlik hesaplama yöntemlerinden gelen farklılıklar ele alındığında, en uygun frekanslarda kullanılan genel bir zayıflatıcı ele alınmıştır.

Deneysel çalışma için seçilen zayıflatıcı ile tüm s parametreler için (S11, S21, S12, S22) her frekansta en az 10’ar adet ölçüm yapılmıştır. Çalışmada 10’ar ölçümün ortalaması ölçülen değer olarak verilirken, her frekanstaki 10’ar ölçümün standart

sapması tekrarlı ölçümlerden gelen belirsizlik bileşeni olarak belirsizlik hesabına katılmıştır.

Kalibrasyon kiti olarak kullanılan 85054D ile VNA hata terimleri SOLT yöntemine göre belirlenmiştir.

20 dB zayıflatıcının yansıma ve iletim katsayıları ölçüm sonuçları ve hesaplanan belirsizlikler Tablo 3 ve Tablo 4’te verilmiştir. Deneysel çalışmadaki belirsizlik hesaplamaları Uluslararası ölçüler ve Ağırlıklar Bürosunun (BIPM) yayınladığı GUM dokümanına uygun olarak yapılmıştır [19], [20].

Ripple ve Rigorous yöntemlerindeki belirsizlik değerlerindeki farklılıklar hesaba katılan belirsizlik bileşenlerinin farklılıklardan kaynaklanmaktadır. Tablo 3’teki |S11| ve |S21| değerleri, sırasıyla giriş yansıma katsayıları ve ileri doğru iletim katsayılarının genlikleri, U|SXY| değerleri hesaplama yöntemlerinin %95 (k=2) güvenilirlik seviyesinde belirsizlik değerleridir. 20 dB zayıflatıcının yansıma ve iletim katsayılarının faz ölçüm sonuçları ve hesaplanan belirsizlikler ise Tablo 4’te verilmiştir. Tablo 4’teki faz belirsizlik değerleri %95 güvenilirlik seviyesinde verilmiştir.

Yansıma ve iletim katsayısı fazlarının belirsizlikleri Denklem (7)’de verilen model fonksiyon dikkate alınarak hesaplanmaktadır [21]. Fazı elde etmek için kullanılan katsayısının gerçek ve sanal bileşenin belirsizlikleri faz belirsizliğini belirleyen bileşenlerdir ve bunların aynı olduğu düşünüldüğünde, faz belirsizliği hesaplanan fazın +/- salınım yaptığı faz değeri hakkında bilgi vermektedir.

$$Faz(^{\circ}) = \text{Arctg} \left(\frac{\text{Sanal}}{\text{Gerçek}} \right) \left(\frac{180}{3,14} \right) \quad (7)$$

Deneysel çalışmada zayıflatıcının çıkış yansıma katsayısı (S22) ve geriye doğru iletim katsayısı (S12) ölçülmüş olmakla birlikte bu çalışmada veri karmaşıklığı olmaması için verilmemiştir. İleri ve geri sinyal ölçümlerinde simetrik davranışı benzer olan DUT ve VNA’larda S11, S22 ve S12, S21 değerleri arasında büyük bir farklılık görülmesi beklenmemektedir.

Deneysel çalışmada kullanılan zayıflatıcının 1 GHz frekanstaki her iki belirsizlik hesaplama yöntemi kullanılarak yapılan yansıma ve iletim katsayılarının genlik belirsizlik bileşenleri ve değerleri sırasıyla Tablo 5-8’de verilmiştir. Tablo 9-12’de ise faz belirsizlik bileşenleri verilmiştir. Tablolarda verilen belirsizliklerde, Rigorous yöntemine göre olanların Ripple yöntemine göre kısmen büyük olduğu görülmektedir.

Belirsizlik hesaplamaları içeren tablolardaki veriler, hesaplama araçlarındaki yuvarlamalardan dolayı farklılıklar içermektedir.

Tablo 3. Ripple ve Rigorous yöntemlerine göre giriş yansıması genlik ölçüm sonuçları ve hesaplanan belirsizlik değerleri

Frekans (GHz)	S ₁₁	U S ₁₁ (Ripple)	U S ₁₁ (Rigorous)	S ₂₁	U S ₂₁ (Ripple)	U S ₂₁ (Rigorous)
0,01	0,0050	0,0040	0,0104	0,10431	0,00042	0,00293
0,02	0,0050	0,0040	0,0104	0,10427	0,00042	0,00293
0,03	0,0050	0,0040	0,0104	0,10428	0,00042	0,00294
0,04	0,0050	0,0040	0,0103	0,10426	0,00005	0,00295
0,05	0,0050	0,0040	0,0104	0,10428	0,00042	0,00296
0,1	0,0060	0,0040	0,0104	0,10422	0,00010	0,00297
0,2	0,0060	0,0040	0,0104	0,10415	0,00017	0,00296
0,3	0,0060	0,0040	0,0104	0,10405	0,00041	0,00295
0,4	0,0060	0,0040	0,0105	0,10403	0,00041	0,00293
0,5	0,0060	0,0040	0,0104	0,10397	0,00031	0,00294
0,6	0,0060	0,0040	0,0105	0,10389	0,00034	0,00291
0,7	0,0060	0,0040	0,0106	0,10388	0,00031	0,00292
0,8	0,0050	0,0040	0,0105	0,10379	0,00027	0,00290
0,9	0,0050	0,0040	0,0106	0,10376	0,00022	0,00291
1	0,0050	0,0040	0,0106	0,10374	0,00041	0,00291
2	0,0080	0,0040	0,0104	0,10329	0,00027	0,00288
3	0,0140	0,0040	0,0162	0,10275	0,00033	0,00289
4	0,0200	0,0040	0,0162	0,10229	0,00038	0,00286
5	0,0230	0,0040	0,0160	0,10166	0,00018	0,00308
6	0,0250	0,0040	0,0163	0,10120	0,00041	0,00286
7	0,0290	0,0040	0,0160	0,10044	0,00041	0,00290
8	0,0320	0,0040	0,0163	0,09908	0,00026	0,00283
9	0,0290	0,0040	0,0202	0,09668	0,00034	0,00287

Tablo 4: Ripple ve Rigorous yöntemlerine göre giriş yansıma katsayısı fazı ölçüm sonuçları ve hesaplanan belirsizlik değerleri

Frekans (GHz)	Faz(S ₁₁) (°)	U(Faz(S ₁₁)) (Ripple) (°)	U(Faz(S ₁₁)) (Rigorous) (°)	Faz(S ₂₁) (°)	U(Faz(S ₂₁)) (Ripple) (°)	U(Faz(S ₂₁)) (Rigorous) (°)
0,01	0	42	110	-0,768	0,231	1,043
0,02	-1	42	110	-1,540	0,231	1,043
0,03	-2	42	109	-2,300	0,231	1,056
0,04	-3	42	109	-3,053	0,027	1,070
0,05	-4	42	108	-3,824	0,230	1,078
0,1	-8	41	105	-7,607	0,056	1,088
0,2	-16	39	101	-15,132	0,094	1,102
0,3	-24	39	103	-22,655	0,226	1,111
0,4	-34	40	104	-30,188	0,226	1,115
0,5	-43	40	104	-37,679	0,169	1,136
0,6	-52	41	107	-45,214	0,187	1,133
0,7	-63	41	109	-52,720	0,169	1,157
0,8	-74	42	111	-60,217	0,148	1,163
0,9	-85	43	114	-67,753	0,122	1,184
1	-97	43	114	-75,231	0,227	1,209
2	145	29	75	29,711	0,148	1,362
3	62	16	65	-45,352	0,187	1,549
4	-13	11	46	59,592	0,213	1,709
5	-88	10	41	-15,556	0,100	2,003
6	-170	9	37	88,977	0,234	2,067
7	112	8	32	13,345	0,234	2,268
8	40	7	29	-62,459	0,149	2,418
9	-28	8	40	42,864	0,202	2,633

Tablo 5: Ripple yöntemine göre 20 dB zayıflatıcının 1 GHz'deki giriş yansıma katsayısı genliği birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz
Etkin yönlendiriciliği	Normal	$2,00.10^{-3}$
Tahmini frekans izleme	Dikdörtgen	$-3,82.10^{-7}$
Tahmini doğrusal olmamaktan kaynaklı etkiler toplamını	Normal	$4,13.10^{-6}$
Ölçülen etkin test port uyumsuzluğunu	U	$3,29.10^{-6}$
Sistem çözünürlük ve gürültü etkileri	Dikdörtgen	$1,99.10^{-5}$
Konnektör tekrarlanabilirliği	Normal	$4,25.10^{-6}$
Kablo hareketleri nedeniyle oluşan etkileri	Normal	$-2,65.10^{-6}$
Çevre şartları	Dikdörtgen	$-7,65.10^{-7}$
Birleşik Belirsizlik (k=1)		0,0020
Genişletilmiş Belirsizlik (k=2)		0,0040

Tablo 6: Rigorous yöntemine göre 20 dB zayıflatıcının 1 GHz'deki giriş yansıma katsayısı genliği birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz
Kablo kararlılığı	Dikdörtgen	0,001421
Kalibrasyon standartları	Normal	0,005047
Konnektör tekrarlanabilirliği	Dikdörtgen	0,000448
VNA kayması	Dikdörtgen	0,000365
VNA doğrusallığı	Dikdörtgen	0,000544
VNA gürültüsü	Dikdörtgen	0,000026
Birleşik Belirsizlik (k=1)		0,005303
Genişletilmiş Belirsizlik (k=2)		0,010606

Tablo 7: Ripple yöntemine göre 20 dB zayıflatıcının 1 GHz'deki ileri doğru iletim katsayısı genliği birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz
Konnektör tekrarlanabilirliği	Normal	$3,59.10^{-7}$
Sistem çözünürlük etkileri	Dikdörtgen	$1,02.10^{-6}$
Tahmini doğrusal olmamaktan kaynaklı etkiler toplamını	Normal	$1,96.10^{-4}$
İzolasyon	Normal	$-3,46.10^{-6}$
Sistem gürültüsü	Normal	$-4,62.10^{-6}$
Test port uyumsuzluğunu	U	$-1,86.10^{-6}$
Kablo hareketleri nedeniyle oluşan etkileri	Normal	$-5,77.10^{-5}$
Çevre şartları	Dikdörtgen	$-1,39.10^{-5}$
Birleşik Belirsizlik (k=1)		0,000205
Genişletilmiş Belirsizlik (k=2)		0,00041

Tablo 8: Rigorous yöntemine göre 20 dB zayıflatıcının 1 GHz'deki ileri doğru iletim katsayısı genliği birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz
Kablo kararlılığı	Dikdörtgen	0,001434
Kalibrasyon standartları	Normal	0,000045
Konnektör tekrarlanabilirliği	Dikdörtgen	0,000004
VNA kayması	Dikdörtgen	0,000238
VNA doğrusallığı	Dikdörtgen	0,000086
VNA gürültüsü	Dikdörtgen	0,000003
Birleşik Belirsizlik (k=1)		0,001457
Genişletilmiş Belirsizlik (k=2)		0,002914

Tablo 9: Ripple yöntemine göre 20 dB zayıflatıcının 1 GHz'deki giriş yansıma katsayısı fazı birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz (°)
Yansıma katsayısı gerçek bileşen belirsizliği	Normal	0,000205
Yansıma katsayısı sanal bileşen belirsizliği	Normal	0,000205
Yansıma katsayısı genlik belirsizliği	Normal	0,000205
Birleşik Belirsizlik (k=1)		21,4389
Genişletilmiş Belirsizlik (k=2)		42,8779

Tablo 10: Rigorous yöntemine göre 20 dB zayıflatıcının 1 GHz’deki giriş yansıma katsayısı fazı birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz (°)
Kablo kararlılığı	Dikdörtgen	15,2066
Kalibrasyon standartları	Normal	54,0782
Konnektör tekrarlına bilirliliği	Dikdörtgen	4,8033
VNA kayması	Dikdörtgen	3,9153
VNA doğrusallığı	Dikdörtgen	5,5602
VNA gürültüsü	Dikdörtgen	0,2143
Birleşik Belirsizlik (k=1)		56,7896
Genişletilmiş Belirsizlik (k=2)		113,5792

Tablo 11: Ripple yöntemlerine göre 20 dB zayıflatıcının 1 GHz’deki ileri doğru iletim katsayısı fazı birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz (°)
Yansıma katsayısı gerçek bileşen belirsizliği	Normal	0,0020
Yansıma katsayısı sanal bileşen belirsizliği	Normal	0,0020
Yansıma katsayısı genlik belirsizliği	Normal	0,0020
Birleşik Belirsizlik (k=1)		0,1133
Genişletilmiş Belirsizlik (k=2)		0,2266


Tablo 12: Rigorous yöntemine göre 20 dB zayıflatıcının 1 GHz’deki ileri doğru iletim katsayısı fazı birleşik belirsizlik değeri parametreleri ve değerleri

Belirsizlik Bileşeninin Adı	Dağılımı	Değeri @ 1GHz (°)
Kablo kararlılığı	Dikdörtgen	0,5875
Kalibrasyon standartları	Normal	0,0250
Konnektör tekrarlına bilirliliği	Dikdörtgen	0,0025
VNA kayması	Dikdörtgen	0,1315
VNA doğrusallığı	Dikdörtgen	0,0436
VNA gürültüsü	Dikdörtgen	0,0009
Birleşik Belirsizlik (k=1)		0,6041
Genişletilmiş Belirsizlik (k=2)		1,2082


Ripple ve Rigorous yöntemlerine göre hesaplanmış giriş kapısı yansıma katsayısı ve ileri doğru iletim katsayısı genlik belirsizlikleri ve ölçüm sonuçları Şekil 8 ve Şekil 9’da grafik olarak verilmiştir. Şekil 8 ve Şekil 9’da her frekansta ölçülen büyüklüklerin hesaplanan belirsizlik değerleri ilgili büyüklük üzerinde dikey çubuklarla gösterilmiştir. Rigorous yöntemi belirsizliği kırmızı renkle kesikli çizgilerle, Ripple yöntemi belirsizliği mavi renkle düz çizgilerle verilmiştir. Şekil 10 ve Şekil 11’de ise deneysel ölçümde kullanılan zayıflatıcının çıkış yansıma katsayısı ve geriye doğru iletim katsayısı değerleri ve belirsizlikleri verilmiştir. Tüm S parametre ölçüm değerleri birbiri ile uyumlu iken, Ripple belirsizliğinin Rigorous belirsizliğinden küçük olduğu görülmektedir. Rigorous yönteminde Ripple göre hesaba katılmayan parametrelerin eklenmesi ile belirsizlik büyümektedir.

Ripple ve Rigorous yöntemlerine göre hesaplanmış giriş kapısı yansıma katsayısı fazı ve ileri doğru iletim katsayısı fazı belirsizlikleri ile birlikte sırasıyla Şekil 12 ve Şekil 13’te grafik olarak verilmiştir. Şekil 14 ve Şekil 15’te ise sırasıyla deneysel ölçümde kullanılan zayıflatıcının çıkış yansıma katsayısı fazı ve geriye doğru iletim katsayısı fazı belirsizlikleri ile birlikte verilmiştir. Ripple ve Rigorous yöntemlerinde ölçülen faz değerleri arasında konnektör bağlamalarına bağlı olarak 180 ° farklılıklar olabilmektedir. Bunlar çoğunlukla ölçüm anında VNA’ların fazlarının kaymasından kaynaklanmaktadır. Faz belirsizlikleri çok küçük olduğundan şekillerde görülmeye bilmektedirler. VNA ile yapılan faz ölçümlerinde kaymaların en aza indirgenmesi için üreticiler VNA’ların harici olarak 10 MHz sinyal ile tetiklenmesini tavsiye etmektedirler. 10 MHz referans sinyalin kararlılığı ölçümlerdeki faz kararlılığını etkilemektedir. Bu deneysel çalışmada harici 10 MHz sinyal uygulaması yapılmamıştır. Harici referans sinyal ile tetiklemenin ölçümlere etkisi araştırmacılara gelecek çalışmalar için önerilebilir.


Üreticiler zayıflatıcıları üretirken, mümkün derecede iletim katsayısı fazlarında değişime neden olmayacak şekilde üretmektedirler. Zayıflatıcının sadece sinyali düşürmesi, sinyalin fazını etkilememesi istenen bir durumdur. Bu çalışmada da, ölçümü yapılan zayıflatıcının ileri ve geri iletim katsayısı faz değerlerinin çok küçük olduğu görülmüştür. Aynı faz küçüklüğü değerinin giriş ve çıkış kapılarındaki yansıma katsayısı fazları için söylemek mümkün değildir. Konnektör sıkarken belirli değerlerdeki torkların kullanımı yansıma katsayısı faz değerlerinin değişimine de sebep olmaktadır.




Şekil 8: Giriş yansımaya katsayısı genlikleri ve belirsizlikleri




Şekil 10: Çıkış yansımaya katsayısı genlikleri ve belirsizlikleri




Şekil 9: İleri doğru iletim katsayısı genlikleri ve belirsizlikleri




Şekil 11: Geri doğru iletim katsayısı genlikleri ve belirsizlikleri




Şekil 12: Giriş yansımaya katsayısı fazı ve belirsizlikleri



Şekil 14: Çıkış yansımaya katsayısı fazı ve belirsizlikleri



Şekil 13: İleri doğru iletim katsayısı fazı ve belirsizlikleri



Şekil 15: Geriye doğru iletim katsayısı fazı ve belirsizlikleri

4. Sonuç ve Değerlendirmeler

Bu çalışmada VNA ile yapılan vektörel yansıma ve iletim katsayısı ölçüm belirsizlikleri hesaplamalarında kullanılan Ripple ve Rigorous yöntemleri hakkında bilgi verilmiş ve her iki hesaplama yönteminin karşılaştırması yapılmıştır. Hesaplama yöntemlerinin VNA için sağladığı farklı izlenebilirlik zincirleri de bu çalışmada kısaca bahsedilmiştir. Belirsizlik hesaplama yöntemlerinin kavranmasını kolaylaştırmak için yapılan deneysel ölçüm verileri kullanılarak her iki yöntem için belirlenen frekans bandındaki tüm frekanslar için belirsizlikler hesaplanmıştır. Ayrıca, örnek bir frekansta, yansıma ve iletim katsayı genlikleri ile birlikte fazlarına ilişkin belirsizlik bileşenler her iki hesaplama yöntemi için bu çalışmada detaylandırılmıştır. Çalışmada sunulan hesaplama model fonksiyonları, kalibrasyon yapmak isteyen laboratuvarlar için örnek olması açısından verilmiştir. Model fonksiyonda belirtilen parametreler, VNA'ların teknolojik gelişimi ile gelecekte değişiklikler gösterebilecektir.

Bu çalışmadaki örnek uygulamalara bakılarak her iki yöntemin de kalibrasyon laboratuvarlarında kullanılması mümkün gibi görünse de, Ripple yöntemi için, belirsizlik bileşenleri doğru ve güncel kalibrasyon kiti verilerinin kullanılması durumunda belirsizlik hesaplamasının kolay olduğu söylenebilir. Bu çalışmada, Rigorous yöntemine göre hesaplanan belirsizliklerin Ripple yöntemine göre büyük olduğu da görülmüştür. Bu farkın en büyük nedeni Rigorous hesaplamalarında Ripple'a göre daha fazla parametrenin hesaba katılmasıdır.

VNA'lar her ne kadar fazları da ölçebilen cihazlar olsalar da, ölçümlerde referans osilatörlerinin faz değerlerinin kayması olasılığı mevcuttur. Bu faz kaymalarının önüne geçebilmek için üreticilerinin belirttiği şekilde VNA'ların harici olarak kararlı 10 MHz referans sinyal ile tetiklenmesi gereklidir. Bu harici sinyal ile tetiklenmeye rağmen, VNA'lar da faz kayması yine de olacaktır. VNA'nın harici sinyal ile tetiklenmesi ve tetiklenmemesi durumlarına göre ölçümlerdeki faz kaymalarının incelenmesi ileriki çalışmalar için önerilir. Zayıflatıcı gibi uygulanan sinyalin fazını en az kaydıracak mikrodalga devre elemanları ilerideki faz kayması çalışmaları için uygun olacaktır.

Bu çalışmada kullanılan VNA, harici sinyal ile tetiklenmemiştir. Zayıflatıcının giriş çıkış yansıma katsayısı faz belirsizliklerinin büyük çıkması nedenlerinden biri VNA'nın sinyal fazlarındaki salınımın fazla olmasından kaynaklıdır. Ayrıca zayıflatıcının ileri ve geri iletim katsayısı faz değerlerinin çok küçük olduğu da görülmüştür. İletim katsayısı faz açıları çok küçük olduğundan, hesaplanan faz belirsizlikleri de çok küçük çıkmıştır.

Bununla birlikte Ripple yöntemi kalibrasyon laboratuvarlarının her konnektör tipi için ayrı bir verifikasyon kiti kullanımını gerektirdiğinden pahalı bir yöntemdir. Ripple yönteminin yüksek frekanslardaki uygulanabilirliğinde zorluklar olduğu da bilinmektedir. Ayrıca Ripple yöntemi ile belirsizlik hesaplaması yapabilmek için VNA konusunda uzman bir personelin olması da gereklidir. Bu yöntem ile izlenebilirlik sağlamak isteyen laboratuvarların, verifikasyon kitlerini birincil seviye sistemler ile kalibre ettirmeleri ve VNA performans testlerinde güncel kalibrasyon kiti verilerini kullanmaları önerilmektedir.

Rigorous yöntemi Ripple yöntemine göre kıyaslandığında hesaplaması kolay ve VNA konusunda uzman olmayan operatör ile gerçekleştirilebilmektedir. Rigorous yönteminde kullanılması zorunlu olan VNA Tools ve benzeri yazılımlar operatör adına birçok hesaplamayı yapabilmektedir. Bu yöntem için VNA'nın performans testleri ve TRL kalibrasyon kitlerinin kalibrasyonları yine ulusal metroloji enstitülerindeki birincil seviye veya bunlardan izlenebilir ikinci seviye ölçüm sistemleri ile kalibrasyonu yapılabilmektedir. Yani Rigorous yöntemi kullanan laboratuvarların VNA ve kalibrasyon kitlerini bir üst laboratuvara göndererek izlenebilirlik almaları gereklidir.

5. Bilgilendirme

Bu çalışma, TÜBİTAK UME RF ve Mikrodalga Laboratuvarında gerçekleştirilmiştir.

6. Kaynaklar

- [1] Pozar D. M., *Microwave Engineering*, John Wiley & Sons 4th Edition, 2011. ISBN: 1118213637, 9781118213636.
- [2] Famton A., *Radio frequency & microwave power measurement*, IEE Electrical Measurement Series 7, Peter Peregrinus Ltd, London, UK, 1990.
- [3] Teppati V., Ferrero A., and Sayed M., *Modern RF and Microwave Measurement Techniques*, Cambridge University Press, 2013. ISBN 978-1-107-03641-3.
- [4] Dunsmore J. *Handbook of Microwave Component Measurements: with Advanced VNA Techniques*. John Wiley & Sons, Ltd, 2012. ISBN 978-1-119-97955-5.
- [5] Bailey A.E., *Microwave Measurements*; IEE Electrical Measurement Series; Peter Peregrinus Ltd. Volume 3, pp. 547–561, Stevenage, UK, 1989.
- [6] Keysight Application Note 1, *Fundamentals of RF and Microwave Power Measurements (Part 1)*; Keysight Application Note 5988-9213; Keysight Technology, USA, 2017.
- [7] Anne Y. R., Lyman E. B., “Radio Frequency Power Measurement”, *Proceeding of The IEEE*, Vol 55, No 6, pp 837-850, June 1967.
- [8] Keysight Application Note, *PNA Family Microwave Network Analyzers Configuration Guide (5992-1465EN)*, Keysight Technologies, USA, August 1, 2024.
- [9] Rohde & Schwarz Application Note, *ZVA Vector Network Analyzer*, Rohde & Schwarz (PD 5213.5680.12), Version 13.00, December 2017.
- [10] Keysight Technologies, *Network Analyzer Basics*, Electronic document. Back to Basics Series, available at www.keysight.com.
- [11] Keysight Application Note, *Keysight Technologies Specifying Calibration Standards and Kits for Keysight Vector Network Analyzers* - Application Note, Electronic document. Available at <http://literature.cdn.keysight.com/litweb/pdf/5989-4840EN.pdf>.
- [12] Ferrero A. and Pisani U., “Two-port network analyzer calibration using an unknown thru”. *IEEE Microwave & Guided Wave Letters*, 2(12):505 – 507, 1992.
- [13] Eğitim Notu, *TÜBİTAK UME Genel Mikrodalga Ölçüm ve Uygulamaları Eğitim Notları*, 2024.
- [14] Wuebbeler G., Elester C., Reichel T., and Judaschke R., Determination of the Complex Residual Error Parameters of a Calibrated One-Port Vector Network Analyzer”, *IEEE Trans. Instr. & Meas.*, 58(9):3238 – 3244, 2009.

- [15] Garelli M. and Ferrero A., “A Unified Theory for S-Parameter Uncertainty Evaluation”, *IEEE Trans. Microwave Theory & Tech.*, 60(12):3844 – 3855, 2012.
- [16] Hall B.D., *VNA error models: Comments on EURAMET/cg-12/v.01*, ANAMET Report 051, 2010.
- [17] Euramet Calibration Guide, *Guidelines on the Evaluation of Vector Network Analysers (VNA) EURAMET Calibration Guide No. 12 Version 3.0 (03/2018)*, 2018. ISBN: 978-3-942992-51-0, <https://www.euramet.org>.
- [18] Software Tool, *METAS VNA Tools*, available at www.metas.ch/vnatools.
- [19] BIPM Guide, *JCGM 100:2008; Evaluation of Measurement Data—Guide to the Expression of the Uncertainty in Measurement*, 1st ed., BIPM (Bureau International des Poids et Mesures): Paris, France, 2008.
- [20] Mubarak F. and Rietveld G., “Uncertainty Evaluation of Calibrated Vector Network Analyzers”, *IEEE Trans. Microwave Theory & Tech.*, PP(99):1 – 13, 2017.
- [21] Karay E., Çelik M. E., Danaci E., “RF Vektörel Ölçümlerde Belirsizlik Hesaplamaları”, 2023 International Marmara Sciences Congress (Imascon Spring), 2023.

Özgeçmişler



Dr. Erkan DANACI, Selçuk Üniversitesi Mühendislik Mimarlık Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nden 1991 yılında mezun olmuştur. Selçuk Üniversitesi Fen bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda sırasıyla 1996 yılında Yüksek Lisans ve 2002 yılında Doktora çalışmasını tamamlamıştır.

1992-2000 yılları arasında Selçuk Üniversitesi Mühendislik Mimarlık Fakültesi Elektrik-Elektronik Mühendisli Bölümü Devreler ve Sistemler Teorisi Anabilim Dalı'nda Araştırma Görevlisi olarak çalışmıştır. 2000 yılında TÜBİTAK UME RF ve Mikrodalga Laboratuvarı'nda Araştırmacı olarak çalışmaya başlamıştır. 2007-2014 yılları arasında TÜBİTAK UME Stratejik Planlama ve İş Geliştirme Birimi Sorumluluğu görevini yürütmüş, bunun yanında 2011-2014 yıllarında arasında TÜBİTAK UME Müdür İdari Yardımcılığı görevine vekalet etmiştir. 2014 yılından itibaren TÜBİTAK UME RF ve Mikrodalga Laboratuvarında araştırmacı olarak çalışmakta ve 2020 yılından beri Laboratuvar sorumlusu görevini yürütmektedir.

TÜRKAK'da RF ve Mikrodalga ölçümleri konusunda denetçi olarak görev almaktadır.

2011 yılında buyana EURAMET TC-IM Türkiye delegasyonu, 2020 yılından buyana EURAMET TC-EM RFSC Türkiye delegasyonu görevlerini sürdürmektedir.

2023 yılından beri de TÜBİTAK UME Dijitalleşme Çalışma Grubu Koordinatörlüğünü yürütmektedir.

Yüksek Hızlı AC Sürücülerde Çok Ölçütlü Karar Verme Yöntemleri ile Topoloji ve Anahtar Seçimi Uygulanması

Semiconductor Switch Selection in the High Speed Drives Using Multi-Criteria Decision Making Methods

Gülsüm Yıldırım

 0000-0001-6075-7310

Düzce Meslek Yüksekokulu, Elektrik ve Enerji Bölümü

Düzce Üniversitesi

gulsumyildirim@duzce.edu.tr

Özet

Güç elektroniği sektöründe uygun topoloji ve anahtarlama elemanının seçimi; soğutucu ve filtre tasarımını, sistem performansını, verimi ve maliyeti etkiler. Uygulamanın gerilim, güç, çalışma frekansı gibi genel kısıtların yanında; maliyet, çalışma şartları ve hacim gibi endüstriyel seri üretim kısıtları da seçimi etkiler. Endüstriyel çalışmalarda güç elektroniği topolojisi-yarı iletken anahtar seçimi için maliyet veya termal performans öne çıkarken, akademik araştırmalarda anahtarlama kayıpları ve verim önemlidir. Birden fazla kriter ve bu kriterlerinin ağırlıklarına göre işletilecek bir karar verme süreci, daha gerçekçi ve doğru sonuçlar verecektir. Bu noktada Çok Ölçütlü Karar Verme (ÇÖKV) yöntemleri kullanılmaktadır. Çalışmada 5 kW, 1200V, 30-60 kHz frekans aralığındaki yüksek hızlı AC motor sürücü topolojisi için; güç kaybı, anahtarlama hızı, hacim ve fiyat seçim ölçütleri dikkate alınarak TOPSIS ve AHP yöntemleriyle seçim yapılmıştır. Üç seviyeli IGBT tabanlı T-NPC ve iki seviyeli SiC-MOSFET tabanlı sürücü arasında yapılan seçimde, her iki yöntemin sonucunda da, iki seviyeli SiC-MOSFET tabanlı sürücü seçimi uygun bulunmuştur. Anahtar kelimeler: Si-IGBT, SiC-MOSFET, Anahtar seçimi, AHP, TOPSIS.

Abstract

The selection of the appropriate topology and switching element affects the cooler and filter design, system performance, efficiency and cost in the power electronics applications. In addition to general constraints such as voltage, power and operating frequency of the application, industrial mass-production constraints such as cost, operating conditions and volume also affect the selection. While the cost or thermal performance is prominent for the selection of power electronics topology-switch pair in industrial works, the switching losses and the efficiency are important in academic research. A decision-making process that is operated according to more than one criteria, and the weights of these criteria will give more realistic and accurate results. At this point, Multi-Criteria Decision Making (MCDM) methods are used. In this paper, the configuration selections have been examined with TOPSIS and AHP methods by considering the selection criteria of power loss, switching


speed, volume and price for the high-speed AC motor drive topology in the frequency range of 5 kW, 1200V, 30-60 kHz. According to the results of both methods, the two-level SiC-MOSFET based driver has been found more suitable than three-level IGBT based T-NPC.

Key words: Si-IGBT, SiC-MOSFET, Motor driver, AHP, TOPSIS.

1. Giriş

Yenilebilir enerji kaynakları, elektrikli araçlar, akıllı şebekeler vb. teknoloji alanındaki gelişmelerle birlikte son yıllarda güç elektroniği teknolojisi ivme kazanmıştır. Güç elektroniği devrelerinin yaygınlaşması ile sistemler daha etkin, esnek, güvenli, verimli ve daha küçük hacimlere sahip hale gelmiştir. Aynı sistem isterleri, farklı topolojilerin uygulanması ile gerçekleştirilebilir. Örneğin bir DC/DC dönüştürücüde; geleneksel yükseltici (boost) topolojisi kullanılabileceği gibi, iç içe geçmiş çok anahtarlı yükseltici topolojisi veya CUK dönüştürücü de tercih edilebilir. Güç elektroniği teknolojisi temelde yarı iletken anahtarlama devre elemanlarına dayanmaktadır. Anahtarlama devre elemanları devre tasarım kriterine bağlı olarak farklı kategorilere ayrılabilir. Bunlardan bazıları; tristörler, transistörler, tiryaklar, GTO'lar, IGBT'ler ve MOSFET'ler vs. sayılabilir. Sağladıkları teknik üstünlükler sebebiyle IGBT ve MOSFET'lerin kullanımı zamanla daha yaygın hale gelmiştir. Son teknolojik gelişmelerle birlikte IGBT ve MOSFET'lerin geniş bant aralığına sahip daha üstün performans gösteren üst sürümleri olan Si-IGBT, SiC-MOSFET ve GaN-MOSFET modelleri geliştirilmiştir (Şekil 1).

Yarıiletken anahtarların performansı ve çalışma aralıkları geliştikçe kullanım alanları da artmıştır. Kesintisiz güç kaynakları [1], maksimum güç noktası takibi [2], rejeneratif frenleme [3], motor sürücüleri [4, 5] gibi pek çok farklı sistemde yaygın olarak kullanılır hale gelmişlerdir. Çalışma parametrelerine göre, çok düşük frekanslardan çok yüksek frekans değerlerine (MHz) kadar veya çok düşük gerilim ve akım seviyelerinden çok yüksek gerilim ve akım seviyelerine (kV, kA) kadar oldukça geniş bir yelpazeye yayılmış çalışma aralıklarına sahiptirler.



Şekil 1. (a) 1200V 300A SiC MOSFET (b) Si IGBT [6]

Bu sebeplerle hangi topoloji ve yarı iletken anahtarın seçileceğine karar verirken, öncelikle kontrol edilecek sistemle uyumlu çalışma parametrelerine sahip yarıiletken anahtarlama eleman alternatifleri ve topoloji kısıtları belirlenmelidir. Sonrasında belirlenen seçenekler arasında aranan ölçütler için en uygun konfigürasyon seçilebilir.

Anahtar seçimine, literatürde farklı güç elektroniği uygulamalarında rastlanmaktadır. Örneğin, elektrikli araç tahrik inverter topolojisi için anahtarlama gereksinimlerine dair yarıiletken anahtar çeşitleri karşılaştırmalı incelenmiş ve ihtiyaç görülen alanlar için termal tasarım yöntemleri önerilmiştir [7]. Güç elektroniği teknolojisi gelişerek daha üstün performans sağlayan yarıiletken anahtarlar yaygınlaştıkça, akademik çalışmaların yönü yeni nesil sürümlere dönmeye başlamıştır. Çalışma gerilim ve akım benzerliği dolayısıyla, emsal topolojilerde tercih edilen yarı iletken anahtarlardan olan SiC-MOSFET ve Si-IGBT'lerle ilgili de pek çok performans karşılaştırmalı çalışması bulunmaktadır [6, 8-11]. Silisyum Karbür ile Silisyum tabanlı aygıtların performansları kıyaslanarak SiC-MOSFET'in muadili anahtarlardan daha iyi anahtarlama performansı gösterdiği ortaya konmuş, bu bilgiler ışığında indüksiyonlu ocaklarda Silisyum Karbür aygıtlarının kullanımı önerilmiştir [12]. Yüksek hızlı trenlerde kullanılan katı hal transformatör tabanlı çekiş sistemlerinde sistemi daha verimli ve küçük hale getirmek için geniş bant aralığına sahip yarı iletken anahtarların kullanılması önerilmiştir [13]. Yine Silisyum Tabanlı bipolar transistörler, IGBT'ler, tristörler ile SiC tabanlı MOSFET'ler vb. yeni nesil yarıiletken anahtarlar kıyaslanmış ve her ne kadar 4,5kV üzeri gerilimlerde Silisyum tabanlı yarı iletken anahtarlar mevcutta vazgeçilmez olsa da 650V ve altındaki gerilim seviyelerinde SiC-MOSFET vb. yeni nesil yarı iletken anahtarların eski nesil anahtarların hakimiyetini devirmeye aday olduğu öne sürülmüştür [14]. Kelepçeli inverter beslemeli indüksiyon motor sürücüsü için Si-IGBT, SiC-MOSFET ve GaN tabanlı diyotlarla anahtarlama testleri yapılarak güç kayıpları karşılaştırılmıştır. Yapılan çalışmadan GaN tabanlı diyotun alternatiflerine göre daha az güç kaybına sahip olduğu belirlenmiştir. Güç kaybının azaltılması durumunda soğutucu boyutlarının küçültülebileceği öngörülmüştür [15]. Bir rüzgâr enerji santralinde, farklı rüzgâr hızları için Si tabanlı ve SiC tabanlı yarı iletken anahtarlar arasında verimlilik maliyet ve hacim

karşılaştırması yapılmış ve daha yüksek maliyete sahip olmasına rağmen verimlilik ve daha minimal soğutma ihtiyacı nedeniyle hacim konusunda SiC-MOSFET'in üstünlüğü kabul edilmiştir [16]. SiC-MOSFET, Si-IGBT'e karşı önemli üstünlükler göstermektedir. Ancak değişken frekanslı sürücü gibi yüksek anahtarlama hızı gerektiren uygulamalarda yüksek dv/dt sorunları ortaya çıkabilir. Bu nedenle sistem performans beklentilerine göre tasarım yapılırken yarı iletken anahtar ve topoloji seçimi birlikte değerlendirilir. [17]'de 2L SiC-MOSFET tabanlı inverter ile Si-IGBT tabanlı T-NPC inverter karşılaştırılmıştır. Güç kaybı ve verimlilik bakımından SiC-MOSFET tabanlı 2 seviyeli inverter ön plana çıkarken, fiyat ve hacim avantajı açısından Si-IGBT tabanlı T-NPC inverter üstünlük göstermektedir. Yani doğal seçim ölçütleri; güç kaybı, verimlilik, fiyat ve hacimdir. Ancak her bir ölçüt için ayrı sonuç elde edilmiştir. Sayısal sonuçların bütünü göz önünde bulundurularak bir seçim önceliği belirlenmemiştir.

Bir devre ya da sistem tasarımı yaparken tek kriteri dikkate almak yanıltıcı olabilir. Seri üretime konu olması amaçlanan tasarımlarda gerilim, akım, güç gibi deneysel parametrelerin yanı sıra hacim, fiyat gibi kriterler de göz önünde bulundurulmalıdır. Birden fazla kriter göz önünde bulundurulduğunda; kullanılacak seçim yöntemi, tüm kriterleri önemi nispetinde değerlendirebilme kabiliyetinde olmalıdır. Bunun için ÇÖKV yöntemleri geliştirilmiştir. En bilinen ve yaygın kullanılan ÇÖKV yöntemleri; TOPSIS, AHP, MOORA, COPRAS vs. olarak sayılabilir. ÇÖKV'de, seçenekleri her bir kriter için ayrı ayrı kıyaslamak yerine, tüm kriterler göz önünde bulundurularak karar seçenekleri için öncelik değerlendirmesi yapılır [18]. Literatürde ÇÖKV yöntemleri ile elektrikli batarya seçimi vb. karar verme çalışmaları önerilmiştir [19-21]. Güç elektroniği uygulamalarından düşük güç seviyeli AC/DC topolojilerinin seçiminde TOPSIS yönteminin kullanımı [22]'de incelenmiştir. Yakıt pili uygulamaları için DC-DC dönüştürücü seçiminde ÇÖKV yöntemlerinden TOPSIS kullanılırken [23], bir başka çalışmada iki seviyeli Z-kaynak evirici topolojileri çoklu karar sıralamasına tabii tutulmuştur [24]. Tüm bu güncel çalışmalar, özdeş performanslı güç elektroniği topolojilerinin çoklu kriterler dikkate alınarak seçimi veya sıralamasının önemini göstermektedir. Her ne kadar son yıllarda farklı güç elektroniği devre uygulamalarında ÇÖKV yöntemleri uygulansa da; yüksek hızlı AC motor sürücü devrelerinin seçimi, bu çalışmada ilk kez ele alınmıştır.

Bu çalışmada anahtarlama seçiminin kritik olduğu yüksek hızlı bir motor sürücü uygulaması dikkate alınmıştır [17]. 5kW anma güç ve 48000 rpm anma hıza sahip bir AC motor için tasarlanmış yüksek hızlı sürücüler için, 30kHz-60kHz frekans bandında kullanılacak en uygun anahtarlama devre elemanı – topoloji konfigürasyonunun seçimi amaçlanmıştır. Bu referans çalışmada; seçenekler olarak benzer çıkış gerilim ve akım THD'sine sahip, iki seviyeli (2L) SiC-MOSFET tabanlı sürücü ile üç seviyeli (3L) Si-IGBT tabanlı T-NPC sürücü belirlenmiştir. Her ne kadar güç kaybı ve verim açısından 2L SiC-MOSFET sürücünün, fiyat ve hacim açısından ise 3L Si-IGBT T-NPC'nin önüne çıktığı vurgulansa da yazarlar anahtarlama kayıplarının kendileri için daha önemli olduğunu vurgulayarak bir karar vermişlerdir. Diğer bir ifade ile hacim, soğutucu, maliyet vb. kriterler konfigürasyon seçiminde göz önüne alınmamıştır. Bu makalede, karar önceliklerini belirlemek için literatürdeki uygulamalardan farklı olarak ÇÖKV yöntemlerinden TOPSIS ve AHP yöntemleri uygulanmıştır. Böylece verilen kararın doğruluğu iki ayrı

ÇÖKV yöntemi ile de sınanmıştır. Karar verme için endüstriyel uygulamalarda da önemli kriterler olan güç kaybı, anahtarlama hızı, hacim ve fiyat ölçütleri kullanılmıştır. Elde edilen bulguların farklı güç elektroniği uygulamalarındaki topoloji ve anahtar seçimlerinde de uygulanabileceği düşünülmektedir.

2. Metot

Güç elektroniği devrelerinde farklı tip topolojiler ve devre elemanları arasında en uygunu seçmek önemlidir. Literatür çalışmalarında araştırmacılar, ağırlıklı olarak önerdikleri sistemin performansını ön plana çıkaracak şekilde anahtar seçimi yapmaktadırlar. Seri üretim, maliyet, hacim, üretim kolaylığı gibi endüstriyel beklentiler ise göz ardı edilebilmektedir. Bu noktada anahtar seçimi için, ÇÖKV yöntemlerine başvurulabilir. ÇÖKV yöntemleri, belirlenen seçeneklerin arasında somut veya soyut delillere dayandırılarak en iyi seçimi yapmayı hedeflemektedir. Yöntemin güçlü yanları sade ve anlaşılır olmasıdır. Yöntem uygulama sürecinde problemin doğru tanımlanması ve seçim ölçütlerinin doğru belirlenmesi, yöntemin başarımını artırmaktadır. Bu çalışmada çoklu karar verme yöntemlerinin sonuçlarını ve tutarlılığını gözlemleyebilmek için iki ayrı yöntem, TOPSİS ve AHP yöntemi ayrı ayrı incelenmiş ve sonuçları birlikte değerlendirilmiştir.

2.1. TOPSİS Yöntemi

TOPSİS yöntemi; çok ölçütlü seçimlerde, benzerliğe göre sıralayarak karar verme tekniğidir. Seçenekler arasında yapılacak değerlendirme sonucunda, pozitif ideal çözüm ve negatif ideal çözüm olarak iki temel sonuç elde edilir. Bu iki temel sonuçtan yola çıkarak; pozitif ideal çözüme minimum, negatif ideal çözüme maksimum uzaklıktaki karar seçeneğine ulaşmaya çalışılır.

TOPSİS yöntemi uygulaması için öncelikle karar matrisi oluşturulur. Karar matrisi, karar verme sürecinde elde edilen seçenekler ve seçimi belirleyen ölçütlerden oluşur. Mevcut seçenek sayısı n ve belirleyici ölçüt sayısı m olarak belirlendiği durum için; $n \times m$ boyutlu bir karar matrisi, D elde edilir. D matrisinde satırlar karar verme sürecindeki seçenekleri, sütunlar ise kararı belirleyecek ölçütleri ifade etmektedir.

Sonraki aşamada karar verme sürecinde belirlenen seçenekler ve ölçütlerle oluşturulan karar matrisi normalize edilerek standart karar matrisi oluşturulur. D matrisindeki her bir eleman, içinde bulunduğu sütundaki her bir elemanın kareleri toplamının kareköküne bölünerek yeni bir değer kazanır (2). Yeni elde edilen değerler kullanılarak, R standart karar matrisi hesaplanır (3). Daha sonra SWARA yöntemi yada ölçütlerin önem derecesine göre öznel değerlendirme ile belirlenmiş ağırlık değerleri ($w_i, i = 1, 2, \dots, m$) kullanılarak V olarak tanımlanan ağırlıklı standart karar matrisi oluşturulur (4).

$$D = \begin{bmatrix} d_{11} & \dots & d_{1m} \\ \vdots & \ddots & \vdots \\ d_{n1} & \dots & d_{nm} \end{bmatrix} \quad (1)$$

$$r_{ij} = \frac{d_{ij}}{\sqrt{\sum_{k=1}^n d_{kj}^2}}, \quad i = 1, 2, \dots, n, j = 1, 2, \dots, m \quad (2)$$

$$R = \begin{bmatrix} r_{11} & \dots & r_{1m} \\ \vdots & \ddots & \vdots \\ r_{n1} & \dots & r_{nm} \end{bmatrix} \quad (3)$$

$$V = \begin{bmatrix} w_1 r_{11} & \dots & w_m r_{1m} \\ \vdots & \ddots & \vdots \\ w_1 r_{n1} & \dots & w_m r_{nm} \end{bmatrix} = \begin{bmatrix} v_{11} & \dots & v_{1m} \\ \vdots & \ddots & \vdots \\ v_{n1} & \dots & v_{nm} \end{bmatrix} \quad (4)$$

Oluşturulan ağırlıklı standart karar matrisinde her bir sütun üzerindeki en büyük ve en küçük değerler belirlenir. Belirlenen en büyük değerler pozitif ideal çözüm kümesini $V^+ = \{V_1^+, V_2^+, \dots, V_m^+\}$, en küçük değerler negatif ideal çözüm kümesini $V^- = \{V_1^-, V_2^-, \dots, V_m^-\}$ oluşturur. Elde edilen pozitif ve negatif ideal çözüm kümelerindeki değerler, Öklid uzaklık yaklaşımına tabi tutularak uzaklık değerleri belirlenir (5, 6). Uzaklık değerleri kullanılarak, ideal çözüme göreli yakınlık katsayıları hesaplanır (7). Burada $0 \leq C_i^* \leq 1$, $i = 1, 2, \dots, n$ 'dir. Bulunan C_i^* değerlerinden 1'e yakın olanı tercih edilir.


$$S_i^+ = \sqrt{\sum_{j=1}^m (V_{ij} - V_j^+)^2}, \quad i = 1, 2, \dots, n \quad (5)$$

$$S_i^- = \sqrt{\sum_{j=1}^m (V_{ij} - V_j^-)^2}, \quad i = 1, 2, \dots, n \quad (6)$$

$$C_i^* = \frac{S_i^-}{S_i^+ + S_i^-}, \quad i = 1, 2, \dots, n \quad (7)$$

2.2. AHP Yöntemi

AHP, sezgisel veya deneyime dayalı öznel ya da nesnel yargıları aynı problem çözümünde ele alan bir yöntemdir. Çözüm için bir veya daha fazla görüş dikkate alınır. Bu görüşler deneysel sayısal verilere dayandırılmış olabileceği gibi, tamamen kişisel tercihlerle belirlenmiş de olabilir. Yani bu yöntemde karar verici, vereceği kararda özgür bırakılmıştır.



Şekil 2. AHP hiyerarşik yapı [25]

Yöntem, en üst seviyede amaç olmak üzere devamında sırasıyla ana ölçütler ve alt ölçütlerden oluşan asgari üç seviyeli hiyerarşik bir yapıya dayandırılmıştır (Şekil 2). En alt seviye karar seçeneklerine aittir. Yöntemin başarımının artırılması için, ölçütlerin sayısı ve tanımları doğru tayin edilmelidir. Yöntem; subjektif verilere ve karşılaştırmalara dayandırıldığından, ikili karşılaştırma matrisleri oluşturulurken alanında uzman görüşlerine başvurulmalıdır.

Yöntem uygulamasında öncelikle problem tanımlanarak, problem çözümü için ölçütler ve ölçütlerin birbirleriyle kıyaslanarak önem dereceleri belirlenir. Ardından, hiyerarşik yapı inşa edilir. Hiyerarşik yapı, en üstten alta sıra ile temel hedefler, temel ölçütler, alt ölçütler ve en alt basamakta karar

seçeneklerinden oluşur. Her bir basamaktaki seçenekler birbirinden bağımsızdırlar.

Hiyerarşik yapı oluşturulduktan sonra tüm ölçütlerin ve bu ölçütler dikkate alınarak karar seçeneklerinin kendi aralarında karşılaştırıldığı karşılaştırma matrisleri oluşturulur. (8)'de temsili olarak verilmiş, köşegen elemanları 1 olan, bir kare karşılaştırma matrisi görülmektedir. Matriste a_{ij} değerleri i değerinin j değerine oranla tercih derecesini gösteren karşılaştırma değeridir. Aynı bakış açısıyla a_{ji} değeri j değerinin i değerine oranla tercih derecesini göstereceği için matris üzerinde $a_{ij} = 1/a_{ji}$ olarak değerlendirilir. Tercih değerleri belirlenirken Tablo 1'de gösterilen Saaty tarafından önerilmiş karşılaştırma ölççekleri kullanılır.

$$\begin{bmatrix} 1 & a_{12} & \dots & a_{1n} \\ 1/a_{21} & 1 & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a_{1n} & 1/a_{2n} & \dots & 1 \end{bmatrix} \quad (8)$$

Tablo 1. Saaty karşılaştırma ölçeği

Önem Derecesi	Tanım
1	Eşit önemli
2	Zayıf ya da hafif
3	Biraz önemli
4	Makul artı
5	Fazla önemli
6	Güçlü artı
7	Çok fazla önemli
8	Çok çok güçlü
9	Son derece önemli

Karşılaştırma ölçeği kullanılarak bulunan a_{ij} değerleri, öncelik vektörü w_i 'i hesaplamak için normalize edilirler (9, 10). w_i , ölçütlerin önem yüzdesini göstermektedir.

$$a'_{ij} = \frac{a_{ij}}{\sum_{i=1}^n a_{ij}}, i, j = 1, 2, \dots, n \quad (9)$$

$$w_i = \left(\frac{1}{n}\right) \sum_{i=1}^n a'_{ij} \quad (10)$$

İkili karşılaştırma ve önceliklerin belirlenmesi sonrası, karşılaştırma matrisinin tutarlı olup olmadığını belirlemek amacı ile tutarlılık indeksi (CI-Consistency Index) hesaplanır (11). Burada λ_{max} , karşılaştırma değerleri ve öncelik vektörlerine bağlıdır (12). Daha sonra Tablo 2'de verilmiş olan RI (Rassal Index) değerleri kullanılarak, Tutarlılık Oranı, CR hesaplanır (13). CR değeri; 0,10'dan küçükse karşılaştırma matrisinin tutarlı olduğu anlamına gelir. Son olarak, öncelik vektörleriyle elde edilmiş öncelik matrisi ile karar seçeneklerin öncelik matrisi çarpılarak sonuç vektörü oluşturulur. Sonuç vektöründe seçeneklerin ağırlıkları tercih sırasını belirler.

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (11)$$

$$\lambda_{max} = \frac{1}{n} \sum_{i=1}^n \left(\frac{\sum_{j=1}^n a_{ij} w_j}{w_i} \right) \quad (12)$$

$$CR = \frac{CI}{RI} \quad (13)$$

Tablo 2. Karşılaştırma matrislerinin boyutuna bağlı RI değer tablosu


n	1	2	3
RI	0	0	0,58
n	4	5	6
RI	0,90	1,12	1,24
n	7	8	9
RI	1,32	1,41	1,45
n	10	11	12
RI	1,49	1,51	1,59

3. ÇÖKV'nin Güç Elektroniği Devrelerine Uygulanması


Yarı iletken anahtarlar, güç elektroniği devrelerinin vazgeçilmez devre elemanlarıdır. Yarı iletken teknolojinin gelişimiyle anahtarlama devre elemanları hacimsel olarak küçülmekte ve verimlilikleri artmaktadır. Aynı sistem çalışma performansları için farklı yarı-iletken anahtarların ve/veya devre topolojilerinin kullanılması mümkündür. Örneğin [26]'de 3,7 kW'lık bir asenkron motorun değişken frekanslı sürücüsü için geleneksel iki seviyeli inverter, üç seviyeli NPC ve üç seviyeli TNPC inverterler önerilmiş ve performansları karşılaştırılmıştır. Karşılaştırma kriterleri; yüksek dv/dt gerilim artışları, sistem verimi ve çıkış akımı THD'i olabilir. Anahtar seçimlerinde de anahtarlama frekansı, termal performans ve düşük anahtarlama kaybı dikkate alınır. Son yıllarda SiC-MOSFET; geniş bant aralıklarında kullanımı, yüksek anahtarlama hızı, yüksek sıcaklık kapasitesi ve düşük anahtarlama kayıpları ile dikkati çekmektedir. [27]'de üç fazlı bir T-NPC'de IGBT ve SiC-MOSFET kullanımı incelenmiştir. SiC-MOSFET kullanımı ile sistem verimliliği arttırılabilir. Ayrıca tam SiC-MOSFET kullanımı yerine, ana anahtarlama elemanı olarak SiC-MOSFET ve nötr nokta kelepçeli anahtar olarak Si-IGBT kullanımı ile de yüksek verimlilik sağlanabilir. SiC-MOSFET, Si-IGBT'e karşı önemli bir alternatiftir. Buna karşın değişken frekanslı bir sürücüde yüksek anahtarlama hızı, motor tahrik sisteminde yüksek dv/dt sorunlarına neden olabilir [26]. Bu nedenle sistem performans beklentilerine göre anahtar ve topoloji seçimi gerekebilir. [22]'de üç fazlı 3-10 kW güç seviyesinde ve çift yönlü çalışan dönüştürücü topolojileri arasında seçim yapmak için; maliyet, kararlılık, verim ve güç yoğunluğu kriterleri dikkate alınarak TOPSİS yöntemi ile ÇÖKV yapılmıştır. Farkı bir güç elektroniği uygulaması olarak, yakıt pilleri ile kullanılmak üzere beş adet izolesiz DC-DC dönüştürücü topolojisinin seçiminde de TOPSİS yönteminden faydalandığı görülmektedir [23].

Bu çalışmada 5kW nominal güç ve 48000 rpm nominal hıza sahip bir AC motorun yüksek hızlı sürücüsü için (1200V çalışma gerilimi) 30kHz-60kHz frekans bandında kullanılacak en uygun inverter topolojisi ve yarı-iletken anahtar kullanımının seçimi amaçlanmıştır. Adil bir karşılaştırma için aynı çıkış akımı THD'si (%2,5) ve aşırı gerilim seviyelerine (dv/dt) sahip iki inverter topolojisi belirlenmiştir. [28]'de; 2L SiC-MOSFET sürücü ile 3L IGBT T-NPC sürücü RL yükte güç kayıplarını karşılaştırmak için statik durum analizi, anahtarlama ve güç kayıplarını karşılaştırmak için de dinamik analizi LPspice programında yapılmış ve seçilen topolojilerin özdeş anahtarlama kayıplarına ve dv/dt oranına sahip oldukları gösterilmiştir. Seçilen sürücü topolojileri Şekil 3'te

gösterilmiştir. 3L T-NPC sürücünde S_1 , S_4 anahtarları RGS50TSX2DHR IGBT, S_2 , S_3 anahtarları RGCL80TK60D IGBT olarak kullanılmıştır. [29-31]. 3L Si-IGBT T-NPC



(a)



(b)


Şekil 3. (a) 2L SiC-MOSFET sürücü (b) 3L Si-IGBT T-NPC sürücü [17]

Tablo 3. Si-IGBT ve SiC-MOSFET çalışma parametreleri [17]

Parametreler	SiC-MOSFET (SCT3080KLHR)	IGBT (RGS50TSX2DHR)	IGBT (RGCL80TK60D)
V_{DSS} / V_{CES}	1200V	1200V	600V
$I_D / I_C (25^\circ\text{C})$	31A	50A	35A
$I_D / I_C (100^\circ\text{C})$	22A	25A	21A
P_D (Güç kaybı)	165W	395W	57W
$R_{DS(on)}$	80mΩ	-	-
$V_{CE(sat)}$	-	1,7V	1,4V
Anahtarlama Hızı	Hızlı	Normal	Normal
Fiyat	Yüksek	Düşük	Düşük

V_d ve I_d değerleri, çalışılmak istenilen gerilim ve akım değerleriyle uyumlu ve yeterli olması bakımından oldukça önemlidir. Çünkü uygun V_d ve I_d çalışma aralığı koşulunu sağlamayan malzemelerle çalışmak zaten mümkün değildir. Ancak çalışma aralığı koşulu sağlandığı sürece V_d ve I_d değerleri malzeme seçiminde ayırt edici veya tercih nedeni değildir. $R_{DS(on)}$ veya V_{CE} değerlerinin sistem çıkışına etkileri halihazırda P_D değerinde karşılık bulmaktadır. Bu sebeple $R_{DS(on)}$ veya V_{CE} değerlerinin de seçim ölçütleri olarak değerlendirilmeleri anlamlı değildir. Diğer taraftan “anahtarlama güç kaybı” (P_D), “anahtarlama hızı”, “fiyat” ve “fiziki hacim” devre tasarımında ayırt edici nitelikte avantaj veya dezavantaj ortaya koymaktadır. Bu nedenle seçim ölçütleri olarak bu dört parametre seçilmiştir.

Çalışma için belirlenmiş olan seçenekler ve karar verme ölçütleri ile ilgili olarak, Elektrik Elektronik Mühendisliği (1 Profesör, 3 Doç. Dr. ve 2 Dr. Öğr. Üyesi) öğretim üyelerinin ve sektörde güç elektronigi alanında çalışan iki ARGE, bir ÜRGE ve bir tasarım mühendisinin uzman görüşleri doğrultusunda ölçütlerin önem ve öncelik dereceleri belirlenmiştir. Çalışmada ölçütler sırasıyla K1 (P_d güç kaybı), K2 (Anahtarlama hızı), K3 (Fiyat), K4 (Hacim) olarak kodlanmıştır. Çok ölçütlü karar vermede hem TOPSİS hem de AHP yöntemi uygulanmıştır. “3L Si-IGBT T-NPC sürücü” için “S1” ve “2L SiC-MOSFET sürücü” için “S2” kısaltması kullanılmıştır. Çalışmanın hiyerarşik yapısı ve tanımlamalar Şekil 4’te gösterilmiştir.



Şekil 4. ÇÖKV Hiyerarşik Yapısı

3.1. TOPSİS Yönteminin Uygulanması

Uzman görüşleri alınırken sistem çalışma gereksinimleri, karar seçeneklerinin performans bilgileri ve yarı iletken anahtarların özellikleri açıkça belirtilmiştir. Akademik ve sektörel uzmanların görüşleri ile oluşturulan D karar matrisi Tablo 4’te görülmektedir. Karar matrisi normalize edilip, denklem (2) kullanılarak R standart karar matrisi oluşturulur (Tablo 5). SWARA yöntemi ile uzman görüşlerinden faydalanılarak Tablo 6’da verilen ağırlık değerleri w_i belirlenmiştir [20]. Oluşturulan standart karar matrisi elemanları ile ölçütlerin

ağırlık değerleri çarpılarak Tablo 7’de verilmiş olan ağırlıklı standart karar matrisi V oluşturulmuştur.

Tablo 4. TOPSİS Karar Matrisi (D)

	Seçim Ölçütleri			
Seçenekler	K1	K2	K3	K4
S1	36	32	30	18
S2	36	41	25	19

Tablo 5. TOPSİS Standart Matrisi (R)

	Seçim Ölçütleri			
Seçenekler	K1	K2	K3	K4
S1	0,7071	0,6173	0,7682	0,6832
S2	0,7071	0,7867	0,6402	0,7303

Tablo 6. Ölçütlerin ağırlık değerleri (w_i)

w_1	w_2	w_3	w_4
0,3238	0,3238	0,2513	0,1113

Tablo 7. TOPSİS ağırlıklı standart karar matrisi (V_i)

	Seçim Ölçütleri			
Seçenekler	K1	K2	K3	K4
S1	0,2289	0,1998	0,1930	0,0760
S2	0,2289	0,2547	0,1608	0,0812

Tablo 8. TOPSİS pozitif ideal V^+ ve negatif ideal V^- çözüm değerleri

Çözüm Değerleri	V_1	V_2	V_3	V_4
Pozitif ideal çözüm değerleri V^+	0,2289	0,2547	0,1930	0,0812
Negatif ideal çözüm değerleri V^-	0,2289	0,1998	0,1608	0,0760

Ağırlıklı standart karar matrisinde bulunan değerler kullanılarak, her bir sütundaki maksimum değerler pozitif ideal çözüm değerlerini V^+ , ve minimum değerler negatif ideal çözüm değerlerini V^- oluşturur. Pozitif ve negatif ideal çözüm değerleri Tablo 8’de verilmiştir. Denklem (5) ve (6) kullanılarak, pozitif ideal çözüm değerlerine uzaklık (S_i^+) ve negatif ideal çözüm değerlerine uzaklık (S_i^-) değerleri bulunur. Hesaplanan uzaklık değerleri denklem (7)’de yerine

konularak, ideal çözüme göreli yakınlık katsayıları (C_i^*) hesaplanır. Elde edilen sonuçlar Tablo 9’da verilmiştir. C_1^* ve C_2^* arasında **0,6314** değerle 1’e en yakın seçenek C_1^* olduğu için, TOPSİS yöntemi sonucu **2L SiC-MOSFET sürücü** seçeneğinin tercih edilmesi uygun görülmüştür.

Tablo 9. TOPSİS S_i^+ , S_i^- ve C_i^* değerleri

(i) Seçenekler	S_i^+	S_i^-	C_i^*
(1) S1	0,0551	0,0322	0,3686
(2) S2	0,0322	0,0551	0,6314*

3.2. AHP Yönteminin Uygulanması

AHP yöntemine hiyerarşik yapı oluşturulması ile başlanır. Bu çalışmada “amaç”; Şekil 4’te verilen hiyerarşik yapıda görüldüğü gibi, anma çalışma aralıkları belirlenmiş bir yüksek hızlı motor AC motor için sürücü topolojisi ve anahtarlama devre elemanı seçme olarak belirlenmiştir. Hiyerarşik yapının ikinci basamağında amaç için belirlenmiş ayırt edici ölçütler; K1 (P_d güç kaybı), K2 (Anahtarlama hızı), K3 (Fiyat), K4 (Hacim) olarak kodlanmıştır. Son basamakta amaç için belirlenmiş karar seçenekleri; S1 (3L Si-IGBT T-NPC sürücü), S2 (2L SiC-MOSFET sürücü) olarak belirlenmiştir. Belirlenen ölçütler ve bu ölçütler dikkate alınarak belirlenen karar seçenekleri için ikili karşılaştırma matrisleri oluşturulmalıdır. Tablo 10’da ölçütler için uygulanmış ikili karşılaştırma matrisi verilmiştir. Ölçütler için oluşturulan ikili karşılaştırma matrisinin normalize edilmesiyle Tablo 11 elde edilmiştir.

Tablo 10. Ölçütler için ikili karşılaştırma matrisi

Ölçütler	K1	K2	K3	K4
K1	1	1	3	5
K2	1	1	3	5
K3	1/3	1/3	1	3
K4	1/5	1/5	1/3	1

Tablo 11. Ölçütler için normalize edilmiş ikili karşılaştırma matrisi

Ölçütler	K1	K2	K3	K4
K1	0,3947	0,3947	0,4091	0,3571
K2	0,3947	0,3947	0,4091	0,3571
K3	0,1316	0,1316	0,1364	0,2143
K4	0,0789	0,0789	0,0455	0,0687

Normalize edilmiş ikili karşılaştırma matrisinde; her bir satır değerinin ortalaması, o satırın belirleyici ölçütünün özvektörünü verir. Tablo 12’de ölçütlerin özvektörleri

görülmektedir. Karar seçenekleri de ayrı ayrı dört değerlendirme ölçütü üzerinden karşılaştırılarak önem seviyeleri belirlenir. Tablo 13'te karar seçeneklerinin ölçüt bazında özvektörleri verilmiştir.

Tablo 12. Ölçütlerin Özvektör matrisi

Ölçütler	w_i
K1	0,3889
K2	0,3889
K3	0,1535
K4	0,0687

İkili karşılaştırma kararı sonuçlarının tutarlı olup olmadığını anlamak amacı ile denklem (11), (12) ve (13) kullanılarak $\lambda_{max}=4,0439$, $CI=0,0146$, $CR=0,0163$ olarak hesaplanmıştır. Burada $CR<0,1$ 'den küçük olduğu için karşılaştırma matrisi tutarlıdır.

Tablo 13. Karar seçeneklerinin özvektör matrisi

Ölçütler	K1	K2	K3	K4
S1	0,5	0,25	0,75	0,33
S2	0,5	0,75	0,25	0,67

Son aşamada karar seçenekleri özvektör matrisi ile ölçütlerin özvektör matrisleri çarpıldığında, karar seçeneklerinin önem ağırlıkları bulunmuş olur (Tablo 14). Tablo 14'ten anlaşılacağı üzere hesaplama sonunda, S1'in önem ağırlığı %42,97 ve S2'nin önem ağırlığı %57,03 olarak bulunmuştur. Önem ağırlığı daha büyük bir değere sahip bulunduğu için, AHP yöntemi sonucunda da **"2L SiC-MOSFET sürücü"** seçeneğinin tercih edilmesi uygun görülmüştür.

Tablo 14. Karar seçeneklerinin önem ağırlığı

Seçenekler	Önem aralığı	Sıralama
S2	0,5703*	1
S1	0,4297	2

4. Sonuç ve Tartışma

Bu çalışmada yüksek hızlı bir AC motor için en uygun sürücü topolojisi ve anahtarlama devre elemanının seçimi amaçlanmıştır. Seçim için, çalışılmak istenen gerilim ve akım seviyelerinde sıklıkla tercih edildiği bilinen iki alternatif topoloji belirlenmiştir. Bunlar benzer çıkış gerilim ve akım THD'sine sahip 2L SiC-MOSFET sürücü ile 3L Si-IGBT T-NPC sürücüdür. Referans alınan çalışmada; 5 kW'lık 1200V ve 30-60 kHz aralığında çalışacak AC motoru sürmek için, sadece anahtarlama kayıpları dikkate alınarak, 2L SiC-MOSFET sürücü seçilmiştir. Buna karşın maliyetin yüksek

olduğu da kabul edilmiştir. Bu gerçekler, çok ölçütlü karar vermenin gerekliliğini ortaya koymaktadır.

Karar verme önceliklerini belirlemek için literatürden farklı olarak yalnızca performans kriterleri değil; Güç kaybı, Anahtarlama hızı, Hacim ve Fiyat kriterleri birlikte ele alınmıştır. Hem akademiden hem de sektörden uzman görüşleri dikkate alınmıştır. Çok ölçütlü karar verme yöntemlerinin sonuçlarının daha anlamlı olması için, iki ayrı ÇÖKV yöntemi, TOPSİS ve AHP yöntemleri ayrı ayrı uygulanmıştır. TOPSİS yöntemi için kullanılan ölçüt ağırlık değerlerinin belirlenmesinde, SWARA yönteminden faydalanılmıştır. Bu çalışmada dikkate alınan ölçütler ve ölçütlerin uzman görüşleri doğrultusunda belirlenmiş önem derecelerine göre; her iki ÇÖKV yönteminde de (TOPSİS ve AHP) 2L SiC-MOSFET sürücü topolojisinin, 3L Si-IGBT tabanlı T-NPC'den daha uygun bir alternatif olduğu görülmüştür. Böylece ÇÖKV'nin sonuçları, iki ayrı yöntemle birlikte doğrulanmıştır.

Özellikle son yıllarda güç elektroniği uygulamalarında ÇÖKV yöntemlerinin uygulanması ile topoloji ve konfigürasyon seçimleri yapılmaktadır. Sonraki çalışmalarda; deneysel ve/veya benzetim çalışmalar ile elde edilen bulguların kullanıldığı MOORA gibi karar verme yöntemleri incelenebilir. Subjektif ve sayısal verilere dayalı elde edilen bulgular ışığında yöntemlerin başarımı, deneysel sonuçlar ile ortaya konulabilir.

Kaynaklar

- [1] T. Halder, "Selection of switching skills of the power MOSFET in the static converter", In 2017 14th IEEE India Council International Conference (INDICON), 2017, 1-6.
- [2] A. Durusu, ve A. Erduman, "PV Panellerin Farklı Koşullar Altında IV Eğrisini Çıkartan ve Maksimum Güç Noktası Takibi Yapan Deney Sisteminin Tasarımı", Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(3), 1242-1250, 2020.
- [3] G. Ferreira da Silva, "Improved regenerative braking in electric vehicles through switch selection optimization", University of British Columbia, Yüksek Lisans Tezi, 2021.
- [4] F. Chang, O. Ilina, M. Lienkamp, ve L. Voss, "Improving the overall efficiency of automotive inverters using a multilevel converter composed of low voltage si mosfet", IEEE Transactions on Power Electronics, 34(4), 3586-3602, 2018.
- [5] E. Macrae, R. Pollock, N. McNeill, D. Holliday, K. Ahmed, ve B.W. Williams, "Experimental efficiency comparison of a superjunction MOSFET, IGBT and SiC MOSFET for switched reluctance machine drives", IET Conference Proceedings, Cilt 4, 2022, pp. 583-587.
- [6] A. Albanna, A. Malburg, M. Anwar, A. Guta, ve N. Tiwari, "Performance comparison and device analysis between Si IGBT and SiC MOSFET", In 2016 IEEE Transportation Electrification Conference and Expo (ITEC), 2016, 1-6.
- [7] J. Gallagher, ve D. Seals, "Design considerations for the power electronics of an electric vehicle propulsion inverter", In Proceedings of WESCON'94, 34-40, 1994.
- [8] J. Loncarski, M. Ricco, V. Monteiro, ve V.G. Monopoli, "Efficiency comparison of a DC-DC interleaved converter based on SiC-MOSFET and Si-IGBT devices for EV chargers", In 2020 IEEE 14th International

- Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG), Vol. 1, 2020, pp. 517-522.
- [9] W. Zhou, ve X. Yuan, "Experimental Evaluation of SiC MOSFETs in Comparison to Si IGBTs in a Soft-Switching Converter", *IEEE Transactions on Industry Applications*, 56(5), 5108-5118, 2020.
- [10] C.D. Fuentes, M. Müller, S. Bernet, ve S. Kouro, "SiC-MOSFET or Si-IGBT: Comparison of design and key characteristics of a 690 V grid-tied industrial two-level voltage source converter", *Energies*, 14(11), 3054, 2021.
- [11] J. Srijeeth, S.R. Mohanrajan, ve A. Vijayakumari, "Performance comparison of Si-IGBT and SiC-MOSFET in an inverter application using DPT", In 2021 IEEE 2nd International Conference on Smart Technologies for Power, Energy and Control (STPEC), 2021, pp. 1-5.
- [12] S. Aslan, M. Ozturk, ve N. Altintas, "A comparative study of SiC and Si power devices in induction cookers", 5th International Conference on Electrical and Electronic Engineering (ICEEE), 2018, pp. 297-301.
- [13] D. Ronanki, ve S.S. Williamson, "Topological overview on solid-state transformer traction technology in high-speed trains", *IEEE Transportation Electrification Conference and Expo (ITEC)*, 2018, pp. 32-37.
- [14] J.O. Gonzalez, R. Wu, S. Jahdi, ve O. Alatise, "Performance and reliability review of 650 V and 900 V silicon and SiC devices: MOSFETs, cascode JFETs and IGBTs", *IEEE Transactions on Industrial Electronics*, 67(9), 7375-7385, 2019.
- [15] S. Dutta, ve A.K. Yadav, "Power Loss Comparison of Si-IGBT SiC-MOSFET And GaN Based 3-level Diode Clamped Inverter fed Induction Motor Drive", *IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE)*, 2023 pp. 1-6.
- [16] J. Loncarski, H.A. Hussain, ve A. Bellini, "Efficiency, Cost, and Volume Comparison of SiC-Based and IGBT-Based Full-Scale Converter in PMSG Wind Turbine. *Electronics*, 12(2), 385, 2023.
- [17] J. Loncarski, V.G. Monopoli, R. Leuzzi, P. Zanchetta, ve F. Cupertino, "Efficiency, cost and volume comparison of Si-IGBT based T-NPC and 2-level SiC-MOSFET based topology with dv/dt filter for high speed drives", *IEEE Energy Conversion Congress and Exposition (ECCE)*, pp. 3718-3724, 2020.
- [18] M. Hamurcu, E. Çakır, ve T. Eren, "Kullanıcı perspektifli çok kriterli karar verme ile elektrikli araçlarda batarya seçimi", *International Journal of Engineering Research and Development*, 13(2), 733-749, 2021.
- [19] M.K. Loganathan, B. Mishra, C.M. Tan, T. Kongsvik, ve R.N. Rai, "Multi-Criteria decision making (MCDM) for the selection of Li-Ion batteries used in electric vehicles (EVs), *Materials Today: Proceedings*, 41, 1073-1077, 2021.
- [20] A. Abdulvahitoğlu, A. Abdulvahitoğlu, ve M. Kılıç" Elektrikli Araç Bataryalarının Bütünleşik Swara-Topsis Metodu ile Değerlendirilmesi", *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 1061-1076, 2022.
- [21] D. Barić, S. Grabušić, M. Jakara, ve M. Emanović, "Reviewing the Cost-Benefit Analysis and Multi-Criteria Decision-Making Methods for Evaluating the Effectiveness of Lithium-Ion Batteries in Electric Vehicles", *Sustainability*, 16(1), 233, 2023.
- [22] L. Tuimala, "Choosing a three-phase converter topology for low-power applications based on subjective selection criteria." *Yüksek Lisans Tezi Lappeenranta-Lahti University of Technology LUT*, 2023.
- [23] O. Alavi, T. Rajabloo, W. De Ceuninck, M. Daenen, "Non-isolated DC-DC converters in fuel cell applications: Thermal analysis and reliability comparison.", *Applied Sciences*, 12(10), 5026, 2022.
- [24] T.V. Do, M. Kandidayeni, J. P. F. Trovão, L. Boulon, "Multi-criteria ranking of Z-source inverter topologies for a three-wheel fuel cell hybrid electric vehicle." *IEEE Transactions on Vehicular Technology*, 2023.
- [25] V.V. Shimin, V.A. Shah, M.M. Lokhande, "An advanced semiconductor material selection for switching devices in electric vehicles using three multiple attribute decision making methods." *AIMS Electronics and Electrical Engineering*, 4(4), 369-388, 2020.
- [26] S. Baek, Y. Cho, B.G. Cho, C. Hong, "Performance comparison between two-level and three-level SiC-based VFD applications with output filters." *IEEE Transactions on Industry Applications*, 55(5), 4770-4779, 2019.
- [27] X. Li, L. Ma, "Comprehensive comparison of efficiency in the three-phase active rectifier and TNPC with SiC MOSFET for the electric vehicle charger." In 2023 25th European Conference on Power Electronics and Applications (EPE'23 ECCE Europe), IEEE, September 2023, pp. 1-8.
- [28] J. Loncarski, V.G. Monopoli, R. Leuzzi, L. Ristic, F. Cupertino, "Analytical and simulation fair comparison of three level Si IGBT based NPC topologies and two level SiC MOSFET based topology for high speed drives.", *Energies*, 12(23), 4571, 2019.
- [29] ROHM Semiconductor, URL: <https://fscdn.rohm.com/en/products/databook/datasheet/discrete/sic/mosfet/sct3080klhr-e.pdf> (Erişim tarihi: 01.10.2025)
- [30] ROHM Semiconductor, URL: <https://fscdn.rohm.com/en/products/databook/datasheet/discrete/igbt/rgs50tsx2dhr-e.pdf> (Erişim tarihi: 01.10.2025)
- [31] ROHM Semiconductor, URL: <https://fscdn.rohm.com/en/products/databook/datasheet/discrete/igbt/rgcl80tk60d-e.pdf> (Erişim tarihi: 01.10.2025)

Özgeçmişler



Gülsüm Yıldız, Lisans eğitimini 2007 yılında Gazi Üniversitesi Elektrik Elektronik Mühendisliği'nde, Yüksek Lisans eğitimini 2012 yılında Cumhuriyet Üniversitesi Elektrik Elektronik Mühendisliği'nde ve Doktora eğitimini 2022 yılında Düzce Üniversitesi Elektrik Elektronik Mühendisliği'nde tamamlamıştır. 2008-2010 yılları arasında Türk Telekom'da, 2010-2017 yılları arasında Sağlık Bakanlığı'nda Elektrik Elektronik Mühendisi olarak görev almıştır. 2017 yılında Düzce Üniversitesi Düzce Meslek Yüksekokulu Elektrik Programında Öğretim Görevlisi olarak çalışmaya başlamış ve halen görevine devam etmektedir. Araştırma alanları arasında; güç sistemlerinde matematiksel modelleme ve tahmin yöntemleri, güç elektroniği uygulamaları, haberleşme modülasyon yöntemleri yer almaktadır.

Görüntü ve Sinyal İşleme İçin Adaptif Daire Yerleşimi Yoluyla Geometrik Maskeleme

Geometric Masking via Adaptive Circle Placement for Image and Signal Processing

Rıdvan Fırat Çınar

 0000-0002-0904-2165

Batman Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü,
Batman, Türkiye
ridvanfirat.cinar@batman.edu.tr

Özet

Bu çalışma, sinyal ve görüntü işleme uygulamaları için herhangi bir bölümlenmiş düzensiz geometrik alanı daire ayrıştırmasıyla temsil etmek üzere yenilikçi bir algoritma sunmaktadır. Önerilen algoritma, dinamik bir sınır içinde en büyük dairelerin yerleşimini optimize ederek hem maskeleme hem de filtreleme işlemleri için verimli bir yöntem sağlar. Kullanıcı tanımlı sınır bilgilerini kullanarak algoritma, düzensiz alanlar içinde maksimum boyutlu, çakışmayan veya ir tolerans dahilinde çakışan daireleri tanımlar ve alanın geometrik bir özetini oluşturur. Bu özet, görüntü tanıma, yerel filtreleme, segmentasyon ve özellik çıkarma gibi çeşitli görevlerde kullanılabilir. Sonuçlar, önerilen yöntemin yüksek performansını gösterirken, kapalı şekilli nesnelerin daha basit ve etkili veri kümeleri olarak temsil edilmesi için hızlı, dinamik ve parametrik olarak kontrol edilebilir bir yaklaşımı literatüre kazandırmaktadır.

Anahtar Kelimeler: Daire Yerleştirme, Adaptif Filtreleme, Sinyal İşleme, Görüntü İşleme

Abstract

This study offers a novel algorithm for representing any segmented irregular geometric domain through circle decomposition, intended for applications in signal and image processing. The proposed algorithm optimizes the placement of the largest circles within a dynamic boundary, providing an efficient method for both masking and filtering operations. By utilizing user-defined boundary information, the algorithm identifies the maximum-sized, non-overlapping or overlapping by a tolerance value circles within irregular domains, creating a geometric summary of the area. This summary can be applied in various tasks such as image recognition, local filtering, segmentation, and feature extraction. The results demonstrate the high performance of the proposed method and introduce a fast, dynamic, and parametrically controllable approach to the

literature for representing closed-shaped objects as simpler and more effective datasets.

Keywords: Circle Packing, Adaptive Filtering, Signal Processing, Image Processing.

1. Giriş

Geometrik alanların verimli bir şekilde temsil edilmesi, sinyal [1, 2] ve görüntü işleme [3, 4] gibi disiplinlerde önemli bir araştırma konusudur. Düzensiz şekillerin analiz edilmesi ve işlenmesi, yerel filtreleme, segmentasyon ve görüntü tanıma [5-9] gibi birçok uygulamanın temelini oluşturur. Bu alanların dairesel bölgelere ayrılması, matematiksel sadelik ve hesaplama verimliliği açısından önemli avantajlar sunar. Daire yerleştirme algoritmaları, alanları çakışmayan dairelerle doldurarak geometrik analiz yapılmasını sağlayan yaygın olarak çalışılan yöntemlerdir [10-15].

Mevcut daire yerleştirme yaklaşımlarının çoğu, kareler veya sabit sınırlara sahip çokgenler gibi düzenli geometrik alanlara odaklanmaktadır. Voronoi bölütlemeleri, düzenli alanların bölünmesi ve temsil edilmesi için kullanılan temel yöntemler arasındadır. Bu yöntemler, geometrik verilerin anlamlı alt bölgelere ayrılmasında önemli bir rol oynar [16, 17]. Ayrıca, daire yerleştirme algoritmaları, mikro yapı analizi [18], malzeme bilimi [19, 20] ve biyomedikal modelleme [21] gibi alanlarda yerleştirme yoğunluğunu ve mekânsal düzenlemeyi incelemek için uygulanmıştır. Ancak, özellikle düzensiz şekiller için tasarlanmış yöntemler literatürde sınırlı kalmakta ve dinamik sınırlara sahip karmaşık alanların işlenmesi yeterince ele alınmamıştır [22-24].

Bu çalışma, herhangi bir bölümlenmiş düzensiz geometrik alanı çakışmayan ve kontrol edilebilir şekilde çakışan daireler kullanarak temsil etmek için yenilikçi bir algoritma sunmaktadır. Önerilen algoritma, kullanıcı tarafından tanımlanan dinamik bir kapalı sınır içinde en büyük dairelerin

yerleşimini optimize ederek düzensiz alanların geometrik olarak özetlenmesi için verimli bir çözüm sağlamaktadır. Elde edilen geometrik özet, görüntü ve sinyal işleme alanlarındaki çeşitli görevlerde uygulanabilir. Algoritma, yerel filtreleme, özellik çıkarma, segmentasyon ve yoğunluk analizi için uygun esnek bir yapıya sahiptir. Bu makale, önerilen algoritmanın matematiksel çerçevesini ve pratik uygulamalarını incelemektedir. Önerilen yaklaşım, karmaşık ve düzensiz alanlarda veri işleme ve analizine yenilikçi bir bakış açısı sağlamayı amaçlamaktadır.

2. Eniyilenmiş Daire Yerleştirme

2.1. Dinamik Sınır

Dinamik sınır, bir nokta kümesi veya sürekli bir fonksiyon ile tanımlanan kapalı ve esnek bir şekli ifade eder. Bu sınırlar genellikle, bir veri kümesindeki ilgi nesnelerini çevreleyen segmentasyon sonuçları veya diğer görüntü işleme tekniklerinden türetilir. Matematiksel olarak, dinamik bir sınır şu şekilde temsil edilebilir:

$$B = \{(x, y) \mid f(x, y) = 0\} \quad (1)$$

Burada $f(x, y)$ sınır fonksiyonunu tanımlar ve B kümesi şeklin kapalı konturunu temsil eder. Bu sınır içinde, sınır kısıtlamalarına uyararak, mümkün olan en büyük çakışmayan dairelerle veya tolerans dahilinde çakışan dairelerle bu kapalı şekli doldurma görevi vardır.

2.2. Daire Yerleştirme

Algoritmanın temel fikri, sınırın içinde mümkün olan en büyük daireleri yinelemeli olarak yerleştirmek, bu dairelerin çakışmamasını ve dinamik sınırın tamamen içinde kalmasını sağlamaktır. Bu, aday noktaların bir ızgarasını değerlendirerek ve her bir nokta için mümkün olan maksimum daire yarıçapını hesaplayarak gerçekleştirilir. Yerleştirme süreci, her yeni dairenin iki kısıtlamaya uyduğunu garanti eder: mevcut herhangi bir daireyle çakışmaması ve sınırın içinde kalması. Optimum daire belirlendikten sonra, yerleştirilmiş daireler listesine eklenir ve yeni geçerli daire yerleştirilemeyecek hale gelene kadar süreç tekrarlanır.

Algoritma, B 'nin kapalı sınırını tümünden kaplayan bir P noktalar ızgarası adayı tanımlayarak başlar. Bu aday noktalar kapalı sınır içinde eşit aralıklı olup, potansiyel daire merkezlerinin kapsamlı bir şekilde taranmasını sağlar. Kapalı eğri, sınırın minimum ve maksimum koordinatlarıyla tanımlanır:

$$[x_{min} \cdot x_{max}] \times [y_{min} \cdot y_{max}] \quad (2)$$

Sınırın dışına düşen noktalar, geometrik bir doğrulama adımı kullanılarak hariç tutulur. Bir aday nokta (x, y) , yalnızca $(x, y) \in B$ koşulunu sağlıyorsa tutulur, burada B sınır tarafından tanımlanan kapalı bölgeyi temsil eder. Bu doğrulama, hesaplamaları yalnızca geçerli alana sınırlayarak

hesaplama yükünü azaltır. Her bir geçerli aday nokta $(x, y) \in P_{geçerli}(x, y)$ için, mümkün olan en büyük daire, iki kısıtlamaya dayalı olarak yarıçapı hesaplanarak belirlenir:

Bunlardan birincisi olan sınır kısıtı, aday noktadan sınır üzerindeki en yakın noktaya olan mesafedir:

$$r_{sınır} = \min_{(x_b, y_b) \in B} \left[\sqrt{(x - x_b)^2 + (y - y_b)^2} \right] \quad (3)$$

Diğer faktör olan daire çakışma kısıtı ise mevcut en yakın dairenin kenarına olan mesafedir:

$$r_{daire} = \min_{(x_c, y_c, r_c) \in B} \left[\sqrt{(x - x_c)^2 + (y - y_c)^2} - r_c \right] \quad (4)$$

Aday dairenin yarıçapı şu şekilde belirlenir:

$$r = \min(r_{sınır}, r_{daire}) \quad (5)$$

Bu, aday dairenin tamamen sınır içinde kalmasını ve mevcut dairelerle çakışmamasını sağlar. Tüm geçerli aday noktalar değerlendirildikten sonra, en büyük yarıçapa sahip daire yerleştirilmek üzere seçilir:

$$(x_{eniyi}, y_{eniyi}, r_{eniyi}) = \arg \max_{(x, y) \in P_{geçerli}} r \quad (6)$$

Eğer yerleştirmede rastgelelik istenirse, bu adımda σ adlı ek bir rastgele değişken tanımlanabilir, $(x_{eniyi} + \sigma_x)$ ve $(y_{eniyi} + \sigma_y)$ olarak uygulanabilir.

Ardından, daire merkez koordinatları ve yarıçaplarını içeren tüm yerleştirilmiş dairelerin saklandığı bir C listesine eklenir:

$$C = C \cup (x_{eniyi}, y_{eniyi}, r_{eniyi}) \quad (7)$$

Her daire yerleştirildikten sonra, yeni eklenen daireyi dikkate almak için ızgara ve sınır kısıtlamaları güncellenir. Süreç, artık geçerli bir daire yerleştirilemeyecek duruma gelene kadar, yani mümkün olan en büyük yarıçap r_{eniyi} 'in, anlamlı en küçük daire boyutunu temsil eden önceden tanımlanmış bir eşik ϵ 'in altına düştüğü ana kadar tekrarlanır.

Bu yapılandırılmış ve yinelemeli yerleştirme stratejisi, sınırın mümkün olan en büyük dairelerle etkili bir şekilde doldurulmasını sağlayarak hem alan kapsamını hem de hesaplama verimliliğini optimize eder.

2.3. Sözde Kod ve Akış Şeması

Önerilen algoritma, dinamik bir sınır içinde mümkün olan en büyük çakışmayan daireleri yinelemeli olarak yerleştirerek hem verimli alan kaplamasını hem de sınır kısıtlamalarına uyumu sağlar. Aşağıda, yöntemin adım adım mantığı sözde kod (pseudocode) biçiminde özetlenmiştir.

Tablo 1. Sözde kod

Algoritma: Önerilen metot için sözde kod

- 1 Girdi
Dinamik şeklin sınır noktaları:
 $B = \{(x_1, y_1), (x_2, y_2), \dots (x_n, y_n)\}$
Parametreler: ızgara çözünürlüğü, minimum yarıçap eşiği ϵ
- 2 Başlat
B'nin kapalı sınırları içinde bir aday noktalar ızgarası P oluştur
Aday noktaları sınır doğrulaması kullanarak sadece B 'nin içinde kalanlarla filtrele.
- 3 Daire yerleştirme
 - a) Yerleştirilebilecek geçerli daireler olduğu sürece:
 - aşağıdakilere göre yarıçapı hesapla:
 - i. Sınır noktasına olan mesafe.
 - ii. Mevcut dairelere olan mesafe (çakışma kısıtı).
 - b) Mümkün olan en büyük yarıçapa sahip noktayı seç.
 - c) Daireyi yerleştir ve yerleştirilen daireler listesini (C) güncelle
- 4 Durdurma
Yerleştirilebilecek geçerli daire kalmadığında durdur (yarıçap ϵ ya da ulaşılan ön belirli daire sayısı).
- 5 Çıktı
Daire listesi
 $B = \{(x_1, y_1, r_1), (x_2, y_2, r_2), \dots (x_n, y_n, r_n)\}$
Kapsama alanının hesaplanması

Yukarıda matematiksel çerçevesi ve sözde kodu ayrıntılı biçimde açıklanan algoritmanın işleyiş süreci, Şekil 1'deki akış diyagramında görselleştirilmiştir. Bu diyagram, algoritmanın başlangıçtan durma koşuluna kadar olan tüm temel adımlarını sıralı ve anlaşılır biçimde sunarak genel yapının takip edilmesini kolaylaştırır. Her adımın işlem sırasına göre yerleştirildiği yapı, algoritmanın uygulama sürecine dair bakış sağlar.


2.4. Kapsama Oranı

R_c kapsama oranı, C listesindeki dairelerin toplam alanını orijinal şeklin alanıyla karşılaştırır ve sonucu yüzde olarak verir.

$$R_c = \frac{\text{Dairelerin toplam alanı}}{\text{Şeklin toplam alanı}} \times 100 \quad (8)$$

Bu metrik, daire yerleştirme algoritmasının verimliliğini değerlendirmek için kullanılır.

Algoritmada kullanılan rastgelelik, daire merkezlerinin konumuna çok küçük sapmalar ekleyerek uygulanır. Bu sapmalar genellikle %1 seviyesini geçmediği için yerleşim desenini bozmadan çalışır. Sonuç olarak, kapsama oranı üzerindeki etkisi ihmal edilebilir düzeyde kalır ve genel performansı anlamlı şekilde etkilemez.



Şekil 1. Verilen algoritmaya ait akış diyagramı

2.5. Hesap Karmaşıklığı Analizi

Önerilen algoritmanın hesaplama karmaşıklığı, G : griddeki toplam aday merkez sayısı M : kapalı şeklin sınırını tanımlayan nokta sayısı, N : maksimum yerleştirilecek daire sayısı, K : o an yerleştirilmiş daire sayısı (her iterasyonda artar, $K \leq N$), ϵ çakışma toleransı veya rastgelelik düzeyi olmak üzere beş temel parametreye bağlıdır:

Her iterasyonda, griddeki G nokta değerlendirilir. Her bir aday nokta için işlem sayısının lineer artışını temsil etmek üzere O notasyonu kullanırsak sınır eğrisine en kısa mesafe $O(M)$, mevcut K daireyle çakışma kontrolü $O(K)$ karmaşıklığındadır. Böylece her iterasyonun toplam maliyeti $O(G \cdot (M + K))$ olur. Bu işlem N kez tekrarlanır; K değeri iteratif olarak arttığından toplam karmaşıklık T :

$$T(N) = O(G \cdot (N \cdot M + N^2)) \quad (9)$$

şeklinde ifade edilir. Burada $G \cdot N^2$ terimi büyüme hızını belirleyen ana etkidir. Şeklin sınır yapısı karmaşıksa, M artar ve her aday merkez için mesafe hesaplama süresi uzar. Ayrıca rastgelelik veya tolerans kullanımı durumunda, karar adımı deterministik değil olasılıksal hale gelir ve seçim sürecine ek işlem yükü eklenir. Bu faktörler algoritmanın toplam süresini ve bellek tüketimini doğrudan etkiler. Dolayısıyla, karmaşıklığı azaltmak için G grid yoğunluğu düşürülebilir, sınır sadeleştirilebilir veya veri yapıları (örneğin KD-ağaç) ile K üzerindeki yük hafifletilebilir [25, 26].

3. Uygulama

Bu bölüm, önerilen algoritmanın basit ve karmaşık şekiller üzerinde gerçekleştirilen bir dizi deneyle uygulamasını sunmaktadır. Yöntem, basit şekiller, düzensiz sınırlar ve gerçek dünyadan alınmış bölümlenmiş şekiller dahil olmak üzere çeşitli geometrik yapılandırmalar üzerinde test edilerek geçerliliği ve verimliliği gösterilmiştir.

Deneyler, algoritmanın ayarlanabilir tolerans parametresini kontrol ederek daire yerleştirme davranışını düzenlemektedir. Tolerans değeri artırıldığında, daireler arasındaki izin verilen çakışma artırılır ve bu da kapalı şekli temsil etmek için gereken daire sayısında bir azalma ile sonuçlanır. Bu çakışma ve daire sayısı arasındaki denge, yöntemin belirli uygulama ihtiyaçlarına uyum sağlamadaki esnekliğini vurgulamaktadır. Farklı tolerans ayarlarının etkilerini göstermek için görsel sonuçlar ve nicel değerlendirmeler sunulmuştur. Ayrıca, genel sonuçlar üzerindeki etkisini gözlemlemek amacıyla, dairelerin konumlarına bir miktar ayarlanabilir rastgelelik eklenmiştir.

4. Sonuçlar

Bu çalışma, düzensiz sınırlar içinde çakışmasız ve tolerans kontrollü daire yerleştirme yaklaşımıyla şekil temsili için esnek, kontrol edilebilir ve yüksek kapsama verimi sağlayan bir yöntem önermiştir. Algoritma, parametrik ayarlanabilirliği ve uygulama genelliği sayesinde sinyal ve görüntü işleme başta olmak üzere pek çok alanda uygulanabilir niteliktedir.

4.1. Algoritmanın Uygulama Çıktıları

Tablo 2, önerilen algoritmanın basit şekillerden karmaşık olanlara kadar çeşitli kapalı şekillere uygulandığında elde edilen çıktıları göstermektedir. Birinci satır (a–c), bir daire, bir elips ve bir yatık sekiz şekli gibi basit geometrileri içermektedir; burada algoritma, sınırları kaplamak için çakışmayan daireleri verimli bir şekilde yerleştirmiştir. İkinci satır (d–f), düzensiz "Amibe" formları ve bir denizyıldızı deseni gibi daha karmaşık şekillerden oluşmakta olup, algoritmanın karmaşık ve simetrik yapılarla uyum sağlama yeteneğini göstermektedir. Üçüncü satır (g–i), radyasyon deseni ve radar benzeri şekiller gibi değiştirilmiş ve dağınık sınırları içermekte olup, algoritmanın düzensizlikleri ve gürültüyü ele alırken etkili kapsama alanını koruma yeteneğini sergilemektedir. Bu sonuçlar, kapalı şekillerin optimize edilmiş daire yerleşimiyle

temsil edilmesinde algoritmanın uyarlanabilirliğini ve etkinliğini vurgulamaktadır.

Bu uygulamada, kapalı şekil içindeki boş alanları azaltmak için yarıçapı artıran tolerans faktörü %10 olarak belirlenmiştir. Bu, diskler ve kapalı şekil arasında kabul edilebilir bir çakışma seviyesi sağlamaktadır. Disk merkezlerinin konumlarını ayarlayan rastgelelik faktörü ise maksimum %1 ile sınırlandırılmıştır. Algoritmanın durma kriteri, yarıçapın 0.001'den küçük olması veya maksimum 50 dairenin yerleştirilmiş olması koşuluna dayanmaktadır.

Tablo 2. Performans metriklerinin Şekil 2 için değerlendirilmesi.

Şekil 2. (a-i) için performans metrikleri (kapsama alanı)		
(a) %102.99	(b) %97.19	(c) %97.19
(d) %97.51	(e) %96.53	(f) %98.33
(g) %94.31	(h) %97,55	(i) %98,65


Tablo 2, Şekil 2'de gösterilen durumlar için performans metriklerini, özellikle kapsama alanı yüzdeleri sunmaktadır. Sonuçlar, farklı yapılandırmalar arasında kapsama verimliliğindeki değişiklikleri vurgulamaktadır.

Tablo 3. Performans metriklerinin Şekil 3 için 0%, 10% ve 20% tolerans değerleri için değerlendirilmesi


Şekil 3. (a-c) için performans metrikleri (kapsama alanı ve daire adedi)		
(a) %80.92	(b) %97.19	(c) %98.02
(a) 120 adet	(b) 95 adet	(c) 65 adet

Tablo 3, Şekil 3'te gösterildiği gibi, önerilen algoritmanın farklı tolerans değerleri (%0, %10 ve %20) için performans metriklerini (kapsama alanı) değerlendirmektedir. %0 toleransta algoritma, çakışmayan daire yerleşimine odaklanarak ve minimum boşluk bırakarak %80.92 kapsama alanına ulaşmaktadır. Toleransın %10'a çıkarılması, hafif çakışmalara izin vererek kapsama oranını %97.19'a yükseltmekte ve verimlilik ile temsil doğruluğu arasında bir denge sağlamaktadır. %20 toleransta ise daha fazla çakışmaya izin verilerek kapsama oranı %98.02'ye ulaşmakta, daha az daire kullanılarak temsil basitleştirilmektedir. Amip no:2 şekli için tolerans parametresi arttıkça şekli kaplamak için gereken daire sayısı önemli ölçüde azalır.

Tolerans 0 olarak ayarlandığında, dairelerin çakışmasına izin verilmediği için şeklin tamamen kaplanması toplamda 120 daire gerektirir. %10 gibi hafif bir toleransla, daire sayısı 95'e düşer, çünkü artık daha büyük daireler çakışan bölgeleri kaplayabilir. Tolerans %20'ye çıkarıldığında, daire sayısı daha da azalır ve toplamda 65 daireyle şekil temsil edilebilir hale gelir. Bu sonuçlar, tolerans parametresinin artırılmasının şekli daha az ve daha büyük daireyle ifade etmeyi sağladığını, böylece veri setindeki gereksiz tekrarları azalttığını göstermektedir. Özellikle veri özetleme ve sıkıştırma gibi uygulamalarda bu bir avantaj sağlar.



Şekil 2. Örnek kapalı şekiller için algoritma çıktıları (a) Çember (b) Elips (c) Yatık sekiz (d) Amip no:1 (e) Amip.no:2 (f) Deniz yıldızı (g) Yayılım deseni - dağınık (h) Radar işaretleri no:1-çok dağınık (i) Radar işaretleri no:2-az dağınık.



Şekil 3. Amip no:2 kapalı şekli için (a) 0% (b) 10% (c) 20% tolerans değerleri ile sağlanan algoritma çıktıları

4.2. Yöntemin Karşılaştırmalı Analizi

Farklı daire yerleştirme yöntemlerinin hesaplama karmaşıklıkları, algoritmaların uygulama alanları, sınır türleri ve yerleştirme stratejileriyle doğrudan ilişkilidir. Aşağıdaki tabloda, literatürde yaygın kullanılan üç anahtar yaklaşım ile önerilen algoritmanın teorik işlem yükleri karşılaştırılmıştır. Graham & Lubachevsky yöntemi [11] çakışmasız yoğun yerleşim amacıyla fizik tabanlı bir simülasyon sunarken, Ahn ve ark. deterministik, sabit grid üzerinde çalışır [9]. Tóth ise teorik sınırlara odaklandığı için işlem karmaşıklığı açıkça tanımlanmaz [5]. Önerilen yöntem ise kullanıcı tanımlı düzensiz sınırlarda çalışmakta ve tolerans kontrollü çakışma analizi içermektedir. Bu esneklik ve uyarlanabilirlik, hesaplama maliyetini artırsa da uygulama çeşitliliğini ve gerçek dünya uyumunu güçlendirir.

Tablo 4. Algoritmaların teorik işlem yükleri

Yöntem/ Kaynak	Karmaşıklık $T(N)$	Açıklama
Graham et al. (1998) [11]	$O(N^2 \cdot \log N)$	Yoğun çakışmasız yerleştirme, fizik tabanlı.
Tóth (1976) [5]	Belirtmez (teorik analiz)	Teorik sınırları modelleme.
Ahn et al. (2012) [9]	$O(N)$	Sabit grid üzerinde, yerleşim skoruna göre.
Önerilen Yöntem	$O(G \cdot (N \cdot M + N^2))$	Düzensiz sınır, tolerans, çakışma ve sınır kontrolü

Önerilen algoritma, uygulama esnekliği açısından literatürdeki birçok yaklaşımdan ayrılmaktadır. Özellikle sabit ve düzenli sınırlar yerine düzensiz, kullanıcı tanımlı konturlar üzerinde çalışabilmesi, gerçek dünya uygulamaları için önemli bir avantaj sağlar. Parametrik kontrol yeteneği sayesinde kullanıcı, tolerans ve rastgelelik gibi ayarlanabilir değişkenlerle doğruluk ve verimlilik arasında denge kurabilir. Literatürde bu düzeyde esneklik sunan yöntem sayısı oldukça sınırlıdır. Ayrıca, deneysel sonuçlar bu algoritmanın daha az daireyle yüksek kapsama oranlarına ulaşabildiğini göstermektedir. Hesaplama yükü nispeten yüksek olsa da bu durum algoritmanın sunduğu kontrol, esneklik ve başarı oranı göz önüne alındığında kabul edilebilir seviyede görülmektedir.

5. Değerlendirme ve Tartışma

Bu algoritma, düzensiz şekillerin dairelerle ayrıştırılması yoluyla elde edilen çıktılar sayesinde bilgisayarla görme ve veri görselleştirme alanlarında önemli katkılar sağlar. Karmaşık konturların dairesel yapılarla temsil edilmesi, verinin parametrik ve sıkıştırılmış biçimde özetlenmesine olanak tanır. Bu sayede hem bellek verimliliği sağlanır hem de öznetelik uzayı daha sade hale getirilerek makine öğrenmesi sistemlerine uygun girdi formatı oluşturulur.

Önerilen daire yerleştirme algoritması, çıktıları sayesinde dört temel alana doğrudan katkı sağlar: bilgisayarla görme, veri görselleştirme, makine öğrenmesi uygulamaları ve sinyal/görüntü işleme. Her alanda, karmaşık şekillerin basit dairesel öğelerle temsil edilmesi, işlemeyi kolaylaştıran yapısal avantajlar sunar.

Bilgisayarlı görü alanında algoritma, özellikle segmentasyon sonrası oluşan konturların özetlenmesinde kullanılır. Dairesel ayrıştırma sayesinde bir nesnenin sınırı az sayıda parametreyle tanımlanır ve bu özet yapı, şekil karşılaştırma, sınıflandırma ve yerel analiz gibi işlemleri hızlandırır. Daire merkezlerinin koordinatları ve yarıçapları, kontur yerine geçerek bölgesel işlem birimlerine dönüşür. Böylece geleneksel piksel düzeyinde işlem yerine anlamlı ve daha az sayıda yapısal birim kullanılır.

Veri görselleştirme açısından, daireler şekil içinde yayılım ve yoğunluk gösteriminde kullanılır. Her dairenin boyutu ve konumu, yerel alanların büyüklüğü ve dağılımı hakkında doğrudan fikir verir. Bu yapı, özellikle karmaşık sınırlara sahip verilerin sadeleştirilmiş, sezgisel olarak okunabilir biçimde sunulmasına olanak tanır. Böylece şekil içinde bilgi yoğunluğu, simetri veya düzensizlik görsel olarak kolayca ayırt edilir.

Makine öğrenmesi ve yapay zekâ uygulamaları için ise algoritma, yüksek boyutlu şekil verisini düşük boyutlu ama anlamlı vektörlere dönüştürür. Her daire bir örneklem birimi gibi ele alınabilir. Daire merkez koordinatları, yarıçap ve içerdiği bölgeye ait öznetelikler (yoğunluk, doku vb.) makine öğrenmesi modellerine uygun girişler oluşturur. Bu sayede sınıflandırma, kümeleme ve çıkarımsal analiz işlemleri daha etkili hale gelir.

Sinyal ve görüntü işleme alanından değerlendirilecek olursa, her daire bir filtre uygulama bölgesi (kernel) gibi kullanılabilir. Dairelerin farklı boyutlarda ve konumlarda olması, konum-adaptif ve çok çözünürlüklü filtreleme yaklaşımlarına olanak verir. Özellikle desen tanıma, kenar yumuşatma veya bölgeye özel işlem gerektiren uygulamalarda, bu yapı dinamik ve lokal müdahale imkânı sağlar.

Algoritma, uygulanabilirliğini ve performansını artırmak için birkaç yönde genişletilebilir. Önerilen daire yerleşimi tekniğine ait teknik detaylar eliptik bir geometri seçimi için tekrar uyarlanabilir Yöntemin üç boyutlu şekillere uyarlanması, 3D modelleme ve hacimsel veri analizi alanlarında kullanımını genişleterek, verimli küre tabanlı temsil olanakları sağlayacaktır. Şekil karmaşıklığı ve uygulamaya özel kısıtlamalar temelinde tolerans parametresinin otomatik optimizasyonu, doğruluk ile veri sıkıştırma arasındaki dengeyi daha da geliştirebilir. Makine öğrenimi tekniklerinin entegrasyonu, gerçek zamanlı uygulamalar için otomatik şekil tanıma, özellik çıkartımı ve parametrelerin dinamik olarak ayarlanmasını sağlayabilir. Bir çerçeve olarak bu yöntem birçok teknik alanda kullanılmak üzere tekrar yorumlanabilir niteliktedir.

Kaynakça

- [1] S. S. Haykin, ve B. Van Veen, "Signals and systems," p. 802, 2004.
- [2] A. V. Oppenheim, R. W. Schaffer, ve J. R. Buck, "Discrete-time signal processing," p. 864, 1999.
- [3] R. C. Gonzales, R. E. Woods, "Digital Image Processing Digital Image Fundamental," *Radiol Technol*, 2018.
- [4] C. Solomon, ve T. Breckon, "Fundamentals of digital image processing : a practical approach with examples in matlab," 2013, Accessed: Ara. 20, 2024. [Online]. Available: <https://www.everand.com/book/149045666/Fundamentals-of-Digital-Image-Processing-A-Practical-Approach-with-Examples-in-Matlab>
- [5] G. Fejes Tóth, "Multiple packing and covering of the plane with circles," *Acta Mathematica Academiae Scientiarum Hungaricae*, vol. 27, no. 1–2, pp. 135–140, Mar. 1976, doi: 10.1007/BF01896768.
- [6] Y. D. Marr, ve D. E. Hildreth, "Theory of edge detection," *Proc R Soc Lond B Biol Sci*, vol. 207, no. 1167, pp. 187–217, Şub. 1980, doi: 10.1098/rspb.1980.0020.
- [7] T. McNerney, ve D. Terzopoulos, "Deformable models in medical image analysis: a survey," *Med Image Anal*, vol. 1, no. 2, pp. 91–108, Oca. 1996, doi: 10.1016/S1361-8415(96)80007-7.
- [8] G. L. Orick, K. Stephenson, ve C. Collins, "A linearized circle packing algorithm," *Computational Geometry*, vol. 64, pp. 13–29, Ağu. 2017, doi: 10.1016/j.comgeo.2017.03.002.
- [9] Y. J. Ahn, C. M. Hoffmann, ve P. Rosen, "A note on circle packing," *Journal of Zhejiang University SCIENCE C*, vol. 13, no. 8, pp. 559–564, Ağu. 2012, doi: 10.1631/jzus.C1200010.
- [10] S. J. Gortler, C. Gotsman, ve D. Thurston, "Discrete one-forms on meshes and applications to 3D mesh parameterization," *Comput Aided Geom Des*, vol. 23, no. 2, pp. 83–112, Şub. 2006, doi: 10.1016/j.cagd.2005.05.002.
- [11] R. L. Graham, B. D. Lubachevsky, K. J. Nurmela, ve P. R. J. Östergård, "Dense packings of congruent circles in a circle," *Discrete Math*, vol. 181, no. 1–3, pp. 139–154, Şub. 1998, doi: 10.1016/S0012-365X(97)00050-2.
- [12] R. L. Lubachevsky, ve B. D. Graham, "Dense Packings of Equal Disks in an Equilateral Triangle: From 22 to 34 and Beyond," *Combinatorics*, no. 1, pp. 1–39, Jun. 2004, Accessed: Ara. 14, 2024. [Online]. Available: <http://arxiv.org/abs/math/0406252>
- [13] Sh. I. Galiev, ve M. A. Karpova, "Optimization of multiple covering of a bounded set with circles," *Computational Mathematics and Mathematical Physics*, vol. 50, no. 4, pp. 721–732, Nis. 2010, doi: 10.1134/S0965542510040135.
- [14] G. F. Tóth, "Multiple packing and covering of spheres," *Acta Mathematica Academiae Scientiarum Hungaricae*, vol. 34, no. 1–2, pp. 165–176, Mar. 1979, doi: 10.1007/BF01902605.
- [15] C. T. J. Zahn, "Black box maximization of circular coverage:," Gaithersburg, MD, 1962. doi: 10.6028/NBS.RPT.7386.
- [16] F. Aurenhammer, "Voronoi diagrams—a survey of a fundamental geometric data structure," *ACM Comput Surv*, vol. 23, no. 3, pp. 345–405, Eyl. 1991, doi: 10.1145/116873.116880.
- [17] J. W. Cannon, W. J. Floyd, ve W. R. Parry, "Introduction to circle packing: the theory of discrete analytic functions," *The Mathematical Intelligencer*, vol. 29, no. 3, pp. 63–66, Haz. 2007, doi: 10.1007/BF02985693.
- [18] H. Haslach, "Random Heterogeneous Materials: Microstructure and Macroscopic Properties," *Appl Mech Rev*, vol. 55, no. 4, pp. B62–B63, Tem. 2002, doi: 10.1115/1.1483342.
- [19] K. A. Dowland, M. Gilbert, ve G. Kendall, "A local search approach to a circle cutting problem arising in the motor cycle industry," *Journal of the Operational Research Society*, vol. 58, no. 4, pp. 429–438, Nis. 2007, doi: 10.1057/palgrave.jors.2602170.
- [20] Y. Jiao, F. H. Stillinger, ve S. Torquato, "Optimal Packings of Superdisks and the Role of Symmetry," *Phys Rev Lett*, vol. 100, no. 24, p. 245504, Haz. 2008, doi: 10.1103/PhysRevLett.100.245504.
- [21] M. S. Bayzid, T. Hunt, ve T. Warnow, "Disk covering methods improve phylogenomic analyses," *BMC Genomics*, vol. 15, no. S6, p. S7, Eki. 2014, doi: 10.1186/1471-2164-15-S6-S7.
- [22] Jianbo Shi, ve J. Malik, "Normalized cuts and image segmentation," *IEEE Trans Pattern Anal Mach Intell*, vol. 22, no. 8, pp. 888–905, Ağu. 2000, doi: 10.1109/34.868688.
- [23] S. S. Skiena, *The Algorithm Design Manual*. in Texts in Computer Science. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-54256-6.
- [24] A. S. Elfshawy, S. B. Kesler, ve A. S. Abutaleb, "Adaptive algorithms for change detection in image sequence," *Signal Processing*, vol. 23, no. 2, pp. 179–191, May 1991, doi: 10.1016/0165-1684(91)90072-Q.
- [25] T. H. Cormen, C. E. Leiserson, R. L. Rivest, ve C. Stein, "Introduction to algorithms, 4 Edition," *The MIT Press Cambridge, Massachusetts London, England*, p. 1291, 2022, Accessed: Nis. 13, 2025. [Online]. Available: <http://lccn.loc.gov/2021037260>
- [26] S. S. Skiena, *The Algorithm Design Manual*. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-54256-6.

Özgeçmişler



Dr. Öğr. Üyesi Rıdvan Fırat Çınar, 2011 yılında Malatya İnönü Üniversitesi, Elektrik-Elektronik Mühendisliği bölümünden lisans, 2015 yılında Sakarya Üniversitesi, Elektrik-Elektronik Mühendisliği bölümünden yüksek lisans ve 2022 yılında aynı üniversiteden doktora derecesini almıştır.

2014-2022 yılları arasında Batman Üniversitesi, Teknoloji Fakültesi ve Sakarya Üniversitesi, Elektrik-Elektronik Mühendisliği bölümlerinde araştırma görevlisi olarak çalışmıştır. 2023 yılından itibaren Batman Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği bölümünde Doktor Öğretim Üyesi olarak görev yapmaktadır.

Araştırma alanları arasında görüntü işleme, radar görüntüleme, radar sinyal işleme, kestirim kuramı ve optimizasyon algoritmaları yer almaktadır.

Lityum-iyon Pil Bozulma Testlerinin Hızlandırılması İçin Yeni Bir Yaklaşım

New Approach to Acceleration of Li-ion Battery Degradation Testing

Cansu İçöz¹, Mehmet Aksoy², Çiğdem Ezgi Arer³

 0009-0000-5333-2736  0009-0009-0218-816X  0009-0009-3855-0378

¹ Tasarım & Ürün Kalitesi Kıdemli Uzman, Beko, Tekirdağ, Türkiye
cansu_icoz@beko.com

² Test ve Sertifikasyon Merkezi Kıdemli Lider, Beko, Tekirdağ, Türkiye
mehmet_aksoy@beko.com

³ Veri Analitiği Kıdemli Lider, Beko, İstanbul, Türkiye
cigdemezgi.arer@beko.com

Özet

Lityum-iyon piller için standart komponent ömür testleri uzun süreli olmakla birlikte, pillerin yaşlanmayla bozulma performansını anlayabilmek için gereklidir. Degradasyon testleri, ürünlerin zamanla kalite, yapı veya performansındaki azalma veya bozulmayı tespit etmek amacıyla yapılan güvenilirlik testleridir. Bu çalışmada li-iyon pillerin zamanla bozulma testlerini hızlandırmak için degradasyon testinin kullanılması önerilmektedir. Hasarsız degradasyon testinde örnekler, pek çok güvenilirlik test türlerinden farklı olarak, tamamen arızalanana kadar test edilmediği için, bu yaklaşım doğal olarak testlerin daha hızlı tamamlanma avantajını sunar. Ancak, bu yöntemi kullanırken dikkate alınması gereken kritik bir nokta, testin durdurulması gereken uygun aşamanın belirlenmesidir. Test süresi, modelin, testin orijinal süresini tamamladığında elde edilecek sonuçlar ile uyumlu ve doğru sonuçlar tahmin etmesini sağlayabilmelidir. Bu çalışma, pil ömür test sürelerinin farklı oranlarda kısaltılması koşullarındaki model tahminleri ile klasik ömür testi sonuçları arasındaki doğruluk oranını incelemektedir. Çalışma sonucunda, %30'luk bir kısaltmanın, klasik ömür testi ile istatistiksel olarak benzer sonuçlar verdiğini göstermektedir.

Anahtar Kelimeler- Pil Bozulması, Bozulma Analizi (DEG), Yaşam Döngüsü Testleri, Lityum-iyon Piller, Test Süresi Azaltma, Weibull Analizi (WEI)

Abstract

Standard lifespan tests for lithium-ion batteries are essential for understanding ageing and degradation but are time-consuming. Degradation tests are reliability tests conducted to detect the decrease or deterioration in the quality, structure, or performance of a product over time. This study explores using non-destructive degradation testing to accelerate battery lifespan tests. Unlike traditional methods, samples in this approach are not tested to complete failure, enabling faster results. A key challenge is determining the optimal stopping point to ensure accurate predictions aligned with full-duration test outcomes. The study compares model predictions from reduced-duration tests with classical lifespan

test results and finds that a 30% reduction produces statistically similar outcomes. This method provides a practical way to save time while maintaining test accuracy.

Keywords - Battery Degradation, Degradation Analysis (DEG), Life Cycle Testing, Li-ion Batteries, Test Duration Reduction, Weibull Analysis (WEI)

1. Giriş

Günümüzde hızla gelişen teknolojik yenilikler; insansız hava ve su altı araçları, robotik sistemler, otonom cihazlar, hibrit ve elektrikli araçlar, taşınabilir bilgisayarlar, akıllı telefonlar, dijital kameralar, askeri sistemler, kablosuz iletişim teknolojileri ve akıllı ev uygulamaları gibi pek çok alanda ileri teknolojiye sahip elektronik cihazların yaygın olarak kullanılması sağlamıştır. Bu sistemlerin kesintisiz, güvenilir ve verimli bir şekilde çalışabilmesi için yüksek enerji yoğunluğuna, uzun ömre ve güvenli çalışma koşullarına sahip enerji depolama çözümlerine olan ihtiyaç her geçen gün artmaktadır [1]. Bu bağlamda, geleneksel enerji depolama sistemlerinden farklı olarak, özellikle lityum-iyon (Li-ion) batarya teknolojileri; yüksek enerji yoğunluğu, düşük kendiliğinden deşarj oranı, uzun çevrim ömrü, hafiflik ve geniş çalışma gerilim aralığı gibi avantajları nedeniyle günümüzde en yaygın kullanılan sistemler arasında yer almaktadır [2]–[5]. Lityum-iyon bataryalar, her ne kadar çok sayıda avantaj sunsa da, zaman içinde çeşitli çevresel etkiler ve kullanım şartları nedeniyle performanslarında ciddi bozulmalar ortaya çıkmaktadır. Yüksek sıcaklık, yüksek akım, hızlı şarj/deşarj döngüleri ve derin deşarj gibi zorlu çalışma koşulları; kapasite azalması, iç direnç artışı, lityum metali birikimi, elektrot bozulmaları ve elektrolit parçalanması gibi çeşitli yaşlanma mekanizmalarını tetikleyebilir [6]–[9]. Bu yaşlanma süreçlerinin güvenilir şekilde analiz edilmesi ve ömür boyunca performans değişimlerinin tahmin edilebilmesi hem ürün güvenliği hem de sistem verimliliği açısından kritik öneme

sahiptir. Literatürde batarya yaşlanmasını değerlendirmek ve kalan kullanım ömrünü tahmin etmek amacıyla kullanılan pek çok yaklaşım bulunmaktadır. Bunlardan ilki, bataryaların ömrünü daha kısa sürede tahmin edebilmek amacıyla stres faktörlerini artırarak gerçekleştirilen Hızlandırılmış Ömür Testleri (Accelerated Life Testing - ALTA) yöntemleridir. ALTA kapsamında sıcaklık, voltaj ve akım gibi parametreler yükseltilerek bataryaların hızlı biçimde yaşlandırılması sağlanır ve yeni hücre tasarımları daha kısa sürede değerlendirilebilir [6], [10], [14], [15]. Bu tür testler, özellikle elektrikli araçlar gibi yüksek enerji talepli sistemler için zaman avantajı sağlayan bir araç olarak görülmektedir. Hızlı şarj-deşarj döngüleri de bu yaklaşıma dâhil olarak; bataryaların yüksek C-rate değerleri altında davranışlarını test etmeye olanak tanır. Örneğin Han ve arkadaşlarının çalışmasında [17], bu tür yüksek hızlı döngülerin batarya kapasitesinde hızlı düşüşe neden olduğu ortaya konulmuştur. Her ne kadar ALTA, batarya performans değerlendirmelerinde zaman kazandıran etkili bir yöntem olarak öne çıksa da, bu yaklaşımın bazı sınırlamaları da göz önünde bulundurulmalıdır. Yüksek sıcaklık veya akım gibi ekstrem stres koşullarında yapılan bu testler, bataryaların gerçek kullanım senaryolarını her zaman doğru bir şekilde yansıtmayabilir. Ayrıca, bu koşullar altında ortaya çıkan bozulma mekanizmaları, normal çalışma koşullarında gözlemlenenlerden farklılık gösterebilir. Bu da model geçerliliği açısından belirsizliklere neden olabilir [4], [16], [18], [27]. ALTA yöntemlerinin kısıtlarını tamamlayıcı nitelikte geliştirilen bir diğer yöntem ise, bataryaların yaşlanma süreçlerini daha gerçekçi kullanım senaryoları altında ve uzun vadeli olarak inceleyen degradasyon temelli ömür tahmini yaklaşımlarıdır. Bu yaklaşımlar, batarya hücresinin iç yapısında zamanla oluşan fiziksel ve kimyasal değişimleri takip eder. Degradasyon analizlerinde kapasite kaybı, iç direnç artışı, aktif malzeme kaybı, elektrot bozulmaları ve lityum kaynaklarının tükenmesi gibi parametreler sistematik olarak izlenir. Bu tür analizler empirik regresyon modelleri [19], elektrokimyasal empedans spektrumu tabanlı modeller [12], termodinamik değerlendirmeler [6] ve makine öğrenmesi algoritmaları gibi farklı yöntemlerle yürütülebilmektedir [20], [25]. Ayrıca, ömrü tamamlanan bataryalar üzerinde gerçekleştirilen post-mortem analizler, batarya hücresinin iç yapısında meydana gelen faz değişimleri ve mikroyapısal bozulmaları ortaya koyarak, ömür tahmin modellerinin doğruluğunu artırmak için kullanılmaktadır [11], [24]. Son yıllarda geliştirilen çalışmalarda, hızlandırılmış testlerin sunduğu zaman avantajı ile degradasyon analizlerinin sunduğu doğruluk bir arada kullanılmaya başlanmıştır. Örneğin Ren ve arkadaşları [23], batarya bozulma mekanizmalarının eşdeğerliğine dayalı olarak kontrollü stres koşulları altında hızlandırılmış test yöntemleri geliştirerek, hem zamandan tasarruf etmiş hem de model geçerliliğini artırmayı başarmıştır. Paarmann ve arkadaşları [24] ise kısa süreli testlerle uzun vadeli yaşlanma senaryolarını simüle ederek, ömür tahmin süreçlerini optimize etmeyi amaçlamıştır. Fricke ve arkadaşları tarafından oluşturulan veri seti [26], sabit ve değişken yükleme koşullarında gerçekleştirilen hızlandırılmış testlere dayanmakta olup, literatürde sıkça başvurulan güvenilir bir kaynak olarak öne çıkmaktadır. Literatürde öne çıkan hızlandırılmış test ve

modelleme yöntemlerinin avantajları ve sınırlılıkları Tablo 1'de özetlenmiştir.

Tablo 1: Hızlandırılmış Batarya Test Yöntemlerinin Karşılaştırılması

Test Türü	Avantajları	Sınırlılıkları	Örnek Kaynaklar
ALTA (Accelerated Life Testing)	Kısa sürede ömür tahmini, istatistiksel modelleme imkanı	Gerçek kullanım koşullarını sınırlı temsil eder	[6], [10], [13], [27]
Hızlı Şarj-Deşarj Testleri	Gerçekçi döngü senaryoları, termal etkilerin değerlendirilmesi	Termal stres kaynaklı anomaliler diğer faktörlerle ayrıştırılama yabilir	[4], [7], [8], [17], [18]
Degradasyon Analizi	Gerçek kullanım koşullarında zamana bağlı performans takibi, model geçerliliği	Test süresi uzun olabilir, veri toplama zahmetlidir	[10], [11], [14], [15], [19], [23]
Ampirik / Veri Odaklı Modeller	Hızlı tahmin sağlar; farklı kullanım senaryolarının a kolayca entegre edilebilir	Fiziksel temelden yoksun olabilir; genellenebilirlik sınırlı kalabilir	[19], [20], [21], [25]
Fiziksel / Termodinamik Modeller	İç yapıya dair detaylı analiz sunar; fiziksel ilkelerle yüksek doğrulukta modelleme yapılabilir	Karmaşık matematiksel yapı ve yüksek veri ihtiyacı nedeniyle uygulanabilirlik zorlukları barındırır	[6], [12], [22]
Post-Mortem (Ömür Sonrası) Analizler	Elektrot, elektrolit ve batarya içi ayırıcı malzeme bozulmaları analiz ederek model doğrulamayı destekler.	Yalnızca ömrünü tamamlamış hücreler üzerinde uygulanabilir; bazı uygulamalar hücre yapısına fiziksel müdahale gerekebilir.	[11], [16], [24]


Mevcut literatür incelendiğinde, pek çok çalışmanın ya yalnızca hızlandırılmış test yöntemlerine odaklandığı ya da

yalnızca veri odaklı modellemelerle degradasyon tahmini yaptığı görülmektedir. Ancak bu yaklaşımlar, özellikle uygulamaya özel sistemler için tek başlarına yeterli olmayabilir. Çünkü bir yandan test süresini optimize etmek gerekirken, diğer yandan ömür tahmininin gerçek kullanım koşullarını yansıtmaması da önemlidir. Sonuç olarak, ALTA ve hızlı döngü testleri zaman avantajı sağlarken; degradasyon analizi yöntemleri, batarya davranışlarını daha kapsamlı ve uzun vadeli olarak anlamamıza olanak tanır. Bu nedenle, özellikle uygulamaya özel ömür modellemelerinde degradasyon temelli yaklaşımlar, hızlandırılmış testlerin sınırlı temsil gücünü tamamlayıcı nitelikte önemli bir rol oynamaktadır [10], [13], [14].

Bu araştırma kapsamında, degradasyon analizlerinin mevcut ömür testlerini nasıl destekleyici ve hızlandırıcı şekilde kullanılabileceği araştırılmıştır. Bölüm 2’de, uygulanan degradasyon temelli test yaklaşımı detaylı biçimde açıklanmış; elde edilen veriler analiz edilerek modelleme süreci ortaya konmuştur. Elde edilen sonuçlar doğrultusunda modelin geçerliliği ve doğruluğu tartışılmış; Sonuçlar bölümünde ise bulgular bütüncül bir yaklaşımla değerlendirilerek çalışmanın uygulamaya yönelik çıkarımları ve önerileri paylaşılmıştır.

2. Metodoloji

Bu çalışmada, lityum-iyon hücreler, ömür ve performans karakteristiklerinin analizine yönelik olarak kapsamlı bir batarya ömür testiyle analiz edilmiştir. Test verileri, çeşitli şarj-deşarj döngüleri süresince toplanmış ve analiz edilmiştir. Elde edilen veriler, ReliaSoft yazılımı [28] kullanılarak değerlendirilmiş; bu kapsamda Weibull ömür dağılımı analizi ve degradasyon modelleri uygulanmıştır. Weibull analizi, hücrelerin belirli bir ömür aralığında arıza verme olasılıklarını inceleyerek sistemin güvenilirliğini ortaya koymaktadır. Degradasyon modeli ise bataryadaki zamana bağlı kapasite düşüşünü analiz ederek, arızaya yol açan bozulma sürecini karakterize etmektedir. Bu metodolojik yaklaşım, hücre performansındaki zamana bağlı değişimleri ve kapasite kaybını anlamak amacıyla kullanılmaktadır. Şekil 1, lityum-iyon bataryaların ömür tahminine yönelik önerilen yöntemsel süreci göstermektedir. Süreç, batarya ömür testi ve veri toplama adımlarının her çevrimde tekrarlandığı döngüsel bir yapıya sahiptir. Elde edilen veriler analiz edilmekte, ardından model doğrulama adımıyla değerlendirilerek ömür tahminine yönelik sonuçlara ulaşılmaktadır.




Şekil 1. Çalışmanın özet akışı

2.1. Li – iyon hücre

Şekil 2’de verilen lityum-iyon batarya hücresi, yüksek kapasite ve enerji yoğunluğuna sahip, 18 mm çapında ve 65 mm uzunluğunda olan 18650 tipi Li-iyon şarj edilebilir pil türüdür. Çalışmada kullanılan hücrenin nominal kapasitesi 3400 mAh olup, bu değer, hücrenin tamamen şarj olduğunda 3400

miliamper-saatlik elektriksel yük depolama kapasitesine sahip olduğunu göstermektedir. Nominal hücre voltajı 3.6V olup, bu değer, hücrenin çalışma voltajını ifade etmektedir. Şarj akımı 1.02A olup, bu değer bataryanın güvenli ve verimli bir şekilde şarj edilmesini sağlamaktadır. Deşarj akımı 3.4 A olup, bu değer bataryanın enerji sağlayarak boşalma sürecinde ilettiği elektrik akımının büyüklüğünü ifade etmektedir. Deşarj kesme voltajı ise 2.5V olup, bataryanın aşırı deşarjdan korunması amacıyla deşarj işleminin sonlandırıldığı voltaj seviyesini belirtmektedir. Deşarj Derinliği (Depth of Discharge- DoD), bataryanın %100 dolu durumundan %0 tam boş duruma kadar olan deşarj oranını ifade eder. Bir bataryanın belirli bir DoD seviyesine kadar deşarj edilip ardından tamamen şarj edilmesi bir çevrim olarak tanımlanır.



Şekil 2. Li-iyon batarya hücresi

2.2. Batarya ömür testi ve veri toplama

Li-iyon bataryaların ömrü ve güvenilirliğini değerlendirmek amacıyla yapılan ömür testi, batarya performansını analiz etmek için kritik bir yöntemdir. Bu test, belirli şarj ve deşarj koşulları altında uygulanarak bataryanın zaman içindeki performans değişimleri incelenmiştir. Tablo 2’de verilen IEC 61960-3:2017 test prosedürü taşınabilir uygulamalar için kullanılan lityum bazlı ikincil pillerin (şarj edilebilir bataryaların) özelliklerini belirleyen bir standarttır. Bu standart, özellikle prizmatik ve silindirik lityum ikincil hücreleri ile bu hücrelerden yapılan bataryaların performans gereksinimlerini ve test prosedürlerini kapsamaktadır. IEC 61960-3:2017, bataryaların güvenli kullanımını sağlamak amacıyla elektriksel, mekanik ve çevresel testleri tanımlar. Ayrıca, bu bataryaların taşıma, depolama ve kullanım sırasında güvenliğini artıran tasarım özelliklerini de belirtir. Bu çalışmada, bataryaların veri sayfalarındaki özelliklere dayanarak Tablo 3’de verilen test prosedürleri geliştirilmiştir. Bu prosedürler arasındaki temel farklar, bataryaların test koşullarındaki zorluk seviyelerinden kaynaklanmaktadır. Farklı döngü sayıları, deşarj akımları ve test sonunda elde edilen kapasite değerleri, bataryaların dayanıklılığını ve performansını daha zorlu koşullar altında değerlendirmeyi hedeflemektedir. Özellikle, bataryaların yüksek deşarj akımları ve fazla sayıda şarj-deşarj döngüsü ile test edilmesi, gerçek kullanım koşullarına daha yakın sonuçlar elde edilmesini sağlamaktadır. Bu tür testler, bataryaların uzun vadeli performansını, kapasite kaybını ve güvenlik sınırlarını daha detaylı bir şekilde analiz etmeyi sağlamaktadır.

Tablo 2. IEC 61960-3:2017 Standardına göre test prosedürü

Özellik	IEC 61960-3:2017 Standardına Göre Hızlandırılmış Test Prosedürü
Döngü Sayısı	400 çevrim
Şarj akımı ve voltajı	Üretici tarafından tanımlanan (1,02A ile 4,2V'a kadar)
Deşarj akımı ve voltajı	0,5 lt A (1,7A) ile 2,5V'a kadar
Kalan kapasite	60%

Tablo 3. Batarya verilerine göre oluşturulan test prosedürü


Özellik	Bataryanın Değerlerine Göre Oluşturulan Test Prosedürü
Döngü Sayısı	600 çevrim
Şarj akımı ve voltajı	Üretici tarafından tanımlanan (1,02A ile 4,2V'a kadar)
Deşarj akımı ve voltajı	Üretici tarafından tanımlanan (3,4A ile 2,5V'a kadar)
Kalan kapasite	70%

İlk olarak, batarya 1.02 A akımla şarj edilir ve 4.2 V voltaj seviyesine ulaşana kadar bu işlem devam eder (sabit akım aşaması). Ardından, batarya 170 mA kesme akımına ulaşana kadar sabit voltaj aşamasında şarj edilmeye devam edilir. Sonrasında, bataryanın performansını değerlendirmek için 3.4 A akımla deşarj edilir ve voltaj 2.5 V'ye düşene kadar deşarj işlemi sürdürülür. Endüstri standartlarına göre, bataryanın yaşam döngüsü 600 döngü olarak belirlenmiş olup, kullanılabilir kapasite yüzdesi minimum %70 olarak kabul edilmiştir. Test sonuçları, bataryanın 600 döngü sonunda kapasitesinin %70'in altına düşüp düşmediğini belirler. Eğer kapasite bu seviyenin üzerinde kalırsa, batarya sağlıklı kabul edilir ve performans açısından herhangi bir sorun olmadığı belirtilir. Bataryanın genel durumu, kapasite kaybı, şarj-deşarj döngüleri, sıcaklık değişimleri ve deşarj derinliği (DoD) gibi çeşitli kriterlere dayanarak değerlendirilir. Sonuç olarak, batarya normal işleyiş gösteriyorsa, tüm gerekli voltaj, akım ve kapasite spesifikasyonlarını karşıladığı sonucuna varılır. Aksi takdirde, batarya bu koşulları karşılayamıyorsa, normal çalışmadığı ve kritik arıza modlarına girdiği tespit edilir. Bu kapsamlı test süreci, Li-iyon bataryaların dayanıklılığı ve ömrü hakkında önemli bilgiler sağlar. Batarya ömür testinin değerlendirme kriterleri belirlendikten sonra, bu kriterlere dayalı olarak testin gerçekleştirilme aşamasına geçilmiştir. Bu aşamada, bataryaların elektriksel bağlantıları ve kullanılan test ekipmanı detaylı bir şekilde düzenlenmiştir. Şekil 2'de gösterilen batarya hücresi Şekil 3'teki Cadex batarya test cihazı ile test edilmiştir. Şekil 4 ise test edilecek hücrenin elektriksel bağlantılarının yapılarak sisteme bağlanma şeklini göstermektedir. Cadex batarya test sisteminin yazılım uygulamasında, test edilecek bataryanın elektriksel ve kimyasal özelliklerine göre şarj ve deşarj döngülerini yöneten bir C kodu

(konfigürasyon kodu) kullanılarak bir test programı hazırlanmıştır. Bu program, Cadex test cihazı aracılığıyla çalıştırılmış ve batarya test süreci başlatılmıştır.



Şekil 3. C8000 batarya test sistemi [29]



Şekil 4. Cadex batarya test cihazı

Tablo 4'te, C kodu bataryanın veri sayfasına göre belirlenen değerleri içermektedir. Ayrıca, nominal kapasite, şarj oranı (bataryanın şarj edileceği akım) ve deşarj oranı (bataryanın deşarj edileceği akım) da belirtilmiştir. Buna ek olarak, kritik parametreler arasında sabit akım aşamasında bataryanın ulaşabileceği en yüksek voltaj olan maksimum şarj voltajı ve deşarj sürecinde bataryanın inebileceği en düşük voltaj olan deşarj bitiş voltajı yer almaktadır. Son olarak, şarj bitiş noktası, sabit voltaj aşamasında şarjın durdurulacağı minimum şarj akımını ifade etmektedir.

Tablo 4. Li – iyon batarya parametreleri


C-Code	
Chemistry (cell kimyası)	Li-ion
Number of cells (cell sayısı)	1 cell
Rating (nominal kapasite)	3400 mAh
Charge rate (şarj oranı)	1020 mA
Discharge rate(deşarj oranı)	3400 mAh
Maximum charge voltage (maksimum şarj voltajı)	4,2 V
End of discharge (deşarj bitiş voltajı)	2,5 V
Charge termination point (minimum şarj akımı)	170 mA
Target capacity (hedef kapasite)	70%

Tablo 5, bataryanın ömür testini gerçekleştiren programın adımlarını özetlemektedir. Program, şarj ve deşarj aşamaları ile diğer döngüsel işlemleri detaylı bir şekilde tanımlar. Her adım belirli bir sırayla uygulanır ve bir döngü tamamlandıktan sonra, herhangi bir hata olmadığı takdirde, bir sonraki döngü otomatik olarak başlar. Bu sayede test, tüm koşullar sağlanana kadar veya manuel olarak sonlandırılana kadar kesintisiz şekilde devam eder.


Tablo 5. Cadex Program

Program			
Step	Action	Duration	Test
0	Finished-No Action		No Test
1	Charge		No Test
2	Discharge		Cap > target
3	No Action		Loop
4	Charge	30 mins	No Test
5	Impedance		

Şekil 5'de, test edilen bataryanın şarj ve deşarj döngüleri gösterilmektedir. Bu döngüler sırasında, test sürecinin ilerlemesiyle bataryanın kapasitesinde bir değişiklik gözlemlenmektedir. Bu değişiklik, bataryanın performansındaki değişimi ve ömür sürecindeki kapasite kaybını anlamamıza yardımcı olur. Şekil 5, testin bir kısmında elde edilen verileri sunmaktadır. Öte yandan, Şekil 6, testin sonunda toplanan kapsamlı kapasite kaybı verilerini göstermektedir. Şekil 6'da, başlangıçtaki kapasite değeri %92 iken, testin sonunda %77'ye düşmüştür.



Şekil 5. Şarj-deşarj döngüsü grafiği



Şekil 6. Bataryanın başlangıç ve bitiş kapasite seviyeleri

Tablo 6'da verilen bilgilere göre, test bataryayı belirli bir akıma göre şarj ederek başlar ve batarya maksimum voltaja ulaşana kadar şarj edilmeye devam eder. Ardından, voltaj sabit tutulur ve akım, kesme akımına ulaşana kadar düşer, böylece şarj aşaması tamamlanır. Sonrasında, batarya belirtilen akıma göre deşarj edilir ve kesme voltajına ulaşana kadar devam eder. Deşarjdan sonra, batarya 30 dakika boyunca sabit akımla yeniden şarj edilir ve ardından otomatik bir DC empedans ölçümü yapılır. Eğer koşullar ve kapasite verilen bilgilerin gereksinimleriyle uyumluysa, döngü yeniden başlar ve belirtilen değerler elde edilene kadar işlem tekrarlanır.

Tablo 6. Bir tam test sırası

Test Sırası	Adım
1- Şarj (sabit akım aşaması 1.02A)	
2- Voltaj, maksimum şarj voltajına ulaştı mı?	Evet: Adım 3'e gidin Hayır: Adım 1'e gidin
3- Şarj (sabit voltaj aşaması 4.2V)	
4- Şarj akımı, 0.17A'lık kesme akımına ulaştı mı?	Evet: Adım 5'e gidin Hayır: Adım 3'e gidin
5- Deşarj (3.4A)	
6- Voltaj, 2.5V'lık kesme voltajına düştü mü?	Evet: Adım 7'ye gidin Hayır: Adım 5'e gidin
7- Şarj (sabit akım aşaması 1.02A)	
8- 30 dakika geçti mi?	Evet: Adım 9'a gidin Hayır: Adım 7'ye gidin
9- Otomatik DC Empedans Ölçümü	Başa dönün

Tablo 7'ya göre, test, her döngünün sonunda bataryanın kapasitesinin %70'in üzerinde olup olmadığı kontrol edilerek başlar. Eğer kapasite %70'in altına düşerse, test başarısız olarak işaretlenir ve sonlandırılır. Kapasite %70'in üzerinde ise ve döngü sayısı 600'ün altındaysa, bir sonraki döngüye başlanır. Test, 600 döngüye ulaşır ve kapasite hala %70'in üzerinde ise test başarılı ve tamamlanmış kabul edilir.

Tablo 7. Test tasarım akışı


Test Sırası	Adım
1- Bir tam test sırası (Tablo I)	
2- Kapasite < 70%	Evet: Batarya normal şekilde çalışmıyor ve gereken tüm voltaj, akım ve kapasite özelliklerini karşılamıyor. (Test Başarısız) Hayır: Batarya iyi durumda ve herhangi bir arıza veya performans düşüşü belirtisi göstermiyor. (Adım 3'e gidin)
3- < 600 Test döngüsü (varsayım)	Evet: Adım 4'e gidin Hayır: Test başarıyla tamamlandı.
4- Test, bir sonraki döngüyle devam eder.	Başlangıca dön

Veri toplama planında, Cadex'te test edilen üç aynı tip batarya örneği için farklı çevrim miktarları boyunca her bir çevrimde kapasite düşümü ölçülüp kayıt altına alınmıştır. Degradasyon modelinin 600 çevrim sonucunu kısa sürede tahmin edebilmek amacıyla, elde edilen ham verilerden çeşitli kırılmış veri setleri tasarlanmıştır. Tablo 8, her bir batarya örneği için elde edilen başlangıç ham veri miktarlarını ve ham verilere %10, %20, %30, %40 ve %50 kesme işlemleri uygulandıktan sonra kalan çevrim veri sayıları göstermektedir. Örneğin, Batarya 1 için ham veri sayısı 101 olarak belirlenmişken, %10 kesme yapıldığında veri sayısı 90'a düşmekte, %20 kesme ile ise bu sayı 80'e inmektedir. Benzer şekilde, diğer batarya örneklerinde de başlangıç verilerinde çeşitli kesintiler uygulanarak kalan veri sayıları elde edilmiştir.

Tablo 8. Her bir batarya için kırılma oranına göre veri sayıları

Numune	Ham Data	10%	20%	30%	40%	50%
Batarya 1	101	90	80	70	60	50
Batarya 2	188	169	150	132	113	94
Batarya 3	454	409	363	318	272	227


Şekil 7'de, batarya test sürecinde elde edilen ham veriler üzerinden uygulanan farklı kırılma oranları (%10, %20, %30, %40 ve %50) sonrasında ilgili çevrim verileriyle elde edilen kapasite değerleri gösterilmektedir. Her bir kırılma oranı için kapasite düşüşü grafikte ayrı ayrı gösterilmiştir.



Şekil 7. Kırılmış veri setleri kapasite kaybı grafiği

2.4. Model analizi ve arıza modu tanımı

Bu araştırmada, bataryanın yaşlanmasına etki eden ana faktörler şarj - deşarj döngü sayısı, Deşarj Derinliği (DoD)'dir. Bu faktörler, bataryanın ömrünü etkileyen ve performansını zamanla düşüren önemli parametrelerdir. Şarj-deşarj döngü sayısı arttıkça bataryanın kapasitesinde azalma gözlemlenir. Yüksek Deşarj Derinliği (DoD) bataryanın daha fazla enerji kullanmasına neden olur ve bu da ömrünü kısaltır. Bu araştırmada, şarj ve deşarj döngüleri ile birlikte oda koşullarında sıcaklık (20-25°C) ve %100 DoD kullanılarak testler yapılmıştır. DoD, her döngüde bataryanın ne kadar deşarj olduğunu ölçer. Yüksek DoD değerleri, daha derin deşarjları gösterir ve bu da batarya içinde olumsuz kimyasal reaksiyonları tetikleyebilir. Örneğin, tam deşarj, elektrotlar arasında zararlı değişimlere yol açarak kalıcı kapasite kaybına neden olabilir. Buna karşın, düşük DoD değerleri, döngüler sırasında aşınma ve yıpranmayı azaltarak batarya ömrünü uzatır. Bu araştırma, şarj ve deşarj döngülerinin batarya üzerindeki etkilerini incelemiş ve batarya yaşlanmasının sebeplerini daha iyi anlamayı amaçlamaktadır. Şekil 8'de, çalışmada kullanılan test koşullarının özet tablosu verilmiştir.



Şekil 8. Li-iyon batarya çalışma koşulları için belirlenen değişkenler

2.4.1 Analiz modeli tanımı

Bu çalışmada, batarya ömrü ve performansındaki değişimleri analiz edebilmek amacıyla istatistiksel modelleme yöntemlerinden yararlanılmıştır. Özellikle, batarya sistemlerinde zamanla ortaya çıkan arızaları ve kapasite düşüşünü anlamak amacıyla anlamak için sıkça kullanılan 2P Weibull modeli tercih edilmiştir. Bu model, test verilerinin güvenilirlik açısından değerlendirilmesini ve sistemin zaman içerisindeki arıza olasılıklarının tahmin edilmesini mümkün kılmaktadır. 2P Weibull dağılımının iki parametresi vardır: η (karakteristik ömür) ve β (şekil parametresi). Bu modelin genel formu şu şekilde ifade edilir:

$$f(t; \eta; \beta) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} \exp\left(-\left(\frac{t}{\eta}\right)^{\beta}\right) \quad (1)$$

Denklem 1’de, t arıza zamanını, η , karakteristik ömrü (ölçek parametresi), β şekil parametresini, arıza oranının eğilimini ifade eder. ($\beta=1$ kullanım ömrünü, $\beta>1$ yaşlanmayı, $\beta<1$ ise erken arızaları gösterir).

İkinci olarak, degradasyon modeli kullanılmıştır. Degradasyon modeli, bataryaların zaman içinde kapasite kaybını analiz eden bir yaklaşımdır ve bataryaların ömrü boyunca kapasite kaybını doğrusal, üssel veya başka bir fonksiyonla modelleyebilir. Bu çalışmada, Reliasoft Degradasyon Model Sihirbazı kullanılarak en uygun degradasyon modeli belirlenmiştir. Sihirbaz, Lineer, Üstel, Power ve Logaritmik dağılımlar arasından veri setine en iyi uyum sağlayan modelin doğrusal (lineer) olduğunu tespit etmiştir. Bataryalar, zamanla kapasite kaybına uğrarlar. Bu kaybın matematiksel modeli, bataryaların iç yapısına ve çalışma koşullarına bağlı olarak çeşitli fonksiyonlarla ifade edilebilir. Lineer degradasyon modeli, bataryanın kapasitesindeki kaybın, zamana doğrusal bir şekilde gerçekleştiği varsayımına dayanır. Bu model, batarya ömrü boyunca kapasite kaybının sabit bir oranda olduğunu öngörür. Lineer Degradasyon modelinin matematiksel formülü şu şekilde ifade edilebilir:

$$C(t) = C_0 - k \cdot t \quad (2)$$

Denklem 2’de, $C(t)$ zaman t ’deki kapasite, C_0 başlangıç kapasitesi ve k kapasite kaybı hızıdır. Bu analizde bataryaların zaman içerisinde ne kadar ve ne hızda kapasite kaybı yaşadığı incelenmiştir. Veri setlerinin analizi, ham ve kırılmış veri setleri üzerinde yapılmıştır. Kırılmış veri setleri, ham verilerin sırasıyla %10, %20, %30, %40 ve %50 oranında azaltılmasıyla oluşturulmuştur. Kırılmış veri setlerinin Degradasyon modelinde hesaplanan arıza zamanları, 2P Weibull analizi ile işlenmiş ve kontur grafiği oluşturulmuştur. Kontur grafiği, η (karakteristik ömür) ve β (şekil parametresi) değerlerinin %95 güven aralığındaki dağılımını göstererek modelin güvenilirliğini görsel olarak değerlendirmemizi sağlar. Bu grafik, özellikle modelin parametrelerinin veriye ne kadar uyum sağladığını göstermektedir. Bu aşamada, hızlandırılmış ömür testi uygulanarak, kırılmış verilerle elde edilen η değerlerinin, ham verilerle elde edilen η değerleriyle %95

güven aralığında benzer olduğunu ispatlamak amaçlanmıştır. Ayrıca, β parametresi, arıza fiziğini ve bataryanın arıza oranını temsil ettiğinden hem kırılmış hem de ham veriler için β parametresinin tutarlı bir şekilde elde edilmesi beklenmiştir. Bu doğrultuda, modelin doğruluğunu test etme süreci tamamlanmıştır. Modelin doğruluğu, kırılmış veri setleri ile yapılan analizlerle değerlendirilmiştir. Bu yaklaşım sayesinde, hızlandırılmış yaşlanma testlerinin batarya ömrü üzerindeki etkileri detaylı bir şekilde incelenmiştir.


2.4.2 Analiz sonuçları

Şekil 9, bataryaların zaman içindeki degradasyonunu ve test edilen Li-ion bataryalarının β (beta) ile η (eta) parametrelerini göstermektedir. Beta, bataryanın arızalanma hızını ve arıza fiziğini temsil eden önemli bir parametredir. Yüksek beta değeri, bataryanın hızla arızalanma eğiliminde olduğunu, düşük beta değeri ise daha stabil bir performans sergilediğini gösterir. Bu araştırma kapsamında elde edilen $\beta = 2.863$ değeri, bataryanın hızla kapasite kaybedeceğini ve daha dik bir arıza eğrisine sahip olacağını göstermektedir. Eta, bataryanın karakteristik ömrünü belirten bir parametre olup, kapasite kaybının zaman içinde nasıl değişeceğini gösterir. Spesifik olarak, eta değeri, numunelerin %63,2’sinin arızalanma zamanını ifade eder. Yüksek eta değeri, bataryanın daha uzun ömre sahip olduğunu, düşük eta değeri ise bataryanın daha kısa sürede arızalanacağını gösterir. Batarya 1 için elde edilen $\eta = 468,42$ çevrim, bataryanın kapasite kaybının bu çevrimden sonra belirgin şekilde hızlanacağı ve yaklaşık bu çevrimde arızalanma noktasına yaklaşacağı anlamına gelmektedir.

Results Report	
Report Type	Degradation Results
User Info	
Name	26029280 26029280
Company	
Date	5.04.2025
Parameters	
Distribution	Weibull 2P
Analysis	RRX
CB Method	FM
Ranking	MED
Beta	2,862932
Eta (cyc)	468,420398
LK Value	-18,682134
Rho	0,9997
Fail \ Susp	3 \ 0
LOCAL VAR/COV MATRIX	
Var-Beta=2,149311	CV Eta Beta=-21,143174
CV Eta Beta=-21,143174	Var-Eta=11755,672055


Şekil 9. Eta ve Beta parametreleri için analiz sonuçları

Şekil 10’daki grafikte, batarya degradasyonlarının zamanla nasıl değiştiği gösterilmektedir. Grafikte pembe renkli doğru, bataryanın arızalı kabul edileceği kritik kapasite seviyesini göstermekte olup, bu seviye 70 olarak belirlenmiş olsa da güven marjı bırakmak amacıyla çalışma kapsamında 80 olarak kabul edilmiştir. Grafikte görülen bataryaların sırasıyla 416, 546 ve 279 çevrimlerinde arızalanacağı modelde hesaplanmıştır.



Şekil 10. Ham veri degradasyon vs. zaman grafiği

Şekil 11’de, ham veri ve %10, %20, %30, %40, %50 kırma oranlarına sahip veri setlerinin Reliability vs Time grafiklerinin karşılaştırılması gösterilmektedir. Her bir veri seti için elde edilen beta (β) ve eta (η) değerleri de gösterilmiştir. Beta değerleri incelendiğinde, veri kırma oranı arttıkça beta değeri genellikle artmaktadır. Ham Veri ($\beta = 2.86$) ile %10 kırma ($\beta = 2.79$) değerinin birbirine yakın olduğu görülmekle birlikte %50 kırma ($\beta = 3.33$) değeri belirgin bir şekilde daha yüksek çıkmaktadır. Bu, veri setinde daha fazla kırma yapıldıkça bataryanın daha hızlı arızalanacağı ve kapasite kaybının daha hızlı gerçekleşeceği sonucuna ulaşılmaktadır; dolayısıyla yanılma payının artması beklenmektedir. Eta değeri incelendiğinde, kırma oranı arttıkça eta değeri azalmaktadır. Ham Veri ($\eta = 468.42$ çevrim) ile %10 kırma ($\eta = 452.42$ çevrim) arasındaki fark az olmakla birlikte, %50 kırma ($\eta = 365.73$ çevrim) değerinde belirgin bir azalma görülmektedir. Bu durum, kırma oranı arttıkça, bataryanın daha hızlı kapasite kaybı yaşayacağı değerleri üzerinden istatistiksel fark analizi yapılması gerektiğini göstermektedir.



Şekil 11. Tüm veri setleri reliability vs. zaman grafiği


2.5 Model doğrulama

Model doğrulama aşamasında, ReliaSoft yazılımı kullanılarak %10, %20, %30, %40 ve %50 kırılmış veri setleri ile ham veri seti üzerinden degradasyon modelinin hesapladığı arıza zamanları elde edilmiştir. Bu verilerle yapılan 2P Weibull analizi, Şekil 12’de gösterilmiştir.

State F or S	Time to F or S (cyc)	Subset ID 1
F	416,0612467	Battery - Sample 1
F	546,4098585	Battery - Sample 2
F	279,6521062	Battery - Sample 3


Şekil 12. Modelin hesapladığı arıza zamanı verilerinin 2P Weibull analizine aktarılması

Şekil 13’de, η (karakteristik ömür) ve β (şekil parametresi) değerlerinin %95 güven aralığındaki dağılımı gösterilmiştir. Bu grafik, özellikle modelin parametrelerinin ham veri ile benzer sonuçlar verdiğini göstermektedir. Hızlandırılmış ömür testi yapılması amaçlandığı için, kırılmış veri ile elde edilen η değerlerinin, ham verilerle elde edilen η değerleriyle benzerlik göstermesi sağlanmak istenmiştir. Ayrıca, β parametresi, arıza fizikini ve bataryanın arıza oranını temsil ettiğinden, β parametresinin hem kırılmış hem de ham veriler için benzer sonuçlar vermesi beklenmiştir.



Şekil 13. Kontur grafiğinde %50’ye kadar azaltılan verilerin durumu

Şekil 14’de verilerin %30’a kadar azaltılmasının beta ve eta değerleri açısından %95 güven aralığında ham verilerle istatistiksel olarak anlamlı bir fark yaratmadığı gösterilmiştir. Test süresindeki %30’luk azalış, tam döngü testi sonuçlarını doğru bir şekilde simüle etmektedir.



Şekil 14. %30'a kadar azaltılan veri setleri

Tablo 9'da Ham, %10 kırılmış, %20 kırılmış ve %30 kırılmış veri setlerinin %95 güven aralığında Weibull dağılımının karakteristik ömür parametresi olarak tanımlanan eta değerinin aralığı verilmektedir. Kapasite kaybının zamanla değişimini ilişkilendiren bu analizde, farklı veri setlerine ait eta aralıklarının %95 güven düzeyinde örtüşmesi, kapasite kaybı açısından gruplar arasında istatistiksel olarak anlamlı bir fark olmadığını göstermektedir. Bu durum, hipotez testi yaklaşımıyla değerlendirildiğinde, veri setleri arasında güvenilirlik açısından anlamlı bir fark olmadığı sonucunu desteklemektedir. Bu hesaplama, modelin tutarlılığını pekiştirmekte olup, %30'a kadar kısaltılmış ömür testinin Degradasyon modeli ile mevcut ömür testini simüle ettiğini, %95 güvenle doğrulamaktadır.

Confidence Limits:	Lower:	5,00%	Upper	95,00%
---------------------------	--------	-------	-------	--------

Estimates and Confidence Bounds for Distribution Parameters				
Data Set	Parameter	Estimate	Lower Limit	Upper Limit
0% (Raw Data)	Eta	468,42	320,10	685,46
10%	Eta	452,43	308,24	664,06
20%	Eta	421,49	295,52	601,15
30%	Eta	399,66	283,57	563,28

Tablo 9. Ham, %10 kırılmış, %20 kırılmış ve %30 kırılmış veri setlerinin %95 aralığındaki karakteristik ömür parametre (Eta) değerleri

3. Sonuçlar

Bu çalışma, batarya ömrü ve performansını analiz etmeye odaklanarak, ömür testlerini hızlandırmak amacıyla 2P Weibull modeli ve degradasyon modelini kullanarak bir yöntem önermektedir. Weibull modelinin β (şekil parametresi) ve η (karakteristik ömür) parametreleri, bataryaların arıza eğilimlerini ve kapasite kaybını doğru bir şekilde tahmin etmemizi sağlamıştır. Degradasyon modeli ise bataryaların zaman içinde kapasite kaybını doğrusal bir şekilde modelleyerek bu kaybın hızını belirlemiştir. Klasik ömür testleriyle karşılaştırıldığında, bu çalışmada önerilen yaklaşım, batarya ömrü testlerini %30 oranında kısaltarak benzer sonuçlara ulaşmayı başarmaktadır. Kırılmış veri setleri kullanılarak yapılan analizlerde, Weibull analizi, ham verilerin %10, %20, %30, %40 ve %50 oranında azaltılmasıyla gerçekleştirilmiştir. Bu süreçte, eta ve beta değerleri için istatistiksel fark testi uygulamak amacıyla bir kontur grafiği kullanılmıştır. Analiz sonuçlarına göre, verilerin %30'a kadar olan azaltılmış setlerinin, %95 güven aralığında ham veriden istatistiksel olarak farklı olmadığı görülmüştür. Bu bulgu, kırılmış veri setlerinin güvenilirliğini ve geçerliliğini doğrulamaktadır. Test sürelerinin %30 oranında kısaltılması, batarya ömrü tahminlerini daha kısa sürede elde edebilmemizi sağlamaktadır ve bu da endüstriyel süreçlerde zaman ve kaynak tasarrufu açısından önemli bir avantaj sunmaktadır. Ayrıca, bu yaklaşım veri analiz süreçlerinin optimizasyonunu desteklemektedir. Sonuç olarak, bu çalışma, batarya performans değerlendirmelerinde hem hızlı hem de güvenilir sonuçlar elde edilmesini sağlamaktadır.

Teşekkür

Araştırma çalışmalarımıza sağladığı test imkanları ve değerli katkıları için BEKO şirketine teşekkürlerimizi sunarız. Şirketimizin bu süreçteki desteği, elde ettiğimiz bulguların doğruluğunu ve güvenilirliğini önemli ölçüde artırmış, aynı zamanda araştırma sürecimiz boyunca sunduğu teşvik edici yaklaşım ve sürekli desteği, çalışmanın başarısında önemli rol oynamıştır.

Kaynaklar

- [1] K. C. Sezer ve G. Basmacı, "Şarj edilebilir pillere genel bakış", *Mühendislik Bilimleri ve Tasarım Dergisi*, cilt 10, no. 1, ss. 297–309, 2022.
- [2] J. Baker, "New technology and possible advances in energy storage," *Energy Policy*, cilt 36, no. 12, ss. 4368–4373, 2008.
- [3] L. Zheng, S. Zhang, H. Huang, R. Liu, M. Cai, Y. Bian, ... ve H. Du, "Artificial intelligence-driven rechargeable batteries in multiple fields of development and application towards energy storage," *Journal of Energy Storage*, cilt 73, 108926, 2023.
- [4] H. Cho, J. Kim, M. Kim, H. An, K. Min, ve K. Park, "A review of problems and solutions in Ni-rich cathode-based Li-

ion batteries from two research aspects: Experimental studies and computational insights," *Journal of Power Sources*, cilt 597, 234132, 2024.

[5] N. Sharmili, R. Nagi, ve P. Wang, "A review of research in the Li-ion battery production and reverse supply chains," *Journal of Energy Storage*, cilt 68, 107622, 2023.

[6] K. P. Lijesh ve M. M. Khonsari, "A thermodynamic approach for characterizing the degradation of Li-ion batteries," *Journal of Energy Storage*, cilt 82, 110565, 2024.

[7] R. Jilte, A. Afzal, S. A. Khan, M. Asif, E. P. Venkatesan, ve A. Munimathan, "Cooling performance of a Li-ion cylindrical battery pack with liquid circulating pipes embedded in phase change material," *Journal of Energy Storage*, cilt 87, 111335, 2024.

[8] Y. Li, X. Gao, H. Wang, G. J. Offer, S. Yang, Z. Zhao, ve M. Ouyang, "Direct venting during fast charging of lithium-ion batteries," *Journal of Power Sources*, cilt 592, 233926, 2024.

[9] W. Vermeer, G. R. C. Mouli, ve P. Bauer, "A comprehensive review on the characteristics and modeling of lithium-ion battery aging," *IEEE Transactions on Transportation Electrification*, cilt 8, no. 2, ss. 2205–2232, 2021.

[10] C. Kupper, B. Weißhar, S. Reißmann, ve W. G. Bessler, "End-of-life prediction of a lithium-ion battery cell based on mechanistic aging models of the graphite electrode," *Journal of The Electrochemical Society*, cilt 165, no. 14, ss. A3468–A3480, 2018.

[11] M. S. D. Darma, M. Lang, K. Kleiner, L. Mereacre, V. Liebau, F. Fauth, ... ve H. Ehrenberg, "The influence of cycling temperature and cycling rate on the phase specific degradation of a positive electrode in lithium ion batteries: A post mortem analysis," *Journal of Power Sources*, cilt 327, ss. 714–725, 2016.

[12] S. E. Li, B. Wang, H. Peng, ve X. Hu, "An electrochemistry-based impedance model for lithium-ion batteries," *Journal of Power Sources*, cilt 258, ss. 9–18, 2014.

[13] O. Mekan, M. Gossen, ve K. P. Birke, "Variation in capacity aging trend of lithium-ion cells regarding sudden death spread," *Energy Reports*, cilt 11, ss. 2003–2010, 2024.

[14] J. M. Reniers, G. Mulder, ve D. A. Howey, "Review and performance comparison of mechanical-chemical degradation models for lithium-ion batteries," *Journal of The Electrochemical Society*, cilt 166, no. 14, ss. A3189–A3200, 2019.

[15] M. Petit, E. Prada, ve V. Sauvant-Moynot, "Development of an empirical aging model for Li-ion batteries and application to assess the impact of Vehicle-to-Grid strategies on battery lifetime," *Applied Energy*, cilt 172, ss. 398–407, 2016.

[16] M. Schimpe, M. E. von Kuepach, M. Naumann, H. C. Hesse, K. Smith, ve A. Jossen, "Comprehensive modeling of temperature-dependent degradation mechanisms in lithium iron

phosphate batteries," *Journal of The Electrochemical Society*, cilt 165, no. 2, ss. A181, 2018.

[17] X. Han, M. Ouyang, L. Lu, J. Li, Y. Zheng, and Z. Li, "A comparative study of commercial lithium ion battery cycle life in electrical vehicle: Aging mechanism identification," *J. Power Sources*, vol. 251, pp. 38–54, Apr. 2014.

[18] Y. Li, W. Guo, D. I. Stroe, H. Zhao, P. K. Kristensen, L. R. Jensen, *et al.*, "Evolution of aging mechanisms and performance degradation of lithium-ion battery from moderate to severe capacity loss scenarios," *Chem. Eng. J.*, vol. 498, p. 155588, 2024.

[19] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications," *Journal of Power Sources*, vol. 241, pp. 680–689, Nov. 2013.

[20] Hu, X., Che, Y., Lin, X., & Onori, S. (2020). Battery health prediction using fusion-based feature selection and machine learning. *IEEE Transactions on Transportation Electrification*, 7(2), 382–398.

[21] S. S. Madani, Y. Shabeer, F. Allard, M. Fowler, C. Ziebert, Z. Wang, *et al.*, "A comprehensive review on lithium-ion battery lifetime prediction and aging mechanism analysis," *Batteries*, vol. 11, no. 4, p. 127, 2025.

[22] Y. Wu, H. Zhao, Y. Wang, R. Li, and Y. Zhou, "Research on life cycle SOC estimation method of lithium-ion battery oriented to decoupling temperature," *Energy Reports*, vol. 8, pp. 4182–4195, 2022.

[23] X. Ren, T. Sun, S. Mao, Y. Zheng, X. Han, and M. Ouyang, "Accelerated aging protocols design for Li-ion batteries based on equivalence of the degradation mechanisms," *J. Energy Storage*, vol. 99, p. 113386, 2024.

[24] S. Paarmann *et al.*, "Short-Term Tests, Long-Term Predictions – Accelerating Ageing Characterisation of Lithium-Ion Batteries," *Batteries & Supercaps*, vol. 7, no. 11, Art. no. e202300594, Nov. 2024.

[25] A. Lanubile, P. Bosoni, G. Pozzato, A. Allam, M. Acquarone, and S. Onori, "Domain knowledge-guided machine learning framework for state of health estimation in Lithium-ion batteries," *Communications Engineering*, vol. 3, no. 1, Art. no. 168, Nov. 2024.

[26] K. Fricke, R. Nascimento, M. Corbetta, C. S. Kulkarni, and F. Viana, "Accelerated life testing dataset for lithium-ion batteries with constant and variable loading conditions," *Int. J. Progn. Health Manag.*, vol. 14, no. 2, Dec. 2023, doi: 10.36001/ijphm.2023.v14i2.3587.

[27] R. Li, L. Bao, L. Chen, C. Zha, J. Dong, N. Qi, R. Tang, Y. Lu, M. Wang, R. Huang, K. Yan, Y. Su, and F. Wu, "Accelerated aging of lithium-ion batteries: Bridging battery aging analysis and operational lifetime prediction," *eTransportation*, vol. 17, p. 100194, 2023, doi: 10.1016/j.etrans.2023.100194.

[28] ReliSoft, *Reliability Analysis Software*. [Çevrimiçi].
Mevcut: <http://www.reliasoft.com>. [Erişim: Aralık 05, 2024].

[29] Cadex Electronics Inc., “Cadex C8000 Battery Analyzer.”
[Online]. Available: <https://www.cadex.com/products/c8000>.
[Accessed: Dec. 5, 2024].

Özgeçmişler



Cansu İçöz, 2019 yılında Yeditepe Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. Lisans eğitimi süresince kontrol sistemleri üzerine yoğunlaştı. Mezuniyetinin ardından, aynı yıl Beko Elektronik İşletmesi Test ve Sertifikasyon Merkezi'nde Proje Mühendisi olarak profesyonel kariyerine başladı. 2021 yılında Kalite Güvence Yöneticiliği birimine geçerek önce Uzman Mühendis, ardından Kıdemli Uzman Mühendis pozisyonlarında görev aldı. Bu süreçte kalite süreçleri konularında aktif rol üstlendi. Yüksek lisans eğitimini Yeditepe Üniversitesi Elektrik-Elektronik Mühendisliği programında tamamladı. Akademik çalışmalarında Lityum-iyon bataryalar üzerine odaklanarak, özellikle Batarya Yönetim Sistemleri (BMS) ve şarj tahmin algoritmaları kapsamında Kalman Filtreleme yöntemleri üzerine araştırmalar yürüttü. Şu anda, Beko Kurutma Makinesi İşletmesi bünyesinde kalite süreçleri alanında çalışmalarını sürdürmektedir.



Mehmet Aksoy, 1985 yılında Tekirdağ'da doğdu. 2010 yılında Hacettepe Üniversitesi Elektrik&Elektronik Mühendisliği bölümünden lisans derecesi ile mezun oldu. 2022 yılından itibaren Beko'da Merkez Arge Test & Sertifikasyon bölümünde Reliability Mühendisi olarak görev yapmaktadır. İlgi alanları arasında yenilenebilir enerji sistemleri, enerji depolama teknolojileri, lityum-iyon piller ve batarya yönetim sistemleri yer almaktadır.

Özgeçmişler



Çiğdem Ezgi Arer, 1994 yılında Türkiye’de doğdu. 2017 yılında Yıldız Teknik Üniversitesi Makine Mühendisliği bölümünden lisans derecesi ile mezun oldu.

Kariyerine Beko’da Kurutucu Ar-Ge departmanında Sistem Tasarım Mühendisi olarak başladı ve burada ısı pompalı kurutucuya yönelik bir patent yayımladı. 2019–2022 yılları arasında Küçük Ev Aletleri departmanında Ürün Değerlendirme Uzmanı olarak görev yaptı; bu süreçte güvenilirlik, Altı Sigma ve FMEA metodolojilerine odaklandı. Bu alanlardaki uzmanlığı sayesinde, şu anda Beko Genel Merkezi’nde Merkezi Kalite departmanında Kıdemli Lider olarak görev yapmaktadır. Bu görev kapsamında Güvenilirlik, Altı Sigma, FMEA ve İleri Veri Analitiği konularında eğitim, proje koçluğu ve yol haritası geliştirme faaliyetlerini yürütmektedir.

Çiğdem Ezgi Arer; Altı Sigma Kara Kuşak (Black Belt) ve Güvenilirlik Şampiyonu (Reliability Champion) gibi sertifikalara sahiptir. Güvenilirlik, Altı Sigma, FMEA ve İleri Veri Analitiği alanlarında çok sayıda projeye liderlik etmiştir. “Ticari Üründe Güvenilirlik ve Yaşam Döngüsü Yönetimi” başlıklı makalesi, TMMOB Makina Mühendisleri Odası tarafından yayımlanan Mühendis ve Makina dergisinde yer almıştır.

SCADA Sistemlerinde Dijital Dönüşüm: Endüstri 4.0 Çağında WinCC Unified

Digital Transformation In SCADA Systems: WinCC Unified In The Era of Industry 4.0

Ömer ÖNÜMLÜ¹, Birol ARIFOĞLU²
0009-0009-7128-8316 0000-0003-0323-5860

¹ Elektrik Mühendisliği Bölümü
Kocaeli Üniversitesi, Kocaeli, Türkiye
215102024@kocaeli.edu.tr

² Elektrik Mühendisliği Bölümü
Kocaeli Üniversitesi, Kocaeli, Türkiye
barif@kocaeli.edu.tr

Özet

Bu çalışma, Siemens firmasına ait WinCC Unified sisteminin modern SCADA çözümleri arasındaki konumunu ve sunduğu avantajları incelemektedir. Geleneksel SCADA sistemlerinin endüstrideki rolü tartışılarak, WinCC Unified'in yenilikleri web tabanlı mimari, entegrasyon kolaylığı ve güvenlik açısından değerlendirilmiştir.

Çalışmada karşılaştırmalı analiz yöntemi kullanılmış; WinCC Unified, Ignition, AVEVA System Platform, GE Digital iFIX, Rockwell FactoryTalk View ve Schneider EcoStruxure gibi SCADA sistemleriyle entegrasyon, güvenlik ve ölçeklenebilirlik kriterleri açısından karşılaştırılmıştır.

Bulgular, WinCC Unified'in IT/OT entegrasyonu, IEC 62443 uyumlu güvenlik özellikleri ve esnek yapısıyla rakiplerine kıyasla üstünlük sağladığını göstermektedir. Bununla birlikte, sistemin bazı endüstrilerdeki uygulama maliyetleri ve mevcut SCADA altyapılarıyla entegrasyonu gibi sınırlamaları da tartışılmıştır.

Anahtar Kelimeler: SCADA, WinCC Unified, Endüstriyel Otomasyon, HMI, Web Tabanlı SCADA

Abstract

This study examines the position and advantages of WinCC Unified system from Siemens among modern SCADA solutions. The role of traditional SCADA systems in the industry is discussed, and WinCC Unified's innovations are evaluated in terms of web-based architecture, ease of integration and security.

A comparative analysis method was used in the study; WinCC Unified was compared with SCADA systems such as Ignition, AVEVA System Platform, GE Digital iFIX, Rockwell FactoryTalk View and Schneider EcoStruxure in terms of integration, security and scalability criteria.

The findings show that WinCC Unified provides superiority over its competitors with its IT/OT integration, IEC 62443 compatible security features and flexible structure. However, the limitations of the system such as implementation costs in

some industries and integration with existing SCADA infrastructures are also discussed.

Keywords: SCADA, WinCC Unified, Industrial Automation, HMI, Web-Based SCADA

1. Giriş

SCADA (Supervisory Control and Data Acquisition) sistemleri, endüstriyel süreçlerin uzaktan izlenmesi ve kontrol edilmesini sağlayan kritik yazılım ve donanım bütünüdür. SCADA sistemleri, analiz ve kontrol için gerekli bilgileri sahadaki ekipmanlarla doğrudan iletişim kurarak büyük ölçekli üretim tesislerden enerji yönetimine kadar geniş bir yelpazede kullanılmaktadır [1]. Ancak son yıllarda, bulut bilişim [2] ve web tabanlı arayüzlerin gelişimi [3], SCADA sistemlerinin dönüşümüne ivme kazandırmıştır. Bu bağlamda, WinCC Unified platformu, modern SCADA çözümlerine yönelik yenilikçi bir yaklaşım sunmaktadır.

Bu çalışma, WinCC Unified'in teknik altyapısını, mevcut SCADA sistemleri ile karşılaştırmasını ve sunduğu avantajları ayrıntılı bir şekilde ele almaktadır. Ayrıca, sistemin potansiyel eksiklikleri ve gelecekteki endüstriyel uygulamalardaki rolü üzerine bir tartışma sunmaktadır.

2. Literatür Taraması

SCADA sistemleri üzerine yapılan akademik çalışmalar, bu sistemlerin güvenlik, entegrasyon, maliyet ve performans boyutlarını ele almaktadır [4]. Yapılan araştırmalara göre, geleneksel SCADA sistemlerinin en büyük eksikliklerinden biri, merkezi olmayan yapılarının güvenlik açıklarına neden olmasıdır [5]. Aynı zamanda, modern SCADA sistemleri, IT/OT entegrasyonu sayesinde daha ölçeklenebilir ve güvenli hale gelmektedir [6].


WinCC Unified özelinde yapılan çalışmalar, sistemin HTML5 tabanlı web erişimi sağlamanın, platform bağımsız çalışmasını kolaylaştırdığını göstermektedir. Ayrıca, kullanıcı

desti arayüzü ve düşük konfigürasyon süresi sayesinde işletmelerin daha hızlı bir geçiş süreci yaşadığı belirtilmektedir. Ek olarak, WinCC Unified'in siber güvenlik avantajları, IEC 62443 uyumluluğu ve bulut tabanlı SCADA çözümlerine entegrasyonu ile öne çıktığı görülmektedir [7].

3. WinCC Unified'in Teknik Özellikleri Ve Avantajları

WinCC Unified, modern üretim tesislerinin tüm ihtiyaçlarına cevap verebilecek şekilde tasarlanmış, web tabanlı yapısı sayesinde cihazdan bağımsız kullanım, ölçeklenebilirlik, entegrasyon kolaylığı ve modülerlik gibi esneklik ve çok yönlülük sunan bir SCADA platformudur [7]. HTML5 tabanlı teknolojisi sayesinde herhangi bir cihazdan erişim sağlanırken, SVG (Scalable Vector Graphics) desteği ile ölçeklenebilir grafikler ve dinamik arayüzler oluşturulmasına da olanak tanır [7]. Bu özellik, operatörlerin tüm görüntüleme cihazlarında kalite kaybı olmadan çalışabilmesini sağlar.

WinCC Unified, IT (Bilgi Teknolojileri) ve OT (Operasyonel Teknolojiler) arasındaki entegrasyonu güçlendiren modern bir SCADA çözümü sunmaktadır. Geleneksel otomasyon yapıları, "Yekpare Piramit" modeliyle yukarıdan aşağıya doğru yapılandırılmış, birbirinden bağımsız ve katı sistemlerden oluşmaktaydı. ERP, MES, SCADA ve PLC gibi sistemler arasında net bir hiyerarşi bulunurken, günümüz endüstriyel ortamında bu katmanlı yapı yerini IT ve OT arasında güçlü bir entegrasyona bırakmıştır. WinCC Unified, yatay ve dikey veri akışı sağlayarak sistemlerin eş zamanlı ve senkronize çalışmasına imkan tanımaktadır. Büyük veri (Big Data), Edge Computing ve bulut tabanlı çözümler ile ERP, SCADA ve MES gibi sistemlerin entegre çalışmasını sağlayarak, üretim süreçlerinin daha esnek, dinamik ve verimli hale gelmesini desteklemektedir. Bu dönüşüm, işletmelerin üretim süreçlerini optimize etmelerine ve rekabet avantajı kazanmalarına önemli katkılar sunmaktadır. Otomotiv endüstrisinde, ERP ve SCADA sistemleri arasında gerçek zamanlı veri paylaşımı ve izlenebilirlik, WinCC Unified'in IT/OT entegrasyon avantajlarını somutlaştırmaktadır.



Şekil 1: Geleneksel Yekpare Piramit Modeli ve Modern IT/OT Entegrasyonu (Traditional Monolithic Pyramid Model and Modern IT/OT Integration)

Ayrıca, WinCC Unified'in siber güvenlik konusunda sunduğu gelişmiş özellikler, sistemin rakiplerine kıyasla önemli bir avantaj sağlamasına neden olmaktadır. Geleneksel SCADA sistemlerinde Windows güvenlik duvarlarına bağımlılık büyük bir risk teşkil etmekte ve siber saldırılara açık hale getirmektedir [4]. WinCC Unified, IEC 62443 standardına tam

uyumlu olması sayesinde endüstriyel otomasyon ortamlarında yüksek güvenlik sunmaktadır. Özellikle yetkisiz erişimi önleme, gelişmiş şifreleme protokolleri ve düzenli güncelleme mekanizmaları ile güvenlik açıklarını en aza indirmektedir [6]. Örneğin kimya sektöründe, yüksek hassasiyetli üretim süreçlerinin korunması açısından güvenlik kritik bir rol oynamaktadır

WinCC Unified, web tabanlı mimarisi sayesinde masafüstü bilgisayarlardan, tabletlerden ve akıllı telefonlardan erişim imkanı sunarak sahada veya uzaktan çalışma durumlarında üretim süreçlerinin kesintisiz ve etkin bir şekilde yönetilmesini mümkün kılar. Örneğin enerji üretim tesislerinde, sahada çalışan operatörlerin sistemlere uzaktan erişimi büyük önem taşır. Farklı üretim süreçlerine kolayca entegre olabilmesiyle de dikkat çeken bu platform, mevcut otomasyon altyapısıyla uyumlu çalışabilir ve yeni teknolojilerin entegrasyonuna açık bir yapı sunar. Bu sayede işletmeler, mevcut sistemlerini koruyarak yenilikçi çözümleri hızlı bir şekilde uygulayabilirler.

WinCC Unified, Custom Web Control özelliği ile HTML5 ve JavaScript gibi modern web teknolojilerini kullanarak özel kontrol panelleri oluşturma olanağı sunar. Bu sayede işletmeler, üretim ve kontrol süreçlerine tam uyum sağlayan çözümler geliştirebilir. GraphQL desteği sayesinde hızlı ve dinamik veri sorgulamaları yapılabilirken, OpenPipe entegrasyonu ile ERP sistemleri arasında veri paylaşımı gerçekleştirilebilir [7]. Böylece işletmelerin operasyonel verimliliği artırılmış olur.

Open Development Kit (ODK) özelliği sayesinde, SCADA programlayıcıları projelerine özel işlevler ve uygulamalar ekleyebilir [7]. Bu, işletmelerin ihtiyaç duyduğu özelleştirilmiş çözümleri hayata geçirmelerine olanak tanır. Ayrıca, sistemin merkezi mimarisi tüm üretim sahası verilerini tek bir platformda toplayarak analiz edilmesini kolaylaştırır. Bulut entegrasyonu sayesinde, üretim verileri uzaktan erişilebilir hale gelir ve coğrafi olarak dağıtık tesislere sahip işletmeler için büyük avantajlar sağlar.

Sonuç olarak, WinCC Unified yalnızca bir SCADA platformu değil, aynı zamanda modern dijital dönüşümü destekleyen güçlü bir altyapı sunmaktadır. Endüstri 4.0 dönüşümüne uyum sağlayan bu sistem, işletmelere uzun vadeli rekabet avantajı kazandırırken, yapay zeka, makine öğrenimi ve dijital ikiz teknolojileri ile daha da entegre hale gelerek gelecekteki endüstriyel ihtiyaçlara yanıt verebilecek şekilde gelişmeye devam etmektedir.

4. Geleneksel Scada Sistemleri Ile Karşılaştırmalı Analiz

SCADA sistemleri, endüstriyel süreçlerin uzaktan izlenmesi ve kontrol edilmesini sağlayan merkezi bir yönetim altyapısıdır. İlk nesil SCADA sistemleri, lokal sunuculara bağımlı, sınırlı entegrasyon yeteneklerine sahip ve siber güvenlik açısından riskli çözümler olarak geliştirilmiştir. 2000'li yıllara kadar kullanılan geleneksel SCADA sistemleri, Windows tabanlı istemcilerle çalışan, genellikle Java veya Flash tabanlı grafik arayüzleri içeren ve erişim için VPN gerektiren kapalı sistemlerdir. Ancak, Endüstri 4.0 dönüşümüyle birlikte, sistemlerin daha esnek, bulut tabanlı ve siber güvenli hale gelmesi gerekliliği doğmuştur.

WinCC Unified platformu, geleneksel SCADA sistemlerinin kısıtlarını ortadan kaldıran modern bir SCADA çözümü olarak öne çıkmaktadır. Web tabanlı HTML5 arayüzü, güçlü IT/OT entegrasyonu ve siber güvenlik özellikleri sayesinde geleneksel SCADA mimarilerine kıyasla daha esnek ve ölçeklenebilir bir yapı sunmaktadır.

4.1. Geleneksel SCADA İle WinCC Unified Karşılaştırması

Yapılan karşılaştırmalarda kullanılan kriterler, endüstriyel SCADA çözümlerinin teknik ve operasyonel değerlendirme ölçütlerine dayanmaktadır. Modern SCADA sistemlerinin sadece veri toplama ve görselleştirme değil, aynı zamanda erişilebilirlik, siber güvenlik, entegrasyon, bakım kolaylığı ve ölçeklenebilirlik gibi alanlarda da yüksek performans göstermesi beklenmektedir. Bu bağlamda, karşılaştırma için seçilen kriterler hem akademik literatürde hem de uygulamalı mühendislik sahasında yaygın olarak benimsenen değerlendirme boyutlarına dayandırılmıştır [6], [7].

Arayüz ve erişim özellikleri, kullanıcı deneyimi ve sistemin farklı cihazlarla uyumu açısından belirleyici unsurlardır. Özellikle HTML5 gibi platform bağımsız teknolojilerin kullanımı, mobil ve uzaktan erişim imkanları açısından fark yaratmaktadır. Entegrasyon kabiliyeti, sistemin IT/OT ortamlarında diğer yazılım ve donanım çözümleriyle birlikte çalışma yeteneğini belirlerken, bu durum özellikle ERP, MES ve IoT altyapıları ile bütünlükli üretim tesisleri için kritik hale gelmektedir.

Siber güvenlik, SCADA sistemlerinin Endüstri 4.0 ortamındaki artan tehditlere karşı dayanıklılığını temsil eder. IEC 62443 gibi uluslararası standartlarla uyumluluk, gelişmiş şifreleme algoritmaları ve rol tabanlı erişim kontrolü gibi kriterler bu bağlamda önem kazanmaktadır. Bakım kolaylığı ise sistemin güncellenebilirliği, yedeklenebilirliği ve teknik servis ihtiyacının minimize edilmesi gibi yönlerden değerlendirilmiştir. Son olarak, ölçeklenebilirlik; sistemin küçük, orta ve büyük ölçekli işletmelerde uygulanabilirliğini ve genişlemeye açık yapısını temsil etmektedir.

Bu kriterler, hem Tablo 1'deki geleneksel SCADA sistemleri ile WinCC Unified arasındaki farkları, hem de Tablo 2'deki WinCC Unified ile diğer modern SCADA çözümleri arasındaki farklılıkları değerlendirmeye uygun şekilde yapılandırılmıştır. Özellikle çok kullanıcı, coğrafi olarak dağılmış ve yüksek güvenlik gerektiren tesislerde bu kriterler sistem seçiminde belirleyici olmaktadır. Tablo 1'de sunulan teknik özellik karşılaştırması, ilgili sistemin teknik özelliklerine dair sistem dökümanında belirtilen sistem yetenekleri esas alınarak hazırlanmıştır [7].

Tablo 1: Geleneksel SCADA ile WinCC Unified Karşılaştırması (Comparison of Traditional SCADA and WinCC Unified)

Özellik	Geleneksel SCADA	WinCC Unified
Arayüz	Masaüstü tabanlı, eski teknolojiler kullanır	✓ HTML5 tabanlı, modern grafikler ve platform bağımsız çalışır
Erişim	Lokal sunucu ve VPN bağlantısı gerektirir	✓ Web tarayıcısı üzerinden herhangi bir cihazdan erişim sağlar
Güvenlik	Siber saldırılara açık, güvenlik güncellemeleri düzensizdir	✓ IEC 62443 uyumlu, düzenli güncellenen güvenlik önlemleri içerir
Entegrasyon	IT/OT entegrasyonu sınırlı	✓ IoT, bulut, ERP ve MES sistemleriyle tam entegrasyon sağlar
Mobil Erişim	Mobil cihaz desteği yok veya sınırlı	✓ Tablet ve telefonlardan tam erişim sunar
Gerçek Zamanlı Veri Analizi	Genellikle manuel veri toplama gerektirir	✓ Gerçek zamanlı veri işiği ve büyük veri eği vardır
Ölçeklenebilirlik	Sınırlı, belirli donanımlara bağımlı	✓ Modüler ve esnek, her ölçekteki işletmeye uyum sağlar

Ayrıca, gıda üretiminde kullanılan küçük ve orta ölçekli SCADA altyapılarında sistemlerin hızlıca devreye alınabilir olması kritik önemdedir. Bu bağlamda, WinCC Unified'in modüler ve kullanıcı dostu yapısı, sınırlı kaynaklarla çalışan işletmelerin sistemlerini kısa sürede dijitalleştirmelerine ve süreçlerine entegre etmelerine olanak tanımaktadır.

4.2. WinCC Unified Sisteminin Farklı SCADA Sistemleri ile Karşılaştırması

SCADA sistemleri, endüstriyel süreçlerin izlenmesi ve kontrol edilmesi için kritik öneme sahiptir. Geleneksel SCADA sistemleri uzun yıllardır üretim, enerji, su yönetimi gibi bir çok endüstride kullanılmaktadır. Yukarıdaki açıklamada da geleneksel SCADA sistemleri ile WinCC Unified SCADA'nın bir karşılaştırılması yapılmıştır. Ancak Endüstri 4.0 ile birlikte web tabanlı, entegrasyonu kolay, güvenliği yüksek ve düşük bakım gerektiren SCADA çözümlerine olan ihtiyaç artmasından dolayı [2] da WinCC Unified sisteminin modern SCADA çözümleri arasındaki konumu incelenmiş ve Ignition, AVEVA System Platform, GE Digital iFIX, Rockwell FactoryTalk View ve Schneider EcoStruxure gibi alternatif SCADA sistemleriyle karşılaştırılmıştır. Karşılaştırma kriterleri, arayüz, erişim, entegrasyon yeteneği, siber güvenlik, bakım kolaylığı ve ölçeklenebilirlik başlıkları altında ele alınmıştır.

Tablo 2’deki ve Tablo 3’teki veriler her bir SCADA çözümüne ait teknik değerlendirmeler, resmi sistem dökümantasyonu temel alınarak birbiri ile karşılaştırılmıştır [7], [8], [9], [10].

Tablo 2: WinCC Unified Sisteminin Farklı SCADA Sistemlerinin Teknik Özellikleri Karşılaştırması (Comparison of Technical Features of WinCC Unified System with Different SCADA Systems)

Özellik	WinCC Unified (Siemens)	Ignition (Inductive Automation)	AVEVA System Platform	GE Digital iFIX	FactoryTalk View (Rockwell)	EcoStruxure (Schneider)
Arayüz	✔ HTML5 tabanlı, platform bağımsız	⚠ Web tabanlı, ancak bazı grafik eksiklikleri var	✗ Windows bağımlı, istemci gerektirir	✗ Eski sistemlere bağlı, modern grafik desteği zayıf	✗ Windows tabanlı, modern web desteği yok	⚠ Web tabanlı ancak grafik yetenekleri sınırlı
Erişim	✔ Web tarayıcısı üzerinden, platform bağımsız erişim	✔ Web ve mobil uyumlu	✗ Sadece Windows istemcilerle erişim	✗ Yerel istemci tabanlı, uzaktan erişim sınırlı	✗ VPN bağlantısı gerektiriyor, mobil destek zayıf	✔ Web tabanlı uzaktan erişim mevcut
Entegrasyon	✔ IoT, bulut, ERP/MES uyumu güçlü	✔ MQTT, OPC UA desteği var	⚠ ERP entegrasyonu var ama modern sistemlerle entegrasyonu zor	✗ PLC ve eski sistemlerle uyumlu ama modern entegrasyonlar sınırlı	✗ Rockwell PLC dışındaki sistemlerle entegrasyonu zor	⚠ IoT ve enerji yönetimi entegrasyonu var, ancak genel SCADA entegrasyonları sınırlı
Siber Güvenlik	✔ IEC 62443 uyumlu, gelişmiş şifreleme	⚠ Açık kaynak esneklik sağlıyor, ancak güvenlik kullanıcıya bağlı	✗ Windows güvenlik duvarlarına bağımlı, saldırılara açık	✗ Eski sistemlere bağlı olduğu için güvenlik açıkları olabilir	⚠ Rockwell sistemleri ile güvenli ama kapalı bir ekosistem	✔ Endüstriyel IoT güvenliği güçlü
Bakım Kolaylığı	✔ Merkezi yönetim, kolay güncelleme ve bakım	✔ Açık kaynak olduğu için esnek bakım seçenekleri var	✗ Bakım ve güncellemeler zor, eski sistemler için karmaşık	✗ Eski sistemlerle uyumlu olmasına rağmen bakım maliyetleri yüksek	✗ Büyük ölçekli sistemlerde bakım ve güncelleme zorlu	✔ Bulut tabanlı bakım desteği var
Ölçeklenebilirlik	✔ Küçük, orta ve büyük ölçekli işletmeler için ideal	⚠ Küçük ve orta ölçekli işletmeler için uygun, büyük ölçekli uygulamalarda performans sınırlı olabilir	✔ Büyük ölçekli endüstriyel uygulamalara uygun	⚠ Küçük ve orta ölçekli sistemler için yeterli ancak büyük ölçekli sistemlerde verimsiz	✔ Büyük ölçekli tesisler için optimize edilmiş	⚠ Orta seviyede, büyük ölçekli üretim için uygun değil

WinCC Unified, web tabanlı ve platform bağımsız yapısı sayesinde aynı sektördeki diğer firmaların yazılımlarına kıyasla önemli avantajlar sunmaktadır. Ignition haricindeki diğer SCADA sistemleri (AVEVA, iFIX, FactoryTalk), Windows tabanlı istemciler gerektirirken, WinCC Unified’in HTML5 tabanlı olması, kullanıcıların herhangi bir cihazdan erişim sağlamasına olanak tanımaktadır. Bu durum, işletmeler için esneklik ve mobil erişim açısından önemli bir avantaj sunmaktadır.

Bunun yanı sıra, IT/OT entegrasyonu açısından da WinCC Unified güçlü bir yapı sergilemektedir. IoT, ERP ve MES gibi sistemlerle kolay ve hızlı bir entegrasyon sunarken, AVEVA ve

GE iFIX gibi eski mimari sistemlerin entegrasyon süreci daha karmaşıktır ve kısıtlıdır.

WinCC Unified’in siber güvenlik konusunda IEC 62443 uyumluluğuna sahip olması, onu geleneksel SCADA çözümlerinden ayıran en önemli faktörlerden biridir. Ignition gibi açık kaynak tabanlı SCADA çözümlerinde güvenlik yönetimi tamamen kullanıcının sorumluluğuna bırakılmışken, GE iFIX ve AVEVA gibi çözümler ise Windows güvenlik duvarlarına bağımlıdır, bu da dış tehditlere karşı daha savunmasız hale gelmelerine neden olmaktadır [6].

Özellikle SCADA sistemlerine yönelik siber saldırılar her geçen gün artmaktadır ve bu durum, endüstriyel otomasyon

sistemlerinin sürekli güncellenen güvenlik protokollerine sahip olmasını zorunlu hale getirmiştir [4]. Bu bağlamda, WinCC Unified'in düzenli güvenlik güncellemeleri alması ve

gelişmiş yetkilendirme mekanizmalarına sahip olması, onu rakiplerinden bir adım öne çıkarmaktadır.

Tablo 3: SCADA Sistemlerinin Siber Güvenlik Karşılaştırması (Cyber Security Comparison of SCADA Systems)

Özellik	WinCC Unified	Ignition	AVEVA System Platform	GE iFIX	FactoryTalk View	EcoStruxure
IEC 62443 Uyumluluğu	✓ Evet	✗ Hayır	⚠ Kısmen	⚠ Kısmen	✗ Hayır	✓ Evet
Gelişmiş Şifreleme	✓ Evet (Endüstriyel üretim için optimize edilmiş)	⚠ Kullanıcıya bağlı	✗ Hayır	✗ Hayır	✗ Temel düzeyde	✓ Evet (IoT ve enerji yönetimi odaklı)
Yetkilendirme Mekanizmaları	✓ RBAC + Merkezi Üretim Yönetimi Yetkilendirmesi	⚠ Kullanıcı tarafından yönetilmeli	✗ Temel düzeyde	✗ Temel düzeyde	✗ Sınırlı	✓ Gelişmiş ancak IoT güvenliği odaklı
Güvenlik Güncellemeleri	✓ Düzenli olarak güncellenir, SCADA için optimize edilmiştir	✗ Kullanıcı güncellemelerine bağlı	✗ Windows güvenliğine bağlı	✗ Windows güvenliğine bağlı	✗ Windows güncellemeleriyle sınırlı	✓ Düzenli olarak güncellenir, IoT ve enerji yönetimi için optimize edilmiştir
Gerçek Zamanlı Veri İşleme & Olay Yönetimi	✓ Evet (SCADA için optimize edilmiş olay yönetimi)	⚠ Kullanıcı tarafından özelleştirilmeli	✗ Hayır	✗ Hayır	✗ Sınırlı	✗ Yok (IoT odaklı, SCADA için optimize edilmemiş)

WinCC Unified'in Ignition karşısındaki üstünlüklerinden biri, daha kapsamlı yerel destek ve uzun vadeli sürdürülebilirlik sunmasıdır. WinCC Unified sistemi, kurumsal kullanıcılar için uzun vadeli teknik destek ve sürekli güncellenen bir altyapı sağlamaktadır. Öte yandan, Ignition'ın açık kaynak tabanlı olması, kullanıcılara genişletilebilirlik sunsa da kurumsal destek ve standartlaştırılmış güncelleme süreçleri açısından dezavantaj yaratmaktadır.

Ayrıca, Ignition'ın güçlü bir yazılım altyapısı olmasına rağmen, WinCC Unified daha geniş çaplı endüstriyel entegrasyonlara olanak tanıyan gelişmiş nesne tabanlı modelleme ve otomasyon yetenekleri sunmaktadır. Özellikle büyük ölçekli üretim tesislerinde, merkezi kontrol ihtiyacı olan işletmeler için WinCC Unified daha uygun bir çözümdür.

Son olarak, WinCC Unified'in yüksek performanslı grafik motoru ve gelişmiş kullanıcı arayüzü, Ignition'ın sunduğu çözümlerden daha modern ve endüstriyel kullanıma uygun bir yapı sunmaktadır. Bu, özellikle operatörlerin üretim süreçlerini daha verimli yönetmesine olanak tanır ve kullanıcı deneyimini önemli ölçüde iyileştirir.

Yapılan karşılaştırmalı analiz, WinCC Unified'in mevcut SCADA çözümleri arasında en esnek, güvenli ve yüksek entegrasyon kapasitesine sahip sistemlerden biri olduğunu ortaya koymaktadır. Web tabanlı ve platform bağımsız olması, WinCC Unified'i rakiplerinden ayıran en belirgin özelliklerden biridir. HTML5 tabanlı yapısı sayesinde herhangi bir cihaza veya işletim sistemine bağlı kalmaksızın erişim sağlanabilmesi, kullanıcılar için önemli bir avantaj sunmaktadır. Geleneksel SCADA sistemleri hâlâ Windows tabanlı istemci yazılımlarına ihtiyaç duyarken, WinCC Unified doğrudan web tarayıcısı üzerinden yönetilebilmektedir.

Bunun yanı sıra, siber güvenlik konusundaki güçlü yapısı ve IEC 62443 uyumluluğu, özellikle endüstriyel otomasyon sistemlerinde güvenliği ön planda tutan işletmeler için önemli bir kriterdir. Açık kaynak kodlu SCADA çözümlerinde güvenlik yönetimi büyük ölçüde kullanıcıya bırakılırken, eski sistemlere bağımlı çözümler ise modern güvenlik tehditlerine karşı yeterli koruma sağlayamamaktadır. WinCC Unified, modern güvenlik protokollerini destekleyen mimarisi sayesinde, hem esneklik hem de güçlü bir güvenlik altyapısı sunmaktadır.

Özellikle Ignition ve AVEVA gibi SCADA çözümleri, güvenlik, hız ve entegrasyon kapasitesi gibi alanlarda

eksiklikler göstermektedir. Ancak, bu eksiklikler, daha küçük ve basit üretim tesislerinde daha az önemli hale gelmekte ve sistemler için daha düşük performans gereksinimlerinin olduğu senaryolarda göz ardı edilebilmektedir. Buna karşılık, büyük ölçekli ve kritik üretim hatlarında bu eksiklikler operasyonel aksaklıklara ve güvenlik açıklarına yol açabilir.

Ayrıca, IoT, ERP ve MES sistemleriyle entegre çalışabilmesi, sistemin ölçeklenebilirliğini ve geleceğe dönük uyumunu artırmaktadır. Geleneksel SCADA çözümlerinde entegrasyon süreçleri uzun ve karmaşık olurken, WinCC Unified, modern endüstriyel ekosistemlerle hızlı ve kolay entegrasyon sağlayarak verimliliği artırmaktadır. Özellikle, Endüstri 4.0 dönüşüm sürecinde işletmelerin farklı sistemler arasında kesintisiz veri akışı sağlaması kritik bir gereklilik haline gelmiştir ve WinCC Unified bu ihtiyacı başarıyla karşılamaktadır.

Bütün bu faktörler değerlendirildiğinde, WinCC Unified, sadece günümüzün değil, aynı zamanda geleceğin SCADA çözümlerinden biri olarak öne çıkmaktadır. Modern teknolojilere uyumlu mimarisi, gelişmiş güvenlik protokolleri ve geniş entegrasyon yetenekleri sayesinde, bu çalışmada SCADA sistemleri için en uygun seçenek olarak tercih edilmiştir.

5. Sonuç Ve Gelecek Çalışmalar

5.1. Sonuç

Bu çalışma, SCADA sistemlerinin dijital dönüşüm sürecindeki evrimini ve WinCC Unified platformunun bu süreçteki yerini çok boyutlu biçimde ele almıştır. Literatürde yer alan geleneksel SCADA sistemlerine kıyasla, WinCC Unified'in sunduğu HTML5 tabanlı mimari, platform bağımsızlığı, IT/OT entegrasyonu, gelişmiş güvenlik protokolleri ve merkezi yapılandırma özellikleri, Endüstri 4.0 ile uyumlu dijital üretim ortamları için önemli avantajlar sunmaktadır [2].

Yapılan karşılaştırmalı analizler ve örnek senaryolar, sistemin mobil erişim, esnek konfigürasyon yapısı ve çeşitli veri kaynakları ile entegrasyon gibi açılardan öne çıktığını göstermektedir. Enerji, otomotiv, gıda üretimi ve kimya sektörlerinden alınan saha örnekleri, WinCC Unified'in pratikteki uygulanabilirliğini ve operasyonel verimlilik üzerindeki etkisini desteklemektedir. Bu da sistemin yalnızca teorik değil, aynı zamanda saha gerçeklerine dayalı güçlü bir çözüm sunduğunu ortaya koymaktadır.

Bununla birlikte, WinCC Unified'in her koşulda ideal çözüm olduğu söylenemez. Özellikle yüksek lisanslama ve bakım maliyetleri, küçük ölçekli işletmeler için giriş engeli oluşturabilir. Ayrıca sistemin kurulum ve konfigürasyon süreçlerinin bazı rakiplerine kıyasla daha fazla eğitim ve teknik bilgi gerektirdiği görülmektedir. Platformun özelleştirme seçeneklerinin genişliği, ileri düzeyde kullanıcı

deneyimi olmayanlar için başlangıçta karmaşıklık yaratabilir. Siemens'in lisanslama politikası, kullanıcı sayısı ve bağlantı tipi gibi unsurlara göre değişen ücretlendirme yapısıyla esnek büyüme hedefleyen firmalar açısından ek maliyet yaratabilir. Bunlara ek olarak, bazı eski SCADA altyapılarına entegrasyon sırasında donanım veya yazılım uyumsuzlukları yaşanması da olasıdır. WinCC Unified'in ileri düzey teknolojik yapısı, çok eski protokolleri desteklemekte sınırlı kalabilir. Bu tür sınırlamaların göz önünde bulundurulması, kullanıcıların daha bilinçli tercihler yapmasını kolaylaştıracaktır.

Gelecekte yapılacak çalışmalar kapsamında, yapay zeka tabanlı kestirimci bakım sistemleri, 5G iletişim altyapıları ve dijital ikiz teknolojileri ile entegrasyon gibi alanlara odaklanılması önerilmektedir. Bu alanlarda geliştirilecek sistematik araştırmalar, SCADA çözümlerinin esnekliğini, kestirilebilirliğini ve akıllı otomasyon kapasitesini artırabilir. Ayrıca, sistemin farklı endüstrilerdeki performansını ölçen ampirik çalışmalar, web tabanlı SCADA çözümlerinin akademik literatürde daha sağlam bir konum edinmesine katkı sağlayacaktır.

Sonuç olarak, WinCC Unified platformu, SCADA sistemlerinin dijital dönüşüm sürecinde öne çıkan, teknik açıdan güçlü ve entegre çözümler sunan bir sistem olarak değerlendirilmektedir. Ancak, sistemin hem avantajları hem de sınırlamaları göz önünde bulundurularak, sektörel bazda özelleştirilmiş değerlendirmeler yapılması önemlidir. Bu bağlamda, bu çalışma WinCC Unified sistemine dair kapsamlı bir çerçeveye sunarak, hem WinCC Unified sistemi hem de web tabanlı SCADA yazılımları ile ilgili akademik ve endüstriyel paydaşlar için yön gösterici olmayı hedeflemektedir.

5.2. Gelecek Çalışmalar

Bu çalışma kapsamında WinCC Unified platformunun teknik yetenekleri, geleneksel SCADA sistemlerine kıyasla avantajları ve sektörel kullanımları detaylı bir şekilde ele alınmıştır. Ancak, SCADA teknolojilerinin sürekli gelişmesi ve dijital dönüşüm süreçlerinin hızlanması, bu alanda yeni araştırma konularının ortaya çıkmasına neden olmaktadır. Bu doğrultuda, genel olarak web tabanlı SCADA sistemlerine yönelik ilerleyen dönemlerde yapılacak araştırmalarda aşağıdaki başlıkların ele alınması önerilmektedir:

- Web Tabanlı SCADA Yazılımlarının Yapay Zeka ile Entegrasyonu: Endüstriyel otomasyon sistemlerinde, yapay zeka destekli kestirimci bakım ve otonom üretim süreçleri, gelecekteki önemli araştırma alanları arasında yer almaktadır. Web tabanlı SCADA yazılımlarının, yapay zeka ve makine öğrenimi algoritmalarıyla entegrasyonu, sistemlerin daha verimli hale gelmesini sağlayabilir. Bu entegrasyon, anomalilik tespiti, üretim hattı optimizasyonu ve enerji verimliliği analizleri gibi önemli fonksiyonların daha akıllı ve etkili hale gelmesini mümkün kılacaktır. Gelecekteki araştırmalar, SCADA

sistemlerinin yapay zeka tabanlı analizlerle entegrasyonunu ve bunun gerçek zamanlı karar destek sistemleri üzerindeki etkilerini derinlemesine incelemelidir. Bu çalışmalar, SCADA sistemlerinin sadece arızaların tespiti için değil, aynı zamanda üretim süreçlerinin optimize edilmesi ve enerji verimliliği sağlanması açısından da önemli katkılar sağlayacaktır.

- Web Tabanlı SCADA Sistemlerinde Siber Güvenlik Yaklaşımlarının Derinlemesine İncelenmesi: Web tabanlı SCADA sistemleri, kritik altyapılar için önemli bir güvenlik katmanı sağlamaktadır. Bu nedenle, bu sistemlerin siber saldırılara karşı dayanıklılıklarının artırılması gerekmektedir. Gelecekte yapılacak çalışmalarda, web tabanlı SCADA sistemlerinin güvenlik açıkları üzerine daha derinlemesine analizler yapılabilir. Bu bağlamda, IEC 62443 standardı çerçevesinde, bu tür sistemlerin siber tehditlere karşı korunma yöntemleri daha etkin bir şekilde araştırılmalıdır. Ayrıca, güvenlik yönetim stratejilerinin geliştirilmesi ve sistemlerin güvenlik düzeylerinin artırılması adına uygulanabilir çözümler önerilebilir. Özellikle, endüstriyel sistemlerdeki siber güvenlik tehditlerinin daha iyi tanımlanması ve bu tehditlere karşı proaktif güvenlik önlemlerinin alınması, gelecekteki araştırmaların önemli odak noktalarından biri olmalıdır.
- Dijital İkiz Teknolojisi ile Web Tabanlı SCADA Sistemlerinin Entegrasyonu: Dijital ikiz (Digital Twin) teknolojisi, üretim süreçlerinin simüle edilmesi ve gerçek zamanlı veri ile eşleştirilmesi açısından büyük bir potansiyel taşımaktadır. Web tabanlı SCADA sistemleri ile dijital ikiz teknolojisinin entegrasyonu, üretim süreçlerini daha dinamik ve verimli hale getirebilir. Gelecekte yapılacak çalışmalarda, dijital ikiz teknolojisinin web tabanlı SCADA sistemleriyle entegrasyonunun, özellikle süreç optimizasyonu üzerindeki etkileri derinlemesine incelenmelidir. Bu entegrasyon, üretim süreçlerini daha verimli hale getirebilir, enerji verimliliğini artırabilir ve olası arızaları proaktif bir şekilde tespit etme imkanı sunabilir. Dijital ikiz teknolojisi, fiziksel sistemlerin dijital kopyalarını oluştururken, gerçek zamanlı simülasyonlar ve performans izleme ile sistemlerin optimizasyonunu sağlayabilir. Gelecekteki araştırmalar, dijital ikiz teknolojisinin web tabanlı SCADA sistemlerine entegrasyonu ile elde edilebilecek performans kazançlarını ve gerçek zamanlı veri analizine katkılarını daha ayrıntılı bir şekilde incelemelidir.
- Web Tabanlı SCADA Sistemleri ve 5G Teknolojisi ile Gerçek Zamanlı Kontrol Mekanizmaları: 5G teknolojisinin düşük gecikme süreleri, web tabanlı SCADA sistemlerinin gerçek zamanlı veri işleme yeteneklerini önemli ölçüde artırabilir. 5G destekli sistemlerin web tabanlı SCADA sistemleriyle entegrasyonu, daha hızlı ve güvenilir veri iletimini mümkün kılabilir. Gelecekte yapılacak çalışmalarda, 5G

teknolojisinin web tabanlı SCADA sistemlerine entegrasyonu, özellikle gerçek zamanlı kontrol ve veri iletimi alanlarında derinlemesine incelenebilir. Düşük gecikmeli haberleşme altyapısı, gerçek zamanlı karar verme mekanizmalarıyla desteklendiğinde, web tabanlı SCADA sistemlerinin saha verilerini milisaniyeler içinde işlemesi ve uzaktan karar destek sistemleriyle etkileşime girmesi mümkün olacaktır.

- Farklı Endüstrilerde Web Tabanlı SCADA Sistemlerinin Performans Analizleri: Mevcut çalışmalar çoğunlukla SCADA sistemlerinin teknik yeteneklerine odaklanmaktadır. Ancak, web tabanlı SCADA sistemlerinin enerji yönetimi, su ve atık arıtma tesisleri, akıllı fabrikalar gibi farklı endüstrilerdeki uygulama performansının değerlendirilmesi büyük önem taşımaktadır. Gelecekte yapılacak çalışmalarda, web tabanlı SCADA sistemlerinin çeşitli endüstrilerdeki performans analizi, bu sistemlerin avantajlarını ve sınırlamalarını daha ayrıntılı bir şekilde belirlemeye olanak sağlayacaktır. Bu bağlamda, her bir endüstrinin özelliklerine göre, web tabanlı SCADA sistemlerinin adaptasyonunu ve verimlilik üzerindeki etkilerini araştırmak, sistemlerin kapsamlı değerlendirilmesi açısından büyük önem taşımaktadır.
- Büyük Veri ve Web Tabanlı SCADA Sistemlerinin Entegrasyonu: Büyük veri teknolojisinin gelişimi, web tabanlı SCADA sistemlerinin verimliliğini ve veri işleme kapasitelerini önemli ölçüde artırabilir. Özellikle endüstriyel alanlarda, büyük miktarda verinin hızlı bir şekilde işlenmesi ve analiz edilmesi, üretim süreçlerinin daha verimli hale gelmesini sağlayacaktır. Gelecekte yapılacak çalışmalar, büyük veri teknolojilerinin SCADA sistemlerine entegrasyonu üzerine yoğunlaşan araştırmalar yaparak, veri akışının hızlandırılmasını ve gerçek zamanlı analizlerle sistem performansının artırılmasını inceleyebilir. Büyük veri entegrasyonu, yalnızca veri toplama ve işleme süreçlerini hızlandırmakla kalmaz, aynı zamanda enerji verimliliği ve süreç optimizasyonu gibi alanlarda da önemli kazançlar sağlayabilir. Web tabanlı SCADA sistemlerinin büyük veri desteğiyle daha akıllı hale gelmesi, veri analitiği ve makine öğrenimi gibi teknolojilerle desteklenmesi, endüstriyel otomasyon sistemlerinin daha esnek ve daha hızlı olmasına olanak tanıyacaktır. Gelecekteki araştırmalar, büyük veri ile web tabanlı SCADA sistemlerinin entegrasyonu sonucunda elde edilebilecek performans kazançlarını ve veri analitiği süreçlerinin endüstriyel sistemlere katkılarını daha ayrıntılı bir şekilde incelemelidir.

Bu öneriler doğrultusunda yapılacak gelecek çalışmalar, hem web tabanlı SCADA sistemlerinin gelişimini destekleyecek hem de SCADA sistemlerinin Endüstri 4.0 çerçevesinde nasıl daha akıllı ve güvenli hale getirilebileceği konusunda yol gösterici olacaktır.

6. Kaynaklar

- [1] Elektrik Mühendisleri Odası (EMO), *Kontrol sistemleri - SCADA*, 2024. Erişim adresi: https://www.emo.org.tr/ekler/0f829170c36aaf4_ek.pdf
- [2] L. D. Xu, E. L. Xu ve L. Li, "Industry 4.0: State of the art and future trends", *International Journal of Production Research*, cilt 56, no. 8, ss. 2941-2962, 2018. Erişim adresi: <https://doi.org/10.1080/00207543.2018.1444806>
- [3] Abbas, H. A. (2011). *Efficient Web-Based SCADA System* (Yüksek lisans tezi). University of Connecticut. Erişim adresi: <https://arxiv.org/abs/1501.05725>
- [4] Yadav, G., & Paul, K. (2021). Architecture and security of SCADA systems: A review. *International Journal of Critical Infrastructure Protection*, 56, 100433. Erişim adresi: <https://doi.org/10.1016/j.ijcip.2021.100433>
- [5] Irmak, E., & Erkek, İ. (2018). Endüstriyel Kontrol Sistemleri ve SCADA Uygulamalarının Siber Güvenliği: Modbus TCP Protokolü Örneği. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji*, 6(1), 1-16. Erişim adresi: <https://doi.org/10.29109/http-gujsc-gazi-edu-tr.364411>
- [6] Bhamare, D., Zolanvari, M., Erbad, A., Jain, R., Khan, K., & Meskin, N. (2020). Architecture and security of SCADA systems: A survey. *arXiv preprint*. Erişim adresi: <https://doi.org/10.48550/arXiv.2002.04124>
- [7] Siemens AG, *SIMATIC WinCC Unified System Manual*, 2025. [Çevrimiçi]. Erişim Adresi: <https://support.industry.siemens.com/cs/document/109828368/> (Erişim Tarihi: Şubat, 2025).
- [8] Inductive Automation, *Ignition SCADA Technical Overview*, 2025. [Çevrimiçi]. Erişim: <https://docs.inductiveautomation.com/docs/8.1/intro> (Erişim Tarihi: Şubat, 2025).
- [9] AVEVA Group, *AVEVA System Platform: Industrial Automation & SCADA Solutions*, 2025. [Çevrimiçi]. Erişim: <https://docs.aveva.com/category/system-platform> (Erişim Tarihi: Şubat, 2025).
- [10] Rockwell Automation, *FactoryTalk View SE: Scalable HMI and SCADA Solutions*, 2025. [Çevrimiçi]. Erişim: https://literature.rockwellautomation.com/idc/groups/literature/documents/um/viewse-um006_-en-e.pdf (Erişim Tarihi: Şubat, 2025)

Özgeçmişler



Ömer Önümlü, 1986 yılında İzmir’de doğdu. Kocaeli Üniversitesi Elektrik Mühendisliği Bölümü’nden 2010 yılında mezun oldu. Lisans eğitimi sürecinde SCADA ve PLC programlama alanlarında projeler üzerinde çalışmış ve bu alandaki bilgi birikimini geliştirmiştir. Lisans bitirme tezi, hareket kontrol uygulamaları üzerine odaklanmış olup, bu çalışma endüstriyel otomasyon sistemlerine yönelik uygulamalı çözüm ve teknik gelişmeleri içermektedir. SCADA ve endüstriyel otomasyon sistemlerine olan ilgisi, akademik eğitimle başlamış, sonrasında profesyonel hayatında 15 yıllık bir deneyime dönüşmüştür. Bu süreçte, dünya çapındaki otomasyon firmalarında çalışarak sektördeki teknik bilgi ve becerilerini artırmış, endüstriyel otomasyon ve sistem entegrasyonu konularında derinlemesine deneyimler edinmiştir.



Dr. Birol Arifoğlu, 1968 yılında Yunanistan’da doğdu. Yıldız Teknik Üniversitesi Kocaeli Mühendislik Fakültesi Elektrik Mühendisliği bölümünden 1989 yılında bölüm birincisi olarak mezun oldu. 1989-1993 yılları arasında İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Kontrol ve Bilgisayar Mühendisliği Anabilim Dalı’ndan Yüksek Lisans derecesini aldı. 1993-1998 yılları arasında ise Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı’ndan Doktora derecesini tamamladı. 1990 yılından bu yana Kocaeli Üniversitesi Mühendislik Fakültesi Elektrik Mühendisliği Bölümü’nde öğretim üyeliği yapmaktadır. Araştırma alanları Güç Elektroniği Uygulamaları, Otomatik Kontrol, Elektrikli ve Otonom Araçlar, Robotik Uygulamaları ve Endüstriyel Otomasyon Sistemleri üzerinedir.

Bireylerin Çevresel Tutumlarını Tahminde Makine Öğrenmesi: ANOVA ve Ki-Kare Temelli Özellik Seçimi ile Algoritma Performanslarının Karşılaştırılması

Predicting Individuals' Environmental Attitudes Using Machine Learning: Comparison of Algorithm Performances with ANOVA and Chi-Square-Based Feature

Rukiye Uzun Arslan¹, İrem Şenyer Yapıcı², Fuat Alkan¹

 0000-0002-2082-8695  0000-0003-0655-340X  0000-0001-7914-2383

¹Elektrik-Elektronik Mühendisliği Bölümü

Zonguldak Bülent Ecevit Üniversitesi

rukiye.uzun@beun.edu.tr, fuatalkan_67@hotmail.com

²Bilgisayar Mühendisliği Bölümü

Zonguldak Bülent Ecevit Üniversitesi

senyerirem@gmail.com

Özet

Bu çalışma, bireylerin çevresel tutumlarının makine öğrenmesi (MÖ) yöntemleriyle tahmin edilmesine yönelik veri odaklı bir model geliştirmeyi amaçlamaktadır. Çalışmada, çevresel farkındalık düzeylerinin sınıflandırılmasına yönelik beş farklı MÖ algoritmasının (Destek Vektör Makineleri, Gradyan Artırma (GA), Çok Katmanlı Algılayıcı, Kuadratik Diskriminant Analizi ve Torbalama) performansı karşılaştırılmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek amacıyla tek yönlü varyans analizi (ANOVA) ve Ki-Kare Bağımsızlık Testi gibi istatistiksel yöntemler uygulanmıştır. Deneysel sonuçlar, ANOVA ve Ki-Kare tabanlı özellik seçimi süreçlerinin model başarımını artırmada etkili olduğunu göstermektedir. Özellikle GA algoritması, doğruluk, kesinlik ve F1 skoru bakımından diğer yöntemlere kıyasla üstün performans sergilemiştir. Elde edilen bulgular, MÖ algoritmalarının çevresel tutumların modellenmesi ve tahmin edilmesinde güçlü bir analitik çerçeve sunduğunu ortaya koymaktadır. Çalışma, çevresel farkındalık düzeylerinin veri odaklı yöntemlerle değerlendirilmesinin, sürdürülebilir çevre politikalarının geliştirilmesine ve bireylerin çevre bilincinin artırılmasına katkı sağlayacağını ortaya koymaktadır. Anahtar kelimeler: çevresel tutum, özellik seçimi, makine öğrenmesi, sürdürülebilirlik

Abstract

This study aims to develop a data-driven model to predict individuals' environmental attitudes based on machine learning (ML) algorithms. The study compares the performance of five different ML algorithms—Support Vector Machines, Gradient Boosting (GB), Multilayer Perceptron, Quadratic Discriminant Analysis, and Bagging—in classifying environmental awareness levels. During the model

development process, statistical methods such as one-way analysis of variance (ANOVA) and the Chi-Square Independence Test were applied to assess the impact of variables on classification accuracy. Experimental results indicate that ANOVA- and Chi-Square-based feature selection processes effectively enhance model performance. In particular, the GB algorithm outperforms others in terms of accuracy, precision, and F1 score. The findings demonstrate that ML algorithms provide a robust analytical framework for modelling and predicting environmental attitudes. This study highlights the significance of evaluating environmental awareness levels through data-driven approaches, contributing to the development of sustainable environmental policies and the enhancement of individuals' environmental consciousness.

Keywords: environmental attitude, feature selection, machine learning, sustainability

1. Giriş

Çevre, ekosistemlerin doğal işleyişini, biyolojik çeşitliliği ve yaşamın sürdürülebilmesi için gerekli kaynakları kapsayan bütünsel bir yapıdır. Ancak insan faaliyetleri, bu dengenin bozulmasına yol açarak çevreyi benzeri görülmemiş bir tehdit altına sokmuş ve çevre sorunlarını küresel bir krize dönüştürmüştür. Bu krizin temel nedenleri arasında bilinçsiz bireysel tutumlar, sanayileşmenin hızlanması, doğal kaynaklara erişimin kolaylaşması ve kontrolsüz kentleşme yer almaktadır [1, 2]. Bilimsel ve teknolojik gelişmeler yaşam standartlarını artırırken çevresel dengede ciddi bozulmalara yol açmış, nüfus artışıyla birlikte çevre kirliliği ve ekosistemler üzerindeki baskı giderek artmıştır. Bu bağlamda, çevresel sorunların önüne geçebilmek için küresel iş birliğinin güçlendirilmesi, sürdürülebilir kalkınma ilkelerinin benimsenmesi ve çevre dostu yaşam biçimlerinin teşvik

edilmesi gerekmektedir [3, 4]. Ancak, bu önlemler yeterince uygulanmadığında çevresel bozulma kaçınılmaz hale gelmekte, ekosistemlerin dengesi bozulmakta ve canlıların yaşam kalitesi olumsuz etkilenmektedir. Bu durum, uzun vadeli çevre sorunlarının ortaya çıkmasına neden olmaktadır. Özellikle, doğal sistemlere yapılan bilinçsiz müdahaleler, ekosistemlerin dengesini bozarak çevresel bozulmayı daha da derinleştirmekte ve ekosistemlerin kendini yenileme kapasitesinin azalmasına yol açmaktadır [5]. Ekolojik sistemlerde meydana gelen bu tahribat, sadece doğal yaşamı değil, insan sağlığını ve ekonomik faaliyetleri de olumsuz etkilemektedir. Bu nedenle, çevresel sürdürülebilirliği sağlamak ve ekosistemlerin kendini koruma ve yenileme kapasitesini artırmak amacıyla çevre bilinci yüksek, çevresel sorunlara duyarlı ve hem teorik hem de uygulamalı çalışmalara katkı sunabilecek bireylerin yetiştirilmesi büyük önem taşımaktadır.

Bu doğrultuda, çevre eğitimi, bireylerin çevresel farkındalık kazanmasını sağlamak, doğaya duyarlı davranışları teşvik etmek ve çevre sorunlarının çözümüne yönelik etkin stratejiler geliştirmelerine katkıda bulunmak amacıyla temel bir unsur olarak öne çıkmaktadır. Çevre eğitimi, bireylerin ekosistemlerin işleyişini anlamalarını sağlarken, aynı zamanda sürdürülebilir çözümler üretebilmeleri için gerekli bilgi, beceri ve değerleri kazanmalarına da olanak tanımaktadır [6]. Böylece, çevreye duyarlılığı yüksek bireylerin yetiştirilmesi desteklenmekte ve çevresel sorunların çözümüne uzun vadeli katkılar sağlanmaktadır. Günümüzde, çevresel sorunların yönetimi ve sürdürülebilir çözümler üretilmesi noktasında yalnızca bireysel farkındalık ve eğitim yeterli olmamakta, aynı zamanda veri odaklı yaklaşımlar da büyük bir önem kazanmaktadır. Bu bağlamda, makine öğrenimi (MÖ) gibi ileri teknoloji yöntemleri, büyük ölçekli çevresel verileri analiz ederek çevresel süreçlerin daha iyi anlaşılmasına ve etkin politika geliştirilmesine katkı sağlamaktadır. Özellikle, hava ve su kirliliği tahmini, ekosistem değişikliklerinin izlenmesi ve enerji verimliliğinin artırılması gibi alanlarda MÖ modelleri, karar destek sistemlerine entegre edilerek daha doğru ve hızlı çözümler sunmaktadır.

Literatürde yapılan çalışmalar incelendiğinde, çevresel tutumların sınıflandırılmasına yönelik MÖ tabanlı yaklaşımların giderek yaygınlaştığı görülmektedir. Bu çalışmalar, bireylerin çevresel farkındalığını ve tutumlarını nesnel verilerle analiz ederek, sürdürülebilir çevre politikalarının geliştirilmesine katkıda bulunmayı amaçlamaktadır. Özellikle, anket verileri ve diğer çevresel değişkenler kullanılarak gerçekleştirilen MÖ uygulamaları, bireylerin çevreye yönelik eğilimlerini modellemek ve gelecekteki çevresel davranışları öngörmek için güçlü bir araç olarak öne çıkmaktadır. Bu doğrultuda, MÖ algoritmaları çevresel konuların analiz edilmesi ve çevresel tutumların sınıflandırılması süreçlerinde yaygın olarak kullanılmaktadır. Beiser-McGrath ve Huber (2018), bireylerin iklim değişikliği ve çevresel bozulmaya yönelik tutumlarını tahmin edebilmek amacıyla psikolojik ve demografik faktörlerin önemini değerlendirmiştir. Çalışmalarında, Çin, İsviçre ve ABD’de gerçekleştirilen saha araştırmalarından elde edilen veriler kullanılarak Rastgele Orman (RO) algoritması uygulanmıştır. Sonuçlar, gelecek sonuçları dikkate alma ölçeğinin çevresel tutumların tahmininde güçlü bir gösterge olduğunu ortaya koymuştur. Ayrıca, geleneksel açıklayıcı değişkenler olan gelir ve eğitimin, çevresel tutumları tahmin etme gücünün


daha sınırlı olduğu tespit edilmiştir [7]. Değirmenci (2024) bireylerin çevresel tutumlarını k en yakın komşu (kNN), karar ağacı (KA) ve destek vektör makineleri (DVM) olmak üzere üç farklı MÖ algoritmasıyla analiz etmiştir. Gerçekleştirilen çalışmada algoritmalara özgü hiperparametre optimizasyonu, kapsamlı Grid Search ve 10 kat çapraz doğrulama ($k = 10$) ile gerçekleştirilmiştir. Elde edilen bulgular en yüksek performansın DVM algoritmasıyla (doğruluk = 0,9576, F1 skoru = 0,9615, hassasiyet = 0,9576, duyarlılık = 0,9670) elde edildiği ortaya konulmuştur [8]. Choudhury ve arkadaşları (2024), MÖ algoritmalarını kullanarak tüketicilerin yeşil satın alma niyetini tahmin etmeyi amaçlamıştır. 310 katılımcıdan toplanan verilerle RO, KA, kNN, DVM, Gradyan Artırma (GA) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost) algoritmalarıyla yapılan analizlerde, yeşil özdeşleşme, çevresel bilinç, çevresel bilgi ve sosyal medyanın etkili faktörler olduğu belirlenmiştir. Çalışmada kullanılan algoritmalar arasında RO modeli, %83 doğruluk ve 0,84 alıcı karakteristik eğrisinin altındaki alan (AUC-ROC) değeriyle en yüksek başarıyı göstermiştir [9]. Köklü ve Sulak (2024), bireylerin çevresel tutumlarını sınıflandırmak amacıyla çeşitli yapay zeka algoritmalarını kullanarak bir analiz gerçekleştirmiştir. Çalışmada, 384 katılımcıdan elde edilen ve 37 değişkenden oluşan bir çevresel tutum veri kümesi kullanılmıştır. Sınıflandırma işlemi için Lojistik Regresyon (LR), DVM ve KA algoritmaları uygulanmıştır. Sonuçlara göre, LR modeli %94,53, DVM modeli %92,96 ve KA modeli %82,55 doğruluk oranı ile başarılı sınıflandırma performansı sergilemiştir. Elde edilen bulgular, çevresel tutumların analizinde yapay zeka tabanlı sınıflandırma yöntemlerinin etkili bir şekilde kullanılabileceğini göstermektedir. Ayrıca, veri kümesinin genişletilmesi ve sınıfların dengeli dağıtılması gibi faktörlerin sınıflandırma başarısını artırabileceği vurgulanmaktadır [3]. Amangeldi ve arkadaşları (2024), 2014-2023 yılları arasındaki sosyal medya verilerini inceleyerek çevresel konulara dair kamuoyu duygusu ve emosyonlarını analiz etmiştir. Twitter, Reddit ve YouTube gibi üç büyük sosyal medya platformundan toplanan veriler, noktasal karşılıklı bilgi (Pointwise Mutual Information, PMI) algoritması kullanılarak değerlendirilmiştir. Çalışmanın bulguları, çevreyle ilgili paylaşımlarda negatif duyguların baskın olduğunu, iklim değişikliği, hava kalitesi, emisyonlar, plastik ve geri dönüşüm gibi konuların öne çıktığını göstermektedir. Ayrıca, korku, güven ve beklenti gibi duyguların en yaygın şekilde ifade edilen duygular olduğunu ortaya koymaktadır. Çalışma, her platformun kullanıcı etkileşimi ve duygusal yansımaları arasında farklar olduğunu; Twitter ve YouTube’un genellikle negatif, Reddit’ in ise zamanla artan olumlu paylaşımlar gösterdiğini vurgulamaktadır [10]. Takshe ve arkadaşları (2023) Birleşik Arap Emirlikleri’ndeki üniversite öğrencileri arasında çevre dostu davranışları etkileyen faktörleri incelemişlerdir. Çalışma, çevresel sürdürülebilirliğin tehdit altında olduğu bir dönemde, öğrencilerin çevreye yönelik tutum ve davranışlarını etkileyen ana faktörleri keşfetmiştir. Çalışmanın bulguları, çevre bilincini artırmanın ve çevre dostu davranışları teşvik etmenin, sadece eğitimle değil, aynı zamanda ekonomik teşvikler ve doğrudan deneyimlerin de etkili olabileceğini göstermektedir. Çalışma, çevre bilincini artıran müdahalelerin, bireylerin tutumlarını şekillendirerek daha sürdürülebilir davranışlar geliştirmelerine yardımcı olabileceğini ortaya koymuştur [11]. Wang ve arkadaşları

(2022) üniversite öğrencilerinin çevreye duyarlı davranışlarını tahmin etmek amacıyla MÖ tabanlı bir KA modeli geliştirmişlerdir. Guangdong Eyaleti'nden 334 üniversite öğrencisinin katılımıyla gerçekleştirilen çalışmada, çevresel sorumluluk bilinci, yenilikçi davranışlar ve algılanan davranışsal kontrolün çevresel davranışın en güçlü belirleyicileri olduğu ortaya konulmuştur. MÖ algoritmalarının veri madenciliği süreçlerinde sunduğu yüksek tahmin doğruluğundan faydalanan bu araştırma, KA modelinin çevreye duyarlı davranışların öngörülmesinde etkili bir yöntem olduğunu göstermiştir [12]. Lou ve arkadaşları (2022) çevre koruma önceliğini ekonomik büyümenin önüne koymayı öngören bir model geliştirmek için makroekonomik, demografik ve psikolojik değişkenleri içeren bir MÖ temelli bir yaklaşım kullanmışlardır. RO algoritması ile yapılan analizlerde, sekiz değişkenin en güçlü öngörücüler olduğu belirlenmiş ve önerilen model %34,15 hata oranıyla başarılı bir performans sergilemiştir [13]. Li ve arkadaşları (2022) Çin'deki kamu firmalarının çevre koruma konusundaki tutumlarını analiz etmek için duygu analizi ve RO modellerini kullanmıştır. 2018-2021 yılları arasında yatırımcı-firma soru-cevap kayıtlarını toplayarak karbon ve çevreyle ilgili metinleri çıkarmış ve doğal dil işleme teknikleriyle firma düzeyindeki tutumları değerlendirmişlerdir. Çalışma, COVID-19 pandemisi ve çevre politikalarının firmaların karbon azaltımı konusundaki tutumlarını önemli ölçüde etkilediğini göstermiştir. Ayrıca, firmaların çevresel tutumlarında sektörler arası farklılıkların belirgin olduğu ve finansal performansın da tutumlar üzerinde etkili olduğu tespit edilmiştir. Model değerlendirmeleri sonucunda, RO algoritmasının firma tutumlarını tahmin etmede en iyi performansı gösterdiği ve en düşük hata oranına (karekök ortalama kare hatası = 10,98) sahip olduğu belirlenmiştir [14].

Literatürdeki bu çalışmalar, bireylerin çevresel farkındalık düzeylerinin değerlendirilmesi ve çevre dostu davranışlarının tahmin edilmesi konusunda MÖ algoritmalarının etkili olduğunu ortaya koymaktadır. Ancak, bu alandaki çalışmaların hâlâ gelişim aşamasında olduğu, farklı MÖ algoritmalarının karşılaştırmalı performans analizine yönelik araştırmaların sınırlı olduğu görülmektedir. Bu doğrultuda gerçekleştirilen bu çalışmada, bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla veri odaklı bir model geliştirilmiş ve çevresel tutum düzeylerinin sınıflandırılmasında beş farklı MÖ algoritmasının performansı karşılaştırılmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek amacıyla tek yönlü varyans analizi (ANOVA) ve Ki-Kare Bağımsızlık Testi uygulanmıştır. Bu aşama, modelin doğruluk oranını artırmak ve gereksiz değişkenlerin olası etkilerini en aza indirmek amacıyla gerçekleştirilmiş olup, çıkarılan anlamlı özellikler temel alınarak sınıflandırma işlemi yürütülmüştür. Bu sayede, çevresel tutumların sınıflandırılmasında daha güvenilir ve karşılaştırılabilir sonuçların elde edilmesi hedeflenmiştir.

2. Materyal ve Metot

Çalışma kapsamında bireylerin çevresel farkındalık ve tutum düzeylerini sınıflandırmak için geliştirilen modelin akış şeması Şekil 1'de sunulmaktadır.



Şekil 1: Önerilen modelin akış diyagramı.

2.1. Veri Seti

Bu çalışmada, Koklu ve Sulak tarafından açık erişime sunulan "Environmental Attitude Dataset" başlıklı veri seti kullanılmıştır. Söz konusu veri seti, Türkiye'de ikamet eden bireylere yönelik çevrimiçi uygulanan bir anket yoluyla elde edilmiştir. Veri toplama süreci, yaşları 18 ile 45 arasında değişen 177 erkek ve 207 kadın olmak üzere toplam 384 katılımcının katılımıyla gerçekleştirilmiştir. Veri seti, bireylerin çevresel sorumlu davranışlarını etkileyen faktörlerin analizine olanak tanıyacak şekilde yapılandırılmış olup, çevresel farkındalık ve tutum düzeylerini değerlendirmeye yönelik 37 farklı değişken içermektedir. Bu değişkenler, çevresel farkındalık, çevre dostu davranış kalıpları, sürdürülebilirlik bilinci ve çevresel sorumluluk düzeyi gibi çok boyutlu kavramları kapsamaktadır [3].

2.2. Veri Ön işleme

MÖ tabanlı karar destek sistemlerinin geliştirilmesinde, verinin doğru ve etkin bir biçimde işlenmesi hayati önem taşımaktadır. Bu doğrultuda, veri ön işleme süreci, modelin başarımını doğrudan etkileyen temel adımlardan biri olup eksik verilerin giderilmesi, hatalı veya gürültülü verilerin temizlenmesi, verinin normalleştirilmesi ve özellik seçimi tekniklerinin uygulanması gibi çeşitli aşamaları kapsamaktadır. Veri ön işleme, modelin doğruluk oranını artırarak daha güvenilir ve kesin tahminler yapılmasına katkı sağlamaktadır. Çalışmada bu amaç doğrultusunda, veri setindeki anlamlı özellikler ANOVA ve Ki-Kare testleri ile belirlenmiştir. Özellik seçimi sürecinde, her iki yöntem bağımsız olarak uygulanmış ve her test sonucunda ayrı veri setleri oluşturulmuştur. Modelin hedef değişken tahmin

performansını artırmak amacıyla her bir yöntemde on anlamlı özellik çıkarılmıştır. Çıkarılan bu özellikler, modelin sınıflandırma başarısını iyileştirmek amacıyla analiz sürecine entegre edilmiştir.

Özellik seçimi sürecinin tamamlanmasının ardından, çıkarılan özellikler kullanılarak oluşturulan veri setlerine StandardScaler yöntemi uygulanmıştır. Bu işlem ile tüm değişkenlerin aynı ölçek aralığında standardize edilmesi sağlanarak, model üzerindeki değişkenlerin etkilerinin dengelenmesi ve sınıflandırma performansının iyileştirilmesi hedeflenmiştir.

2.3. Makine Öğrenme Algoritmaları

Gerçekleştirilen bu çalışmada bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla DVM, GA, Çok Katmanlı Algılayıcı (ÇKA), Kuadratik Diskriminant Analizi (KDA) ve Torbalama (Bagging) olmak üzere beş farklı MÖ algoritmasından yararlanılmıştır. İlgili algoritmaların temel çalışma prensipleri aşağıda açıklanmaktadır:

DVM, veri noktalarını maksimum marjın sağlayacak şekilde bir hiperdüzlem ile ayırmayı amaçlayan güçlü bir MÖ algoritmasıdır. Bu yaklaşım, farklı sınıflara ait veri noktalarının birbirinden en uzak şekilde konumlanmasını sağlayarak modelin genelleme performansını artırmaktadır. Böylece DVM, yalnızca eğitim verileri üzerinde etkili olmakla kalmayıp, daha önce karşılaşmamış örnekler üzerinde de yüksek doğrulukla tahminlerde bulunabilmektedir. Bu avantaj, modelin aşırı öğrenmeden kaçınmasına ve farklı veri kümeleriyle karşılaştığında tutarlı sonuçlar üretmesine olanak tanımaktadır. Ancak, bazı veri kümelerinde sınıflar doğrusal olarak ayrıl原因amamaktadır. Bu durumda, DVM'in esnekliği, veri noktalarını daha yüksek boyutlu bir uzaya projekte ederek ayrıştırılabilir hale getiren çekirdek (kernel) fonksiyonları sayesinde artmaktadır. Ayrıca, modelin karmaşıklığı düzenleme (regularization) parametresi ile kontrol edilerek aşırı öğrenme riski minimize edilebilmektedir. Bu özellikleri sayesinde DVM, doğrusal ve doğrusal olmayan problemlerde etkin bir şekilde kullanılmaktadır [15]-[17].

GA, birçok zayıf sınıflandırıcının bir araya gelerek güçlü bir tahmin modeli oluşturan etkili bir topluluk öğrenme algoritmasıdır. Temel olarak KA algoritmasının prensiplerine dayanan bu yaklaşım, her yeni KA'nın, önceki ağaçların hata oranlarını minimize edecek şekilde oluşturulmasına dayanır. Bu süreçte, modelin genel başarımını artırmak amacıyla yanlış sınıflandırılan örnekler üzerinde yoğunlaşmakta ve hata oranı kademeli olarak azaltılmaktadır. GA algoritması, zayıf sınıflandırıcıları ardışık olarak geliştirerek daha dayanıklı ve genellenebilir bir model elde etmektedir. Bu iyileştirme süreci, modelin doğruluğunu artırmak için çeşitli ince ayar ve optimizasyon tekniklerini içermektedir. Bunun yanı sıra, GA, eksik veri yönetimi konusunda güçlü bir yetkinliğe sahiptir. Eksik verilerin neden olduğu belirsizlikleri azaltmak adına gelişmiş stratejiler kullanarak veri temizleme süreçlerine olan bağımlılığı en aza indirmektedir. [16]-[18].

ÇKA, denetimli öğrenme yaklaşımlarında yaygın olarak kullanılan, ileri beslemeli bir yapay sinir ağı modelidir. Bu model, giriş katmanından başlayarak bir veya daha fazla gizli katman aracılığıyla çıkış katmanına ulaşan çok katmanlı bir mimariye sahiptir. Her katmandaki nöronlar, önceki katmandan gelen girdileri belirli ağırlıklarla çarparak ve

doğrusal olmayan aktivasyon fonksiyonları aracılığıyla işleyerek bir sonraki katmana iletmektedir. Modelin öğrenme süreci, hata fonksiyonunun geri yayılım algoritması kullanılarak minimize edilmesine dayanmaktadır. Bu süreçte, türev tabanlı optimizasyon yöntemleriyle modelin ağırlık parametreleri güncellenmekte ve böylece modelin doğruluk oranı iyileştirilmektedir. Söz konusu optimizasyon süreci, modelin yüksek boyutlu ve doğrusal olmayan veri örüntülerini öğrenme yetisini artırarak daha genel ve genellenebilir tahminler üretmesine olanak tanımaktadır [19]. KDA, denetimli öğrenme kapsamında kullanılan istatistiksel bir sınıflandırma algoritması olup, özellikle sınıflar arasındaki ayrımı modelleme sürecinde esneklik sağlamasıyla öne çıkmaktadır. Geleneksel Lineer Diskriminant Analizi (LDA), her sınıfın ortak bir kovaryans matrisine sahip olduğunu varsayarken, KDA her sınıf için ayrı bir kovaryans matrisi kullanmaktadır. Bu yaklaşım, özellikle sınıfların farklı varyans yapıları sergilediği ve doğrusal olmayan ayrım sınırlarının gerektiği durumlarda daha güçlü bir modelleme yeteneği sunmaktadır. KDA, sınıflandırma işlemini Bayes teoremi temelinde gerçekleştirerek, her bir veri örneğinin belirli bir sınıfa ait olma olasılığını hesaplamaktadır. Modelin öğrenme sürecinde, her sınıfa özgü ortalama vektörler ve kovaryans matrisleri hesaplanarak sınıflar arasındaki ayırt edici özellikler belirlenmektedir. Bu özellikleri sayesinde, özellikle karmaşık veri yapılarında ve sınıflar arası varyans farklılıklarının belirgin olduğu senaryolarda yüksek sınıflandırma performansı elde edilebilmektedir [20].

Torbalama, MÖ'de model kararlılığını artırmak ve genelleme hatasını en aza indirmek amacıyla geliştirilen bir topluluk öğrenme (ensemble learning) algoritmasıdır. Temel olarak, yüksek varyansa sahip modellerin aşırı öğrenme (overfitting) eğilimini azaltarak daha güvenilir tahminler üretmesini sağlamaktadır. Torbalama yönteminde, eğitim verisi içerisinden rastgele ve yinelenmeli olarak seçilen alt kümeler oluşturularak birden fazla zayıf model (base learners) eğitilmektedir. Bu alt kümeler, orijinal veri kümesinden yerine koymalı (bootstrap sampling) örnekleme yöntemi ile oluşturulmakta olup, her bir alt model farklı bir veri dağılımı üzerinde öğrenme sürecini gerçekleştirmektedir. Daha sonra, elde edilen tüm modellerin tahminleri birleştirilerek nihai karar verilmektedir. Torbalama, özellikle KA gibi yüksek varyansa sahip algoritmalarla kullanıldığında önemli avantajlar sunmaktadır. Bu yöntem, eğitim verisindeki küçük değişimlere karşı modelin duyarlılığını azaltarak daha istikrarlı ve güvenilir tahminler elde edilmesini sağlamaktadır. Bununla birlikte, her bir alt modelin birbirinden bağımsız olarak eğitilmesi, paralel hesaplama teknikleri ile uygulanabilirliği artırarak büyük veri setleri üzerinde de verimli bir şekilde kullanılmasına olanak tanımaktadır [21].

Bu çalışmada kullanılan tüm MÖ algoritmaları, Python programlama dili ve Scikit-learn kütüphanesi kullanılarak gerçekleştirilmiştir. Algoritmaların eğitiminde, Scikit-learn kütüphanesinde tanımlı varsayılan hiperparametre değerleri kullanılmıştır. Gerçekleştirilen bu çalışmada hiperparametre optimizasyonuna gidilmemiş olup, algoritmalar varsayılan ayarlarla değerlendirilmiştir. Model karşılaştırmaları, algoritmaların genel eğilimlerinin değerlendirilmesi amacıyla yapılmış, her bir model varsayılan ayarlarla aynı koşullar altında test edilerek performans farkları gözlemlenmiştir. Gelecek çalışmalarda, her algoritma için hiperparametre ayarlarının optimize edilmesi planlanmaktadır.

2.4. Model Doğrulama Yöntemleri

Veri ayırma ve model değerlendirme, MÖ süreçlerinde modelin performansını doğru bir şekilde değerlendirebilmek için kritik öneme sahiptir. Bu bağlamda, k-çapraz doğrulama (k-fold cross-validation) ve hold-out sıklıkla başvuru alan teknikler arasında yer almaktadır.

Daha basit ve hızlı bir veri ayırma tekniği olan hold-out tekniği; veri kümesi belirli bir oranla ikiye (eğitim/test) ayrılmaktadır. Eğitim verisi ile model eğitilirken, test verisiyle modelin başarımı değerlendirilmektedir. Bu teknik daha hızlı sonuçlar verirken, veri kümesinin sadece bir kısmı eğitim veya test için kullanıldığı için modelin genellenebilirliği konusunda daha sınırlı bilgi sağlamaktadır. Ayrıca, rastlantısal veri bölünmesi nedeniyle farklı sonuçlar elde edilme olasılığı bulunmaktadır.

k-çapraz doğrulama tekniğinde veri kümesi k eşit parçaya bölünerek her bir parça sırasıyla test kümesi olarak kullanılmakta, geri kalan k-1 parça ise eğitim verisi olarak değerlendirilmektedir. Bu işlem k kez tekrarlanarak elde edilen performans metriklerinin ortalaması alınarak modelin genel başarısı belirlenmektedir. k-çapraz doğrulama tekniği, modelin genellenebilirliği artırırken aşırı uyum (overfitting) riskini azaltmaktadır.

Gerçekleştirilen bu çalışmada, veri ön işleme sürecinde anlamlı özelliklerin belirlenmesi ve ölçeklendirme işlemlerinin tamamlanmasının ardından, modelleme aşamasına geçilmiştir. Bu kapsamda, her algoritma için belirlenen özellik kümeleri üzerinden eğitim gerçekleştirilmiş, %80 oranındaki eğitim verisiyle 5 katlı çapraz doğrulama uygulanmış ve nihai değerlendirme %20'lik test verisiyle yapılmıştır. Böylece tüm modeller aynı koşullar altında karşılaştırılmıştır.

2.5. Model Performans Değerlendirme Kriterleri

MÖ tabanlı modellerinin başarımları çeşitli performans metriklerine dayanarak değerlendirilmektedir. Modelin sınıflandırma başarısını belirleyen bu ölçütler, doğruluk düzeyinin nesnel bir şekilde ölçülmesine katkı sağlamaktadır. Bu doğrultuda, çalışmada doğruluk, kesinlik, duyarlılık ve F1 skoru gibi yaygın sınıflandırma metrikleri kullanılarak model performansı kapsamlı bir şekilde incelenmiştir. İlgili metrikler ait matematiksel ifadeler aşağıda verilmiştir. Bunun yanı sıra önerilen modelin performansını daha iyi anlamak adına, yalnızca en başarılı sınıflandırma sonuçlarını veren algoritma üzerinden pozitif ve negatif örneklerin doğru ya da yanlış sınıflandırılmasına ilişkin ayrıntılar karmaşıklık matrisi ile ortaya konmuştur. Karmaşıklık matrisi, sınıflandırma performansının ayrıntılı bir şekilde incelenmesini sağlayarak her bir sınıf için modelin başarımını dört temel kategori üzerinden değerlendirmeye olanak tanımaktadır: Doğru Pozitifler (DP), model tarafından doğru şekilde pozitif olarak sınıflandırılan örneklerdir; Doğru Negatifler (DN), negatif olup model tarafından doğru şekilde negatif olarak sınıflandırılan örnekleri ifade etmektedir; Yanlış Pozitifler (YP), gerçekte negatif olan ancak model tarafından hatalı biçimde pozitif olarak sınıflandırılan örneklerdir; Yanlış Negatifler (YN) ise pozitif olup model tarafından yanlış bir şekilde negatif olarak sınıflandırılan örneklerdir. Bu kategoriler, modelin sınıflandırma başarımının kapsamlı bir

şekilde değerlendirilmesini sağlayarak farklı hata türlerinin analizi için temel oluşturmaktadır [22].

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

$$\text{F1 skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$


3. Deneysel Sonuçlar

Bu çalışmada, bireylerin çevresel farkındalık ve tutum düzeylerini değerlendirmek amacıyla veri odaklı bir model tasarlanmış ve bu model kullanılarak çevresel tutum düzeylerinin sınıflandırılmasında beş farklı MÖ algoritmasının performansı karşılaştırılmıştır. Model oluşturma sürecinde, öncelikle veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek için ANOVA ve Ki-Kare tabanlı özellik seçim yöntemleri uygulanmıştır. Bu aşama, modelin verimliliğini artırmak ve gereksiz değişkenlerin olası etkilerini en aza indirmek amacıyla gerçekleştirilmiş olup, belirlenen önemli özellikler kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Özellik seçiminin ardından, sınıflandırma aşamasında DVM, GA, ÇKA, KDA ve Bagging algoritmalarının performansı analiz edilmiştir. Modelin değerlendirilmesi amacıyla veri kümesi, %80 eğitim ve %20 test olarak ayrılmış; ardından modelin genellenebilirliği artırmak ve aşırı öğrenme riskini azaltmak amacıyla eğitim verisi üzerinde 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Bu yaklaşım, veri kümesindeki farklı örneklerin modele katkısını güçlendirerek daha güvenilir sonuçlar elde edilmesini sağlamaktadır. Model eğitiminin tamamlanmasının ardından, test verisi üzerinde doğruluk, kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri kullanılarak kapsamlı bir değerlendirme gerçekleştirilmiştir. Gerçekleştirilen analizlerde, MÖ algoritmalarının sınıflandırma performansları karşılaştırılmış ve elde edilen bulgular detaylandırılmıştır. Bu kapsamda ANOVA testiyle seçilen özelliklerin algoritmaların performanslarına etkisi Şekil 2'de gösterilmiştir.


Şekil 2'deki verilere göre, en yüksek doğruluk oranı %84,4 ile GA tarafından elde edilmiştir. Diğer algoritmaların doğruluk oranları ise %81,8 seviyesinde sabit kalmıştır. Kesinlik metriği açısından, en yüksek değer %87,5 ile Bagging algoritmasında gözlemlenmiş, bunu sırasıyla %86,1 ile GA, %85,3 ile ÇKA ve %83,3 ile DVM ve KDA algoritmaları takip etmiştir.

Duyarlılık metriğinde, GA algoritması %81,6 ile en yüksek performansı sergilemiş, DVM ve KDA algoritmaları ise %78,9 ile benzer sonuçlar elde etmiştir. ÇKA algoritması %76,3, Bagging ise %73,7 ile bu algoritmaların gerisinde kalmıştır. F1 skoru açısından ise, GA algoritması %83,8 ile en yüksek değere ulaşırken, DVM ve KDA algoritmaları %81,1, ÇKA %80,6 ve Bagging %80,0 değerleriyle sıralanmıştır.



Şekil 2: ANOVA testi ile seçilen özelliklerin sınıflandırıcıların performanslarına etkisi.

Elde edilen bulgular, GA algoritmasının doğruluk, duyarlılık ve F1 skoru metrikleri bakımından diğer algoritmalara kıyasla daha dengeli ve üstün bir performans sergilediğini açıkça ortaya koymaktadır. Özellikle en yüksek doğruluk oranına ulaşması, bu algoritmanın sınıflandırma performansı açısından avantajlı olduğunu göstermektedir. Bu bağlamda, GA algoritmasının elde ettiği sınıflandırma başarısını daha ayrıntılı incelemek amacıyla, ilgili karışıklık matrisi Şekil 3'de sunulmuştur.




Şekil 3: Önerilen modelin akış diyagramı.

Şekil 3'de sunulan karışıklık matrisine göre, 0 sınıfına ait 39 örneğin 34'ü doğru bir şekilde 0 sınıfına atanırken, 5 örnek yanlışlıkla 1 sınıfına sınıflandırılmıştır. Benzer şekilde, 1 sınıfına ait 38 örneğin 31'i doğru olarak 1 sınıfına atanmış, 7 örnek ise hatalı bir şekilde 0 sınıfına dahil edilmiştir. Bu sonuçlar doğrultusunda, 0 sınıfına ait örneklerin doğruluk oranı %87,18, 1 sınıfına ait örneklerin doğruluk oranı ise %81,58 olarak hesaplanmıştır. Elde edilen bulgular, 0

sınıfının 1 sınıfına kıyasla daha yüksek doğruluk oranına sahip olduğunu göstermekte olup, modelin 1 sınıfına ait örnekleri sınıflandırmada görece daha fazla hata yaptığını ortaya koymaktadır.


ANOVA testi ile belirlenen özellikler kullanılarak elde edilen sonuçların ardından, farklı bir özellik seçme yöntemi olan Ki-kare testi uygulanmış ve modelin performansı üzerindeki etkisi değerlendirilmiştir. Bu doğrultuda Ki-kare testi ile belirlenen özellikler kullanıldığında MÖ algoritmalarının performans metrikleri Şekil 4'de karşılaştırmalı olarak sunulmuştur.

Şekil 4'den görüldüğü üzere, en yüksek doğruluk oranı %85,7 ile GA algoritmasında elde edilmiştir. Bunu sırasıyla %84,4 ile DVM, %83,1 ile ÇKA ve Bagging algoritmaları takip etmiştir. En düşük doğruluk oranı ise %81,8 ile KDA algoritmasında kaydedilmiştir. Kesinlik metriği açısından en yüksek değer %86,5 ile GA algoritmasında elde edilmiştir. DVM algoritması %86,1, ÇKA ve Bagging algoritmaları ise %82,1 ile sıralanırken, KDA algoritması %78,6 ile en düşük kesinlik değerine ulaşmıştır. Duyarlılık metriği açısından, KDA algoritması %86,8 ile en yüksek performansı sergilemiş, bunu %84,2 ile GA, ÇKA ve Bagging algoritmaları takip etmiştir. DVM algoritması ise %81,6 duyarlılık değeri ile daha düşük bir performans sergilemiştir. F1 skoru açısından en yüksek değer %85,3 ile GA algoritmasında elde edilmiştir. Bunu sırasıyla %83,8 ile DVM, %83,1 ile ÇKA ve Bagging algoritmaları takip ederken, KDA algoritması %82,5 ile en düşük F1 skorunu göstermiştir. Genel olarak GA algoritması tüm metriklerde dengeli ve yüksek performans gösterirken, DVM kesinlik açısından, KDA ise duyarlılık açısından öne çıkmıştır. Ancak bu çalışmada doğruluk metriği öncelikli bir değerlendirme ölçütü olarak ele alındığından, Şekil 5'de en yüksek doğruluk oranına sahip GA algoritmasına ait karmaşıklık matrisi sunulmuştur.



Şekil 4: Ki-Kare testi ile seçilen özelliklerin sınıflandırıcıların performanslarına etkisi.

Şekil 5’de gösterilen karışıklık matrisi incelendiğinde, 0 sınıfına ait 39 örnekten 34’ü doğru şekilde 0 olarak sınıflandırılmış, 5 örnek ise yanlışlıkla 1 sınıfına atanmıştır. Benzer şekilde, 1 sınıfına ait 38 örneğin 32’si doğru şekilde 1 olarak sınıflandırılmış, ancak 6 örnek hatalı olarak 0 sınıfına dahil edilmiştir. Bu doğrultuda, 0 sınıfına ait örneklerin doğru sınıflandırılma oranı %87,18; 1 sınıfına ait örnekler için ise %84,21 olarak hesaplanmıştır. Bu sonuçlar, modelin her iki sınıfta da yüksek doğruluk oranlarına sahip olduğunu, ancak yanlış sınıflandırmaların dikkate alınması gerektiğini göstermektedir.



Şekil 5: Ki-kare tabanlı özellik seçimi uygulanan GA algoritmasına ait karışıklık matrisi.

4. Sonuç ve Tartışma

Bu çalışma, bireylerin çevresel farkındalık ve tutum düzeylerini sınıflandırmak amacıyla veri odaklı bir model geliştirmiş ve beş farklı MÖ algoritmasının performansını karşılaştırmıştır. Model oluşturma sürecinde, veri setindeki değişkenlerin sınıflandırma başarısına etkisini belirlemek için ANOVA ve Ki-Kare bağımsızlık testi gibi istatistiksel yöntemler uygulanmış ve anlamlı özellikler doğrultusunda sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlar, GA algoritmasının genel olarak en yüksek doğruluk oranına sahip olduğunu göstermiştir. Özellikle ANOVA tabanlı özellik seçimi ile uygulanan GA modeli, diğer algoritmalara kıyasla daha dengeli ve başarılı bir sınıflandırma performansı sergilemiştir. Ki-Kare testi kullanılarak yapılan analizlerde de GA algoritması en yüksek doğruluk oranına ulaşmış, dolayısıyla çevresel tutumların sınıflandırılmasında bu algoritmanın güçlü bir seçenek olduğu ortaya konmuştur. Bu çalışmanın bulguları, literatürdeki benzer araştırmalarla paralellik göstermektedir. Özellikle çevresel farkındalık ve tutum düzeylerinin MÖ algoritmaları aracılığıyla başarılı bir şekilde tahmin edilebildiği görülmüştür. Bulgular, farklı algoritmaların başarı düzeylerinin, veri setinin yapısı, özellik seçimi ve sınıf dağılımı gibi faktörlere bağlı olarak değişkenlik gösterebildiğini ortaya koymaktadır. Bu durum, modelleme sürecinde algoritma seçiminin yanı sıra veri ön işleme aşamalarının da dikkatle planlanması gerektiğini göstermektedir. Ayrıca, çevresel tutumların analizinde sosyal medya gibi alternatif veri kaynaklarının kullanımı, bireylerin çevreye ilişkin duygu ve düşüncelerini daha geniş bir

bağlamda değerlendirme imkânı sunmaktadır. Mevcut çalışma, veri odaklı yaklaşımların çevresel farkındalık düzeylerinin belirlenmesinde önemli bir araç olabileceğini ortaya koymakla birlikte, bu alandaki araştırmaların henüz başlangıç aşamasında olduğunu ve daha kapsamlı çalışmalara ihtiyaç duyulduğunu da göstermektedir. Gelecekte gerçekleştirilecek çalışmalarda, dengesiz veri yapısının sınıflandırma performansı üzerindeki etkisinin azaltılmasına yönelik gelişmiş örnekleme tekniklerinin uygulanması ve elde edilen sonuçların politika geliştirme süreçlerine entegre edilmesi, bu alandaki katkıyı daha da artıracaktır.

5. Kaynaklar

- [1] R. L. Singh and P. K. Singh, "Global Environmental Problems," in *Principles and Applications of Environmental Biotechnology for a Sustainable Future*, R. Singh, Ed., Applied Environmental Science and Engineering for a Sustainable Future. Singapore: Springer, 2017, pp. 23-45
- [2] J. E. Hardoy, D. Mitlin, and D. Satterthwaite, "Environmental Problems in Third World Cities". London: Taylor & Francis, 2024.
- [3] N. Koklu and S. A. Sulak, "Classification of Environmental Attitudes with Artificial Intelligence Algorithms," *Intelligent Methods in Engineering Sciences*, vol. 3, no. 2, pp. 54-62, 2024.
- [4] S. Çelik, "The effects of climate change on human behaviors," *Environment, Climate, Plant and Vegetation Growth*, pp. 577-589, 2020.
- [5] M. Ahmadi and M. B. Tahoori, "Dynamic reconfigurable IoT security: Challenges and opportunities," *Proc. IEEE*, vol. 106, no. 1, pp. 72-86, 2018.
- [6] X. Guo, K. Huang, and J. Lach, "Energy-adaptive cryptographic solutions for energy-harvesting IoT devices," *IEEE Trans. Circuits Syst. I: Regular Papers*, vol. 63, no. 5, pp. 629-638, 2016.
- [7] L. F. Beiser-McGrath and R. A. Huber, "Assessing the relative importance of psychological and demographic factors for predicting climate and environmental attitudes," *Climatic Change*, vol. 149, pp. 335-347, 2018.
- [8] A. Değirmenci, "Comparison of K-Nearest Neighbors, Decision Tree and Support Vector Machines Methods in Predicting Environmental Attitudes," *Emerging Trends in Electrical and Electronics Engineering*, vol. 4, 2024.
- [9] N. Choudhury, R. Mukherjee, R. Yadav, Y. Liu, and W. Wang, "Can machine learning approaches predict green purchase intention? - A study from Indian consumer perspective," *Journal of Cleaner Production*, vol. 456, p. 142218, 2024.
- [10] D. Amangeldi, A. Usmanova, and P. Shamoi, "Understanding Environmental Posts: Sentiment and Emotion Analysis of Social Media Data," *IEEE Access*, vol. 12, pp. 12345-12356, 2024.
- [11] A. A. Takshe, M. Hennawi, S. E. Jebril, S. Alawi, S. AlZaidan, and A. Okasha, "Investigating determinants of pro-environmental behaviors amongst UAE university students through Q-methodology," *Discover Sustainability*, vol. 4, no. 1, p. 38, 2023.
- [12] Q. Wang, Z. Kou, X. Sun, S. Wang, X. Wang, H. Jing, and P. Lin, "Predictive analysis of the pro-environmental behavior of college students using a decision-tree model," *Int. J. Environ. Res. Public Health*, vol. 19, no. 15, p. 9407, 2022.
- [13] X. Lou, Y. Lin, and L. M. W. Li, "Predicting priority of environmental protection over economic growth using macroeconomic and individual-level predictors: Evidence from machine learning," *J. Environ. Psychol.*, vol. 82, p. 101843, 2022.
- [14] C. Li, L. Li, J. Zheng, J. Wang, Y. Yuan, Z. Lv, ... and W. Liu, "China's public firms' attitudes towards environmental protection based on sentiment analysis and random forest models," *Sustainability*, vol. 14, no. 9, p. 5046, 2022.
- [15] Z. Kadiroğlu, E. Deniz, and A. Şenyiğit, "A comparison of deep learning models for pneumonia detection from chest x-ray images," *J. Faculty Eng. Architect. Gazi Univ.*, vol. 39, no. 2, pp. 729-740, 2024.
- [16] İ. Ş. Yapıcı, R. U. Arslan, ve O. Erkamaz, "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.
- [17] E. I. Elsedimy, S. M. AboHashish, and F. Algarni, "New cardiovascular disease prediction approach using support vector machine and quantum-behaved particle swarm optimization," *Multimedia Tools Appl.*, vol. 83, no. 8, pp. 23901-23928, 2024.
- [18] A. Villar and C. R. V. de Andrade, "Supervised machine learning algorithms for predicting student dropout and academic success: a comparative study," *Discover Artificial Intelligence*, vol. 4, no. 1, pp. 2, 2024.
- [19] B. Shankarlal, S. Dhivya, K. Rajesh, and S. Ashok, "A hybrid thyroid tumor type classification system using feature fusion, multilayer perceptron and bonobo optimization," *Journal of X-Ray Science and Technology*, Preprint, pp. 1-25, 2024.
- [20] S. M. Malakouti, M. B. Menhaj, and A. A. Suratgar, "Machine learning and transfer learning techniques for accurate brain tumor classification," *Clinical eHealth*, vol. 7, pp. 106-119, 2024.
- [21] D. V. Nguyen, J. Park, H. Lee, T. Han, and D. Wu, "Assessing industrial wastewater effluent toxicity using boosting algorithms in machine learning: A case study on ecotoxicity prediction and control strategy development," *Environmental Pollution*, vol. 341, p. 123017, 2024.
- [22] R. Janković Babić, "A comparison of methods for image classification of cultural heritage using transfer learning for feature extraction," *Neural Computing and Applications*, vol. 36, no. 20, pp. 11699-11709, 2024.

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 YAPICI, 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.



Fuat ALKAN, lisans eğitimini Abant İzzet Baysal Üniversitesi Düzce Teknik Eğitim Fakültesi'nde, mühendislik tamamlama eğitimini ise 2015 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. 2014 yılında öğretmenliğe başlayan Alkan, 2021 yılından bu yana Zonguldak Devrek Mesleki ve Teknik Anadolu Lisesi'nde Elektrik-Elektronik Öğretmeni (Uzman Öğretmen) olarak görev yapmaktadır. Akademik çalışmalarına Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği yüksek lisans programında devam etmektedir.

Telekomünikasyon Sektöründe Müşteri Kaybı Tahmini İçin Açıklanabilir Makine Öğrenmesi

Explainable Machine Learning for Customer Churn Prediction in Telecommunication Industry

M. Aslı Aydın¹

 0000-0002-8905-7518

¹İşletme Mühendisliği Bölümü

Bahçeşehir Üniversitesi

asli.aydin@bau.edu.tr

Özet- Telekomünikasyon sektöründe ayrılacak müşterilerin önceden tahmin edilmesi, firmaların bu müşterilere özel elde tutma stratejileri geliştirerek müşteri kaybını önlemesinde oldukça önemlidir. Bu çalışmada müşteri kaybı tahmini için geleneksel makine öğrenmesi yöntemlerinden Lojistik Regresyon, Destek Vektör Makineleri ve Yapay Sinir Ağlarının performansı, topluluk öğrenme yöntemleri olan Rastgele Orman, Gradyan Güçlendirme Makineleri ve Aşırı Gradyan Güçlendirme yöntemlerinin performansı ile kıyaslanmıştır. Açık erişimli telekomünikasyon verisinde bulunan sınıf dengesizliği problemi, modellerin performansına olan olumsuz etkisinin önlenmesi amacıyla SMOTE yeniden örnekleme yöntemiyle giderilmiştir. Deney sonuçlarına göre Rastgele Orman modeli tahminlerin %85,9 doğruluk oranı ile diğer modellere üstünlük sağlamıştır. Model sonuçlarına en çok etki eden faktörlerin tespit edilip yorumlanabilmesi için Shapley Katkı Açıklamaları yöntemi kullanılmıştır. Bu yöntemle müşterilerin ayrılma kararına etki eden temel faktörler değerlendirilip ayrılacağı tahmin edilen müşterilere yönelik caydırıcı teşvik ve promosyonlar önerilmiştir.

Anahtar Kelimeler- Müşteri Kaybı Tahmini, Telekomünikasyon, Makine Öğrenmesi, Açıklanabilir Yapay Zeka, Shapley Değeri

Abstract— In telecommunication industry, prediction of the customers who are the most likely to leave is very crucial for companies to prevent customer churn by developing special retention strategies for those. This study presents a comparison of the performances of traditional machine learning methods Logistic Regression, Support Vector Machines and Artificial Neural Networks with the performance of ensemble learning methods Random Forest, Gradient Boosting Machines and Extreme Gradient Boosting for customer churn prediction. We address class imbalance problem with SMOTE resampling method to reduce the adverse impact of imbalanced data on model performance. The results show Random Forest model outperforms the other models with an accuracy of 85.9%. We utilized Shapley Additive Explanation method to identify and interpret the features affecting the customer's decisions to leave most. This approach enables the subsequent recommendation of tailored incentives and promotions for those customers who are predicted to be at risk of leaving.

Keywords— Churn Prediction, Telecommunications, Machine Learning, Explainable AI, Shapley Value

I. GİRİŞ

Telekomünikasyon (telekom) sektörü, hızlı teknolojik gelişmeler ve değişen müşteri talepleri ile karakterize edilen son derece rekabetçi bir ortamda faaliyet göstermektedir. Mevcut müşterilerin rakip firmalara geçmesi olarak tanımlanabilen müşteri kaybı, telekom operatörleri için gelir, pazar payı ve marka itibarını etkileyen önemli bir tehdit oluşturmaktadır. Ayrıca sürdürülebilir büyüme ve kârlılık için müşteriyi elde tutmak çok önemlidir. Çünkü yeni müşteri edinmenin maliyeti, mevcut müşterileri elde tutmanın maliyetinden çok daha fazladır [1]. Burez ve Van den Poel [2] müşteri kaybını yönetmek için belirlenen yaklaşımların reaktif ve proaktif olmak üzere kategorize edilebileceğini söyler. Reaktif yaklaşımı benimseyen firmalar müşteriden ayrılma talebi gelene kadar bekler. Böyle bir durumla karşılaştıklarında aksiyon alıp ayrılacak müşterilere teşvik sunarlar. Ancak bu tedbirler sıklıkla çok geç uygulanmaktadır. Öte yandan, proaktif yaklaşımı benimseyen firmalar hangi müşterilerin ayrılma olasılığının yüksek olduğunu önceden tahmin etmeyi hedefler. Böylece bu müşteriler henüz ayrılmayı talep etmeden onlara özel ihtiyaçları karşılamak için hedefe yönelik kampanya ve promosyon gibi teşviklerle müşteri kaybını azaltmayı amaç edinir. Proaktif yaklaşımın reaktif yaklaşıma göre daha düşük teşvik maliyetlerine sahip olma gibi avantajları vardır. Ancak, müşteri kaybı tahminleri yanlışsa bu sistemler çok masraflı olabilir. Örneğin, firma ayrılmayacak müşteriyi ayrılacak diye tahmin ederse kaybetmeyeceği müşteri için gereksiz teşvik vermiş olur. Ya da ayrılacak müşteriyi doğru tahmin edemezse müşteriyi kaybedebilir. Bu nedenle, tahminlerin doğruluğu, sağlanacak kampanya veya promosyonların maliyeti ve ayrılacak müşterinin doğru tespit edilememesi durumunda yaşanacak müşteri kaybı düşünüldüğünde önem kazanmaktadır.

Müşteri kaybı tahmini probleminin temelde mevcut müşterilerin *Ayrılanlar* ve *Ayrılmayanlar* şeklinde iki sınıfa ayrılması (İkili Sınıflandırma) problemi olarak da tanımlanabiliyor olması, son yıllarda ön plana çıkan makine öğrenmesi yöntemlerinin de çözüm yaklaşımları arasında olmasını gündeme getirmiştir. Makine öğrenmesi yöntemleri, büyük boyutlardaki müşteri verisini analiz etme, müşteri kaybı eğilimini gösteren karmaşık kalıpları ve ilişkileri belirleme ve mevcut müşterilerin ayrılma davranışını yüksek doğrulukla tahmin etme potansiyeli sunmaktadır. Ancak üzerinde çalışılan verinin özellikleri uygulanan makine öğrenimi yönteminin tahmin başarısını etkileyebilmektedir. Örneğin denetimli öğrenme yöntemleriyle çözülecek ikili sınıflandırma problemlerinde bir sınıfa ait örneklerin diğerine göre önemli ölçüde fazla olması Veride Sınıf Dengesizliği olarak bilinir [3]. Telekom sektöründen elde edilen çok sayıda veri setinde *Ayrılan* sınıfındaki müşterilerin oranı *Ayrılmayan* sınıfındaki müşterilerin

oranına göre oldukça düşüktür. Bu da telekom verilerinde sınıf dengesizliği probleminin varlığına işaret eder [4]. Birçok makine öğrenmesi yöntemi verideki dengesiz yapıyı ayırt edebilecek şekilde tasarlanmamıştır. Bu sebeple, bu tip veriye uygulanan makine öğrenmesi yöntemlerinin performansı olumsuz etkilenebilmektedir [5]. Bu sebeple öncelikle verideki sınıf dengesizliğinin giderilmesi, sonra dengelenmiş veriye makine öğrenmesi yöntemlerinin uygulanması tahminlerin doğruluğunu artırmaktadır.

Telekom sektöründe müşteri kaybını önlemede belirli bir müşterinin ayrılıp ayrılmayacağını başarılı bir şekilde tahmin edilmesi kadar ayrılmaların ardında yatan nedenlerin tespit edilip açıklanabilmesi de önem arz etmektedir. Hızla gelişen makine öğrenmesi yöntemleri verideki dengesizliğin giderilmesi gibi desteklerle oldukça başarılı tahminlerde bulunsun da ayrılmaların arkasındaki sebepleri açıklamak gibi bir amaçları yoktur. Yapılan tahminlerin arkasındaki mantık insanlar tarafından bir bakışla anlaşılamadığı için bu yöntemler bir kara kutu olarak kabul edilir [6].

Açıklanabilir Yapay Zekanın (XAI) telekom sektöründeki müşteri kaybı tahminine entegrasyonu, müşteri memnuniyetsizliğini anlama ve ele alma konusunda önemli bir ilerlemeyi temsil etmektedir. XAI teknikleri, tahminler için şeffaf açıklamalar ve yorumlanabilirlik sağlayarak makine öğrenmesi yöntemlerini geliştirir ve firmaların müşteri kaybına neden olan temel faktörleri anlamalarına olanak tanır. Yönetimsel bakış açısıyla değerlendirildiğinde, XAI tüm paydaşların geliştirilmekte olan tahmin modelini daha iyi anlaması ve güven duymasını sağlayarak otomatik algoritmaları insani içgörüyle bütünleştirir [7]. Böylece firmaların hedeflenen müşteriler için daha etkin elde tutma stratejileri geliştirebilmeleri kolaylaşır.

Bu çalışma telekom sektöründe müşteri kaybını etkin bir biçimde tahmin edilirken aynı zamanda müşteri kaybının ardındaki nedenlerin de anlaşılmasını sağlamayı hedeflemektedir. Çalışmanın katkıları aşağıda özetlenmiştir:

- Sınıf dengesizliği bulunan telekom verisine öne çıkan makine öğrenmesi yöntemleri uygulanarak müşteri kaybı tahminindeki performansları analiz edilmiştir.
- Makine öğrenmesi yöntemlerinden elde edilen sonuçların nedenlerini yorumlayabilmek için açıklanabilir yapay zeka yöntemi kullanılmıştır.
- Özniteliklerin müşteri kaybı tahminine olumlu ya da olumsuz etkileri yönetim perspektifinden değerlendirilmiştir.

Bu çalışma aşağıdaki şekilde düzenlenmiştir. 2. bölümde ilgili çalışmalar özetlenerek bu çalışmayla olan ilişkileri incelenmiştir. 3. bölümde üzerinde çalışılan veri tanıtılıp veri ön işleme işlemlerinden bahsedilmiştir. Ayrıca sınıf dengesizliği problem için uygulanan yeniden örnekleme yöntemi ve makine öğrenmesi yöntemlerinden bahsedilmiştir. 4. bölümde test sonuçları verilmiş ve bunların XAI ile değerlendirilmesi yapılmış, elde edilen bulgular tartışılmıştır. 5. bölümde ise çalışmada elde edilen sonuçlar özetlenmiştir.

II. LİTERATÜR TARAMASI

Makine öğrenmesi yöntemleri müşteri kaybı tahminindeki başarıları dolayısıyla kısa bir süre içinde yaygın bir kullanım ve popülerlik kazanmıştır. Telekom sektöründeki müşteri kaybı tahmininde erken dönem çalışmalar arasında sıklıkla Naïve Bayes (NB) [8, 9], Karar Ağaçları (KA) [10, 11], Lojistik Regresyon (LR) [12, 13], Destek Vektör Makineleri (DVM) [14, 15], K-En Yakın Komşuluk (KNN) [16] ve Yapay Sinir Ağları (YSA) [17-19] yöntemlerinin kullanıldığı görülmektedir. Bu yöntemler birçok araştırmacı

tarafından farklı Telekom veri setlerine uygulanmış ve performansları kıyaslanmıştır. Bunlar arasında Keramati vd. [20] KA, DVM, KNN ve YSA, Kaynar vd. [21] ise NB, DVM ve YSA yöntemlerinin performansını kıyaslamış, en başarılı tahminlere YSA ile ulaştıklarını açıklamışlardır. Aydın [22] çalışmasında telekom verisindeki sınıf dengesizliği probleminde de değinmiş, uygulanan yöntemlerden DVM'nin diğerlerine göre daha iyi performans gösterdiği açıklamıştır.

Güncel çalışmalarda araştırmacıların temel makine öğrenme yöntemlerine ek olarak Rastgele Orman (RO), Gradyan Güçlendirme Makineleri (Gradient Boosting Machines-GBM), Aşırı Gradyan Güçlendirme (Extreme Gradient Boosting-XGBoost) gibi daha gelişmiş topluluk yöntemleri de kullanıldığı görülmektedir. Sikri vd. [23] çalışmalarında farklı yöntemlerle dengelikleri telekom verisine NB, KA, LR, YSA, KNN, XGBoost yöntemlerini uygulamış, XGBoost yöntemiyle daha başarılı tahmin sonuçları elde etmişlerdir. Afzal vd. [24] ise KA, KNN, RO ve XGBoost yöntemlerini kıyasladıkları çalışmalarında RO yönteminin %98,25 doğruluk oranı ile diğer yöntemlerden daha başarılı sonuç verdiğini açıklamışlardır. Kök [25] çalışmasında öncelikle verideki sınıf dengesizliğine değinip sonra NB, KA, DVM, KNN ve RO yöntemlerini uygulamışlardır. RO yöntemi ile tahminlerde %81 doğruluk oranı elde etmiştir. Daha sonra bu modele ait tahminleri açıklanabilir yapay zeka yöntemleriyle yorumlamıştır. Boozary vd. [26] çalışmalarında sınıf dengesizliğini giderdikleri veriye LR, DVM, KNN, RO ve XGBoost yöntemlerini uygulamışlar, topluluk yöntemlerinin, spesifik olarak XGBoost yönteminin diğerlerinden daha yüksek performans gösterdiğini açıklamışlardır. Ayrıca tahminlere öznitelik katkılarını ölçmek, model yorumlanabilirliğini artırmak için açıklanabilir yapay zeka yöntemleri kullanmışlardır. Özkurt [27] çalışmasında geleneksel makine öğrenmesi yöntemlerine ek olarak RO, XGBoost, Gradyan Güçlendirme, LightGBM, CatBoost, AdaBoost gibi birçok güncel topluluk yöntemlerine yer vermiştir. Elde edilen sonuçlara göre LightGBM yöntemi %73,085 doğruluk oranı ile diğer yöntemlerden daha iyi performans sergilemiştir. Elde edilen makine öğrenmesi sonuçları iki farklı XAI yöntemi ile yorumlanmıştır. Asif vd. [28] çalışmalarında geleneksel makine öğrenmesi yöntemlerine yer vermezken, sınıf dengesizliği giderilmiş veriseti üzerinde XGBoost, CatBoost ve LightGBM yöntemlerinin bir kombinasyonu olan TriBoost yöntemini kullanmışlardır. Bu yöntemi bireysel temel yöntemlerle karşılaştırmış ve performans ölçütlerinde iyileşme gözlemlemişlerdir. Daha sonra elde edilen sonuçlar XAI yöntemleriyle ile açıklanmıştır.

Bu çalışmanın amacı telekom sektöründe müşteri kaybını etkin bir biçimde tahmin edebilmek ve sonrasında müşteri kaybına yol açan esas nedenlerin anlaşılmasını sağlamaktır. Böylece firmaların müşterileri elde tutma stratejileri geliştirmesi kolaylaşacaktır.

Çalışmada uygulanan yöntemlerle mevcut çalışmalarda kullanılan yöntemlerin kıyaslaması Tablo 1'de görülmektedir. Buna göre [20] ve [21]'de daha yüksek performans gösterme potansiyeli olan topluluk yöntemleri kullanılmamışken bu çalışmada bu yöntemler de yer verilmiştir. Ayrıca bu çalışmalarda uygulanan makine öğrenmesi yöntemlerinin performansını olumsuz etkileyecek sınıf dengesizliği probleminde değinilmemişken bu çalışmada öncelikle veri dengeli hale getirilmektedir. [22], [23] ve [25]'de sadece bir topluluk yöntemi kullanılmıştır. Bu çalışmada geleneksel makine öğrenmesi yöntemlerine farklı topluluk yöntemleri de eklenerek daha kapsamlı bir değerlendirme hedeflenmiştir. [24] ve [27] 'de çeşitli yöntemler denenmiş ancak verideki sınıf dengesizliği problemi giderilmemiştir. Bu çalışmada [26]'te kullanılmayan ama başka çalışmalarda yüksek performans gösterdiği açıklanan YSA ve GBM yöntemleri de araştırmaya dahil edilmiştir. [28] sadece

topluluk yöntemleri arasında bir kıyaslama yaparken, bu çalışmada hem geleneksel makine öğrenme yöntemlerine hem de topluluk yöntemlerine yer verilmiştir. Ayrıca [20-24]'te açıklanabilir yapay zeka teknikleri kullanılmamışken bu çalışma tahminlerin yorumlanabilirliğine de değinmiştir.

TABLO 1. ÇALIŞMALARDA KULLANILAN TEKNİKLERİN ÖZETİ

	<i>Geleneksel Makine Öğrenmesi Yöntemleri</i>	<i>Topluluk Yöntemleri</i>	<i>Yeniden Örneklem Yöntemleri</i>	<i>XAI Yöntemleri</i>
[20]	KA, DVM, KNN, YSA	X	X	X
[21]	NB, DVM, YSA	X	X	X
[22]	NB, KA, LR, DVM, KNN, YSA	RO	✓	X
[23]	NB, KA, LR, YSA, KNN	XGBoost	✓	X
[24]	KA, KNN	RO, XGBoost	X	X
[25]	NB, KA, DVM, KNN	RO	✓	✓
[26]	LR, DVM, KNN	RO, XGBoost	✓	✓
[27]	NB, KA, LR, KNN	RO, XGBoost, LightGBM, GB, AdaBoost, CatBoost,	X	✓
[28]	--	TriBoost	✓	✓
Bu Çalışma	LR, DVM, YSA	RO, XGBoost, GBM	✓	✓

III. YÖNTEM

Bu çalışmada açık erişimli telekom verisi üzerinde müşteri kaybı tahmini farklı makine öğrenmesi yöntemleriyle yapılmış ve performans değerlendirilmesi sunulmuştur. Ayrıca en başarılı yöntemin sonuçlarının yorumlanabilmesini sağlamak için açıklanabilir yapay zeka yöntemi kullanılmıştır. Çalışmanın deney tasarımı Şekil 1'de şematize edilmiştir. Buna göre ham veriye öncelikle veri ön işleme adımları uygulanmıştır. Daha sonra veri 80:20 oranında eğitim ve test verisi olmak üzere iki parçaya ayrılmıştır. Verideki sınıf dengesizliği problemini gidermek için sadece eğitim verisi olarak ayrılan kısım sentetik veri üretimi tekniği kullanılarak dengeli hale getirilmiştir. Bu işlem test için ayrılan kısma uygulanmamıştır. Aksi halde, test verisindeki üretilmiş veriler, makine öğrenmesi yönteminin eğitildiği veriyle benzerlik gösterecektir. Makine öğrenmesi yöntemleri dengeli hale getirilmiş veriye uygulanarak eğitilmiştir. Performans ölçümü için uygulanan testler sınıf dengesizliği bulunan test verisi üzerinde yapılmıştır. Böylece makine öğrenmesi yöntemlerinin performansının olduğundan daha iyi olduğu algısına yol açan aşırı uyum probleminin önüne geçilmiştir [22].

Makine öğrenmesi yöntemlerinden elde edilen sonuçlara göre en başarılı modele açıklanabilir yapay zeka yöntemi uygulanarak sonuçlar yorumlanmıştır.

A. Veri Seti

Bu çalışmada müşteri kaybı tahmini için açık erişimli, sınıf dengesizliği bulunan bir telekom verisi [29] kullanılmıştır. Veri setinde 7043 müşterinin *Cinsiyet (gender)* ve *Yaşlı/Emekli olma*

durumu (SeniorCitizen) gibi demografik bilgilerini, *Abonelik Süresi (tenure)* ve *Kontrakt bilgisi (Contract)* gibi hesap bilgilerini, *Telefon hizmeti (PhoneService)* ve *İnternet Hizmeti (InternetService)* olup olmadığı gibi hizmet bilgilerini içeren öznitelikler yer almaktadır. Biri ikili sınıf değişkeni olmak üzere farklı türlerde toplam 21 öznitelik bulunmaktadır. Öznitelikler ve açıklamaları Tablo 2'de ayrıntılarıyla görülebilir. İkili sınıf değişkeninde 1849 müşteri *Ayrılan*, 5194 müşteri *Ayrılmayan* olarak etiketlendiğinden veride sınıf dengesizliği bulunduğu anlaşılmaktadır. Dengesizlik oranı, baskın sınıfın örneklem büyüklüğünün azınlık sınıfının örneklem büyüklüğünün oranı olarak hesaplanabilir. Çalışmada kullanılan veri seti için bu oran %35,5'tir.

B. Veri Ön İşleme

Veri ön işleme aşamasında öncelikle veri setinde tekrarlayan ya da eksik değerler bulunup bulunmadığı kontrol edilmiş, bu tip örneklerle rastlanmamıştır. Sonrasında verideki kategorik değerler one-hot kodlama tekniğiyle nümerik değerlere dönüştürülmüştür. Artan sütun sayısının kontrol edilebilir boyutta kalmasını sağlamak için dönüştürülen her öznitelik için kategori sayısı 4'e indirilmiştir. Bütün özniteliklerin müşteri kaybına etkisinin ölçülebilmesi, açıklanabilir yapay zeka modelinde değerlendirilebilmesi için öznitelik seçme işlemi uygulanmamıştır. Ancak *Müşteri Numarası (customerID)* her müşteri için farklı bir değere sahip olduğundan ayrılacak müşteri tahmininde belirleyici olmadığı kanaatiyle silinmiştir. Bununla veri boyutunun makul seviyede tutulması amaçlanmıştır.

TABLO 2. ÖZNİTELİKLER

	<i>Öznitelik</i>	<i>Açıklama</i>	<i>Veri Tipi</i>
1	<i>customerID</i>	Müşteri Numarası	Nümerik
2	<i>gender</i>	Cinsiyeti	Kategorik
3	<i>SeniorCitizen</i>	Yaşlı/Emekli olup olmaması	Kategorik
4	<i>Partner</i>	Eş Durumu	Kategorik
5	<i>Dependents</i>	Bakmak zorunda olduğu kişi olup olmadığı	Kategorik
6	<i>tenure</i>	Abonelik süresi (ay)	Nümerik
7	<i>PhoneService</i>	Telefon servisi alma durumu	Kategorik
8	<i>MultipleLines</i>	Birden fazla hatta sahip olma durumu	Kategorik
9	<i>InternetService</i>	İnternet servis sağlayıcısı	Kategorik
10	<i>OnlineSecurity</i>	Çevrimiçi güvenliğinin olup olmadığı	Kategorik
11	<i>OnlineBackup</i>	Çevrimiçi yedeği sahibi olup olmadığı	Kategorik
12	<i>DeviceProtection</i>	Cihaz korumasına sahip olup olmadığı	Kategorik
13	<i>TechSupport</i>	Teknik destek alıp almadığı	Kategorik
14	<i>StreamingTV</i>	İnternet TV kullanıp kullanmadığı	Kategorik
15	<i>StreamingMovies</i>	İnternet Film kullanıp kullanmadığı	Kategorik
16	<i>Contract</i>	Kontrat süresi	Kategorik
17	<i>PaperlessBilling</i>	Elektronik fatura kullanıp kullanmadığı	Kategorik
18	<i>PaymentMethod</i>	Ödeme şekli	Kategorik
19	<i>MonthlyCharges</i>	Aylık ödeme miktarı	Nümerik
20	<i>TotalCharges</i>	Toplam ödeme miktarı	Nümerik
21	<i>Churn (Sınıf Değişkeni)</i>	Ayrılmaya durumu	Kategorik

C. Verinin Dengeli Hale Getirilmesi

Sınıf dengesizliği bulunan verinin dengeli hale getirilmesi için literatürde farklı yöntemler mevcuttur. Bu yöntemler üç ana grupta incelenebilir:

1) Alt Örneklem:

Bu yöntem, baskın sınıfa ait verilerden rastgele seçilen bir bölümün silinmesiyle gerçekleşir. Veri setini daha dengeli hale getirmenin yanı sıra, özellikle büyük veri kümelerinde daha küçük boyutlu veriye çalışılmasını sağlar. Bu da makine öğrenmesi yöntemlerinin hesaplama süresini kısaltır. Ancak, silinen verilerdeki bilgiler kaybolduğundan yetersiz uyum (underfitting) problemine yol açabilir.

2) Aşırı Örneklem:

Azınlık sınıfına ait verilerden rastgele seçilen bir bölümünün tekrarlanarak bu sınıfa ait veri sayısının artırılması olarak tanımlanabilir. Bu yöntemde bilgi kaybı olmadığından alt örnekleme göre daha üstün bir yöntemdir. Ancak, verilerin bir kısmı aynen tekrarlandığı için aşırı uyum (overfitting) problemine yol açabilir.

3) Sentetik Veri Üretimi:

Bu yöntemde, azınlık sınıfına ait yeni sentetik veriler oluşturularak veri setine eklenir. Bu şekilde dengeli hale getirilen veride hem aşırı uyum hem de yetersiz uyum sorunları daha az görülür. Literatürde sentetik veri üretimi için farklı stratejilere sahip birçok yöntem vardır. Bunlar arasında Sentetik Azınlık Aşırı Örneklem Yöntemi (Synthetic Minority Over-sampling Technique - SMOTE) en yaygın kullanılan sentetik veri üretme tekniklerinden biridir. Chawla vd. [30] tarafından geliştirilen bu yöntem birçok sentetik veri üretme algoritması için de temel oluşturur. Bu yöntemin çalışma prensibi şu şekildedir: Öncelikle azınlık sınıftan rastgele bir örnek seçilir. Bu örneğin azınlık sınıfına ait k en yakın komşusu belirlenir. Bu komşular arasından bir tanesi rastgele seçilir ve seçilen örnekler bir doğru üzerinde birleştirilir. Bu doğru üzerindeki seçilen rastgele bir nokta, yeni sentetik veri olarak veri setine eklenir. Bu şekilde oluşturulan sentetik veri, seçilen iki örneğin bir doğrusal kombinasyonu olarak hesaplanmış olur.

Bu çalışmada verideki sınıf dengesizliği problem SMOTE yöntemi ile sentetik veri üretilerek giderilmiştir. Yeniden örneklenmiş veri setinde dengesizlik oranı 1'dir. Yani *Ayrılan* ve *Ayrılmayan* müşteri sayıları birbirine eşitlenmiştir.


D. Makine Öğrenmesi Yöntemleri

Bu çalışmada telekom verisinde müşteri kaybı tahmini için verimliliği ve güvenilirliği dolayısıyla sıklıkla kullanılan makine öğrenmesi yöntemlerinden Lojistik Regresyon, Destek Vektör Makineleri, Yapay Sinir Ağları, Rastgele Orman, Gradyan Güçlendirme Makineleri ve Aşırı Gradyan Güçlendirme yöntemlerinin performanslarının karşılaştırılması sunulmaktadır. Kullanılan yöntemlere ait kısa bilgiler aşağıda yer almaktadır.

1) Lojistik Regresyon (LR)

Lojistik regresyon, özellikle ikili sınıflandırma problemleri için kullanılan, amacın bağımsız değişkenlere (özniteliklere) göre bir olayın meydana gelme olasılığını tahmin etmek olduğu istatistiksel bir yöntemdir. Oluşturulan model, bağımsız değişkenlerin doğrusal kombinasyonunu olasılıklara dönüştürmek için logit fonksiyonunu

kullanır ve tahmin edilen olasılıkların 0 ile 1 arasında olmasını sağlar. Lojistik regresyondaki katsayılar, diğer tüm değişkenleri sabit tutarken bağımsız değişkenden bir birimlik değişiklik için olasılık oranındaki değişikliğini temsil eder. Bu, sonuçların olayın



Şekil 1. Deney Tasarımı.

gerçekleşme olasılığı açısından yorumlanmasına olanak tanır.

2) Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri hem sınıflandırma hem de regresyon için kullanılan bir denetimli öğrenme yöntemidir [31]. DVM ana fikri öznitelik uzayında sınıfları aralarındaki uzaklığı maksimize edecek şekilde ayıran optimum hiper düzlemi belirlemektir. Bu hiper düzlem, hiper düzlem ile destek vektörleri olarak bilinen her bir sınıfın en yakın veri noktaları arasındaki mesafe olan en büyük marja sahip olacak şekilde seçilir. DVM'ler özellikle verilerin doğrusal olarak ayrılamadığı durumlarda polinom, sigmoid gibi çekirdek fonksiyonları kullanarak verilerin doğrusal olarak ayrılabilir hale geldiği daha büyük boyutlu bir uzaya yansıtır ve etkili sınıflandırmaya izin verir. DVM'lerin amacı, marjı en üst düzeye çıkararak yanlış sınıflandırma riskini en aza indirmektir. Bu, DVM'leri özellikle öznitelik sayısının veri sayısına kıyasla büyük olduğu durumlarda etkili kılar ve güçlü sınıflandırma performansı sunar.

3) Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beyninin yapısı ve işlevinden esinlenen temel bir makine öğrenmesi yöntemidir. Birbirine bağlı düğümlerden veya bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı olmak üzere katmanlar halinde düzenlenmiş nöronlardan oluşur. Giriş katmanı, karmaşık, doğrusal olmayan ilişkileri modellemek için ağırlıklar ve aktivasyon fonksiyonları kullanılarak gizli katmanlar aracılığıyla işlenen ham verileri alır. Her nöron girdilerinin ağırlıklı bir toplamını hesaplar, doğrusal olmayan bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana aktarır. Eğitim sırasında ağ, tahmin edilen ve gerçek çıktılar arasındaki hatayı en aza indirmek için geriye yayılma gibi teknikler kullanarak bu ağırlıkları hesaplar. Bu yinelemeli öğrenme süreci, yapay sinir ağlarının verilerden otomatik olarak örüntüler ve özellikler çıkarmasını sağlar. YSA verilerden genelleme yapma ve karmaşık sorunları yüksek doğrulukla ele alma yetenekleri nedeniyle görüntü tanıma, doğal dil işleme, tahmine dayalı modelleme ve karar verme gibi uygulamalarda yaygın olarak kullanılmaktadır.

4) Rastgele Orman (RO)

Rastgele Orman, tahminlerin doğruluğunu artırmak için birden fazla karar ağacını birleştiren bir topluluk öğrenme yöntemidir. Rastgele Ormanın ana fikri, her biri verinin rastgele bir alt kümesi üzerinde

eğitilmiş çok sayıda karar ağacı oluşturmaktır. Bu rastgelelik, aşırı uyumu azaltmaya yardımcı olur ve modelin genelleme yeteneğini artırır. Ormandaki her ağaç hedef değişkeni tahmin eder ve nihai tahmin, sınıflandırma problemlerinde oylama veya regresyon

TABLO 3. MODEL HİPERPARAMETRELERİ

	Hiperparametre	Değer
DVM	Kernel	Linear
	C	10
YSA	Gizli katman boyutu	(64,32)
	Aktivasyon	Relu
	Çözümleyici	Adam
	Max-iterasyon	200
RO	n-tahminci	100
GGM	n-tahminci	100
	Öğrenme-hızı	0.3
	Max- derinlik	3
XGB	Yineleme sayısı	100
	Öğrenme-hızı	0.1
	Max- derinlik	3

problemlerinde ortalama alma yoluyla tüm ağaçların tahminlerinin değerlendirilmesiyle yapılır. RO birden fazla karar ağacının güçlü yönlerinden yararlanarak hem kategorik hem de sayısal verileri işleyebilir. Bundan dolayı araştırmacılar tarafından büyük ve karmaşık veri setlerinde sıklıkla tercih edilir.

5) Gradyan Güçlendirme Makineleri (GGM)

Gradyan Güçlendirme Makineleri hem regresyon hem de sınıflandırma problemleri için kullanılan güçlü bir topluluk öğrenme yöntemidir. GGM'lerin çalışma prensibi karar ağaçları gibi birden fazla zayıf öğreniciyi sırayla birleştirerek güçlü bir tahmin modeli oluşturmaktır. Sıradaki her ağaç, tahmin edilen ve gerçek değer arasındaki farklara odaklanarak kendinden önceki ağacın hatalarını düzeltmek üzere eğitilir. Bu iteratif süreç, gradyan iniş optimizasyonunu kullanarak ortalama karesel hata veya log kaybı gibi belirli bir kayıp fonksiyonunu en aza indirir. GGM'ler, tüm ağaçların tahminlerini bir araya getirerek verideki karmaşık ilişkileri yakalayan sağlam bir tahmin modeli oluşturur. GGM farklı kayıp fonksiyonlarına göre uyarlanabilir. Ayrıca düzenleme ve öğrenme hızı ayarı gibi teknikler aracılığıyla aşırı uyumu azaltmada etkilidir. Bu özellikler GGM'leri çeşitli uygulamalarda yüksek performanslı modelleme için popüler bir seçenek haline getirmektedir.

6) Aşırı Gradyan Güçlendirme (XGBoost)

Aşırı Gradyan Güçlendirme hızı, ölçeklenebilirliği ve tahmin performansı ile öne çıkan gradyan artırma algoritmasının optimize edilmiş ve gelişmiş bir uygulamasıdır. GGM'inkine benzer şekilde karar ağaçları gibi zayıf öğrenicileri yinelemeli olarak birleştirerek tahmin modelleri oluşturur. Ancak XGBoost'da aşırı uyumu kontrol etmek için bulunan L1 (Lasso) ve L2 (Ridge) düzenlemeleri GGM'de bulunmamaktadır. Ayrıca XGBoost, paralel işleme, etkin bellek yönetimi ve önbelleğe duyarlı algoritmalar gibi iyileştirmeler sayesinde GGM'den daha hızlı sonuç üretebilmektedir. Dağıtık hesaplamayı desteklemesi büyük ölçekli veri kümelerinde çalışmasını kolaylaştırmaktadır. XGBoost, seyrekliğe duyarlı algoritmalar kullanarak verideki eksik değerleri kendi içindeki yapılarla işlerken, GGM genellikle bunun için veri ön işleme

gerektirir. XGBoost, aşırı uyumla daha iyi mücadele edebilmek için ağaçlar için bırakma düzenlemesi getiren DART (Bırakma Katkılı Regresyon Ağaçları) gibi ek teknikler içerir. Bu tür özellikler GGM uygulamalarında mevcut değildir. XGBoost'un sahip olduğu bu özellikler araştırmacılar tarafından sıklıkla tercih edilmesini sağlamaktadır.

IV. DENEYSEL BULGULAR VE TARTIŞMALAR

Bu bölümde deneylerden elde edilen sonuçlar, bu sonuçlara göre özneteliklerin değerlendirilmesi ve bunların tartışılması yer almaktadır.

A. Makine Öğrenmesi Modellerinin Performansı ve Tartışma

Makine öğrenmesi modelleri Scikit-learn paketi [32] kullanılarak Python programla diliyle uygulanmıştır. Modellerin performansını optimize etmek için ızgara arama (grid search) yöntemiyle hiperparametre ayarlaması yapılmıştır. Modeller için seçilen bazı hiperparametreler Tablo 3'te görülmektedir. Bunlar dışındaki parametreler için varsayılan değerler kabul edilmiştir.

Modellerin performansı Doğruluk, Kesinlik, Duyarlılık, F1-Skoru ve ROC-Eğrisinin Altında Kalan Alan (ROC-AUC) ölçütlerine göre değerlendirilmiştir. Elde edilen sonuçlar Tablo 4'te sunulmuştur. Her bir ölçüt için en iyi performans değeri koyu, en düşük performans değeri ise italik ile gösterilmiştir. Çalışmada kullanılan spesifik veri setinden elde edilen sonuçlara göre Rastgele Orman bütün ölçütlere göre en iyi performansı sergileyerek diğerlerine üstünlük sağlayan yöntem olmuştur. Destek Vektör Makineleri Doğruluk ve Keskinlik ölçütlerine göre, Yapay Sinir Ağları ise Duyarlılık, F1-skoru ve ROC-AUC ölçütlerine göre en düşük performansı sergileyen yöntemler olmuşlardır.


TABLO 4. MAKİNE ÖĞRENMESİ MODELLERİNİN PERFORMANSI

	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru	ROC-AUC
LR	0.759	0.543	0.796	0.645	0.770
DVM	0.748	0.528	0.817	0.641	0.770
YSA	0.774	0.599	0.543	0.570	0.702
RO	0.859	0.874	0.837	0.855	0.859
GBM	0.796	0.647	0.572	0.607	0.726
XGB	0.777	0.576	0.719	0.639	0.759

Deney sonuçlarına göre Rastgele Orman modeli müşteri kaybını %85,9 gibi yüksek bir doğruluk oranıyla tahmin edebilmektedir. Rastgele Orman birden çok karar ağacının bir araya gelerek oluşturduğu bir topluluk öğrenme modeli olduğu için topluluk öğrenme modeli olmayan LR, DVM ve YSA'dan daha iyi performans göstermesi şaşırtıcı olmamıştır. Çalışmada yer verilen diğer topluluk öğrenme yöntemleri olan GGM ve XGBoost modelleri doğruluk ölçütüne göre topluluk öğrenme modeli olmayan LR, DVM ve YSA'dan daha iyi performans sergilemiş olmalarına rağmen özellikle dengesiz veri setlerindeki performans değerlendirmelerinde sıklıkla tercih edilen F1-skoru ve ROC-AUC ölçütlerine göre bu modellerden daha düşük başarı değerlerine sahip olmuşlardır. Bu sonucun kullanılan veri setinin özelliklerinden kaynaklandığı düşünülmektedir. Çünkü GGM ve XGBoost modellerinin daha çok büyük ve karmaşık bir yapıya sahip veri setlerinde daha başarılı sonuçlar verdikleri bilinmektedir [33].

İleriki bir çalışma konusu olarak GGM ve XGBoost yöntemlerinin daha büyük boyutlu ve öznelilik ilişkilerinin daha karmaşık olduğu veri setlerindeki performanslarının gözlemlenmesi planlanabilir.

setini kullanan [25]'in Rastgele Orman modelinden elde ettiği sonuç %77,9 iken bu çalışmada aynı yöntemle %85,9 başarı elde edilmiştir. Bu çalışmada üretilen model mevcut çalışma sonuçlarından daha başarılı sonuçlar üreterek telekom sektöründe



Şekil 2. RO modeline göre özneliliklerin katkılarını gösteren SHAP değerleri

Topluluk öğrenme modelleri kendi aralarında değerlendirildiğinde de Rastgele Orman modelinin GGM ve XGBoost'tan daha iyi performans sergilemesinin sebebi olarak Rastgele Orman modelinin küçük ve dengesiz veri setlerinde diğerlerinden daha başarılı tahminlerde bulunması gösterilebilir.

Çalışmanın bulguları yeniden örnekleme ile dengelenmiş veri setinde topluluk öğrenme yöntemlerini de içeren farklı modellerin performansını değerlendiren mevcut çalışmalarla da kıyaslanmıştır. Tüm çalışmalar modellerin F1-skorunu raporladığından kıyaslama bu ölçüte göre yapılmıştır. Buna göre [22]'de SMOTE ile dengelenmiş veri setinden iyi performansı %78,9 ile DVM göstermiştir. Topluluk öğrenme modeli olarak sadece RO kullanılmış, performansı %74 olmuştur. [23] topluluk öğrenme yöntemleri olarak XGboosting ve Gradyan Artışı yöntemleri kullanılmış, XGboosting %68,8 ile en iyi performansı sergilerken buna en yakın geleneksel makine öğrenmesi modeli %46,72 başarı ile Karar ağaçları modeli olmuştur. [25]'te ise SMOTE ile dengelenmiş veri setinde topluluk öğrenme yöntemi olan Rastgele Orman %77,9 başarı oranı göstermiştir. [26]'da ise XGBoost algoritması %99 başarı ile yüksek bir performans sergilemiştir. [27]'de LightGBM yöntemi %73,085 doğruluk oranı ile en iyi performansa sahip yöntem olmuştur. [28]'de ise topluluk öğrenme yöntemlerinin kendi aralarında yapılan değerlendirmede kombine yöntemin bireysel yöntemlere göre kayda değer bir iyileştirme sağlamadığı gözlemlenmiştir.


Mevcut çalışmalardan elde edilen sonuçlar, bu çalışmadan elde edilen topluluk yöntemlerinin geleneksel makine öğrenmesi yöntemlerinden daha iyi performans sergilediği sonucunu desteklemektedir. Bu çalışmadaki yöntemle en yakın yöntem ve veri

müşteri kaybı tahminine katkı sağlamıştır.

B. Özneliliklerin Değerlendirilmesi

Telekom sektöründe ayrılacak müşterilerin önceden doğru tahmin edilmesi müşteri kaybını önlemede tek başına yeterli olmamaktadır. Ayrılacak müşteri tahmin edildikten sonra bu müşterilere sağlanacak teşvik ve promosyonların doğru belirlenerek müşteri kaybının en aza indirilmesi hedeflenmektedir. Makine öğrenmesi modelleri yüksek tahmin performansı göstermelerine rağmen teşviklerin planlanması için bilgi sunmazlar. Ancak açıklanabilir yapay zeka yöntemleri kullanılarak makine öğrenmesi modelinin tahminlerinin arkasındaki sebeplerin şeffaf bir şekilde yorumlanması sağlanabilir.

Bu çalışmada açıklanabilir yapay zeka yöntemlerinden Shapley Katkı Açıklamaları (SHAP-Shapley Additive Explanations) kullanılmıştır. SHAP yöntemi ana fikri Lloyd Shapley'nin oyun teorisinde oyuncuların oyunun skoruna bireysel katkılarını bulmak için hesapladığı Shapley değerlerine dayanmaktadır [34]. Benzer mantıkla verideki her bir özneliliğin Shapley değeri hesaplanarak makine öğrenmesi modelinin performansına olan katkısı açıklanmaya çalışılır. Bu yöntem telekom sektöründe müşteri kaybı tahmini probleminde müşterilerin ayrılacak diye tahmin edilmesinde hangi özneliliklerin katkısının daha fazla olduğunun belirlenmesini kolaylaştırır. Makine öğrenmesi modelinin tahminin ardındaki sebebin açıklanabilmesi belirlenen özelliklere sahip müşterilerin daha iyi analiz edilmesine olanak sağlar. Böylece bu müşterilerin ayrılmalarını önleyecek teşvik ve promosyonlar daha kolay ve doğru bir şekilde belirlenebilir



Şekil 3. Rastgele Orman modeline göre Arı Sürüşü Grafiği

Bu çalışmada kullanılan veri setinde %85,9 doğruluk oranıyla en iyi performans gösteren Rastgele Orman modelinin sonuçlarını yorumlayabilmek amacıyla SHAP yöntemi kullanılmıştır. Bu yöntemle hesaplanan ağırlıklara göre sıralanmış en önemli on öznetelik Tablo 5 'te sunulmuştur. Şekil 2'de ise tüm özneteliklerin modele katkısı görülebilir. Bu sonuçlara göre Abonelik Süresi (*tenure*), Kontrat süresi (*Contract*) ve İnternet Servis Sağlayıcısı (*InternetService*) türü ayrılıp ayrılmama kararına en çok etki eden öznetelikler olarak görülmektedir. Müşterinin İnternet TV kullanıp kullanmadığı (*StreamingTV*), Birden fazla hatta sahip olup olmadığı (*MultipleLines*) ve Telefon servisi alma durumunun (*PhoneService*) modele katkısı en az olmuştur.

TABLO 5. RO MODELİNE GÖRE EN ÖNEMLİ 10 ÖZNETELİK

	Öznetelik	Ağırlık
1	tenure	0.604147
2	Contract_Two year	0.463502
3	InternetService_Fiber optic	0.347486
4	PaymentMethod_Electronic check	0.203429
5	MonthlyCharges	0.202202
6	Contract_One year	0.192431
7	PaperlessBilling_Yes	0.128885
8	StreamingMovies_Yes	0.126132
9	OnlineSecurity_Yes	0.121431
10	TechSupport_Yes	0.113812

Öznetelik değerlerinin RO modeliyle müşteri kaybı tahminine etkisinin anlaşılabilmesi için SHAP yöntemiyle çizilen Arı Sürüşü Grafiği (BeeSwarm plot) incelenmiştir. Şekil 3'te görülen grafikte

öznetelikler önem sıralarına göre yukarıdan aşağıya sıralanmışlardır. Her bir veri noktasının özneteliklere göre dağılımını kırmızı veya mavi renkteki noktalarla gösterilmiştir. Her noktanın rengi, ilgili özneteliğin orijinal değerini gösterir. Genellikle, yüksek öznetelik değerleri kırmızı, düşük değerler ise mavi renkte gösterilir. Her bir noktanın yataydaki yeri, o özneteliğin SHAP değerine göre belirlenir. Pozitif SHAP değerleri, yani merkezdeki dikey çizginin sağındaki noktalar, özneteliğin bu değerlerinin modelin sonucunu artırdığını, negatif SHAP değerleri, merkezdeki dikey çizginin solundaki noktalar ise modelin sonucunu azalttığını gösterir. Bu, öznetelik değerinin modelin çıktısına nasıl etkide bulunduğunu anlamaya yardımcı olur.

Şekil 3 bu bilgiler ışığında incelendiğinde müşteri kaybı tahminine etkisi en fazla olan Abonelik süresi (*tenure*)'nin değeri büyüdükçe müşterinin ayrılma olasılığının azaldığı anlaşılmaktadır. Buna göre müşteri kaybını en aza indirmek isteyen bir telekom firması uygulayacağı promosyon ve teşvikleri daha çok Abonelik süresi daha kısa olan müşterilerine yönelik planlayabilir. Benzer şekilde Kontrat süresi (*Contract*) arttıkça da ayrılma olasılığı azalmaktadır. Özellikle Kontrat süresi iki yıl olan müşterilerde bu olasılığın oldukça düşük olduğu görülmektedir. Buna göre firmanın müşterilerinin Kontrat Süresini uzattığında müşteri kaybının azalacağı beklenebilir. Ayrıca İnternet Servis Sağlayıcısı Fiber Optik olan müşterilerin ayrılma olasılığının daha fazla olduğu görülmektedir. Bu telekom firmasının fiber optik alt yapısının yeterli olmadığını düşündürmektedir. Buna göre firmanın fiber optik İnternet servis sağlayıcısına yatırım yaparak şartlarını geliştirmesi müşteri kaybını azaltmaya yardımcı olabilir. Bunun yanında Ödeme Şekli (*PaymentMethod*) incelendiğinde Elektronik Çek (*Electronic Check*) olan müşterilerin de ayrılma olasılığının daha fazla olduğu ama diğer ödeme türlerinin (Kredi kartı ve Posta Çeki) müşterilerin ayrılma kararında önemli bir etkisinin olmadığı görülmektedir. Bu da firmada Elektronik Çek ödeme türüyle ilgili bir problem olabileceğini düşündürmektedir. Firmanın bunu fark ederek problemi çözmesi ya da müşterileri diğer ödeme türlerine yönlendirmesi müşteri kaybını azaltmaya yönelik önlemler arasında

olabilir. Aylık ödeme miktarı (MonthlyCharges) bilgileri incelendiğinde ise ödeme miktarı çok fazla olan müşterilerin ayrılma olasılığının yüksek olduğu anlaşılrken ortalama bir miktar ödeyen müşterilerin ayrılıp ayrılmayacağına dair net bir çıkarım yapılamamaktadır.

V. SONUÇ

Telekomünikasyon sektöründe müşteri kaybı sebeplerini anlamak ve azaltmak büyüme ve karlılığı sürdürebilmek için oldukça önemlidir. Bu yüzden firmalar ayrılma riski yüksek müşterilerin önceden tahmin ederek bu müşterileri elde tutmaya yönelik geliştirecekleri teşvik ve promosyonlarla müşteri kaybını en aza indirmek isterler. Bunu gerçekleştirmede müşteri verilerini işleyip analiz eden makine öğrenmesi yöntemleri hangi müşterilerin ayrılabilceğini etkili bir şekilde tahmin etme yeteneği ile öne çıkmaktadır.

Bu çalışmada müşteri kaybı tahmini için başarılı bir makine öğrenmesi yöntemi belirlerken aynı zamanda müşteri kaybının arkasındaki nedenlere ilişkin öngörüler de sunmak hedeflenmiştir. Bunun için geleneksel makine öğrenmesi yöntemlerinden Lojistik Regresyon, Destek Vektör Makineleri ve Yapay Sinir Ağlarının performansı daha gelişmiş topluluk öğrenme yöntemleri olan Rastgele Orman, Gradyan Güçlendirme Makineleri ve Aşırı Gradyan Güçlendirme yöntemlerinin performansı ile kıyaslanmıştır. Telekom verilerinde sıklıkla karşılaşılan sınıf dengesizliği problemi model performansına olumsuz etkileri sebebiyle ele alınıp SMOTE yeniden örnekleme yöntemiyle giderilmiştir. Testlerde Rastgele Orman modeli %85,9 doğruluk oranı ile diğer modellere göre üstünlük sağlamıştır.


Makine öğrenmesi yöntemleri müşteri kaybı tahmininde yüksek başarı göstermesine rağmen özneliliklerin tahminleri nasıl etkilediğine dair bir bilgi sunmamaktadır. Müşterilerin ayrılma kararlarının ardındaki sebebi anlayabilmek, özneliliklerin önemi hakkında fikir edinmek için Rastgele Orman modelinin tahminleri için SHAP değerlerinden yararlanılmıştır. Bu bilgiler, müşteri kaybını en çok etkileyen faktörleri belirlemek isteyen telekom şirketleri için yol gösterici olmaktadır. Bu çalışmada kullanılan müşteri verisine göre SHAP değerleri kullanılarak, abonelik süresi, kontrat süresi ve internet servis sağlayıcısı türü özneliliklerinin müşteri kayıp tahmini üzerinde önemli etkiye sahip olduğunu belirlenmiştir. Böylece müşteri kaybına neden olan temel faktörlerin şeffaf bir şekilde yorumlanabilmesini sağlanmış, telekomünikasyon sektöründe müşteri kaybını en aza indirmek için geliştirilecek stratejilerin belirlenmesi kolaylaşmıştır.

KAYNAKLAR

- [1] J. Cao, X. Yu & Z. Zhang, "Integrating OWA and data mining for analyzing customers churn in E-commerce.", *J Syst Sci Complex*, vol.28, pp. 381–392, (2015) <https://doi.org/10.1007/s11424-015-3268-0>
- [2] J. Burez, & D. Van den Poel. "Crm at a pay-TV company: Using analytical models to reduce customer attrition by targeted marketing for subscription services". *Expert Systems with Applications*, 32, 277–288. (2007)
- [3] E. Kartal, Z. Özen, "Dengesiz Veri Setlerinde Sınıflandırma", *Mühendislikte Yapay Zekâ Uygulamaları*, Sakarya, 109-131, (2017).
- [4] C. Gui, "Analysis of imbalanced data set problem: The case of churn prediction for telecommunication", *Artif. Intell. Research*, 6:2, 93, (2017).
- [5] J. Burez and D. Van den Poel, "Handling class imbalance in customer churn prediction," *Expert Syst. Appl.*, vol. 36, no. 3 PART 1, pp. 4626–4636, (2009) doi: 10.1016/j.eswa.2008.05.027.
- [6] F. Emmert-Streib, O. Yli-Harja, M. Dehmer. "Explainable artificial intelligence and machine learning: A reality rooted perspective". *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(6), Article e1368. (2020).
- [7] A. Barredo Arrieta et al., "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI," *Inform Fusion*, vol. 58, pp. 82-115, (2020).
- [8] C. Kirui, et al. "Predicting customer churn in mobile telephony industry using probabilistic classifiers in data mining," *International Journal of Computer Science Issues (IJCSI)* 10.2 Part 1: 165 (2013).
- [9] P. Kisioglu and Y.I. Topcu, "Applying Bayesian Belief Network approach to customer churn analysis: A case study on the telecom industry of Turkey," *Expert Syst Appl*, vol. 38, no. 6, pp. 7151 7157, (2011).
- [10] I. Brandusoiu, G. Todorean, "Churn prediction modeling in mobile telecommunications industry using decision trees". *Journal of Computer Science and Control Systems*, 6(1), 14, (2013).
- [11] S. Nisha, G. K. Monika, and K. Garg. "Churn prediction in telecommunication industry using decision tree." *International Journal of Engineering Research & Technology (IJERT)* 6, no. 4: 439-433 (2017).
- [12] K. Preeti, et al. "Analysis of customer churn prediction in telecom industry using decision trees and logistic regression." *2016 symposium on colossal data analysis and networking (CDAN)*. IEEE,(2016).
- [13] J. Mandák, and J. Hančlová. "Use of Logistic Regression for Understanding and Prediction of Customer Churn in Telecommunications." *Statistika: Statistics & Economy Journal* 99.2 (2019).
- [14] Z. Yu, et al. "Customer churn prediction using improved one-class support vector machine." *Advanced Data Mining and Applications: First International Conference, ADMA 2005, Wuhan, China, July 22-24, 2005. Proceedings 1*. Springer Berlin Heidelberg, (2005).
- [15] G. Xia, and W. Jin. "Model of customer churn prediction on support vector machine." *Systems Engineering-Theory & Practice* 28.1: 71-77. (2008).
- [16] N. Sjarif, et al. "A customer Churn prediction using Pearson correlation function and K nearest neighbor algorithm for telecommunication industry." *Int. J. Advance Soft Compu. Appl* 11.2 (2019).
- [17] C. F. Tsai and Y. H. Lu, "Customer churn prediction by hybrid neural networks," *Expert Syst. Appl.*, vol. 36, no. 10, pp. 12547–12553, (2009). doi: 10.1016/j.eswa.2009.05.032.
- [18] S. and P. "A Neural Network based Approach for Predicting Customer Churn in Cellular Network Services" *International Journal of Computer Applications* (2011) doi:10.5120/3344-4605.
- [19] O. Adwan, et al. "Predicting customer churn in telecom industry using multilayer perceptron neural networks: Modeling and analysis." *Life Science Journal* 11.3: 75-81. (2014).
- [20] A., Keramati et. Al. "Improved churn prediction in telecommunication industry using data mining techniques", *Applied Soft Computing*, Volume 24, 994-1012, (2014). <https://doi.org/10.1016/j.asoc.2014.08.041>.
- [21] O. Kaynar v.d. "Makine öğrenmesi yöntemleriyle müşteri kaybı analizi", *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18 (1) , 1-14, (2017)
- [22] M. A. Aydın, "Müşteri kaybı tahmininde sınıf dengesizliği problemi", *Politeknik Dergisi*, 25(1): 351-360, (2022).
- [23] A. Sikri, R. Jameel, S.M. Idrees, et al. "Enhancing customer retention in telecom industry with machine learning driven churn prediction". *Sci Rep* 14, 13097 (2024). <https://doi.org/10.1038/s41598-024-63750-0>
- [24] M. Afzal, S. Rahman, D. Singh and A. Imran, "Cross-Sector Application of Machine Learning in Telecommunications: Enhancing Customer Retention Through Comparative

- Analysis of Ensemble Methods," in *IEEE Access*, vol. 12, pp. 115256-115267, (2024) doi: 10.1109/ACCESS.2024.3445281.
- [25] İ. Kök, "Açıklanabilir Yapay Zekaya Dayalı Müşteri Kaybı Analizi ve Elde Tutma Önerisi", *Müh.Bil.ve Araş.Dergisi*, c. 6, sy. 1, ss. 13–23, (2024) doi: 10.46387/bjesr.1344414.
- [26] P. Boozary, S. Sheykan, H. GhorbanTanhaei, C. Magazzino, "Enhancing customer retention with machine learning: A comparative analysis of ensemble models for accurate churn prediction", *International Journal of Information Management Data Insights*, Volume 5, Issue 1, 100331, (2025)
- [27] C. Özkurt, "Transparency in Decision-Making: The Role of Explainable AI (XAI) in Customer Churn Analysis", *ITEB*, vol. 2, no. 1, pp. 1–11, Jan. 2025.
- [28] Malhotra, R., Shah, S., Bansal, S. "Customer Churn Analysis Using Machine Learning in Telecom Industry". *Proceedings of Data Analytics and Management. ICDAM 2024. Lecture Notes in Networks and Systems*, vol 1301. Springer, Singapore. (2025).
- [29] <https://www.kaggle.com/blastchar/telco-customer-churn/version/1> (Son erişim tarihi: 05/02/2025)
- [30] N. V. Chawla, et.al., "SMOTE: Synthetic Minority Over-Sampling Technique", *Journal of Artificial Intelligence Research*, 16, 321–357 (2002).
- [31] B. E. Bernhard, I. M. Guyon, and V. N. Vapnik. "A training algorithm for optimal margin classifiers." *Proceedings of the fifth annual workshop on Computational learning theory*. (1992).
- [32] F. Pedregosa, et al. "Scikit-learn: Machine Learning in Python." *ArXiv abs/1201.0490* (2011)
- [33] H. Alshari, A. Saleh, ve A. Odabas, "CPU Performansı için Gradyan Artırıcı Karar Ağacı Algoritmalarının Karşılaştırılması", *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, c. 37, sy. 1, ss. 157–168, (2021).
- [34] S. M., Lundberg & S. I. Lee, "A unified approach to interpreting model predictions". *Advances in Neural Information Processing Systems*, 30, 4765-4774, (2017).

Özgeçmişler



M. Aslı Aydın, lisans derecesini Boğaziçi Üniversitesi Matematik Bölümü'nden, yüksek lisans ve doktora derecelerini sırasıyla Bahçeşehir Üniversitesi ve Boğaziçi Üniversitesi Endüstri Mühendisliği Bölümü'nden almıştır. Araştırma ilgi alanları arasında yöneylem araştırması ve makine öğrenmesi uygulamaları yer almaktadır. Güncel araştırmaları kombinatoriyal optimizasyon problemleri için takviyeli öğrenme yöntemleri üzerinde yoğunlaşmaktadır.

Türkçe Görüntü Altyazılama: Mevcut Çalışmalar, Uygulamalar, Veri Setleri, Metrikler ve Gelecekteki Olası Eğilimler Üzerine Bir İnceleme

Turkish Image Captioning: A Review of Current Studies, Applications, Datasets, Metrics and Potential Future Trends

Abbas Memiş

ID 0000-0003-2645-8071

Bilgisayar ve Bilişim Teknolojileri Fakültesi, Bilgisayar Mühendisliği Bölümü
İstanbul Üniversitesi
abbas.memis@istanbul.edu.tr

Özet

Son on yılda bilgisayarla görme ve makine öğrenmesinde kaydedilen sarsıcı gelişmeler, akıllı sistemlerin hızla yaygınlaştığı, çeşitlendiği ve insan hayatına daha çok etki ettiği bir dönemi başlatmıştır. Bu gelişmelerin ivmelendirdiği ve yön verdiği önemli araştırma alanlarından birisi de otomatik görüntü altyazılamadır. Son yıllarda otomatik görüntü altyazılama kapsamında çok farklı diller için kaydedeğer seviyede çalışmalar yapılmakla birlikte, Türkçe görüntü altyazılamada da önemli ve umut verici gelişmelerin yaşandığı görülmektedir. Sunulan makalede, Türkçe görüntü altyazılamadaki bu önemli ve umut verici gelişmelerin ışığında, Türkçe görüntü altyazılama özelindeki mevcut çalışmaları ve uygulamaları ele alan kapsamlı bir inceleme çalışması raporlanmıştır. Çalışma kapsamında, güncel literatürdeki çalışmalara ek olarak, uygulama alanları ve veri setleri de değerlendirilmiştir. Makalede ayrıca, görüntü altyazılama sistemlerinin altyazı oluşturma başarımlarını ölçmek amacıyla kullanılan genel ve standart metriklerle de yer verilmiştir. Bununla birlikte, Türkçe görüntü altyazılama için gelecekteki olası eğilimler ve potansiyel gelişmeler makale yazarlarının perspektiflerinden değerlendirilmiş ve paylaşılmıştır.

Anahtar kelimeler: Görüntü altyazılama, Türkçe görüntü altyazılama, görüntü altyazılama alanları, görüntü-altyazı veri setleri, görüntü altyazılama metrikleri.

Abstract

Over the past decade, groundbreaking advances in computer vision and machine learning have led to an era in which intelligent systems have become more widespread, diverse and impactful on human life. One of the major research areas accelerated and driven by these advances has been automatic image captioning. In recent years, not only a remarkable amount of work on automatic image captioning has been proposed for a wide range of languages, but there have also been significant and promising advances in Turkish image captioning. In the context of these notable and promising achievements in Turkish image captioning, a comprehensive review of existing studies and applications in the field of

Turkish image captioning is reported in this article. In addition to current studies in the literature, application domains and datasets are also covered. The paper also includes common and standard metrics used to measure the captioning performance of image captioning systems. Furthermore, possible future trends and potential developments for Turkish captioning are discussed from the authors' perspective and shared.

Keywords: Image captioning, Turkish image captioning, image captioning domains, image-caption datasets, image captioning metrics.

1. Giriş

Son birkaç on yılda, elektronik ve bilgisayar teknolojilerindeki ilerlemeler ve özellikle; yapay zekâ, bilgisayarla görme, görüntü işleme, makine öğrenmesi, derin öğrenme ve doğal dil işleme alanlarında yürütülen araştırmalar, akıllı sistemlerin gelişimine oldukça büyük bir katkı sağlamıştır. Bu gelişmelerin neticesinde ise, bugün akıllı sistemlerin seviye atlayarak hızla yaygınlaştığı, çeşitlendiği ve insan hayatına daha çok etki etmeye başladığı bir dönemden geçilmektedir. Akıllı sistemlerin son yıllardaki gelişiminde ve bu sistemlerin göstermekte olduğu başarıda, ImageNet 2012 Challenge'ta büyük bir etki yaratmış olan Evrimsel Sinir Ağı (Convolutional Neural Network, CNN) AlexNet [1] ile başlayan derin öğrenme süreci çok önemli bir rol oynamıştır. Derin öğrenme sayesinde, geleneksel makine öğrenmesi yaklaşımları ile sağlanan başarımlar domine edilerek oldukça üst seviyelere taşınmış ve neredeyse uzman bir insan kadar etkili akıllı sistemlerin geliştirilebilmesinin önü açılabilmiştir. Son yıllarda, ulaşım [2] ve tıptan [3] finansa [4], eğlenceye [5], çeviriye [6], medyaya [7], pazarlamaya [8], robotiğe [9] ve siber güvenliğe [10] kadar geniş bir yelpazede derin öğrenme tabanlı yaklaşımlar önerilmektedir.

Derin öğrenmede önemli gelişmelerin yaşandığı araştırma alanlarından birisi de bilgisayarla görme ve görüntü işleme olmuştur [11, 12]. Son yıllarda geliştirilen derin modeller sayesinde, çeşitli görüntüleme sistemlerinden elde edilen görüntüler ve videolar üzerinde tespit [13], takip [14], bölütleme [15], tanıma [16], anlama [17] gibi başlıca bilgisayarla görme işlemleri geleneksel yöntemlere nazaran

daha başarılı gerçekleştirilebilir hâle gelmiştir. Bilgisayarla görme kapsamında üzerine araştırma yürütülen önemli ve zorlu araştırma konularından bir diğeri ise görüntü altyazılamadır [18]. Görüntü altyazılama, temel olarak görüntülerin bilgisayar sistemleri tarafından otomatik bir biçimde yorumlanması ve görüntülerin içeriğine dair görsel bilgilerin metinsel formda ifade edilmesi olarak tanımlanır [18]. Otomatik görüntü altyazılama [19-21] sayesinde, görüntü içerikleri akıllı sistemler tarafından anlaşılabilen [22], ve bu içerik bilgisi ilgili sistemlerin çeşitli dâhili ve harici mekanizmalarında kullanılmaktadır.

Her ne kadar güncel literatürde görüntü altyazılama üzerine kapsamlı derleme ve inceleme çalışmaları [18, 23-27] yapılmış olsa da, bu alandaki çalışmaların kapsamı güncel teknolojiler ve uygulama alanları bağlamında farklılıklar gösterebilmekte ve kaydedilen hızlı gelişmelere bağlı olarak önerilen yeni yöntemleri, ortaya çıkan yeni uygulama sahalarını ve mevcut durumu ele almada belirli ölçüde yetersiz kalabilmektedir. Bununla birlikte, bilindiği kadarıyla, güncel literatürde Türkçe görüntü altyazılama üzerine yapılmış genel bir inceleme ve derleme çalışması raporlanmamıştır. Ayrıca, Türkçe görüntü altyazılama geçmişinin çok uzun olmaması ve bu alanda yapılmış çalışmaların da kısıtlı olması, bu alanda çalışma, tez veya proje üretmek isteyen araştırmacılar için zorluk teşkil edebilmektedir. Son yıllarda otomatik görüntü altyazılama kapsamında çok farklı diller için kaydedilen seviyede çalışmalar yapılmakla birlikte, Türkçe görüntü altyazılamada da önemli ve umut verici gelişmelerin yaşandığı görülmektedir. Sunulan makalede, Türkçe görüntü altyazılamadaki bu önemli ve umut verici gelişmelerin ışığında, Türkçe görüntü altyazılama özelindeki mevcut çalışmaları ve uygulamaları ele alan kapsamlı bir inceleme çalışması raporlanmıştır. Çalışma kapsamında, güncel literatürdeki çalışmalara ek olarak, uygulama alanları ve veri setleri de değerlendirilmiştir. Makalede ayrıca, görüntü altyazılama sistemlerinin altyazı oluşturma başarımlarını ölçmek amacıyla kullanılan genel metriklere de yer verilmiştir. Bununla birlikte yazarlar, Türkçe görüntü altyazılama için gelecekteki olası eğilimleri ve potansiyel gelişmeleri de kendi perspektiflerinden değerlendirmiş ve bu değerlendirmelerini paylaşmışlardır.

Makalenin ilerleyen bölümleri şu şekilde organize edilmiştir: Makalenin 2. bölümünde, otomatik görüntü altyazılama kapsamında; genel görüntü altyazılama yaklaşımlarına, görüntü altyazılama veri setlerine, görüntü altyazılama metriklerine ve görüntü altyazılamanın genel uygulama alanlarına yer verilmiştir. Bölüm 3'te ise, özel olarak otomatik Türkçe görüntü altyazılama ele alınmıştır. Bu bağlamda, Türkçe görüntü altyazılamada genel durum, mevcut çalışmalar, bu çalışmaların dâhil olduğu uygulama alanları, Türkçe görüntü-altyazı veri setleri ve Türkçe görüntü altyazılamanın geleceği ile olası eğilimler tartışılmıştır. Makalenin son bölümü olan Bölüm 4'te ise, sonuçlar ve genel değerlendirmeler paylaşılmıştır.

2. Otomatik Görüntü Altyazılama

Görüntü altyazılama, en sade biçimiyle, bir resmin içeriğinin kelimelerle tanımlanması, tasvir edilmesi olarak ifade edilebilir [18]. Bir görüntü altyazılama sistemi genel yapısı itibarıyla, girdi olarak aldığı her bir görüntü için, referans olarak kullandığı bir görüntü-altyazı seti üzerinden bir altyazı üretir. Üretilen bu altyazıların hem biçimsel (syntactic) hem de


anlamsal (semantic) olarak doğru olması beklenir [26]. Bu işlem temel olarak bir bilgisayarla görme görevi olmasına rağmen, metin oluşturma ve işleme de içerdiği için belirli bir ölçüde doğal dil işlemenin de kapsamına girer. Dolayısıyla otomatik görüntü altyazılama, her iki araştırma alanının da kesişiminde yer alan spesifik araştırma konularından birisidir. Görüntü altyazılama, öne çıkan ve popüler bazı uygulama alanlarında (uzaktan algılama [28-30], sosyal medya [31-33], haber [34-36], tıp [37-39], turizm [40-42], sanat ve kültür [43-45], kimya ve biyoloji [46-48]) kullanılabiliyor olmasının yanında, doğası gereği birçok alanda ve çok farklı amaçlara yönelik olarak uygulanabilme potansiyeline de sahiptir [49]. Görüntü altyazılama probleminin çözümü için güncel literatürde, farklı kategorilerde sınıflandırılacak birçok yöntem önerilmiştir. Bununla birlikte, bu alandaki araştırma çalışmalarına destek vermek amacıyla çeşitli araştırma grupları tarafından farklı veri setleri de oluşturulmuş ve paylaşılmıştır. Aşağıdaki alt başlıklarda, görüntü altyazılamada kullanılan genel yaklaşımlar ile öne çıkan veri setleri ele alınmıştır. Ayrıca, görüntü altyazılama modellerinin altyazı üretimindeki başarımlarını değerlendirmek amacıyla kullanılan çeşitli metriklere de yer verilmiştir. Son kısımda ise görüntü altyazılamanın uygulama alanlarından bahsedilmiş ve bu alanlarda öne çıkan bazı spesifik örnekler tartışılmıştır.

2.1. Görüntü Altyazılamada Genel Yaklaşımlar

Görüntü altyazılama için geçmişten günümüze doğru önerilen yöntem ve yaklaşımları: 1) Geleneksel görüntü altyazılama yöntemleri ve 2) Derin öğrenme tabanlı görüntü altyazılama yöntemleri olmak üzere kabaca iki ana başlık altında kategorize etmek mümkündür [25]. Derin öğrenme öncesi dönemde önerilen yöntemler daha çok geleneksel yöntemler olarak sınıflandırılmakta olup, günümüz görüntü altyazılama sistemlerine nazaran daha basit ve ilkel bir yapıdadır. Bu kategoride yer alan yöntemler ise genel olarak şablon tabanlı (template-based) ve erişim tabanlı (retrieval-based) yöntemlerdir. Geleneksel yöntemler her ne kadar performans açısından belirli bir seviyede kabul görmüş olsa da açık problemlere sahiptir [50] ve otomatik görüntü altyazılamada yetersiz kalabilmektedir. Geleneksel yöntemlerle ilgili bu bağlamdaki hususlar ilerleyen satırlarda daha detaylı olarak ele alınmıştır. Derin öğrenmenin doğuşu ve son on yıldaki hızlı yükselişi birçok konuda ve araştırma alanında olduğu gibi görüntü altyazılamada da önemli gelişmeleri beraberinde getirmiştir. Bu sayede, geleneksel yöntemlerdeki bazı önemli eksikliklerin giderilebilmesinin önü açılmış, görüntü altyazılama için domine edici başarımlar gözlemlenmeye ve geleneksel yöntemler yerini derin modellere bırakmaya başlamıştır [50]. Derin öğrenme tabanlı yöntemler dâhilinde ise; CNN tabanlı, graf tabanlı, dönüştürücü (transformer) tabanlı, dikkat (attention) mekanizması tabanlı vb. olmak üzere çok çeşitli yaklaşımlar önerilmektedir. Şekil 1'de, görüntü altyazılama için kullanılan yöntem ve yaklaşımların kategorizasyonunu gösteren genel bir şema sunulmuştur.

2.1.1. Geleneksel Görüntü Altyazılama Yöntemleri

Şekil 1'de de görsel olarak ifade edildiği üzere, geleneksel görüntü altyazılama yöntemleri: 1) Şablon tabanlı ve 2) Erişim tabanlı yöntemler olmak üzere iki ana gruba ayrılır [51]. Şablon tabanlı yaklaşımlarda genel olarak önceden birtakım



Şekil 1: Görüntü altyazılamada genel yöntemler.

biçimsel kurallar tanımlanır ve buna bağlı olarak çeşitli altyazı şablonları belirlenir [52]. Görüntü altyazıları da bu şablonlara göre oluşturulur. Şablon tabanlı yaklaşımlarda öncelikle bir görüntüdeki içeriğe dair görsel bileşenlerin/kavramların (nesneler, bu nesnelerin özellikleri, edatlar ve görüntüdeki aksiyonlar yani fiiller vb. gibi) tespit edilmesi gerekir. Sonrasında ise bu bilgiler, altyazı şablonlarındaki önceden tanımlanmış boşluklara yerleştirilir ve bu sayede görüntü altyazıları oluşturulur. Şablon tabanlı yöntemler ile başarılı bir görüntü altyazılamaya gerçekleştirebilmek için bazı faktörlerin dikkate alınması gerekir. Bu faktörler sırasıyla; şablon oluşturma, görsel öğelerin ve kavramların tespiti ve bunlara göre anlamlı altyazı metinlerinin oluşturulması ile ilgilidir. Sistem tarafından oluşturulacak olan altyazının anlamsal bağlamdaki başarısında ise nesnelerin, nesne özelliklerinin ve görüntüdeki aksiyonların tespiti ayrıca önemlidir. Bu bakımdan, şablon tabanlı bir görüntü altyazılama modelinde nesnelerin, nesne özelliklerinin ve aksiyonların yüksek doğrulukla tespiti ve nesneler arası edatsal bilgilerin yüksek doğrulukla çıkarılması gerekir. Görüntülerdeki aksiyonların belirlenmesi noktasında, belirli nesne veya nesne grupları ile ilişkileri içeren ön-tanımlı bir nesne-aksiyon sözlüğü de tercih edilebilmektedir [52]. Ancak, şablon tabanlı yöntemler ile her ne kadar biçimsel açıdan hatasız görüntü altyazıları oluşturulabilse de, anlamsal açıdan her zaman başarılı altyazılar oluşturulamayabilir. Şekil 2’de, genel bir şablon tabanlı görüntü altyazılama modeli resmedilmiştir.

Geleneksel görüntü altyazılama teknikleri dâhilindeki ikinci yaklaşım ise erişim tabanlı görüntü altyazılama yaklaşımıdır. Bu yaklaşım, bilgisayarla görmede ele alınan görüntü erişimi (image retrieval) görevi ile oldukça benzer bir işlem mekanizmasına sahiptir. Erişim tabanlı görüntü altyazılama yöntemlerinde genel işleyiş temel olarak şu şekildedir: Altyazısı üretilecek bir görüntü (ki bu görüntü genelde sorgu görüntüsü olarak adlandırılır) mevcut bir görüntü veri setinde sorgulanır ve bu sorgu görüntüsüne içerik olarak en çok benzeyen görüntüler (aday görüntüler) belirlenir [51, 53]. Devamında ise, aday görüntülere ait önceden


tanımlanmış görüntü altyazıları referans alınarak sorgu görüntüsü için bir altyazı üretilir [53]. Üretilen görüntü altyazısı, doğrudan altyazı setindeki bir cümle olabileceği gibi, birden fazla altyazının birleşiminden elde edilen bir metin de olabilir [51]. Şekil 3’te, erişim tabanlı görüntü altyazılama modelleri için genel bir sistem yapısı görsel olarak ifade edilmiştir. Erişim tabanlı görüntü altyazılama yöntemlerinin, belirli bir seviyede başarılı altyazılar üretmesine rağmen, şablon tabanlı yöntemlerde olduğu gibi bazı kısıtları da bulunmaktadır. Bu tarz metotlar, biçimsel olarak doğru altyazılar üretebilmesine rağmen anlamsal olarak doğru görüntü altyazıları oluşturmada yetersiz kalabilirler [51]. Bununla birlikte, üretilecek olan görüntü altyazısının biçimsel ve anlamsal doğruluğu korpus olarak kullanılan görüntü altyazısı setine de doğrudan bağlıdır. Örneğin, eğitim setinin (korpus altyazı setinin) çok küçük ve anlamsal varyansının düşük olması, üretilecek olan altyazıların hem biçimsel hem de anlamsal olarak birbirine benzerliğini artırır. İlave olarak, yine aynı kısıta bağlı olarak, veritabanında sorgu görüntüsüne benzer görüntülere erişim olasılığı azalacağından, sorgu görüntüsü için çok anlamlı olmayan aday görüntüler seçilebilir. Bu durum ise, sorgu görüntüsü için oluşturulacak olan altyazının başarısına doğrudan etki eder ve görüntü ile uyum seviyesi düşük altyazıların üretilmesine sebep olur. Bahsi geçen hususlar sebebiyle, erişim tabanlı görüntü altyazılama için veri setinin büyüklüğü ile altyazı korpusunun anlamsal çeşitliliği oldukça önem arz eder.

2.1.2. Derin Öğrenme Tabanlı Görüntü Altyazılama Yöntemleri

Derin öğrenme birçok bilgisayarla görme uygulamasında olduğu gibi görüntü altyazılamada da önemli gelişmeleri tetiklemiştir [27, 50]. Derin öğrenme tabanlı yaklaşımlar sayesinde, sistemlerin görüntü altyazılamadaki başarımlarının artmasına ve daha anlamlı görüntü altyazıları üretilmesine ek olarak, geleneksel görüntü altyazılama yöntemlerindeki önemli eksikliklerin de üstesinden gelinebilmesinin önü açılmıştır. Derin öğrenmenin çok uzun bir geçmişi olmamasına rağmen, görüntü altyazılama konusunda derin öğrenme teknikleri kullanan, özellikle son yıllarda, kaydadeğer miktarda çalışma yapılmaktadır [54] ve bu bağlamda derin öğrenme tabanlı çok çeşitli görüntü altyazılama mimarileri [55-68] sunulmaktadır.

Şekil 1’de, görüntü altyazılama için kullanılan yöntem ve yaklaşımların kategorizasyonunu gösteren genel bir şemaya yer verilmişti. İlgili şekil üzerinden de takip edilebileceği üzere, derin öğrenme tabanlı görüntü altyazılama kapsamında; dikkat (attention) mekanizması tabanlı [57], graf tabanlı [60], CNN tabanlı [55], denetimsiz (unsupervised) öğrenme tabanlı [66], pekiştirmeli (reinforcement) öğrenme tabanlı [67], dönüştürücü (transformer) tabanlı [69], kodlayıcı-kod çözücü (encoder-decoder) tabanlı [62] vb. olmak üzere çok farklı yaklaşımlar önerilmiştir. Bununla birlikte, Yinelemeli Sinir Ağı (Recurrent Neural Network, RNN) [70, 71], Uzun Kısa-Süreli Bellek (Long Short-Term Memory, LSTM [72, 73] ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit, GRU) [74] gibi yapıların kullanımına da yaygın olarak rastlanmaktadır.

Derin öğrenme tabanlı yaklaşımların geleneksel görüntü altyazılamaya nazaran daha başarılı olmasındaki temel faktör, normale göre çok daha fazla, çeşitli ve ayırt edici özelliği çıkarmaya imkân verebilmesidir. Yakın geçmişte CNN tabanlı



Şekil 2: Şablon tabanlı görüntü altyazılama sistemlerinde genel yapı.



Şekil 3: Erişim tabanlı görüntü altyazılama sistemlerinde genel yapı.

ve kodlayıcı-kod çözücü tabanlı yöntemler ile görece yüksek başarımlara ulaşılmıştır [75]. Bu kategorilerdeki yöntemler, görüntülerdeki birincil ilgi bölgelerine ve esas aksiyonlara odaklanmadan genel olarak görüntüleri bir bütün olarak ele alıp özellik çıkarımı gerçekleştirmektedir. Bu nedenle, görüntüleri tasvir edecek olan önemli özellikler ile, görüntüyle ilintili olan ancak altyazılama için çok da değerli olmayan özellikler birlikte değerlendirilmektedir. Bu durumun altyazılama başarımı açısından ortaya çıkacağı zayıflıkları gidermek amacıyla, görüntülerdeki önemli ve öne çıkan ilgi bölgelerini, yani görüntüyü daha başarılı tasvir etmeyi sağlayacak olan önemli özellikleri ön plana çıkarmayı amaçlayan dikkat mekanizmaları önerilmiştir [18]. Dikkat mekanizmalarının kodlayıcı-kod çözücü modellerdeki başarısı, metinlerdeki bağlamı ve metnin farklı bölümleri arasındaki ilişkiyi öğrenmeye imkân veren dönüştürücü modellerin de geliştirilmesinin önünü açmıştır. Dönüştürücü modellerdekine benzer bir yaklaşım, görüntüleri çeşitli bölgelere ayıran ve bu bölgeler arasındaki bağlamı ve ilişkiyi öğrenmek için dikkat mekanizmasını kullanan görü dönüştürücülerde de (vision transformer) [76] kullanılmaktadır. Dönüştürücü tabanlı modeller, bahsedilen karakteristik özellikleri sayesinde, LSTM tabanlı klasik kodlayıcı-kod çözücü modellere nazaran daha başarılı görüntü altyazılama gerçekleştirebilmektedir. Derin öğrenme tabanlı bu yöntem ve yaklaşımlara ek olarak, graf tabanlı mekanizmalar ile varlıklar arasındaki etkileşimler de

tanımlanabilmekte ve görüntülerdeki zengin anlamsal bilgiler çıkarılabilmektedir [77, 78].

Son yıllarda, derin öğrenme tabanlı yöntem ve yaklaşımların görüntü altyazılama görevindeki kullanım ve uygulamalarına dair çeşitli spesifik inceleme raporları da yayınlanmaktadır [24, 25, 27, 18, 79, 75]. Oldukça kapsamlı olarak hazırlanmış olan bu raporlarda, derin öğrenme tabanlı yöntem ve yaklaşımlar etrafıca ele alınmaktadır. Derin öğrenme tabanlı görüntü altyazılama yöntemlerine dair daha detaylı bilgiler, ilgili derleme ve inceleme raporlarından ve özel araştırma çalışmalarına ait yukarıda paylaşılan kaynaklardan takip edilebilir.

2.2. Görüntü Altyazılama Veri Setleri

Genel-amaçlı görüntü altyazılama konusunda yapılan çalışmalarda gerek sistemlerin performanslarını sınamak, gerekse de önerilen sistemleri mevcut çalışmalarla kıyaslamak amacıyla genellikle iki temel görüntü-altyazı veri setinin kullanımı ön plana çıkmaktadır: MS COCO [80] ve Flickr [81, 82]. Literatürdeki çalışmalarda sıklıkla tercih edilen bu iki veri seti, görüntü altyazılama en çok kullanılan denektaşı (benchmark) veri setleri arasında yer almaktadır. İlgili veri setlerinden türetilmiş alt veri kümeleri de bulunmakla birlikte, bu alt veri kümelerinin de yaygın kullanımı göze çarpmaktadır. Örneğin, Flickr görüntü-altyazı veri seti için Flickr8K [81] ve Flickr30K [82] olarak

Tablo 1: Genel-amaçlı görüntü altyazılama için önerilmiş ve kullanıma açık bazı veri setleri.

Veri seti	Kaynak	Yıl	Görüntü sayısı	Görüntü başına altyazı	Altyazı dili
IAPR TC-12	[84]	2006	20,000	1-5	İngilizce, Almanca, İspanyolca
PASCAL1K	[85]	2010	1,000	5	İngilizce
UIUC Pascal	[86]	2010	1,000	5	İngilizce
SBU dataset	[87]	2011	1,000,000	1	İngilizce
Flickr8K	[81]	2013	8,092	5	İngilizce
Flickr30K	[82]	2014	31,783	5	İngilizce
MS COCO	[80]	2014	328,000	5	İngilizce
YFCC100M	[88]	2016	100,000,000	≥ 1	İngilizce, İspanyolca, Çince, Fransızca vd. [89]
Google Refexp	[90]	2016	26,711	≥ 1	İngilizce
InstaPIC	[31]	2017	721,176	1	İngilizce
FlickrStyle10K	[91]	2017	10,000	1-5	İngilizce
Google's Conceptual Captions	[92]	2018	$\approx 3,300,000$	1	İngilizce
Nocaps	[93]	2019	15,100	11	İngilizce
TextCaps	[94]	2020	28,408	5	İngilizce
Conceptual 12M	[95]	2021	12,000,000	1	İngilizce

isimlendirilmiş ve farklı sayılarda görüntüler içeren alt kümeler tanımlanmıştır. Bununla birlikte, "Karpathy's split" [83] olarak bilinen ve MS COCO, Flickr8K ve Flickr30K veri setlerinden oluşturulmuş bir veri seti de mevcuttur. Andrej Karpathy tarafından tanımlanan bu veri kümesi de oldukça popülerdir. MS COCO ve Flickr ile birlikte, genel-amaçlı görüntü altyazılama için önerilmiş ve genel kullanıma açık diğer bazı veri setlerine ait bilgilere Tablo 1'de yer verilmiştir. Tablo 1'de, bu veri setlerindeki toplam görüntü sayısı, görüntü başına tanımlı altyazı sayısı ve altyazıların yazıldığı dil bilgisi de paylaşılmıştır.

Tablo 1'de verilen ve ekseriyeti İngilizce olan genel görüntü-altyazı veri setleri haricinde; Japonca [96], Arapça [97], Bengalce [98] ve Hintçe [99] gibi diller esas alınarak oluşturulmuş daha özel ve yerel görüntü altyazılama veri setleri de mevcuttur. Ancak bu tarz veri setlerinin bir bölümünün (örneğin [97, 99]) Flickr gibi bilinen veri setlerinden otomatik çeviri yoluyla elde edildiği de göz önünde bulundurulmalıdır. Tablo 1'deki genel görüntü-altyazı veri setleri dışında, görüntü altyazılama için önerilmiş SentiCap [100] (duygu tabanlı görüntü altyazılama tabanlı) ve Visual Genome [101] (bölgesel görüntü açıklamaları tabanlı) gibi spesifik veri setleri de mevcuttur. Buna ek olarak, uzaktan algılama görüntüsü altyazılama [102] ve tıbbi görüntü altyazılama [103] gibi alana-özel (domain-specific) görüntü altyazılama çalışmalarında kullanılan veri setleri de mevcut olmakla birlikte, bu tarz veri setleri bu çalışma kapsamında özel olarak ele alınmamıştır. Ayrıca, video görüntü altyazılama [104-106] ve bu amaçla önerilmiş veri setleri de (ör. MSVD [107], MSR-VTT [108], MSVD-S [109] vb.) çalışma kapsamında incelenmemiştir.

2.3. Görüntü Altyazılama Metrikleri

Otomatik görüntü altyazılama sistemleri için başarımlar ölçümünün, diğer bilgisayarla görme ve görüntü işleme görevlerine nazaran biraz daha zorlu olduğu söylenebilir. Bu durum daha çok, sistemlerin oluşturmakta olduğu altyazıların hem biçimsel hem de anlamsal açıdan doğru olması gerekliliğinden kaynaklanmaktadır. Bu bağlamda, etkin bir görüntü altyazılama sisteminin veya yönteminin, sadece yazım açısından doğru ifadeler üretebilmesi değil, aynı

zamanda görüntünün içeriğindeki anlamı da doğru yansıtabilmesi (nesneler arası ilişkiler ve aksiyonlar/filer) gerektiği söylenebilir.

Görüntü altyazılama sistemlerinde girdi/sorgu görüntüleri için oluşturulan altyazıların doğruluğunu analiz etmek için niteliksel (qualitative) ve niceliksel (quantitative) olmak üzere iki temel değerlendirme yöntemi izlenebilir. Niteliksel yöntemlerde, görüntüler için tahmin edilen altyazılar bir veya daha fazla değerlendirici tarafından değerlendirilip skorlanır. Bu değerlendirme yöntemi, kişiye bağlı olması sebebiyle ve kişilerin farklı zamanlarda farklı değerlendirmelerde bulunabileceği göz önüne alındığında niceliksel yöntemler kadar güvenilir sonuçlar üretme potansiyeline sahip değildir ve oldukça maliyetlidir. Otomatik görüntü altyazılama sistemlerinde altyazı başarımını ölçmek amacıyla güncel literatürde çok sayıda niceliksel ölçüm metriği önerilmiştir. Bu metriklerin ekseriyeti de bu alanda çalışan araştırma toplulukları tarafından genel olarak kabul görmüştür ve çalışmalarda önerilen sistemlerin performansını analiz etmek için tercih edilmektedir. Görüntü altyazılamada performans ölçümü amacıyla kullanılan bu metriklerden öne çıkan bazıları şunlardır:

- BiLingual Evaluation Understudy (BLEU) [110]
- Metric for Evaluation of Translation with Explicit ORdering (METEOR) [111]
- Recall Oriented Understudy for Gisting Evaluation (ROUGE-L) [112]
- Consensus-based Image Description Evaluation (CIDEr) [113]
- Semantic Propositional Image Caption Evaluation (SPICE) [114]

Görüntü altyazılama başarımının ölçümü için en sık kullanılan metriklerden birisi BLEU'dur. BLEU metriğinin hesaplanmasında öncelikle test korpusunun modifiye edilmiş keskinlik (precision) skorlarının geometrik ortalaması alınır ve sonrasında ise bu değer, bir üstel kısalık ceza faktörü (exponential brevity penalty factor) ile çarpılır. BLEU skoru, tahmin edilen ve referans görüntülerdeki farklı sayıdaki kelime grubu eşleşmeleri (n-gram) için de hesaplanabilmekle

(BLEU-n) birlikte, bu kelime eşleşmeleri genellikle ayrı ayrı olmak üzere 4-gram'a kadar gerçekleştirilerek BLEU-1, BLEU-2, BLEU-3, BLEU-4 ölçümleri yapılır. BLEU metriği görüntü alt yazılarının başarımını biçimsel bağlamda ele aldığından küçük n-gram eşleşmelerinde elde edilen yüksek skorlar her zaman anlamsal doğruluğu yansıtmayabilir. Bunun için, BLEU-4 gibi büyük n-gram eşleşmelerine dayalı ölçümleri de dikkate almak gereklidir. BLEU metriği, referans ve tahmin edilen görüntü alt yazıları arasındaki benzerliğin ölçümünde duyarlılığı (recall) yani referans alt yazıdaki toplam n-gram sayısı içinde eşleşen n-gramların oranını, ki bu bilgi oldukça önemli olmasına rağmen, hesaba katmaz. Bununla birlikte, BLEU metriğinin diğer bazı çalışmalarda [111] değinilen başka zayıf yönleri de bulunmaktadır. Bu zayıf yönler ilerleyen dönemde Banerjee ve Lavie tarafından ele alınmış, giderilmeye çalışılmış ve yapılan iyileştirmeler neticesinde yeni bir metrik olarak METEOR önerilmiştir. METEOR da, görüntü alt yazılama modelinin ürettiği alt yazı ile gerçek-referans görüntü alt yazısı arasındaki kelime (word-to-word) eşleşmelerine dayalı olarak bir puan hesaplar ve tahmin edilen görüntü alt yazısının doğruluğu bu puan üzerinden değerlendirilir. METEOR'un açıklamalı matematiksel notasyonu ve detayları için [111] numaralı referans kaynak incelenebilir.

ROUGE-L, CIDEr ve SPICE de görüntü alt yazılama da öne çıkan diğer sayısal ölçüm metrikleridir. ROUGE-L, duyarlılık bilgisini göz önünde bulundurarak, LCS (Longest Common Subsequence) tabanlı bir alt yazı doğruluk ölçümü gerçekleştirir. Bu işlemden, referans bir görüntü alt yazısı ile tahmin edilen alt yazı arasındaki maksimum uzunluğa sahip ortak alt dizi belirlenir ve bu en uzun ortak alt dizi sayesinde iki alt yazı metni arasındaki benzerlik ortaya konulur. Bir diğer n-gram tabanlı ölçüm yöntemi olan CIDEr ise, TF-IDF (Term Frequency-Inverse Document Frequency) yöntemini kullanarak n-gramları ağırlıklandırır ve n-gram ağırlıklarına göre, aslında n-gramların taşıdıkları bilgi değerini ortaya koymaya çalışarak (veri setinde yaygın olarak görülen n-gramlara daha az bilgi verici olmaları muhtemel olduğundan daha düşük ağırlık verilmesi), daha anlamlı bir ölçüm yapmayı amaçlar. Görüntü alt yazılama sistemlerince üretilen alt yazıların başarımlarının değerlendirilmesinde BLEU, ROUGE-L, CIDEr veya METEOR gibi metrikleri kullanmanın problem oluşturabilecek temel noktalarından biri, bu metriklerin n-gram örtüşmesine duyarlı olmasıdır. Tahmin edilen ve referans görüntü alt yazıları arasındaki n-gram örtüşmesi, iki alt yazının aynı anlamı taşıdığından gösterilmesi açısından yeterli değildir [115, 114]. Bu temel noktadan hareketle Anderson ve ark. tarafından önerilen SPICE metriği, sahne graflarını da (scene graphs) kullanarak görüntü alt yazıları arasındaki benzer anlamsal yapıları yakalamayı hedefler. Anlamsal içeriklerin benzerliği üzerinden bir keskinlik ve duyarlılık bilgisi de kullanılarak modellerin ürettiği alt yazılar için SPICE skorları hesaplanır. SPICE metriğinin, insan değerlendirmeleriyle uyum açısından mevcut n-gram metriklerinden daha iyi performans gösterdiği de belirtilmektedir [114].

2.4. Görüntü Alt Yazılamanın Uygulama Alanları

Otomatik görüntü alt yazılama üzerine yapılan çalışmalar her ne kadar yoğunlukla genel-amaçlı görüntü analizi üzerine odaklansa da, bu bağlamda önerilen yöntemler tabii olarak birçok görüntü/kamera tabanlı akıllı sistem uygulamasında


kullanılabilme potansiyeli taşır. Nitekim güncel bilimsel literatür incelendiğinde, bu tarz uygulamaların; trafik sahnesi analizi [22, 116, 117], uzaktan algılama [28-30, 118], sosyal medya [31-33], haber [34-36], tıp [37-39], turizm [40-42], sanat ve kültür [43-45], kimya ve biyoloji [46-48], güvenlik [119-121], otonom sürüş ve akıllı ulaşım/taşıma [122-124] ve askeri alan [125-127] gibi oldukça geniş bir alan (domain) yelpazesine yayıldığı da görülebilir.

Li ve ark. tarafından sunulan bir makalede [22], görüntü alt yazılama dayalı olarak trafik sahnelerinin anlaşılması ve tahmin edilmesi üzerine bir çalışmaya yer verilmiştir. Cheng ve ark. ise, uzaktan algılama görüntülerinin betimlenmesinde otomatik görüntü alt yazılama faydalanmışlardır [118]. [31] numaralı kaynakta refere edilen çalışmada, Chunseong Park ve ark. fotoğraf paylaşım sosyal ağlarından biri olan Instagram'dan resim gönderileri toplamışlar ve bu sosyal medya görüntüleri üzerinde görüntü alt yazılama gerçekleştirmişlerdir. Tran ve ark. ise, haber makaleleri ile birlikte sunulan resimler için alt yazılar üreten uçtan uca bir model önermişlerdir [34]. Akıllı turizm amaçlı yapılan alan-spesifik bir başka çalışmada [40], Fudholi ve ark., ileride çeşitli kullanıcılara yardımcı olacak yapay zekâ destekli sistemlerin geliştirilmesini de destekleyecek, yerel turizme özgü bir görüntü alt yazılama modeli tasarlamışlardır. Nivedita ve ark. ise, akıllı ve güvenli video gözetim sistemleri için görüntü alt yazılama faydalanmayarak tasarlamışlardır [119]. Bu amaçla, görüntülerdeki nesneler hakkında bağlamsal açıklamalar üreten ve daha sonra bu açıklamaları, sahne hakkında bilgi sağlamak için kullanan görsel sistemler geliştirmek için bir yapı önermişlerdir. Mori ve ark. tarafından sunulan bir bildiride, görüntü alt yazılamanın otonom sürüş ve akıllı ulaşım/taşıma alanında kullanımına dair bir çalışma sunulmuştur [122]. Kazaları önlemek ve yolcuları uyarmak adına, yakın gelecekte gerçekleşecek herhangi bir olay için görüntü alt yazısı oluşturma önemli olduğundan yola çıkarak araç içi kamera görüntüleri için uygun olan bir görüntü alt yazılama yöntemi önermişlerdir.

Otomatik görüntü alt yazılamanın son yıllarda öne çıkan önemli uygulama alanlarından bir diğeri ise tıp ve sağlıktır. Bu alanda yapılan çalışmalar özellikle tıbbi görüntülerin otomatik olarak yorumlanması için oldukça ümit vericidir. Selivanov ve ark. tarafından yakın geçmişte yayınlanan bir makalede [37], otomatik klinik görüntü alt yazısı oluşturmak için, radyolojik taramaların analizini metinsel kayıtlardan gelen yapılandırılmış hasta bilgileriyle birleştiren bir model önerilmiştir. Çalışmanın sonuçları, ilgili araştırmacıların önermiş olduğu modelin, göğüs röntgeni görüntülerinin alt yazılmasında etkin bir şekilde uygulanabilirliğini göstermiştir.

Otomatik görüntü alt yazılamanın sanat ve kimya gibi çok daha spesifik konularda da uygulandığı dikkat çekmektedir. Oldukça yakın tarihli bir makalede [43], Zheng ve ark. kültürel sanat eserleri için görüntü alt yazılama ele almış ve seramikler üzerine bir vaka çalışması gerçekleştirmişlerdir. Bu çalışmalardan daha spesifik bir konuda ise, Yi ve ark. önceden eğitilmiş bir kodlayıcı-kod çözücü mimarisi ile moleküler görüntü alt yazılama gerçekleştirmişlerdir [46]. MICER olarak adlandırılan bu yapının [46], kapsamlı ve doğru otomatik moleküler yapı tanımlama araçları geliştirmek için pratik bir çerçeve sunduğu da belirtilmiştir.

Otomatik görüntü alt yazılamanın askeri amaçlara yönelik olarak da uygulandığı bilinmekle birlikte, bu alandaki



Şekil 4: Türkçe görüntü altyazılama kapsamında son on yıllık süreçte yapılan çalışmalar ve bu çalışmaların kronolojisi.

çalışmalar kısıtlıdır. Literatürdeki bu kısıtlı çalışmalar da, askeri karar verme mekanizmalarını desteklemek [125] ve doğrudan görüntü altyazıları oluşturmak [126, 127] için önerilmiştir. Pan ve ark., gerçekleştirdikleri güncel bir çalışmada [127] askeri görüntü altyazılama problemini ele almışlardır. Bu çalışmada, insansız hava ve kara araçlarına ait görüntülerden ve bu görüntülere karşılık gelen altyazılardan oluşan MOCO (Military Objects in Real Combat) isimli bir açık erişimli denektaşı veri setini sunmuşlardır. Yine ilgili çalışmada [127], MAE-MilitIC olarak adlandırılan yeni bir görüntü altyazılama mimarisi de önerilmiştir.

Otomatik görüntü altyazılama, yukarıda bahsi geçen uygulama alanları haricinde, görüntü analizine açık çok daha farklı ve özel araştırma alanlarında da uygulanabilme potansiyeli taşımaktadır.

3. Türkçe Görüntü Altyazılama

Bu bölümde, Türkçe görüntü altyazılama özelinde olmak üzere, öncelikle mevcut durumun genel bir değerlendirmesi yapılmış ve literatürdeki öne çıkan çalışmalar ele alınarak bu çalışmalara dair bilgiler verilmiştir. Bununla birlikte, otomatik Türkçe görüntü altyazılama için oluşturulmuş veri setlerine dair bilgiler de paylaşılmıştır. Ayrıca yazarlar, Türkçe görüntü altyazılamanın geleceğine ve bazı potansiyel araştırma konularına dair öngörülerini paylaşmışlardır.

3.1. Türkçe Görüntü Altyazılama Genel Durum

Güncel görüntü altyazılama literatürü İngilizce gibi yaygın ve geniş kitlelerce konuşulan diller için oldukça zengin olmasına rağmen, ne yazık ki Türkçemiz için görüntü altyazılama kapsamında yapılan çalışmalar oldukça kısıtlıdır. Bu bağlamda, Türkçe görüntü altyazılama literatürünün henüz doygun bir seviyede olmadığı ve araştırmaya oldukça açık olduğu söylenebilir. Güncel literatür göz önüne alındığında, Türkçe özelinde yapılan otomatik görüntü altyazılama çalışmalarının neredeyse on yıllık bir geçmişi olduğu görülebilir. Bu alanda yapılan ilk çalışmalara ise 2010'lu yılların ortalarında rastlanmaktadır. Bununla birlikte, son yıllarda, doğal dil işleme ve geniş dil modellerindeki (Large Language Models) [128, 129] gelişmelere de paralel olarak, Türkçe görüntü altyazılama çalışmalarında önceki yıllara

nazaran umut verici bir yükseliş dikkat çekmektedir. Otomatik Türkçe görüntü altyazılama kapsamında yapılan çalışmaların detaylarına bir sonraki bölümde etraflıca yer verilmiş olup, bu çalışmaların son on yıllık süreçteki gelişimi ise Şekil 4'te yer alan zaman çizelgesi (timeline) üzerinde görsel olarak sunulmuştur.

3.2. Türkçe Görüntü Altyazılamada Mevcut Çalışmalar ve Uygulama Alanları

Otomatik Türkçe görüntü altyazılama kapsamında yapılan çalışmalar, Şekil 4 üzerinden de açıkça görüleceği üzere, yaklaşık 10 yıllık bir geçmişi kapsamaktadır. 2016 yılında Unal ve ark. tarafından sunulan görüntü betimleme çalışması [130], Türkçe görüntü altyazılamada yapılan ilk çalışmalar arasında yer almaktadır. Bu çalışmada temel olarak, literatürde ilk kez, görüntülerden Türkçe altyazılar üretmeye imkân veren ve bu amaçla denektaşı olarak kullanılabilecek yeni bir veri seti sunulmuştur. TasvirEt olarak adlandırılan bu veri seti, Flickr8K veri kümesinde yer alan görüntüler için Türkçe altyazıların toplanması ile oluşturulmuştur. Unal ve ark. tarafından yapılan bu çalışmada, aynı zamanda, otomatik Türkçe görüntü altyazılama için ilk yöntemler de önerilmiştir. Bu bağlamda ilgili çalışma [130], otomatik Türkçe görüntü altyazılama literatüründe oldukça önemli bir yere sahiptir.

2017 yılında gerçekleştirilen bir çalışmada ise [131], Samet ve ark. "Görüntü altyazılama için otomatik tercümeyle eğitim kümesi oluşturulabilir mi?" sorusuna yanıt aramışlardır. Bu amaçla, MS COCO ve Flickr30K veri setlerindeki İngilizce görüntü altyazılarını Google Translate API kullanarak Türkçe'ye çevirmişler ve çeviri Türkçe altyazılar üzerinden bir görüntü altyazılama modeli eğitmişlerdir. Samet ve ark., yaptıkları bu çalışmada oldukça yüksek başarımlar gözlemlemişlerdir. Sonuç olarak, Türkçe bir görüntü altyazısı seti haricinde, yabancı bir dilden otomatik tercüme araçları ile Türkçe'ye çevrilen görüntü altyazıları kullanarak da bu işlemin efektif olarak gerçekleştirilebileceğini göstermişlerdir. Çeviri tabanlı bu tarz bir otomatik görüntü altyazılama yaklaşımında, ilgili çalışmada da açıkça belirtildiği gibi [131], İngilizce'den Türkçe'ye çevrilmiş altyazılarla eğitilmiş bir model kullanmak yerine, doğrudan İngilizce orijinal altyazılarla eğitilmiş bir modelin üreteceği altyazıyı Türkçe'ye çevirmek

de tercih edilebilir. Hatta, İngilizce altyazılarla eğitilmiş bir modelin üreteceği altyazıyı Türkçe'ye çevirmenin daha pratik ve iyi olacağı da akla gelebilir. Samet ve ark. bu tarz bir olası durumu da ayrıca ele almışlar ve Türkçe'ye çevrilmiş görüntü altyazıları ile eğitilen modelin, İngilizce görüntü altyazıları ile eğitilip ürettiği çıktı altyazısını Türkçe'ye çeviren modelden daha başarılı olduğunu nümerik sonuçlarla da destekleyerek raporlamışlardır.

Bilindiği üzere Türkçe, dil ailesi ve dil yapısı olarak İngilizce'den oldukça farklıdır. Sondan eklemeli bir dil yapısına sahip olan Türkçe'de, sözcüklerin sonuna eklenen ekler sözcüğün anlamını değiştirebilmektedir. Bu sebeple, Türkçe için geliştirilecek olan görüntü altyazılama yöntemlerinde, yaklaşımlarında ve modellerinde, dilin yapısına ait bu tarz özelliklerin de göz önünde bulundurulması gerekebilir. 2018 yılında Kuyu ve ark. tarafından sunulan özgün bir bildiride [132], Türkçe'nin sondan eklemeli dil özelliğini dikkate alan ve bu durumun sebebiyet verebileceği performans noksanlığını tolere etmek adına, kelimeler yerine altsözcük öğelerini kullanan bir altyazılama modeli ele alınmıştır. İlgili çalışmada, önerilen bu altsözcük tabanlı modelin sözcük tabanlı normal modellere göre daha başarılı sonuçlar verdiği, ve bu sayede daha anlamlı ve Türkçe'nin dil bilgisi kurallarına daha uygun görüntü altyazıları üretildiği ifade edilmiştir. 2019 yılında yapılan bir çalışmada ise [133], Yılmaz ve ark. otomatik Türkçe görüntü altyazılama için CNN tabanlı bir görüntü kodlayıcı ile RNN'nin özel bir türü olan LSTM kullanmışlar ve başarılı bir görüntü altyazılama gerçekleştirmişlerdir. İlgili çalışmada ayrıca, MS COCO altyazı veri tabanının makine çevirisi kullanılarak Türkçe diline kazandırılmaya başlandığı da (Türkçe MS COCO) belirtilmiştir. [133]'daki ile benzer bir çalışmada da [134], Yıldız ve ark. tarafından, CNN tabanlı bir görüntü kodlayıcı ve LSTM ile bir görüntü altyazılama gerçekleştirilmiştir. Ayrıca, [133] ile refere edilen çalışmada bahsi geçen Türkçe MS COCO görüntü-altyazı veritabanı [135]'deki çalışmada detaylı olarak tanıtılmıştır. Atıcı ve Omurca tarafından gerçekleştirilmiş olan 2021 tarihli bir çalışmada [136], Türkçe görüntü altyazılama işlemi görece farklı bir problemin çözümünde ele alınmıştır. Bu bağlamda Atıcı ve Omurca, sınıflandırılmış reklamların alışveriş kategorisindeki ürün resimleri için en uygun başlığı oluşturmayı amaçlamışlardır. Derin öğrenme tabanlı görüntü altyazılama modelleri kullanılarak gerçekleştirilen bu çalışma ile ürün görsellerinin başarılı bir biçimde tanımlanabileceği ortaya konulmuştur. Bu çalışma [136] literatürde, sınıflandırılmış reklam ürün görsellerine Türkçe başlık/açıklama üreten ilk çalışma olma özelliği ile de öne çıkmaktadır.

Yukarıda değinilen çalışmalara ek olarak, özellikle son yıllarda otomatik Türkçe görüntü altyazılama üzerine yapılan çalışmalar da [137-141] oldukça dikkat çekicidir. Bilindiği üzere, Türkçe görüntü altyazı setlerinin azlığı ve kısıtlılığı sebebiyle, Türkçe görüntü altyazılama modellerinin eğitiminde kullanılacak olan görüntü altyazılarını oluşturmak için Google Translate gibi web tabanlı gelişmiş ve başarılı otomatik dil çeviri sistemlerinin kullanımı oldukça yaygındır. Yıldız ve ark. tarafından yakın geçmişte sunulan bir bildiride [137], bu yaklaşımın biraz dışına çıkılarak, otomatik Türkçe görüntü altyazılama derin makine çevirisinin etkisine yönelik bir araştırma çalışması raporlanmıştır. İlgili çalışmada, genel-amaçlı ve birçok dili destekleyen derin bir dil modeli kullanılarak İngilizce görüntü altyazıları otomatik

olarak Türkçe'ye çevrilmiş ve derin öğrenme tabanlı bir Türkçe görüntü altyazılama modeli, makine çevirisi Türkçe görüntü altyazıları kullanılarak eğitilmiştir. Yıldız ve ark. tarafından gerçekleştirilen başka bir güncel çalışmada ise [138], TRCaptionNet olarak isimlendirilen ve görsel dönüştürücü tabanlı görüntü kodlayıcılar ile derin dilsel metin kod çözümler üzerine inşa edilmiş yeni ve başarılı bir derin Türkçe görüntü altyazılama modeli önerilmiştir. İlgili çalışmada farklı veri setleri için raporlanan sonuçlar ile bu modelin Türkçe görüntü altyazılama ümit verici performansı da desteklenmiştir. TRCaptionNet Türkçe görüntü altyazılama modeli, yine Yıldız ve ark. tarafından yapılmış başka bir çalışma dâhilinde [141] özel olarak TasvirEt veri seti [130] için de analiz edilmiştir. Bu çalışmada [141] gerçekleştirilen görüntü altyazılama analizlerinde, TRCaptionNet ile TasvirEt veri seti üzerinde literatürdeki en iyi başarımlara ulaşıldığı raporlanmıştır. Yine TasvirEt veri seti üzerinde gerçekleştirilen, ve Ertuğrul ve Omurca tarafından sunulan 2023 tarihli bir çalışmada [140], VGG-16, DenseNet ve LSTM kullanılarak Türkçe altyazı oluşturmaya yönelik bir analiz yapılmıştır ve başarılı addedilebilecek sonuçlar gözlemlenmiştir. TRCaptionNet'e ek olarak, otomatik Türkçe görüntü altyazılama için son yıllarda önerilmiş görsel dönüştürücü tabanlı bir diğer spesifik ve yeni derin model ise ORTPiece'dir [139]. Ersoy ve ark. tarafından önerilen bu model, temel olarak girdi görüntüleri üzerinden görünüm (appearance) ve geometri özelliklerini çıkarır ve bunları kelime parçaları (wordpiece) gösterimleri ile birleştirerek Türkçe görüntü altyazılarını oluşturur. Kodlayıcı-kod çözücü bir mimariye sahip olan ORTPiece, Nesne İlişkisi Dönüştürücü (Object Relation Transformer, ORT) yöntemini de kullanır ve wordpiece tokenizasyonu ile altsözcük öğelerini analiz eder. Bu sayede, sondan eklemeli bir dil yapısına sahip olan Türkçe için daha başarılı görüntü altyazıları oluşturmaya amaçlar.

Yukarıdaki paragraflarda ana hatlarıyla ele alınmış olan otomatik Türkçe görüntü altyazılama çalışmalarına ait yöntemsel detaylar, kullanılan veri seti bilgileri ve ölçülen başarımlar oranları gibi daha detay bilgiler ise Tablo 2'de verilmiştir.

Şekil 4 ve Tablo 2 üzerinden de açıkça görüleceği üzere, bilimsel literatürdeki otomatik Türkçe görüntü altyazılama çalışmaları uzun bir geçmişe sahip olmamakla birlikte nicelik bakımından da henüz yüksek bir seviyede değildir. Bu alanda yapılan çalışmaların neredeyse tamamı tek bir konuya, bilinen ve genel kullanıma açık görüntü-altyazı veri setleri üzerinden genel-amaçlı görüntü altyazılama yöneliktir. İlgili çalışmalar arasında, yalnızca, Atıcı ve Omurca tarafından gerçekleştirilmiş olan 2021 tarihli çalışmada [136] genel-amaçlı görüntü altyazılama farklı bir uygulama alanına meyledildiği ve Türkçe görüntü altyazılama işleminin görece farklı bir problemin çözümüne uygulandığı (sınıflandırılmış reklamların alışveriş kategorisindeki ürün resimleri için başlık oluşturma) görülmektedir. Görüntü altyazılamanın genel olarak; tıbbi görüntü analizi, uzaktan algılama, güvenlik, görsel yardım ve çok modlu arama motorları gibi birçok farklı alanda uygulanabilirliği göz önüne alındığında, Türkçe görüntü altyazılamanın birçok uygulama alanında henüz aktif olarak yer almadığı ve bu alanların araştırmaya ve çalışmaya oldukça açık olduğu ifade edilebilir.

Tablo 2: Güncel literatürdeki otomatik Türkçe görüntü altyazılama çalışmalarında yöntemsel detaylar, kullanılan veri seti bilgileri ve ölçülen başarımlar oranları.

Kaynak	Yıl	Yöntem	Veri seti	BLEU-1	BLEU-2	BLEU-3	BLEU-4	METEOR	ROUGE-L	CIDEr	SPICE
[130]	2016	Benzer görüntü altyazıları üzerinden altyazılama	TasvirEt (eğitim ve test)	0.2110	0.0720	0.0200	-	-	-	-	-
[130]	2016	Adaptif komşuluk temelli konsensus altyazılama	TasvirEt (eğitim ve test)	0.2600	0.1020	0.0340	-	-	-	-	-
[131]	2017	Derin öğrenme (CNN + kök alma)	MS COCO (eğitim ve test)	0.3420	0.1810	0.0850	0.0390	0.1570	0.3220	0.4610	-
[131]	2017	Derin öğrenme (CNN + kök alma)	Flickr30K (eğitim ve TasvirEt (test))	0.3350	0.1720	0.0820	0.0350	0.1230	0.2680	0.2360	-
[132]	2018	Derin öğrenme (Altsözcük tabanlı)	MS COCO (eğitim ve test)	0.2930	0.1650	0.0880	0.0530	0.1470	0.3020	0.5670	-
[132]	2018	Derin öğrenme (Altsözcük tabanlı)	MS COCO (eğitim ve TasvirEt (test))	0.2630	0.1630	0.0970	0.0550	0.1030	0.2670	0.3200	-
[132]	2018	Derin öğrenme (Altsözcük tabanlı)	Flickr30K (eğitim ve test)	0.2970	0.1650	0.0790	0.0380	0.1120	0.2650	0.2140	-
[133]	2019	Derin öğrenme (CNN + LSTM)	MS COCO (eğitim ve test)	0.2880	0.1550	0.0710	0.0300	0.1250	0.2660	0.4790	-
[134]	2020	Derin öğrenme (CNN + RNN)	MS COCO (eğitim ve test)	0.2880	0.1550	0.0710	0.0300	0.1250	0.2660	0.4790	-
[134]	2020	Derin öğrenme (CNN + LSTM)	MS COCO (eğitim ve test)	0.2970	0.1640	0.0760	0.0350	0.1290	0.2720	0.5280	-
[135]	2022	Derin öğrenme (Resnet101 Batch60 English)	MS COCO (eğitim ve test)	0.8330	0.6450	0.4920	0.4150	0.2330	0.4690	1.3620	-
[135]	2022	Derin öğrenme (Resnet101 Batch60 Turkish)	MS COCO (eğitim ve test)	0.4990	0.4240	0.3130	0.2370	0.2500	0.4630	1.2570	-
[135]	2022	Derin öğrenme (Resnet152 Batch60 Turkish)	MS COCO (eğitim ve test)	0.5620	0.4010	0.2990	0.2270	0.1930	0.4480	0.9800	-
[135]	2022	Derin öğrenme (Resnet101 Batch32 Turkish)	MS COCO (eğitim ve test)	0.4370	0.3540	0.2750	0.2140	0.1700	0.4050	0.8990	-
[135]	2022	Derin öğrenme (Meshed-Memory Transformers Turkish)	MS COCO (eğitim ve test)	0.7230	0.5620	0.4130	0.2960	0.2550	0.5270	0.9350	-
[137]	2023	Derin öğrenme (ResNet18 + LSTM)	MS COCO (eğitim ve test)	0.3122	0.1054	0.0441	0.0217	0.1111	0.2636	0.0465	-
[137]	2023	Derin öğrenme (ResNet34 + LSTM)	MS COCO (eğitim ve test)	0.3116	0.1068	0.0454	0.0206	0.1111	0.2642	0.0466	-
[137]	2023	Derin öğrenme (ResNet50 + LSTM)	MS COCO (eğitim ve test)	0.3115	0.1060	0.0446	0.0213	0.1110	0.2636	0.0447	-
[137]	2023	Derin öğrenme (ResNet101 + LSTM)	MS COCO (eğitim ve test)	0.3079	0.1024	0.0434	0.0191	0.1102	0.2623	0.0435	-
[137]	2023	Derin öğrenme (ResNet152 + LSTM)	MS COCO (eğitim ve test)	0.2989	0.1028	0.0432	0.0198	0.1070	0.2539	0.0440	-
[137]	2023	Derin öğrenme (ResNext50 (32x4d) + LSTM)	MS COCO (eğitim ve test)	0.3086	0.1037	0.0411	0.0178	0.1108	0.2624	0.0423	-
[137]	2023	Derin öğrenme (ResNext101 (32x8d) + LSTM)	MS COCO (eğitim ve test)	0.3105	0.1061	0.0453	0.0205	0.1112	0.2636	0.0465	-
[137]	2023	Derin öğrenme (ResNext101 (64x4d) + LSTM)	MS COCO (eğitim ve test)	0.3109	0.1055	0.0450	0.0214	0.1106	0.2633	0.0448	-
[137]	2023	Derin öğrenme (Swin (base) + LSTM)	MS COCO (eğitim ve test)	0.3122	0.1040	0.0433	0.0179	0.1106	0.2639	0.0432	-
[137]	2023	Derin öğrenme (Swin (small) + LSTM)	MS COCO (eğitim ve test)	0.3079	0.1045	0.0440	0.0198	0.1104	0.2627	0.0443	-
[137]	2023	Derin öğrenme (Swin (tiny) + LSTM)	MS COCO (eğitim ve test)	0.3103	0.1043	0.0433	0.0196	0.1100	0.2628	0.0423	-
[138]	2023	Derin öğrenme (TRCaptionNet)	MS COCO (eğitim ve test)	0.5773	0.4146	0.2839	0.1954	0.2546	0.4652	0.6552	-
[138]	2023	Derin öğrenme (TRCaptionNet)	MS COCO (eğitim ve Flickr30K (test))	0.5311	0.3587	0.2293	0.1395	0.2146	0.4192	0.3798	-
[138]	2023	Derin öğrenme (TRCaptionNet)	Flickr30K (eğitim ve MS COCO (test))	0.4213	0.2576	0.1518	0.0900	0.1933	0.3619	0.3145	-
[138]	2023	Derin öğrenme (TRCaptionNet)	Flickr30K (eğitim ve test)	0.5477	0.3771	0.2535	0.1671	0.2271	0.4393	0.4668	-
[138]	2023	Derin öğrenme (TRCaptionNet)	MS COCO + Flickr30K (eğitim ve MS COCO (test))	0.5761	0.4124	0.2803	0.1905	0.2523	0.4609	0.6437	-
[138]	2023	Derin öğrenme (TRCaptionNet)	MS COCO + Flickr30K (eğitim ve Flickr30K (test))	0.5713	0.4056	0.2789	0.1843	0.2330	0.4491	0.5154	-
[139]	2023	Derin öğrenme (ORTPiece (voc. size 19k))	MS COCO (eğitim ve test)	0.3300	-	-	0.0550	0.1720	0.3250	0.5260	0.0770
[139]	2023	Derin öğrenme (ORTPiece (voc. size 24k))	MS COCO (eğitim ve test)	0.3330	-	-	0.0530	0.1740	0.3290	0.5530	0.0770
[139]	2023	Derin öğrenme (ORTPiece (voc. size 39k))	MS COCO (eğitim ve test)	0.3310	-	-	0.0530	0.1720	0.3260	0.5240	0.0740
[140]	2023	Derin öğrenme (VGG-16 + LSTM)	TasvirEt (eğitim ve test)	0.3316	0.1118	0.0687	0.0571	-	-	-	-
[140]	2023	Derin öğrenme (DenseNet + LSTM)	TasvirEt (eğitim ve test)	0.3068	0.0946	0.0617	0.0421	-	-	-	-
[141]	2024	Derin öğrenme (TRCaptionNet (CLIP ViT-B/16))	TasvirEt (eğitim ve test)	0.2880	0.1662	0.0915	0.0459	0.1392	0.2738	0.2709	-
[141]	2024	Derin öğrenme (TRCaptionNet (CLIP ViT-B/32))	TasvirEt (eğitim ve test)	0.3093	0.1862	0.1063	0.0577	0.1457	0.2890	0.3135	-
[141]	2024	Derin öğrenme (TRCaptionNet (CLIP ViT-L/14))	TasvirEt (eğitim ve test)	0.3069	0.1841	0.1042	0.0555	0.1480	0.2889	0.3078	-
[141]	2024	Derin öğrenme (TRCaptionNet (CLIP ViT-L/14@336px))	TasvirEt (eğitim ve test)	0.3406	0.2110	0.1253	0.0690	0.1610	0.3145	0.3879	-

3.3. Türkçe Görüntü Altyazılama için Veri Setleri

Otomatik Türkçe görüntü altyazılama üzerine mevcut çalışmaların ve bu çalışmaların dâhil olduğu özel uygulama alanlarının ele alındığı bir önceki bölümde de ifade edildiği üzere, Türkçe görüntü altyazılama literatürü yapılan

çalışmaların niceliği ve çeşitliliği açısından henüz yüksek bir seviyede değildir. Mevcut literatürün bu durumunda, her ne kadar Türkçe üzerine yapılan ilk çalışmaların oldukça yakın tarihli olmasının etkisi olsa da, kanaatimizce, Türkçe görüntü altyazılama için oluşturulmuş veri setlerinin az ve kısıtlı olmasının da etkisi vardır. Nitekim mevcut çalışmalar

incelendiğinde, otomatik Türkçe görüntü altyazılama ile ilgili problemlerin çözümünde istifade edilebilecek veri setlerinin yalnızca TasvirEt ve Türkçe MS COCO veri setleri olduğu görülmektedir. Bu iki veri seti de, her ne kadar Türkçe görüntü-altyazı seti olsa da, esasında MS COCO ve Flickr gibi bilinen görüntü-altyazı setleri referans alınarak oluşturulmuştur.

TasvirEt [130], Unal ve ark. tarafından Flickr8K görüntüleri üzerine Türkçe altyazıların toplanması ile oluşturulmuş bir veri setidir. TasvirEt veri kümesi 8091 adet görüntü ve bu görüntülere ait toplam 12222 adet Türkçe görüntü altyazısından meydana gelmektedir. TasvirEt veri setinin tanıtıldığı bildiride [130], görüntü altyazılarının toplanabilmesi için özel bir sistem geliştirildiği de bildirilmiştir. Golech ve ark. tarafından hazırlanan Türkçe MS COCO görüntü altyazılama veri seti ise [135], orijinal MS COCO veritabanındaki görsellere ait altyazıların Google Cloud Platform'un çeviri Uygulama Programlama Arayüzü (Application Programming Interface, API) kullanılarak Türkçe'ye çevrilmesiyle oluşturulmuştur. İlgili altyazı çevirilerinin biçimsel ve anlamsal doğruluğunun insan gözü ile doğrulanması amacıyla da bir ekip oluşturulmuş ve görselleri daha doğru bir şekilde tanımlamak için çeviri altyazılar bu ekipçe düzeltilmiştir. Türkçe MS COCO veri kümesi toplamda 123.287 adet görüntü ve bu görüntülere karşılık gelen toplam 616.767 açıklamadan (görüntü altyazısı) müteşekkildir. TasvirEt ve Türkçe MS COCO veri setlerine ait çok daha detaylı bilgilere ve istatistiklere bu veri setlerinin tanıtıldığı bilimsel raporlardan [130, 135] erişilebilmesi mümkündür.

Bilindiği üzere, görüntü altyazılama için veri seti oluşturmak oldukça yorucu ve iş gücü, zaman gibi kaynaklar açısından da oldukça maliyetli bir süreçtir. Bu zorluk ve maliyet her ne kadar tüm veri setlerinin oluşturulmasında genel bir problem olsa da, görüntü altyazılama için bunun bir parça daha üst seviyede olduğu söylenebilir. Bunun temel ve öne çıkan sebeplerinden bazıları ise şunlardır:

- Veri setinin kategori ve anlamsal içerik bakımından zengin olması gerekliliği: Modellerin görüntülerdeki birçok içeriği öğrenebilmesi ve buna bağlı olarak daha anlamlı görüntü altyazıları üretebilmesi.
- Görüntülere ait gerçek-referans altyazıların oluşturulmasının oldukça vakit alıcı olması: Görüntülerin önce insan gözüyle detaylı olarak incelenmesi ve görüntü altyazılarının belli bir düşünme sürecinden sonra yazılması.
- Gerçek-referans görüntü altyazılarının anlamlı, doğru, içeriği iyi tanımlayan ve yeterli bir kelime uzunluğunda oluşturulması gerekliliği: Modellerin iyi tanımlanmış verilerle eğitilmesi ve buna bağlı olarak anlamlı, doğruluk oranı yüksek altyazılar üretebilmesi.
- Subjektiflik: Bir görüntü için, belli bir benzerlik dâhilinde, herkesin farklı bir betimleme yapabilmesi. Aynı zamanda, bir kişinin bir görüntüyü farklı zamanlarda farklı biçimsel ifadelerle betimleyebilmesi.
- Her bir görüntü için birden fazla gerçek-referans altyazı oluşturulması ihtiyacı: Bir görüntüyü betimleyen birden fazla doğru altyazının olması.

Türkçe görüntü altyazılama literatüründe, bildiğimiz kadarıyla, bahsi geçen iki veri setinin (TasvirEt ve Türkçe MS COCO) haricinde genel kullanıma açık bir görüntü-altyazı

seti bulunmamaktadır. Ayrıca, yine bilgimiz dâhilinde, tamamen Türkçe özelinde hazırlanmış orijinal bir görüntü-altyazı seti de şu an için mevcut değildir. Her ne kadar şu an için çeviri yoluyla elde edilmiş veri setleri üzerinden başarılı sayılabilecek görüntü altyazılama modelleri geliştirilebilse de, Türkçe'ye spesifik yeni görüntü-altyazı veri setlerinin oluşturulması bu alandaki araştırmalara ve uygulamalara önemli katkı sağlayacaktır.

3.4. Türkçe Görüntü Altyazılamanın Geleceği ve Olası Eğilimler

Literatürde otomatik Türkçe görüntü altyazılama üzerine yapılmış çalışmaların yıllara göre gelişimi ve dağılımı Şekil 4'teki bir zaman çizgisi üzerinde, bu çalışmalarda kullanılan yöntemler ile raporlanan başarımlar ise Tablo 2'de gösterilmiştir. Şekil 4'e odaklanıldığında, her ne kadar çalışma sayısı kısıtlı olsa da, mevcut çalışmaların yaklaşık %50'sinin son birkaç yıl içinde yapıldığı ve raporlandığı dikkat çekmektedir. Bununla birlikte, son yıllarda yapılan çalışma sayısında bir artış da mevcuttur. Türkçe doğal dil modellerindeki gelişmeler [142-147] ve henüz Türkçe görüntü altyazılama ile ilgili birçok alt alanda çalışma yapılmamış olması da göz önüne alındığında, otomatik Türkçe görüntü altyazılama kapsamındaki çalışmaların artacağı öngörülmektedir.

2. Bölüm'deki "Görüntü Altyazılamanın Uygulama Alanları" başlığı altında, otomatik görüntü altyazılamanın hâlihazırdaki bazı genel ve spesifik uygulama alanları ve bu alanlarda yapılmış öne çıkan bazı güncel araştırmalar paylaşılmıştır. Literatürdeki otomatik Türkçe görüntü altyazılama çalışmaları, bazı çalışmalar haricinde (örneğin alışveriş kategorisindeki ürün resimleri için altyazı oluşturma gibi [136]) neredeyse tamamen genel-amaçlı görüntü altyazılamaya yöneliktir. Dolayısıyla, Türkçe görüntü altyazılama şu an için tıp, turizm, eğitim, eğlence, ulaşım ve engelli bireylerin hayat standartlarını artırma gibi birçok alana özel uygulamaya açıktır. Bu alanlarda yapılmış araştırma çalışmalarında İngilizce altyazı üretici modellerin domine edici etkisi görülmektedir. Bu tarz modellerin, çok büyük miktardaki veriye olan ihtiyaçları göz önüne alındığında yapısal ve dilbilimsel açıdan Türkçe'ye uyarlanması güç gibi görünmesine rağmen, gelişmiş otomatik çeviri sistemleri ile entegre edilerek üretecekleri çıktılarının Türkçe'ye uyarlanabilmesi mümkündür. Bu bağlamda, ChatGPT [148], Bard [149], Gemini [150] vb. gibi geniş dil modellerinden istifade edilebilir. Öte yandan, Türkçe doğal dil modellerinin geliştirilmesinde son yıllarda yaşanan umut verici gelişmeler de [142-147] hesaba katıldığında, yabancı diller için geliştirilmiş görüntü altyazılama modellerini Türkçe için kullanmanın ve alana özel spesifik Türkçe görüntü altyazılama uygulamaları geliştirmenin daha da kolaylaşacağı söylenebilir.

4. Sonuçlar

Bu makalede, otomatik Türkçe görüntü altyazılama üzerine bir inceleme çalışması sunulmuş olup, genel olarak Türkçe görüntü altyazılamadaki mevcut çalışmaların/uygulamaların ele alınması ve değerlendirilmesi amaçlanmıştır. Bununla birlikte, görüntü altyazılamada kullanılan genel yaklaşımlara, veri setlerine ve metriklere de makale kapsamında yer verilmiştir. Ayrıca, Türkçe görüntü altyazılamanın mevcut uygulama alanları da analiz edilmiş ve bu konu ile ilgili

araştırmaya açık alanlara da temas edilmiştir. Çalışma kapsamında yapılan incelemeler ve değerlendirmeler, son yıllarda otomatik Türkçe görüntü altyazılamada yaşanan önemli ve umut verici gelişmelere rağmen Türkçe görüntü altyazılamada henüz kaydadeğer bir literatür birikimi oluşmadığını ortaya koymaktadır. Literatürdeki mevcut çalışmaların çok büyük bir yüzdesinin (yaklaşık %50) son birkaç yılda yapıldığı da göz önüne alındığında bu durum daha da belirgin olarak göze çarpmaktadır. Dahası, ilgili çalışmaların neredeyse tamamının genel-amaçlı görüntü altyazılama problemine yoğunlaştığı, farklı uygulama alanlarına yönelik (tıp, eğitim, turizm, ulaşım vb. gibi) spesifik araştırma çalışmalarının çok kısıtlı olduğu tespit edilmiştir. Bu bağlamda, Türkçe görüntü altyazılama literatürünün bu alanda çalışma yürüten veya uygulama geliştirmeyi planlayan araştırmacıların hemen hemen her türlü katkısına açık olduğunu ifade etmek mümkündür.

5. Kaynaklar

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
- [2] S. Yıldız, O. Aydemir, A. Memiş, and S. Varlı, "A turnaround control system to automatically detect and monitor the time stamps of ground service actions in airports: A deep learning and computer vision based approach," *Engineering Applications of Artificial Intelligence*, vol. 114, p. 105032, 2022, doi:10.1016/j.engappai.2022.105032.
- [3] X. Chen, X. Wang, K. Zhang, K.-M. Fung, T. C. Thai, K. Moore, R. S. Mannel, H. Liu, B. Zheng, and Y. Qiu, "Recent advances and clinical applications of deep learning in medical image analysis," *Medical image analysis*, vol. 79, p. 102444, 2022, doi:10.1016/j.media.2022.102444.
- [4] A. M. Ozbayoglu, M. U. Gudelek, and O. B. Sezer, "Deep learning for financial applications: A survey," *Applied soft computing*, vol. 93, p. 106384, 2020, doi:10.1016/j.asoc.2020.106384.
- [5] X. Zhifeng, "Virtual entertainment robot based on artificial intelligence image capture system for sports and fitness posture recognition," *Entertainment Computing*, vol. 52, p. 100793, 2025, doi:10.1016/j.entcom.2024.100793.
- [6] H. Wang, H. Wu, Z. He, L. Huang, and K. W. Church, "Progress in machine translation," *Engineering*, vol. 18, pp. 143–153, 2022, doi:10.1016/j.eng.2021.03.023.
- [7] R. K. Kaliyar, A. Goswami, and P. Narang, "FakeBERT: Fake news detection in social media with a BERT-based deep learning approach," *Multimedia tools and applications*, vol. 80, no. 8, pp. 11 765–11 788, 2021, doi:10.1007/s11042-020-10183-2.
- [8] Y. Yang, K. Zhang, and P. Kannan, "Identifying market structure: A deep network representation learning of social engagement," *Journal of Marketing*, vol. 86, no. 4, pp. 37–56, 2022, doi:10.1177/00222429211033585.
- [9] M. Soori, B. Arezoo, and R. Dastres, "Artificial intelligence, machine learning and deep learning in advanced robotics, a review," *Cognitive Robotics*, vol. 3, pp. 54–70, 2023, doi:10.1016/j.cogr.2023.04.001.
- [10] M. Ozkan-Ozay, E. Akin, Ö. Aslan, S. Kosunalp, T. Iliev, I. Stoyanov, and I. Beloev, "A comprehensive survey: Evaluating the efficiency of artificial intelligence and machine learning techniques on cyber security solutions," *IEEE Access*, 2024, doi:10.1109/ACCESS.2024.3355547.
- [11] Y. Matsuzaka and R. Yashiro, "Ai-based computer vision techniques and expert systems," *AI*, vol. 4, no. 1, pp. 289–302, 2023, doi:10.3390/ai4010013.
- [12] S. V. Mahadevkar, B. Khemani, S. Patil, K. Kotecha, D. R. Vora, A. Abraham, and L. A. Gabralla, "A review on machine learning styles in computer vision—techniques and future directions," *Ieee Access*, vol. 10, pp. 107 293–107 329, 2022, doi:10.1109/ACCESS.2022.3209825.
- [13] R. Kaur and S. Singh, "A comprehensive review of object detection with deep learning," *Digital Signal Processing*, vol. 132, p. 103812, 2023, doi:10.1016/j.dsp.2022.103812.
- [14] D. Meimetus, I. Daramouskas, I. Perikos, and I. Hatzilygeroudis, "Real-time multiple object tracking using deep learning methods," *Neural Computing and Applications*, vol. 35, no. 1, pp. 89–118, 2023, doi:10.1007/s00521-021-06391-y.
- [15] Y. Mo, Y. Wu, X. Yang, F. Liu, and Y. Liao, "Review the state-of-the-art technologies of semantic segmentation based on deep learning," *Neurocomputing*, vol. 493, pp. 626–646, 2022, doi:10.1016/j.neucom.2022.01.005.
- [16] S. Yıldız, "Turkish scene text recognition: Introducing extensive real and synthetic datasets and a novel recognition model," *Engineering Science and Technology, an International Journal*, vol. 60, p. 101881, 2024, doi:10.1016/j.jestch.2024.101881.
- [17] D. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evolutionary intelligence*, vol. 15, no. 1, pp. 1–22, 2022, doi:10.1007/s12065-020-00540-3.
- [18] L. Xu, Q. Tang, J. Lv, B. Zheng, X. Zeng, and W. Li, "Deep image captioning: A review of methods, trends and future challenges," *Neurocomputing*, vol. 546, p. 126287, 2023, doi:10.1016/j.neucom.2023.126287.
- [19] A. Verma, A. K. Yadav, M. Kumar, and D. Yadav, "Automatic image caption generation using deep learning," *Multimedia Tools and Applications*, vol. 83, no. 2, pp. 5309–5325, 2024, doi:10.1007/s11042-023-15555-y.
- [20] L. Agarwal and B. Verma, "From methods to datasets: A survey on Image-Caption Generators," *Multimedia Tools and Applications*, vol. 83, no. 9, pp. 28 077–28 123, 2024, doi:10.1007/s11042-023-16560-x.
- [21] S. Sreela and S. M. Idicula, "A Systematic Survey of Automatic Image Description Generation Systems," *International Journal of Image and Graphics*, p. 2650002, 2024, doi:10.1142/S0219467826500026.
- [22] W. Li, Z. Qu, H. Song, P. Wang, and B. Xue, "The traffic scene understanding and prediction based on image captioning," *IEEE Access*, vol. 9, pp. 1420–1427, 2020, doi:10.1109/ACCESS.2020.3047091.
- [23] Y. Ming, N. Hu, C. Fan, F. Feng, J. Zhou, and H. Yu, "Visuals to text: A comprehensive review on automatic image captioning," *IEEE/CAA Journal of Automatica Sinica*, vol. 9, no. 8, pp. 1339–1365, 2022, doi:10.1109/JAS.2022.105734.

- [24] M. Z. Hossain, F. Sohel, M. F. Shiratuddin, and H. Laga, "A comprehensive survey of deep learning for image captioning," *ACM Computing Surveys (CSUR)*, vol. 51, no. 6, pp. 1–36, 2019, doi:10.1145/3295748.
- [25] D. Sharma, C. Dhiman, and D. Kumar, "Evolution of visual data captioning methods, datasets, and evaluation metrics: A comprehensive survey," *Expert Systems with Applications*, vol. 221, p. 119773, 2023, doi:10.1016/j.eswa.2023.119773.
- [26] F. Chen, X. Li, J. Tang, S. Li, and T. Wang, "A survey on recent advances in image captioning," in *Journal of Physics: Conference Series*, vol. 1914, no. 1. IOP Publishing, 2021, p. 012053, doi:10.1088/1742-6596/1914/1/012053.
- [27] H. Sharma and D. Padha, "A comprehensive survey on image captioning: from handcrafted to deep learning-based techniques, a taxonomy and open research issues," *Artificial Intelligence Review*, vol. 56, no. 11, pp. 13 619–13 661, 2023, doi:10.1007/s10462-023-10488-2.
- [28] X. Huang, K. Lu, S. Wang, J. Lu, X. Li, and R. Zhang, "Understanding remote sensing imagery like reading a text document: What can remote sensing image captioning offer?" *International Journal of Applied Earth Observation and Geoinformation*, vol. 131, p. 103939, 2024, doi:10.1016/j.jag.2024.103939.
- [29] Y. Li, X. Zhang, X. Cheng, X. Tang, and L. Jiao, "Learning consensus-aware semantic knowledge for remote sensing image captioning," *Pattern Recognition*, vol. 145, p. 109893, 2024, doi:10.1016/j.patcog.2023.109893.
- [30] K. Zhao and W. Xiong, "Exploring region features in remote sensing image captioning," *International Journal of Applied Earth Observation and Geoinformation*, vol. 127, p. 103672, 2024, doi:10.1016/j.jag.2024.103672.
- [31] C. Chunseong Park, B. Kim, and G. Kim, "Attend to you: Personalized image captioning with context sequence memory networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 895–903, doi:10.1109/CVPR.2017.681.
- [32] N. Sanguansub, P. Kamolrungwarakul, S. Poopair, K. Techaphonprasit, and T. Siriborvornratanakul, "Song lyrics recommendation for social media captions using image captioning, image emotion, and caption-lyric matching via universal sentence embedding," *Social Network Analysis and Mining*, vol. 13, no. 1, p. 95, 2023, doi:10.1007/s13278-023-01097-6.
- [33] J.-H. Wang, C.-W. Huang, and M. Norouzi, "Improving Rumor Detection by Image Captioning and Multi-Cell Bi-RNN With Self-Attention in Social Networks," *International Journal of Data Warehousing and Mining (IJDWM)*, vol. 18, no. 1, pp. 1–17, 2022, doi:10.4018/IJDWM.313189.
- [34] A. Tran, A. Mathews, and L. Xie, "Transform and tell: Entity-aware news image captioning," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 13 035–13 045, doi:10.1109/CVPR42600.2020.01305.
- [35] Z. Zhang, H. Zhang, J. Wang, Z. Sun, and Z. Yang, "Generating news image captions with semantic discourse extraction and contrastive style-coherent learning," *Computers and Electrical Engineering*, vol. 104, p. 108429, 2022, doi:10.1016/j.compeleceng.2022.108429.
- [36] J. Chen and H. Zhuge, "A news image captioning approach based on multimodal pointer-generator network," *Concurrency and Computation: Practice and Experience*, vol. 34, no. 7, p. e5721, 2022, doi:10.1002/cpe.5721.
- [37] A. Selivanov, O. Y. Rogov, D. Chesakov, A. Shelmanov, I. Fedulova, and D. V. Dylov, "Medical image captioning via generative pretrained transformers," *Scientific Reports*, vol. 13, no. 1, p. 4171, 2023, doi:10.1038/s41598-023-31223-5.
- [38] G. Reale-Nosei, E. Amador-Domínguez, and E. Serrano, "From vision to text: A comprehensive review of natural image captioning in medical diagnosis and radiology report generation," *Medical Image Analysis*, p. 103264, 2024, doi:10.1016/j.media.2024.103264.
- [39] J. Pavlopoulos, V. Kougia, I. Androutsopoulos, and D. Papamichail, "Diagnostic captioning: a survey," *Knowledge and Information Systems*, vol. 64, no. 7, pp. 1691–1722, 2022, doi:10.1007/s10115-022-01684-7.
- [40] D. H. Fudholi, Y. Windiatmoko, N. Afrianto, P. E. Susanto, M. Suyuti, A. F. Hidayatullah, and R. Rahmadi, "Image captioning with attention for smart local tourism using efficientnet," in *IOP Conference Series: Materials Science and Engineering*, vol. 1077, no. 1. IOP Publishing, 2021, p. 012038, doi:10.1088/1757-899X/1077/1/012038.
- [41] S. Watcharabutsarakham, S. Marukatat, K. Kiratiratanapruk, and P. Temniranrat, "Image Captioning for Thai Cultures," in *2022 17th International Joint Symposium on Artificial Intelligence and Natural Language Processing (ISAI-NLP)*. IEEE, 2022, pp. 1–5, doi:10.1109/ISAI-NLP56921.2022.9960251.
- [42] Y. Bounab, M. Oussalah, and A. Ferdenache, "Reconciling image captioning and user's comments for urban tourism," in *2020 Tenth International Conference on Image Processing Theory, Tools and Applications (IPTA)*. IEEE, 2020, pp. 1–6, doi:10.1109/IPTA50016.2020.9286602.
- [43] B. Zheng, F. Liu, M. Zhang, T. Zhou, S. Cui, Y. Ye, and Y. Guo, "Image captioning for cultural artworks: a case study on ceramics," *Multimedia Systems*, vol. 29, no. 6, pp. 3223–3243, 2023, doi:10.1007/s00530-023-01178-8.
- [44] E. Cetinic, "Iconographic image captioning for artworks," in *Pattern Recognition. ICPR International Workshops and Challenges: Virtual Event, January 10–15, 2021, Proceedings, Part III*. Springer, 2021, pp. 502–516, doi:10.1007/978-3-030-68796-0_36.
- [45] Y. Lu, C. Guo, X. Dai, and F.-Y. Wang, "Artcap: A dataset for image captioning of fine art paintings," *IEEE Transactions on Computational Social Systems*, vol. 11, no. 1, pp. 576–587, 2022, doi:10.1109/TCSS.2022.3223539.
- [46] J. Yi, C. Wu, X. Zhang, X. Xiao, Y. Qiu, W. Zhao, T. Hou, and D. Cao, "Micer: a pre-trained encoder-decoder architecture for molecular image captioning," *Bioinformatics*, vol. 38, no. 19, pp. 4562–4572, 2022, doi:10.1093/bioinformatics/btac545.
- [47] A. Lozano, M. W. Sun, J. Burgess, L. Chen, J. J. Nirschl, J. Gu, I. Lopez, J. Aklilu, A. W. Katzer, C. Chiu et al., "BIOMEDICA: An Open Biomedical Image-Caption Archive, Dataset, and Vision-Language Models Derived from Scientific Literature," *arXiv preprint*

- arXiv:2501.07171, 2025, doi:10.48550/arXiv.2501.07171.
- [48] D. Tran, N. T. Pham, N. Nguyen, and B. Manavalan, “Mol2Lang-VLM: Vision-and Text-Guided Generative Pre-trained Language Models for Advancing Molecule Captioning through Multimodal Fusion,” in Proceedings of the 1st Workshop on Language+ Molecules (L+M 2024), 2024, pp. 97–102, doi:10.18653/v1/2024.langmol-1.12.
- [49] H. Sharma and D. Padha, “Domain-specific image captioning: a comprehensive review,” *International Journal of Multimedia Information Retrieval*, vol. 13, no. 2, pp. 1–27, 2024, doi:10.1007/s13735-024-00328-6.
- [50] X. He and L. Deng, “Deep learning for image-to-text generation: A technical overview,” *IEEE Signal Processing Magazine*, vol. 34, no. 6, pp. 109–116, 2017, doi:10.1109/MSP.2017.2741510.
- [51] S. Bai and S. An, “A survey on automatic image caption generation,” *Neurocomputing*, vol. 311, pp. 291–304, 2018, doi:10.1016/j.neucom.2018.05.080.
- [52] Y. Yang, C. Teo, H. Daumé III, and Y. Aloimonos, “Corpus-guided sentence generation of natural images,” in Proceedings of the 2011 conference on empirical methods in natural language processing, 2011, pp. 444–454.
- [53] R. Mason and E. Charniak, “Nonparametric method for data-driven image captioning,” in Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), 2014, pp. 592–598.
- [54] T. Ghandi, H. Pourreza, and H. Mahyar, “Deep learning approaches on image captioning: A review,” *ACM Computing Surveys*, vol. 56, no. 3, pp. 1–39, 2023, doi:10.1145/3617592.
- [55] J. Aneja, A. Deshpande, and A. G. Schwing, “Convolutional image captioning,” in Proceedings of the IEEE conference on computer vision and pattern recognition, 2018, pp. 5561–5570, doi:10.1109/CVPR.2018.00583.
- [56] K. R. Suresh, A. Jarapala, and P. Sudeep, “Image captioning encoder–decoder models using cnn-rnn architectures: A comparative study,” *Circuits, Systems, and Signal Processing*, vol. 41, no. 10, pp. 5719–5742, 2022, doi:10.1007/s00034-022-02050-2.
- [57] Q. You, H. Jin, Z. Wang, C. Fang, and J. Luo, “Image captioning with semantic attention,” in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 4651–4659, doi:10.1109/CVPR.2016.503.
- [58] L. Huang, W. Wang, J. Chen, and X.-Y. Wei, “Attention on attention for image captioning,” in Proceedings of the IEEE/CVF international conference on computer vision, 2019, pp. 4634–4643, doi:10.1109/ICCV.2019.00473.
- [59] X. Yang, K. Tang, H. Zhang, and J. Cai, “Auto-encoding scene graphs for image captioning,” in Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2019, pp. 685–694, doi:10.1109/CVPR.2019.01094.
- [60] N. Xu, A.-A. Liu, J. Liu, W. Nie, and Y. Su, “Scene graph captioner: Image captioning based on structural visual representation,” *Journal of Visual Communication and Image Representation*, vol. 58, pp. 477–485, 2019, doi:10.1016/j.jvcir.2018.12.027.
- [61] X. Li and S. Jiang, “Know more say less: Image captioning based on scene graphs,” *IEEE Transactions on Multimedia*, vol. 21, no. 8, pp. 2117–2130, 2019, doi:10.1109/TMM.2019.2896516.
- [62] X. Xiao, L. Wang, K. Ding, S. Xiang, and C. Pan, “Deep hierarchical encoder-decoder network for image captioning,” *IEEE Transactions on Multimedia*, vol. 21, no. 11, pp. 2942–2956, 2019, doi:10.1109/TMM.2019.2915033.
- [63] R. Castro, I. Pineda, W. Lim, and M. E. Morochó-Cayamcela, “Deep learning approaches based on transformer architectures for image captioning tasks,” *IEEE Access*, vol. 10, pp. 33 679–33 694, 2022, doi:10.1109/ACCESS.2022.3161428.
- [64] M. Cornia, M. Stefanini, L. Baraldi, and R. Cucchiara, “Meshed-memory transformer for image captioning,” in Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2020, pp. 578–587, doi:10.1109/CVPR42600.2020.01059.
- [65] K. Qian, Y. Pan, H. Xu, and L. Tian, “Transformer model incorporating local graph semantic attention for image caption,” *The Visual Computer*, pp. 1–12, 2023, doi:10.1007/s00371-023-03180-7.
- [66] Y. Feng, L. Ma, W. Liu, and J. Luo, “Unsupervised image captioning,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019, pp. 4125–4134, doi:10.1109/CVPR.2019.00425.
- [67] Z. Ren, X. Wang, N. Zhang, X. Lv, and L.-J. Li, “Deep reinforcement learning-based image captioning with embedding reward,” in Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 290–298, doi:10.1109/CVPR.2017.128.
- [68] X. Hu, Z. Gan, J. Wang, Z. Yang, Z. Liu, Y. Lu, and L. Wang, “Scaling up vision-language pre-training for image captioning,” in Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2022, pp. 17 980–17 989, doi:10.1109/CVPR52688.2022.01745.
- [69] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, “Attention is all you need,” *Advances in neural information processing systems*, vol. 30, 2017.
- [70] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning internal representations by error propagation, parallel distributed processing, explorations in the microstructure of cognition,” ed. de rumelhart and j. mccllland. vol. 1. 1986, *Biometrika*, vol. 71, no. 599–607, p. 6, 1986, doi:10.7551/mitpress/4943.003.0128.
- [71] A. Tsantekidis, N. Passalis, and A. Tefas, “Recurrent neural networks,” in *Deep learning for robot perception and cognition*. Elsevier, 2022, pp. 101–115, doi:10.1016/B978-0-32-385787-1.00010-5.
- [72] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997, doi:10.1162/neco.1997.9.8.1735.
- [73] A. Sherstinsky, “Fundamentals of recurrent neural network (rnn) and long short-term memory (lstm) network,” *Physica D: Nonlinear Phenomena*, vol. 404, p. 132306, 2020, doi:10.1016/j.physd.2019.132306.
- [74] K. Cho, “Learning phrase representations using rnn encoder-decoder for statistical machine translation,”

- arXiv preprint arXiv:1406.1078, 2014, doi:10.48550/arXiv.1406.1078.
- [75] O. Ondeng, H. Ouma, and P. Akuon, "A review of transformer-based approaches for image captioning," *Applied Sciences*, vol. 13, no. 19, p. 11103, 2023, doi:10.3390/app131911103.
- [76] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, et al., "An image is worth 16x16 words: Transformers for image recognition at scale," *arXiv preprint arXiv:2010.11929*, 2020, doi:10.48550/arXiv.2010.11929.
- [77] M. J. Parseh and S. Ghadiri, "Graph-based image captioning with semantic and spatial features," *Signal Processing: Image Communication*, vol. 133, p. 117273, 2025, doi:10.1016/j.image.2025.117273.
- [78] J. Jia, X. Ding, S. Pang, X. Gao, X. Xin, R. Hu, and J. Nie, "Image captioning based on scene graphs: A survey," *Expert Systems with Applications*, vol. 231, p. 120698, 2023, doi:10.1016/j.eswa.2023.120698.
- [79] A. S. Al-Shamayleh, O. Adwan, M. A. Alsharaiah, A. H. Hussein, Q. M. Kharmah, and C. I. Eke, "A comprehensive literature review on image captioning methods and metrics based on deep learning technique," *Multimedia Tools and Applications*, vol. 83, no. 12, pp. 34 219–34 268, 2024, doi:10.1007/s11042-024-18307-8.
- [80] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick, "Microsoft coco: Common objects in context," in *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part V 13*. Springer, 2014, pp. 740–755, doi:10.1007/978-3-319-10602-1_48.
- [81] M. Hodosh, P. Young, and J. Hockenmaier, "Framing image description as a ranking task: Data, models and evaluation metrics," *Journal of Artificial Intelligence Research*, vol. 47, pp. 853–899, 2013, doi:10.1613/jair.3994.
- [82] P. Young, A. Lai, M. Hodosh, and J. Hockenmaier, "From image descriptions to visual denotations: New similarity metrics for semantic inference over event descriptions," *Transactions of the Association for Computational Linguistics*, vol. 2, pp. 67–78, 2014, doi:10.1162/tacl_a_00166.
- [83] A. Karpathy and L. Fei-Fei, "Deep visual-semantic alignments for generating image descriptions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 3128–3137, doi:10.1109/TPAMI.2016.2598339.
- [84] M. Grubinger, P. Clough, H. Müller, and T. Deselaers, "The iapr tc-12 benchmark: A new evaluation resource for visual information systems," in *International workshop ontoImage*, vol. 2, 2006.
- [85] C. Rashtchian, P. Young, M. Hodosh, and J. Hockenmaier, "Collecting image annotations using amazon's mechanical turk," in *Proceedings of the NAACL HLT 2010 workshop on creating speech and language data with Amazon's Mechanical Turk*, 2010, pp. 139–147.
- [86] A. Farhadi, M. Hejrati, M. A. Sadeghi, P. Young, C. Rashtchian, J. Hockenmaier, and D. Forsyth, "Every picture tells a story: Generating sentences from images," in *Computer Vision–ECCV 2010: 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5–11, 2010, Proceedings, Part IV 11*. Springer, 2010, pp. 15–29, doi:10.1007/978-3-642-15561-1_2.
- [87] V. Ordonez, G. Kulkarni, and T. Berg, "Im2text: Describing images using 1 million captioned photographs," *Advances in neural information processing systems*, vol. 24, 2011.
- [88] B. Thomee, D. A. Shamma, G. Friedland, B. Elizalde, K. Ni, D. Poland, D. Borth, and L.-J. Li, "Yfcc100m: The new data in multimedia research," *Communications of the ACM*, vol. 59, no. 2, pp. 64–73, 2016, doi:10.1145/2812802.
- [89] A. Koochali, S. Kalkowski, A. Dengel, D. Borth, and C. Schulze, "Which languages do people speak on flickr? a language and geo-location study of the yfcc100m dataset," in *Proceedings of the 2016 ACM Workshop on Multimedia COMMONS*, 2016, pp. 35–42, doi:10.1145/2983554.2983560.
- [90] J. Mao, J. Huang, A. Toshev, O. Camburu, A. L. Yuille, and K. Murphy, "Generation and comprehension of unambiguous object descriptions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 11–20, doi:10.1109/CVPR.2016.9.
- [91] C. Gan, Z. Gan, X. He, J. Gao, and L. Deng, "Stylenet: Generating attractive visual captions with styles," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 3137–3146, doi:10.1109/CVPR.2017.108.
- [92] P. Sharma, N. Ding, S. Goodman, and R. Soricut, "Conceptual captions: A cleaned, hypernymed, image alt-text dataset for automatic image captioning," in *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 2018, pp. 2556–2565, doi:10.18653/v1/P18-1238.
- [93] H. Agrawal, K. Desai, Y. Wang, X. Chen, R. Jain, M. Johnson, D. Batra, D. Parikh, S. Lee, and P. Anderson, "Nocaps: Novel object captioning at scale," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 8948–8957, doi:10.1109/ICCV.2019.00904.
- [94] O. Sidorov, R. Hu, M. Rohrbach, and A. Singh, "Textcaps: a dataset for image captioning with reading comprehension," in *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part II 16*. Springer, 2020, pp. 742–758, doi:10.1007/978-3-030-58536-5_44.
- [95] S. Changpinyo, P. Sharma, N. Ding, and R. Soricut, "Conceptual 12m: Pushing web-scale image-text pre-training to recognize long-tail visual concepts," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2021, pp. 3558–3568, doi:10.1109/CVPR46437.2021.00356.
- [96] Y. Yoshikawa, Y. Shigeto, and A. Takeuchi, "Stair captions: Constructing a large-scale japanese image caption dataset," in *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, 2017, pp. 417–421, doi:10.48550/arXiv.1705.00823.
- [97] A. Alsayed, T. M. Qadah, and M. Arif, "A performance analysis of transformer-based deep learning models for arabic image captioning," *Journal of King Saud*

- University-Computer and Information Sciences, vol. 35, no. 9, p. 101750, 2023, doi:10.1016/j.jksuci.2023.101750.
- [98] B. Das, R. Pal, M. Majumder, S. Phadikar, and A. A. Sekh, "A visual attention-based model for bengali image captioning," *SN Computer Science*, vol. 4, no. 2, p. 208, 2023, doi:10.1007/s42979-023-01671-x.
- [99] A. Rath, "Deep learning approach for image captioning in hindi language," in 2020 international conference on computer, electrical & communication engineering (ICCECE). IEEE, 2020, pp. 1–8, doi:10.1109/ICCECE48148.2020.9223087.
- [100] A. Mathews, L. Xie, and X. He, "Senticap: Generating image descriptions with sentiments," in *Proceedings of the AAAI conference on artificial intelligence*, vol. 30, no. 1, 2016, doi:10.1609/aaai.v30i1.10475.
- [101] R. Krishna, Y. Zhu, O. Groth, J. Johnson, K. Hata, J. Kravitz, S. Chen, Y. Kalantidis, L.-J. Li, D. A. Shamma et al., "Visual genome: Connecting language and vision using crowdsourced dense image annotations," *International journal of computer vision*, vol. 123, pp. 32–73, 2017, doi:10.1007/s11263-016-0981-7.
- [102] B. Qu, X. Li, D. Tao, and X. Lu, "Deep semantic understanding of high resolution remote sensing image," in 2016 International conference on computer, information and telecommunication systems (Cits). IEEE, 2016, pp. 1–5, doi:10.1109/CITS.2016.7546397.
- [103] D. Demner-Fushman, M. D. Kohli, M. B. Rosenman, S. E. Shooshan, L. Rodriguez, S. Antani, G. R. Thoma, and C. J. McDonald, "Preparing a collection of radiology examinations for distribution and retrieval," *Journal of the American Medical Informatics Association*, vol. 23, no. 2, pp. 304–310, 2016, doi:10.1093/jamia/ocv080.
- [104] J. Vaishnavi and V. Narmatha, "Video captioning—a survey," *Multimedia Tools and Applications*, pp. 1–32, 2024, doi:10.1007/s11042-024-18886-6.
- [105] M. Abdar, M. Kollati, S. Kuraparthi, F. Pourpanah, D. McDuff, M. Ghavamzadeh, S. Yan, A. Mohamed, A. Khosravi, E. Cambria et al., "A review of deep learning for video captioning," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, doi:10.1109/TPAMI.2024.3522295.
- [106] M. S. Wajid, H. Terashima-Marin, P. Najafirad, and M. A. Wajid, "Deep learning and knowledge graph for image/video captioning: A review of datasets, evaluation metrics, and methods," *Engineering Reports*, vol. 6, no. 1, p. e12785, 2024, doi:10.1002/eng2.12785.
- [107] D. Chen and W. B. Dolan, "Collecting highly parallel data for paraphrase evaluation," in *Proceedings of the 49th annual meeting of the association for computational linguistics: human language technologies*, 2011, pp. 190–200.
- [108] J. Xu, T. Mei, T. Yao, and Y. Rui, "Msr-vtt: A large video description dataset for bridging video and language," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 5288–5296, doi:10.1109/CVPR.2016.571.
- [109] M. Ravinder, V. Gupta, K. Arora, A. Ranjan, and Y.-C. Hu, "Video-Captioning Evaluation Metric for Segments (VEMS): A Metric for Segment-level Evaluation of Video Captions with Weighted Frames," *Multimedia Tools and Applications*, vol. 83, no. 16, pp. 47 699–47 733, 2024, doi:10.1007/s11042-023-17328-z.
- [110] K. Papineni, S. Roukos, T. Ward, and W.-J. Zhu, "Bleu: a method for automatic evaluation of machine translation," in *Proceedings of the 40th annual meeting of the Association for Computational Linguistics*, 2002, pp. 311–318, doi:10.3115/1073083.1073135.
- [111] S. Banerjee and A. Lavie, "Meteor: An automatic metric for mt evaluation with improved correlation with human judgments," in *Proceedings of the acl workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization*, 2005, pp. 65–72.
- [112] C.-Y. Lin, "Rouge: A package for automatic evaluation of summaries," in *Text summarization branches out*, 2004, pp. 74–81.
- [113] R. Vedantam, C. Lawrence Zitnick, and D. Parikh, "Cider: Consensus-based image description evaluation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 4566–4575, doi:10.1109/CVPR.2015.7299087.
- [114] P. Anderson, B. Fernando, M. Johnson, and S. Gould, "Spice: Semantic propositional image caption evaluation," in *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part V 14*. Springer, 2016, pp. 382–398, doi:10.1007/978-3-319-46454-1_24.
- [115] J. Giménez and L. Màrquez, "Linguistic features for automatic evaluation of heterogenous mt systems," in *Proceedings of the Second Workshop on Statistical Machine Translation*, 2007, pp. 256–264.
- [116] Y. Li, C. Wu, L. Li, Y. Liu, and J. Zhu, "Caption generation from road images for traffic scene modeling," *IEEE Transactions on intelligent transportation systems*, vol. 23, no. 7, pp. 7805–7816, 2021, doi:10.1109/TITS.2021.3072970.
- [117] H. Zhang, C. Xu, B. Xu, M. Jian, H. Liu, and X. Li, "TSIC-CLIP: Traffic Scene Image Captioning Model Based on Clip," *Information Technology and Control*, vol. 53, no. 1, pp. 98–114, 2024, doi:10.5755/j01.itc.53.1.35095.
- [118] Q. Cheng, H. Huang, Y. Xu, Y. Zhou, H. Li, and Z. Wang, "Nwpu-captions dataset and mlca-net for remote sensing image captioning," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–19, 2022, doi:10.1109/TGRS.2022.3201474.
- [119] M. Nivedita, P. Chandrashekar, S. Mahapatra, Y. A. V. Phamila, and S. K. Selvaperumal, "Image captioning for video surveillance system using neural networks," *International Journal of Image and Graphics*, vol. 21, no. 04, p. 2150044, 2021, doi:10.1142/S0219467821500443.
- [120] P. Liwen, "Image Captioning-based Smart Phone Forensics Analysis Model," in *Proceedings of the 2023 6th International Conference on Big Data Technologies*, 2023, pp. 372–376, doi:10.1145/3627377.3627435.
- [121] M. Jeon, J. Ko, and K. Cheoi, "Enhancing Surveillance Systems: Integration of Object, Behavior, and Space Information in Captions for Advanced Risk Assessment," *Sensors*, vol. 24, no. 1, p. 292, 2024, doi:10.3390/s24010292.
- [122] Y. Mori, T. Hirakawa, T. Yamashita, and H. Fujiyoshi, "Image captioning for near-future events from

- vehicle camera images and motion information,” in 2021 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2021, pp. 1378–1384, doi:10.1109/IV48863.2021.9575562.
- [123] H. Lee, J. Song, K. Hwang, and M. Kang, “Auto-Scenario Generator for Autonomous Vehicle Safety: Multi-modal Attention-based Image Captioning Model using Digital Twin Data,” IEEE Access, vol. 12, pp. 159 670–159 687, 2024, doi:10.1109/ACCESS.2024.3487588.
- [124] F. Chen, C. Xu, Q. Jia, Y. Wang, Y. Liu, H. Zhang, and E. Wang, “Egocentric Vehicle Dense Video Captioning,” in Proceedings of the 32nd ACM International Conference on Multimedia, 2024, pp. 137–146, doi:10.1145/3664647.3681214.
- [125] D. Ghataoura and S. Ogbonnaya, “Application of image captioning and retrieval to support military decision making,” in 2021 international conference on military communication and information systems (ICMCIS). IEEE, 2021, pp. 1–8, doi:10.1109/ICMCIS52405.2021.9486395.
- [126] S. Das, L. Jain, and A. Das, “Deep learning for military image captioning,” in 2018 21st International Conference on Information Fusion (FUSION). IEEE, 2018, pp. 2165–2171, doi:10.23919/ICIF.2018.8455321.
- [127] L. Pan, C. Song, X. Gan, K. Xu, and Y. Xie, “Military Image Captioning for Low-Altitude UAV or UGV Perspectives,” Drones, vol. 8, no. 9, p. 421, 2024, doi:10.3390/drones8090421.
- [128] W. X. Zhao, K. Zhou, J. Li, T. Tang, X. Wang, Y. Hou, Y. Min, B. Zhang, J. Zhang, Z. Dong et al., “A survey of large language models,” arXiv preprint arXiv:2303.18223, 2023, doi:10.48550/arXiv.2303.18223.
- [129] Y. Chang, X. Wang, J. Wang, Y. Wu, L. Yang, K. Zhu, H. Chen, X. Yi, C. Wang, Y. Wang et al., “A survey on evaluation of large language models,” ACM Transactions on Intelligent Systems and Technology, vol. 15, no. 3, pp. 1–45, 2024, doi:10.1145/3641289.
- [130] M. E. Unal, B. Citamak, S. Yagcioglu, A. Erdem, E. Erdem, N. I. Cinbis, and R. Cakici, “TasvirEt: A benchmark dataset for automatic Turkish description generation from images,” in 2016 24th signal processing and communication application conference (SIU). IEEE, 2016, pp. 1977–1980, doi:10.1109/SIU.2016.7496155.
- [131] N. Samet, S. Hiçsönmez, P. Duygulu, and E. Akbaş, “Could we create a training set for image captioning using automatic translation?” in 2017 25th Signal Processing and Communications Applications Conference (SIU). IEEE, 2017, pp. 1–4, doi:10.1109/SIU.2017.7960638.
- [132] M. Kuyu, A. Erdem, and E. Erdem, “Image captioning in Turkish with subword units,” in 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018, pp. 1–4, doi:10.1109/SIU.2018.8404431.
- [133] B. D. Yılmaz, A. E. Demir, E. B. Sönmez, and T. Yıldız, “Image captioning in turkish language,” in 2019 Innovations in Intelligent Systems and Applications Conference (ASYU). IEEE, 2019, pp. 1–5, doi:10.1109/ASYU48272.2019.8946358.
- [134] T. Yıldız, E. B. Sönmez, B. D. Yılmaz, and A. E. Demir, “Image captioning in Turkish language: Database and model,” Journal of the Faculty of Engineering and Architecture of Gazi University, vol. 35, no. 4, pp. 2089–2100, 2020, doi:10.17341/gazimmfd.597089.
- [135] S. B. Golech, S. B. Karacan, E. B. Sönmez, and H. Ayral, “A complete human verified turkish caption dataset for ms coco and performance evaluation with well-known image caption models trained against it,” in 2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME). IEEE, 2022, pp. 1–6, doi:10.1109/ICECCME55909.2022.9988025.
- [136] B. Atıcı and S. İlhan Omurca, “Generating classified ad product image titles with image captioning,” in Trends in Data Engineering Methods for Intelligent Systems: Proceedings of the International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2020). Springer, 2021, pp. 211–219, doi:10.1007/978-3-030-79357-9_21.
- [137] S. Yıldız, A. Memiş, and S. Varlı, “Automatic Turkish image captioning: The impact of deep machine translation,” in 2023 8th International Conference on Computer Science and Engineering (UBMK). IEEE, 2023, pp. 414–419, doi:10.1109/UBMK59864.2023.10286693.
- [138] S. Yıldız, A. Memiş, and S. Varlı, “TRCaptionNet: A novel and accurate deep Turkish image captioning model with vision transformer based image encoders and deep linguistic text decoders,” Turkish Journal of Electrical Engineering & Computer Sciences, vol. 31, no. 6, pp. 1079–1098, 2023, doi:10.55730/1300-0632.4035.
- [139] A. Ersoy, O. T. Yıldız, and S. Özer, “ORTPiece: An ORT-based Turkish image captioning network based on transformers and wordpiece,” in 2023 31st Signal Processing and Communications Applications Conference (SIU). IEEE, 2023, pp. 1–4, doi:10.1109/SIU59756.2023.10223956.
- [140] M. A. C. Ertuğrul and S. İ. Omurca, “Generating image captions using deep neural networks,” in 2023 8th International Conference on Computer Science and Engineering (UBMK). IEEE, 2023, pp. 271–275, doi:10.1109/UBMK59864.2023.10286622.
- [141] S. Yıldız, A. Memiş, and S. Varlı, “Turkish image captioning with vision transformer based encoders and text decoders,” in 2024 32nd Signal Processing and Communications Applications Conference (SIU). IEEE, 2024, pp. 1–4, doi:10.1109/SIU61531.2024.10600738.
- [142] S. Schweter, “BERTurk - BERT models for Turkish,” Apr. 2020.
- [143] G. Uludoğan, Z. Y. Balal, F. Akkurt, M. Türker, O. Güngör, and S. Üsküdarlı, “Turna: A turkish encoder-decoder language model for enhanced understanding and generation,” arXiv preprint arXiv:2401.14373, 2024, doi:10.48550/arXiv.2401.14373.
- [144] H. T. Kesgin, M. K. Yuce, and M. F. Amasyali, “Developing and evaluating tiny to medium-sized turkish bert models,” arXiv preprint arXiv:2307.14134, 2023, doi:10.48550/arXiv.2307.14134.
- [145] N. Tas, “Roberturk: Adjusting roberta for turkish,” arXiv preprint arXiv:2401.03515, 2024, doi:10.48550/arXiv.2401.03515.
- [146] H. T. Kesgin, M. K. Yuce, E. Dogan, M. E. Uzun, A. Uz, H. E. Seyrek, A. Zeer, and M. F. Amasyali, “Introducing cosmosgpt: Monolingual training for turkish

language models,” arXiv preprint arXiv:2404.17336, 2024, doi:10.48550/arXiv.2404.17336.

[147] H. Türkmen, O. Dikenelli, C. Eraslan, M. C. Callı, and S. S. Özbek, “Bioberturk: Exploring turkish biomedical language model development strategies in low-resource setting,” *Journal of Healthcare Informatics Research*, vol. 7, no. 4, pp. 433–446, 2023, doi:10.1007/s41666-023-00140-7.

[148] OpenAI, “ChatGPT,” <https://chat.openai.com/chat>, 2023.

[149] Google, “Bard,” <https://bard.google.com/>, 2023.

[150] Google, “Gemini,” <https://gemini.google.com/>, 2024.

Özgeçmişler



Dr. Abbas Memiş, 2010 yılında Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü’nden mezun olmuştur. Yüksek lisans ve Doktora derecelerini ise sırasıyla 2013 ve 2020 yıllarında Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı’ndan almıştır. Şu anda İstanbul Üniversitesi, Bilgisayar ve Bilişim Teknolojileri Fakültesi, Bilgisayar Mühendisliği Bölümü’nde Dr. Öğr. Üyesi olarak çalışmakta ve ağırlıklı olarak bilgisayarla görme, görüntü işleme, medikal görüntü analizi, yapay zekâ ve tıpta/sağlıkta yapay zekâ konularında araştırma çalışmaları yürütmektedir.

