


ISSN: 1308-9064

Cilt: 38 / Sayı: 1 / Yıl: 2026

# FIRAT ÜNİVERSİTESİ FEN BİLİMLERİ DERGİSİ





**F ı r a t Ü n i v e r s i t e s i**  
**Fen Bilimleri Dergisi (FBD)**  
**Cilt:38, Sayı:1, Yıl:2026**  
**ISSN: 1308 - 9064**

### **İ l e t i Ő i m**

Fırat Üniversitesi  
Fen Bilimleri Enstitüsü  
23119, ELAZIĞ

**Tel: 0 424 212 27 07**  
**Faks: 0 424 236 99 55**  
**e-posta: [fenbilim@firat.edu.tr](mailto:fenbilim@firat.edu.tr)**

**Bu dergi yılda 2 kez ve hakemli olarak yayımlanır.**

***Derginin Eski Adı: Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi***  
***Derginin Eski ISSN Numarası: 1300-2708***

***<http://dergipark.gov.tr/fufbd>***



# Fırat Üniversitesi

## Fen Bilimleri Dergisi (FBD)

### Sahibi

**Prof. Dr. Fahrettin GÖKTAŞ**  
Fırat Üniversitesi Rektörü

### Genel Yayın Yönetmeni

**Prof. Dr. Burhan ERGEN**  
F.Ü. Fen Bilimleri Enstitüsü Müdürü

### Baş Editör

**Doç. Dr. Mahmut KAYA**  
F.Ü. Fen Bilimleri Enstitüsü Müdür Yrd.

### Editör

**Prof. Dr. Emrah YILMAZ**  
F.Ü. Fen Bilimleri Enstitüsü Müdür Yrd.

## DANIŞMA KURULU

İsim	Kurum
<b>Prof. Dr. Abdülkadir ŞENGÜR</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Ahmet Kadri CETİN</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Ali KARCI</b>	İnönü Üniversitesi, Türkiye
<b>Prof. Dr. Ali YAZICI</b>	Atılım Üniversitesi, Türkiye
<b>Prof. Dr. Deniz UNER</b>	Orta Doğu Teknik Üniversitesi, Türkiye
<b>Prof. Dr. Ercan AKSOY</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Erhan AKIN</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Ertan GÖKALP</b>	Karadeniz Teknik Üniversitesi, Türkiye
<b>Prof. Dr. Güneş S. KÜRKCÜOĞLU</b>	Eskişehir Osmangazi Üniversitesi, Türkiye
<b>Prof. Dr. Haluk KORALAY</b>	Gazi Üniversitesi, Türkiye
<b>Prof. Dr. Hanifi GÜLDEMİR</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Hikmet GEÇKİL</b>	İnönü Üniversitesi, Türkiye
<b>Prof. Dr. İlhami KIZIROĞLU</b>	OSTİM Teknik Üniversitesi, Türkiye
<b>Prof. Dr. İlker Bekir TOPÇU</b>	Eskişehir Osmangazi Üniversitesi, Türkiye
<b>Prof. Dr. İzzet KARA</b>	Pamukkale Üniversitesi, Türkiye
<b>Prof. Dr. Mahmut ELP</b>	Kastamonu Üniversitesi, Türkiye
<b>Prof. Dr. Ömer AKIN</b>	TOBB Ekonomi ve Teknoloji Üniversitesi, Türkiye
<b>Prof. Dr. Resul DAŞ</b>	Fırat Üniversitesi, Türkiye
<b>Prof. Dr. Serdar SALMAN</b>	Milli Savunma Üniversitesi, Türkiye
<b>Prof. Dr. Serkan DAĞ</b>	Orta Doğu Teknik Üniversitesi, Türkiye
<b>Prof. Dr. Seyfettin ÇAKMAK</b>	Süleyman Demirel Üniversitesi, Türkiye
<b>Prof. Dr. Ülkü YETİŞ</b>	Orta Doğu Teknik Üniversitesi, Türkiye
<b>Prof. Dr. Zühtü Hakan AKPOLAT</b>	Fatih Sultan Mehmet Vakıf Üniversitesi, Türkiye



İÇİNDEKİLER / CONTENTS

- 1. M-Bus Haberleşme Protokolü ile Kalorimetre Okuma ve Faturalandırma Yazılımı**  
*Calorimeter Reading and Billing Software with M-Bus Communication Protocol*  
**Ergün ACUR, Günnur ŞEN, Murat DEMİR, Mustafa NİL** ..... 1-11
- 2. Sosyal Medya İçeriklerinde Toksik Dilin Tespitine Yönelik Hibrit Derin Öğrenme Modeli**  
*A Hybrid Deep Learning Model for Detecting Toxic Language in Social Media Content*  
**Anıl UTKU** ..... 13-24
- 3. YOLO ile Tarımsal Ürün ve Yabani Bitki Sınıflandırması: Yeni Bir Veri Seti ve Farklı Stratejilerin Tespit Başarılarının Karşılaştırılması**  
*Agricultural Crop and Wild Plant Classification with YOLO: A New Dataset and Comparison of Detection Success of Different Strategies*  
**Yunus YAMAN, Yusuf DEMİR, Yavuz CANBAY** ..... 25-36
- 4. Mikro Gaz Türbinlerinde Güç Tahmini İçin Doğru Yapay Zekâ Modelinin Seçimi: Kapsamlı Bir Performans Çalışması**  
*Choosing the Right AI Model for Power Forecasting in Micro Gas Turbines: A Comprehensive Performance Study*  
**Emrullah GAZİOĞLU** ..... 37-48
- 5. Suluçayır Düzünde (Sivrice - Elazığ) Bulunan Bir Göletin (Tmi 12) Epifitik Algleri**  
*Epiphytic Algae Of A Pond (Tmi 12) Located in Suluçayır Pond (Sivrice - Elazığ)*  
**Güneş PALA** ..... 49-57



## M-Bus Haberleşme Protokolü ile Kalorimetre Okuma ve Faturalandırma Yazılımı

Ergün ACUR<sup>1</sup>, Günnur ŞEN<sup>2\*</sup>, Murat DEMİR<sup>3</sup>, Mustafa NİL<sup>4</sup>

<sup>1,4</sup> Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Manisa Celal Bayar Üniversitesi, Manisa, Türkiye

<sup>2</sup> Elektrik Programı, Aliğa Meslek Yüksekokulu, Ege Üniversitesi, İzmir, Türkiye

<sup>3</sup> Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, İzmir Bakırçay Üniversitesi, İzmir, Türkiye

<sup>1</sup> ergun\_acur@hotmail.com, <sup>2\*</sup> gunnur.sen@ege.edu.tr, <sup>3</sup> murat.demir@bakircay.edu.tr, <sup>4</sup> mustafa.nil@cbu.edu.tr

(Geliş/Received: 29/05/2025;

Kabul/Accepted: 20/09/2025)

**Öz:** Dünya nüfusundaki artışa bağlı olarak barınma ihtiyacının artması, konut tiplerinin coğrafi bölgelere göre çeşitlilik göstermesine neden olmaktadır. Özellikle kentsel alanlarda müstakil konutlar yerine sitelerde yaşamın yaygınlaşması, merkezi ısıtma sistemleri gibi toplu yaşam gerekliliklerini beraberinde getirmiştir. Enerji verimliliğinin sağlanması ve kaynakların sürdürülebilir kullanımı, özellikle merkezi ısıtma sistemlerinde kritik bir öneme sahiptir. Bu çalışmada, M-Bus (Meter-Bus) protokolü ve LabVIEW grafiksel programlama platformu kullanılarak, kalorimetrelerden gerçek zamanlı veri okuma, işleme ve otomatik faturalandırma yapabilen bütünleşmiş bir sistem geliştirilmiştir. Sistem, binalarda enerji tüketiminin şeffaf ve verimli bir şekilde yönetilmesini sağlamak için, uzaktan izleme, arıza tespiti ve kullanıcı dostu bir arayüz sunmaktadır. M-Bus protokolünün düşük güç tüketimi, yüksek güvenilirlik ve endüstriyel uyumluluk avantajlarından yararlanılarak geliştirilen sistem, özellikle 2000 m<sup>2</sup> ve üzeri binalarda 5627 sayılı Enerji Verimliliği Kanunu'nun gerekliliklerini karşılamaktadır. Çalışmada, gerçek zamanlı veri analizi, tüketim trendlerinin görselleştirilmesi ve otomatik raporlama gibi işlevler ilave edilmiştir. Deneysel sonuçlar, geliştirilen sistemin %98,5 doğruluk oranı ile enerji tüketimini ölçtüğünü ve faturalandırmada %30'a varan tasarruf sağladığını göstermiştir. Bu çalışma, akıllı bina ve enerji yönetim sistemleri alanında düşük maliyetli, ölçeklenebilir ve yenilikçi bir çözüm sunmaktadır.

**Anahtar kelimeler:** M-Bus, LabVIEW, akıllı sayaç, enerji verimliliği, otomatik faturalandırma.

### Calorimeter Reading and Billing Software with M-Bus Communication Protocol

**Abstract:** The increase in the need for housing due to the increase in the world population causes housing types to vary according to geographical regions. The widespread use of housing estates instead of detached houses, especially in urban areas, has brought along the requirements for collective living such as central heating systems. Ensuring energy efficiency and sustainable use of resources are critical, especially in central heating systems. In this study, an integrated system capable of real-time data reading, processing and automatic billing from calorimeters is developed using the M-Bus (Meter-Bus) protocol and LabVIEW graphical programming platform. The system provides transparent and efficient management of energy consumption in buildings and offers remote monitoring, fault detection and a user-friendly interface. Utilizing the advantages of low power consumption, high reliability and industrial compatibility of the M-Bus protocol, the system meets the requirements of the Energy Efficiency Law No. 5627, especially in buildings of 2000 m<sup>2</sup> and above. In the study, functions such as real-time data analysis, visualization of consumption trends and automatic reporting are integrated.

**Keywords:** M-bus, LabVIEW, smart meter, energy efficiency, automatic billing.

### 1. Giriş

Enerji verimliliği ve sürdürülebilir kaynak yönetimi, günümüzün en kritik küresel sorunları arasında yer almaktadır. Dünya nüfusundaki artışa bağlı olarak barınma ihtiyacının yükselmesi, konut tiplerinin coğrafi bölgelere göre çeşitlenmesine yol açmıştır. Özellikle kentsel alanlarda müstakil konutlar yerine sitelerde toplu yaşamın yaygınlaşması, merkezi ısıtma sistemleri gibi ortak yaşam gerekliliklerini beraberinde getirmiştir. Bu bağlamda, binalarda kullanılan enerjinin yaklaşık %40'ını oluşturan ısıtma sistemleri, enerji verimliliğinin sağlanması ve kaynakların sürdürülebilir kullanımı açısından önemli bir potansiyel barındırmaktadır [1]. Türkiye'de 5627 sayılı Enerji Verimliliği Kanunu ve Binalarda Enerji Performans Yönetmeliği, özellikle 2000 m<sup>2</sup> ve üzeri binalarda merkezi ısıtma sistemlerinde ısı paylaşımının adil ve şeffaf bir şekilde dağıtılmasını zorunlu kılmıştır [2]. Bu yasal düzenlemeler, merkezi sistemlerde kullanılan enerjinin nasıl ölçüleceği ve adaletli bir şekilde pay edilmesi gibi sorunları gündeme getirmiş; bu durum, birçok firmanın kalorimetre ve fatura paylaşım

\* Sorumlu yazar: [gunnur.sen@ege.edu.tr](mailto:gunnur.sen@ege.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0009-0004-5040-7164, <sup>2</sup> 0000-0001-7793-3616, <sup>3</sup> 0000-0003-4407-9673, <sup>4</sup> 0000-0003-0794-7603

programları geliştirmesine neden olmuştur. Kalorimetre, fiziksel değişimlerde açığa çıkan ısı ölçme ile ilgili olduğundan mekanik ve elektronik kısımlarının ölçüm ve hesaplamaları da iyi bilinmelidir. Merkezi kısım debi ölçümünde, elektronik kısım ise hesaplama alanında gerektiğinden faturalandırmada tasarruf için uygun şartlar sağlanmış olur. Merkezi sistemlerde ortaya çıkan sıcaklığın algılayıcılar vasıtasıyla ölçülmesi neticesinde hesaplamaların yapılabilmesi için fatura programlarının belirli standartlarda olması gerekir.

Otomatik sayaç okuma (automatic meter reading (AMR)) sistemleri konusundaki araştırmalar, son yıllarda önemli ölçüde artış göstermiştir. Literatürde, Mukul tarafından ev enerji izleme sistemleri için geliştirilen grafiksel kullanıcı ara yüzü tasarımı, kullanıcı dostu ara yüzlerin enerji tüketim alışkanlıklarını değiştirmedeki rolünü vurgulamıştır [3]. Benzer şekilde, Ahmed ve arkadaşları, Bangladeş'te düşük maliyetli dijital wattmetre ve WiMAX teknolojisi kullanarak geliştirdikleri otomatik elektrik sayaç okuma sisteminin maliyet etkinliğini kanıtlamıştır [4]. Karaman ve arkadaşları ise gerçek zamanlı enerji izleme ve tüketici farkındalığı için LabVIEW™ programı ile otomatik sayaç okuma üzerine bir çalışma sunmuştur [5].

Son yıllarda, Nesnelerin İnterneti (Internet of Things (IoT)) tabanlı akıllı ölçüm sistemleri büyük ilgi görmektedir. Gajda ve Retkowski, IoT çağında M-Bus iletişiminin potansiyelini incelemiş ve endüstriyel uygulamalardaki rolünü vurgulamıştır [6]. Zhou ve arkadaşları, yapay zekâ tabanlı aykırılık tespit sistemlerinin enerji tüketimindeki düzensizlikleri belirlemedeki etkinliğini kanıtlamıştır [7]. Merkezi ısıtma sistemlerinde kullanılan kalorimetre teknolojileri de sürekli olarak gelişmektedir. Örneğin, Karaca tüketim sayaçlarında M-Bus standartlarının uygulanmasının geleneksel metotlara göre avantajlarını incelemiştir [8]. Ayrıca, European Commission tarafından yayınlanan yeni direktifler, akıllı ölçüm sistemlerinin yaygınlaştırılması için bir yol haritası çizmiştir [9].

Bu çalışma, mevcut literatürdeki eksiklikleri gidermek ve belirtilen yasal gereklilikleri karşılamak amacıyla M-Bus (Meter-Bus) protokolü ve LabVIEW grafiksel programlama platformu kullanılarak, kalorimetrelere gerçek zamanlı veri okuma, işleme ve otomatik faturalandırma yapabilen bütünleşmiş bir sistem önermektedir. Bu bağlamda çalışmanın başlıca katkıları şunlardır:

- M-Bus protokolü ve LabVIEW platformunu bütünleştiren yenilikçi bir sistem mimarisi sunulması.
- Türkiye'deki 5627 sayılı Enerji Verimliliği Kanunu ve ilgili yönetmeliklere tam uyumlu bir çözüm sağlanması.
- Düşük maliyetli ve ölçeklenebilir bir altyapı tasarımıyla akıllı bina ve enerji yönetim sistemleri alanına katkıda bulunulması.

Geliştirilen sistemin temel özellikleri ise şunlardır:

- Gerçek zamanlı enerji tüketim verisi toplama ve analiz yeteneği.
- Kullanıcı dostu grafiksel ara yüz tasarımı ile kolay kullanım imkânı.
- Enerji tüketimindeki anormallikler için arıza tespiti ve uyarı mekanizmaları.
- EN 13757 ve ISO/IEC 14908 gibi uluslararası standartlarla tam uyumluluk [10,11].


## 2. Materyal ve Yöntem

Bu bölümde, geliştirilen bütünleşmiş sistemin genel mimarisi, kullanılan donanım ve yazılım bileşenleri, veri toplama ve işleme prosedürleri ile deneysel kurulum detayları ayrıntılı olarak açıklanmaktadır. Çalışma, özellikle merkezi ısıtma sistemlerinde enerji tüketimini M-Bus protokolü üzerinden gerçek zamanlı olarak izlemek, işlemek ve otomatik faturalandırmak amacıyla tasarlanmıştır.


### 2.1. Sistem mimarisi ve bileşenleri

Geliştirilen sistem, merkezi ısıtma sistemlerinden kalorimetrelere aracılığıyla elde edilen enerji tüketim verilerini toplayarak işleyen ve faturalandıran bütünleşmiş bir yapıdır. Otomatik sayaç okuma (OSO) sistemleri, enerji ölçüm cihazlarından verilerin otomatik olarak okunması, faturalandırılması ve merkezi bir veri tabanına iletilmesi prensibine dayanır [12]. Sistemin temel bileşenleri üç ana birimden oluşmaktadır: Elektronik sayaçlar (kalorimetrelere), veri iletim hattı ve merkezi sistem birimi. Şekil 1'de OSO sisteminin birimleri ve Şekil 2'de genel yapısı görülmektedir [13]. Burada elektrik sayacından alınan bilgiler çevrimiçi olarak bilgisayara gelmektedir. Bilgisayarda toplanan veriler müşteri kayıtları altında depolanmakta ve veri tabanı oluşturulmaktadır.

Daha sonra bu veriler ile faturalama ve hesaplamalar yapılmaktadır. Aynı zamanda sayaçlardan gelen çevrimiçi bildirimler ve olaylar kayıt altına alınmaktadır.



Şekil 1. Otomatik sayaç okuma sistemi birimleri [13].




Şekil 2. Otomatik sayaç okuma sistemi genel yapısı [13].

**Elektronik Sayaçlar (Kalorimetreler):** Merkezi ısıtma ve soğutma sistemlerinde tüketilen ısı enerjisini ölçmek için kullanılan M-Bus uyumlu kalorimetreler kullanılmıştır. Isı sayaçları, harici ve dâhili sıcaklık sensörleri ile

gidiş ve dönüş sıcaklıkları arasındaki farkı ( $\Delta T$ ) hesaplar. Aynı zamanda geçen debiyi anlık olarak ölçerek tüketilen enerjiyi kilowatt saat (kWh) cinsinden bulur [13]. Sistemde birden fazla kalorimetreden eş zamanlı veri alınmıştır.

**Veri İletim Hattı (M-Bus Protokolü ve Dönüştürücü):** Kalorimetrelerden toplanan verilerin merkezi sisteme iletilmesi için M-Bus (Meter-Bus) protokolü kullanılmıştır. M-Bus, su, gaz veya elektrik tüketim sayaçlarının uzaktan okunması için geliştirilmiş, bükümlü çift kablo üzerinden iletişim sağlayan bir Avrupa standardıdır [14, 15]. Bu protokol, düşük güç tüketimi, yüksek güvenilirlik ve endüstriyel uyumluluk avantajları nedeniyle tercih edilmiştir. M-Bus sinyallerinin bilgisayar ortamına aktarılması için M-Bus seviye dönüştürücü (converter) kullanılmıştır. M-Bus dönüştürücüler, M-Bus cihazlarından gelen uygun voltaj veya akım değişimini diğer cihazlar veya sistemlerle uyumlu hale getirir; özellikle RS232, RS485 ve TCP/IP gibi yaygın veri yolu protokolleriyle M-Bus uyumluluğunu sağlarlar [6]. Çalışmada RS232-M-Bus dönüştürücü ve seri porttan bağlantıyı sağlamak için bir USB seri adaptör kullanılmıştır. İletim, senkronizasyonun her karakter için başlangıç ve bitiş bitleriyle uygulandığı asenkron seri bit iletimini kullanır, yarı iki katlı olarak ve en az 300 Baud veri hızıyla gerçekleşmektedir. Şekil 3'te bir baytın çağrı ve yanıtlama yönünde iletilmesi gösterilmektedir [16].



Şekil 3. Çağrı ve cevap yönünde bir karakterin iletimi [16].

**Merkezi Sistem Birimi (Veri Toplama, İşleme ve Faturalandırma):** Toplanan verilerin işlendiği, depolandığı ve otomatik faturalandırmanın yapıldığı ana birimdir. Bu birim, National Instruments LabVIEW grafiksel programlama platformu kullanılarak geliştirilen özel bir yazılım ile yönetilmektedir. LabVIEW, "Laboratory Virtual Instruments For Workbench" ifadesinin kısaltması olup, görsel bir programlama dili (GPL) teknolojisine sahiptir. Ölçme ve enstrümantasyon odaklı geliştirilmiş bu platform, grafiksel ara yüz oluşturma ve veri elde etme süreçlerinde yaygın olarak kullanılır ve C tabanlı programlara göre daha fazla verimlilik sunar [17]. Merkezi sistem birimi, kalorimetrelerden okunan verileri doğrulamakta, veri tabanına kaydetmekte ve tüketim trendlerini görselleştirmektedir. Ayrıca, enerji tüketimindeki anormallikler için arıza tespiti ve uyarı mekanizmaları da bu birimde bütünleştirilmiştir. Faturalandırma algoritmaları, 5627 sayılı Enerji Verimliliği Kanunu'nun ilgili yönetmeliklerine uygun olarak tasarlanmıştır.

## 2.2. Veri toplama ve işleme prosedürü

Sistemin veri toplama ve işleme süreci aşağıdaki adımlarla gerçekleştirilmiştir:

**Kalorimetre Bağlantısı ve Veri Okuma:** Tüm M-Bus uyumlu kalorimetreler, M-Bus ağı üzerinden RS232-M-Bus dönüştürücüye bağlanmıştır. Dönüştürücü ise USB seri adaptör aracılığıyla merkezi bilgisayara bütünleştirilmiştir. LabVIEW yazılımı, belirlenen periyotlarda (örn: her 15 dakikada bir) kalorimetrelerden

otomatik olarak enerji tüketim verilerini (toplam kWh, anlık tüketim, cihaz durumu vb.) okumuştur. Bu aşamada, seri iletişimin yapılacağı port ve Baud hızı ile kalorimetrenin adres bilgileri (primer veya sekonder ID) ayarlanmaktadır. Tarama ekranında tespit edilen slave'lere ait adresler ve taramanın ilerleyişi takip edilebilmektedir. Okunan HEX kodları ekrana yazdırılarak kalorimetre ile M-Bus dönüştürücü arasında veri alışverişi sağlanmaktadır.

**Veri Doğrulama ve Depolama:** Okunan ham veriler, M-Bus protokolünün **FT 1.2 format sınıfına** uygun olarak (Tek Karakter, Kısa Çerçeve, Kontrol Çerçevesi, Uzun Çerçeve) veri bütünlüğü kontrollerinden geçirilmiştir. Dönüştürülen anlamlı veriler, ayarlar ekranına aktarılarak kontrol edilmekte ve verilerin ne sıklıkla ekrana yazdırılması gerektiği gibi zamanlama ayarları yapılmaktadır. Kalorimetreler pil ile beslendiği için daha uzun süre çalışmaları amacıyla bu değer günde bir defa veri yazılması uygun görülmüştür. Doğrulanmış veriler, tarih ve zaman bilgileriyle birlikte bir veri tabanına kaydedilmiştir. FT 1.2 biçim sınıfı, özel başlangıç karakterleri aracılığıyla tanınabilen üç farklı telgraf biçimini belirtir. Aşağıda ve Tablo 1' de, M-Bus için kullanılan telgraf biçimleri açıklanacaktır [16].

**Tablo 1.** M-Bus protokolünün telegram formatları [16]

Tek Karakter	Kısa Çerçeve	Kontrol Çerçevesi	Uzun Çerçeve
E5h	10h'de başla	68h'de başla	68h'de başla
	C Alanı	L Alanı = 3	L Alanı
	Bir Alan	L Alanı = 3	L Alanı
	Kontrol Toplamı	68h'de başla	68h'de başla
	16 h dur	C Alanı	C Alanı
		Bir Alan	Bir Alan
		CI Alanı	CI Alanı
		Kontrol Toplamı	Kullanıcı Verileri
		16 h dur	(0-252 Bayt)
			Kontrol Toplamı
			16 h dur

**Veri Analizi ve Görselleştirme:** Veritabanında depolanan tüketim verileri, LabVIEW'de geliştirilen arayüz üzerinden görselleştirilmiştir. Program, bu verileri bir tabloya dönüştürerek değerlerin tek noktadan kontrolünü ve izlenmesini sağlamaktadır. Bu sayede, kullanıcılar ve yöneticiler, anlık ve geçmiş tüketim trendlerini, enerji verimliliklerini ve potansiyel arızaları kolayca takip edebilmiştir.

**Otomatik Faturalandırma:** Sistem, toplanan ve analiz edilen tüketim verilerini kullanarak otomatik faturalandırma işlemini gerçekleştirmiştir. Tablolaştırılan veriler, LabVIEW ekranından Excel ortamına aktarılmakta; burada sayaç ID'si ve tüketim değeri gibi faturalar için gerekli olan bilgiler kaydedilmektedir. Excel ortamına aktarılan veriler, burada oluşturulan fatura paylaşım programı ile faturalandırılarak süreç tamamlanmaktadır. Faturalandırma, ilgili yasal düzenlemeler ve önceden tanımlanmış tarifeler esas alınarak yapılmıştır.

### 2.3. Deneysel kurulum ve test ortamı

Geliştirilen bütünleşmiş sistemin performansı ve doğruluğu, laboratuvar ortamında kurulan bir deney düzeneği üzerinde test edilmiştir. Deney düzeneği Şekil 4'te gösterilmektedir.

- **Uygulama Ortamı ve Donanımlar:** Deney düzeneğinde İsta markasına ait **M-Bus dönüştürücü**, Baylan markasına ait 2 adet,İntegral markasına ait 1 adet olmak üzere toplam 3adet **kalorimetre**, seri porttan bağlantıyı sağlamak için **USB seri adaptör** ve bilgisayarda **LabVIEW 2020** programı kullanılmıştır. Bu kurulum,aynı marka sayaçlarla yapılan tekli ve çoklu ölçümlerin yanı sıra farklı marka sayaçlarla da veri okuma, dönüştürme ve faturalandırma işlemlerinin laboratuvar koşullarında başarılı bir şekilde gerçekleştirildiğini göstermiştir. Özellikle kablolu veri aktarımı tercih edilerek bodrum katlarda yer alan elektrik odaları gibi zorlu koşullarda sistemin kararlılığı test edilmiştir. EN 13756 Standartına göre,tekli bir fiziksel M-Bus hattına doğrudan **250** cihaza kadar bağlantı yapılabilmektedir.
- **Program Arayüzü ve Test Prosedürü:** Deney düzeneği kurulduktan sonra program çalıştırılarak yazılan kodların ve programın arayüzünün olduğu ön panel ve blok diyagram sayfaları açılmıştır (Şekil 5). Seri iletişim ayarları (port ve Baud hızı) ve kalorimetrenin adres bilgileri yapılarak iletişim sağlanmıştır. Sistemden elde edilen tüketim verileri, manuel okumalar veya referans sayaç verileri ile karşılaştırılarak ölçüm doğruluğu ve faturalandırma hassasiyeti belirlenmiştir.
- **Performans Değerlendirmesi:** Sistemin performansı, laboratuvar ortamında öncelikle tek bir sayaç ile başlatılmış, daha sonra iki adet M-Bus uyumlu (Baylan marka) kalorimetre aynı hat üzerinden bağlanarak test edilmiştir. Sonraki aşamada ise bu sayaçlara ek olarak farklı bir marka (Integral) sayaç da eklenmiş ve sistem yeniden test edilmiştir. Ölçümler sonucunda, sistemin 2400 Baud hızında kararlı bir iletişim sağladığı ve veri kaybı yaşanmadığı gözlemlenmiştir. Ölçülen değerler hem sayaç üzerindeki dijital ekrandan hem de farklı bir ticari firmaya ait program kullanılarak doğrulanmıştır. Aynı marka sayaçların sonuçlarında yüzde yüz doğruluk elde edilirken, farklı marka sayaçların aynı anda ölçümü sırasında sayaç markasından kaynaklı veri farklılıkları gözlenmiştir; örneğin, sayaçlardan biri sıcaklık verisini 12,95 °C gösterirken, diğeri 13 °C göstermektedir. Bu değerler baz alınarak sistemin ortalama doğruluk değeri %98,5 olarak öngörülmüştür.

### 3. Bulgular ve Tartışma

Kalorimetre ve M-Bus dönüştürücü ve seri port yardımı ile bilgisayar birbiri ile iletişim kurması sağlanmaktadır. Bağlantı yapıldıktan sonra mevcutta okumak istenilen kalorimetrenin seri port ayarları yapılır. Ardından kalorimetrenin adresini girilerek haberleşme sağlanır. Şekil 4'te deney düzeneği görülmektedir. İsta markasına ait M-BUS dönüştürücü, Baylan markasına ait kalorimetre, seri porttan bağlantı sağlamak için USB seri adaptör ve Bilgisayarda LabVIEW 2020 programı yardımı ile deney düzeneği hazırlanmıştır.



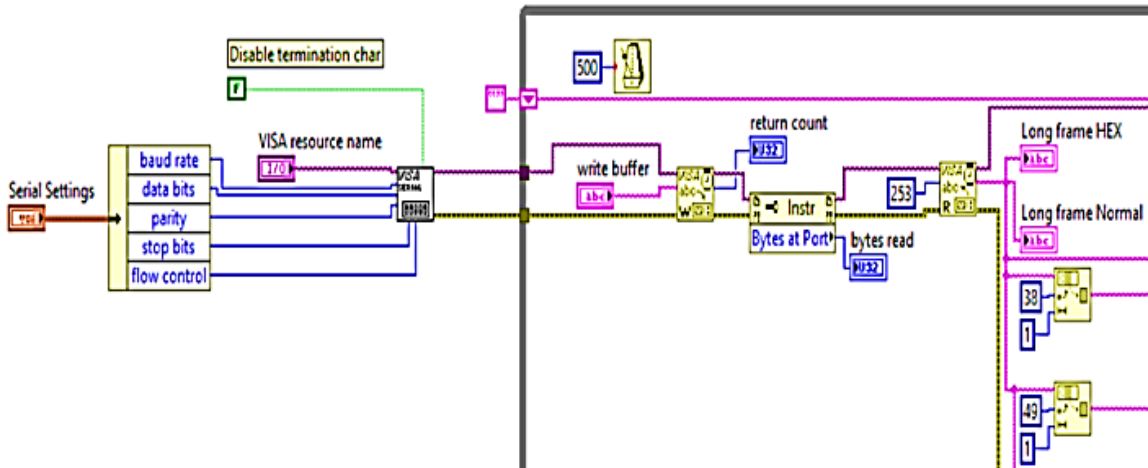
Şekil 4. Deney düzeneği.

Deney düzeneği kurulduktan sonra program çalıştırılarak yazılan kodların ve programın ara yüzünün olduğu ön panel ve blok diyagram sayfaları açılır. Şekil 5'te sayfaların görseli yer almaktadır.



Şekil 5. Programın ön panel ve blok diyagramı.

Bu aşamada öncelikle bazı ayarlar yapılmaktadır. Bunlar; seri iletişimin hangi porttan yapılacağı ve Baud hızı yani cihazın kalorimetre ile veri alış verişinin yapılacağı hız değeri, kalorimetrenin adres bilgileridir. Burada iki farklı bilgi vardır. Bunlardan ilki adres bilgisi diğeri ise kimlik bilgisi değeridir. Kalorimetreler, üretim yapan firmaya göre bazıları primer bazılarında ise sekonder adres kimlik ID değerleri yüküldür. Tasarlanan ara yüz de her iki adres bilgilerinin taranması ve veri aktarılması ayrı ayrı yapılmakta tarama ekranında mevcut taranan slave ait adres gösterilmekte ayrıca taramanın ilerleyişi de ekrandan takip edilebilmektedir. Adresleri taranan ve tespit edilen slavelere ait veriler alınarak yani kalorimetrenin yaptığı ölçüm sonuçları HEX kodları ekrana yazdırılmakta yani kalorimetre ile M-Bus dönüştürücü arasında veri alışverişi sağlanmaktadır.



Şekil 6. Seri iletişim bağlantı sağlayan kodlar.

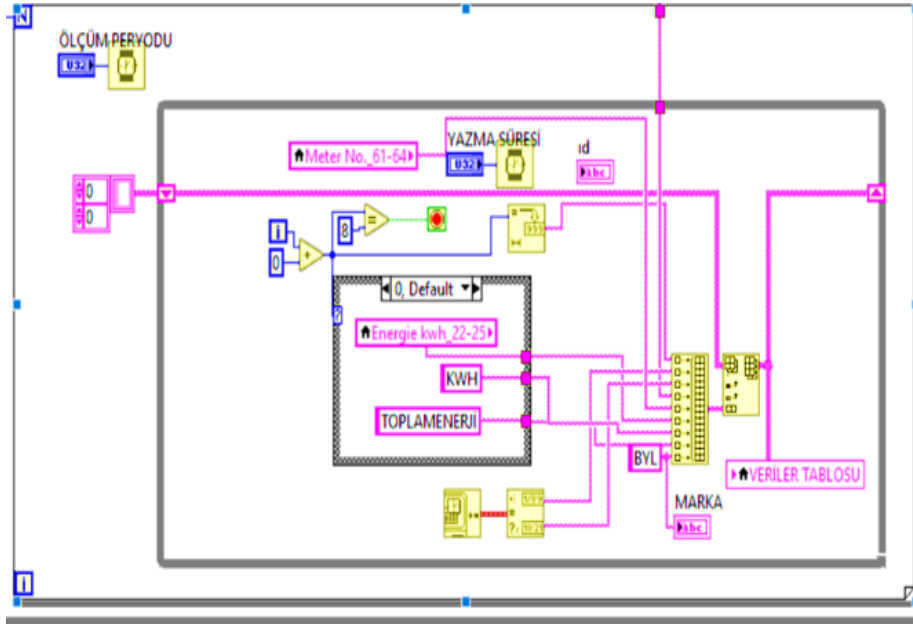
Anlamli deęerlere dönüştürülen veriler, ayarlar ekranına aktarılarak kontrol edilmekte ve verilerin ne sıklıkla ekrana yazdırılması gerektiği gibi zamanlama ayarları yapılmaktadır. Kalorimetreler pil ile beslendiğinden dolayı

daha uzun süre çalışması için günde bir defa veri yazılması uygun görülmektedir. Şekil 7’de bu değerler görülmektedir.

Başla_0	Enerji kwh_22-25
Uzunluk Alanı_1	Hacim m <sup>3</sup> _28-31
Uzunluk Alanı_2	T1 Giriş Sıcaklık_46-48
Başla_3	T2 Çıkış Sıcaklık 51-53
Kontrol Alanı 4	T1-T2 Sıcaklık Farkı 56-58
Adres Alanı_5 M-Bus adresi	Güç_W 34-37
Kontrol Bilgi Alanı_6	Açık Kalma Süre _67-69
Sayaç No_61-64	Debi_m <sup>3</sup> /h_40-43
Cihaz Türü_14	Ölçüm Zamanı 72_76
Hata Mesajı_16	

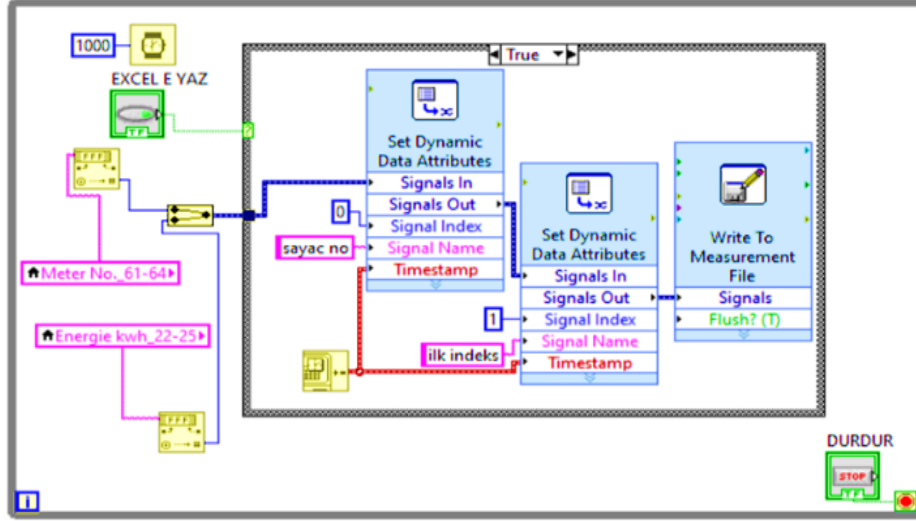
Şekil 7. Verilerin anlamlandırılması.

Program bu verileri bir tabloya çevirerek değerlerin tek noktadan kontrolünü ve izlenmesini sağlamaktadır. Şekil 8’de değerleri tabloya çevirmek için kullanılan görsel kodlar görülmektedir.



Şekil 8. Verilerin tabloya çevrilmesi görsel kodları.

Tablodaki veriler faturaya dönüştürülmek için bir sonraki aşamada LabVIEW ekranından Excel ortamına aktıracaktır. Bu dönüşümü yapan görsel kodları aşağıda şekil 9’da görülmektedir. Faturalarda kullanılan tüketim değeri gerekl olduğundan excel ortamına sayaç ID ve tüketim değeri olarak yazdırılmaktadır.



Şekil 9. Verilerin excel'e aktarma kodları.

Excel ortamına aktarılan yazdırıldığı tarih, tüketim değeri ve sayaç ID si olarak bize fatura oluşturulması için gerekli olan değerlerdir. LabVIEW Front Panel üzerinde oluşturulan fatura sekmesinden yazdırma işlemi kolayca yapılmaktadır.

Son aşamada excel ortamına aktarılan veriler burada oluşturulan fatura paylüt programı ile faturalandırılmaktadır. Fatura programında LabVIEW üzerinden alınan veriler ve yönetmeliklerde belirtilmiş pay etme verileri kullanılarak hazırlanmıştır. Şekil 10’da hazırlanmış olan fatura örneği görülmektedir.

SİTE ADI		DÖNEMİ	
MYRINA PARK		May.25	
MALİK BİLGİLERİ		ÖDENECEK TUTAR(TL)	SON ÖDEME TARİHİ
ADI SOYADI	ERGÜN ACUR	129,46	11.06.2025
BLOK	B	EK ÖDEMELER	
DAİRE NO	5	HİZMET BEDELİ	25
DÖNEM BİLGİLERİ		BİNA ISITMA TÜKETİM BİLGİLERİ	
OKUMA TARİHİ	30.05.2025	TÜKETİM TUTARI	7863,80
SON ÖDEME TARİHİ	14.06.2025	ORTAK.KUL.TUTARI	3370,20
DOĞALGAZ FATURASI	11234	TOPLAM TÜKETİM (KWH)	4303,11
TOPLAM ALAN	5670	M2 BAŞINA TÜKETİM	0,76
BİREYSEL ISITMA GİDERLERİ			
GİDER	BİRİM FİYATI	TÜKETİM MİKTARI	TÜKETİM TUTARI
ISITMA BEDELİ	1,83	10	18,27
ORTAK ALAN GİDER BEDELİ	0,59	145	86,19
DAİRE SAYAÇ BİLGİLERİ			
SAYAÇ NO	5172	İLK ENDEKS	37612
SAYAÇ TİPİ	Kalorimetre	SON ENDEKS	37622
OKUMA TARİHİ	1.06.2025	TÜKETİM (KWh)	10
		TÜKETİM TUTARI	18,27

Şekil 10 .Hazırlanmış fatura örneği.

Hazırlanan kullanıcı dostu ara yüz ile kullanıcılar tüm proje boyunca bahsedilen tüm işlemleri kolaylıkla izleyebilmekte ve işleyebilmektedir.

#### 4. Sonuçlar ve Öneriler

Bu çalışma, merkezi ısıtma sistemlerinde kullanılan kalorimetre verilerinin M-Bus haberleşme protokolü aracılığıyla okunmasını ve LabVIEW görsel programlama dili kullanılarak otomatik faturalandırma sürecine bütünleştirilmesi amaçlamıştır.

Geliştirilen yazılım, piyasadaki mevcut ticari çözümlere kıyasla daha düşük maliyetli, esnek, grafik tabanlı ve kullanıcı dostu bir alternatif sunmaktadır. M-Bus protokolü üzerine yapılan çalışmalar genellikle teorik düzeyde olmakla birlikte, bu projede M-Bus haberleşmesi gerçek donanım (Ista LC250) üzerinden uygulamalı olarak gerçekleştirilmiştir. Proje kapsamında sayaçlardan elde edilen veriler yalnızca okunmakla kalmayıp, kullanıcı ara yüzü sayesinde gerçek zamanlı olarak görselleştirilmekte ve kayıt altına alınmaktadır. Ayrıca, geliştirilen sistem modüler bir yapıya sahip olup, farklı sayaç türleri veya protokollerle kolayca bütünleşebilecek şekilde tasarlanmıştır. Bu özellik, sistemin akıllı şehir altyapılarına entegrasyonunu mümkün kılmakta ve enerji yönetimi ile veri toplama süreçlerinde esneklik sağlamaktadır.

Deneysel aşamada, kullanılan donanımlar (kalorimetre, M-Bus dönüştürücü, USB seri adaptör vb.) ve yazılımlar (LabVIEW) ile laboratuvar ortamında başarılı bir şekilde veri okuma, dönüştürme ve faturalandırma işlemleri gerçekleştirilmiştir. Özellikle kablolu veri aktarım yöntemi tercih edilerek, bodrum katlar gibi zorlu elektromanyetik koşullara sahip alanlarda sistemin kararlılığı test edilmiştir. Üç sayaç üzerinden yapılan bu uygulama, geliştirilen sistemin doğru çalıştığını ve hedeflenen tüm fonksiyonları başarıyla yerine getirebildiğini göstermiştir.

LabVIEW yazılımı sayesinde oluşturulan kullanıcı dostu ara yüz, görsel programlamanın sağladığı kolaylıklarla hata tespiti ve müdahale süreçlerini önemli ölçüde hızlandırmıştır. Kablolu haberleşme yöntemlerinin kullanılması, elektromanyetik parazit gibi olumsuz dış etkenlerin etkisini azaltmayı hedeflemiş ve sistemin zorlu çevre koşullarındaki performansının gözlemlenmesini sağlamıştır. Ayrıca, dönüştürücü ve sayaç cihazlarının piyasadaki en temel modellerden seçilmesi, sistemin toplam maliyetini düşürmeye katkıda bulunmuştur. Excel ile sağlanan veri aktarımı ise fatura çıktılarının dijital ortama kolayca bütünleşmesini mümkün kılmıştır.

Gelecek çalışmalarda sistemin performansı ve kararlılığı, maksimum sayaç kapasitesine çıkarılarak test edilebilir. Mevcut durumda yerel bağlantı ile çalışan sistem, GPRS, Wi-Fi veya LoRa gibi kablosuz iletişim protokollerinin bütünleştirilmesi uzaktan erişilebilir hale getirilebilir. Ayrıca, kullanıcıların geçmiş fatura dökümlerini takip edebilecekleri ve pil bitmesi, kablo kopması gibi veri okunamayan durumlarda alarm bildirimleri alabilecekleri mobil bir uygulama geliştirilmesi faydalı olacaktır.

Günümüzün gelişen teknolojileri olan yapay zekâ ve makine öğrenimi alanında çalışma yapan araştırmacılar için, bu veriler üzerinde kullanım tahminleri yaparak enerji tasarrufu yöntemleri geliştirme potansiyeli bulunmaktadır. M-Bus protokolünün mevcut temel güvenlik seviyesi göz önüne alındığında, şifreleme ve kimlik doğrulama gibi ileri güvenlik donanımlarının programa bütünleştirilmesi sistemin güvenliğini artıracaktır.

Sonuç olarak, bu çalışma ile M-Bus haberleşme protokolü kullanılarak geliştirilen otomatik faturalandırma yazılımı hem teknik uygulanabilirliğini hem de merkezi ısıtma sistemlerindeki sektörel ihtiyaçlara cevap verebilme potansiyelini ortaya koymuştur. Geliştirilen sistemin özgün, ekonomik ve geliştirilmeye açık yapısı, benzer projelerde referans olarak kullanılmasını mümkün kılmaktadır. Bu çalışmanın, gelecekte yapılacak araştırmalara ve sektörel uygulamalara önemli katkılar sağlayacağı değerlendirilmektedir.

#### Kaynaklar

- [1] International Energy Agency (IEA). Energy Efficiency in Buildings. Paris: IEA, 2022.
- [2] Türkiye Cumhuriyeti Resmî Gazete. 5627 Sayılı Enerji Verimliliği Kanunu. Resmî Gazete, 02.05.2007, Sayı: 26510.
- [3] Mukul MJ. Design of a graphical user interface for home energy monitoring system. MSc, Aalto University School of Science and Technology, Espoo, Finland, 2010.
- [4] Ahmed T, Miah M, Islam MM, Uddin M. Automatic electric meter reading system: A cost-feasible alternative approach in meter reading for Bangladesh perspective using low-cost digital wattmeter and WiMAX technology. Int J Eng Technol 2011; 8: 1-8.
- [5] Karaman B, Taşkın S, Tokay M. Gerçek zamanlı enerji izleme ve tüketici farkındalığı için LabVIEW™ programı ile otomatik sayaç okuma. J Energy Syst 2021; 33(2): 225-232.
- [6] Gajda G, Retkowski B. Nesnelerin interneti çağında akıllı M-Bus iletişimi. IFAC-PapersOnLine 2018; 51(6): 169-174.

- [7] Zhou Y, ve diğerleri. AI-based anomaly detection in smart metering systems. *IEEE Trans Smart Grid* 2023; 14(2): 1450-1462.
- [8] Karaca B. Tüketim sayaçlarında M-BUS standartlarının uygulanmasının geleneksel metotlara göre avantajları. Yüksek Lisans Tezi, Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye, 2023.
- [9] European Commission. Directive (EU) 2023/1791 on energy efficiency and smart metering rollout. *Official Journal of the European Union*, L 231, 22.09.2023.
- [10] Türk Standartları Enstitüsü. TS EN 13757-4:2023 – Wireless M-Bus implementation guidelines. Ankara: TSE, 2023.
- [11] International Organization for Standardization (ISO). ISO/IEC 14908-1:2012 – Communication protocol for local area control networks. Geneva: ISO, 2012.
- [12] Jiang MC, Chen JC, Liu YW. WLAN-centric authentication in integrated GPRS-WLAN networks. In: *IEEE Vehicular Technology Conference*; 6-9 Oct 2003; Orlando, FL, USA. New York, NY, USA: IEEE. pp. 2242-2246.
- [13] Şahin H. Elektronik sayaçlarda kullanılmak üzere uzaktan GPRS modül ile elektronik elektrik sayacı okuma uygulaması. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, Türkiye, 2007.
- [14] Türk Standartları Enstitüsü. TS EN 13757-2: Ölçü aletlerinde haberleşme sistemleri ve uzaktan okuma standardı – Bölüm 2: Fiziksel ve bağlantı hat katmanı. Ankara: TSE, 2005.
- [15] Türk Standartları Enstitüsü. TS EN 13757-3: Ölçü aletlerinde haberleşme sistemleri ve uzaktan okuma standardı – Bölüm 3: Tahsisli uygulama katmanı. Ankara: TSE, 2005.
- [16] M-Bus Association. M-Bus documentation. Erişim Tarihi: 2024. Erişim adresi: <https://m-bus.com/documentation>
- [17] Şentürk Z, Cebeci KR. LabVIEW denetimli Peltierli ortam soğutucusu. Lisans Bitirme Çalışması, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye, 2011.



## Sosyal Medya İçeriklerinde Toksik Dilin Tespitine Yönelik Hibrit Derin Öğrenme Modeli

Anıl UTKU<sup>1\*</sup>

<sup>1</sup> Bilgisayar Mühendisliği, Mühendislik Fakültesi, Munzur Üniversitesi, Tunceli, Türkiye

\*<sup>1</sup>anilutku@munzur.edu.tr

(Geliş/Received: 21/12/2025;

Kabul/Accepted: 15/03/2026)

**Öz:** Bu çalışmada, sosyal medya platformlarında yer alan toksik içeriklerin otomatik olarak tespit edilmesi amacıyla klasik makine öğrenmesi yöntemleri, derin öğrenme tabanlı modeller ve CNN-BiLSTM hibrit mimarisi karşılaştırmalı olarak ele alınmıştır. Deneysel analizler, kısa ve gürültülü metinlerden oluşan ve belirgin sınıf dengesizliği içeren Twitter veri seti üzerinde gerçekleştirilmiştir. LR, NB ve SVM gibi klasik yöntemler ile LSTM, BiLSTM ve CNN-BiLSTM hibrit modeli aynı eğitim-test bölme stratejisi altında değerlendirilmiştir. Model performansları doğruluk, kesinlik, duyarlılık ve F-skor metrikleri kullanılarak analiz edilmiştir. Deneysel sonuçlar, klasik makine öğrenmesi modellerinin toksik olmayan sınıf üzerinde yüksek doğruluk sağlarken, azınlık sınıf olan toksik içeriklerin tespitinde sınırlı kaldığını göstermektedir. Derin öğrenme tabanlı modellerin bağlamsal bağımlılıkları öğrenme yetenekleri sayesinde daha dengeli sonuçlar ürettiği gözlemlenmiştir. Önerilen CNN-BiLSTM hibrit modelinin ise yerel ve bağlamsal özellikleri birlikte ele alarak tüm modeller arasında en yüksek ve en dengeli performansı sağladığı ortaya konulmuştur.

**Anahtar kelimeler:** Toksik dil tespiti, metin sınıflandırma, derin öğrenme, doğal dil işleme.

### A Hybrid Deep Learning Model for Detecting Toxic Language in Social Media Content

**Abstract:** This study comparatively examines classical machine learning methods, deep learning-based models, and a CNN-BiLSTM hybrid architecture for the automatic detection of toxic content on social media platforms. Experimental analyses were conducted on a Twitter dataset consisting of short, noisy texts with significant class imbalance. Classical methods such as LR, NB, and SVM, along with LSTM, BiLSTM, and the CNN-BiLSTM hybrid model, were evaluated under the same training-test split strategy. Model performances were analyzed using accuracy, precision, sensitivity, and F-score metrics. Experimental results show that while classical machine learning models achieve high accuracy on the non-toxic class, they are limited in detecting the minority toxic class. Deep learning-based models were observed to produce more stable results because they can learn contextual dependencies. The proposed CNN-BiLSTM hybrid model achieved the highest and most stable performance among all models, balancing local and contextual features.

**Keywords:** Toxic language detection, text classification, deep learning, natural language processing.

### 1. Giriş

Sosyal medya platformlarının yaygınlaşmasıyla birlikte, kullanıcılar tarafından üretilen içerik miktarı her geçen gün artmaktadır [1]. Twitter (X) gibi mikroblog tabanlı platformlar, bireylerin düşüncelerini kısa ve anlık metinler aracılığıyla paylaşmasına olanak tanıırken, aynı zamanda nefret söylemi, hakaret, tehdit ve toksik içeriklerin de hızla yayılmasına zemin hazırlamaktadır [2]. Bu tür içerikler, bireyler üzerinde psikolojik olarak olumsuz etkilere yol açabildiği gibi, toplumsal kutuplaşmayı artıran bir faktör haline de gelmiştir. Bu nedenle, sosyal medya üzerindeki toksik içeriklerin otomatik olarak tespit edilmesi, hem akademik hem de endüstriyel açıdan önemli bir araştırma konusu olarak öne çıkmaktadır [3]. Toksik içerik tespiti problemi, doğal dil işleme alanında genellikle ikili metin sınıflandırma problemi olarak ele alınmaktadır. Ancak sosyal medya metinlerinin kısa, gürültülü ve bağlamdan kopuk yapısı, argo ifadeler, kısaltmalar, emojiler ve yazım hataları içermesi nedeniyle bu problem oldukça zordur [4]. Geleneksel metin madenciliği yaklaşımları, belirli durumlarda başarılı sonuçlar verse de, dilin bağlamsal yapısını yeterince yakalayamamakta ve karmaşık dil örüntülerini modellemekte sınırlı kalabilmektedir [5].

Literatürde toksik içerik tespiti için hem klasik makine öğrenmesi yöntemleri hem de derin öğrenme tabanlı yaklaşımlar yaygın olarak kullanılmaktadır. TF-IDF gibi özellik çıkarma yöntemleri ile desteklenen Destek Vektör Makineleri (Support Vector Machine-SVM), Lojistik Regresyon (Logistic Regression-LR) ve Naive Bayes (NB) gibi algoritmalar, özellikle kısa metinlerde güçlü ve kararlı performanslar sergileyebilmektedir [6]. Ancak, Uzun

\* Sorumlu yazar: [anilutku@munzur.edu.tr](mailto:anilutku@munzur.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-7240-8713

Kısa Süreli Bellek (Long Short-Term Memory-LSTM) ve Çift Yönlü LSTM (Bidirectional LSTM-BiLSTM) gibi tekrarlı sinir ağları, metin içerisindeki ardışık bağımlılıkları modelleyebilme avantajına sahiptir [7].

Bununla birlikte, literatürde derin öğrenme tabanlı modellerin toksik içerik tespitinde her zaman klasik yöntemleri geride bırakmadığı görülmektedir. Bunun başlıca nedenleri arasında, sosyal medya veri setlerinde yaygın olarak karşılaşılan sınıf dengesizliği, kısa metin uzunlukları ve etiket gürültüsü yer almaktadır [8]. Özellikle toksik içeriklerin azınlık sınıfı oluşturduğu veri setlerinde, derin öğrenme modelleri çoğunluk sınıfına yönelme eğilimi gösterebilmekte ve yüksek doğruluk değerlerine rağmen azınlık sınıfında zayıf performans sergileyebilmektedir [9]. Bu noktada, literatürde tek bir model yapısına bağlı kalmak yerine, farklı yaklaşımların güçlü yönlerini bir araya getiren hibrit model stratejileri ön plana çıkmaktadır. Hibrit modeller, klasik yöntemlerin kararlılığı ile derin öğrenme modellerinin bağlamsal temsil gücünü birleştirerek daha dengeli ve genellebilir çözümler sunmayı amaçlamaktadır [10]. Özellikle metin sınıflandırma problemlerinde, farklı temsil ve öğrenme mekanizmalarının birlikte değerlendirilmesi, model performansını ve yorumlanabilirliği artırabilmektedir [11].

Bu çalışmada, Twitter üzerindeki toksik içeriklerin otomatik olarak tespit edilmesi amacıyla, klasik ve derin öğrenme tabanlı yaklaşımlar ile CNN-BiLSTM hibrit modelinin karşılaştırmalı analizi gerçekleştirilmiştir. TF-IDF tabanlı klasik makine öğrenmesi modelleri ile LSTM ve BiLSTM gibi tekrarlayan sinir ağı tabanlı yöntemlere ek olarak, yerel metinsel örüntülerin çıkarımını ardışık bağımlılıkların modellenmesiyle birleştiren CNN-BiLSTM modeli uygulanmıştır. Tüm modeller, aynı veri bölme stratejisi ve aynı değerlendirme ölçütleri kullanılarak adil bir deneysel ortamda test edilmiştir. Ayrıca, veri setinde mevcut olan sınıf dengesizliğinin model performansı üzerindeki etkileri ayrıntılı biçimde incelenmiş ve karar eşiği optimizasyonu gibi dengesizliğe duyarlı değerlendirme yaklaşımları uygulanmıştır.

Önerilen CNN-BiLSTM modeli, Evrimsel Sinir Ağlarının (Convolutional Neural Network-CNN) n-gram düzeyindeki yerel özellikleri etkili biçimde yakalama yeteneği ile BiLSTM mimarisinin uzun menzilli bağlamsal bağımlılıkları modelleme gücünü bir araya getirmektedir. Bu hibrit yapı sayesinde, sosyal medya metinlerinde sıkça görülen kısa ama anlam yüklü ifade kalıplarının daha zengin bir temsilinin elde edilmesi hedeflenmiştir. Böylece, toksik içerik tespiti problemine yönelik daha dengeli ve kapsamlı bir çözüm çerçevesi sunulmuştur.

Bu çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir:

- Klasik makine öğrenmesi ve derin öğrenme tabanlı modeller ile CNN-BiLSTM hibrit modelinin sistematik bir karşılaştırması sunulmuştur.
- Farklı model türlerinin toksik içerik tespiti problemindeki performansları incelenerek, sosyal medya metinlerinin yapısal özelliklerinin model başarımı üzerindeki etkileri deneysel olarak ortaya konulmuştur.
- Olasılık temelli modeller için karar eşiği optimizasyonunun, toksik içerik tespiti gibi problemlerde model değerlendirmesi üzerindeki rolü vurgulanmıştır.
- Önerilen CNN-BiLSTM hibrit model aracılığıyla, yerel ve bağlamsal özelliklerin birlikte ele alınmasının toksik dil tespitindeki katkısı gösterilmiştir.

## 2. Literatürdeki Çalışmalar

Sosyal medya platformlarında toksik dil, nefret söylemi ve saldırgan içeriklerin otomatik olarak tespit edilmesi, doğal dil işleme alanında uzun süredir üzerinde çalışılan ve giderek önem kazanan bir araştırma konusudur. Literatürdeki çalışmalar incelendiğinde, kullanılan yöntemlerin ve veri setlerinin zaman içerisinde önemli bir evrim geçirdiği görülmektedir. Bu çalışmalar genel olarak klasik makine öğrenmesi tabanlı yaklaşımlar, derin öğrenme tabanlı modeller ve hibrit yapılar olmak üzere üç ana başlık altında toplanabilir.

Toksik içerik tespiti problemi çoğunlukla kelime frekanslarına ve istatistiksel özelliklere dayalı temsiller kullanılarak ele alınmıştır [12]. Davidson ve ark., Twitter verisi üzerinde gerçekleştirdikleri çalışmada, nefret söylemi ile saldırgan ancak nefret içermeyen dil arasındaki ayrımın zorluğuna dikkat çekmiş ve LR ile SVM gibi doğrusal sınıflandırıcıların güçlü bir temel performans sunduğunu göstermiştir [13]. Bu çalışmalar, doğrusal ve istatistiksel temelli modellerin toksik içerik tespitinde güçlü bir başlangıç sunduğunu ancak bağlamsal bağımlılıkları yeterince modelleyemediğini göstermektedir. Bu sınırlılık, çalışmamızda klasik yöntemlerin derin öğrenme tabanlı modellerle karşılaştırılmasının temel motivasyonunu oluşturmaktadır. Benzer şekilde, Wulczyn ve ark. [14], Wikipedia tartışma sayfalarındaki kişisel saldırıları büyük ölçekte analiz ederek, doğrusal modellerin toksik içerik tespitinde etkili olmakla birlikte bağlamsal hatalara açık olduğunu ortaya koymuştur. Bu tür klasik yaklaşımlar, düşük hesaplama maliyetleri ve yorumlanabilirlik avantajlarına sahip olsa da, dilin anlamsal ve bağlamsal yapısını yeterince modelleyememektedir.

Derin öğrenme tabanlı yöntemlerin yaygınlaşmasıyla birlikte, toksik dil tespitinde daha karmaşık ve bağlama duyarlı modeller kullanılmaya başlanmıştır. LSTM mimarisi, Hochreiter ve Schmidhuber tarafından önerilmiş olup, metin içerisindeki uzun menzilli bağımlılıkları öğrenebilme yeteneği sayesinde metin sınıflandırma

problemlerinde yaygın olarak benimsenmiştir [15]. Badjatiya ve ark., tweet'ler üzerinde gerçekleştirdikleri çalışmada, LSTM ve CNN tabanlı modellerin klasik makine öğrenmesi yöntemlerine kıyasla daha yüksek performans elde ettiğini göstermiştir [16]. Bununla birlikte, söz konusu çalışmada da vurgulandığı üzere, sınıf dengesizliği derin öğrenme modellerinin performansını önemli ölçüde etkileyebilmektedir. Elde edilen bu sonuçlar, bağlamsal bilginin toksik dil tespitinde kritik bir rol oynadığını ortaya koymaktadır. Bu bağlamda, çalışmamızda LSTM ve BiLSTM modelleri temel derin öğrenme yaklaşımları olarak ele alınmış ve performansları hibrit yapı ile karşılaştırılmıştır.

Tek yönlü sıralı modellerin sınırlılıklarını aşmak amacıyla geliştirilen BiLSTM, metni hem ileri hem de geri yönde işleyerek daha zengin bağlamsal temsiller elde edilmesini sağlamaktadır [17]. BiLSTM tabanlı modellerin, özellikle bağlamın kritik olduğu toksik dil ve nefret söylemi tespiti problemlerinde daha dengeli sonuçlar ürettiği birçok çalışmada rapor edilmiştir. Ancak yalnızca sıralı bağımlılıklara odaklanan bu modeller, kısa ve gürültülü sosyal medya metinlerinde yerel ayırt edici örüntüleri yakalamakta zaman zaman yetersiz kalabilmektedir.

Bu noktada CNN, metin sınıflandırma problemlerinde yerel n-gram benzeri örüntüleri yakalama yetenekleri sayesinde önemli bir alternatif olarak öne çıkmıştır. CNN tabanlı modellerin kısa metinlerde yüksek performans elde edebildiği görülmüş ve bu yaklaşım sonraki birçok toksik dil tespit çalışmasına temel oluşturmuştur [18]. Ancak CNN modelleri, tek başına kullanıldığında uzun menzilli bağlamsal ilişkileri modellemede sınırlı kalmaktadır.

Son yıllarda, bu sınırlılıkları gidermek amacıyla farklı derin öğrenme mimarilerinin birlikte kullanıldığı hibrit modeller literatürde yaygınlaşmıştır. Zhang ve ark., CNN ve tekrarlı sinir ağlarını bir araya getiren hibrit yapıların, toksik içerik tespitinde hem yerel hem de bağlamsal bilgiyi birlikte değerlendirerek daha dengeli sonuçlar sunduğunu göstermiştir [19]. Hibrit yaklaşımlar, özellikle sınıf dengesizliği bulunan veri setlerinde azınlık sınıf performansını iyileştirme potansiyeli nedeniyle dikkat çekmektedir. Bu çalışmalar, yerel ve bağlamsal özelliklerin birlikte değerlendirilmesinin toksik içerik tespitinde daha dengeli sonuçlar üretebildiğini göstermektedir. Çalışmamızda önerilen CNN-BiLSTM mimarisi, bu yaklaşımdan ilham alınarak tasarlanmıştır.

Öte yandan, Transformer tabanlı modellerin ortaya çıkışıyla birlikte toksik dil tespitinde önemli performans artışları rapor edilmiştir. Devlin ve ark. tarafından önerilen BERT modeli, ön-eğitilmiş bağlamsal temsil gücü sayesinde birçok metin sınıflandırma görevinde üstün başarı sağlamıştır [20]. Ancak bu modellerin yüksek hesaplama maliyetleri ve uygulama karmaşıklığı, özellikle pratik senaryolarda kullanımını sınırlandırabilmektedir. Bu nedenle, daha hafif ve yorumlanabilir hibrit yaklaşımlar hâlen güncelliğini korumaktadır. Transformer tabanlı modellerin yüksek performansına rağmen hesaplama maliyetleri ve uygulama karmaşıklıkları dikkat çekmektedir. Bu nedenle, çalışmamızda daha hafif ve yorumlanabilir bir alternatif olarak hibrit derin öğrenme mimarilerine odaklanılmıştır.

Sonuç olarak, literatürdeki çalışmalar, toksik dil tespitinde tek bir model yapısının her senaryo için yeterli olmadığını ve özellikle kısa, gürültülü ve dengesiz sosyal medya verilerinde yerel ve bağlamsal özelliklerin birlikte ele alınmasının kritik olduğunu ortaya koymaktadır. Bu çalışmada önerilen CNN-BiLSTM hibrit model, literatürde rapor edilen bu bulgular doğrultusunda tasarlanmış olup, klasik ve derin öğrenme tabanlı yaklaşımların güçlü yönlerini bir araya getirerek toksik dil tespitine yönelik daha dengeli ve genellebilir bir çözüm sunmayı amaçlamaktadır.

### 3. Materyal ve Yöntem

Bu bölümde, çalışmada kullanılan veri seti, uygulanan veri ön-işleme adımları, karşılaştırılan sınıflandırma modelleri ve geliştirilen hibrit derin öğrenme mimarisi ayrıntılı olarak açıklanmaktadır. İlk olarak, toksik içerik tespiti amacıyla kullanılan Twitter veri setinin temel özellikleri ve sınıf dağılımı tanıtılmaktadır. Ardından, sosyal medya metinlerinin gürültülü yapısını azaltmaya yönelik uygulanan ön-işleme adımları ile sınıf dengesizliğinin etkisini azaltmak için kullanılan stratejiler sunulmaktadır. Devamında, klasik makine öğrenmesi ve derin öğrenme tabanlı modellerin genel yapıları açıklanmakta ve önerilen CNN-BiLSTM hibrit modelin mimarisi ayrıntılı biçimde ele alınmaktadır. Son olarak, modellerin eğitim sürecinde kullanılan hiperparametreler ve deneysel ayarlar tanımlanmaktadır.

#### 3.1. Veri seti

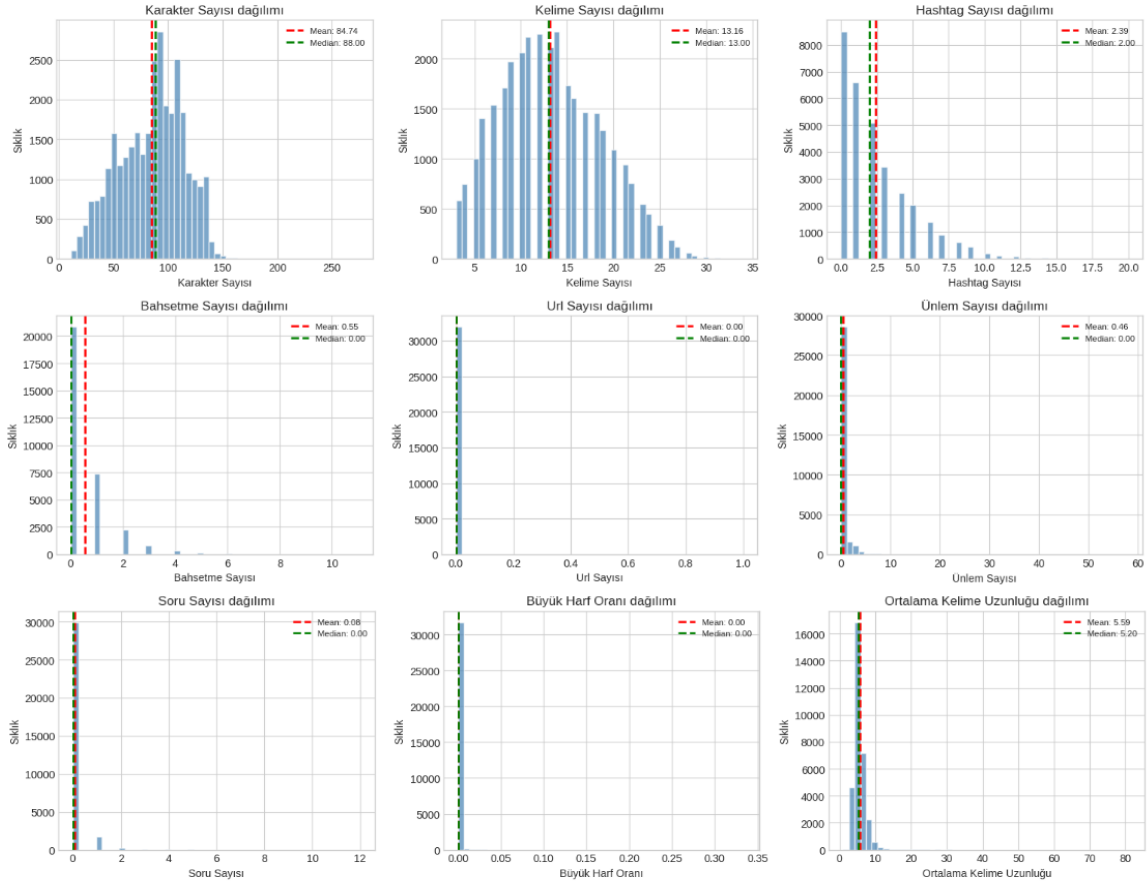
Bu çalışmada, tweetlerdeki toksik içeriklerin tespiti amacıyla oluşturulmuş olan Twitter Toxic Tweets veri seti kullanılmıştır [21]. Veri seti, 31962 adet gerçek tweet'ten oluşmaktadır. Her bir tweet, içerdiği dilin toksik olup olmamasına göre ikili sınıflandırma şeklinde etiketlenmiştir. Veri seti, eksik değer içermemesi ve gerçek sosyal medya dilini yansıtması nedeniyle doğal dil işleme ve makine öğrenmesi tabanlı çalışmalar için uygun bir

yapıya sahiptir. Veri seti id, etiket ve tweet olmak üzere üç temel öznelikten oluşmaktadır. Id, her bir tweet için benzersiz tanımlayıcı değerdir. Etiket 0 toksik olmayan, 1 ise toksik tweet'leri ifade etmek üzere tweet'in toksik olup olmadığını belirten sınıf etiketidir. Tweet ise tweet'in metin içeriğini ifade etmektedir. Tweet, sosyal medya diline özgü olarak kullanıcı etiketleri (@), hashtag'ler (#), URL bağlantıları, emojiler ve özel karakterler içermektedir. Tablo 1'de veri setindeki tweet örnekleri görülmektedir.

**Tablo 1.** Veri setindeki tweet örnekleri

Tweet	Uzunluk	Sınıf
@user when a father is dysfunctional and is s...	102	Toksik değil
@user @user thanks for #lyft credit i can't us...	122	Toksik değil
bihday your majesty	21	Toksik değil
@user #cnn calls #michigan middle school 'buil...	74	Toksik
no comment! in #australia #opkillingbay #se...	101	Toksik
retweet if you agree!	22	Toksik

Twitter veri setinin metinsel yapısını daha ayrıntılı biçimde incelemek amacıyla, tweet'lerin uzunluk ve biçimsel özelliklerine ilişkin çeşitli istatistiksel dağılımlar analiz edilmiştir. Bu kapsamda; karakter ve kelime sayısı, hashtag, bahsetme (@), URL, ünlem ve soru işareti kullanımı ile büyük harf oranı ve ortalama kelime uzunluğu gibi sosyal medya metinlerine özgü dilsel göstergeler hesaplanmıştır. Bu analizler, veri setinin yapısal özelliklerini ortaya koymanın yanı sıra, kullanılan modellerin neden belirli performans davranışları sergilediğini açıklamaya yardımcı olmaktadır. Şekil 1'de, söz konusu özelliklerin dağılımları, ortalama ve medyan değerler ile birlikte sunulmaktadır.



**Şekil 1.** Veri setindeki tweet'lerin uzunluk ve biçimsel özellik dağılımları

Şekil 1’de, tweet’lerin büyük çoğunluğunun kısa metinlerden oluştuğu görülmektedir. Bu dağılımlar, tweet’lerin çoğunlukla kısa ve gürültülü metinlerden oluştuğunu göstermekte olup, klasik kelime frekansına dayalı modellerin sınırlılıklarını ve yerel–bağlamsal özellikleri birlikte ele alan hibrit mimarilere duyulan ihtiyacı desteklemektedir. Karakter sayısının ortalama ve medyan değerlerinin görece düşük olması, Twitter metnlerinin sınırlı uzunluğa sahip olduğunu doğrulamaktadır. Benzer şekilde, kelime sayısı dağılımı da tweet’lerin çoğunlukla az sayıda kelimedenden oluştuğunu göstermekte ve bağlamsal bilginin sınırlı olmasına yol açmaktadır. Hashtag ve bahsetme sayılarının dağılımları, çoğu tweet’te bu öğelerin hiç kullanılmadığını ya da çok sınırlı düzeyde yer aldığını ortaya koymaktadır. URL ve büyük harf oranı dağılımlarında gözlenen yoğunluk, veri setinin büyük bölümünde bağlantı paylaşımı ve tamamen büyük harf kullanımının nadir olduğunu göstermektedir. Ünlem ve soru işareti kullanımı gibi duygu ve vurgu belirteçlerinin az sayıda da olsa belirli tweet’lerde yoğunlaştığı görülmektedir. Ortalama kelime uzunluğu dağılımı, tweet’lerde kullanılan kelimelerin genellikle kısa yapıda olduğunu ve sosyal medya diline özgü kısaltmaların yaygınlığını yansıtmaktadır. Bu bulgular, veri setinin gürültülü ve informel dil yapısını açıkça ortaya koymakta, aynı zamanda kısa metinlerde yerel ve bağlamsal örüntülerin yakalanmasının neden zor olduğunu açıklamaktadır.

Veri setindeki 29720 toksik olmayan tweet ve 2242 toksik tweet bulunmaktadır ve belirgin bir sınıf dengesizliği mevcuttur. Bu dağılım, veri setinin büyük çoğunluğunun toksik olmayan içeriklerden oluştuğunu göstermektedir. Sınıf dengesizliği, özellikle derin öğrenme modellerinin çoğunluk sınıfına yönelmesine ve yalnızca doğruluk metriğine bakıldığında yanıltıcı sonuçlar elde edilmesine neden olabilmektedir. Bu nedenle, veri ön-işleme ve deneysel hazırlık adımlarında sınıf dengesizliğinin etkisini azaltmak amacıyla sınıf oranlarını koruyarak bölme, sınıf ağırlıkları ile dengesizliğe duyarlı eğitim ve karar eşiği optimizasyonu uygulanmıştır.

Sınıf oranlarını koruyarak bölme işleminde, eğitim/doğrulama/test ayrımı yapılırken stratified sampling kullanılmıştır. Böylece her alt kümede sınıf oranları ana veri setine benzer şekilde korunmuş, dengesizliğin bir alt kümede aşırı artması veya azalması engellenmiştir. Bu adım, özellikle doğrulama ve test performansının adil ölçülmesi açısından kritik öneme sahiptir. Sınıf ağırlıkları ile dengesizliğe duyarlı eğitim işleminde, dengesiz sınıflarda modelin azınlık sınıfını öğrenbilmesi için eğitim aşamasında `class_weight` yaklaşımı kullanılmıştır. Bu yöntemde, azınlık sınıfına ait hatalar daha yüksek maliyetle cezalandırılarak modelin toksik sınıfı göz ardı etmesi azaltılmıştır. Sınıf ağırlıkları eğitim verisi üzerinden otomatik hesaplanmış ve model eğitimi sırasında kullanılmıştır. Veri dağılımı değiştirilmeden, kayıp fonksiyonuna azınlık sınıfını daha fazla önemseyen bir ağırlıklandırma eklenmiştir.

Karar eşiği optimizasyonu işleminde ise dengesiz veri setlerinde varsayılan 0.5 karar eşiği çoğu zaman yanıltıcı olup, modelin azınlık sınıfını yeterince yakalayamamasına veya tersine aşırı yanlış pozitif üretmesine neden olabileceği için sigmoid çıktısından elde edilen olasılıklar için karar eşiği doğrulama kümesi üzerinde optimize edilmiştir. Böylece, modelin toksik sınıf performansı yalnızca doğruluk üzerinden değil, F-skor ve duyarlılık gibi daha anlamlı hedeflere göre dengelenmiştir.

Tweet verilerinin gürültülü ve yapılandırılmamış olmaları nedeniyle, model performansını artırmak amacıyla veri ön işleme uygulanmıştır. Tüm metinler küçük harfe dönüştürülmüştür, kullanıcı etiketleri (@kullanıcı) kaldırılmıştır, URL bağlantıları temizlenmiştir, kelime içeriği korunarak hashtag sembolü (#) kaldırılmıştır, noktalama işaretleri ve sayısal karakterler kaldırılmıştır, fazla boşluklar normalize edilmiştir. Bu işlemler sonucunda elde edilen temizlenmiş tweet metinleri, hem klasik makine öğrenmesi hem de derin öğrenme modellerinde giriş verisi olarak kullanılmıştır.

Veri seti, sınıf oranlarını koruyacak şekilde stratified sampling yöntemiyle eğitim, doğrulama ve test kümelerine ayrılmıştır. Toplam verinin %80’i eğitim ve doğrulama, %20’si ise test amacıyla kullanılmıştır. Eğitim kümesinin bir bölümü ayrıca doğrulama verisi olarak ayrılarak hiperparametre ayarlamaları ve karar eşiği optimizasyonu süreçlerinde kullanılmıştır.

### 3.2. Sınıflandırma modelleri

LR, ikili sınıflandırma problemlerinde yaygın olarak kullanılan doğrusal ve olasılıksal bir makine öğrenmesi yöntemidir. LR, giriş özellikleri ile sınıf etiketleri arasındaki ilişkiyi sigmoid fonksiyonu aracılığıyla olasılık temelli olarak öğrenir [22]. Basit yapısı sayesinde yüksek boyutlu ve seyrek veri temsilleri üzerinde etkili sonuçlar üretebilmektedir. Metin sınıflandırma problemlerinde genellikle TF-IDF gibi özellik çıkarım yöntemleriyle birlikte kullanılmaktadır. Yorumlanabilirliği ve düşük hesaplama maliyeti nedeniyle birçok çalışmada temel model olarak tercih edilmektedir [23].

SVM, sınıflar arasındaki ayrımı maksimize eden optimal bir karar sınırı öğrenmeyi amaçlayan güçlü bir sınıflandırma algoritmasıdır [24]. Özellikle yüksek boyutlu özellik uzaylarında genelleme kabiliyeti yüksek performans sergilemektedir. Doğrusal çekirdekli SVM modelleri, metin sınıflandırma problemlerinde yaygın


olarak kullanılmaktadır. Kısa ve seyrek metin temsillerinde karar sınırını etkili biçimde öğrenebilmektedir [25]. Bu özellikleri nedeniyle SVM, doğal dil işleme uygulamalarında sıkça tercih edilen yöntemlerden biridir.

NB, olasılıksal temellere dayanan ve Bayes teoremini kullanan bir sınıflandırma algoritmasıdır. Model, özellikler arasındaki bağımsızlık varsayımına dayanmasına rağmen metin sınıflandırma problemlerinde başarılı sonuçlar verebilmektedir [26]. Kelime frekanslarına dayalı temsillerle birlikte kullanıldığında hızlı ve verimli bir çözüm sunar. Hesaplama maliyetinin düşük olması, büyük veri setlerinde önemli bir avantaj sağlamaktadır. Bu nedenle NB, metin sınıflandırma çalışmalarında yaygın bir referans model olarak kullanılmaktadır [27].

LSTM, tekrarlı sinir ağları ailesine ait bir derin öğrenme mimarisidir. Uzun menzilli bağımlılıkları öğrenebilmek için bellek hücreleri ve kapı mekanizmaları kullanmaktadır [28]. Metin verilerinde kelimeler arasındaki sıralı ilişkileri modelleyerek bağlamsal temsiller oluşturur [29]. Zaman serileri ve doğal dil işleme problemlerinde yaygın olarak uygulanmaktadır. Ancak performansı, veri setinin uzunluğu ve yapısal özelliklerine duyarlıdır. BiLSTM, LSTM mimarisinin genişletilmiş bir versiyonu olup metin dizilerini hem ileri hem de geri yönde işler. Bu sayede bir kelimenin anlamı, hem önceki hem de sonraki bağlam dikkate alınarak öğrenilir [30]. Daha zengin bağlamsal temsiller elde edilmesine olanak tanır. Özellikle dilin bağlama duyarlı olduğu metin sınıflandırma problemlerinde avantaj sağlamaktadır. BiLSTM mimarileri, tek yönlü LSTM modellerine kıyasla daha kapsamlı bağlam bilgisi sunmaktadır.

### 3.3. Geliştirilen hibrit sınıflandırma modeli

Bu çalışmada, tweet'lerin kısa, gürültülü ve bağlamdan kopuk yapısını daha etkili biçimde temsil edebilmek amacıyla CNN-BiLSTM hibrit sınıflandırma modeli geliştirilmiştir. Önerilen mimari, evrimsel sinir ağlarının yerel metinsel örüntüleri yakalama yeteneği ile çift yönlü LSTM yapısının uzun menzilli bağlamsal bağımlılıkları modelleme gücünü bir araya getirmektedir. Geliştirilen hibrit modelin mimarisi Şekil 2'de görülmektedir.



Şekil 2. Geliştirilen hibrit model mimarisi.

Şekil 2'de görüldüğü üzere, önerilen CNN-BiLSTM hibrit model mimarisi, metinlerin ön-işleme adımlarından sonra sırasıyla kelime gömme, evrimsel özellik çıkarımı ve çift yönlü bağlamsal öğrenme aşamalarından oluşmaktadır. Mimari, CNN katmanları ile yerel n-gram düzeyindeki örüntüleri yakalarken, BiLSTM katmanı aracılığıyla uzun menzilli bağlamsal bağımlılıkları modellemekte ve sosyal medya metinlerine özgü kısa ve dengesiz yapıların daha etkili temsil edilmesini sağlamaktadır. Bu aşamada URL'ler, noktalama işaretleri ve özel karakterler kaldırılmakta; tüm metinler küçük harfe dönüştürülmektedir. Bu işlemler, metinlerdeki gürültüyü azaltarak modelin anlamlı örüntülere odaklanmasını sağlamaktadır. Ön-işleme sonrası elde edilen metinler, modelin giriş katmanına aktarılmaktadır.

Hibrit modelin ikinci aşamasında, metinler öğrenilebilir kelime gömme katmanı aracılığıyla yoğun vektör temsillerine dönüştürülmektedir. Bu temsiller, kelimeler arasındaki anlamsal ilişkilerin model tarafından veri odaklı olarak öğrenilmesine olanak tanımaktadır. Elde edilen gömme vektörleri, yerel özellik çıkarımı amacıyla CNN katmanlarına iletilmektedir.

CNN katmanları, farklı filtreler aracılığıyla tweet metinleri içerisindeki n-gram benzeri yerel örüntüleri otomatik olarak öğrenmektedir. Bu aşamada, özellikle kısa metinlerde ayırt edici olan kelime grupları ve ifade kalıpları ön plana çıkarılmaktadır. Evrimsel katmanları takiben uygulanan havuzlama işlemi, en baskın

özelliklerin seçilmesini sağlayarak boyut indirgeme ve gürültü azaltma işlevi görmektedir. Ardından, elde edilen özellik temsilleri tam bağlı katman aracılığıyla birleştirilmektedir.

Modelin son aşamasında, CNN katmanlarından elde edilen özellikler BiLSTM katmanlarına aktarılmaktadır. BiLSTM yapısı, metni hem ileri hem de geri yönde işleyerek bağlamsal bilgiyi daha kapsamlı biçimde öğrenmektedir. Bu sayede, kelimelerin anlamı yalnızca önceki değil, sonraki kelimelerle olan ilişkileri dikkate alınarak değerlendirilmektedir. BiLSTM katmanının çıktısı, sigmoid aktivasyon fonksiyonuna sahip çıktı katmanı aracılığıyla toksik ve toksik değil olmak üzere ikili sınıflandırma kararına dönüştürülmektedir. CNN-BiLSTM hibrit mimarisi, yerel metinsel örüntülerin çıkarımı ile uzun menzilli bağlamsal bağımlılıkların birlikte değerlendirilmesini sağlayarak, sosyal medya metinlerine özgü zorluklara karşı daha dengeli bir temsil sunmayı amaçlamaktadır. Bu yapı, özellikle kısa ve dengesiz metinlerden oluşan veri setlerinde, tek başına kullanılan derin öğrenme modellerine kıyasla daha kapsamlı bir öğrenme çerçevesi sunmaktadır.

Bu çalışmada karşılaştırılan tüm sınıflandırma modelleri, adil ve tutarlı bir değerlendirme ortamı sağlamak amacıyla aynı eğitim-test bölme stratejisi altında eğitilmiştir. Veri seti, sınıf oranları korunacak şekilde %80 eğitim ve %20 test olacak biçimde ayrılmıştır. Eğitim kümesinin %10'u doğrulama amacıyla kullanılmıştır. Model hiperparametreleri, doğrulama verileri üzerinde GridSearch kullanılarak belirlenmiştir.

Derin öğrenme tabanlı modellerin eğitim sürecinde aşırı öğrenmeyi (overfitting) önlemek amacıyla erken durdurma (early stopping) mekanizması kullanılmıştır. Erken durdurma kriteri olarak doğrulama kümesi üzerindeki kayıp (validation loss) izlenmiş ve bu değer 3 ardışık epoch boyunca iyileşmemesi durumunda eğitim süreci sonlandırılmıştır. En düşük doğrulama kaybına karşılık gelen model ağırlıkları geri yüklenerek (restore best weights) test aşamasında kullanılmıştır.

Sınıf dengesizliğinin etkisini azaltmak amacıyla, olasılık temelli modellerde varsayılan 0.5 karar eşiği yerine karar eşiği optimizasyonu uygulanmıştır. Bu kapsamda, sigmoid çıktı katmanından elde edilen olasılıklar doğrulama kümesi üzerinde değerlendirilmiş ve F-skorunu maksimize eden eşik değeri seçilmiştir. Seçilen bu eşik değeri, test kümesi üzerinde tüm performans metriklerinin hesaplanmasında sabit olarak kullanılmıştır.

LR, TF-IDF ile temsil edilen metinler üzerinde doğrusal bir sınıflandırıcı olarak yapılandırılmıştır. Özellik çıkarımı aşamasında unigram ve bigram'ları kapsayacak şekilde TF-IDF temsili kullanılmıştır. Modelin genelleme yeteneğini artırmak amacıyla L2 düzenleme uygulanmış ve sınıf dengesizliği nedeniyle sınıf ağırlıkları dengeli olarak ayarlanmıştır. LR, C=2.0 düzenleme parametresi ile eğitilmiş ve maksimum iterasyon sayısı 2000 olarak belirlenmiştir. SVM, metin sınıflandırma problemlerinde yaygın olarak tercih edilen doğrusal çekirdekli yapı ile kullanılmıştır. TF-IDF temsili üzerinde yüksek boyutlu özellik uzayında etkili bir karar sınırı öğrenmesi hedeflenmiştir. Sınıf dengesizliğinin etkisini azaltmak amacıyla sınıf ağırlıkları dengeli olarak ayarlanmıştır. SVM, C=1.0 parametresi ve squared hinge kayıp fonksiyonu ile eğitilmiş, maksimum iterasyon sayısı 5000 olarak belirlenmiştir. NB, metin sınıflandırmaya uygun olasılıksal bir yaklaşım olarak Multinomial Naive Bayes olarak uygulanmıştır. TF-IDF temsili üzerinde kelime frekanslarının sınıflara katkısı bağımsızlık varsayımı altında değerlendirilmiştir. Modelde smoothing parametresi olarak  $\alpha=0.5$  kullanılmıştır.

LSTM, tweet metinlerinin sıralı yapısını öğrenebilmek amacıyla yapılandırılmıştır. Girdi metinleri, vocab\_size=20000 ve embedding\_dim=128 olacak şekilde öğrenilebilir kelime gömme (embedding) katmanı ile temsil edilmiştir. Maksimum dizi uzunluğu max\_len=100 olarak belirlenmiştir. Modelde 128 gizli birime sahip tek katmanlı bir LSTM kullanılmıştır. Aşırı öğrenmeyi önlemek amacıyla Dropout=0.5 uygulanmıştır. Çıkış katmanı, sigmoid aktivasyon fonksiyonuna sahip tek nöronlu yapıdan oluşmaktadır. LSTM, Adam optimizasyon algoritması ve binary cross-entropy kayıp fonksiyonu ile, batch\_size=64 ve epochs=10 ayarlarıyla eğitilmiştir. Eğitim sürecinde erken durdurma (early stopping) mekanizması kullanılmıştır.

BiLSTM, metin dizilerini hem ileri hem de geri yönde işleyerek bağlamsal bilgiyi daha kapsamlı biçimde öğrenmek amacıyla kullanılmıştır. Model yapısı, LSTM ile aynı girdi ve embedding ayarlarını kullanmaktadır. BiLSTM katmanında 128 gizli birim kullanılmış ve çıktı, tam bağlantılı katman aracılığıyla sigmoid aktivasyon fonksiyonuna sahip ikili sınıflandırma katmanına aktarılmıştır. Dropout oranı 0.5 olarak belirlenmiş ve model Adam optimizasyon algoritması ile eğitilmiştir.

Önerilen CNN-BiLSTM hibrit modelinde, ilk aşamada öğrenilebilir kelime gömme katmanı kullanılarak metinler yoğun vektör temsillerine dönüştürülmüştür. Ardından, yerel n-gram örüntülerini yakalamak amacıyla filters=128 ve kernel\_size=3 olacak şekilde bir boyutlu evrişimsel (Conv1D) katman uygulanmıştır. Evrişimsel katmanın ardından pool\_size=2 değerine sahip maksimum havuzlama (MaxPooling) işlemi gerçekleştirilmiştir. CNN katmanından elde edilen özellikler, 64 gizli birime sahip BiLSTM katmanına aktarılmıştır. Tam bağlantılı katmanda 64 nöron kullanılmış ve Dropout=0.5 uygulanmıştır. Sigmoid aktivasyon fonksiyonuna sahip çıktı katmanı ile sınıflandırma işlemi gerçekleştirilmektedir. Eğitim süreci, Adam optimizasyon algoritması, binary cross-entropy kayıp fonksiyonu, batch\_size=64, epochs=10 ve erken durdurma mekanizması ile yürütülmüştür.

### 3.4. Değerlendirme metrikleri

Bu çalışmada, toksik içerik tespiti problemi ikili sınıflandırma kapsamında ele alınmış ve veri setinde belirgin bir sınıf dengesizliği bulunduğundan, model performansları yalnızca doğruluk (accuracy) metriği üzerinden değerlendirilmemiştir. Bunun yerine, azınlık sınıfın (toksik içerik) başarımını daha doğru yansıtan kesinlik (precision), duyarlılık (recall) ve F-skoru (F-score) değerlendirme metrikleri kullanılmıştır.

Doğruluk, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade etmektedir. Matematiksel olarak, doğru pozitif ve doğru negatif tahminlerin toplamının tüm örneklere oranı şeklinde tanımlanır [31]. Ancak sınıf dengesizliğinin bulunduğu veri setlerinde, doğruluk metriği modelin azınlık sınıf üzerindeki başarımını yeterince yansıtmayabilmektedir [32]. Bu nedenle, doğruluk metriği çalışmada yalnızca tamamlayıcı bir gösterge olarak raporlanmıştır.

Kesinlik, model tarafından toksik olarak sınıflandırılan tweet'lerin ne kadarının gerçekten toksik olduğunu ölçmektedir. Yüksek kesinlik değeri, modelin yanlış pozitif üretme oranının düşük olduğunu göstermektedir. Özellikle yanlış alarm maliyetinin yüksek olduğu senaryolarda kesinlik metriği önemli bir değerlendirme ölçütüdür [33]. Bu çalışmada kesinlik, modelin toksik içerik tespitinde ne derece seçici davrandığını ortaya koymak amacıyla kullanılmıştır.

Duyarlılık, gerçek toksik tweet'lerin ne kadarının model tarafından doğru biçimde tespit edildiğini ifade etmektedir. Azınlık sınıfın tespiti açısından kritik bir metrik olan duyarlılık, modelin toksik içerikleri kaçırma oranını doğrudan yansıtmaktadır. Düşük duyarlılık değeri, modelin önemli miktarda toksik içeriği gözden kaçırdığını göstermektedir [34]. Bu nedenle, sınıf dengesizliği bulunan bu çalışmada duyarlılık metriğine özel önem verilmiştir.

F-skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalaması olup, bu iki ölçüt arasındaki dengeyi değerlendirmektedir. Modelin hem yanlış pozitifleri hem de yanlış negatifleri ne ölçüde kontrol edebildiğini tek bir değerle ifade etmektedir [35]. Özellikle dengesiz veri setlerinde, model performansını daha dengeli biçimde değerlendirmek için sıklıkla tercih edilmektedir. Bu çalışmada F-skoru, modellerin genel sınıflandırma başarımını karşılaştırmada temel metriklerden biri olarak kullanılmıştır.

## 4. Deneysel Sonuçlar

Bu bölümde, toksik içerik tespiti problemi için karşılaştırılan tüm modellerin deneysel sonuçları sunulmaktadır. Modellerin performansları doğruluk, kesinlik, duyarlılık ve F-skoru kullanılarak değerlendirilmiştir. Veri setinde belirgin bir sınıf dengesizliği bulunduğundan, değerlendirme sürecinde yalnızca doğruluk metriğine dayalı yorumlardan kaçınılmış, özellikle azınlık sınıf olan toksik tweet'ler üzerindeki başarımı yansıtan metriklere odaklanılmıştır.

Tüm modeller, aynı eğitim–test bölme stratejisi (%80 eğitim, %20 test) altında eğitilmiş ve test edilmiştir. Böylece, farklı model türleri arasında adil ve tutarlı bir karşılaştırma ortamı sağlanmıştır. Tablo 1’de ve Şekil 3’te, LR, NB ve SVM gibi klasik makine öğrenmesi yöntemleri, LSTM ve BiLSTM gibi derin öğrenme tabanlı modeller ile CNN–BiLSTM hibrit modelinin sınıf bazlı ve ortalama performans sonuçları sunulmaktadır. Veri setinde toksik ve toksik olmayan sınıflar arasında belirgin bir dengesizlik bulunduğundan, çoğunluk sınıfın baskın etkisini azaltmak ve her iki sınıfın performansını eşit biçimde değerlendirebilmek amacıyla makro ortalama değerler kullanılmıştır.

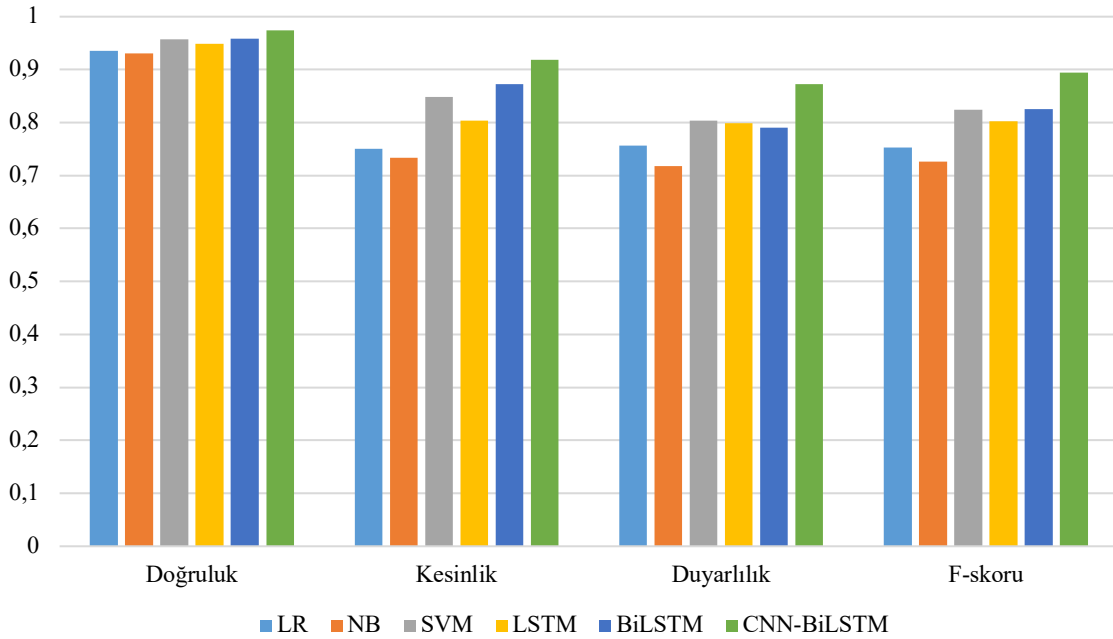
**Tablo 1.** Deneysel sonuçlar.

Model	Sınıf	Doğruluk	Kesinlik	Duyarlılık	F-skoru
LR	Toksik değil	0,935	0,966	0,964	0,965
	Toksik		0,536	0,547	0,541
	Makro ortalama		0,751	0,756	0,753
	Ağırlıklı ortalama		0,936	0,935	0,935
NB	Toksik değil	0,931	0,960	0,966	0,963
	Toksik		0,508	0,471	0,489
	Makro ortalama		0,734	0,718	0,726
	Ağırlıklı ortalama		0,929	0,931	0,930
SVM	Toksik değil	0,957	0,972	0,982	0,977
	Toksik		0,724	0,625	0,671

**Tablo 1.** (Devam) Deneysel sonuçlar.

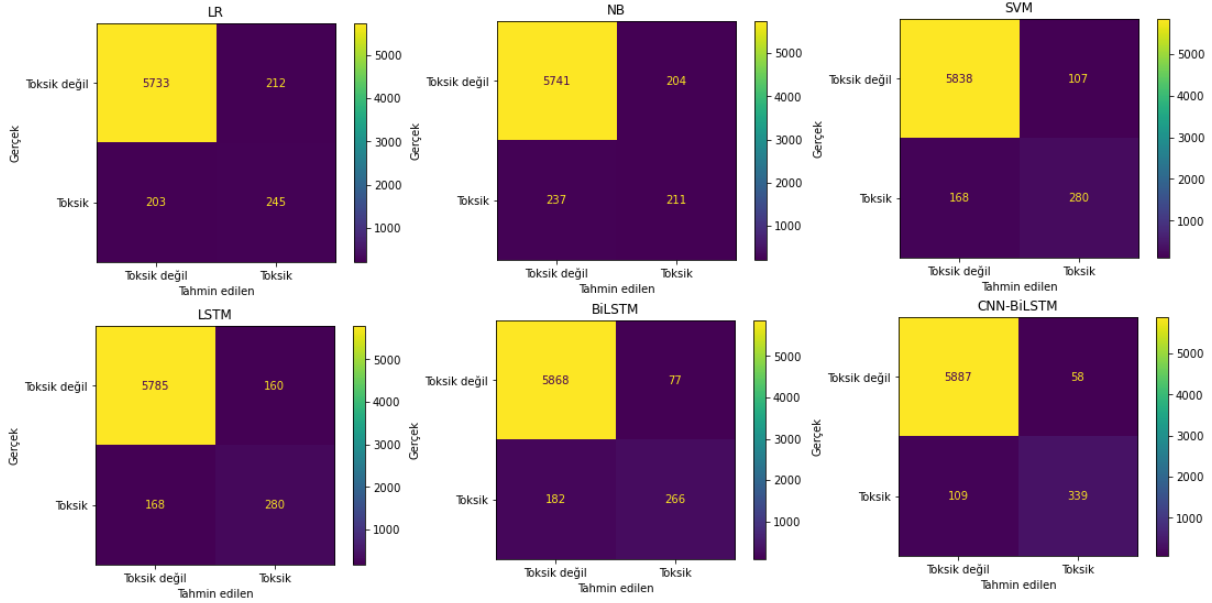
	Makro ortalama		0,848	0,804	0,824
	Ağırlıklı ortalama		0,955	0,957	0,956
LSTM	Toksik değil	0,949	0,972	0,973	0,972
	Toksik		0,636	0,625	0,631
	Makro ortalama		0,804	0,799	0,802
	Ağırlıklı ortalama		0,948	0,949	0,948
BiLSTM	Toksik değil	0,959	0,970	0,987	0,978
	Toksik		0,776	0,594	0,673
	Makro ortalama		0,873	0,790	0,825
	Ağırlıklı ortalama		0,959	0,959	0,957
CNN-BiLSTM	Toksik değil	0,974	0,982	0,990	0,986
	Toksik		0,854	0,757	0,802
	Makro ortalama		0,918	0,873	0,894
	Ağırlıklı ortalama		0,973	0,974	0,973

Tablo 1 ve Şekil 3'te, klasik makine öğrenmesi modelleri ile derin öğrenme tabanlı yaklaşımlar arasında belirgin performans farklılıkları olduğu görülmektedir. LR ve NB, toksik olmayan sınıf üzerinde yüksek doğruluk ve kesinlik değerleri elde etmelerine rağmen, toksik sınıf üzerindeki duyarlılık ve F-skoru değerlerinin görece düşük kaldığı gözlemlenmiştir. Bu durum, söz konusu modellerin sınıf dengesizliğinden etkilenerek çoğunluk sınıfına yönelme eğilimi gösterdiğini ortaya koymaktadır.

**Şekil 3.** Deneysel sonuçlar.

Sınıf dengesizliği nedeniyle, Şekil 3'te sunulan görsel karşılaştırmalarda makro ortalama değerleri tercih edilmiş ve her iki sınıfın performansı eşit ağırlıkta değerlendirilmiştir. Makro ortalama değerler, sınıf dengesizliğinin etkisini azaltarak toksik ve toksik olmayan sınıfların performanslarını eşit ağırlıkta değerlendirmekte ve önerilen CNN-BiLSTM modelinin diğer yaklaşımlara kıyasla daha dengeli sonuçlar ürettiğini ortaya koymaktadır. SVM, klasik yöntemler arasında en dengeli performansı sergileyerek toksik sınıf üzerinde daha yüksek duyarlılık ve F-skoru değerlerine ulaşmıştır. Ayrıca, derin öğrenme tabanlı LSTM ve BiLSTM modellerinin, metin içerisindeki bağlamsal bağımlılıkları öğrenebilme yetenekleri sayesinde toksik sınıf

performansını belirgin biçimde iyileştirdiği görülmektedir. Özellikle BiLSTM, ileri ve geri bağlam bilgisini birlikte kullanarak LSTM'e kıyasla daha dengeli sonuçlar üretmiştir.



Şekil 4. Karışıklık matrisleri

Karışıklık matrisleri, özellikle toksik sınıfa ait yanlış negatif örneklerin CNN-BiLSTM hibrit modelinde belirgin biçimde azaldığını ve karar eşiği optimizasyonunun azınlık sınıf performansına olumlu katkı sağladığını göstermektedir. CNN-BiLSTM hibrit model MizanpaçFen

Dinin ise tüm modeller arasında en yüksek performansı sağladığı dikkat çekmektedir. Hibrit yapı, CNN katmanlarının yerel metinsel örüntüleri yakalama yeteneği ile BiLSTM mimarisinin uzun menzilli bağlamsal bağımlılıkları modelleme gücünü birleştirerek, hem toksik hem de toksik olmayan sınıflarda yüksek başarı elde etmiştir. Özellikle makro ve ağırlıklı ortalama F-skoru değerlerinde gözlenen artış, önerilen modelin sınıf dengesizliğine rağmen daha dengeli ve genellenebilir bir sınıflandırma performansı sunduğunu göstermektedir. Şekil 4'te her bir modelin karışıklık matrisleri görülmektedir.

Karışıklık matrisleri incelendiğinde, özellikle derin öğrenme tabanlı modellerde toksik sınıfa ait yanlış negatif örneklerin görece düşük olduğu görülmektedir. Bu durum, karar eşiği optimizasyonunun azınlık sınıf performansı üzerindeki olumlu etkisini açıkça ortaya koymaktadır. Varsayılan karar eşiği yerine doğrulama kümesi üzerinde optimize edilen eşik değerleri sayesinde, toksik içeriklerin tespitinde daha dengeli bir duyarlılık-keskinlik dengesi elde edilmiştir. Şekil 4'te sunulan karışıklık matrisleri, modellerin sınıf bazlı davranışlarını daha ayrıntılı biçimde ortaya koymaktadır. Özellikle klasik makine öğrenmesi modellerinin toksik olmayan sınıfta yüksek doğru sınıflandırma oranlarına sahip olduğu, ancak toksik sınıfta yanlış negatiflerin arttığı görülmektedir. Buna karşılık, derin öğrenme tabanlı modellerin ve özellikle CNN-BiLSTM hibrit yapısının toksik sınıf üzerindeki doğru tespit oranını belirgin biçimde artırdığı dikkat çekmektedir.

## 5. Sonuçlar

Bu çalışmada, sosyal medya içeriklerinde toksik dilin otomatik olarak tespit edilmesi amacıyla klasik makine öğrenmesi yöntemleri, derin öğrenme tabanlı modeller ve CNN-BiLSTM hibrit mimarisi karşılaştırmalı olarak değerlendirilmiştir. Deneysel sonuçlar, sınıf dengesizliği içeren ve kısa metinlerden oluşan Twitter veri setinde, klasik yöntemlerin çoğunluk sınıf üzerinde yüksek doğruluk sağlarken azınlık sınıf olan toksik içeriklerin tespitinde sınırlı kaldığını göstermektedir. Derin öğrenme tabanlı LSTM ve BiLSTM modelleri, bağlamsal bağımlılıkları öğrenme yetenekleri sayesinde bu sınırlılığı kısmen azaltmıştır.

Önerilen CNN-BiLSTM hibrit modelinin ise tüm modeller arasında en dengeli ve en yüksek performansı sunduğu görülmüştür. CNN katmanlarının yerel n-gram düzeyindeki ayırt edici örüntüleri yakalama yeteneği ile BiLSTM yapısının uzun menzilli bağlamsal bağımlılıkları modelleme gücünün birlikte kullanılması, özellikle

azınlık sınıf performansında belirgin bir iyileşme sağlamıştır. Elde edilen bulgular, sosyal medya metinleri gibi kısa ve gürültülü veri yapılarında tek bir öğrenme mekanizması yerine tamamlayıcı mimarilerin birlikte kullanılmasının önemini ortaya koymaktadır.

DeneySEL sonuçlar, hibrit yaklaşımların toksik dil tespiti probleminde daha dengeli ve genellenebilir çözümler sunduğunu göstermektedir. Gelecek çalışmalarda, farklı diller ve platformlara ait veri setlerinin kullanılması, transformer tabanlı modellerle hibrit yapıların karşılaştırılması ve maliyet-duyarlı öğrenme stratejilerinin entegrasyonu ile bu yaklaşımın kapsamının genişletilmesi planlanmaktadır.

### Kaynaklar

- [1] Santos, M. L. B. D. The “so-called” UGC: an updated definition of user-generated content in the age of social media. *Online Inf Rev* 2022; 46 (1), 95-113.
- [2] Canbay, P., Ekinci, E. (2023). Derin ve Sığ Makine Öğrenmesi Yöntemleri ile Türkçe Tweetlerden Saldırgan Dil Tespiti. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* 2023; 16(1), 1-10.
- [3] Sheth, A., Shalin, V. L., Kursuncu, U. Defining and detecting toxicity on social media: context and knowledge are key. *Neurocomputing* 2022; 490, 312-318.
- [4] Khan, J., Ahmad, K., Jagatheesaperumal, S. K., Sohn, K. A. Textual variations in social media text processing applications: challenges, solutions, and trends. *Artif Intell Rev* 2025; 58(3), 89.
- [5] Feuerriegel, S., Maarouf, A., Bär, D., Geissler, D., Schweisthal, J., Pröllochs, N., Van Bavel, J. J. Using natural language processing to analyse text data in behavioural science. *Nat Rev Psychol* 2025; 4(2), 96-111.
- [6] Zhang, L. Features extraction based on Naive Bayes algorithm and TF-IDF for news classification. *PLoS One* 2025; 20(7).
- [7] Das, S., Tariq, A., Santos, T., Kantareddy, S. S., Banerjee, I. Recurrent neural networks (RNNs): architectures, training tricks, and introduction to influential research. *Machine learning for Brain disorders* 2023; 117-138.
- [8] Rupapara, V., Rustam, F., Shahzad, H. F., Mehmood, A., Ashraf, I., Choi, G. S. (2021). Impact of SMOTE on imbalanced text features for toxic comments classification using RVVC model. *IEEE Access* 2021; 9, 78621-78634.
- [9] Abbasi, A., Javed, A. R., Iqbal, F., Kryvinska, N., Jalil, Z. Deep learning for religious and continent-based toxic content detection and classification. *Sci Rep* 2022; 12(1), 17478.
- [10] Ahmed, S. F., Alam, M. S. B., Hassan, M., Rozbu, M. R., Ishtiaq, T., Rafa, N., Gandomi, A. H. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artif Intell Rev* 2023; 56(11), 13521-13617.
- [11] Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., Gao, J. Deep learning--based text classification: a comprehensive review. *ACM comput surv* 2021; 54(3), 1-40.
- [12] Fortuna, P., Nunes, S. A survey on automatic detection of hate speech in text. *Acm Comput Surv* 2018; 51(4), 1-30.
- [13] Davidson, T., Warmley, D., Macy, M., Weber, I. Automated hate speech detection and the problem of offensive language. In *Proceedings of the international AAAI conference on web and social media*; Mayıs 2017; Montreal, Canada. 512-515.
- [14] Wulczyn, E., Thain, N., Dixon, L. Ex machina: Personal attacks seen at scale. In *Proceedings of the 26th international conference on world wide web*; Nisan 2017; Perth Australia. 1391-1399.
- [15] Hochreiter, S., Schmidhuber, J. Long short-term memory. *Neural comput* 1997; 9(8), 1735-1780.
- [16] Badjatiya, P., Gupta, S., Gupta, M., Varma, V. Deep learning for hate speech detection in tweets. In *Proceedings of the 26th international conference on World Wide Web companion*; Nisan 2017; Perth Australia. 759-760.
- [17] Schuster, M., Paliwal, K. K. Bidirectional recurrent neural networks. *IEEE Trans Signal Process* 1997; 45(11), 2673-2681.
- [18] Hassan, A., Mahmood, A. Convolutional recurrent deep learning model for sentence classification. *IEEE Acc* 2018; 6, 13949-13957.
- [19] Zhang, Z., Robinson, D., Tepper, J. Detecting hate speech on twitter using a convolution-gru based deep neural network. In *European semantic web conference*; Haziran 2018; Crete, Greece. 745-760.
- [20] Devlin, J., Chang, M. W., Lee, K., Toutanova, K. Bert: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language Technologies*; Haziran 2019; Minneapolis, Minnesota. 4171-4186.
- [21] Kayaardı, Ümit. 2020. Twitter Toxic Tweets Dataset. Kaggle. <https://www.kaggle.com/datasets/umitka/twitter-toxic-tweets/data> (Erişim Tarihi: 10.10.2025)
- [22] Graf, R., Zeldovich, M., Friedrich, S. Comparing linear discriminant analysis and supervised learning algorithms for binary classification—A method comparison study. *Biometrical Journal* 2024; 66(1), 2200098.
- [23] Xiang, L. Application of an Improved TF-IDF Method in Literary Text Classification. *Adv Multimed* 2022; 2022(1), 9285324.
- [24] Valkenborg, D., Rousseau, A. J., Geubbelmans, M., Burzykowski, T. Support vector machines. *Am J Orthod Dentofacial Orthop* 2023; 164(5), 754-757.
- [25] Gasparetto, A., Marcuzzo, M., Zangari, A., Albarelli, A. (2022). A survey on text classification algorithms: From text to predictions. *Information*, 13(2), 83.
- [26] Kumar, R., Goswami, B., Mhatre, S. M., Agrawal, S. Naive bayes in focus: a thorough examination of its algorithmic foundations and use cases. *Int. J. Innov. Sci. Res. Technol* 2024; 9(5), 2078-2081.
- [27] Palanivinaayagam, A., El-Bayeh, C. Z., Damaševičius, R. Twenty years of machine-learning-based text classification: A systematic review. *Algorithms* 2023; 16(5), 236.

- [28] Krichen, M., Mihoub, A. Long short-term memory networks: A comprehensive survey. *AI* 2025; 6(9), 215.
- [29] Naik, D., Jaidhar, C. D. A novel Multi-Layer Attention Framework for visual description prediction using bidirectional LSTM. *J of Big Data* 2022; 9(1), 104.
- [30] Kowsher, M., Tahabilder, A., Sanjid, M. Z. I., Prottasha, N. J., Uddin, M. S., Hossain, M. A., Jilani, M. A. K. LSTM-ANN & BiLSTM-ANN: Hybrid deep learning models for enhanced classification accuracy. *Proc Comp Sci* 2021; 193, 131-140.
- [31] Utku, A., Kaya, M., Canbay, Y. A New Hybrid ConvViT Model for Dangerous Farm Insect Detection. *App Sci* 2025; 15(5), 2518.
- [32] Kaya, Y., Yiner, Z., Kaya, M., & Kuncan, F. A new approach to COVID-19 detection from X-ray images using angle transformation with GoogleNet and LSTM. *Measurement Science and Technology* 2022; 33(12), 124011.
- [33] Obi, J. C. A comparative study of several classification metrics and their performances on data. *World J. Adv. Eng. Technol. Sci* 2023; 8(1), 308-314.
- [34] Abbasi, A., Javed, A. R., Iqbal, F., Kryvinska, N., Jalil, Z. Deep learning for religious and continent-based toxic content detection and classification. *Sci Rep* 2022; 12(1), 17478.
- [35] Utku, A. Dental radyografi görüntülerinin sınıflandırılmasına yönelik hibrit ConvViT modeli. *J Fac Eng Archit Gazi Univ* 2025; 40(3), 2071-2086.

## YOLO ile Tarımsal Ürün ve Yabani Bitki Sınıflandırması: Yeni Bir Veri Seti ve Farklı Stratejilerin Tespit Başarılarının Karşılaştırılması

Yunus YAMAN<sup>1\*</sup>, Yusuf DEMİR<sup>2</sup>, Yavuz CANBAY<sup>3</sup>

<sup>1,2,3</sup> Bilgisayar Mühendisliği, Mühendislik ve Mimarlık Fakültesi, Sütçü İmam Üniversitesi, Kahramanmaraş, Türkiye

<sup>\*1</sup> yunusyaman0110@gmail.com, <sup>2</sup> yd36473@gmail.com, <sup>3</sup> yavuzcanbay@ksu.edu.tr

(Geliş/Received: 25/12/2025;

Kabul/Accepted: 18/02/2026)

**Öz:** Tarımsal üretimde verimliliği düşüren en önemli faktörlerden biri, kültür bitkileriyle rekabete girerek kaynak tüketimine neden olan yabancı bitkilerdir. Bu bitkilerin erken evrede tespiti ve mücadelesi, sürdürülebilir tarım için kritik öneme sahiptir. Bu çalışmada, tarımsal ürünlerin (elma, havuç, kabak, marul) ve yabancı bitkilerin tespiti amacıyla YOLOv8 tabanlı bir derin öğrenme yaklaşımı sunulmuştur. Çalışmanın özgünlüğü, sadece nesne tespitine değil, aynı zamanda eğitim stratejilerinin performans üzerindeki etkisine odaklanmasında yatmaktadır. Bu kapsamda, sınıfların ayrı ayrı ve toplu olarak eğitildiği iki farklı stratejinin başarımları karşılaştırılmıştır. Ayrıca, çalışma kapsamında toplanan 200 adet özgün görüntü, veri artırma yöntemleriyle 1200 adede çıkarılarak yeni bir veri seti oluşturulmuş ve literatürün kullanımına sunulmuştur. Deneysel sonuçlar, ayrı eğitim stratejisinin sınıflar arası karışıklığı minimize ederek %99,2 mAP değerine ulaştığını, toplu eğitimde ise bu oranın %96,5 seviyesinde gerçekleştiğini göstermiştir. Bulgular, YOLOv8 mimarisinin tarımsal nesne tespitinde yüksek potansiyele sahip olduğunu, ancak karmaşık sahnelerde eğitim stratejisinin başarımlar üzerinde belirleyici bir rol oynadığını ortaya koymaktadır.

**Anahtar kelimeler:** Derin öğrenme, YOLO, yabancı bitki tespiti, tarımsal ürün tespiti

### Agricultural Crop and Wild Plant Classification with YOLO: A New Dataset and Comparison of Detection Success of Different Strategies

**Abstract:** One of the most significant factors reducing productivity in agricultural production is weeds, which compete with cultivated crops and cause excessive consumption of essential resources. Early detection and control of these plants are critical for sustainable agriculture. In this study, a YOLOv8-based deep learning approach is proposed for the detection of agricultural crops (apple, carrot, zucchini, lettuce) and weeds. The originality of the study lies not only in object detection but also in its focus on the impact of training strategies on performance. In this context, the performances of two different strategies—training classes separately and training them collectively—were compared. Additionally, 200 original images collected within the scope of the study were expanded to 1,200 images through data augmentation techniques, forming a new dataset that has been made available to the literature. Experimental results showed that the separate training strategy minimized inter-class confusion and achieved a mAP of 99.2%, whereas the collective training strategy reached 96.5%. The findings demonstrate that the YOLOv8 architecture has high potential for agricultural object detection; however, in complex scenes, the training strategy plays a decisive role in overall performance.

**Keywords:** Deep learning, YOLO, wild plant detection, agricultural crops detection

#### 1. Giriş

Tarım, canlıların temel gereksinimlerinden biri olan beslenme ihtiyacını karşılamak amacıyla gerçekleştirilen zirai faaliyetlerin tümünü kapsar. Tarımsal arazilerde beslenme için gerekli ürünler yetiştirilirken, bu alanlarda bulunan yabancı bitkiler ekinlerle rekabet ederek arazi verimliliğini önemli ölçüde düşürmektedir [1]. Bu bitkiler, tarımsal ürünlerin topraktan alması gereken mineralleri ve suyu kullanarak büyümekte, böylece hem ürün kalitesini hem de miktarını olumsuz yönde etkilemektedir. Arazi verimliliğinin artırılması ve tarımsal sürdürülebilirliğin sağlanması için yabancı otların etkin bir şekilde tespit edilip kontrol altına alınması gerekmektedir [2]. Ancak, geleneksel yöntemlerle yapılan görsel gözlemlerle de yabancı bitkilerin tespiti ve imhası, büyük bir zaman, iş gücü ve maliyet kaybına neden olmakta ve hata payı yüksek süreçler ortaya çıkarmaktadır [3]. Bu gibi zorluklar, tarımsal üretimde teknolojik çözümlerin geliştirilmesini gerekli kılmaktadır.

Son yıllarda yapay zekâ ve derin öğrenme teknolojilerindeki hızlı gelişmeler tarımsal üretimdeki bu tür sorunlara yenilikçi çözümler sunmaya başlamıştır [4]. Özellikle bilgisayarlı görü teknolojileri, görsel verilerden

\* Sorumlu yazar: yunusyaman0110@gmail.com. ORCID Numarası: <sup>1</sup> 0009-0008-2047-3821, <sup>2</sup> 0009-0000-0074-9036, <sup>3</sup> 0000-0003-2316-7893

anamlı bilgiler çıkarmak ve bu bilgileri eyleme dönüştürmek için güçlü araçlar sunmaktadır. Derin öğrenme algoritmaları ve özellikle evrişimsel sinir ağları (CNN), bu tür sistemlerin doğruluğunu ve etkinliğini önemli ölçüde artırmıştır. CNN tabanlı modeller, görüntülerdeki nesnelere tanımlamak sınıflandırmak ve izlemek için etkili bir yapı sunmakta, tarım sektöründe ürün tanıma, yabancı bitki tespiti, hastalık teşhisi ve verim tahmini gibi uygulamalarda kullanılmaktadır [5].

Derin öğrenme yöntemlerinin görüntü işleme üzerindeki etkisinin, özellikle CNN ile daha belirgin hale geldiğini belirtmiştir. Modern derin öğrenme modelleri genellikle yapay sinir ağlarına dayanmakta ve verileri giderek daha soyut ve karmaşık bir temsil düzeyine dönüştürmeyi öğrenmektedir. CNN'ler, görsel imgelemeyi analiz etmek için en yaygın kullanılan derin sinir ağı türüdür ve minimum ön işleme gerektirecek şekilde tasarlanmıştır. Bu özellik, CNN'leri çok yönlü ve çeşitli görevler için uygun hale getirmektedir. Tarımsal uygulamalarda ise bu tür gelişmiş derin öğrenme algoritmaları, verimliliği artırmak ve insan müdahalesini en aza indirmek için önemli bir çözüm sunmaktadır. Nesne tespiti ve sınıflandırma işlemlerinde CNN'in yüksek performansı, modern görüntü işleme projelerinde temel bir yapı taşı olarak kullanılmasını sağlamaktadır. Ayrıca, R-CNN ve benzeri algoritmaların, yüksek doğruluk oranlarını koruyarak işlem süresini kısaltma konusunda büyük avantajlar sunduğu gösterilmiştir [6]. Bu bağlamda, gerçek zamanlı nesne algılama yetenekleriyle öne çıkan YOLO modelleri, tarımsal uygulamalar için etkili bir çözüm sunmaktadır. YOLO modelleri, evrişimsel sinir ağları kullanarak bir görüntüdeki nesnelere hızlı ve doğru bir şekilde tespit edebilmekte, bu özellikleriyle tarımsal uygulamalarda büyük bir avantaj sağlamaktadır [7].

Bu çalışmada, YOLO modellerinden YOLOv8 kullanılarak tarımsal alanlarda yabancı bitki ve tarımsal ürün tespiti için bir sistem geliştirilmiştir. YOLOv8, optimize edilmiş işlem kapasitesi, yüksek doğruluk oranı ve düşük gecikme süresi gibi özellikleriyle dikkat çekmekte olup, gerçek zamanlı uygulamalarda başarıyla kullanılabilen bir altyapı sunmaktadır.

Bu çalışma için 4 tarımsal ürün sınıfı ve 2 yabancı bitki sınıfı içeren 200 dijital görüntüden oluşan bir veri seti hazırlanmıştır. Modelin genelleme yeteneğini geliştirmek için veri artırma yöntemleri uygulanarak veri seti yaklaşık 1200 görüntüye çıkarılmıştır. Modelin eğitimi sırasında, YOLOv8'in temel özellikleri olan hızlı öğrenme ve yüksek doğruluk kapasitelerinden yararlanılmıştır. YOLOv8, farklı veri setlerinde test edilmiş ve özellikle tarımsal görüntülerin karmaşıklığına rağmen yüksek doğruluk değerleri elde etmiştir. Çalışmada, eğitim işlemi her bir sınıfın ayrı ayrı ve tüm sınıflar birlikte olacak şekilde yapılmış ardından elde edilen test sonuçları karşılaştırılmıştır. Bu yöntemle, farklı bitki türlerinin tespitinde model performansının değişimi incelenmiş ve sınıf bazlı ayrıştırmanın modellerin genel başarımına etkisi değerlendirilmiştir.

Sonuç olarak, bu çalışma, tarımsal alanlarda tarımsal ürün ve yabancı bitki tespiti için hem teknolojik hem de operasyonel açıdan yenilikçi bir çözüm sunmaktadır. Bu özellikler, tarımsal üretimde daha verimli, düşük maliyetli ve sürdürülebilir uygulamaların önünü açmaktadır.

Literatürde YOLO mimarilerinin tarımsal problemlere uygulanmasına dair pek çok çalışma bulunmakla birlikte, bu çalışma, modelin öğrenme dinamiklerini farklı eğitim stratejileri üzerinden karşılaştırmasıyla benzerlerinden ayrılmaktadır. Bu kapsamda, çalışmanın literatüre sağladığı başlıca özgün katkılar şunlardır:

- Tarımsal ürün ve yabancı bitkilerin tespiti için sınıf bazlı ayrı eğitim ve toplu (birleşik) eğitim olmak üzere iki farklı strateji kurgulanmış; bu stratejilerin modelin ayırt etme yeteneği üzerindeki etkileri nicel olarak (mAP, F1-skor ve karmaşıklık matrisleri üzerinden) karşılaştırılmıştır.
- Çalışma kapsamında oluşturulan ve literatürdeki benzer veri setlerinden farklı olarak hem laboratuvar hem de yarı-kontrollü ortam görüntülerini içeren veri seti, araştırmacıların kullanımı için açık erişime sunulmuştur.
- Güncel YOLOv8 mimarisi kullanılarak, kısıtlı veri senaryolarında dahi veri artırma teknikleriyle yüksek başarımlar elde edilebileceği deneysel olarak gösterilmiştir.

Bu çalışma, tarımsal otonom sistemler için model geliştirirken hangi eğitim stratejisinin daha verimli olabileceğine dair geliştiricilere rehberlik etmeyi amaçlamaktadır.

## 2. Literatür Özeti

Silva ve arkadaşlarının yaptığı çalışmada insansız hava araçları (İHA) tarafından çekilen görüntüler kullanılarak tarımsal ürünlerdeki yabancı otların tespiti ve segmentasyonu için derin öğrenme tekniklerinin uygulanması ele alınmıştır. YOLOv8n, YOLOv8s, YOLOv8m ve YOLOv8l gibi farklı YOLO modelleri ile Mask R-CNN ve U-Net modellerinin performansı karşılaştırılmıştır. Sonuçlar, YOLOv8s modelinin %97 mAP50, %99,7 hassasiyet ve %99 geri çağırma oranı ile diğer modellere göre daha yüksek bir performans gösterdiğini ortaya koymuştur. Bu çalışma, derin öğrenme modellerinin, iyi etiketlenmiş ve geniş bir veri seti ile eğitildiğinde,

soya fasulyesi ve fasulye gibi ürünlerdeki yabancı otların otomatik olarak tespit edilmesinde ne kadar etkili olabileceğini göstermektedir [8].

Liu ve arkadaşlarının yaptığı çalışmada buğday tarlalarındaki yabancı otların tespiti için Vision Transform (ViT) ve çok ölçekli özellik füzyonuna dayalı bir YOLOv8 modeli olan YOLOv8-MBM önerilmiştir. Geliştirilen modelin doğruluğu %92,7'ye oranında olmakla beraber orijinal YOLOv8s modeline kıyasla, hassasiyet, geri çağırma, mAP1 ve mAP2 sırasıyla %10,6, %8,9, %9,7 ve %9,3 oranında artmıştır. Bu sonuçlar, YOLOv8-MBM modelinin, buğday tarlalarında yabancı ot tespiti için gereksinimleri başarıyla karşıladığını göstermektedir [9].

Yapılan başka bir çalışmada ise tarımda nesne tespiti için YOLO derin öğrenme algoritmasının kullanımı incelenmektedir. YOLO'nun, tek aşamalı bir nesne tespit algoritması olarak, hızı, doğruluğu ve açık kaynaklı olması nedeniyle popüler hale geldiği belirtilmektedir. Tarımda, uzaktan algılama ve İHA teknolojileriyle birlikte YOLO'nun, ürünleri, hastalıkları ve zararlıları sınıflandırmak ve tespit etmek, arazi kullanım haritalaması, çevresel izleme ve yaban hayatı takibi gibi birçok uygulamada kullanıldığı vurgulanmaktadır. Çalışmada, YOLOv4'ün fasulye bitkilerinin İHA ile çekilmiş görüntülerinde küçük nesnelere sayma ve yerini belirlemede %84,8 mAP ve %89 geri çağırma oranıyla yüksek doğruluk gösterdiği; YOLOv5'in ise pirinç yaprağı hastalıklarını tanımlamada %90 hassasiyet oranına ulaştığı belirtilmektedir [10].

Kamilaris ve Prenafeta-Boldú tarafından yapılan çalışmada, tarımsal alanda yapay zekâ uygulamalarının yaygınlaştığını ve özellikle görüntü sınıflandırma, zararlı-yabancı ot tespiti, ürün hastalık tanısı gibi alanlarda derin öğrenmenin yüksek doğruluk sağladığını vurgulamıştır. Ayrıca, bu teknolojilerin geleneksel manuel gözleme kıyasla hem hız hem de maliyet açısından önemli avantajlar sunduğu belirtilmiştir [11].

Baran ve arkadaşları, YOLO algoritmasının tarımsal uygulamalarda kullanımını incelemiştir. Araştırmada YOLO'nun bitki hastalıklarının teşhisi ve ürün sınıflandırma süreçlerinde veri setleri üzerinde eğitim ve test edilerek uygulandığı belirtilmiştir. Kullanılan yüksek çözünürlüklü tarla ve sera görüntülerinde, modelin gerçek zamanlı çalışabilmesi ve %90'ın üzerinde doğruluk oranı elde etmesi vurgulanmıştır. Ayrıca, klasik görüntü işleme tekniklerine kıyasla YOLO'nun çok daha düşük gecikme süresiyle tespit yapabildiği ve geniş çaplı tarım alanlarında akıllı ilaçlama gibi uygulamalara olanak sağladığı aktarılmıştır [12].

Bağcı tarafından yapılan çalışmada, mısır tarlalarında yabancı otların tespiti için YOLOv9 mimarisinin avantajlarını kullanmıştır. Çalışmada, RGB görüntüler ve farklı ışık koşullarında çekilen tarla fotoğrafları kullanılarak modelin eğitildiği, eğitim ve test aşamasında IoU ve mAP gibi performans metriklerinin değerlendirildiği belirtilmiştir. YOLOv9'un hem yabancı ot hem de mısır bitkisi ayırımında %92'ye varan mAP değerleri elde ettiği ve küçük nesne tespiti kabiliyetinin özellikle ön plana çıktığı rapor edilmiştir. Ayrıca model, otomatik ilaçlama robotlarına entegre edilmeye uygun bir hız ve doğruluk sunmuştur [13].

Çiçek 2022 yılında yaptığı çalışmada, şeker pancarı ve ona eşlik eden 12 farklı yabancı ot türü için YOLO modeli ile derin öğrenme tabanlı nesne tespiti yapmıştır. 4234 bitki görüntüsü üzerinde yapılan deneylerde, modelin özellikle küçük alan kaplayan yabancı otları ayırt etmede başarı gösterdiği ve hassasiyet değerlerinin %90'ın üzerine çıktığı kaydedilmiştir [14].

Bir başka çalışmada, Tokat bölgesi buğday üretim alanlarında yabancı ot tespiti için farklı gelişim dönemlerinde çekilmiş görüntüler üzerinde YOLOv4 tabanlı model geliştirmiştir. Çalışmada, eğitim sırasında görüntüler üzerinde tekniklerinin kullanıldığı, modelin F1-score ve Precision değerlerinin yüksek çıktığı vurgulanmıştır. Tespit edilen yabancı ot türlerinin lokalizasyonu, tarla haritalama ve hassas ilaçlama için başarıyla uygulanmıştır. Ayrıca YOLO modeli, klasik SVM ve k-NN gibi yöntemlere kıyasla daha az yanlış pozitif sonuç üretmiştir [15].

Dulkadir ve Gültekin yaptıkları çalışmada, muz meyvesinin olgunluk seviyelerinin tespiti için YOLOv4 ve YOLOv5 gibi farklı derin öğrenme modellerini karşılaştırmıştır. Kullanılan görsel veri setinde, olgunluk seviyeleri renk ve yüzey dokusu temelinde sınıflandırılmış, YOLOv5 modelinin %94'e varan doğrulukla en iyi sonuçları verdiği belirtilmiştir. Model, gerçek zamanlı sınıflandırma yeteneği ile hasat planlamasında otomasyonun önünü açan bir yaklaşım olarak önerilmiştir [16].

Kâhya ve Aslan, gerçek zamanlı zeytin tespiti uygulaması için derin öğrenme algoritmaları kullanmış ve YOLO mimarisini zeytin tanelerinin tespitinde başarıyla uygulamıştır. Model, yüksek çözünürlüklü görüntülerde ürünleri hızlı ve doğru şekilde ayırarak otomatik veri toplama ve verim tahmini çalışmalarına altyapı sağlamıştır. Çalışmada, YOLO algoritmasının özellikle farklı olgunluk evrelerindeki zeytinlerin tespitinde %96 üzerinde doğruluk elde ettiği ve klasik yöntemlere göre daha düşük hata oranıyla çalıştığı vurgulanmıştır. Ayrıca, modelin gerçek zamanlı sistemlerde doğrudan entegre edilebilmesi önemli bir avantaj olarak gösterilmiştir [17].

Tavus ve arkadaşları tarafından gerçekleştirilen çalışmada, tarımsal alanlarda yüksek çözünürlüklü uydu görüntüleri üzerinden ürün tespiti yapılmıştır. YOLO mimarisine benzer nesne tespit ve sınıflandırma yöntemleriyle yapılan analizlerde, tarımsal ürünlerin arazi üzerinde uzamsal dağılımı başarıyla ortaya konmuştur.

Model, farklı sınıfların ayırımında ve ürün değişimlerinin zamansal takibinde %90'ın üzerinde doğruluk ve yüksek sınıflandırma performansı sunmuştur [18].

Altaş ve arkadaşlarının yaptıkları çalışmada, şeker pancarı yaprak leke hastalığının tespiti üzerine yaptıkları çalışmada, uzman gözlemi ile görüntü işleme yönteminin doğruluğunu karşılaştırmış ve yüksek bir uyum elde etmişlerdir. Uzmanın değerlendirmesine göre hastalık şiddeti %50 olarak belirlenen bir yaprakta, geliştirilen görüntü işleme algoritması ile hastalık şiddeti %48 olarak hesaplanmıştır. Bu durum, görüntü işleme yönteminin hastalık şiddetini tespit etmedeki doğruluğunu ve güvenilirliğini ortaya koymaktadır. Görüntü işleme teknikleri, hastalıklı alanları belirlemede kesin sonuçlar sunarak, geleneksel gözlem yöntemlerine kıyasla daha kesin ve nesnel ölçümler sağlamaktadır [19].

Solak ve Altınışık çalışmalarında, görüntü işleme teknikleri kullanılarak ortamda bulunan nesnelerin tespit ve sınıflandırılması için üç aşamalı bir yöntem önermektedir. İlk aşama olan görüntü ön işleme sürecinde, kameradan alınan görüntüler üzerinde filtreleme, grileştirme, ikili resme çevirme ve morfolojik işlemler uygulanarak, görüntülerdeki istenmeyen gürültü ve bozulmalar minimize edilmiştir. Nesne tespiti ve öznitelik çıkarımı aşamasında, ortamda yer alan nesnelere tespit edilmiş ve bu nesnelerin alan, boyut ve konum gibi öznitelikleri çıkarılmıştır [20].


Ajayi ve arkadaşları, YOLOv5 algoritmasının İHA görüntüleriyle tarımsal alanlarda ürün ve yabancı ot ayırımında otomatik olarak kullanılmasını incelemiştir. Çalışmada, YOLOv5'in farklı eğitim döngülerinde performansı test edilmiş ve sınıf ayırımı ile nesne tespiti kabiliyeti değerlendirilmiştir. Model, geniş kapsamlı arazi görüntülerinde hem ana ürünleri hem de farklı yabancı ot türlerini yüksek doğruluk ve hızlı işlem süresiyle başarılı şekilde ayırt edebilmiştir. Sonuçlar, tarımsal görüntülerde YOLOv5'in hassasiyetinin %95'e, genel doğruluğunun ise %94'ün üzerine çıktığını göstermiştir. Araştırma, hassas tarım uygulamaları için modern derin öğrenme tabanlı tespit sistemlerinin etkili biçimde uygulanabileceğini ortaya koymaktadır [21].

Kılıç tarafından yapılan çalışmada, bitki hastalıklarının erken teşhisinin önemini ve bu alanda derin öğrenme yöntemlerinin başarısını ele almıştır. Geleneksel teşhis yöntemlerinin zaman alıcı olması nedeniyle otomatik tespit sistemlerine duyulan ihtiyacın arttığını belirtmiştir. DenseNet201, PlantVillage veri seti üzerinde %99,81 doğruluk ile en yüksek performansı gösterirken, ViT modeli %99,27 doğruluk ile en düşük performansı sergilemiştir. Modellerin karar süreçlerini analiz etmek amacıyla açıklanabilir yapay zekâ (XAI) yöntemleri kullanılarak, modellerin hangi özelliklere dayanarak karar verdikleri görselleştirilmiştir. Çalışma, laboratuvar ortamında elde edilen yüksek doğrulukların, gerçek dünya koşullarında aynı başarıyı göstermeyebileceğini ve XAI yöntemlerinin modellerin karar süreçlerini daha anlaşılır kılmak adına büyük potansiyel taşıdığını vurgulamaktadır [22].

### 3. Materyal ve Metot

#### 3.1. Veri seti

Çalışmada kullanılan veri seti, yüksek çözünürlüklü kamera ile çekilen tarımsal ürün ve yabancı bitki görüntülerinden oluşmaktadır. Görseller, yüksek çözünürlüklü olarak kaydedilmiş ve her sınıf için LabelImg programı kullanılarak etiketlenmiştir. Veri setinde tarımsal ürünlere ait (elma, havuç, kabak, marul) 4 sınıf, yabancı bitkilere ait (yabancı bitki 1 ve yabancı bitki 2) 2 sınıf olmak üzere toplamda 200 adet görüntü mevcut olup, örnek görüntüler Şekil 1'de sunulmuştur. Ayrıca oluşturulan ve bu çalışmada kullanılan veri setine <https://github.com/Yunusyaman/Tarimsal-Arazide-Yabani-Bitki-ve-Urun-Tespiti-icin-Goruntu-Veri-Seti-YOLOv8-> linkinden ulaşılabilir.



Şekil 1. Oluşturulan veri kümesi örnekleri

### 3.2. Yolov8 modeli

Bu çalışmada, tarımsal arazilerdeki yabancı bitkilerin ve tarımsal ürünlerin tespitinde derin öğrenme tabanlı nesne algılama algoritmalarından biri olan ve YOLO mimarisinin en güncel sürümlerinden YOLOv8 modeli kullanılmıştır. YOLO, evrimsel sinir ağları yapısını temel alarak görsellerdeki nesnelere gerçek zamanlı ve yüksek doğrulukla tespit edebilen, nesne algılama alanında öncü bir modeldir. YOLOv8'in tercih edilmesinin temel sebepleri arasında; yüksek doğruluk oranı, düşük gecikme süresi, optimize edilmiş işlem kapasitesi ve hafif yapısı sayesinde farklı donanımlarda verimli çalışabilmesi yer almaktadır.

Tarımsal uygulamalarda özellikle yabancı bitkilerin erken tespiti ve hızlı müdahale gereksinimi, gerçek zamanlı ve yüksek performanslı sistemlerin kullanımını zorunlu kılmaktadır. Bu bağlamda YOLOv8'in sunduğu üstün performans, modelin otonom sistemlerle entegre bir şekilde çalışmasına olanak tanımakta ve tarımsal üretimde verimliliği artırmaya yönelik modern bir çözüm sunmaktadır.

Nitekim literatürde de YOLOv8 mimarisinin farklı alanlarda yüksek başarı sağladığı görülmektedir. Bekçioğulları vd. (2025), farklı YOLO modellerini trafik işareti tespiti üzerinde karşılaştırarak YOLOv8'in gerçek zamanlı uygulamalarda yüksek doğruluk ve hız avantajı sağladığını ortaya koymuştur. Benzer şekilde, Şanver ve Saygılı (2024) tarafından gerçekleştirilen çalışmada, YOLOv8 tabanlı derin öğrenme modeli kullanılarak diyabetik retinopati sınıflandırmasında %84,9 doğruluk oranı elde edilmiş ve modelin tıbbi görüntü analizi alanında da başarılı sonuçlar verdiği gösterilmiştir. Bu çalışmalar, YOLOv8 mimarisinin farklı görsel tanıma problemlerinde yüksek genelleme yeteneğine sahip olduğunu ortaya koymakta ve tarımsal veri analizi için güçlü bir referans oluşturmaktadır.

### 3.3. Değerlendirme metrikleri

#### 3.3.1. Kayıp fonksiyonları

YOLOv8 modelinin eğitimi, tahmin edilen değerler ile gerçek değerler arasındaki hatayı en aza indirmeyi amaçlayan bir birleşik kayıp fonksiyonu tarafından yönlendirilir. Bu fonksiyon üç ana bileşenden oluşur:

- Sınıflandırma Kaybı ( $L_{cls}$ ): Bu bileşen, modelin tespit ettiği nesneyi doğru sınıfa atayıp atamadığını kontrol eder. Yanlış sınıflandırmaları cezalandırır.
- Sınırlayıcı Kutu Kaybı ( $L_{box}$ ): Bu bileşen, modelin tahmin ettiği sınırlayıcı kutunun (bounding box) konumu ve boyutları ile gerçek kutu arasındaki farkı ölçer.
- Dağılım Odaklanma Kaybı ( $L_{dfl}$ ): YOLOv8 gibi modern modellerde yer alan bu kayıp, sınırlayıcı kutu koordinatlarını tek bir değer olarak değil, bir olasılık dağılımı olarak ele alır. Bu sayede modelin, kutu sınırlarının olası konumları hakkında daha esnek ve doğru bir öğrenme süreci geçirmesini sağlar ve yerleştirme hassasiyetini önemli ölçüde artırır.

Bu üç bileşenin ağırlıklı toplamı, modelin optimize etmeye çalıştığı toplam kaybı oluşturur. Toplam lambda değerinin hesaplanması Denklem 1'de verilmiştir.

$$L_{Toplam} = \lambda_{box}L_{box} + \lambda_{cls}L_{cls} + \lambda_{dfl}L_{dfl} \quad (1)$$

Burada  $\lambda$  (lambda) değerleri, her bir kayıp bileşeninin toplam hata üzerindeki etkisini dengeleyen hiper-parametrelerdir.

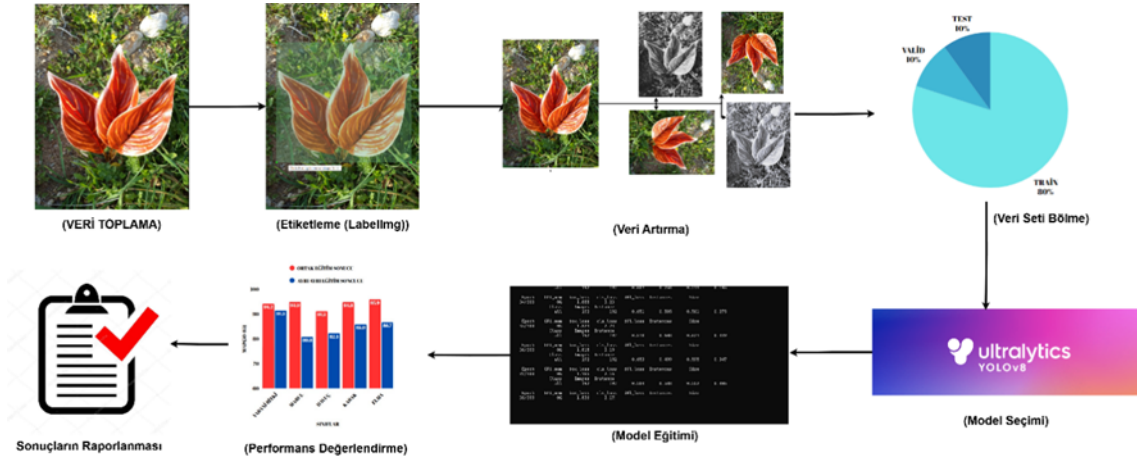
#### 3.3.2. Model performans değerlendirme metrikleri

Modelin eğitim sonrası performansını ölçmek için aşağıdaki standart metrikler ve görselleştirmeler kullanılmıştır:

- mAP: Her sınıf için hesaplanan Ortalama Kesinlik (AP) değerlerinin ortalamasıdır. mAP değeri için gerek hesaplama Denklem 2'de verilmiştir.
- $$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (2)$$
- F1-Güven Eğrisi: Modelin F1 skorunun farklı güven eşiklerine göre nasıl değiştiğini gösteren bir grafikdir. Bu eğri, modelin tahminleri için en uygun güven eşikini bulmaya yardımcı olur.
  - Etiket Korelogramı: Veri setindeki etiketlerin özelliklerinin (örneğin, kutuların x-y konumu, genişliği, yüksekliği) birbirleriyle olan ilişkisini ve dağılımını gösteren bir görselleştirme. Veri setindeki olası yanlışlıkları veya dengesizlikleri anlamak için kullanılır.

### 3.4. Derin öğrenme modeli ve eğitim süreci

Derin öğrenme modellerinin eğitimi için Ultralytics kütüphanesi içerisindeki en güncel modellerden olan YOLOv8n modeli kullanılmıştır. Bu model, YOLO algoritmasının modern bir uygulamasını sunmakta ve kullanıcı dostu bir arayüz sağlamaktadır. Çalışma, yerel bir makinede gerçekleştirilmiştir ve eğitim süreçlerinin yüksek donanım gereksinimleri nedeniyle güçlü bir GPU (NVIDIA RTX 4060) kullanılmıştır. Ultralytics kütüphanesi, Python ortamında yerel olarak kurularak çalıştırılmıştır. Eğitim süreçleri başlamadan önce veri seti kütüphaneye uygun bir formatta yapılandırılmıştır. Her bir sınıfın eğitiminde, YOLOv8n modelinin hiperparametre (öğrenme oranı, epoch sayısı, batch boyutu, vb.) ayarları optimize edilmiştir. Modelin eğitimi sırasında epoch sayısı 300 olarak belirlenmiş ve erken durdurma (early stopping) yöntemi ile aşırı öğrenmenin önüne geçilmiştir. Eğitim sırasında kullanılan öğrenme oranı, başlangıçta 0.001 olarak belirlenmiş ve her epoch'ta doğrulama hatasına göre dinamik olarak ayarlanmıştır. Modelin geliştirilme adımlarını gösteren diyagram Şekil 2'de verilmiştir.



Şekil 2. Model geliştirme ve test adımları.

Derin öğrenme modellerinin başarısı, büyük ölçüde eğitimde kullanılan veri setinin kalitesine ve çeşitliliğine bağlıdır. Bu nedenle, model eğitime geçilmeden önce bir dizi kritik ön işleme adımı gerçekleştirilmiştir. İlk olarak, çalışma kapsamında kullanılacak olan tarımsal ürün ve yabani bitki görselleri yüksek çözünürlüklü kamera cihazları kullanılarak elde edilmiştir. Her bir sınıfa ait nesnelerin model tarafından tanınabilmesi için, LabelImg programı aracılığıyla etiketleme işlemi yapılmıştır. Bu süreç, nesnelerin konumlarının ve sınıf kimliklerinin belirlenmesini sağlamıştır.

Veri setinin sınırlı sayıda örnekten oluşmasının modelin genelleme yeteneğini kısıtlamasını önlemek ve modelin performansını artırmak amacıyla veri artırma teknikleri uygulanmıştır. Bu kapsamda, mevcut görsellere döndürme, ölçeklendirme, parlaklık ve kontrast ayarı, kırpma ve rastgele yatay/dikey çevirme gibi çeşitli dönüşümler uygulanarak veri seti zenginleştirilmiştir. Bu sayede başlangıçta 200 olan görüntü sayısı 1200'e çıkarılmıştır. Son olarak, hazırlanan veri seti, modelin eğitimi, performansının doğrulanması ve nihai başarısının test edilmesi amacıyla standart bir yaklaşımla eğitim (%80), doğrulama (%10) ve test (%10) olmak üzere üç alt kümeye ayrılmıştır.

Eğitim süreci, veri setinin büyüklüğü ve kullanılan modelin karmaşıklığı nedeniyle uzun zaman almıştır. Eğitim sırasında kaydedilen model çıktıları düzenli olarak kontrol edilmiş ve grafiksel olarak analiz edilmiştir. Eğitim sonunda, en iyi performansı gösteren epoch belirlenmiş ve bu model test verisi üzerinde değerlendirilmiştir. Eğitimler sonucunda elde edilen ağırlık dosyaları hazırlanan gerçek zamanlı görüntü işlem kodu ile denenmiştir. Ayrıca eğitimlerin sonucu bulgular kısmında detaylı olarak karşılaştırılmıştır.

## 4. Deneysel Çalışmalar ve Sonuçlar

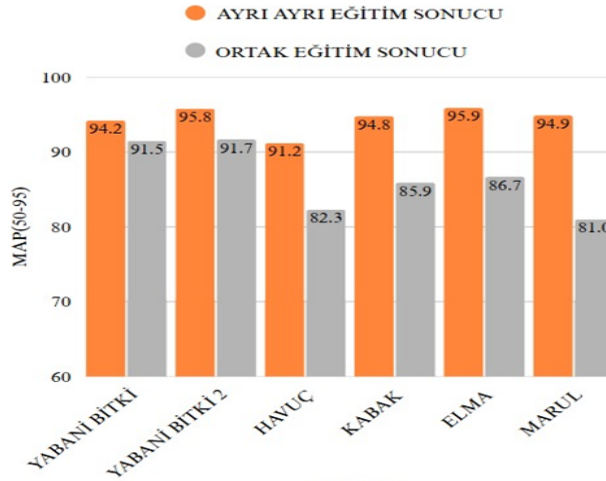
Bu çalışmada, tarımsal ürün ve yabani bitki tespiti amacıyla YOLO derin öğrenme modeli kullanılarak, 4 farklı tarımsal ürün sınıfı (elma, havuç, kabak, marul) ve 2 farklı yabani bitki sınıfı (yabani bitki 1 ve yabani bitki 2) üzerinde eğitim gerçekleştirilmiştir. Modeller iki farklı strateji ile oluşturulmuş, ilk stratejide modeller her bir sınıfa ait veri kümesinde ayrı ayrı eğitilmiş, ikinci stratejide ise tüm sınıfların bir arada yer aldığı birleşik bir veri

kümesi üzerinde eğitilmiştir. Bu süreç, sınıf bazlı eğitim ile birleşik eğitimin performans karşılaştırmasını yaparak, modelin sınıf ayrımına dayalı hassasiyetini ve genelleme kapasitesini incelemeyi amaçlamaktadır.

F1 skoru hem hassasiyet hem de özgüllüğü bir arada değerlendirerek modellerin genel performansını ortaya koymaktadır. Ayrı eğitim yapılan modellerin F1 skoru eğrileri incelendiğinde, eğitim süreci boyunca daha hızlı bir şekilde stabil hale geldiği ve daha yüksek değerlerde sabitlendiği görülmüştür.

- Ayrı eğitimde, sınıflar için ortalama F1 skoru %95,8 olarak kaydedilmişken, toplu eğitimde bu değer %89,7'ye düşmüştür.
- F1 eğrisindeki dalgalanmalar, toplu eğitimde daha belirgin olup, modelin her sınıf için aynı öğrenme hızına sahip olamadığını göstermiştir.

Farklı eğitim stratejilerinin mAP sonuçları Şekil 3'te verilmiştir.



Şekil 3. Ortak eğitim ve ayrı yapılan eğitimlerin mAP sonuç grafiği.

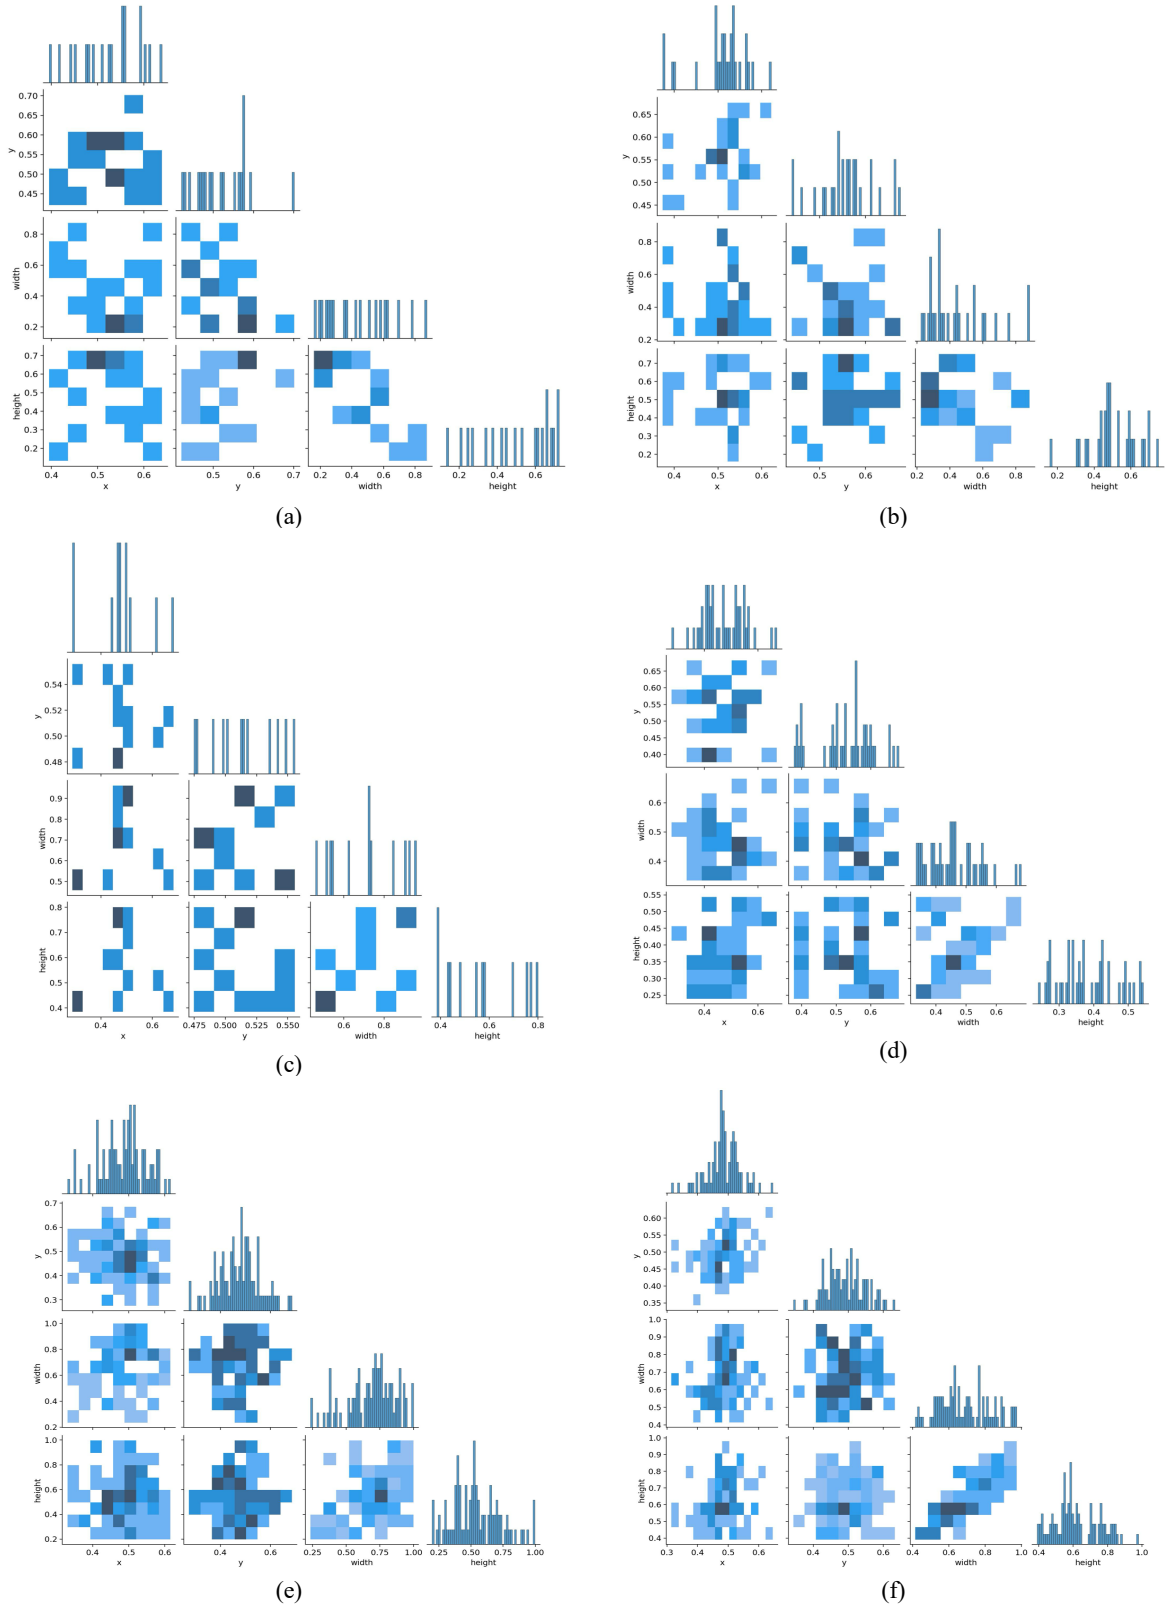
Etiket korelogramı, sınıflar arasındaki görsel benzerliklerin ve bu benzerliklerin modelin performansına etkisinin görselleştirilmesi için kullanılmıştır. Şekil 4'de görüldüğü üzere, ayrı eğitimde, her bir sınıfın bağımsız olarak öğrenmesi sağlandığından, sınıflar arası yanlış ilişkilendirmeler minimum düzeyde kalmıştır. Ancak toplu eğitimde, meyve ve yabani bitki sınıfları arasında örtüşen görsel özellikler nedeniyle yanlış pozitif ve yanlış negatif oranlarının arttığı tespit edilmiştir. Özellikle:

- Tarımsal ürün sınıflarında marul ve elma arasında toplu eğitimde yüksek bir korelasyon (%12,5) görülmüştür.
- Yabani Bitki 1 ile tarımsal ürün sınıfları arasında ayrı eğitimde düşük (%3,2) bir karışıklık oranı tespit edilirken, toplu eğitimde bu oran %10,4'e yükselmiştir.

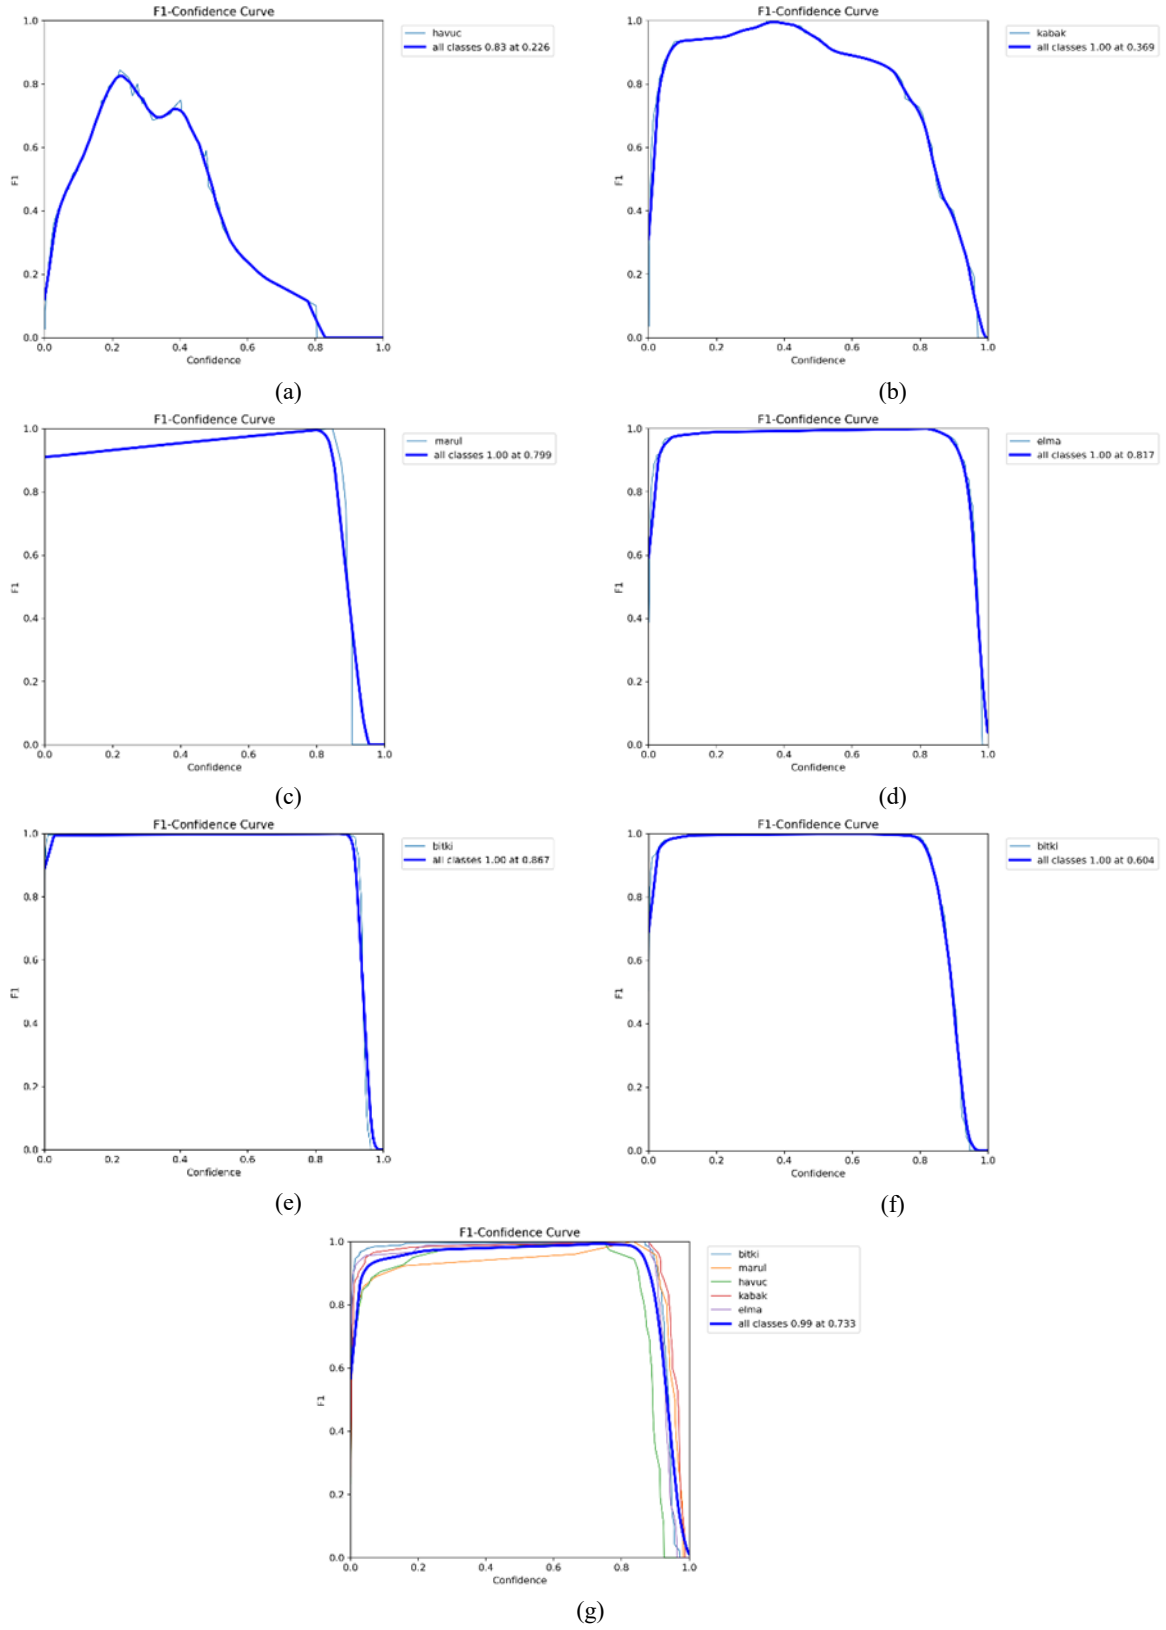
Şekil 5'de ise tüm sınıflara ait F1 güven eğrileri verilmiştir.

Çalışma boyunca elde edilen sonuçlar mAP değeri üzerinden de detaylı olarak incelenmiştir. mAP, modelin genel doğruluğunu ve tahminlerinin kesinliğini değerlendirmek için önemli bir performans göstergesi olarak ele alınmıştır.


- Sınıfları Ayrı Ayrı Eğitime: Ayrı eğitim yapılan modellerde mAP değeri tüm sınıflar için ortalama %99,2 olarak kaydedilmiştir. Bu değer, sınıfların özelliklerinin daha iyi öğrenildiğini ve modelin her sınıfa özgü tahminleri daha yüksek doğrulukla gerçekleştirdiğini göstermektedir.
- Sınıfları Toplu Eğitime: Tüm sınıfların birlikte eğitildiği modellerde mAP değeri ortalama %96,5 seviyesine düşmüştür. Bu düşüş, modelin farklı sınıflar arasında ayırt edici özellikleri öğrenmekte zorlandığını ve bu durumun performans olumsuz yansıdığını ortaya koymaktadır.
- Özellikle yabani bitki sınıflarında, toplu eğitimde modelin performansı ciddi şekilde azalmış, mAP değeri %94 seviyelerine kadar gerilemiştir. Bu durum, yabani bitkilerin görsel olarak meyvelerle benzerlik göstermesi ve toplu eğitimde sınıflar arasında ayırım yapmanın zorlaşmasından kaynaklanmaktadır. Ayrı eğitimde ise yabani bitki sınıfları için mAP değeri %99,9 olarak ölçülmüştür, bu da önemli bir iyileşme olduğunu göstermektedir. Tüm sınıflar için eğitim süreç grafiği Şekil 6'da verilmiştir.



Şekil 4. Sınıflara ait etiket korelogramı (havuç (a), kabak (b), marul (c), elma (d), yabancı bitki-1 (e), yabancı bitki-2 (f)).



Şekil 5. Sınıflara ait F1 güven eğrisi (havuç (a), kabak (b), marul (c), elma (d), yabancı bitki-1 (e), yabancı bitki-2 (f), tüm sınıflar (g)).



Şekil 6. Tüm sınıflar için eğitim süreç grafiği.

## 6. Sonuç

Bu çalışmada, tarımsal arazilerde yabancı bitkilerin ve ürünlerin tespiti amacıyla YOLOv8 mimarisine dayalı bir derin öğrenme yaklaşımı geliştirilmiş ve test edilmiştir. Çalışma kapsamında oluşturulan ve 90 adet yabancı bitki ile 110 adet tarımsal ürün görselinden oluşan özgün veri seti üzerinde gerçekleştirilen deneylerde, mAP50 değeri %99,5, mAP50-95 değerleri ise %91,2 ile %95,9 aralığında kaydedilmiştir. Elde edilen bu sonuçlar, modelin yüksek doğruluk oranlarına sahip olduğunu ve tarımsal otomasyon gibi kritik uygulamalarda etkin bir karar destek sistemi olarak kullanılabilceğini göstermektedir.

Modelin performansı, sınıfların ayrı ayrı ve toplu (birleşik) eğitilmesi senaryoları üzerinden karşılaştırmalı olarak değerlendirilmiştir. Analizler, yabancı bitkiler ve tarımsal ürünlerin ayrı ayrı eğitildiği stratejinin, toplu eğitime kıyasla daha yüksek doğruluk oranları sağladığını ortaya koymuştur. Özellikle sınıflar arası görsel benzerliklerin yoğun olduğu durumlarda, birleşik eğitimin ayırtma gücünü zayıflattığı ve doğruluk değerlerini düşürdüğü gözlemlenmiştir. Bu bulgular, tarımsal nesne tespit problemlerinde veri setinin yapısına uygun eğitim stratejisinin belirlenmesinin önemini vurgulamaktadır.

Deney sonuçları umut verici olmakla birlikte, modelin başarımı sınırlı sayıda (200 adet) özgün görüntüye ve veri artırma tekniklerine dayandığından genellenebilirlik kısıtlılıkları bulunmaktadır. Veri artırma yöntemleri, gerçek tarla koşullarındaki varyasyonları tam olarak temsil edemeyebileceğinden, elde edilen yüksek doğruluk oranları mevcut veri setine özgü değerlendirilmelidir. Gelecek çalışmalarda, modelin genelleme yeteneğini artırmak adına farklı çevresel koşulları içeren daha kapsamlı veri setleriyle testlerin tekrarlanması önerilmektedir. Bunun yanı sıra, geliştirilen sistemin saha uygulamalarındaki etkinliğini artırmak amacıyla, gerçek zamanlı çalışabilen hızlı ve düşük maliyetli donanım entegrasyonu yöntemlerinin araştırılması hedeflenmektedir.

## Kaynaklar

- [1] Şin B, Kadioğlu İ. İnsansız hava aracı (İHA) ve görüntü işleme teknikleri kullanılarak yabancı ot tespitinin yapılması. Turkish Journal of Weed Science, vol. 22, no. 2, pp. 211-217, 2019.
- [2] Günel H, Budak M. Toprak kalitesi ve değerlendirilmesi. IKSAD Yayınevi, 2022.
- [3] Çolak EŞ, Işık D. Yabancı otlar ile mücadelede güncel yöntem: Robotikler. Turkish Journal of Weed Science, vol. 24, no. 2, pp. 166-176, 2021.
- [4] Kavut S. Türkiye’de yapay zekâ alanında yazılan tezlerin içerik analizi yöntemiyle incelenmesi. Türkiye İletişim Araştırmaları Dergisi, no. 41, pp. 80-98, 2022.
- [5] Ağin O, Malaslı MZ. Görüntü işleme tekniklerinin sürdürülebilir tarımdaki yeri ve önemi: Literatür çalışması. Tarım Makinaları Bilimi Dergisi, vol. 12, no. 3, pp. 199-206, 2016.
- [6] Aalami N. Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, vol. 1, no. 1, pp. 17-20, 2020.
- [7] Alemdar KD. Çift sıra parklanma durumunun nesne tespit algoritması YOLOv8 ile tespiti. Journal of the Institute of Science and Technology, vol. 14, no. 3, pp. 1164-1176, 2024.

- [8] Silva J. A. O. S., Siqueira V. S. D., Mesquita M., Vale L. S. R., Marques T. D. N. B., Silva J. L. B. D., Oliveira, H. F. E. D. Deep learning for weed detection and segmentation in agricultural crops using images captured by an unmanned aerial vehicle. *Remote Sensing*, vol. 16, no. 23, p. 4394, 2024.
- [9] Liu Y, Zeng F, Diao H, Zhu J, Ji D, Liao X, Zhao Z. YOLOv8 model for weed detection in wheat fields based on a visual converter and multi-scale feature fusion. *Sensors (Basel, Switzerland)*, vol. 24, no. 13, p. 4379, 2024.
- [10] Ramalingam K, Pazhanivelan P, Jagadeeswaran R, Prabu P. YOLO deep learning algorithm for object detection in agriculture: A review. *Journal of Agricultural Engineering*, vol. 55, no. 4, 2024.
- [11] Kamilaris A, Prenafeta-Boldú FX, A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, vol. 156, no. 3, pp. 312-322, 2018.
- [12] Baran MF, Kahya E, Seydoşođlu S. YOLO derin öğrenmenin tarımsal uygulama örnekleri. *International Conference On Global Practice Of Multidisciplinary Scientific Studies*. Havana, Cuba. 2025.
- [13] Bađcı M. Mısır tarlasında görüntü işleme yöntemi ile yabancı otların tespiti. Yüksek Lisans Tezi. Pamukkale Üniversitesi. 2024.
- [14] Çiçek Y, Uludađ A, Gülbandılar E. Şeker pancarı üretiminde kullanılan yapay zekâ teknikleri. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, vol. 3, no. 2, pp. 54-59, 2022.
- [15] Mustafa G. Tokat bölgesi buđday üretiminde bazı yabancı otların derin öğrenme yöntemi ile tespit edilmesi. Doktora Tezi. Tokat Gaziosmanpaşa Üniversitesi. 2022.
- [16] Dulkadir S, Gültekin GK. Tarımsal otomasyon sistemleri için muz olgunluk seviyelerinin derin öğrenme yöntemleri ile sınıflandırılması. *EMO Bilimsel Dergi*, vol. 13, no. 3, pp. 27-34, 2023.
- [17] Kahya E, Aslan Y. Derin öğrenme destekli gerçek zamanlı zeytin tespiti uygulaması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 7, no. 4, pp. 1438-1454, 2024.
- [18] Tavus B, Karataş K, Türker M. Tarımsal alanlarda yüksek çözünürlüklü IKONOS uydu görüntüsünden nesne-tabanlı ürün deseni tespiti. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 25, no. 5, pp. 603-614, 2019.
- [19] Altaş Z, Özgüven MM, Yanar Y. Bitki hastalık ve zararlı düzeylerinin belirlenmesinde görüntü işleme tekniklerinin kullanımı: Şeker pancarı yaprak leke hastalığı örneđi. *International Erciyes Agriculture, Animal & Food Sciences Conference*. Kayseri. Türkiye. 2019.
- [20] Solak S, Altınışık U. Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science*, vol. 22, no. 1, pp. 56-65, 2018.
- [21] Ajayi OG, Ashi J, Guda B. Performance evaluation of YOLO v5 model for automatic crop and weed classification on UAV images. *Smart Agricultural Technology*, vol. 5, p. 100231, 2023.
- [22] Kılıç AE. Transfer öğrenme tabanlı açıklanabilir derin öğrenme yöntemleri kullanılarak bitki hastalıklarının sınıflandırılması. Yüksek Lisans Tezi. Necmettin Erbakan Üniversitesi. 2024.

## Mikro Gaz Türbinlerinde Güç Tahmini İçin Doğru Yapay Zekâ Modelinin Seçimi: Kapsamlı Bir Performans Çalışması

Yazar Emrullah GAZİOĞLU<sup>1\*</sup>

<sup>1</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Şırnak Üniversitesi, Şırnak, Türkiye

\*<sup>1</sup> gazioglu@sirnak.edu.tr

(Geliş/Received: 29/12/2025;

Kabul/Accepted: 15/01/2026)

**Öz:** Bu çalışmada, 3 kilowatt gücündeki bir mikro gaz türbininden elde edilen 71.225 örneklik veri seti kullanılarak, on dört farklı Yapay Zeka modelinin (geleneksel Makine Öğrenmesi ve Derin Öğrenme) güç tahmin performansı değerlendirilmiştir. GRU mimarisi en yüksek doğruluğu (RMSE: 12,36; R<sup>2</sup>: 0,9997) elde ederken, XGBoost gibi geleneksel modeller önemli ölçüde düşük hesaplama gereksinimleri (77,13 saniyeye karşı 855,04 saniye eğitim süresi) ile rekabetçi performans sunmuştur. Sonuçlar, optimal model seçiminin belirli operasyonel gereksinimlere bağlı olduğunu ve gerçek zamanlı uygulamalar için geleneksel Makine Öğrenmesi modellerinin, yüksek doğruluk gerektiren senaryolar için ise Derin Öğrenme mimarilerinin tercih edilmesi gerektiğini göstermiştir.

**Anahtar kelimeler:** Mikro gaz türbinleri, enerji tahmini, derin öğrenme, zaman serisi analizi.

### Choosing the Right AI Model for Power Forecasting in Micro Gas Turbines: A Comprehensive Performance Study

**Abstract:** This study evaluates the power prediction performance of fourteen different Artificial Intelligence models (traditional Machine Learning and Deep Learning) using a dataset of 71,225 samples from a 3-kilowatt micro gas turbine. The GRU architecture achieved the highest accuracy (RMSE: 12.36; R<sup>2</sup>: 0.9997), while traditional models such as XGBoost offered competitive performance with significantly lower computational requirements (77.13 seconds versus 855.04 seconds training time). Our findings demonstrate that optimal model selection depends on specific operational requirements, with traditional ML models being preferable for real-time applications and DL architectures for scenarios requiring high accuracy.

**Keywords:** Micro gas turbines, energy forecasting, deep learning, time series analysis

#### 1. Giriş

Enerji altyapısı karmaşık hale geldikçe, Yapay Zeka'nın (YZ) enerji sistemlerine entegrasyonu kritik hale gelmiştir [1,2]. Enerji üretim sistemleri sofistike hale geldikçe [3], YZ güdümlü modelleme ve tahmin yetenekleri sistem güvenilirliği ve verimliliği için temel araçlar olarak ortaya çıkmıştır. Bu durum özellikle mikro gaz türbinleri gibi dinamik enerji sistemlerinde daha da belirginleşmiştir [4]. Bu noktada akıllı izleme ve kontrol sistemleri karmaşık, yani doğrusal olmayan davranışları ve zamana bağlı tepkileri ele almalıdır.

Mikro gaz türbinlerinde güç tahmini, değişen yük talepleri nedeniyle gerçek zamanlı izleme ve kontrol gerektiren zorlu süreçler içerir. Geleneksel yöntemler, doğrusal olmayan davranış ve kontrol girişlerine gecikmeli tepkiler sergilediğinde geçiş durumlarını modellemede zorlanır [5,6]. Ayrıca uzun vadeli eğitim verilerinin kısıtlılığı ve sistemin iç bileşenlerinden ayrıntılı ölçümler alınmanın yüksek maliyeti pratik kısıtlamalar oluşturur [7].

Mikro gaz türbini uygulamalarında, geleneksel Makine Öğrenmesi (MÖ) ile Derin Öğrenme (DÖ) yaklaşımlarının tahmin doğruluğu ve hesaplama verimliliği açısından kapsamlı karşılaştırması önemli bir araştırma ihtiyacıdır.

#### 1.1. Çalışmanın katkıları

Bu çalışmada, 71.225 örneklik bir veri seti üzerinde 14 farklı YZ modelinin (5 geleneksel MÖ ve 9 DÖ mimarisi) mikro gaz türbini güç tahminindeki kapsamlı karşılaştırması sunulmuştur. Çalışmanın temel katkıları, model performanslarının sistematik değerlendirilmesi, hesaplama verimliliği ile tahmin doğruluğu arasındaki ilişkiyi analiz etme ve farklı operasyonel senaryolar için pratik model seçim rehberlerinin geliştirilmesidir.

\* Sorumlu yazar: [gazioglu@sirnak.edu.tr](mailto:gazioglu@sirnak.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-7615-305X

## 2. Literatür Taraması

Güç tahmininde MÖ ve DÖ tekniklerinin uygulanması son on yılda önemli ölçüde gelişmiştir. İlk yaklaşımlar ağırlıklı olarak istatistiksel yöntemlere ve basit regresyon modellerine dayanıyordu [8], ancak alan hızla daha sofistike tekniklere doğru ilerlemiştir. Destek Vektör Makineleri (DVM) ve Rastgele Ormanlar dahil geleneksel MÖ yöntemleri, güç tahmin görevlerinde önemli başarılar göstermiştir [9]. Bu yöntemler, hesaplama verimliliği ve model yorumlanabilirliğinin birincil endişeler olduğu senaryolarda özellikle etkili olmuştur.

Son yıllarda DÖ yaklaşımlarına doğru önemli bir kaymaya tanıklık edilmiştir. Tekrarlayan Sinir Ağları ve varyantları, güç sistemlerinde zamansal bağımlılıkları yakalamada dikkate değer potansiyel göstermiştir [10]. Uzun Kısa Süreli Bellek (LSTM) ağları, çeşitli güç tahmin görevlerine başarıyla uygulanmış, uzun vadeli bağımlılıkları ele almada üstün performans göstermiştir [11-13]. Attention (Dikkat) mekanizmalarının ve transformatör mimarilerinin ortaya çıkması, bu alanda DÖ modellerinin yeteneklerini daha da genişletmiştir [14-17].

Gaz türbinleri ve mikro gaz türbinlerinin özel bağlamında, çeşitli çalışmalar farklı modelleme yaklaşımlarını araştırmıştır. Geleneksel fizik tabanlı modeller kademeli olarak veri güdümlü yaklaşımlarla desteklenmiş veya değiştirilmiştir [18]. Fiziksel içgörülerini MÖ teknikleriyle birleştiren hibrit modeller, karmaşık sistem dinamiklerini yakalamada umut verici sonuçlar göstermiştir [19]. Son çalışmalar, çeşitli çalışma koşullarını ve sistem durumlarını ele alabilen daha sağlam ve uyarlanabilir modeller geliştirmeye odaklanmıştır [18,20].

Güç tahmininde topluluk (ensemble) yöntemlerinin uygulanması da dikkat çekmiştir. Yapılan çalışmalarda, tahmin doğruluğunu ve sağlamlığını artırmak için torbalama (bagging), artırma (boosting) ve istifleme (stacking) dahil çeşitli topluluk stratejileri araştırılmıştır. Ancak, bu yöntemlerin etkinliği genellikle belirli uygulama bağlamlarına ve hesaplama kısıtlamalarına bağlı kalmıştır [21-24].

Alandaki son eğilimler arasında, geliştirilmiş genelleme için fizik-bilgili sinir ağlarının entegrasyonu [25,26], değişen çalışma koşullarına uyum sağlayacak uyarlanabilir öğrenme stratejilerinin geliştirilmesi [27], daha iyi model anlayışı için yorumlanabilir YZ tekniklerinin araştırılması [28-30] ve sistemler arası adaptasyon için transfer öğrenme yaklaşımlarının uygulanması [31-33] yer almaktadır.

## 3. Materyal ve Yöntemler

### 3.1. Veri seti açıklaması

Bu çalışmada, [34]'te sunulan zaman serisi veri seti kullanılmış olup, 3 kilowatt gücündeki ticari bir mikro gaz türbini sisteminden elde edilen ölçümleri kapsamaktadır. Bu kapsamlı veri setinde, 8 farklı deney serisine bölünmüş 71.225 örnek bulunmaktadır. Her deney 1,8 ile 3,3 saat arasında sürmüştür. Ölçümler yaklaşık olarak 1 saniye aralıklarla alınmış, bu da türbindeki davranış kalıplarının ince ayrıntılarını incelemek için yüksek zamansal çözünürlük sağlamıştır. Veri seti üç temel değişken içermektedir: saniye cinsinden zamansal bilgi, volt cinsinden kontrol giriş voltajı ve hedef değişken olan watt cinsinden elektrik güç çıkışı. Bu deney serileri iki ana türe ayrılabilir. İlki, kontrol girişinde ani değişiklikler ve güç çıkışında önemli gecikmeler içeren dört dikdörtgen dalga serisi deneyi içermekte olup, geçiş ve kararlı durum fazlarının modellenmesi için kritiktir. Buna karşılık, dört sürekli dalga serisi deneyi, kontrol girişinde kademeli değişiklikler ve güç çıkışında neredeyse hiç gecikme olmadan ilerlemekte ve ağırlıklı olarak kararlı durum davranışının modellenmesine odaklanmaktadır. [34]'te atılan temeller üzerine ilerlenerek, bu makalede ilgili çalışma geliştirilmiş ve bu değerli veri setine çeşitli klasik MÖ ve DÖ yöntemleri uygulanmıştır.

### 3.2. Veri ön işleme

Kurulan veri ön işleme iş hattında, veri hazırlamaya sistematik bir yaklaşım uygulanmıştır. Veri seti stratejik olarak bölünmüş, Deneylerde, [34]'te uygulandığı gibi 1, 9, 20, 21, 23 ve 24 numaralı veriler eğitim (train) için ayrılırken, 4 ve 22 numaralı veriler test kümesi olarak ayrılmıştır. Özellik mühendisliği ile, 5 ile 30 zaman adımı arasında değişen geriye bakış pencereleri (look-back Windows) oluşturulmuş [35], StandardScaler [36] aracılığıyla standardizasyon uygulanmış ve DÖ modelleri için diziler uygun şekilde yeniden şekillendirilmiştir. Kalite güvencesi önlemleri, veri tamlığının kapsamlı doğrulanması, zamansal tutarlılık validasyonu ve kapsamlı sinyal kalitesi değerlendirmesinden oluşmuştur.

### 3.3. Karşılaştırmalı değerlendirme yaklaşımı

#### 3.3.1. Klasik makine öğrenmesi modelleri

Bu çalışmada beş geleneksel MÖ yöntemi uygulanmıştır: torbalama topluluk öğrenme yöntemiyle optimize edilmiş rastgele durumla 100 ağaçtan oluşan bir orman kullanan Rastgele Orman [37]. Paralel işleme kullanarak aşırı öğrenmeyi (overfitting) önleyen düzenleme terimlerini içeren ağaç tabanlı bir öğrenme algoritması olan gradyan artırmanın hızlı ve verimli bir uygulaması olan XGBoost [38]. Microsoft'un histogram tabanlı özellik gruplama ve gradyan tabanlı tek taraflı örnekleme eklentisiyle yaprak odaklı ağaç büyüme stratejisi izleyen LightGBM çerçevesi [39]. Radyal tabanlı fonksiyon (RBF) çekirdeği kullanan Destek Vektör Regresyonu (DVR), doğrusal olmayan ilişkileri modellemek için çekirdek dönüşümü, epsilon-duyarsız kayıp fonksiyonu ve düzenleme yöntemlerini içermektedir. Gradyan Artırma ise, ağaç modellerini kare kaybını optimize edecek şekilde sıralı olarak oluşturan klasik bir yaklaşımla, küçültme tabanlı düzenleme kullanılarak uygulanmıştır.

#### 3.3.2. Derin öğrenme mimarileri

Bu çalışmada dokuz DÖ mimarisi kullanılmıştır: LSTM, GRU, BiLSTM, CNN-LSTM, Zamansal Evrişimsel Ağ (TCN), Transformatör, LSTM+Dikkat, CNN-LSTM+Dikkat ve Transformatör-CNN hibridi.

LSTM ve GRU, kapılama mekanizmaları aracılığıyla uzun vadeli zamansal bağımlılıkları yakalamada etkilidir. BiLSTM, dizileri hem ileri hem geri yönde işleyerek bağlamsal bilgiyi artırır. CNN-LSTM hibrit modelleri, evrişimsel katmanlarla yerel özellik çıkarmayı LSTM'in zamansal modelleme gücüyle birleştirir. Transformatör mimarileri öz-dikkat (self attention) mekanizmaları kullanırken, dikkat mekanizmalı varyantlar giriş dizisinin farklı zaman adımlarına uyarlanabilir önem verir.

Tüm modeller iki katmanlı yapıda (64 ve 32 birim), Adam optimizör (öğrenme oranı: 0,001) ve erken durdurma ile eğitilmiştir.

#### 3.3.3. Topluluk yöntemleri

Bu çalışmada üç farklı topluluk yaklaşımı araştırılmıştır. İstifleme için beş temel model kullanılmıştır: Rastgele Orman, Gradyan Artırma, XGBoost, LightGBM ve modele özgü tabanlar. Bir meta-öğrenici temel modele eşit olarak ayarlanmış ve meta-özellik üretimi için çapraz doğrulama uygulanmıştır. Torbalama uygulaması, yerleştirmeli rastgele örnekleme ve tahmin edicilerin paralel eğitimini kullanarak son tahminler için ortalamaları kullanmıştır. Artırma yönteminde, modeller sıralı olarak inşa edilmiş ve gradyanlara dayalı optimize edilmiştir. Optimal performans için öğrenme oranı katsayısı uygulanmıştır.

### 3.4. Parametre ayarları

MÖ ve DÖ modellerinin performansı, hiper-parametre konfigürasyonlarına bağlıdır. Tablo 1'de, deneyde kullanılan her model için detaylı parametre ayarları gösterilmiştir.

Parametre ayarları, zaman serisi tahmini literatüründeki deneyler ve önceki çalışmalar referans alınarak yapılmıştır. Geleneksel MÖ modellerinde topluluk boyutu ve ağaç parametreleri, DÖ modellerinde mimari derinliği ve öğrenme oranı önceliklendirilmiştir. DÖ modelleri, aşırı uyumu engellemek amacıyla erken durdurma ile eğitilmiş ve en iyi performanslı versiyonları kontrol noktalarına kaydedilmiştir. Tüm DÖ modellerinde Adam optimizör 0,001 başlangıç öğrenme oranıyla kullanılmış, doğrulama kaybı sabitlendiğinde 0,1 faktörle düşürülmüştür.

Geriye bakış penceresi, performansı araştırmanın bir yolu olarak 5 ila 30 zaman adımı aralığında değiştirilmiştir. Bu aralık, zamansal bağımlılıkların yakalanması ile hesaplama fizibilitesinin korunması arasında denge kurularak seçilmiştir. Tüm modeller üç giriş özelliğini dikkate alır: voltaj ölçümü, gücün tarihsel değerleri ve mevcut voltaj. Tüm veriler StandardScaler kullanılarak normalize edilmiş, bu da tüm özellikler arasında aynı ölçeği zorunlu kılmıştır.

**Tablo 1.** MÖ ve DÖ modelleri için parametre ayarları.

Model Kategorisi	Model	Parametreler	Değer
Geleneksel MÖ	Rastgele Orman	n_estimators max_depth random_state	100 Yok Rastgele(1-100)
	XGBoost	learning_rate max_depth n_estimators random_state	0,1 6 100 Rastgele(1-100)
	LightGBM	learning_rate num_leaves n_estimators random_state	0,1 31 100 Rastgele(1-100)
	DVR	kernel C	RBF 1,0
	Gradyan Artırma	learning_rate n_estimators max_depth random_state	0,1 100 3 Rastgele(1-100)
DÖ (1. Kısım)	LSTM	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	LSTM(64) → LSTM(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	GRU	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	GRU(64) → GRU(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	BiLSTM	katmanlar yoğun katmanlar aktivasyon optimizasyon batch boyutu	BiLSTM(64) → BiLSTM(32) 16 → 1 ReLU, Doğrusal Adam(lr=0,001) 32
	CNN-LSTM	CNN katmanları LSTM katmanları yoğun katmanlar aktivasyon optimizasyon	Conv1D(64,3) → MaxPool(2) LSTM(32) → LSTM(16) 8 → 1 ReLU, Doğrusal Adam(lr=0,001)
DÖ (2. Kısım)	Transformer	attention heads key dimension yoğun katmanlar activation optimizer	8 64 64 → 1 ReLU, Linear Adam(lr=0.001)
	TCN	filters kernel size dilation rates activation dropout	64 3 [1, 2, 4, 8] ReLU 0.2
	LSTM+Attention	LSTM katmanı attention tipi pooling yoğun katman optimizer	LSTM(64) Self-attention Global Average 1 Adam(lr=0.001)
	CNN-LSTM+Attention	CNN katmanı LSTM katmanı attention tipi pooling optimizer	Conv1D(64,3) + MaxPool(2) LSTM(64) Self-attention Global Average Adam(lr=0.001)
	Transformer+CNN	attention katmanı CNN katmanı LSTM katmanı yoğun katman optimizer	Self-attention Conv1D(64,3) + MaxPool(2) LSTM(64) 1 Adam(lr=0.001)
Eğitim Ayarları	Genel	epochs validation split early stopping patience sequence length features	100 0.2 5 5-30 3 (voltage, power, current)
	Callbacks	early stopping model checkpoint learning rate reduction	monitor='val_loss' save_best_only=True factor=0.1, patience=3

\*LB (Look-back window): model girdisi olarak kullanılan geçmiş zaman adımı sayısını ifade eder.

### 3.5. Deneysel kurulum

Deneysel çerçeve, 5-30 zaman adımından kısa vadeli ile uzun vadeli tahmini dikkate alarak kapsamlı zaman penceresi analizini içermektedir. Model hiper-parametreleri her mimari türü için dikkatle ayarlanmıştır; klasik MÖ modelleri tahmin edicilerin ve derinlik parametrelerinin özel konfigürasyonlarını kullanırken, DÖ modelleri çok dikkatli seçilmiş bir öğrenme oranı ve parti boyutu ile Adam optimizasyonunu kullanmıştır. Eğitim prosedürü, kapsamlı

veri standardizasyonu, stratejik veri bölme ve en iyi performansı takip etmek için model kontrol noktalarıyla gerçekleştirilmiştir.

Değerlendirme sürecinde, sadece tahmin doğruluğunun incelemesi değil, aynı zamanda bütün resmin görülmesi de amaçlanmıştır. Bu nedenle, farklı ölçüm türlerini kullanılarak kapsamlı bir test yaklaşımı geliştirildi: Doğruluğu (Accuracy) kontrol etmek için RMSE, Kök Ortalama Kare Yüzde Hatası (RMSPE) ve Ortalama Mutlak Hata (MAE) gibi klasik metrikler kullanılırken, tahminlerin gerçeklikle ne kadar iyi eşleştiğini anlamak için  $R^2$  Skoru ve Pearson korelasyon katsayıları (*Corr*) kullanılmış, göreceli hataların bir anlayışını elde etmek için Ortalama Mutlak Yüzde Hatası (MAPE) kullanılmıştır. Bu değerlendirme metriklerinin matematiksel formülasyonları Denklem 1, Denklem 2, Denklem 3, Denklem 4 Denklem 5 ve Denklem 6'daki gibidir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{y_i} \right)^2} \times \%100 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times \%100 \quad (5)$$

$$Corr = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (6)$$

burada,  $y_i$  gerçek değeri,  $\hat{y}_i$  tahmin edilen değeri,  $\bar{y}$  gerçek değerlerin ortalamasını,  $\bar{\hat{y}}$  tahmin edilen değerlerin ortalamasını ve son olarak  $n$  örnek sayısını temsil etmektedir.

#### 4. Deneysel Sonuçlar ve Tartışma

Bu bölüm, dört tamamlayıcı test seti kullanarak deneysel sonuçlarımızın derinlemesine analizi için yapılandırılmış bir çerçeve sağlamaktadır. Deneysel kurulumumuzun açıklamasıyla başlıyor, her mimarinin temel performans özelliklerini belirlememize olanak tanıyan Test Seti 1'de tüm modellerimizin temel değerlendirmesiyle devam ediyoruz. Daha sonra, geriye bakış pencere boyutunun model performansı üzerindeki etkisini test etmek için Test Seti 2'yi kullanıyoruz, ardından Test Seti 3 ile topluluk yöntemlerinin etkinliğinin değerlendirilmesi geliyor. Son olarak, modellerin hesaplama verimliliğine bakıyor ve endüstriyel uygulamalar için pratik sonuçlarını tartışıyoruz. Bu yapılandırılmış yaklaşım, her model konfigürasyonunun hem tahmin performansının hem de pratik değerlendirmelerinin kapsamlı bir incelemesini yapmamızı sağlar.

##### 4.1. Deneysel çerçeveye genel bakış

Bu çalışmada, her biri güç tahmin probleminin farklı yönlerini hedefleyen üç tamamlayıcı test setinden oluşan sistematik bir deneysel çerçeve tasarlandı. Test Seti 1, tüm on dört modelin 10 zaman adımlık sabit bir geriye bakış penceresi kullanılarak birbirleriyle karşılaştırıldığı kapsamlı temel değerlendirme olarak kullanıldı. Bu temel karşılaştırma, üç performans kademesi gösterdi: GRU ve CNN-LSTM+Dikkat gibi yüksek performanslı DÖ modelleri, XGBoost ve LightGBM gibi rekabetçi geleneksel MÖ modelleri ve Transformatör ile DVR gibi nispeten düşük performanslı modeller. Test Seti 2'de geriye bakış pencere boyutunun model performansı üzerindeki etkisi araştırıldı, Test Seti 3'te ise topluluk yöntemlerinin etkinliği değerlendirildi. Tablo 2, her test seti için model seçimleri, geriye bakış pencere boyutları ve topluluk yöntemi varyasyonları dahil olmak üzere detaylı konfigürasyon parametrelerini sunmaktadır.

**Tablo 2.** Test kümesi ayarları.

Test Seti	Amaç	Modeller	Parametreler
1	Temel Model Karşılaştırma	Tüm modeller (1-14)	Geriye bakış: 10 Topluluk: Yok
2	Geriye Bakış	XGBoost (2)	Geriye bakış: 5,10,15,20,30

Test Seti	Amaç	Modeller	Parametreler
3	Pencere Analizi	LSTM (6) CNN-LSTM (9) Transformatör (10)	Topluluk: Yok
	Topluluk Yöntem Analizi	XGBoost (2) LightGBM (3) Transformatör (10)	Geriye bakış: 10 Topluluk türleri: İstifleme, Torbalama, Artırma

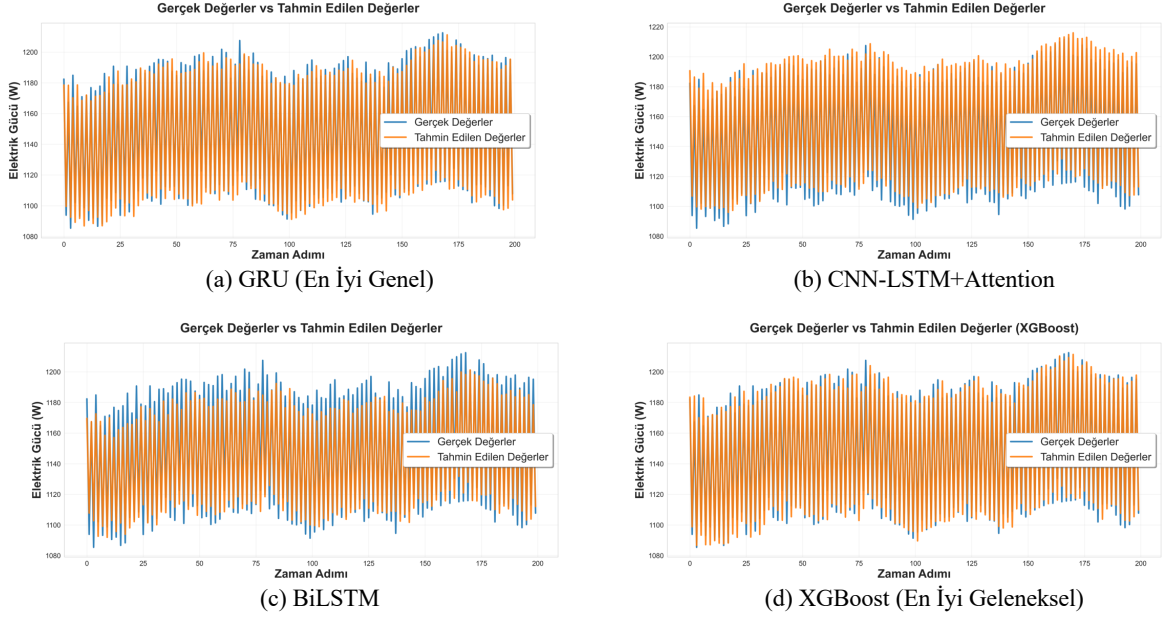
#### 4.2. Temel model performans analizi

Kapsamlı mikro gaz türbini güç tahmini çalışmasında, farklı model mimarileri ve konfigürasyonları için çeşitli önemli bulgular elde edilmiştir. Tablo 3'te görüldüğü üzere, DÖ yöntemleri geleneksel MÖ yöntemlerine kıyasla belirgin şekilde daha iyi performans sergilemiştir. Tablo 3 ve Şekil 1'de sunulan sonuçlara göre, GRU mimarisi test edilen tüm modeller arasında 12,36 RMSE ve 0,9997 R<sup>2</sup> değerleriyle en yüksek doğruluğa ulaşmış, bunu 13,73 RMSE ve 0,9997 R<sup>2</sup> ile dikkat mekanizmalı CNN-LSTM izlemiştir. Ancak bu üstün performans, önemli ölçüde daha uzun eğitim süresi gerektirmektedir: GRU 855,04 saniye eğitim süresine ihtiyaç duyarken, XGBoost yalnızca 77,13 saniyede eğitilebilmektedir.

Elde edilen bulgular, gerçek dünya uygulamaları açısından önemli pratik sonuçlar ortaya koymaktadır. XGBoost gibi geleneksel MÖ modelleri, sınırlı hesaplama kaynaklarıyla gerçek zamanlı tahmin gerektiren senaryolarda doğruluk ve verimlilik arasında optimal denge sağlamaktadır. Öte yandan, tahmin doğruluğunun öncelikli olduğu ve yeterli hesaplama kaynaklarının mevcut bulunduğu durumlarda, özellikle dikkat mekanizmaları içeren DÖ yaklaşımları üstün performans sunmaktadır. Pencere boyutu seçiminin kritik bir faktör olduğu gözlemlenmiş, çoğu mimarinin 10-15 zaman adımı aralığında optimal performans gösterdiği belirlenmiştir.

**Tablo 3.** Test kümesi 1 sonuçları: 10 zaman adımli geriye bakış (LB=10) için modellerin karşılaştırması.

Model	LB	RMSE	RMSPE	MAE	R <sup>2</sup>	MAPE	Korelasyon.	Eğitim Süresi (sn)
GRU	10	12.36	0.72	9.09	0.9997	0.51	0.9998	855.04
CNN-LSTM+Att	10	13.73	0.77	9.94	0.9997	0.55	0.9998	419.35
BiLSTM	10	18.43	1.08	13.43	0.9994	0.76	0.9997	610.81
CNN-LSTM	10	19.73	1.02	13.36	0.9994	0.69	0.9997	474.14
LSTM	10	19.20	1.14	14.45	0.9994	0.84	0.9997	720.78
TCN	10	22.02	1.38	14.13	0.9992	0.82	0.9996	398.20
XGBoost	10	26.51	1.01	13.87	0.9989	0.65	0.9995	77.13
LightGBM	10	26.80	1.01	14.07	0.9989	0.66	0.9995	136.95
GBM	10	27.20	1.03	14.68	0.9988	0.69	0.9995	85.19
Random Forest	10	27.48	1.04	13.89	0.9988	0.65	0.9995	223.64
LSTM+Att	10	27.38	1.65	20.84	0.9988	1.20	0.9996	499.73
Transformer	10	39.76	2.26	27.55	0.9975	1.54	0.9988	517.17
Trans+CNN	10	46.96	2.58	33.24	0.9966	1.80	0.9985	353.85
SVR	10	42.57	2.21	33.20	0.9972	1.82	0.9988	2.52



**Şekil 1.** Önde gelen modellerin performans karşılaştırması: (a) RMSE 12,36 ile en iyi genel performansı elde eden GRU, (b) karşılaştırılabilir performans gösteren CNN-LSTM+Dikkat (RMSE 13,73), (c) güçlü temel performans gösteren BiLSTM (RMSE 18,43), ve (d) en iyi geleneksel MÖ yaklaşımını temsil eden XGBoost (RMSE 26,51).

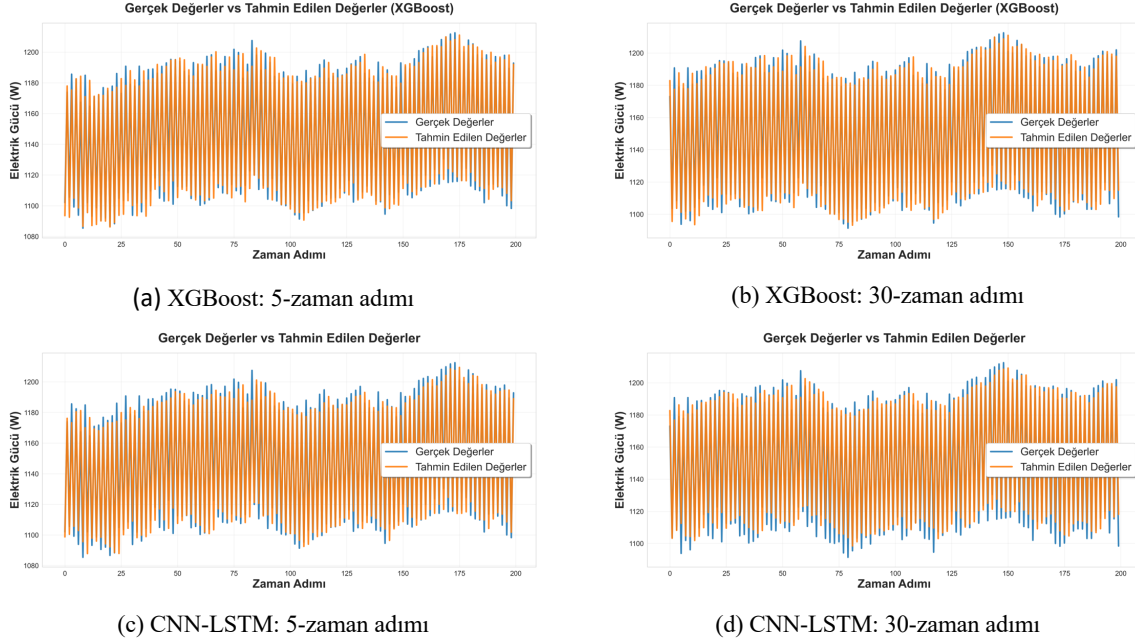
#### 4.3. Geriye bakış pencere boyutunun etkisi

Geriye bakış pencere boyutunun etkisi Tablo 4 ve Şekil 2'de sunulmakta olup, farklı mimarilerde ilginç kalıplar gözlemlenmektedir. Geleneksel MÖ modelleri, özellikle XGBoost, farklı pencere boyutları için oldukça kararlı bir performans sergilemiştir.

Test Seti 2, geriye bakış pencere boyutunun model performansı üzerindeki etkisinin araştırılması amacıyla oluşturulmuştur. Farklı mimari paradigmalardan üç temsili model seçilmiştir: en iyi performans gösteren geleneksel MÖ modeli olarak XGBoost, hibrit mimarilerden güçlü performans sergileyen CNN-LSTM ve Test Seti 1'deki düşük performansının nedenlerini anlamak üzere Transformatör. Bu seçim, deneysel kapsamın yönetilebilir tutulmasının yanı sıra farklı mimari yaklaşımların değişen zamansal bağlam uzunluklarına nasıl tepki verdiğinin incelenmesine olanak sağlamıştır. Diğer modeller, ön testlerde mimari muadilleriyle benzer davranış kalıpları sergilemeleri veya daha az umut verici temel performans göstermeleri nedeniyle değerlendirme dışında bırakılmıştır.

**Tablo 4.** Test kümesi 2 sonuçları: Geriye bakış pencere analizi.

Model	LB	RMSE	RMSPE	MAE	$R^2$	MAPE	Corr.	Eğitim Süresi (sn)
XGBoost	5	27.13	1.06	14.26	0.9988	0.68	0.9995	118.43
	10	26.51	1.01	13.87	0.9989	0.65	0.9995	118.16
	15	26.66	1.04	14.07	0.9989	0.67	0.9995	118.84
	20	26.30	1.04	13.98	0.9989	0.67	0.9995	115.89
	30	25.85	0.98	13.47	0.9989	0.64	0.9995	113.79
CNN-LSTM	5	18.53	1.01	11.68	0.9994	0.62	0.9997	257.66
	10	17.88	0.99	12.04	0.9995	0.66	0.9997	734.35
	15	19.02	0.99	12.51	0.9994	0.64	0.9997	668.11
	20	18.50	1.01	11.86	0.9994	0.64	0.9997	548.85
	30	18.23	1.03	12.09	0.9994	0.66	0.9997	778.05
Transformer	5	33.40	1.82	24.67	0.9982	1.35	0.9991	385.03
	10	43.84	2.45	30.67	0.9970	1.70	0.9985	519.47
	15	30.49	1.47	18.58	0.9985	0.94	0.9993	915.92
	20	67.42	3.50	49.65	0.9930	2.77	0.9969	384.46
	30	69.76	3.99	52.68	0.9925	3.02	0.9963	257.31



**Şekil 2.** Geriye bakış pencere boyutunun model tahminleri üzerindeki etkisi: (a,b) Tutarlı performans gösteren XGBoost için en kısa (5-zaman adımı) ve en uzun (30-zaman adımı) pencereler arasındaki karşılaştırma (RMSE farkı:1,28) ve (c,d) daha kısa pencerelerde optimal performans gösteren CNN-LSTM (RMSE farkı: 0,30).


**Tablo 5.** Test kümesi 3 sonuçları: Topluluk metotları analizi.

Model	Top.	RMSE	RMSPE	MAE	$R^2$	MAPE	Kor.
XGBoost	1	44,11	1,48	20,28	0,9970	0,86	0,9989
	2	26,55	1,00	13,64	0,9989	0,64	0,9995
	3	26,51	1,01	13,87	0,9989	0,65	0,9995
LightGBM	1	40,37	1,48	19,32	0,9975	0,86	0,9991
	2	26,83	1,02	14,09	0,9989	0,66	0,9995
	3	26,80	1,01	14,07	0,9989	0,66	0,9995
Transformatör	1	43,57	2,36	30,22	0,9971	1,60	0,9986
	2	42,14	2,35	28,14	0,9973	1,53	0,9987
	3	44,56	2,43	31,36	0,9970	1,68	0,9985

#### 4.4. Topluluk yöntemleri analizi

Bu çalışmada, potansiyel performans iyileştirmelerinin değerlendirilmesi amacıyla seçili temel modellerle üç farklı topluluk yaklaşımı araştırılmıştır (Tablo 5, Şekil 3). Elde edilen sonuçlar, mikro gaz türbini güç tahmininde topluluk yöntemlerinin sınırlı etkinliğe sahip olduğunu ortaya koymuştur.

İstifleme yaklaşımının beklenmedik şekilde performans bozulmasına yol açtığı gözlemlenmiştir; XGBoost için RMSE 26,51'den 44,11'e, LightGBM için 26,80'den 40,37'ye yükselmiştir. Torbalama yöntemiyle temel model performansı korunmuş (XGBoost: 26,55 RMSE), ancak hesaplama süresi %50 oranında artmıştır. Artırma yöntemiyle minimal iyileşme sağlanmış (XGBoost: 26,51 RMSE), sadece %10 ek hesaplama yükü getirilmiştir. Bu sınırlı etkinlik, güç tahmin verilerinin zamansal yapısının çeşitli model kombinasyonlarının faydalarını sınırladığına ve temel modellerin zaten öğrenilebilir kalıpların büyük çoğunluğunu yakaladığına işaret etmektedir. Mikro gaz türbini güç tahmini bağlamında, topluluk yöntemlerinin getirdiği ek karmaşıklığın performans faydalarıyla gerekçelendirilemediği sonucuna ulaşılmıştır.



**Şekil 3.** XGBoost için topluluk yöntem karşılaştırması: (a) Performans bozulması gösteren İstifleme (RMSE: 44,11), (b) Temel performansı koruyan Torbalama (RMSE: 26,55), ve (c) Minimal iyileşme gösteren Artırma (RMSE: 26,51).

## 5. Sonuç ve Gelecek Çalışmalar

Bu çalışmada, mikro gaz türbini güç tahmini için on dört farklı yapay zeka modelinin kapsamlı karşılaştırması gerçekleştirilmiştir. Geniş kapsamlı deneysel değerlendirmeler sonucunda, derin öğrenme mimarilerinin üstün tahmin doğruluğuna ulaştığı, buna karşın geleneksel makine öğrenmesi modellerinin belirgin hesaplama verimliliği avantajı sunduğu ortaya konmuştur.

Model seçiminin, uygulamaya gereksinimlerine bağlı olarak yapılması gerektiği belirlenmiştir. Gerçek zamanlı tahmin ve sınırlı hesaplama kaynakları gerektiren senaryolarda geleneksel makine öğrenmesi yaklaşımlarının, yüksek doğruluğun öncelikli olduğu uygulamalarda ise derin öğrenme mimarilerinin tercih edilmesi önerilmektedir. Topluluk yöntemlerinin bu özel problemde sınırlı katkı sağladığı, ancak dikkat mekanizmalarının model performansını iyileştirdiği gözlemlenmiştir.

Gelecek araştırmalarda, değişen çevresel koşullar altında model sağlamlığının incelenmesi, uyarlanabilir öğrenme stratejilerinin geliştirilmesi ve derin öğrenme tahminlerinin yorumlanabilirliğinin artırılması yoluyla bu alanda önemli katkılar sağlanabileceği düşünülmektedir.

Özetle, bu çalışma mikro gaz türbini güç tahmininde model doğruluğu ile hesaplama maliyeti arasındaki temel ödünleşimi açık biçimde ortaya koymuştur. GRU ve dikkat mekanizmalı derin öğrenme mimarileri en yüksek tahmin doğruluğunu sağlarken, XGBoost gibi geleneksel makine öğrenmesi modelleri gerçek zamanlı uygulamalar için rekabetçi bir alternatif sunmaktadır. Bu bulgular, farklı operasyonel gereksinimler için uygun model seçimine yönelik pratik bir rehber niteliğindedir.

## Kaynaklar

- [1] Su W, Zeng F, Shi M, Xiao X, Sun T, Guo J. A data-driven multi-time scale coordinated economic dispatch model for flexible interconnection low-voltage distribution station areas. In: 2022 Power System and Green Energy Conference (PSGEC); 25-27 August 2022; Shanghai, China. New York, NY, USA: IEEE. pp. 859-867.
- [2] Massaoudi M, Abu-Rub H, Refaat SS, Chihi I, Oueslati FS. Deep learning in smart grid technology: A review of recent advancements and future prospects. IEEE Access 2021; 9: 54558-54578.
- [3] Ahmadi B, Ceylan O, Ozdemir A. Distributed energy resource allocation using multi-objective grasshopper optimization algorithm. Electr Power Syst Res 2021; 201: 107564.
- [4] Ghenai C, Husein LA, Al Nahlawi M, Hamid AK, Bettayeb M. Recent trends of digital twin technologies in the energy sector: A comprehensive review. Sustain Energy Technol Assess 2022; 54: 102837.

- [5] Beucler T, Pritchard M, Rasp S, Ott J, Baldi P, Gentine P, ve diğerleri. Enforcing analytic constraints in neural networks emulating physical systems. *Phys Rev Lett* 2021; 126(9): 098302.
- [6] Robinson H, Pawar S, Rasheed A, San O, ve diğerleri. Physics guided neural networks for modelling of non-linear dynamics. *Neural Netw* 2022; 154: 333-345.
- [7] Gopisetty S, Treffinger P. Generic combined heat and power (CHP) model for the concept phase of energy planning process. *Energies* 2016; 10(1): 11.
- [8] Forootan MM, Larki I, Zahedi R, Ahmadi A. Machine learning and deep learning in energy systems: A review. *Sustainability* 2022; 14(8): 4832.
- [9] Gaboitaolelwe J, Zungeru AM, Yahya A, Lebekwe CK, Vinod DN, Salau AO. Machine learning based solar photovoltaic power forecasting: A review and comparison. *IEEE Access* 2023; 11: 40820-40845.
- [10] Saffari M, Khodayar M. Spatiotemporal deep learning for power system applications: A survey. *IEEE Access* 2024.
- [11] Wang J, Zhu H, Zhang Y, Cheng F, Zhou C. A novel prediction model for wind power based on improved long short-term memory neural network. *Energy* 2023; 265: 126283.
- [12] Jiang T, Liu Y. A short-term wind power prediction approach based on ensemble empirical mode decomposition and improved long short-term memory. *Comput Electr Eng* 2023; 110: 108830.
- [13] Pasandideh M, da Silva JA, Gonzalez-Hernandez JL, Mehr AS, Chen Y, Wang Y, Ting DSK, Carriveau R, ve diğerleri. Predicting steam turbine power generation: A comparison of long short-term memory and willans line model. *Energies* 2024; 17(2): 352.
- [14] Huang S, Yan C, Qu Y. Deep learning model-transformer based wind power forecasting approach. *Front Energy Res* 2023; 10: 1055683.
- [15] Khan ZA, Hussain T, Baik SW. Dual stream network with attention mechanism for photovoltaic power forecasting. *Appl Energy* 2023; 338: 120916.
- [16] Tian C, Niu T, Wei W. Developing a wind power forecasting system based on deep learning with attention mechanism. *Energy* 2022; 257: 124750.
- [17] Dong H, Zhu J, Li S, Wu W, Zhu H, Fan J. Short-term residential household reactive power forecasting considering active power demand via deep transformer sequence-to-sequence networks. *Appl Energy* 2023; 329: 120281.
- [18] Olsson T, Ramentol E, Rahman M, Oostveen M, Kyprianidis K. A data-driven approach for predicting long-term degradation of a fleet of micro gas turbines. *Energy AI* 2021; 4: 100064.
- [19] Belov S, Nikolaev S, Uzhinsky I. Hybrid data-driven and physics-based modeling for gas turbine prescriptive analytics. *Int J Turbomach Propuls Power* 2020; 5(4): 29.
- [20] Aslanidou I, Rahman M, Zaccaria V, Kyprianidis KG. Micro gas turbines in the future smart energy system: Fleet monitoring, diagnostics, and system level requirements. *Front Mech Eng* 2021; 7: 676853.
- [21] Souhaila C, Mohamed M. Ensemble methods comparison to predict the power produced by photovoltaic panels. *Procedia Comput Sci* 2021; 191: 385-390.
- [22] Piotrowski P, Baczyński D, Kopyt M, Gulczyński T. Advanced ensemble methods using machine learning and deep learning for one-day-ahead forecasts of electric energy production in wind farms. *Energies* 2022; 15(4): 1252.
- [23] Akilandeswari A, Raja SP, Shonika S, Anuradha S. Enhancing solar power generation forecasting using advanced machine learning and ensemble methods. In: 2024 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS); 8-9 October 2024; Chennai, India. New York, NY, USA: IEEE. pp. 1-6.
- [24] Li J, Jia L, Zhou C. Probability density function based adaptive ensemble learning with global convergence for wind power prediction. *Energy* 2024; 312: 133573.
- [25] Hu Z, Jagtap AD, Karniadakis GE, Kawaguchi K. When do extended physics-informed neural networks (XPINNs) improve generalization? *arXiv preprint arXiv:2109.09444*, 2021.
- [26] Kapoor T, Wang H, Núñez A, Dollevoet R. Transfer learning for improved generalizability in causal physics-informed neural networks for beam simulations. *Eng Appl Artif Intell* 2024; 133: 108085.
- [27] Hashmi MB, Mansouri M, Assadi M. Dynamic performance and control strategies of micro gas turbines: State-of-the-art review, methods, and technologies. *Energy Convers Manage X* 2023; 18: 100376.
- [28] Mubarak H, Stegen S, Bai F, Abdellatif A, Sanjari MJ. Enhancing interpretability in power management: A time-encoded household energy forecasting using hybrid deep learning model. *Energy Convers Manage* 2024; 315: 118795.
- [29] Chen Z, Xiao F, Guo F, Yan J. Interpretable machine learning for building energy management: A state-of-the-art review. *Adv Appl Energy* 2023; 9: 100123.
- [30] Machlev R, Heistrene L, Perl M, Levy KY, Belikov J, Mannor S, Levron Y, ve diğerleri. Explainable artificial intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities. *Energy AI* 2022; 9: 100169.
- [31] Li G, Chen L, Liu J, Fang X. Comparative study on deep transfer learning strategies for cross-system and cross-operation-condition building energy systems fault diagnosis. *Energy* 2023; 263: 125943.
- [32] Li G, Zhang X, Mikulski M, Chen X, Ma Z, Ahn J, ve diğerleri. An improved transfer learning strategy for short-term cross-building energy prediction using data incremental. *Build Simul* 2024; 17: 165-183.
- [33] Chen L, Liu J, Li G, Wang Z, Zhang G, Liu Y, Li Y, Cheng L, ve diğerleri. Fault diagnosis for cross-building energy systems based on transfer learning and model interpretation. *J Build Eng* 2024; 91: 109424.
- [34] Bielski P, Eismont A, Bach J, Leiser F, Kottonau D, Böhm K. Knowledge-guided learning of temporal dynamics and its application to gas turbines. In: Proceedings of the 15th ACM International Conference on Future and Sustainable Energy Systems; 4-7 June 2024; Singapore, Singapore. pp. 279-290.

- [35] Ermshaus A, Schäfer P, Leser U. Window size selection in unsupervised time series analytics: A review and benchmark. In: International Workshop on Advanced Analytics and Learning on Temporal Data; 19-23 September 2023; Grenoble, France. Springer. pp. 83-101.
- [36] Maharana K, Mondal S, Nemade B. A review: Data pre-processing and data augmentation techniques. Glob Transit Proc 2022; 3(1): 91-99.
- [37] Probst P, Wright MN, Boulesteix AL. Hyperparameters and tuning strategies for random forest. WIREs Data Min Knowl Discov 2019; 9(3): e1301.
- [38] Nalluri M, Pentela M, Eluri NR. A scalable tree boosting system: XG boost. Int J Res Stud Sci Eng Technol 2020; 7(12): 36-51.
- [39] Ke G, Meng Q, Finley T, Wang T, Chen W, Ma W, Ye Q, Liu TY, ve diğerleri. Lightgbm: A highly efficient gradient boosting decision tree. Adv Neural Inf Process Syst 2017; 30.

## Suluçayır Düzünde (Sivrice - Elâzığ) Bulunan Bir Göletin (Tm1 12) Epifitik Algleri

Güneş PALA<sup>1\*</sup>

<sup>1</sup> Su Ürünleri Temel Bilimleri, Su Ürünleri Fakültesi, Fırat Üniversitesi, Elâzığ, Türkiye

\*<sup>1</sup>gpala@firat.edu.tr

(Geliş/Received: 05/01/2026;

Kabul/Accepted: 23/03/2026)

**Öz:** Bu çalışmada Nisan- Eylül 2022 tarihleri arasında Elâzığ ilinin Sivrice ilçesi Sulu Çayır Düzü' nde yer alan TM1 12 Göleti' nden toplanan *Phragmites australis* 'in gövde ve yaprakları üzerindeki alglerinin kompozisyonu ve göletin bazı fizikokimyasal özellikleri birlikte incelenmiştir. Epifitik alglere ait toplam 65 takson kaydedilmiştir. Bu taksonlardan 1' i Euglenophyta; 4' ü Cyanophyta 7' si Chlorophyta ve 53' ü Bacillariophyta' ya ait olmuştur. Yazın ışık ve sıcaklığın artmaya başlamasıyla Chlorophyta (yeşil) ve Cyanophyta (mavi-yeşil) 'nın birey sayılarında artışlar gözlemlenirken nisan ve eylül aylarına Bacillariophyta (diatomeler)' nin birey sayılarında artışlar gözlemlenmiştir. Örnekleme yapıldığı tüm aylarda ortaya çıkış sıklığı bakımından dominant alg grubu Bacillariophyta olmuştur. Yaz aylarında sıcaklıkların artmaya başlamasıyla çözülmüş oksijen ve pH değerlerinde azalmalar gözlemlenirken, elektriksel iletkenlik değerlerinde artışlar gözlemlenmiştir.

**Anahtar kelimeler:** *Phragmites australis*, alg, epifitik, Sivrice, fizikokimyasal özellik, Elâzığ.

### Epiphytic Algae Of A Pond (Tm1 12) Located in Suluçayır Pond (Sivrice - Elâzığ)

**Abstract:** In this study, the composition of algae on the stems and leaves of *Phragmites australis* collected from the TM1 12 Reservoir located in Sulu Çayır Düzü, Sivrice district, Elâzığ province, between April and September 2022, was examined together with some physicochemical properties of the reservoir. A total of 65 taxa belonging to epiphytic algae were recorded. Of these taxa, 1 belonged to Euglenophyta, 4 to Cyanophyta, 7 to Chlorophyta, and 53 to Bacillariophyta. With the increase in light and temperature in summer, increases in the number of Chlorophyta (green) and Cyanophyta (blue-green) individuals were observed, while increases in the number of Bacillariophyta (diatoms) individuals were observed in April and September. Bacillariophyta was the dominant algal group in terms of frequency of occurrence in all months when sampling was performed. As temperatures began to rise in the summer months, decreases in dissolved oxygen and pH values were observed, while increases in electrical conductivity values were noticeable.

**Keywords:** *Phragmites australis*, algae, epiphytic, Sivrice, physicochemical properties, Elâzığ.

### 1. Giriş

Akuatik ekosistemlerdeki çevresel kaynaklı olumsuzlukları belirleyen en iyi biyolojik bileşenlerden biri de alglerdir. Algler lotik ve lentik çevrelerde çok geniş ekolojik niş teşkil ederler. Alglerin büyük bir çoğunluğu ya kayalar (epilitik) ya kumlar (epipsammik) ya çamurlar (epipelik) ya da bitkiler üzerinde (epifitik) yaşarlar. Bu bitkiler, balık, su kuşları ve diğer su canlıları için önemli bir barınma, beslenme, üreme ve predatör canlılardan korunma alanlarını oluştururlar. Bazı algler ise su kalitesinin belirlenmesinde biyomonitör olarak da kullanılırlar [1]. Epifitik algler içerisinde Sığ göllerin alg florasının çoğunluğunu oluşturan epifitik algler aynı zamanda göllerin verimliliğine de büyük ölçüde katkı sağlamaktadır. Ülkemizde epifitik alglerle ilgili yapılan birçok çalışmaya da rastlanılmaktadır. Bu çalışmaların bazılarında araştırmacılar, Çemişgezek Bölgesi (Keban Baraj Gölü)' ndeki *Potamogeton perfoliatus* üzerindeki epifitik algleri [2], İznik Gölü epifitik alg florasını [3], Hazar Gölü (Suluçayır Düzü) epifitik diyatome florasını [4],; Nuphar lutea L. üzerindeki epifitik diyatomelelerini [5], Ladik Gölü epifitik diyatomelelerini [6], Liman Gölü (Bafra/Samsun) epifitik diyatome florasını [7], Cıp Çayı (Elâzığ/Türkiye) epipelik, epilitik ve epifitik alg florasını [8], Topçu Göleti (Yozgat) epilitik ve epifitik alg florasını [9], taşmanlı Göleti (Sinop-Türkiye) epilitik ve epifitik alglerini [10], Sarısu Çayı (Antalya) Örnekleme alanının epipelik, epifitik ve epilitik indikatör alg türlerinin belirlenmesini [11] incelemişlerdir.

*Phragmites L.* Türkçe adıyla Kamışlar, sürünücü toprakaltı gövdeleri bulunan, iri yapılı, çok yıllık su üstü bitkilerindedir. Gövdeleri sağlam olup, çok boğumludur. Yaprak kınları düz yüzeyle olup, kenarları birbiri üzerine binmiştir. Yaprak ayası yassı, şeritsi ve uç bölüme doğru giderek daralır. Çiçek kümesi büyük, tüysü bir salkımdır. *Phragmites*, sulama sistemlerinde çok yaygın olarak bulunan ve sistemlerin işlevlerini önemli derecede aksatan bir su üstü bitkisidir (Şekil, 1). Yalnız başına ya da başta *Typha* cinsi olmak üzere, diğer yabancı otlarla birlikte

\* Sorumlu yazar: [gpala@firat.edu.tr](mailto:gpala@firat.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0003-0535-4177

gelişmekte, boşaltma kanalları ile toprak sulama kanallarında su iletimini olumsuz yönde etkilemektedir. Bu durum göller, ırmaklar, kanallar, bataklıklar, su birikintileri ve deniz kıyılarında yaygın olarak gelişen bu bitkilerle mücadeleyi zorunlu kılmaktadır [12].



**Şekil 1.** *Phragmites australis* (Cav.) Trin. Ex Steudel.

Bu araştırmada Hazar Gölü çevresinde Sivrice İlçesi yol ayrımında yer alan TMİ 12 Göleti' nde sıkça rastlanılan ve istilacı bir tür olan *Phragmites australis*' in hem gövde ve yaprakları üzerindeki algler belirlenerek farklılıklar olup olmadıklarına bakılmış hem de bentik floranın ortaya çıkarılmasına katkı sağlanmıştır. Ayrıca göletteki epifitik alglerin tespit edilmesinin göletin verimlilik açısından değerlendirilmesine de yardımcı olacağı düşünülmüştür. Bu araştırma ile göl verimliliğinin ortaya çıkarılmasına katkı sağlamanın yanısıra göletin yetiştiricilik yapılıp yapılmamasına uygunluğu da bir nebze de olsa araştırılmıştır.

## 2. Materyal ve Metot

Elazığ ili Sivrice ilçesi Suluçayır Düzü' nde konumlanan TMİ 12 göletinin deniz seviyesinden yüksekliği 1249 m olup, 38° 28' 04" N enlem ve 39° 17' 32" E boylamlarındadır. Elazığ merkeze 22 km uzaklıkta olan göletin Diyarbakır merkezine olan uzaklığı 100 km'dir. Elazığ ile Diyarbakır arasındaki karayolunun yirmi ikinci kilometresi ile Elazığ Sivrice arasındaki karayolunun yirmi ikinci kilometreleri arasında bulunmaktadır. Hazar Gölü'ne olan uzaklığı ortalama 500 m mesafededir ve bir uzantısı Kürk Çayı'na dökülmektedir [13]. Tuğla ve kiremit yapımı için bu gölet çevrede bulunan fabrikalar tarafından, tuğla-kiremit üretmek amacı ile toprakların alınmasıyla meydana gelen çukurluk alanların içinin su dolması ile meydana gelmiştir. Kıyısı geniş bitki örtüsüyle kaplı olan Göletin, Kürk Çayı'nın akışa geçtiği dönemlerde Hazar Gölü'ne dökülerek balıklar için iyi bir beslenme ve üreme alanı oluşturduğu bilinmektedir.

Bu araştırmada, Suluçayır Düzü'nde (Sivrice, Elazığ) bulunan TMİ 12 Göleti' nin etrafında yaygın olarak bulunan *Phragmites australis* Nisan-Eylül 2022 tarihleri arasında aylık periyotlarla alınmıştır. Alınan bitki örneklerinin gövde ve yaprakları üzerinde tutunan algler saf su ile yıkanarak önceden steril edilmiş pet şişelere ayrı ayrı konulmuştur. Diyatome dışındaki alglerin tür teşhisleri için gliserinle geçici preparatları hazırlanmıştır. Geçici preparatlarda sayımlar sırasında ünicellüler (tek hücreli) alglerde hücre sayıları baz alınırken, kolonial veya filamentli formlarda her bir koloni veya filament bir organizma olarak kabul edilmiştir. Diyatomelerin tür teşhislerinin yapılabilmesi için de daimi preparatları hazırlanmıştır. Daimi preparatlar için 20 ml numune alınarak üzerine 10 ml HNO<sub>3</sub> + 10 ml H<sub>2</sub>SO<sub>4</sub> ilave edilmiştir. Isı tablası üzerinde 120 °C'de 15 dakika süre ile kaynatılmıştır. Böylece diyatome hücreleri içerisindeki organik yapıların oksidasyonu sağlanmış geriye yalnızca silisyumdan oluşan kabukları kalmıştır. Kaynatılan numuneler, önceden steril edilmiş ve saf sudan geçirilmiş erlenlerin içine konulmuştur. Kaynatılmış örneklerin asitliği saf su ile nötr hale gelinceye kadar hergün değiştirilmiştir. Saf su ile nötrleştirme işlemi sırasında diyatome kabuklarının her yıkama sonunda beherin dibine çökmesi beklenmiş ve çöken kabuklar üzerindeki fazla su dökülerek yerine saf su eklenmiştir. Diyatome

örneklerinin konulduğu lameller üzerindeki örnek kurutulduktan sonra lam üzerine bir miktar entellan sürülmüş ve lameller lamın üzerine yapıştırılmıştır. Preparatta hava kabarcığı bırakmamak için lam ve lamel yapıştırıldıktan sonra lamelin üzerine hafifçe baskı uygulanmıştır [14]. Daimi preparatları yapılan diyatome örneklerinin tür teşhisleri ve sayımları Nikon marka mikroskop ile 10x100 büyütme kullanılarak yapılmıştır. Sürekli preparatlarda yapılan sayımlar için nispi yoğunluk esas alınmış ve sonuçlar (%) organizma olarak verilmiştir. Tür teşhisleri için ilgili kaynaklardan [15-21] yararlanılmıştır.

Makrofitin gövde ve yaprakları üzerinde kaydedilen algler arasındaki benzerliği ortaya çıkarabilmek için Sorenson Benzerlik İndeksi [22] kullanılmıştır.

$$\text{Sorenson Benzerlik İndeksi} : Q/S = 2J/A+B$$

### 3. Bulgular ve Tartışma

Hazar Gölü Suluçayır Düzü' nde yer alan TMİ 12 Göleti' nden ölçülen elektriksel iletkenlik, pH, çözünmüş O<sub>2</sub> ve sıcaklık değerleri aylık olarak Tablo 1'de gösterilmiştir.

**Tablo 1.** TMİ 12 Göleti' nin (Nisan-Eylül 2022) elektriksel iletkenlik, pH, çözünmüş O<sub>2</sub> ve sıcaklık değerleri.

Ölçümler	Nis.	May.	Haz.	Tem.	Ağu.	Eyl.
El. İletkenlik (µS/cm)	702	724	808	874	914	796
pH	10,2	8,6	8,0	7,8	7,0	7,8
Sıcaklık (°C)	10,4	14,2	17,8	21,8	24,5	16,5
Çözünmüş Oksijen (mgO <sub>2</sub> /L)	12,1	10,8	8,7	8,0	7,4	7,8

Tablo 1' e bakıldığında *Phragmites australis*' in toplandığı göletin alkali özellik gösterdiği görülmektedir. Sıcaklık aylara göre düzenli artışlar göstermiştir. En yüksek (24,5 °C) ağustos ayında en düşük (10,4 °C) ise nisan ayında ölçülmüştür. Çözünmüş oksijen ise sıcaklık artışına paralel bir azalış göstermiştir. Çözünmüş oksijen sıcaklığın en fazla olduğu ağustos ayında en düşük (7,4mg O<sub>2</sub>/L) çıkarken , en yüksek (12,1mg O<sub>2</sub>/L) ise sıcaklığın en düşük olduğu nisan ayında kaydedilmiştir. Elektriksel iletkenlik de sıcaklık gibi en yüksek (914 µS/cm) ağustos; en düşük (702 µS/cm) nisan ayında kaydedilmiştir.

Suluçayır Düzü' nde bulunan TMİ 12 Göleti' nden toplanan *Phragmites australis*' in gövde ve yaprakları üzerinde kaydedilen alglerin bulunuş özellikleri Tablo 2'de gösterilmiştir.

**Tablo 2.** *Phragmites australis*' in gövde ve yaprakları üzerinde kaydedilen alglerin bulunuş özellikleri.

Taksonlar	<i>Phragmites australis</i>	<i>Phragmites australis</i>
<b>Cyanophyta</b>	Gövde	Yaprak
<i>Lyngbya martensiana</i> Meneghini ex Gomont	+	-
<i>Lyngbya majuscula</i> Harvey ex Gomont	+	+
<i>Oscillatoria limosa</i> C. Agardh ex Gomont	+	+
<i>Oscillatoria tenuis</i> C. Agardh ex Gomont	+	+
<b>Chlorophyta</b>		
<i>Maugeotia genuflexa</i> (Roth) C. Agardh	+	-
<i>Maugeotia robusta</i> (De Bary) Wittrock	+	-
<i>Maugeotia scalaris</i> Hassal	+	+
<i>Spirogyra cateniformis</i> (Hassal) Kützing	+	+

Suluçayır Düzü (Sivrice - Elaziğ) 'Nde Bulunan Bir Gölet (Tmi 12)' İn Epifitik Algleri

<i>Spirogyra mirabilis</i> (Hassal) Kützing	+	+
<i>Spirogyra splendida</i> G.S. West	+	-
<i>Tetradesmus obliquus</i> (Turpin) H.J. Wynne	-	+
<b>Euglenophyta</b>		
<i>Euglena gracilis</i> G.A. Klebs	+	+
<b>Bacillariophyta</b>		
<i>Amphora ovalis</i> (Kütz.) Kütz.	+	+
<i>Cocconeis pediculus</i> Ehr.	-	+
<i>Cocconeis placentula</i> Ehr.	+	+
<i>Craticula ambigua</i> (Ehr.) D.G.Mann	+	+
<i>Craticula cuspidata</i> (Kütz.) D.G.Mann	-	+
<i>Cymbella affinis</i> Kütz.	+	+
<i>Cymbella aspera</i> (Ehr.) Cleve	+	+
<i>Cymbella cistula</i> (Ehr.) O. Kirchner	+	-
<i>Cymbella cymbiformis</i> C. Agardh	+	+
<i>Cymbella gracilis</i> (Ehr.) Kütz.	+	+
<i>Cymbella helvetica</i> Kütz.	-	+
<i>Cymbella laevis</i> Naegeli	+	+
<i>Cymbella tumida</i> (Brebisson) Van Heurck	-	+
<i>Denticula elegans</i> Kütz.	-	+
<i>Diatoma elongata</i> (Lyngbye) C. Agardh	-	+
<i>Diatoma vulgare</i> Bory.	+	+
<i>Encyonema ventricosum</i> (C. Agardh) Grunow	+	+
<i>Eolimna minima</i> (Grunow) Lange-Bertalot	+	-
<i>Epithemia argus</i> (Ehr.) Kütz.	-	+
<i>Epithemia turgida</i> (Ehr.) Kütz.	-	+
<i>Fragilaria capucina</i> Desmazieres	+	+
<i>Fragilaria crotonensis</i> Kitton	-	+
<i>Gomphonella olivaceoides</i> Hustedt	+	+
<i>Gomphonema parvulum</i> (Kütz.) Kütz.	+	+
<i>Gomphonema acuminatum</i> Ehr.	+	+
<i>Gomphonema constrictum</i> Ehr.	+	+
<i>Gomphonema coronatum</i> Ehr.	+	+
<i>Gomphonema gracile</i> Ehr.	-	+
<i>Iconella elegans</i> (Ehr.) Bukhtiyarova	+	+
<i>Iconella helvetica</i> (Brun) Ruck & Nakov	+	+

<i>Iconella tenera</i> (W. Gregory) Ruck & Nakov	+	-
<i>Navicula cryptocephala</i> Kütz.	+	+
<i>Navicula phyllepta</i> Kütz.	+	+
<i>Navicula trivialis</i> Lange-Bertalot	+	+
<i>Neidium iridis</i> (Ehr.) Cleve	+	+
<i>Neidium productum</i> (W. Smith) Cleve	-	+
<i>Nitzschia communis</i> Rabenhorst	+	-
<i>Nitzschia fonticula</i> (Grunow) Grunow	+	-
<i>Nitzschia linearis</i> W Smith	+	-
<i>Nitzschia palea</i> (Kütz.) W Smith	+	+
<i>Nitzschia sigma</i> (Kütz.) W. Smith	+	+
<i>Nitzschia sigmoidea</i> (Nitzsche) W. Smith	+	+
<i>Pinnularia alpina</i> W. Smith	+	+
<i>Pinnularia viridis</i> (Nitzsche) Ehr.	+	+
<i>Rhoicosphenia abbreviata</i> (C:Agardh) Lange-Bertalot	+	+
<i>Surirella brebissonii</i> Krammer & Lange-Bertalot	+	+
<i>Surirella minuta</i> Brebisson ex Kützing	-	+
<i>Surirella robusta</i> Ehr.	+	+
<i>Tryblionella angustata</i> W. Smith	+	+
<i>Tryblionella apiculata</i> W. Gregory	+	+
<i>Tryblionella hungarica</i> (Grunow) Frenguelli	+	+
<i>Ulnaria acus</i> (Kütz.) Aboal	-	+
<i>Ulnaria ulna</i> (Nitzsche) Compere	+	+

Tablo 2'ye bakıldığında bitkinin gövdeleri üzerinde toplamda 51, yaprakları üzerinde ise 56 tür kaydedilmiştir. Çalışma süresince alglerden bazıları ( Lyngbya martensiana, Mougeotia genuflexa, Spirogyra splendida, Cymbella cistula Eolimna minita, Iconella tenera, Nitzschia communis, Nitzschia fonticula ve Nitzschia linearis) makrofitin yalnızca gövdeleri üzerinde bazıları (Tetrademus obliquus, Cocconeis pediculus, Craticula cuspidata, Cymbella helvetica, Cymbella tumida, Denticula elegans, Diatoma elongata, Epithemia argus, Epithemia turgida, Fragilaria crotonensis, Gomphonema gracile, Neidium productum, Surirella minuta, Ulnaria acus) ise yalnızca yaprakları üzerinde kaydedilmişlerdir. Birey sayıları ve ortaya çıkış sıklıkları bakımından en önemli grubu Bacillariophyta (diyatome) teşkil etmiştir. Diyatome içerisinden en fazla takson (8 takson) sayısı Cymbella' ya ait olurken bu cinsi 6 taksonla Nitzschia ve Gomphonema izlemiştir. Diyatome Nisan ve Eylül aylarında diğer alg gruplarına oranla daha fazla kaydedilmişlerdir. Cyanophyta ve Chlorophyta üyeleri özellikle sıcaklığın arttığı dolayısıyla besin tuzlarının da artmaya başladığı yaz aylarında sayıca daha artmışlardır. Chlorophyta üyeleri hem takson hem de birey sayıları bakımından en fazla Phragmites australis' in gövdeleri üzerinde yoğunlaşmışlardır.

Cyanophyta üyelerinin birey sayılarında eylül ayında da artışlar göze çarpmıştır.

Phragmites australis' in gövde ve yaprakları üzerindeki algler arasındaki soreson benzerlik indeksi %76,63 olarak kaydedilmiştir. Bazı türler substrat olarak gövdeyi tercih ederlerken bazıları da yaprağı tercih etmişlerdir. Bazı türler ise makrofitin hem gövdesini hem de yaprağını kendilerine yaşam alanı olarak seçmişlerdir.

Araştırmanın yapıldığı Hazar Gölü çevresindeki TMİ 12 Göleti' nde epifitik alg florası içerisinde Euglenophyta 1, Cyanophyta 4, Chlorophyta 7 ve Bacillariophyta 53 taksonla kaydedilmişlerdir. Gölet' in aylara göre artan su sıcaklıkları alglerin gelişimini olumlu yönde etkilemiştir. Makrofitin gövdeleri üzerindeki takson sayısı (51), yapraklara göre (56) düşük kalmasına rağmen birey sayılarında tam tersi bir durum gözlenmiştir. Gövdeler üzerinde kaydedilen alg gruplarına ait birey sayıları, yapraklar üzerinde kaydedilen birey sayılarından çok daha fazla olmuştur. Bu durum toprak ve sudaki besin elementlerini alglerin daha kolay değerlendirebildiklerinin bir göstergesi olabilmektedir.

*Phragmites australis*' in gövde ve yaprakları üzerinde Cyanophyta ve Chlorophyta üyeleri tüm aylarda da ortaya çıkmış olup özellikle mayıs ve haziran aylarında sayıca aşırı çoğalmışlardır. Filamentli olan alglerin herbir filamentli bir hücre kabul edilmiştir. Özellikle mayıs ayında *Spirogyra mirabilis* diğer alg gruplarına oranla dominant bir artış (38 fl/ml) göstermiştir.

Round [30], Mavi- yeşil alglerden *Anabaena*, *Aphanizomenon*, *Lyngbya Microcystis*, ve *Oscillatoria* türlerinin özellikle yaz aylarında oldukça yaygın olduğunu belirterek bu alglerin ötrofik sularda daha iyi gelişme gösterdiklerini vurgulamıştır. Çalışmamızda bu cinslerden yalnızca *Lyngbya* ve *Oscillatoria* türlerine rastlanılmıştır. Bu cinslere ait türlerin birey sayılarında ve ortaya çıkış sıklıklarında yaz aylarında artış dikkat çekmiştir.

Euglenophyta' ya ait yalnızca tek bir tür (*Euglena gracilis*) kaydedilmiştir. Bu tür, makrofitin hem gövdesi hem de yaprakları üzerinde bulunmasına rağmen, birey sayıları olarak en fazla (28 hücre/ml) ağustos ayında kaydedilmişlerdir. *Euglena gracilis*, yüksek miktarda azotlu madde içeren tatlı su göletlerinde ve *Sphagnum* bataklıklarında yaygın olarak bulunur. Acı sularda da bulunmaktadır [23].

*Phragmites australis*' in gövde ve yaprakları üzerinde hem ortaya çıkış sıklığı hem de birey sayıları bakımından en önemli cinsler (*Cymbella*, *Gomphonema* ve *Nitzschia* ) Bacillariophyta' ya ait olmuşlardır. Elazığ ve çevresindeki yüzey su kaynaklarında alglerle ilgili yapılan diğer çalışmalarda [4], [24], [25], [26], [27], [28] da Bacillariophyta' nın diğer alg gruplarına göre dominant olduğu ve *Gomphonema*, *Navicula*, *Cymbella* ve *Nitzschia* cinslerinin ise çok türle temsil edildiği rapor edilmiştir. Dolayısıyla bulgular bu cinslere ait türlerin buldukları habitatları diğer diyatomelere oranla daha iyi değerlendirip çoğalabildiklerine dikkat çekmektedir. Özellikle *Nitzschia* ve *Navicula* türlerinin kozmopolit oldukları [29] tarafından da vurgulanmıştır.

Suluçayır Düzü (Hazar Gölü) epifitik diyatome florası başlıklı çalışmada [4] *Ranunculus rinoii* ve *Ranunculus aquatilis* üzerindeki diyatomeler içerisinde *Ulnaria ulna*, *Cymbella affinis*, *Amphora ovalis* ve *Epithemia turgida* önemli türler olmuşlardır. Çalışmamızda aynı türler tüm aylarda ortaya çıkış sıklıkları ve birey sayıları bakımından hem gövde (*Epithemia* hariç) hem de yapraklar üzerinde en önemli diyatomeler olmuşlardır. *Epithemia*' ya ait türlere ise yalnızca yapraklarda rastlanılmış, gövdede rastlanılmamıştır.

*Cocconeis* spp., *Cymbella* spp., *Navicula* spp. ve *Ulnaria* spp., genelde iç suların tipik epifitik ve epipelik türleri olarak rapor edilmişlerdir [30,31]. Bahsedilen cinslere ait türlere çalışmamızda bolca rastlanılmıştır.

*Ulnaria* türlerinin değişen tuzluluk ve pH seviyelerinden fazla etkilenmedikleri [32] tarafından rapor edilmiştir. Aynı zamanda bu cinsin kalsiyumca zengin suları sevdiği [31] tarafından da vurgulanmıştır. Çalışmamızda *Ulnaria* cinsine *Phragmites australis*' in hem gövde hem de yaprakları üzerinde sıkça rastlanılmıştır.

*Chlamydomonas*, *Euglena*, *Oscillatoria*, *Phormidium* ve *Ulnaria* cinslerine ait türlerin kirliliğe karşı toleranslarının yüksek olduğu belirtilerek, *Nitzschia palea*, *Oscillatoria limosa* ve *Oscillatoria tenuis*' in organik kirlenmenin mevcut olduğu sularda daha fazla bulunduğu ifade edilmiştir [33]. Çalışmamızda bu sayılan türlerin kaydedilmiş olması özellikle ilkbahar ve yaz aylarında fazla birey sayılarıyla kaydedilmiş olmaları TMİ 12 Göleti' nde de kirliliğin olabileceğini ortaya koymaktadır.

Diyatomelerdeki en fazla birey sayılarına temmuz ve ağustos aylarında rastlanılmıştır. Yazın ışık süresinin ve yoğunluğunun artmasıyla makrofitler üzerindeki alglerin tür zenginliği, bolluk ve biomasının değişebileceği başka bir araştırmacı tarafından da vurgulanmıştır [3].

Ülkemizde yapılan birçok alg çalışmalarında [2-11; 24-28] da Bacillariophyta' nın hem bentik hem de planktonik bölgenin baskın algleri oldukları sıkça rapor edilmiştir.

## 5. Sonuçlar ve Öneri

Genel olarak alglerin gelişimi üzerinde sıcaklık ve ışığın etkili olduğu bilinen bir gerçektir. Bu çalışmada da özellikle yaz başlarında tüm alglere ait birey sayılarında gözle görülür bir artış kaydedilmiştir. Algler aynı zamanda su kalitesi belirlemede uzun vadede kullanılan temel organizma guruplarındandır. Alg çalışmaları, ileride bu su kaynaklarının fiziksel ve kimyasal özellikleri de belirlenerek yapılırsa daha verimli sonuçlara ulaşılabilir.

Besin zincirinin ilk halkasını oluşturan algler aynı zamanda suların en önemli oksijen kaynağıdır. Akuatik ortamlarda alglerin birey sayıları ve ortaya çıkış sıklıklarının bilinmesi ortamların yetiştiricilik yapılmasına olanak sağlaması açısından da önemlidir.

Aynı zamanda çalışmamız da bir kez daha şunu gördük ki, diyatomeleler kozmopolit olup, ortam şartlarını silisyumlu kabukları sayesinde diğer alg gruplarına göre daha iyi değerlendiren ve her yerde kolayca bulunabilen bir alg grubu olarak her zaman karşımıza çıkmayı başaracaklardır.

### Kaynaklar

- [1] Charles vd., (1994). Appendix C:Paleolimnological Sampling (Sedimented Diatoms), Lake and Reservoir Bioassessment and Biocriteria: Technical Guidance Document,156 p.
- [2] Şen, B. ve Pala, G., (2001a). Çemişgezek Bölgesi (Keban Baraj Gölü)' ndeki Potamogeton perfoliatus L., üzerindeki epifitik algler, XI. Ulusal Su Ürünleri Sempozyumu, s:206-215, Hatay.
- [3] Albay, M., & Aykulu, G. (2002). Invertebrate Grazer - Epiphytic Algae Interactions on Submerged Macrophytes in a Mesotrophic Turkish Lake. Ege Journal of Fisheries and Aquatic Sciences, 19(1).
- [4] Pala, G., (2014). Hazar Gölü (Suluçayır Düzü) Epifitik Diyatome Florası, Fırat Üniv. Fen Bil. Der.,
- [5] Soylu, E.N., Maraşlıoğlu, F., Gönüloğlu, A., (2005). Epiphytic diatoms on Nuphar lutea L.' in three shallow TurkishLakes. Journal of Freshwater Ecology 20 (44): 791-792.
- [6] Maraşlıoğlu, F., Soylu, E.N., Gönüloğlu, A., (2007). Seasonal variation and occurrence of diatoms in mats of Cladophora glomerata (Chlorophyta) in Lake Ladik, Turkey. Cryptogamie Algologie 28 (4):373-384.
- [7] Soylu, E.N., Maraşlıoğlu, F. and Gönüloğlu, A., (2011). Liman Gölü (Bafra-Samsun) Epifitik diyatome florası. Ekoloji 20, 79, 57-62.
- [8] Çetin, A.K. ve Yavuz, O.G., (2001). Cip Çayı (Elazığ/Türkiye) epipelik, epilitik ve epifitik alg florası. F.Ü. Fen ve Müh. Bil. Derg., 13, 2, 9-14.
- [9] Akköz, C. ve Güler, S., (2004). Topçu Göleti (Yozgat) alg florası I: Epilitik ve Epifitik algler, Cilt:0, Sayı:23, 7-14.
- [10] Gümüş, F. ve Gönüloğlu, A., (2017). Taşmanlı Göleti (Sinop-Türkiye) epilitik ve epifitik algleri. Karadeniz Fen Bil. Derg., 7 (1), 102-116.
- [11] Atıcı, T., Taflı, T., Solak, C., (2018). Epipelik, epifitik ve epilitik indicator alg türlerinin belirlenmesi; Sarısu çayı (Antalya) Örnekleme alanı. Biological Diversity and Conservation Cilt:11, Sayı:3, 174-179.
- [12] Altınayar, G., 1988. Water weirs, Ministry of public works and settlement general directorate of state and water affairs, Ankara, Turkey. 239 P.
- [13] DSİ. 1960. Water analyses report of Elazığ Uluova, belonging to Hazar Lake, (in Turkish). Institute of soil and manure researches, 603-606, 26 (1), 45-51.
- [14] Round, F. E., (1953). An Investigation of Two Benthic Algal Communities Malham Tarn. J. Ecol. 41, 174-179.
- [15] Bourrelly, P., (1972). Les Algues D'eau Douce, Tome I ; Les Algues Vertes. Paris: Edition N.Boubee & Cie3.
- [16] Prescott, G. W., (1975). Algae of The Western Great Lakes Area. Michigan: W. M. C. Brown Company Publishers.
- [17] Germain, H., 1981. Flora Des Diatomées: Diatomophcées des eaux douces et saumâtres du Massif Armoricaïn et des contrées voisines d'Europe occidentale, Société. Nouvelle des Editions Boubée, Paris.
- [18] Krammer, K.ve Lange-Bertalot, H., (1986). Süßwasserflora von Mitteleuropa, Bacillariophyceae Band 2/1, 1. Teil: Naviculaceae. Stuttgart: Gustav Fischer Verlag.
- [19] Krammer, K.ve Lange-Bertalot, H., (1988). Süßwasserflora von Mitteleuropa, Bacillariophyceae Band 2/2, 2. Teil: Bacillariaceae, Epithemiaceae, Surirellaceae. Stuttgart: Gustav Fischer Verlag.
- [20] Krammer, K. ve Lange-Bertalot, H., (1991a). Süßwassers von Mitteleuropa, Bacillariophyceae Band 2/3, 3. Teil: Centrales, Fragilariaceae. Stuttgart: Gustav Fischer Verlag.
- [21] Krammer, K. ve Lange-Bertalot, H., (1991b). Süßwassers von Mitteleuropa, Bacillariophyceae Band 2/4, 4. Teil: Achnanthaceae, Kritische Ergänzungen zu Navicula.
- [22] Sørensen, T., (1948). "A method of establishing groups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on Danish commons". Kongelige Danske Videnskaberne Selskab 5 (4): 1-34.
- [23] David M.; Whitton, Brian A.; Brook, Alan J. (2021). Britanya Adaları'nın Tatlı Su Yosun Florası (2. basım). Cambridge University Press. s. 896.
- [24] Demirkapı, S. ve Pala, G., (2016). Bir Balık üretim tesisi toprak havuzlarda yetişen Ceratophyllum demersum L.' un epifitik algleri. Fırat Üniversitesi Fen Bilimleri Dergisi, 28 (1), 47-54.
- [25] Şen, B., Pala (Toprak), G., (2001). Çemişgezek Bölgesi (Keban Baraj Gölü)' ndeki Potamogeton perfoliatus L., Üzerindeki Epifitik Algler, XI. Ulusal Su Ürünleri Sempozyumu Bildirileri, 206-215.
- [26] Şen, B. ve Pala, G., (2001b). Dipsiz Göl ve Kırk Gözeler (Elazığ) kaynak sularında ortaya çıkan diyatomeleler ve mevsimsel değişimleri, İstanbul Üniv. Su Ürünleri Dergisi,12:1-13.
- [27] Yüce, A. ve Ertan; O.Ö., 2001.Kovada Gölü epifitik algleri(Isparta-Türkiye), XI. Ulusal Su Ürünleri Sempozyumu. S:216-224, 04-06 Eylül, Hatay.
- [28] Özer, G., Pala, G., (2009). Suluçayır Düzü (Sivrice-Elazığ)" nde bulunan bir gölet (TMİ 12)" in fitoplanktonik algleri ve mevsimsel değişimleri-I Bacillariophyta. XV. Ulusal Su Ürünleri Sempozyumu, 01-04 Temmuz, Rize.

- [29] Chessman, B.C., (1986). Diatom flora of an Australian River System: Spatial patterns and Environmental relationships. *Freshwater Biology*, 16, 805-819.
- [30] Round, F.E., (1981). *The Ecology of Algae*, Cambridge University Pres, Cambridge. London, New York, New Rochelle, Melbourne, Sydney, 1-65.
- [31] Hutchinson, G. E., (1957). *A treatise on Limnology. Vol:2, Introduction to lake biology and the limnoplankton*. John Wiley Sons. Inc. New York.
- [32] Hancock, F.D., (1973). The Ecology of Diatoms of the Klip River, Southern transvaal. *Hydrobiologia*, 42, 2-3.
- [33] Palmer, C.M., (1980). *Algae and Water Pollution*, Castle House Pub. Ltd. New York.