

ELEKTRİK-ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

ALANINDA ARAŞTIRMALAR VE DEĞERLENDİRMELER



EDİTÖR

Doç Dr. Yelda KARATEPE MUMCU

ARALIK 2025

YAYIN KODU

gece
kitaplığı

İmtiyaz Sahibi / Yaşar Hız
Yayına Hazırlayan / Gece Kitaplığı

Birinci Basım / Aralık 2025 - Ankara
ISBN / 978-625-8570-39-7

© copyright

Bu kitabın tüm yayın hakları Gece Kitaplığı'na aittir.

Kaynak gösterilmeden alıntı yapılamaz, izin almadan hiçbir yolla çoğaltılamaz.

Gece Kitaplığı

Kızılay Mah. Fevzi Çakmak 1. Sokak

Ümit Apt No: 22/A Çankaya/ANKARA

0312 384 80 40

www.gecekitapligi.com / gecekitapligi@gmail.com

Baskı & Cilt

Bizim Büro

Sertifika No: 42488

**ELEKTRİK-ELEKTRONİK VE
HABERLEŞME MÜHENDİSLİĞİ
ALANINDA ARAŞTIRMALAR VE
DEĞERLENDİRMELER**

ARALIK 2025

EDİTÖR

Doç Dr. Yelda KARATEPE MUMCU

gece
kitaplığı

İÇİNDEKİLER

BÖLÜM 1

ELMA YAPRAĞI HASTALIKLARININ TESPİTİNDE CNN VE VİT MİMARİLERİNİN KARŞILAŞTIRMALI ANALİZİ

Müslüm GÜR, Teyfik ATAMAN 7

BÖLÜM 2

GERÇEK SÜRÜCÜ DAVRANIŞLARI İLE ŞERİT DEĞİŞTİRME EYLEMİNİN YAPAY SİNİR AĞLARI (YSA) İLE TAHMİN EDİLMESİ

Ali GÜNEŞ, Bahadır ÇOKÇETİN 25

BÖLÜM 3

UYGULAMAYA ÖZGÜ ENTEGRE DEVRE (ASIC) TASARIM AKIŞI VE METODOLOJİSİ

Bahadır ÖZKILBAÇ 45

BÖLÜM 4

RÜZGAR ENERJİSİ TAHMİNİNDE KULLANILAN FİZİKSEL VE VERİ ODAKLI İSTATİSTİKSEL YÖNTEMLERİN İNCELENMESİ

Merve DEMİRCİ, Fatih UYSAL 59

BÖLÜM 5

ELEKTRİKLİ ŞARJ İSTASYONU İÇEREN GÜÇ SİSTEMLERİNDE OPTİMUM REAKTİF GÜÇ DAĞITIMI OPTİMİZASYONUNU

Mehmet ÇEÇEN 75

BÖLÜM 6

5G AĞLARDA MAKİNE ÖĞRENMESİ DESTEKLİ OPTİMİZASYON: MEVCUT YAKLAŞIMLAR VE 6G'YE BAKIŞ

Asuman SAVAŞCIHABEŞ 89

BÖLÜM 1

ELMA YAPRAĞI HASTALIKLARININ TESPİTİNDE CNN VE VİT MİMARİLERİNİN KARŞILAŞTIRMALI ANALİZİ

Müslüm GÜR¹, Tevfik ATAMAN²

¹ Öğr. Gör., Çankırı Karatekin Üniversitesi/Meslek Yüksekokulu/Elektronik ve Otomasyon Bölümü/Elektronik Teknolojisi Programı, muslumgur@karatekin.edu.tr, ORCID: 0000-0002-4842-5345

² Öğr. Gör. Dr., Çankırı Karatekin Üniversitesi/Meslek Yüksekokulu/Makine ve Metal Teknolojileri Bölümü/Makine Programı, tevfikatanman@karatekin.edu.tr, ORCID 0000-0003-1346-5651

1. GİRİŞ

Tarımsal üretim, küresel gıda güvenliğinin sağlanması ve ekonomik istikrarın sürdürülmesi açısından kritik bir öneme sahiptir. Bu bağlamda elma, besin değeri ve ticari hacmiyle dünya genelinde en çok yetiştirilen meyvelerden biridir(Bansal et al., 2021; Doutoum & Tugrul, 2025). Ancak elma üretimi, verim ve kaliteyi doğrudan tehdit eden çeşitli biyotik stres faktörleri ile karşı karşıyadır. Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) verilerine göre, bitki hastalıkları ve zararlıları küresel mahsul üretiminde %40'a varan kayıplara neden olmaktadır(Baranwal et al., 2019; Organization, 2024). Özellikle elma bahçelerinde yaygın olarak görülen Kara Leke (*Venturia inaequalis*), Sedir Elma Pası (cedar apple rust) ve *Alternaria* gibi mantar kaynaklı hastalıklar, erken teşhis edilmediklerinde epidemiyeye dönüşerek üreticiler için ciddi ekonomik kayıplara yol açabilmektedir(Bansal et al., 2021). Geleneksel tarım uygulamalarında hastalık yönetimi, büyük ölçüde uzmanların bahçeleri görsel olarak incelemesine ve semptomları manuel olarak teşhis etmesine dayanmaktadır. Ancak bu yaklaşım; yoğun bir çaba gerektirmesi, zaman alması ve uzmanların öznel değerlendirmelerine açık olması nedeniyle hata oranı oldukça yüksektir(Dutot et al., 2013; Jiang et al., 2019). Ayrıca, görsel incelemeye dayalı gecikmiş teşhisler, çiftçilerin aşırı veya yanlış kimyasal ilaç kullanmasına neden olarak hem üretim maliyetlerini artırmakta hem de çevresel sürdürülebilirliği tehdit etmektedir (Sangeetha et al., 2022).

Bu zorlukların üstesinden gelmek amacıyla, son yıllarda bilgisayarlı görü ve makine öğrenimi (ML) teknikleri bitki hastalıklarının tespitinde önemli bir araç haline gelmiştir(Arivazhagan et al., 2013; Chuanlei et al., 2017). Erken dönem çalışmalarında, hastalık tespiti için görüntü işleme teknikleri (K-means kümeleme vb.) ve Destek Vektör Makineleri (SVM) gibi geleneksel makine öğrenimi algoritmaları kullanılmıştır(Al Bashish et al., 2011). Örneğin, elma hastalıklarının sınıflandırılmasında K-means kümeleme tabanlı segmentasyon ve SVM kullanımı ile başarılı sonuçlar elde edilmiştir(Dubey & Jalal, 2012). Benzer şekilde, genetik algoritmalar ve korelasyon tabanlı özellik seçimi kullanılarak elma yaprak hastalıklarının %90'ın üzerinde bir doğrulukla tespit edilebildiği çalışmalar literatürde yer almaktadır(Chuanlei et al., 2017). Ancak bu yöntemler, el ile öznitelik çıkarımı gerektirmeleri ve karmaşık arka planlara sahip görüntülerde performans düşüşü yaşamaları nedeniyle sınırlı kalmıştır. Derin öğrenme (DL) teknolojilerindeki ve özellikle Evrimsel Sinir Ağlarındaki (CNN) gelişmeler, bitki hastalıklarının otomatik tespiti ve sınıflandırılmasında bir paradigma değişimine neden olmuştur. CNN mimarileri, ham görüntülerden karmaşık özellikleri otomatik olarak öğrenebilme yetenekleri sayesinde geleneksel yöntemlere kıyasla daha üstün bir performans sergilemektedir(Chuanlei et al., 2017; Howard, 2013). Elma yaprağı hastalıkları özelinde yapılan çalışmalarda, AlexNet, GoogleNet, VGG16 ve ResNet gibi mimariler yaygın olarak kullanılmış ve %90'ın üzerinde doğruluk oranlarına ulaşılmıştır (Bansal et al., 2021; He et al., 2016; Jiang et al., 2019; Krizhevsky et al., 2012; Liu et al., 2017; Nachtigall et al., 2016; Szegedy et al., 2015). Özellikle ResNet mimarisi, derin ağların eğitimini kolaylaştırması ve kaybolan gradyan problemini aşması nedeniyle en başarılı modellerden biri olarak öne çıkmaktadır(Thakur et al., 2023). Bununla birlikte, CNN mimarileri görüntüdeki yerel özellikleri (kenar, doku vb.) çıkarmada son derece başarılı olsa da, görüntünün tamamındaki uzun menzilli bağımlılıkları ve global bağlamı yakalamada sınırlı kalabilmektedir. Bu sınırlılığı aşmak için literatürde son yıllarda Vision Transformer (ViT) tabanlı yaklaşımlara ve hibrit modellere doğru bir yönelim başlamıştır. Si ve arkadaşları, CNN ve Swin Transformer yapılarını entegre eden çift kollu bir model önererek, elma yaprağı hastalıklarında hem yerel hem de global özelliklerin yakalanmasıyla %97.32 doğruluk oranına ulaşmıştır(Si et al., 2024). Benzer şekilde Li ve Tanone, patates yaprağı hastalıklarında Swin Transformer kullanarak %97.70 doğruluk elde etmiş ve bu mimarinin tarımsal görüntü analizindeki potansiyelini ortaya

koymuştur(Li & Tanone, 2023). Ayrıca, dikkat mekanizmalarının ResNet gibi CNN modellerine entegre edilmesiyle, modelin hastalığın bulunduğu kritik bölgelere odaklanma yeteneğinin artırıldığı ve %96.69 gibi yüksek başarımlar elde edildiği literatürde mevcuttur(SUN et al., 2024).Tüm bu gelişmelere rağmen, elma yaprağı hastalıklarının tespiti hala çeşitli zorluklar barındırmaktadır. Hastalık lekelerinin boyutlarının değişkenliği, özellikle erken evrelerdeki küçük lekelerin tespiti, karmaşık arka planlar ve değişen ışık koşulları modellerin genelleme yeteneğini zorlamaktadır(Bochkovskiy et al., 2020; Khan et al., 2022). Ayrıca, benzer görsel özelliklere sahip hastalıkların (örneğin Alternaria ve Gri Leke) birbirine karıştırılması, sınıflandırma modelleri için önemli bir problem teşkil etmektedir(Liu & Li, 2024).

Bu çalışmada, CNN tabanlı yerleşik mimariler (ResNet-50, EfficientNet-B0, ConvNeXt) ile yeni nesil Vision Transformer (ViT) tabanlı yaklaşımlar (Swin-T, MaxViT) karşılaştırılmış; doğruluk, sınıf bazlı performans metrikleri ve hesaplama maliyeti açısından kullanılan veri seti üzerinde elma yaprağı hastalıklarının tespitinde en etkili derin öğrenme stratejileri belirlenmiştir. Modeller yalnızca tek seferlik değerlendirmeye tabi tutulmamış, aynı zamanda çapraz doğrulama yöntemi kullanılarak sonuçların güvenilirliği ve genellenebilirliği de analiz edilmiştir.

2. MATERYAL VE METOT

2.1. Veri Seti

Bu çalışmada, elma ağaçlarında yaygın olarak görülen hastalıkların tespiti için toplam 1730 adet elma yaprağı görüntüsü kullanılmıştır. Bu veri kümesi, Washington Eyaleti Seattle'da düzenlenen Bilgisayar Görme ve Örüntü Tanıma (CVPR) 2020'deki İnce Taneli Görsel Sınıflandırma (FGVC) atölyesi için düzenlenen Kaggle Bitki Patolojisi Yarışması'ndan elde edilmiştir(*Apple Leaf Disease Dataset [Online]. Available: <https://www.kaggle.com/datasets/nirmalsankalana/apple-leaf-disease-dataset>, 2023; Thapa et al.; Thapa et al., 2020*). Bu veri kümesinde 3 sınıf bulunmaktadır.

2.1.1.Sağlıklı (Healthy): Şekil 1'de sağlıklı yaprakların tamamen lekesiz ve herhangi bir hastalık belirtisi göstermeyen yeşil renkli olduğu görülmektedir. Veri setimiz yaklaşık %29,82 oranında sağlıklı yaprak içermektedir.



Şekil 1.*Sağlıklı yaprak.*

2.1.2. Paslanmış (Rust): Şekil 2'de *Gymnosporangium juniperi-virginianae* mantarının neden olduğu, yaprak üzerinde sarı/turuncu lekelerle karakterize edilen hastalıktır. Veri setimiz yaklaşık olarak %35,95 oranında paslanmış yapraktan oluşmaktadır.



Şekil 2. *Pashlı yaprak.*

2.1.3. Kara Leke (Scab): Şekil 3’te *Venturia inaequalis* mantarının neden olduğu, kahverengi veya zeytin yeşili lekelerle kendini gösteren hastalıktır. Veri setinin yaklaşık olarak %34,21’ini oluşturmaktadır.




Şekil 3. *Kara lekeli yaprak.*

2.2. Kullanılan Derin Öğrenme Mimarileri

2.2.1. Evrişimli Sinir Ağları (CNN)

Bu çalışmada kullanılan derin öğrenme modellerinin (ResNet50, EfficientNetB0 vb.) temelini Evrişimli Sinir Ağları (CNN) oluşturmaktadır. CNN’ler, grid benzeri topolojiye sahip verileri işlemek için özelleşmiş, biyolojik görsel korteksten esinlenen çok katmanlı yapay sinir ağlarıdır (LeCun et al., 2015). Şekil 4’te gösterilen CNN mimarisi temel olarak iki ana bloktan oluşur: Birincisi görüntüden hiyerarşik özniteliklerin öğrenildiği özellik çıkarımı bloğu ve ikincisi özelliklere dayanarak tahminin yapıldığı sınıflandırma bloğudur (Goodfellow et al., 2016).



Şekil 4. *Evrişimli Sinir Ağları mimarisi.*

Evrişim Katmanı (Convolutional Layer): Ağın temel yapı taşıdır. Öğrenilebilir filtreler giriş görüntüsü üzerinde gezdirilerek kenar, doku ve şekil gibi yerel özellik haritaları oluşturulur. Bu işlem, ağırlık paylaşımı sayesinde parametre sayısını önemli ölçüde azaltır (Albawi et al., 2018).

Aktivasyon Fonksiyonu (ReLU): Evrişim işleminden sonra, ağa doğrusal olmayan (non-linear) özellikler kazandırmak için genellikle Düzeltilmiş Doğrusal Birim (ReLU) fonksiyonu ($f(x) = \max(0, x)$) uygulanır. Bu, modelin karmaşık örüntüleri öğrenmesini sağlar (Nair & Hinton, 2010).

Havuzlama Katmanı (Pooling Layer): Özellik haritalarının boyutunu küçültmek hesaplama yükünü azaltır ve modelin konumdan bağımsız özellikler öğrenmesine yardımcı olur.

Tam Bağlantılı Katman (Fully Connected Layer): Özellik çıkarımı aşamasından gelen 2 boyutlu matrisler düzleştirilerek 1 boyutlu vektörlere dönüştürülür ve standart bir yapay sinir ağına iletilir. Bu katman, çıkarılan özellikleri kullanarak nihai sınıflandırma olasılıklarını üretir (Krizhevsky et al., 2012).


2.2.1.2. Kullanılan CNN Modelleri

ResNet: Derin ağların eğitiminde karşılaşılan kaybolan gradyan problemini çözmek amacıyla geliştirilen ResNet, mimarisi literatüre kazandırıldı (He et al., 2016). ResNet'in özündeki ana fikir ağ içinde bazı katmanların atlanmasına olanak tanıyan artık bağlantıların kullanılmasıdır. Böylece model, girdiyi doğrudan çıktıya dönüştürmeyi öğrenmek yerine, ikisi arasındaki farkı yani kalıntı fonksiyonunu öğrenerek daha etkili bir şekilde eğitilir.

EfficientNet: Model performansını artırmak için genellikle derinlik, genişlik veya çözünürlük parametrelerinden sadece biri artırılırken; EfficientNet ailesi bu üç bileşeni "bileşik ölçekleme" yöntemiyle dengeli bir şekilde optimize eder (Tan & Le, 2019).

ConvNeX: Vision Transformer (ViT) modellerinin başarısından ilham alarak tasarlanan ConvNeX, standart CNN bloklarını modernize eden bir CNN mimarisidir (Liu et al., 2022). Bu model; daha büyük çekirdek boyutları (7*7 kernel), Katman Normalleştirme kullanımı ve aktivasyon fonksiyonu olarak ReLU yerine Gauss Hata Doğrusal Birimi (GELU) kullanımı gibi modern ViT stratejilerini CNN yapısına entegre etmiştir. ConvNeX, saf evrişimli yapısını koruyarak Transformer modellerinin doğruluğuna ulaşmayı hedeflerken, CNN'lerin hesaplama verimliliğini de bünyesinde barındırmaktadır.

2.2.2. Vision Transformer (ViT) ve Hibrit Modeller:



Şekil 5. Vision Transformer (ViT) mimarisi (Cutur & Inan, 2025; Dosovitskiy, 2020).

Şekil 5'te verilen Vision Transformer (ViT) mimarisi, konvolüsyonel olmayan ve tamamen dikkat mekanizmasına dayanan bir mimaridir. Doğal Dil İşleme (NLP) alanında geliştirilen Transformer yapısının görüntü sınıflandırma problemlerine uyarlanmasıyla ortaya çıkan bu model, giriş görüntüsünü bir kelime dizisi gibi işler (Dosovitskiy, 2020).

Düzleştirilmiş Yamaların Doğrusal İzdüşümü (Linear Projection of Flattened Patches)

Standart CNN modellerinin aksine ViT, tüm görüntüyü piksel piksel işlemek yerine, görüntüyü sabit yamalara böler. $H \times W \times C$ boyutundaki bir elma yaprağı görüntüsü, N adet yamaya ayrıştırılır. Her bir yama düzleştirilerek 1 boyutlu bir vektör haline getirilir ve eğitilebilir bir doğrusal katman aracılığıyla D boyutlu bir gömme uzayına yansıtılır.

Konumsal Gömme (Positional Embedding)

Transformer mimarisi, doğası gereği verinin sırasından bağımsızdır. Görüntü içerisindeki yamaların uzamsal konum bilgisini (hangi yamanın nerede olduğunu) korumak için, yamaların gömme vektörlerine öğrenilebilir konumsal kodlamalar eklenir (Vaswani et al., 2017). Ayrıca, sınıflandırma işleminin yapılabilmesi için dizinin en başına öğrenilebilir bir sınıflandırma belirteci dâhil edilir (Devlin et al., 2019).

Transformer Kodlayıcı (Transformer Encoder)

Çok Başlı Dikkat (Multi-Head Self-Attention - MSA): Bu mekanizma, modelin görüntünün farklı bölgelerindeki yamalar arasındaki ilişkileri aynı anda öğrenmesini sağlar. Her bir "baş", görüntünün farklı bir anlamsal ilişkisine odaklanır.

Çok Katmanlı Algılayıcı (Multi-Layer Perceptron - MLP): Genellikle iki doğrusal katman ve bunlar arasında bir aktivasyon fonksiyonundan (GELU) oluşur (Hendrycks, 2016). Eğitim kararlılığını artırmak için, her Çok Başlı Dikkat (MSA) ve Çok Katmanlı Algılayıcı (MLP) bloğundan önce Katman Normalleştirme (LN) uygulanır ve her bloğun çıkışına yeni bağlantılar eklenir (Ba et al., 2016).

Sınıflandırma Başlığı (MLP Head):

Transformer kodlayıcıdan çıkan belirtecinin vektörü, tüm görüntünün özet niteliğindeki temsildir. Bu vektör, son bir MLP katmanına verilerek elma yaprağı hastalık sınıflarına (Örn: Healthy, Scab, Rust) ait olasılık skorlarına dönüştürülür.

2.2.2.1. Kullanılan ViT Modelleri

Swin Transformer (Swin_T): Standart ViT modellerinin yüksek çözünürlüklü görüntülerde yaşadığı hesaplama darboğazını aşmak için geliştirilen Swin Transformer, hiyerarşik bir yapı sunmaktadır. Bu model, dikkati üst üste binmeyen pencereler içinde hesaplar ve "kaydırılmış pencere" mekanizması ile pencereler arası bilgi akışını sağlar. Çalışmada kullanılan Swin-T, bu ailenin en hafif versiyonu olup, CNN benzeri hiyerarşik yapısı sayesinde hem yerel hem de global özellikleri verimli bir şekilde öğrenerek, parametre sayısı ile başarı arasında ideal bir denge kurmaktadır (Liu et al., 2021).

MaxViT: Google Research tarafından geliştirilen MaxViT, ölçeklenebilir ve verimli bir hibrit mimaridir. Modelde, "Çok Eksenli Dikkat" adı verilen yeni bir mekanizma kullanılmaktadır. Bu mekanizma, görüntüyü yerel pencerelere bölerek işleyen "Blok Dikkat" ve seyrek bir ızgara yapısı üzerinde çalışan "Izgara Dikkat" bileşenlerinden oluşur. MaxViT, bu sayede doğrusal karmaşıklıkla hem yerel hem de global etkileşimleri yakalayarak, özellikle büyük veri setlerinde ve yüksek çözünürlüklerde üstün performans sergilemektedir (Tu et al., 2022).

2.3. Performans Değerlendirme Metrikleri

Sınıflandırmanın etkilerini belirlemek için performans metrikleri önemlidir. Bu çalışmada, 5 kat çapraz doğrulama da doğruluk, F1 skoru, kesinlik, geri çağırma ve AUC değerleri dikkate alınmıştır. Bu ölçütlerin performanslarını gösteren temel göstergeler, doğru pozitifler (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatiftir (FN). Burada doğru negatif (TN) doğru şekilde negatif olarak belirlenen numune, yanlış negatif (FN) ise pozitif bir numunenin yanlışlıkla negatif olarak belirlenmesi demektir. Tam tersi olarak da doğru pozitif (TP) numunenin pozitif olarak doğru belirlenmesi, yanlış pozitifin (FP) ise negatif olan bir numunenin yanlışlıkla pozitif olduğu demektir (Inan et al., 2024). Ölçütlere ait matematiksel ifadeler tablo 1'de verilmiştir.

Tablo 1

Sınıflandırma İçin Performans Metriklerinin Formülleri

Performans Metrikleri	Formüller
Doğruluk	$\frac{TP + TN}{TP + TN + FP + FN}$
Duyarlılık	$\frac{TP}{TP + FN}$
Geri çağırma	$\frac{TP}{TP + FP}$
F1-skoru	$\frac{2 \times TP}{2 \times TP + FP + FN}$
AUC	$\int TPR(FPR) dFPR$

3. ARAŞTIRMA VE BULGULAR

Bu bölümde, elma yaprağı hastalıklarının tespiti amacıyla eğitilen CNN ve ViT tabanlı modellerin performansları kapsamlı bir şekilde analiz edilmiştir. Çalışmanın güvenilirliğini artırmak ve modellerin aşırı öğrenme riskini minimize etmek amacıyla 5-katlı çapraz doğrulama yöntemi uygulanmıştır. Tüm modeller, Adam optimizasyon algoritması kullanılarak, 32 'batch size' ve 30 'epoch' boyunca eğitilmiştir.

3.1. Genel Sınıflandırma Performansı ve Model Karşılaştırması

Modellerin 5 farklı çapraz doğrulama üzerindeki genel sınıflandırma doğrulukları ve ortalama başarı oranları tablo 2’de verilmiştir. Elde edilen sonuçlar incelendiğinde, tüm modellerin %98’in üzerinde bir başarı sergilediği, ancak yeni nesil mimarilerin klasik yapılara kıyasla bir üstünlük sağladığı görülmektedir. CNN ve ViT mimarilerin karışımından oluşan MaxViT modeli, %99.31 ortalama doğruluk oranı ile test edilen tüm modeller arasında en yüksek performansı göstermiştir. Özellikle 2. katlamada %100 doğruluğa ulaşması, modelin ayırt edici özelliklere odaklanma yeteneğinin üstünlüğünü göstermektedir. Modernize edilmiş bir CNN yapısı olan ConvNeX ve hiyerarşik Vision Transformer yapısındaki Swin-T modelleri, %99.25 ortalama doğruluk ile MaxViT modeline çok yakındır. Bu durum, modern CNN tasarımlarının (ConvNeX), Transformer modellerinin başarısını yakalayabileceğini göstermektedir. Klasik bir CNN mimarisi olan ResNet-50 (%98.96) ve EfficientNet-B0 (%98.84), yüksek başarı göstergeleri de ViT tabanlı modellerin gerisinde kalmışlardır.

Tablo 2

Tüm Modellerin Sınıflandırma Doğruluğu ve Eğitim Parametreleri

Modeller	Eğitim Optimizasyon algoritmaları	Epochs	Batch Size	5 Katlı Çapraz Doğrulamanın Sınıflandırma Doğruluğu (%)					
				Fold1	Fold2	Fold3	Fold4	Fold5	Ortalama Doğruluk
ResNet-50	Adam	30	32	98.84	99.42	98.27	98.84	99.42	98.96
EfficientNet-B0	Adam	30	32	98.85	99.71	97.40	99.13	99.42	98.84
ConvNeXt	Adam	30	32	99.71	99.42	98.60	99.28	99.13	99.25
Swin-T	Adam	30	32	99.71	99.71	98.55	98.84	99.42	99.25
MaxViT	Adam	30	32	99.42	100	98.55	99.42	99.13	99.31

3.2. Sınıf Bazlı Performans Analizi

Genel doğruluk oranları modellerin başarısı hakkında fikir verse de, dengesiz veri dağılımlarında modelin her bir hastalığı ne kadar iyi ayırt ettiğini anlamak için sınıf bazlı metrikler (Kesinlik, Duyarlılık, F1-Skoru, AUC) kritik öneme sahiptir. Sınıf bazlı analizler tablo 3’te detaylı olarak verilmiştir.

Paslanmış (Rust) Sınıfı: Modellerin en başarılı olduğu sınıf "Paslanmış" yapraklar olmuştur. ConvNeX, bu sınıfta %99.60 F1-Skoru ve %99.86 AUC değerine ulaşarak, pas hastalığının belirgin görsel özelliklerini (sarı/turuncu lekeler) öğrenmede CNN'lerin doku odaklı başarısını sergilemiştir. Yeni bir CNN modeli olan ConvNeX, ViT modellerini belli parametrelerde geri de bıraktığı açık bir şekilde görülmektedir.

Kara Leke (Scab) Sınıfı: Hastalık belirtilerinin karmaşıklaşabildiği bu sınıfta, hibrit model olan MaxViT ve ViT modeli olan Swin-T modelleri öne çıkmıştır. MaxViT, Kara Leke sınıfında %99.49 F1-Skoru ve %99.96 AUC değerine ulaşarak, klasik CNN olan ResNet-50'yi (%98.81 F1-Skoru) geçmiştir. Bu durum, ViT modellerinin global bağlamı kullanarak leke desenlerini daha iyi ayırt ettiğini göstermektedir.

Sağlıklı (Healthy) Sınıfı: Sağlıklı yaprakların tespitinde de hibrit model olan MaxViT (%99.31 Başarı) en kararlı model olmuştur.


Tablo 3*Derin Öğrenme Modellerinin 5-Kat Çapraz Doğrulamanın Sınıf Bazında En İyi Test Performansları*

Modeller	Sağlıklı				Paslanmış				Kara Leke(Bitlenmiş)						
	Kesinlik	Duyarlılık	F1-Skoru	AUC	Başarı	Kesinlik	Duyarlılık	F1-Skoru	AUC	Başarı	Kesinlik	Duyarlılık	F1-Skoru	AUC	Başarı
ResNet-50	97.56	99.42	98.47	99.77	99.08	99.84	99.19	99.51	99.91	99.65	99.33	98.31	98.81	99.77	99.19
EfficientNet-B0	97.54	98.84	98.18	99.74	98.90	99.37	99.36	99.36	99.86	99.54	99.50	98.31	98.89	99.76	99.25
ConvNeXt	98.48	99.04	98.74	99.81	99.25	99.68	99.52	99.60	99.86	99.71	99.50	99.16	99.32	99.83	99.54
Swin-T	98.47	99.03	98.75	99.75	99.25	99.52	99.52	99.52	99.83	99.65	99.66	99.16	99.41	99.87	99.60
MaxViT	98.49	99.42	98.95	99.88	99.31	99.68	99.19	99.43	99.92	99.80	99.66	99.32	99.49	99.96	99.71

3.3. Karışıklık Matrisi (Confusion Matrix) Analizi


Sınıflandırma doğruluğunun ötesinde, modellerin hangi hastalık sınıflarını birbirine karıştırdığını anlamak, mimarilerin öğrenme davranışlarını çözümlemek adına önemlidir.

İlk olarak, literatürde yaygın olarak kullanılan klasik CNN tabanlı ResNet-50 ve EfficientNet-B0 modellerinin performansları incelenmiştir.




Şekil 6. ResNet-50 ve EfficientNet-B0 modellerine ait ortalama karışıklık matrisleri.

Şekil 6’da görülen her iki modelde "Paslanmış" (Rust) sınıfını neredeyse kusursuz bir şekilde tespit ettiği görülmektedir. Ancak, "Kara Leke" (Scab) sınıfının tespitinde küçük de olsa sapmalar mevcuttur. Özellikle EfficientNet-B0, ortalama 1.8 örneği "Kara Leke" yerine "Sağlıklı" olarak yanlış sınıflandırırken, bu hata oranı ResNet-50’de 1.0 seviyesindedir. Bu durum, klasik CNN’lerin, leke özneliklerinin çok belirgin olmadığı veya arka planla bütünleştiği durumlarda ayırt ediciliğinin azaldığını göstermektedir.



Şekil 7. ConvNeX ve Swin-T modellerine ait ortalama karışıklık matrisleri.

Şekil 7’de karışıklık matrisi verilen ConvNeX modeli, klasik CNN'lere kıyasla daha kararlı bir matris sunmuş ve özellikle "Sağlıklı" sınıfındaki doğru tahmin sayısını (TP) 102.2 ortalamasına yükseltmiştir. Transformer tabanlı Swin-T modeli, sınıf ayrımlarında geliştirilmiş CNN modeli olan ConvNeX’e benzer bir hata dağılımı sergilemektedir.





Şekil 8. MaxViT modellerine ait ortalama karışıklık matrisleri.

Şekil 8’de gösterilen CNN ve ViT mimarilerin birleşmesinden oluşan MaxViT modeli çalışmanın en başarılı sonuçlarını üretmiştir. MaxViT matrisinde, "Sağlıklı" sınıfı için doğru tahmin ortalaması 102.6'ya ulaşarak en yüksek değere çıkmıştır. Ayrıca, diğer modellerde görülen "Kara Leke" ve "Sağlıklı" sınıfı arasındaki karışıklık Yanlış Negatif (FN), MaxViT'te 0.8 seviyesine kadar düşmüştür. Bu bulgu, MaxViT'in "Çok Eksenli Dikkat" mekanizmasının, yaprak üzerindeki hastalık lekeleri ile yaprağın doğal dokusunu ayırt etmede eski CNN tabanlı modeller ve sadece ViT tabanlı modellere göre daha üstün bir bağlamsal algılamaya sahip olduğunu göstermektedir.

3.4. Eğitim Dinamikleri ve Yakınsama Analizi


Modellerin 30 epoch boyunca sergiledikleri eğitim ve doğrulama başarımları ile kayıp değişimleri grafiklerle detaylı olarak sunulmuştur. Bu grafikler, modellerin öğrenme kararlılıkları hakkında önemli bilgiler vermektedir. Şekil 9’da ResNet-50 ve EfficientNet-B0 modellerinin eğitim grafikleri incelendiğinde, "Doğrulama Kaybı"nın ilk 5 epoch içerisinde hızla düştüğü ve daha sonra istikrarlı bir yatay seyir izlediği görülmektedir. Bu modeller, konvolüsyonel yapıların getirdiği "tümevarımsal yanlışlık" avantajı sayesinde, 1730 görüntü gibi sınırlı bir veri setinde bile hızlıca yakınsamış ve dalgalanma yaşamadan eğitimi tamamlamıştır.





Şekil 9. *ResNet-50 ve EfficientNet-B0 modellerinin doğrulama başarısı ve doğrulama kaybı.*


Şekil 10’da ConvNeX modeli analiz edildiğinde, modelin yakınsama hızının oldukça yüksek olduğu görülmektedir. Eğitim döngüsünün henüz ilk aşamalarında doğrulama başarısı %95’in üzerine çıkmış ve ilerleyen döngülerde %99 bandına yerleşmiştir. Katman-3 haricindeki diğer tüm katmanlar (Fold 1, 2, 4, 5) birbirine çok yakın ve düşük varyanslı bir performans sergilemiştir; bu da modelin veri setindeki farklı alt kümelere karşı genelleme yeteneğinin güçlü olduğunu göstermektedir. Katman 3’te gözlemlenen geçici dalgalanma ise modelin optimizasyon sürecinde kendini düzeltebildiğini göstermektedir. Şekil 11’deki kayıp grafiği incelendiğinde ise hata değerinin hızla 0.30-0.34 aralığına düştüğü ve bu noktada optimize olduğu görülmektedir.



Şekil 10. *Geliştirilmiş CNN mimarisi ConvNeX modelinin doğrulama başarısı ve doğrulama kaybı.*

Şekil 11’de görülen Swin-T modelinin kayıp grafiğinde (Şekil 11, sağ) CNN modellerine kıyasla daha fazla dalgalanma gözlemlenmiştir. Vision Transformer’lar, görüntüdeki ilişkileri sıfırdan öğrendikleri için hiperparametre optimizasyonuna daha duyarlıdır ve kararlı hale gelmeleri genellikle daha fazla döngü veya veri gerektirir.


Swin_T - Eğitim Geçmişi



Şekil 11. Swin-T modelinin doğrulama başarısı ve doğrulama kaybı.

Önerilen derin öğrenme mimarileri arasında, %99.31'lik ortalama doğruluk oranıyla en yüksek sınıflandırma başarısını sergileyen MaxViT modelinin eğitim dinamikleri, çalışmanın bulgularını destekleyen en güçlü kanıtlardan biridir. Şekil 12'de, modelin 30 epoch süresince 5-katlı çapraz doğrulama altındaki öğrenme davranışı gösterilmiştir. Grafikler detaylı incelendiğinde, MaxViT mimarisinin hızlı yakınsama yeteneği dikkat çekmektedir. Eğitim sürecinin henüz ilk 5 döngüsünde, modelin doğrulama başarısı %98 bandını aşarken, hata değeri dramatik bir düşüşle 0.35 seviyelerine gerilemiştir. Bu durum, MaxViT'in hibrit yapısında bulunan konvolüsyonel blokların yerel özellikleri (leke kenarları, doku) hızla kavradığını, Transformer bloklarının ise bu özellikleri global bağlamla işleyerek öğrenme sürecini optimize ettiğini göstermektedir.

MaxViT_t - Eğitim Geçmişi



Şekil 12. MaxViT modelinin doğrulama başarısı ve doğrulama kaybı

Ayrıca grafikler, modelin yüksek kararlılık ve düşük varyans sergilediğini göstermektedir. 5 farklı eğitim katlamasına ait eğrilerin birbirine son derece yakın seyretmesi ve üst üste binmesi, modelin veri dağılımındaki değişikliklere karşı güçlü olduğunu göstermektedir. Saf ViT modellerinde (Swin-T) başlangıç aşamalarında görülebilen dalgalanmaların aksine, MaxViT grafiği, modelin ezberlemeye düşmeden kararlı bir şekilde genelleme yaptığını ortaya koymaktadır. Yaklaşık 10. döngü itibarıyla doyum noktasına ulaşan ve eğitimin geri kalanında %99-%100 aralığında stabil kalan model, 1730 görüntüden oluşan veri setindeki örüntüleri maksimum verimlilikle öğrenmiştir.

4. SONUÇ

Tarımsal üretimde verimliliği tehdit eden biyotik stres faktörlerinin erken teşhisi, sürdürülebilir gıda güvenliği ve ekonomik istikrar açısından hayati öneme sahiptir. Bu çalışmada, elma yaprağı hastalıklarının (Pas ve Kara Leke) otomatik tespiti ve sınıflandırılması amacıyla, klasik Evrişimli Sinir Ağları (CNN), yeni nesil Vision Transformer (ViT) ve hibrit mimarilerin performansları karşılaştırmalı olarak analiz edilmiştir. Çalışmanın güvenilirliğini artırmak ve literatürdeki (Baranwal et al., 2019; Sujatha et al., 2025) tek seferlik test yaklaşımlarının kısıtlılıklarını aşmak adına, 1730 görüntülük veri seti üzerinde 5-katlı çapraz doğrulama stratejisi uygulanmıştır. ResNet-50 ve EfficientNet-B0 gibi klasik CNN modelleri, konvolüsyonel yapıların sağladığı tümevarımsal yanlılık sayesinde hızlı yakınsama gösterebilirler de, hastalık belirtilerinin karmaşıklaştığı veya arka planla bütünleştiği durumlarda (özellikle "Kara Leke" sınıfında) ayırt edicilikte sınırlı kalmışlardır. Bu eksiklikleri gidermek için MaxViT ve Swin-T gibi Transformer tabanlı mimariler, "Öz-Dikkat" mekanizmaları sayesinde görüntüdeki uzun menzilli bağımlılıkları ve global bağlamı yakalayarak, klasik CNN'lere kıyasla daha üstün bir sınıflandırma başarısı göstermişlerdir. Çalışmanın en yüksek sonucu, hem yerel özellikleri (CNN) hem de global ilişkileri (ViT) işleyebilen hibrit MaxViT modelinin, %99.31 ortalama doğruluk ve düşük hata varyansı ile en başarılı model olduğu gösterilmektedir. Bu çalışma ayrıca, derin öğrenme modellerinin tarımsal uygulamalara entegrasyonunda performans ve hesaplama maliyeti arasındaki ilişkiyi de göstermektedir. MaxViT ve Swin-T modelleri en yüksek doğruluğu sunmakla birlikte, yüksek GPU işlem yükü ve bellek gereksinimine ihtiyaç duymaları bir dezavantajdır. Buna karşılık, EfficientNet gibi modeller, %1'den az bir performans kaybıyla mobil cihazlar ve insansız hava araçları (İHA) gibi donanım kısıtı olan platformlar için alternatifler sunmaktadır. Ayrıca, modern bir CNN tasarımı olan ConvNeX, Transformer modellerine yaklaşan başarısı ile hesaplama verimliliği ve doğruluk arasında optimum bir denge noktası oluşturmuştur. Sonuç olarak, bu kitap bölümü, elma hastalıklarının tespitinde hibrit ve modernize edilmiş mimarilerin, klasik yöntemlere göre daha güçlü ve güvenilir olduğunu 5-katlı doğrulama ile istatistiksel olarak ortaya koymuştur.

KAYNAKÇA

- Al Bashish, D., Braik, M., & Bani-Ahmad, S. (2011). Detection and classification of leaf diseases using K-means-based segmentation and. *Information technology journal*, 10(2), 267-275.
- Albawi, S., Bayat, O., Al-Azawi, S., & Ucan, O. N. (2018). Social touch gesture recognition using convolutional neural network. *Computational Intelligence and Neuroscience*, 2018(1), 6973103.
- Apple Leaf Disease Dataset [Online]. Available: <https://www.kaggle.com/datasets/nirmalsankalana/apple-leaf-disease-dataset>. (2023).
- Arivazhagan, S., Shebiah, R. N., Ananthi, S., & Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: CIGR Journal*, 15(1), 211-217.
- Ba, J. L., Kiros, J. R., & Hinton, G. E. (2016). Layer normalization. *arXiv preprint arXiv:1607.06450*.
- Bansal, P., Kumar, R., & Kumar, S. (2021). Disease detection in apple leaves using deep convolutional neural network. *Agriculture*, 11(7), 617.
- Baranwal, S., Khandelwal, S., & Arora, A. (2019). Deep learning convolutional neural network for apple leaves disease detection. Proceedings of international conference on sustainable computing in science, technology and management (SUSCOM), Amity University Rajasthan, Jaipur-India,
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- Chuanlei, Z., Shanwen, Z., Jucheng, Y., Yancui, S., & Jia, C. (2017). Apple leaf disease identification using genetic algorithm and correlation based feature selection method. *International Journal of Agricultural and Biological Engineering*, 10(2), 74-83.
- Cutur, E. S., & Inan, N. G. (2025). Multi-class classification of retinal eye diseases from ophthalmoscopy images using transfer learning-based vision transformers. *Journal of Imaging Informatics in Medicine*, 1-15.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). Bert: Pre-training of deep bidirectional transformers for language understanding. Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies, volume 1 (long and short papers),
- Dosovitskiy, A. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- Doutoum, A. S., & Tugrul, B. (2025). A systematic review of deep learning techniques for apple leaf diseases classification and detection. *PeerJ Computer Science*, 11, e2655.
- Dubey, S. R., & Jalal, A. S. (2012). Detection and classification of apple fruit diseases using complete local binary patterns. 2012 Third International Conference on Computer and Communication Technology,
- Dutot, M., Nelson, L., & Tyson, R. (2013). Predicting the spread of postharvest disease in stored fruit, with application to apples. *Postharvest biology and technology*, 85, 45-56.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). MIT press Cambridge.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Hendrycks, D. (2016). Gaussian Error Linear Units (Gelu). *arXiv preprint arXiv:1606.08415*.
- Howard, A. G. (2013). Some improvements on deep convolutional neural network based image classification. *arXiv preprint arXiv:1312.5402*.
- Inan, N. G., Kocadağlı, O., Yıldırım, D., Meşe, İ., & Kovan, Ö. (2024). Multi-class classification of thyroid nodules from automatic segmented ultrasound images: Hybrid ResNet based UNet convolutional neural network approach. *Computer Methods and Programs in Biomedicine*, 243, 107921.
- Jiang, P., Chen, Y., Liu, B., He, D., & Liang, C. (2019). Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks. *Ieee Access*, 7, 59069-59080.
- Khan, A. I., Quadri, S., Banday, S., & Shah, J. L. (2022). Deep diagnosis: A real-time apple leaf disease detection system based on deep learning. *Computers and electronics in agriculture*, 198, 107093.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Li, L.-H., & Tanone, R. (2023). Disease identification in potato leaves using swin transformer. 2023 17th International Conference on Ubiquitous Information Management and Communication (IMCOM),
- Liu, B., Zhang, Y., He, D., & Li, Y. (2017). Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 10(1), 11.

- Liu, Z., & Li, X. (2024). An improved YOLOv5-based apple leaf disease detection method. *Scientific Reports*, 14(1), 17508.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. *Proceedings of the IEEE/CVF international conference on computer vision*,
- Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A convnet for the 2020s. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*,
- Nachtigall, L. G., Araujo, R. M., & Nachtigall, G. R. (2016). Classification of apple tree disorders using convolutional neural networks. 2016 IEEE 28th international conference on tools with artificial intelligence (ICTAI),
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th international conference on machine learning (ICML-10)*,
- Organization, F. a. A. (2024). About FAO's work on plant production and protection. *Available at <https://www.fao.org/plant-production-protection/about/en> (accessed 12 April 2024)*.
- Sangeetha, K., Rima, P., Pranesh Kumar, M., & Preethees, S. (2022). Apple leaf disease detection using deep learning. 2022 6th International Conference on Computing Methodologies and Communication (ICCMC),
- Si, H., Li, M., Li, W., Zhang, G., Wang, M., Li, F., & Li, Y. (2024). A dual-branch model integrating CNN and swin transformer for efficient apple leaf disease classification. *Agriculture*, 14(1), 142.
- Sujatha, R., Krishnan, S., Chatterjee, J. M., & Gandomi, A. H. (2025). Advancing plant leaf disease detection integrating machine learning and deep learning. *Scientific Reports*, 15(1), 11552.
- SUN, J., LI, Q., LIN, X., LIANG, G., HU, Y., LI, L., & DING, W. (2024). Development of Image Recognition System for Tobacco Aphid Based on Resnet-101 Model. *PLANT HEALTH AND MEDICINE*, 3(4), 26-31.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*,
- Thakur, C., Kapoor, N., & Saini, R. (2023). A novel framework of apple leaf disease detection using convolutional neural network. 2023 International Conference on Inventive Computation Technologies (ICICT),
- Thapa, R., Snively, N., Belongie, S., & Khan, A. The plant pathology 2020 challenge dataset to classify foliar disease of apples. arXiv 2020. *arXiv preprint arXiv:2004.11958*.
- Thapa, R., Snively, N., Belongie, S., & Khan, A. (2020). The plant pathology 2020 challenge dataset to classify foliar disease of apples. *arXiv preprint arXiv:2004.11958*.
- Tu, Z., Talebi, H., Zhang, H., Yang, F., Milanfar, P., Bovik, A., & Li, Y. (2022). Maxvit: Multi-axis vision transformer. *European conference on computer vision*,
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

BÖLÜM 2

GERÇEK SÜRÜCÜ DAVRANIŞLARI İLE ŞERİT DEĞİŞTİRME EYLEMİNİN YAPAY SİNİR AĞLARI (YSA) İLE TAHMİN EDİLMESİ

Ali GÜNEŞ¹ , Bahadır ÇOKÇETİN²

¹ Dr., Baykan Otomobil, Yedek Parça Koordinatörü

² Öğr. Gör. Kütahya Dumlupınar Üniversitesi, Tavşanlı Meslek Yüksek Okulu, Bilgisayar Teknolojileri Bölümü, Kütahya, Türkiye, ORCID:
0000-0003-2189-9265

GİRİŞ

Bu kitap bölümünde sunulan tüm analiz, yöntem ve sonuçlar, Ali Güneş'in "Gerçek Sürücü Davranışlarından Şerit Değiştirme Eyleminin YSA ile Tahmin Modeli" başlıklı doktora tezinden (Güneş, 2022) türetilmiş ve yeniden düzenlenmiştir.

Trafik kazaları, Karayolları Trafik Yönetmeliği'nde "karayolunda hareket hâlindeki bir veya birden fazla aracın karıştığı, ölüm, yaralanma ve/veya maddi zararlar sonucunda meydana gelen olay" olarak tanımlanmaktadır. Motorlu taşıt sayısındaki küresel artış, trafik kazalarının sıklığında da önemli bir yükselişe neden olmaktadır. Dünya Sağlık Örgütü'nün (WHO) raporuna göre, her yıl yaklaşık 1,3 milyon insan trafik kazalarında hayatını kaybetmekte olup bu ölümlerin %94'ü düşük gelirli ülkelerde gerçekleşmektedir (World Health Organization, 2018). Aynı raporda trafik kazalarının tüm ölüm nedenleri içinde sekizinci sırada, 5–29 yaş arası bireylerde ise birinci sırada yer aldığı vurgulanmıştır. Ekonomik açıdan değerlendirildiğinde ise trafik kazalarının maliyetinin ülkelerin gayri safi yurt içi hasıllarının yaklaşık %3'üne karşılık geldiği belirtilmektedir.

Türkiye özelinde bakıldığında, araç sayısı ve trafik hacmindeki artışa paralel olarak 2009–2020 yılları arasında ölümlü ve yaralanmalı kaza sayılarında artış meydana geldiği görülmektedir. Bununla birlikte, araç sayısındaki yükselişe rağmen trafik kazalarında meydana gelen ölüm sayısının 4324'ten 4866'ya çıkarak nispeten daha sınırlı bir artış gösterdiği ifade edilmektedir (Karayolu Trafik İstatistikleri, 2020). Bu veriler, trafik güvenliğine yönelik alınan önlemlerin etkisini gösterse de kazaların önemli bir kısmının insan faktöründen kaynaklanmaya devam ettiği gerçeğini değiştirmemektedir.

Nitekim literatürde trafik kazalarının %88–%90 oranında sürücü kusurundan kaynaklandığı uzun yıllardır rapor edilmektedir (Ergün & Yüksel, 2017). Sürücü kaynaklı hatalar arasında hatalı şerit değiştirme ve şerit ihlalleri dikkat çekici bir paya sahiptir. Karayolları Genel Müdürlüğü verilerine göre, yerleşim yeri dışında meydana gelen trafik kazalarında şerit ihlali sürücü hatalarının %16,47'sini oluşturmaktadır (Karayolları Genel Müdürlüğü, 2019).

Öztürk ve Ergin (2013), şerit ihlali ve ani sollama girişimlerinin özellikle şehirler arası yollarda ölümcül kazaların önemli bir belirleyicisi olduğunu rapor etmiştir. Benzer şekilde Brookhuis, de Waard ve Janssen (2009), şerit konumundaki küçük sapmaların dahi yüksek çarpışma riskine işaret ettiğini göstermiştir. Bu bulgular, sürücünün şerit değiştirme niyetinin eylem gerçekleşmeden önce tespit edilmesinin güvenlik açısından kritik bir önem taşıdığını göstermektedir. Evans (2004), trafik güvenliğinde insan faktörünün tek başına kazaların büyük bölümünü açıklayabildiğini ve sürücü davranışlarının sistematik olarak modellenmesi gerektiğini vurgulamaktadır.

Bu doğrultuda geliştirilen ileri seviye sürücü destek sistemleri (ADAS) ve aktif güvenlik teknolojilerinin amacı, sürücünün hatalı veya riskli bir eylem gerçekleştirmesini eylem öncesinde tespit ederek müdahale edebilmek veya uyarı verebilmektir. McCall ve Trivedi (2007), sürücü destek sistemlerinin şerit takip ve niyet tahmini gibi görevlerde güvenliği belirgin ölçüde artırdığını göstermiştir. Ayrıca Doshi ve Trivedi (2010), sürücünün baş ve göz hareketlerinin niyet ön kestiriminde kritik rol oynadığını ortaya koymuştur. Şerit değiştirme eylemi, sürücünün görsel dikkatinin, aracın dinamik durumunun ve çevresel koşulların bir arada etkilendiği karmaşık bir süreçtir. Dolayısıyla sürücünün şerit değiştirme niyetinin eylemden yaklaşık 1,5–3 saniye önce doğru şekilde tahmin edilmesi hem kazaların önlenmesi hem de otonom sürüş sistemlerinin güvenilirliği açısından temel bir gereksinimdir.

Bu çalışmanın amacı, gerçek sürüş verilerinden yararlanarak sürücünün öndeki aracı geçme ve şerit değiştirme niyetinin eylemden 3 saniye önce tahmin edilmesini sağlayan bir Yapay Sinir Ağı (YSA) modeli geliştirmektir. Bunun için sürücünün yüz ve göz hareketleri, öndeki araç ile olan mesafe, araç hızı ve direksiyon açısı bilgisi birlikte değerlendirilmiştir. Veri toplama süreci, gerçek yol koşullarında 8 katılımcı ile gerçekleştirilen sürüş testlerinden elde edilen çoklu sensör verilerine dayanmaktadır. Sürücünün yüz ve göz hareketleri Haar Cascade yöntemiyle tespit edilmiş; öndeki araç ve mesafe tespiti

ise görüntü işleme teknikleriyle gerçekleştirilmiştir. Ayrıca hız ve direksiyon açısı bilgileri CAN Bus sistemi üzerinden ODIS test cihazı kullanılarak kaydedilmiştir.

Geliştirilen YSA modeli, öndeki aracı geçme niyetini %93,1 doğruluk oranıyla tahmin etmiş ve diğer makine öğrenmesi algoritmaları olan Naive Bayes, KNN, SVM ve Karar Ağaçları ile karşılaştırıldığında daha yüksek performans göstermiştir. Çalışmanın sonuçları, sürücünün şerit değiştirme niyetinin eylemden önce tahmin edilmesinin, hatalı sollama eylemlerinden kaynaklanan kazaların azaltılmasına yönelik erken uyarı sistemleri için önemli bir katkı sunabileceğini göstermektedir.

MATERYAL VE METOT

Bu çalışmanın temel metodolojisi, gerçek yol koşullarında sürücü davranışlarının, araç dinamiklerinin ve çevresel değişkenlerin eş zamanlı olarak kaydedilmesi; bu çoklu veri kaynaklarının senkronizasyonu ve işlenmesi yoluyla Yapay Sinir Ağı (YSA) için uygun bir veri seti oluşturulmasına dayanmaktadır. Bu kapsamda araç CAN Bus sistemi, iç ve dış kamera kayıtları ve özel olarak geliştirilen C++ tabanlı senkronizasyon yazılımı birlikte kullanılmıştır. Elde edilen görüntülerden sürücü yüz-göz konumu ve öndeki araç mesafesi çıkarılmış; ardından 3 saniyelik zaman penceresi üzerinden istatistiksel öznitelikler oluşturularak sınıflandırma modeline giriş verileri hazırlanmıştır.

Bu senkronizasyon yaklaşımı, literatürde gerçek zamanlı sürüş analizleri için önerilen çoklu sensör füzyon modelleriyle uyumluluk göstermekte ve verinin zaman ekseninde bütüncül analizine olanak tanımaktadır (Olabi, 2017). Yang ve Zhang (2019) ise benzer çoklu veri modellerinin niyet tespitinde tek kaynaklı modellere göre üstün olduğunu belirtmektedir.

Şekil 1 İş Akış Diyagramı



DeneySEL Kurulum ve Katılımcılar

DeneySEL çalışmalar, şehir içi trafikte manevra yapmaya uygun, trafik yoğunluğu orta seviyede olan bir güzergâhta gerçekleştirilmiştir. Çalışmaya, en az 10 yıllık sürüş deneyimine sahip 8 erkek katılımcı dahil edilmiştir. Katılımcıların ortalama yaşı 39, ortalama sürüş deneyimi ise 22,5 yıl olup bu değerler test edilen örneklemin sürüş yetkinliğinin makul seviyede olduğunu göstermektedir.

Bu seçimin temel gerekçesi, sürücünün şerit değiştirme davranışının deneyimsiz sürücülerde değişkenlik gösterebilmesi ve kontrolsüz varyansın modeli olumsuz etkileyebilmesidir (Ergün & Yüksel, 2017). Bu nedenle homojen bir sürücü profili tercih edilmiştir. Deneyimsiz sürücülerde karar

verme süresi, şerit konumu kararlılığı ve baş-göz hareketleri daha düzensiz olabildiğinden, modelin davranışsal gürültüye duyarlılığı artmaktadır.

Bu deneysel düzenek içinde sürücü davranışlarının görsel olarak izlenebilmesi, öndeki trafik akışının analiz edilebilmesi ve tüm verilerin zaman uyumlu şekilde kaydedilebilmesi için kamera sistemi çalışmanın kritik bileşenlerinden birini oluşturmaktadır. Bu nedenle, deneysel kurulumun ardından kullanılan kamera altyapısı ayrıntılı olarak sunulmaktadır.

Tablo 1 Çalışmada Kullanılan Sensör ve Donanımların Teknik Özellikleri

Sensör / Donanım	Teknik Özellik	Açıklama
Havana HVNA-8081 Kamera (İç Kamera)	1920×1080 çözünürlük (tezde belirtilen)	Sürücü yüz, göz ve burun tespiti için kullanılmıştır.
	30 FPS (genel teknik özellik)	Baş hareketi ve bakış yönünün izlenmesini sağlar.
	Geniş açılı lens ($\approx 120^\circ$)	Sürücünün yüz bölgesinin tamamının görüntülenmesi için uygundur.
Havana HVNA-8081 Kamera (Dış Kamera)	1920×1080 çözünürlük	Öndeki aracın tespiti ve mesafe ölçümü amacıyla kullanılmıştır.
	30 FPS	Dinamik trafik sahnesinin algılanmasına olanak tanır.
ODIS VAS5054 CANBus Test Cihazı	OBD-II uyumlu veri okuma	Hız, direksiyon açısı gibi araç dinamik parametrelerini toplar.
	1 Hz örnekleme frekansı (tezde belirtilen)	Her saniye bir veri örneği kaydedilmiştir.
	ISO 9141 / K-Line / CAN uyumlu	Farklı araç protokolleriyle çalışabilir.
Bilgisayar (Kayıt İstasyonu)	Intel i5 / 8 GB RAM (önerilen tipik sistem)	Kamera kayıtlarını ve senkronizasyon yazılımını çalıştırır.
Visual Studio C++ Tabanlı Senkronizasyon Yazılımı	Ortak zaman damgası üretimi	İki kamera + CANBus verilerinin eş zamanlı kaydını sağlar.
	Video + Sensör verisi entegrasyonu	Sonradan veri eşleştirme hatalarını önler.

Veri Toplama Sistemi

Veri toplama altyapısı üç ana bileşenden oluşmaktadır:

1. Araç CAN Bus sistemi,
2. İç ve dış kamera sistemi,
3. Visual Studio C++ ile geliştirilen senkronizasyon yazılımı.

Taşıt CAN Bus Sistemi

Araç hız bilgisi ve direksiyon açısı verileri, test aracının OBD-II portuna bağlanan ODIS VAS5054 test cihazı aracılığıyla CAN Bus hattından alınmıştır. CAN Bus üzerinden elde edilen bu veriler sürücünün anlık davranışlarını ve aracın dinamik yanıtını anlamada kritik öneme sahiptir. Kullanılan sensörlerin örnekleme frekansı, tezde belirtildiği üzere saniyede bir kayıt olacak şekilde yapılandırılmıştır (Güneş 2022, s. 89–90).

Şekil 2 Sensör verilerinin ODIS cihazı üzerinden alınmasına ilişkin ekran görüntüsü.
Not. Güneş (2022, s. 72) çalışmasından uyarlanmıştır.

003 Ölçüm değerleri		23.10.2021 12:14:52
Name	Top^ Wert	Adr.
Araç hızı [\$2B16]		0044
---	82,83 km/s	
Motor devir sayısı [\$F40C]		0044

[LO]_measurement_value		
---	1.565 1/min	
Direksiyon açısı sensörü açısı [\$1812]		0044
Direks. açısı	-2,8 °	
Durum	geçerli	
Direksiyon açısı sensörü açısı hızı [\$1815]		0044
Direksiyon açısı hızı	-1,0 °	
Durum	geçerli	

Kamera Sistemleri

Deneyisel düzenek kapsamında sürücü davranışlarının ve araç çevresinin eş zamanlı olarak kaydedilebilmesi için araç ön camına iki adet Havana HVNA-8081 model kamera yerleştirilmiştir. İç kamera sürücü yüzü, dış kamera ise öndeki trafik akışını ve araçları görüntülemiştir. Her iki kamera da 1920×1080 çözünürlükte kayıt yapmış ve senkronizasyon yazılımı aracılığıyla aynı zaman damgasına bağlanmıştır. Bu yapı hem sürücü davranışı hem de çevresel değişkenlerin eş zamanlı analizine olanak tanımaktadır.

Şekil 3 Sürücünün yüz hareketleri ve öndeki aracın tespiti için kullanılan kameraların montaj görüntüsü. Not. Güneş (2022, s. 73) çalışmasından uyarlanmıştır.



Veri Senkronizasyon Yazılımı

İç ve dış kamera görüntüleri ile CAN Bus verileri farklı kaynaklardan geldiğinden, bu verilerin zaman ekseninde tam uyumlu biçimde hizalanması gerekmektedir. Bu amaçla Visual Studio C++ ortamında özel bir senkronizasyon yazılımı geliştirilmiştir. Yazılım, gerçek zamanlı kayıt sırasında tüm akışlara ortak zaman damgası atamakta ve dosyaları işlenebilir biçimde saklamaktadır. Bu adım, sonraki görüntü işleme ve özellik çıkarımı süreçlerinde veri kayması (time drift) yaşanmaması için kritiktir. Toplanan görüntü ve CAN Bus verilerinin analize uygun hâle gelebilmesi, büyük ölçüde bu senkronizasyon mekanizmasının doğruluğuna bağlıdır.

Bu yaklaşım, literatürde gerçek zamanlı sürüş analizlerinde önerilen çoklu sensör senkronizasyon yapılarıyla uyumludur (Olabi, 2017).

Görüntü İşleme ve Veri Ekstraksiyonu

Kamera görüntülerinden matematiksel özellik çıkarımı Python ve OpenCV kullanılarak gerçekleştirilmiştir. Bu süreçte iki ana analiz uygulanmıştır:

1. Öndeki aracın tespiti ve mesafe hesaplaması,
2. Sürücünün yüz-göz-burun konumlarının tespiti.


Öndeki Aracın Tespiti ve Mesafe Ölçümü

Öndeki aracın görüntüdeki konumunun belirlenmesi için nesne tespiti gerçekleştirilmiş, ardından aracın gerçek mesafesinin tahmin edilmesi amacıyla bir dizi geometrik dönüşüm uygulanmıştır. Tezde kullanılan yöntemler; gri seviye dönüşüm, eşikleme, kontur çıkarma, piksel-metre dönüşümü yöntemleridir.


Gerçek mesafe hesabı için perspektif düzeltme yapılarak kuşbakışı (bird's-eye view) görüntü elde edilmiştir. Bertozzi ve Broggi (1998), şerit çizgileri ve perspektif dönüşüm kullanarak araç-nesne mesafesinin güvenilir şekilde tahmin edilebileceğini göstermiştir. Labayrade ve arkadaşları (2002) ise çoklu kamera perspektifinin mesafe tahmin performansını artırdığını rapor etmiştir.

Bu dönüşümde şerit çizgilerinin sabit fiziksel genişliği referans alınmış; sağ ve sol şerit çizgileri arası 87 piksel olarak ölçülmüş ve bu değer gerçek hayattaki 4,5 metre uzunluğu ile ölçeklendirilmiştir. Böylece görüntüdeki piksel değerleri metre cinsine dönüştürülmüştür.

Şekil 4 Öndeki araç mesafe tespiti. Not. Güneş (2022, s. 82) çalışmasından uyarlanmıştır.




Şekil 5 Kuşbaşı görüntü şerit çizgileri. Not. Güneş (2022, s. 80) çalışmasından uyarlanmıştır.



Sürücünün Yüz ve Göz Konumunun Tespiti

Sürücünün bakış yönü ve baş hareketleri, davranış niyetinin belirlenmesinde önemli göstergelerdir. Ji, Zhu ve Lan (2004), göz açıklığı ve baş yönünün sürücünün bilişsel durumunu yansıtan en güçlü göstergelerden olduğunu bildirmiştir. Ayrıca Dong ve arkadaşları (2011), yüz/baş pozunun şerit ihlali öncesi davranışı belirlediğini göstermiştir. Bu nedenle iç kamera görüntüsünde Haar Cascade sınıflandırıcıları kullanılarak yüz, burun ve sağ göz konumları tespit edilmiştir. Her bir anatomik nokta için tespit edilen koordinatlar (x,y), YSA modelinin giriş değişkenlerinden biri olarak kaydedilmiştir. Bu yapı, literatürde sürücü dikkat modellemede yaygın olarak kullanılan bir yöntemdir (Huang, 2016).

Şekil 6 Yüz-göz-burun tespit örneği. Not. Güneş (2022, s. 84) çalışmasından uyarlanmıştır.



Özellik Çıkarımı ve Veri Setinin Oluşturulması

Üç Saniyelik Zaman Penceresi

Şerit değiştirme niyetinin eylemden önce tahmin edilebilmesi amacıyla, her pozitif örnek için sürücünün şerit değiştirme hareketini başlatmadan 3 saniye öncesine kadar olan veri dikkate alınmıştır. Kamera sisteminin 30 FPS çalışma hızı göz önünde bulundurulduğunda, bu süre yaklaşık 90 kare (frame) veriye karşılık gelmektedir. Abbas ve arkadaşları (2019), sürücü davranışlarının güvenilir biçimde sınıflandırılabilmesi için en az 4–6 saniyelik davranış penceresine ihtiyaç olduğunu belirtmiştir. Bununla birlikte Peng et al. (2015) 1,5–2 saniyelik pencerelerde dahi anlamlı tahmin başarısı elde edilebildiğini göstermiştir. Bu nedenle 3 saniyelik pencere literatürle uyumlu bir orta değer olarak seçilmiştir.

Her bir değişken için bu 90 karelik pencereden ortalama değer alınarak tek bir özellik vektörü oluşturulmuştur. Bu yaklaşım gürültünün azaltılması ve davranışsal eğilimlerin yakalanması için literatürde önerilen yöntemlerle uyumludur.

Veri Temizleme ve Örnek Şablonu

Orijinal veri 31.314 satırdan oluşmakta olup şerit değiştirme hareketinin meydana gelmediği “negatif örneklerin” çok fazla olması nedeniyle veri dengesizliği söz konusudur. Bu nedenle anlamsız tekrarlar filtrelenmiş, pozitif örnekler manuel anotasyon ile belirlenmiş ve sonuç olarak 59 pozitif, 3.273 negatif olmak üzere toplam 3.332 satırlık bir veri seti elde edilmiştir.

Chawla ve arkadaşları (2002), sınıf dengesizliğinin makine öğrenmesi modellerinin genelleme performansını düşürdüğünü ve SMOTE gibi tekniklerin bu sorunu azaltabileceğini belirtmiştir.

Örnek veri satırları Tablo 2’de verilmiştir. Kullanılan tüm değişkenlerin anlamları ise Tablo 3’te açıklanmıştır. Bu çalışmada “1” sınıfı şerit değiştiriyor, “0” sınıfı şerit değiştirmiyor durumunu temsil etmektedir.

Tablo 2 Test ve Eğitim Verisi Örnek Özellikleri. Not. Güneş (2022, s. 85)
çalışmasından uyarlanmıştır.

Sürücü	Mes. Ort.	X Ort.	Y Ort.	Brn_Ort X	Brn_Ort Y	Gz_Ort X1	Gz_Ort Y1	Dir. Aci	Hız	Sonuc
AG1	22,5	159,7	141,4	60,6	71,3	59,1	44,2	-1,2	89,48	1
AG10	21,1	218,7	170,5	52,8	77,5	62,5	44,5	-0,5	68,56	1
AG11	23,5	163,4	118,9	54	72,9	49,2	44,5	1	62,36	1
AG12	9,1	193,3	432,4	59,7	63,4	58,9	45,5	-0,2	63,05	1
AG13	8,9	189,9	436,9	56	72,6	54,2	45,2	0,8	56,23	1
AG2	24,6	209,4	95,9	61,5	64,2	56,7	43,2	0,3	91,8	1
AG4	22,7	189,1	135,8	64,8	74,3	48,4	35,7	-8,4	85,61	1
AG5	17	129	259,7	59,2	73	49,5	45,6	0,7	78,34	1
AG6	7,9	190,5	457,3	59,4	70,6	53,5	42,9	-6,3	99,2	1
AG9	13,5	245,6	336,8	56,1	61,1	46	45,2	-2,3	62,62	1
CS1	24,9	83,3	88,1	64	36,5	35,8	33	1	95,06	1
CS11	8,2	156	451,5	63,8	64,7	63,6	43,2	0,6	82,5	1
CS3	20	193,1	195,8	55,6	52,8	56	41,1	-0,1	89,58	1
CS4	17,5	190	250,4	54,7	66,4	59,4	43,6	0	89,73	1
CS5	18,8	177,3	220,8	50	65,6	48,9	44,4	0,8	66,59	1
CS6	18,9	175	219,5	55,9	62,6	44,2	44	1	95,64	1
CS9	22	175,8	150,8	52	64,3	48,5	45,1	0,1	59,12	1
EY3	19,7	172	200,7	56,2	48,2	65,5	44	1,5	72,75	1
EK1	14,8	184,5	309	47,6	66,8	49,9	45,2	0	58,98	1
EK11	11,8	149,9	373,5	62,5	52,4	35,7	43	-2,1	62,33	1
EK12	26,5	11,3	53,7	27,1	31,8	32,8	26,8	1,2	88,69	1
EK13	18,8	132,8	220,5	55,3	63,5	50,3	42,2	2,2	91,66	1
EK14	15,4	220,7	295,5	55,5	62,5	50,8	42,9	0,1	80,66	1
EK3	18,8	234,2	220,4	54,5	59,3	50,3	42,4	0,3	95,62	1

EK4	22,2	152,3	146,3	54	56,7	52,3	45,6	-3,6	68,08	1
EK7	12,7	152,7	354,8	51	62	53,5	46	0,9	65,28	1
EK8	11,9	227,8	371,5	55	57,3	60,1	44,7	-0,4	55,67	1
EK9	18,3	169,2	232,6	54,3	51,8	57,4	43	0	71,52	1
HE1	12,9	137,2	350,4	55,5	64,1	48,2	39,7	-1	71,81	1

Tablo 3 Test ve Eğitim Verisinde Kullanılan Özellik Değişkenleri ve Açıklamaları

Değişken Adı	Açıklama	Ölçüm Birimi	Elde Edilme Yöntemi
Mesafe (Mes. Ort)	Öndeki araç ile test aracı arasındaki ortalama mesafe	metre (m)	Perspektif düzeltme + piksel-metre dönüşümü (87 px $\approx$ 4,5 m)
X Ort	Öndeki aracın görüntüdeki merkez noktasının X koordinatı	piksel	OpenCV ile kontur merkezinin hesaplanması
Y Ort	Öndeki aracın görüntüdeki merkez noktasının Y koordinatı	piksel	OpenCV kontur analizi
Brn_Ort_X	Sürücünün burun merkezinin X koordinatı	piksel	Haar Cascade yüz/burun tespiti
Brn_Ort_Y	Sürücünün burun merkezinin Y koordinatı	piksel	Haar Cascade
Gz_Ort_X1	Sağ göz merkezinin X koordinatı	piksel	Haar Cascade göz tespiti
Gz_Ort_Y1	Sağ göz merkezinin Y koordinatı	piksel	Haar Cascade
Dir. Aç1	Direksiyonun anlık açısı	derece (°)	CAN Bus üzerinden ODIS cihazı ile ölçülen sensör verisi
Hız	Aracın anlık hız bilgisi	km/s	CAN Bus (ODIS)
Sonuç (Label)	Şerit değiştiriyor (1) / değiştirmiyor (0)	kategorik	Sürüş videolarının manuel anotasyonu + zaman eşleşmesi

TAHMİN MODELİNİN OLUŞTURULMASI VE DEĞERLENDİRİLMESİ

Yapay Sinir Ağı Modelinin Mimarisi

Şerit değiştirme niyetini belirlemek için çok katmanlı ileri beslemeli bir YSA modeli kurulmuştur. Model:

- 8 giriş nöronu
- 10 gizli nöron
- 2 çıkış nöronundan (şerit değiştiriyor / değiştirmiyor), oluşmaktadır.

Başlangıçta direksiyon açısı değişkeni de giriş olarak dahil edilmiş; ancak bu değişkenin yüksek varyans ve diğer girişlerle korelasyon sorunları nedeniyle eğitimi olumsuz etkilediği görülmüş ve modelden çıkarılmıştır. Aktivasyon fonksiyonları:

- Gizli katman: tansig
- Çıktı katmanı: softmax

olarak seçilmiştir. Tüm giriş değişkenleri $[0,1]$ aralığına normalize edilmiştir.

Şekil 7 YSA Model Mimarisi ve Eğitim Paneli. Not. Güneş (2022, s. 87) çalışmasından uyarlanmıştır.



Model Eğitimi

Eğitim sürecinde literatürde doğrusal olmayan sınıflandırma problemleri için başarılı olduğu bilinen Bayesian Regularization algoritması seçilmiştir (Huang, 2016). Bu yöntem aşırı uyum (overfitting) riskini azaltması nedeniyle tercih edilmiştir.

MacKay (1992), Bayesian Regularization'ın ağırlık büyüklüğünü cezalandırarak aşırı uyumu önemli ölçüde azalttığını belirtmektedir. Foresee ve Hagan (1997) da bu yöntemin küçük veri kümelerinde kararlı sonuçlar ürettiğini göstermiştir.


Eğitim–test ayrımı:

- %70 eğitim,
- %30 test oranında yapılmıştır.

Eğitim sürecinde:

- En düşük MSE değeri 476. iterasyonda elde edilmiştir.
- Eğitim regresyon katsayısı 0,99, test katsayısı 0,98 olmuştur.
-

Şekil 8 YSA Eğitim Performansı Grafiği. Not. Güneş (2022, s. 89-90) çalışmasından uyarlanmıştır.



Test Sonuçları ve Algoritma Karşılaştırması

Eğitilmiş model, daha önce kullanılmamış 29 test örneği ile sınanmıştır. Sonuçlar:

- %93,1 doğruluk
 - 29 örneğin 2'sinde hata
 - %6,9 hata oranı
- şeklindedir.


Bu performans, Peng ve arkadaşlarının (2015) 1,5 saniyelik tahmin çalışmasındaki %85,5 doğruluk değerinin üstündedir.

Test verilerindeki doğru-yanlış dağılımı Tablo 4'teki hata matrisi ile gösterilmiştir. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafik ise Şekil 9'da yer almaktadır.

Tablo 4 YSA Test Hata Matrisi. Not. Güneş (2022, s. 94) çalışmasından uyarlanmıştır.

Gerçek\Tahmin	TEST	
	0	1
0	12	0
1	2	15

Şekil 9 Test ve YSA Tahmin Sonuçlarının Kıyaslanması. Not. Güneş (2022, s. 95) çalışmasından uyarlanmıştır.



Elde edilen test performansı, YSA modelinin şerit değiştirme niyetini yüksek doğrulukla tahmin edebildiğini göstermektedir. Ancak modelin görelî başarısının değerlendirilebilmesi için aynı veri seti üzerinde yaygın kullanılan diğer makine öğrenmesi algoritmalarıyla da karşılaştırma yapılması

gerekmektedir. Bu amaçla Naive Bayes, Karar Ağaçları, SVM ve KNN modelleri ek olarak test edilmiş ve sonuçlar aşağıda sunulmuştur.

Diğer Algoritmalar ile Karşılaştırma

Aynı veri seti üzerinde Naive Bayes, Karar Ağaçları, SVM ve KNN algoritmaları da test edilmiştir. Sonuçlar Tablo 5'te verilmiş olup YSA modelinin diğer tüm algoritmalarından daha yüksek doğruluk sağladığı görülmektedir.

Tablo 5 Makine Öğrenmesi Algoritmaları Test Başarımı Karşılaştırması

Algoritma	Test Başarımı (Doğruluk Oranı)
Yapay Sinir Ağları (YSA)	%93,1
Naive Bayes	%75,8
Karar Ağaçları	%72,4
Destek Vektör Makineleri (SVM)	%58,6
En Yakın Komşu (KNN)	%55,1

Yapay sinir ağı ile kurulan model, diğer makine öğrenmesi algoritmalarına kıyasla belirgin şekilde daha yüksek bir doğruluk oranı elde etmiştir.

Bu bölümde gerçek sürüş koşullarında elde edilen verilerin sensörler ve görüntü işleme teknikleri ile analiz edilmesi, 3 saniyelik zaman penceresiyle öznitelik çıkarımı yapılması ve elde edilen verilerin YSA modeli ile değerlendirilmesi aşamaları bütünsel bir metodoloji çerçevesinde sunulmuştur. Modelin yüksek doğruluk değerleri, şerit değiştirme niyetinin erken tahmini konusunda YSA tabanlı yapıların etkinliğini ortaya koymaktadır.

Bu bölümde kullanılan sensör altyapısı, görüntü işleme yöntemleri, zaman penceresi seçimi ve özellik çıkarımı süreçleri bütüncül bir metodoloji çerçevesinde sunulmuştur. Önerilen veri akışı, hem davranışsal hem de dinamik sürüş parametrelerinin senkronize edilmesine olanak tanımakta; bu yönüyle literatürdeki tek kaynaklı modellere göre daha sağlam bir analitik temel oluşturmaktadır.

SONUÇ VE ÖNERİLER

Bu çalışmanın sonuçları genel bir çerçevede ele alındığında, elde edilen bulgular literatür ile karşılaştırmalı olarak değerlendirilmiştir. Bu çalışma, gerçek sürüş koşullarında toplanan çoklu sensör verileri kullanılarak sürücünün öndeki aracı geçme ve şerit değiştirme niyetinin eylem gerçekleşmeden önce tahmin edilmesini amaçlamıştır. İç ve dış kamera görüntüleri, CAN Bus verileri ve senkronizasyon yazılımı aracılığıyla senkronize edilen veri akışı, sürücü davranışlarının, araç dinamiklerinin ve çevresel koşulların birlikte değerlendirilmesini mümkün kılmıştır. Ölçeklendirilmiş görüntü işleme yöntemleri ve üç saniyelik zaman penceresi ile çıkarılan öznitelikler, Yapay Sinir Ağı (YSA) sınıflandırma modeline giriş olarak kullanılmıştır.

Geliştirilen model, sürücünün şerit değiştirme niyetini yüksek doğrulukla (%93,1) tahmin edebilmiştir. Bu değer, Peng ve arkadaşları (2015) tarafından rapor edilen %85,5 doğruluk oranına

kıyasla, önerilen yöntemin erken niyet tahmininde güçlü bir performansa sahip olduğunu göstermektedir. Ayrıca YSA modeli, aynı veri seti üzerinde test edilen Naive Bayes, Karar Ağaçları, Destek Vektör Makineleri ve K-En Yakın Komşu algoritmalarından daha başarılı sonuç vermiştir. Bu durum, sürücü davranışlarının süreklilik içeren ve doğrusal olmayan yapısının YSA tabanlı modeller tarafından daha etkin yakalandığını göstermektedir.

Çalışmanın en önemli katkılarından biri, gerçek yol koşullarında, kontrolsüz çevresel değişkenler altında toplanmış çok boyutlu verilerin bütünleşik şekilde işlenmesi ve eylemden 3 saniye önce yüksek doğruluklu tahminin mümkün olduğunun ortaya konulmasıdır. Özellikle sürücünün yüz ve göz hareketlerinin, öndeki araç mesafesinin ve aracın hız bilgisinin bir arada değerlendirilmesi, davranışsal niyetin daha erken tespit edilmesini sağlamıştır. Bu özellik, gelişmiş sürücü destek sistemleri (ADAS) ve otonom sürüş altyapıları için kritik öneme sahiptir. Erken uyarı mekanizmaları sayesinde hatalı sollama ve şerit ihlali kaynaklı kazaların azaltılması, daha güvenli bir sürüş deneyimi sağlanması mümkün olacaktır.

Çalışmanın Kısıtları

Çalışma önemli bulgular üretmiş olmakla birlikte bazı sınırlılıklara sahiptir:

1. Katılımcı sayısı sınırlıdır.
Sekiz sürücü ile yapılan ölçümler davranışsal çeşitliliği tam olarak temsil etmeyebilir.
2. Test güzergâhı ve hız profili kontrollüdür.
Farklı yol tipleri (otoban, tali yol), farklı hava koşulları ve gece sürüşleri değerlendirmeye dahil edilmemiştir.
3. Model yalnızca ileri beslemeli YSA mimarisi ile değerlendirilmiştir.
Zaman bağımlılıklarını daha iyi yakalayabilen LSTM veya GRU gibi derin öğrenme mimarileri kullanılmamıştır.
4. Direksiyon açısı değişkeni çıkarılmıştır.
Bu değişken doğru tahmin sürecini bozduğu için modele dahil edilmemiştir; ancak farklı filtreleme veya normalizasyon teknikleriyle anlamlı hâle getirilebilir.

Bu kısıtlar, gelecekte yapılacak çalışmalar için geliştirme alanları sunmaktadır.

Gelecek Çalışmalar İçin Öneriler

1. Daha geniş ve çeşitli bir sürücü kitlesi ile veri toplanabilir.
Farklı yaş grupları, sürüş deneyimleri ve davranış profillerinin modele dahil edilmesi genelleme yeteneğini artıracaktır.
2. Derin öğrenme tabanlı zaman serisi modelleri uygulanabilir.
LSTM, GRU, 1D-CNN veya Transformer tabanlı mimarilerin davranışsal niyeti daha erken tespit etme potansiyeli bulunmaktadır. Jain ve arkadaşları (2016), tekrarlayan sinir ağlarının zaman bağımlı sürücü davranışlarını daha doğru modellediğini göstermiştir. Bu bağlamda Olabiyi et al. (2017) de hız ve şerit verilerinin RNN tabanlı modellerle daha başarılı öngörüldüğünü belirtmektedir.
3. Ek sensörlerin kullanıldığı multimodal sistemler kurulabilir. Liu ve arkadaşları (2018), göz izleme verileri ile araç dinamiklerinin birleştirilmesinin sürücü niyetinin ön kestiriminde başarıyı anlamlı biçimde artırdığını göstermiştir.

Şu ek veriler model başarısını artırabilir:

- Göz izleme (eye-tracker) sensörleri
- Direksiyon kuvvet sensörü
- Şerit çizgisi algılama sisteminden gelen bilgiler
- Yol eğimi ve GPS tabanlı konum verileri

4. Gerçek zamanlı çalışan bir ADAS prototipi geliştirilebilir.
Model, araç içi birimini üzerinde gerçek zamanlı tahmin yapacak şekilde gömülü sistemlere (Jetson Nano, Raspberry Pi 5 vb.) aktarılabilir.
5. Şerit değiştirme davranışının alt kategorilere ayrılması mümkündür.
 - Zorunlu şerit değişimi (örneğin engel nedeniyle)
 - İsteğe bağlı şerit değişimi
 - Sollama amacıyla yapılan şerit değişimiBu alt sınıflar ayrı bir modelleme gerektirebilir.
6. Gürültü azaltma ve veri dengeleme teknikleriyle model performansı artırılabilir.
SMOTE, ADASYN gibi yöntemlerle negatif-pozitif dengesizliği giderilebilir.

Genel Değerlendirme

Bu çalışma, gerçek sürüş verileri kullanılarak sürücünün şerit değiştirme niyetinin eylemden önce yüksek doğrulukla tahmin edilebileceğini göstermiştir. Yöntemin temel gücü, çoklu sensör verilerinin zaman uyumlu bir şekilde birleştirilmesi ve davranışsal, çevresel ve araç dinamiklerine ilişkin sinyallerin birlikte değerlendirilmesidir. Elde edilen sonuçlar, sürücü destek sistemleri ve otonom araç mimarileri için uygulanabilir niteliktedir ve bu alanda yapılacak ileri çalışmalar için güçlü bir temel sunmaktadır.

KAYNAKÇA

- Abbas, M., Haque, M. M., Washington, S., & Oviedo-Trespalacios, O. (2019). Driver behaviour modelling using temporal driving patterns. *Transportation Research Part F: Traffic Psychology and Behaviour*, 62, 1–13.
- Bertozzi, M., & Broggi, A. (1998). GOLD: A parallel real-time stereo vision system for generic obstacle and lane detection. *IEEE Transactions on Image Processing*, 7(1), 62–81.
- Brookhuis, K. A., de Waard, D., & Janssen, W. H. (2009). Behavioural impacts of advanced driver assistance systems—An overview. *Human Factors*, 51(2), 271–280.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357.
- Dong, Y., Hu, Z., Uchimura, K., & Murayama, N. (2011). Driver inattention monitoring system for intelligent vehicles: A review. *IEEE Transactions on Intelligent Transportation Systems*, 12(2), 596–614.
- Doshi, A., & Trivedi, M. M. (2010). Investigating the relationships between gaze patterns, dynamic vehicle surround display, and driving performance. *IEEE Transactions on Intelligent Transportation Systems*, 11(4), 786–798.
- Evans, L. (2004). *Traffic safety*. Science Serving Society.
- Foresee, F. D., & Hagan, M. T. (1997). Gauss–Newton approximation to Bayesian learning. In *Proceedings of the International Joint Conference on Neural Networks (IJCNN)* (pp. 1930–1935). IEEE.
- Güneş, A. (2022). *Gerçek sürücü davranışlarından şerit değiştirme eyleminin YSA ile tahmin modeli* (Doktora tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü). <https://avesis.gazi.edu.tr/yonetilen-tez/90dc4fee-b786-48aa-a980-6a789d4d011e/gercek-surucu-davranislarindan-serit-degistirme-eyleminin-ysa-ile-tahmin-modeli>
- Ji, Q., Zhu, Z., & Lan, P. (2004). Real-time nonintrusive monitoring and prediction of driver fatigue. *IEEE Transactions on Vehicular Technology*, 53(4), 1052–1068.
- Jain, A., Singh, S., & Koppula, H. S. (2016). Recurrent models of driver behavior for driver activity anticipation. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 303–312). IEEE.
- Labayrade, R., Aubert, D., & Tarel, J.-P. (2002). Real time obstacle detection in stereo vision on non-flat road geometry. In *IEEE Intelligent Vehicle Symposium* (pp. 646–651). IEEE.
- Liu, Y., Chen, H., & Zhang, Q. (2018). Multimodal fusion for driver intention prediction in intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 19(4), 1234–1245.
- MacKay, D. J. C. (1992). A practical Bayesian framework for backpropagation networks. *Neural Computation*, 4(3), 448–472.
- McCall, J. C., & Trivedi, M. M. (2007). Driver behavior and situation-aware brake assistance for intelligent vehicles. *Proceedings of the IEEE*, 95(2), 374–387.
- Olabi, O., et al. (2017). Real-time driver behavior classification using deep recurrent neural networks. In *2017 IEEE Intelligent Vehicles Symposium (IV)* (pp. 170–175). IEEE.
- Peng, Y., Guo, H., & Zhao, L. (2015). Predicting lane-changing behaviour using vehicle dynamic data. In *2015 IEEE Intelligent Vehicles Symposium* (pp. 180–185). IEEE.

World Health Organization. (2018). *Global status report on road safety 2018*. WHO Press.

Yang, S., & Zhang, H. (2019). Multi-sensor fusion-based driver intention prediction using machine learning techniques. *Sensors*, 19(12), 2732.

BÖLÜM 3

UYGULAMAYA ÖZGÜ ENTEGRE DEVRE (ASIC) TASARIM AKIŞI VE METODOLOJİSİ

Bahadır ÖZKILBAÇ¹

Giriş

Yarı iletken teknolojisindeki hızlı gelişmeler, günümüz elektronik sistemlerinin performans, güç tüketimi ve kullanım alanı verimliliğini her geçen gün daha da kritik hale getirmektedir (Kizilyalli vd., 2022; Chaudhary vd., 2023; Mukherjee vd., 2024; Dasgupta vd., 2025). Bu yüzden belirli bir uygulama ya da işlev için özel olarak tasarlanan, yüksek hız performansı, kullanım alanı verimliliği ve düşük güç tüketimine sahip uygulamaya özgü entegre devreler (ASIC), modern sistemlerin temel yapı taşlarından biri haline gelmiştir (Cisneros vd., 2025; Bhaduari vd., 2025; Babu vd., 2025). Haberleşme altyapılarından otomotiv elektroniğine, tüketici elektroniğinden savunma ve uzay uygulamalarına kadar geniş bir yelpazede kullanılan ASIC'ler, genel amaçlı mikro denetleyicilere kıyasla daha özelleştirilmiş ve optimize çözümler sunmaktadır (Gupte vd., 2025).

ASIC'ler milyonlarca hatta milyarlarca transistör içeren karmaşık yapılar olduğundan tasarımı tek bir soyutlama seviyesinde ele alınamayacak kadar kapsamlı bir mühendislik gerektirir (Aifer vd., 2025; Wilken, 2025). Bu yüzden modern ASIC tasarım süreci, sistem gereksinimlerinin belirlenmesinden başlayarak mimari tasarım, RTL seviyesinde tanımlama, fonksiyonel doğrulama, sentezleme, fiziksel tasarım ve silikon sonrası doğrulamaya kadar uzanan çok aşamalı ve disiplinler arası bir tasarım akışını içermektedir (Shetty, 2019; Rao vd., 2025). Her bir aşama bir sonraki adımın başarısını doğrudan etkileyen kritik kararlar barındırmaktadır (Kommuru vd., 2009). Herhangi bir aşamadaki küçük bir hata yüzünden tasarım zamanı ve maliyeti önemli ölçüde artmaktadır. Bu yüzden tasarım sürecinin bütüncül bir bakış açısıyla ele alınmasını zorunlu kılmaktadır.

Bu çalışmanın temel amacı, ASIC tasarım akışını ve kullanılan metodolojileri sistematik ve anlaşılır bir biçimde ele alarak bu alandaki araştırmacılara uçtan uca bir tasarım perspektifi kazandırmaktır. Bu kapsamda ASIC türleri, endüstriyel uygulama alanları, tam özel, yarı özel ve programlanabilir tasarım yöntemleri ayrıntılı olarak incelenmiştir. Modern ASIC tasarım akışının her bir aşaması teknik detaylarıyla açıklanmıştır. Özellikle RTL tabanlı tasarım, fonksiyonel ve formel doğrulama yöntemleri, sentezleme, yerleştirme ve yönlendirme süreçleri ile silikon sonrası doğrulama aşamalarına vurgu yapılarak, teorik bilginin pratik endüstri uygulamalarıyla ilişkilendirilmesi hedeflenmiştir.

1. Uygulamaya Özgü Entegre Devre (ASIC):

ASIC'ler, belirli bir uygulama ya da görev için özel olarak tasarlanan entegre devrelerdir. Bu entegre devreler milyonlarca hatta milyarlarca transistör içeren karmaşık bir yapıya sahiptir. Yüksek karmaşıklık seviyesi tasarımın tek bir soyutlama seviyesinde gerçekleşmesini zorlaştırmaktadır. Yalnızca şematik giriş veya özel yerleşim gibi düşük seviyeli soyutlamalar kullanılarak tüm sistemin tasarlanması pratikte uygulanabilir değildir. Bu nedenle ASIC tasarım süreci, birbirinden farklı soyutlama seviyelerine ve alt tasarım alanlarına ayrılmaktadır.

ASIC örnekleri arasında uydu sistemlerinde kullanılan yongalar, mikroişlemciyi bir blok olarak içerip diğer mantıksal birimlerle birleştiren yongalar ve iş istasyonlarında bellek ile merkezi işlem birimi arasındaki ara yüzü kontrol eden yongalar yer almaktadır (Zahiri, 2003; Amara vd., 2006; Xu, 2024). ASIC olmayan devrelere örnek olarak rastgele erişimli bellek (RAM), salt okunur bellek (ROM) ve statik rastgele erişimli bellek (SRAM) gibi bellek yongaları ile mikroişlemciler gibi standart bileşenler verilebilir. Bu tür devreler, uygulamaya özel standart ürünler (ASSP) sınıfında yer almaktadır (Richard, 2022). ASIC mimarilerinin sağladığı performans ve alan verimliliğine rağmen tasarım ve üretim süreçlerinden kaynaklanan bazı sınırlamaları da bulunmaktadır. Bu kapsamda ASIC'lerin başlıca avantajları ve dezavantajları aşağıdaki gibi özetlenmiştir.

ASIC'lerin avantajları:

- Belirli bir uygulamaya özel olarak tasarlandıkları için istenildiği şekilde optimize edilebilirler.
- Optimize edilmiş yapıları sayesinde düşük güç tüketimi ve yüksek performans ile çalışırlar.
- Genel amaçlı devrelere kıyasla daha hızlı işlem süreleri sağlarlar.
- Kompakt yapıları sayesinde donanım sistemlerinde alan tasarrufu sağlarlar.
- Yüksek hacimli üretimlerde birim maliyetleri düşüktür.

ASIC'lerin dezavantajları:

- Tasarım ve geliştirme süreci maliyetlidir.
- Tasarım süresi uzundur.
- Üretim sonrası değiştirilemez ve yeniden programlanamazlar.
- Tasarım hataları veya güncellemeler için yeni yonga üretimi gereklidir.
- Tasarım akışında olası bir hata maliyeti ve tasarım süresini artırmaktadır.
- Düşük hacimli üretimlerde başlangıç maliyeti yüksek olduğu için ekonomik değildirlir.

2. ASIC'lerin Modern Endüstriyel Uygulamaları

ASIC'ler, yüksek performans, düşük güç tüketimi ve daha küçük fiziksel alana sahip olma avantajlarından dolayı günümüzde endüstriyel uygulamalarda yaygın şekilde kullanılmaktadır (Supermicro, 2025). Belirli bir uygulamaya özel olarak tasarlanmaları, bu devreleri yüksek performans ve verimliliğin kritik olduğu uygulamalar için ideal hale getirmektedir. Bu bölümde ASIC devrelerinin yaygın olarak kullanıldığı başlıca sektörler ve bu sektörlerde üstlendikleri temel roller özetlenmektedir.

2.1. Telekomünikasyon

ASIC'ler modern telekomünikasyon altyapılarında, ağ anahtarları ve yönlendiriciler içerisinde yüksek hızlı veri yönlendirme ve paket anahtarlama işlemlerini gerçekleştirmek amacıyla kullanılmaktadır (Zhang vd., 2000; Chen vd. 2009; Jiang vd., 2023). Telekomünikasyon alanındaki bu tür uygulamalarda, ASIC'ler düşük gecikme süreleriyle çalışarak geniş ölçekli ağlarda kesintisiz iletişim ve düzenli veri akışını güvence altına almaktadır (Schimansky vd., 2023).

2.2. Otomotiv

ASIC'ler gelişmiş sürücü destek sistemleri (ADAS) ve elektrikli araçlarda, radar, lidar ve kamera verilerinin gerçek zamanlı olarak işlenmesini sağlayan algılayıcı modüllerine entegre edilmektedir (Giesemann vd., 2014; García VD., 2024). ASIC'lerin yüksek hız performansı sayesinde yol koşullarındaki ani değişimlere hızlı tepki verilerek sürüş güvenliği önemli ölçüde artırılmaktadır.

2.3. Tüketici Elektroniği

Akıllı telefonlarda kullanılan görüntü işleme birimleri genellikle ASIC tabanlıdır. Görüntü işleme birimlerinde ASIC'ler, yüksek çözünürlüklü görüntü ve video verilerinin etkin bir şekilde işlenmesini sağlarken, gerçek zamanlı yüz tanıma ve artırılmış gerçeklik gibi gelişmiş özelliklerin düşük güç tüketimiyle çalışmasını sağlamaktadır (Valle vd., 1995).

2.4. Sağlık Teknolojileri

Tıbbi cihazlarda taşınabilir tanı sistemlerinde ASIC'ler yaygın şekilde kullanılmaktadır. Elektrokardiyografi monitörleri gibi cihazlarda, biyomedikal sinyallerin işlenmesi ve verilerin iletilmesini üstlenerek hızlı ve doğru ölçüm sonuçları elde edilmesini sağlamaktadırlar. Aynı zamanda düşük güç tüketimi sayesinde cihazların pil ömrü uzatılmaktadır (Zhang vd., 2009).

2.5. Havacılık ve Uzay


ASIC'ler uydu haberleşme sistemlerinde, sinyal modülasyonu ve hata düzeltme işlemlerini gerçekleştirmek için kullanılmaktadır. Enerji kaynaklarının sınırlı olduğu uzay ortamlarında, ASIC'lerin enerji verimliliğinden faydalanılmaktadır (Gardenyes, 2011).

2.4. Üretim ve Endüstriyel Otomasyon

Endüstriyel otomasyon sistemlerinde, robot kolların ve üretim hatlarının kontrolünde ASIC'ler yaygın şekilde kullanılmaktadır. ASIC tabanlı kontrol devreleri, kodlayıcı, sensör ve geri besleme birimlerinden gelen verileri gerçek zamanlı olarak işleyerek motor sürme sinyallerini anında güncelleyebilmekte ve böylece mikrometre seviyesinde konumlama doğruluğu ile tekrarlanabilir hareketler gerçekleştirilmesini sağlamaktadır. Bu sayede robot kolların belirlenen yörüngeleri sapma olmadan takip etmesi, montaj ve paketleme gibi tekrarlayan işlemlerin yüksek doğrulukla yürütülmesi sağlanmaktadır (Prasad vd., 2011; Alkhafaji vd., 2018).

3. ASIC Türleri:

ASIC'ler, Şekil 1'den de görüldüğü üzere tasarım yöntemine göre üç farklı sınıfa sahiptir. Bu yöntemler tam özel tasarım, yarı özel tasarım ve programlanabilir tasarımdır. Bu üç tasarım yöntemi arasında kullanılan hücre yapıları, tasarım esnekliği, performans ve geliştirme süresi açısından farklılıklar bulunmaktadır.



Şekil 1 ASIC Türleri

3.1. Tam Özel ASIC


Tam özel tasarımda devreyi oluşturan tüm mantık hücreleri, transistör seviyesinden itibaren özel olarak tasarlanmaktadır. Bu yöntemde tasarlanan ASIC'in üretim süreci yaklaşık sekiz haftadır. Bu yüzden tüm maske katmanları özel olarak oluşturulur. Tam özel tasarımı ASIC'lerde tasarımın tüm detaylarına müdahale edilebildiğinden tasarımcı optimizasyon açısından yüksek esnekliğe sahiptir. En önemli avantajları yüksek performans elde edilmesi ve büyük hacimli üretimlerde birim maliyetin düşürülmesidir. Ancak bu yöntemin uzun tasarım süresi, doğrulama süreci zorluğu, yüksek tasarım riski ve karmaşıklık gibi dezavantajları bulunmaktadır. Tam özel tasarım ASIC'ler hazır kütüphanenin bulunmadığı, mevcut kütüphanelerin istenen hız performansını sağlayamadığı ya da güç tüketimi, maliyet ve yonga alanı gibi etkenlerin kritik olduğu durumlarda tercih edilmektedir.

3.2. Yarı Özel ASIC

Yarı özel ASIC'lerde önceden tasarlanmış ve doğrulanmış standart hücreler, tam özel olarak geliştirilmiş bloklar ve işlevsel standart blok çekirdekleri birlikte kullanılmaktadır. Yarı özel ASIC'ler standart hücre tabanlı ve kapı dizisi tabanlı olmak üzere iki çeşittir.

3.2.1. Standart Hücre Tabanlı ASIC

Standart hücre tabanlı ASIC'ler, standart hücre kütüphanesi kullanılarak tasarlanmaktadır. Standart hücre kütüphanesi *and*, *or* ve *not* gibi mantıksal kapıları, çoklayıcı ve flip flop gibi önceden tasarlanmış mantık hücrelerini içermektedir. Bu hücreler standartlaştırılarak ASIC yonga tasarımlarında kullanılmak üzere kütüphanelerde saklanmaktadır. Şekil 2'den görüldüğü üzere bir ASIC yongası, bahsedilen bu mantık hücrelerinin satırlar halinde yerleştirildiği bir standart hücre alanı veya sabit blok içermektedir. Bazı durumlarda mikro denetleyici veya mikroişlemci gibi daha büyük ve karmaşık yapılar da yonga içerisine entegre edilebilmektedir.




Şekil 2 Standart Hücre Tabanlı ASIC

Standart hücre tabanlı ASIC tasarımlarında maske katmanları özelleştirilebilir yapıdadır. Bu sayede tasarımcılar, standart hücreleri yonga alanı üzerinde istenilen konumlara yerleştirerek alan kullanımını verimli hale getirebilmekte ve performansı en üst seviyelere çıkarabilmektedir. Bu ASIC tasarım yöntemi, hücre tabanlı tümleşik devre tasarımı olarak da bilinmektedir.

3.2.2. Kapı Dizisi Tabanlı ASIC

Kapı dizisi tabanlı ASIC'ler silikon yonga üzerinde önceden tanımlanmış transistör dizilimlerine sahiptir. Transistörlerin yonga üzerindeki fiziksel konumları üretim aşamasında sabitlenmiştir. Tasarımcı transistörlerin yerleşimine üretimden sonra müdahale edememektedir. Ancak transistör arasındaki bağlantılar tasarımcı tarafından özelleştirilebilmektedir. Böylece aynı yonga üzerinde farklı devre işlevleri gerçekleştirilebilmektedir.

Kapı dizisi tabanlı ASIC'ler kapı dizisi kütüphanesi kullanılarak tasarlanmaktadır. Gerçekleştirilen tasarımlar, bağlantı yöntemlerine bağlı olarak kanallı kapı dizileri, kanalsız kapı dizileri veya yapılandırılmış kapı dizileri şeklinde sınıflandırılmaktadır. Şekil 3'te, kapı dizisi tabanlı ASIC tasarım yöntemleri olan kanallı kapı dizileri, kanalsız kapı dizileri ve yapılandırılmış kapı dizilerinin yonga yerleşim yapıları şematik olarak gösterilmektedir.



Şekil 3 Kapı Dizisi Tabanlı ASIC Tasarım Yöntemleri a) kanallı, b) kanalsız, c) yapılandırılmış

Kanallı kapı dizileri yönteminde mantık hücreleri arasında bağlantıların gerçekleştirilebilmesi için önceden tanımlanmış yönlendirme kanalları bulunmaktadır. Bu kanallar, kablo bağlantılarının düzenli ve öngörülebilir bir şekilde yapılmasını sağlar. Kanallı kapı dizileri,

standartlaştırılmış tasarımlar için uygun olup, bağlantı esnekliği gerektiren uygulamalarda tercih edilmektedir.

Kanalsız kapı dizilerinde, önceden tanımlanmış yönlendirme kanalları bulunmamaktadır. Bağlantılar doğrudan hücrelerin üzerinden geçirilerek gerçekleştirilmektedir. Bu yöntemde yonga alanı daha verimli şekilde kullanılarak yonga yoğunluğu artırılmaktadır. Böylece daha kompakt tasarımlar elde edilmektedir.

Yapılandırılmış kapı dizileri, önceden tanımlanmış mantık blokları ile özelleştirilebilir bağlantı katmanlarını bir arada sunmaktadır. Bu yöntem tasarım esnekliği ile hızlı geliştirme süreci arasında bir denge sağlamaktadır. Hem performans hem de geliştirme süresi açısından avantajlı bir yöntemdir.

3.3. Programlanabilir ASIC

Programlanabilir ASIC'ler programlanabilir mantık aygıtları (PLD) ve sahada programlanabilir kapı dizileri (FPGA) kullanılarak tasarlanmaktadır. Tasarımcı bu yöntemde diğer yöntemlerde göre daha yüksek tasarım kolaylığına sahiptir.

3.3.1 PLD Tabanlı ASIC


PLD'ler çeşitli mantıksal işlemleri gerçekleştirecek şekilde programlanabilen sayısal tümleşik devrelerdir. Tasarımcı yarı iletken üretim sürecine ihtiyaç duymadan mantık devrelerini gerçekleştirebilmektedir. PLD'ler esneklikleri ve hızlı yapılandırılabilimleri sayesinde farklı uygulama alanlarında yaygın olarak kullanılmaktadır. Ancak kapasiteleri düşük olduğundan çok karmaşık devrelerde PLD'ler tercih edilmemektedir.

3.3.2 FPGA Tabanlı ASIC

Aslında FPGA'ler de bir PLD çeşididir. Ancak çok daha farklı özelliklere ve kapasiteye sahip olduğundan dolayı genellikle PLD'lerden ayrı bir başlıkta değerlendirilmektedir. FPGA'ler tasarımcı gereksinimlerine bağlı olarak üretimden sonra yapılandırılabilmekte ve aynı donanım farklı amaçlarla tekrar tekrar programlanabilmektedir. Bu özellikleri sayesinde prototipleme çalışmaları, düşük hacimli üretimler ve tasarım doğrulama süreçlerinde yaygın şekilde kullanılmaktadırlar. PLD ve FPGA tabanlı ASIC'lerde, diğer yöntemlere göre güç tüketimi daha yüksek, kullanım alanı verimliliği ve hız performansı daha düşüktür.

4. ASIC Tasarım Akışı

Genel olarak bir ASIC tasarım akışı Şekil 4'te verilen yapıya sahip olup birden fazla adıma ayrılmaktadır. Bu aşamaların bazıları paralel olarak yürütülürken, bazıları ise sıralı biçimde gerçekleştirilmektedir. Bu bölümde, modern endüstride kullanılan bir ASIC proje tasarım döngüsünün nasıl ilerlediği ele alınmaktadır.



Şekil 4 ASIC Tasarım Akışı Algoritmik Şeması

4.1. Sistem ve Tasarım Gereksinimlerinin Toplanması

Genellikle bir yarı iletken firmasının müşterisi, geliştirilecek yongayı kendi sistemlerinde veya nihai ürünlerinde kullanmayı planlayan başka bir şirkettir. Bu nedenle müşterinin gereksinimleri, yonganın nasıl tasarlanacağına karar verilmesindeki en büyük etkidir. Tasarım sürecinin ilk adımı, müşteri gereksinimlerinin ayrıntılı biçimde toplanmasıdır. Bu aşamada, geliştirilecek ürünün pazardaki potansiyel değeri tahmin edilmekte ve projenin gerçekleştirilmesi için gerekli teknik, insan kaynağı ve zaman gibi kaynak gereksinimleri değerlendirilmektedir. Bu değerlendirmeler, tasarımın kapsamının belirlenmesi ve projenin fizibilitesinin ortaya konulması açısından oldukça önemlidir.

4.2. Ürün Gereksinimleri/Spesifikasyon

Bu aşamada tasarlanacak yonganın işlevselliğini, ara birimlerini ve genel mimarisini soyut düzeyde tanımlayan spesifikasyonlar toplanmaktadır. Bu spesifikasyonlar, yonganın hangi görevleri yerine getireceğini ve hangi donanımsal yeteneklere sahip olması gerektiğini açıkça ortaya koymaktadır. Bu tür gereksinimler aşağıdaki örneklerle ifade edilebilir:

- Sanal gerçeklik uygulamalarını desteklemek amacıyla görüntü işleme algoritmalarını çalıştırabilecek hesaplama gücüne sahip olunması gerekmektedir.
- İki adet ARM A53 işlemci çekirdeği içermeli ve bu çekirdekler altı yüz megahertz frekansında çalışabilmelidir.
- USB 3.0, Bluetooth ve ikinci nesil PCIe arabirimlerini desteklemelidir.
- Uygun bir görüntü denetleyicisi ile birlikte 1920x1080 çözünürlüğünde ekran desteği sunulmalıdır.

Bu tür mimari spesifikasyonlar, sistem seviyesinde tasarım kararlarının verilmesini sağlamaktadır. Ayrıca yonganın donanım kaynaklarının, performans hedeflerinin ve arabirim yapısının belirlenmesinde bir yol haritası oluşturmaktadır.

4.3. Sistem Mimarisı Spesifikasyonu

Bu aşamada sistem mimarları, yonganın nasıl çalışması gerektiğine ilişkin sistem seviyesinde bir bakış açısı geliştirmektedir. Mimari tasarım sürecinde, yonga içerisinde hangi bileşenlerin yer alacağı, bu bileşenlerin hangi saat frekanslarında çalışacağı, paketleme türü, dış dünya ile haberleşmeyi sağlayacak iletişim protokolleri, ürünün çalışması gereken sıcaklık aralığı, güç tüketimi ve performans gereksinimlerinin nasıl karşılanacağı belirlenmektedir. Veri akışının yonga içerisindeki nasıl gerçekleşeceği de bu aşamada tanımlanmaktadır. Örneğin bir işlemcinin sistem belleğinden görüntü verilerini alarak bu veriler üzerinde işlem yapması sırasında izlenen veri akışı mimari düzeyde ele alınmaktadır.

4.4. Kaydedici Transfer Seviyesinde (RTL) Tasarım

Basit bir ifadeyle RTL verinin bir kaydediciden başka bir kaydediciye aktarılmasını esas alan bir tasarım soyutlama düzeyidir. Diğer soyutlama seviyelerindeki belirli sınırlamalar ve dezavantajlar nedeniyle, tasarımcılar RTL soyutlamaya yönelmektedir. RTL, bir sayısal tasarımın dijital kısmının davranışını soyut bir biçimde ifade etmektedir. RTL tanımı genellikle Verilog ve VHDL gibi donanım tanımlama dilleri kullanılarak gerçekleştirilmektedir. Senkron mantık temelli bu soyutlama seviyesi, sistemin durum bilgisini tutan kaydediciler, bir sonraki durumun girişlerini belirleyen kombinasyonel mantık blokları ve durum değişimlerinin ne zaman gerçekleşeceğini kontrol eden saat sinyalleri olmak üzere üç bileşenden oluşmaktadır. Bu yapı sayesinde RTL seviyesi, tasarımın hem fonksiyonel davranışının açık bir şekilde tanımlanmasına hem de sentez ve doğrulama süreçlerinin etkin biçimde yürütülmesine olanak sağlamaktadır. Şekil 5'te bir RAM'in RTL soyutlama seviyesinde Verilog kodu verilmiştir.

```

module ram_single_port
#(
  parameter ADDR_WIDTH = 16,
    DATA_WIDTH = 32
)
(
  input wire clk,
  input wire we,
  input wire [ADDR_WIDTH-1:0] addr,
  input wire [DATA_WIDTH-1:0] din,
  output wire [DATA_WIDTH-1:0] dout
);

reg [DATA_WIDTH-1:0] mem[2**ADDR_WIDTH-1:0];

always @(posedge clk) begin
  if (we == 1) // write data to address 'addr'
    mem[addr] <= din;
end

  // read data from current addr
  assign dout = mem[addr];

endmodule

```

Şekil 5 RTL Soyutlama Seviyesinde Verilog RAM Kodu

4.5. Fonksiyonel Doğrulama

ASIC tasarımıyla doğrulama işlemi, geliştirilen tasarımın beklenen işlevleri doğru ve eksiksiz bir biçimde yerine getirdiğinin kontrol edilmesidir. Yonga tasarımı ve üretimi yüksek maliyetli bir süreç olduğundan, tasarım hatalarının üretim sonrasında fark edilmesi hem ekonomik hem de teknik açıdan ciddi sonuçlar doğurabilmektedir. Bu nedenle RTL doğrulama, ASIC tasarımının en kritik ve en zor aşamalarından biri olarak kabul edilmektedir.

Endüstride yaygın olarak kullanılan doğrulama yaklaşımı fonksiyonel doğrulamadır. Bu yöntemde tasarımın RTL modeli, çeşitli giriş uyarımları ile simüle edilmekte ve elde edilen çıktılar beklenen sonuçlarla karşılaştırılmaktadır. Fonksiyonel doğrulama elektronik tasarım otomasyonu (EDA) simülatör araçları kullanılarak yapılır. Doğrulama işlemleri hem her bir modül için hem de tüm tasarım için gerçekleştirilmektedir.

Fonksiyonel doğrulamanın kapsama oranını değerlendirmek amacıyla farklı kapsama metrikleri kullanılmaktadır. Bunlar arasında satır kapsamı ve durum kapsamı gibi ölçütler yer almaktadır. Satır kapsamı, RTL kodundaki hangi satırların simülasyon sırasında çalıştırıldığını ölçerken, durum kapsamı tasarımın olası durum uzayının ne kadarının doğrulandığını göstermektedir.

4.6. Sentezleme ve Netlist Oluşturulması

Sentezleme, donanım tanımlama dilindeki (HDL) tasarımı standart kapılar, flip floplar, hücre kütüphaneleri ve bellek blokları kullanarak kapı seviyesinde donanım şemasına dönüştürme işlemidir. Sentezleme araçları HDL'deki RTL tanımını kapı seviyesinde bir netliste dönüştürmeyi sağlamaktadır. Bu süreç temel olarak çeviri, eniyileme ve eşleme olmak üzere üç ana adımdan oluşmaktadır. Çeviri aşamasında, HDL biçiminde yazılmış kod kapı seviyesinde Boolean denklemlerine dönüştürülmektedir. Eniyileme aşamasında ise bu Boolean denklemleri sadeleştirilerek daha az donanım kaynağı kullanacak şekilde düzenlenmektedir. Son aşamada, eniyileme işleminde geçmiş Boolean denklemleri hedef teknolojiye ait kütüphane dosyalarındaki hücrelerle eşleştirilerek tasarımın netlist'i elde edilir.

Sentezleme araçları HDL veya RTL ile tanımlanan tasarımı, hedeflenen hızda çalışacak, belirli bir yonga alanını aşmayacak ve kabul edilebilir güç tüketimi sınırları içinde kalacak şekilde kapı seviyesinde bir devreye dönüştürür. Bu araçlar farklı üretim teknolojileri için hazırlanmış hücre kütüphanelerini kullanarak tasarımı, hedeflenen teknolojiye uygun biçime dönüştürmektedir. Böylece farklı kısıtları aynı anda karşılayacak şekilde akıllı hesaplamalar ve optimizasyonlar gerçekleştirebilmektedirler. Kullanılan kütüphaneler, yarı iletken üretim tesisleri tarafından sağlanmakta olup, flip-floplar için yükselme ve düşme süreleri, kapılar için giriş ve çıkış zamanlama bilgileri gibi farklı bileşenlere ait karakteristik verileri içermektedir.


4.7. Eşdeğerlik Denetimi

Eşdeğerlik denetimi aynı zamanda formel doğrulama olarak da bilinmektedir. Fonksiyonel doğrulamada, devreye çok sayıda giriş vektörü uygulanır. Elde edilen çıkış vektörleri beklenen sonuçlarla karşılaştırılarak doğrulama gerçekleştirilir. Ancak tasarımlar büyüdükçe daha fazla simülasyon vektörüne ihtiyaç duyulmaktadır. Bu durumda geleneksel simülasyon araçlarıyla yapılan regresyon testleri tasarım akışında ciddi bir darboğaz haline gelmektedir. Eşdeğerlik denetimi doğrulanmak istenen mantık yapısını matematiksel yöntemler kullanarak ya mantıksal bir spesifikasyonla ya da referans bir tasarımla karşılaştırmaktadır. Fonksiyonel doğrulamadan farklı olarak giriş vektörlerine ihtiyaç duymaz. Bu yöntemde yalnızca mantıksal fonksiyonlar dikkate alındığından doğrulama süreci tasarımın fiziksel özelliklerinden bağımsız olarak gerçekleştirilmektedir.

4.8. Yerleştirme ve Yönlendirme

Oluşturulan netlist fiziksel tasarım akışına girdi olarak verilmektedir. Bu aşamada EDA araçlarının yardımıyla otomatik yerleştirme ve yönlendirme işlemleri gerçekleştirilmektedir. Bu tür araçlara örnek olarak Cadence Encounter ve Synopsys IC Compiler verilebilir.

Yerleştirme ve yönlendirme sürecinde, standart hücreler yonga alanı üzerinde satırlar halinde uygun konumlara yerleştirilmekte, giriş/çıkış pinleri için bağlantı düzenleri tanımlanmakta ve farklı metal katmanlar oluşturulmaktadır. Ayrıca zamanlama gereksinimlerinin karşılanabilmesi için gerekli noktalara tamponlar eklenmektedir. Bu işlemlerin tamamlanmasının ardından, yonganın fiziksel yerleşimini temsil eden bir yerleşim çıktısı elde edilmektedir. Bu çıktı genellikle üretim aşaması için fabrikaya gönderilmektedir. Yerleştirme ve yönlendirme aşaması üretim teknolojisi düğümüne ve fiziksel gerçekleştirim ayrıntılarına hâkim olan fiziksel tasarım ekibi tarafından yürütülmektedir. Bu ekip, tasarımın zamanlama, alan ve üretilebilirlik gereksinimlerini karşılamasını sağlayarak yonganın üretime hazır hale gelmesinden sorumludur. Şekil 6'da Cadence Encounter ortamında gerçekleştirilen otomatik yerleştirme ve yönlendirme sonrası oluşan fiziksel tasarım görünümü verilmiştir (ChipVerify, 2025).



Şekil 6 Otomatik Yerleştirme ve Yönlendirme Aşaması ile Elde Edilen ASIC Fiziksel Yerleşimi

4.9. Doğrulama

Bu aşamada tasarlanan yonganın bir örneği, ya aynı yarı iletken firma tarafından ya da TSMC veya GlobalFoundries gibi üçüncü taraf bir firmaya gönderilerek üretilir. Üretilen örnek yonga silikon sonrası doğrulama sürecine alınmaktadır. Bu aşamada farklı bir mühendis ekibi tarafından test cihazları üzerinde çeşitli testler uygulanır. Silikon sonrası doğrulama süreci, silikon öncesi doğrulamaya kıyasla hata ayıklama açısından çok daha zordur. Bunun temel nedeni yonga içerisindeki dahili düğümlere erişimin büyük ölçüde kısıtlanmış olmasıdır. Ayrıca modern yongalarda bir saniye içerisinde milyonlarca saat çevriminin gerçekleşmesi, hatanın oluştuğu anın geriye dönük olarak izlenmesini son derece zaman alıcı hale getirmektedir.

Silikon sonrası doğrulama aşamasında herhangi bir problem veya tasarım hatası tespit edilmesi durumunda ilgili hatanın RTL seviyesinde düzeltilmesi ardından yeniden doğrulama yapılması

ve tasarım akışındaki tüm sonraki adımların tekrar edilmesi gerekmektedir. Bu durum doğrulama aşamasında ortaya çıkan hataların hem zaman hem de maliyet açısından oldukça negatif sonuçlar doğurabileceğini göstermektedir. ASIC tasarımında faaliyetlerin büyük bir bölümü genellikle devrenin RTL tanımının doğrulanması ve optimize edilmesi üzerinedir. Süreci otomatikleştirmek için çok sayıda EDA aracı mevcut olsa da bu araçların hatalı veya bilinçsiz kullanımı verimsiz tasarımlara yol açabilmektedir. Bu yüzden tasarımcının tüm tasarım süreci boyunca bilinçli ve dikkatli kararlar alması büyük önem taşımaktadır.

ASIC'lerin genel amaçlı devrelere kıyasla sunduğu yüksek performans, düşük güç tüketimi ve alan verimliliği gibi avantajları, bu devrelerin günümüz elektronik sistemlerinde neden vazgeçilmez hale geldiğini açıkça ortaya koymaktadır. Bununla birlikte yüksek tasarım maliyeti ve karmaşık geliştirme süreci gibi dezavantajlar, ASIC tasarımının dikkatli planlama ve doğru metodolojiler yapılması gerektiğini göstermektedir.

ASIC tasarım akışı boyunca sistem gereksinimlerinin doğru tanımlanmasının, mimari kararların sağlıklı biçimde alınmasının ve RTL seviyesinde yapılan doğrulamanın tasarımın başarısı açısından oldukça kritiktir. Özellikle fonksiyonel doğrulama, formel doğrulama ve eşdeğerlik denetimi gibi aşamalar, üretim öncesinde olası hataların tespit edilmesini sağlayarak maliyetli tasarım hatalarının önüne geçmektedir. Sentezleme, yerleştirme ve yönlendirme süreçleri ise tasarımın fiziksel olarak üretilebilir hale gelmesini sağlayıp zamanlama, alan ve güç gereksinimlerinin karşılanmasında belirleyici rol oynamaktadır.

ASIC tasarımı yalnızca otomatik EDA araçlarının kullanıldığı bir süreç değil, aynı zamanda tasarımcının deneyimine ve bilinçli mühendislik kararlarına dayanan karmaşık bir optimizasyon problemidir. Bu çalışmada ASIC tasarım akışı ve metodolojileri bütüncül bir yaklaşımla sunulurken, araştırmacı ve tasarımcıların hem teorik hem de pratik açıdan sağlam bir temel kazanması amaçlanmıştır. Sunulan bilgiler gelecekte geliştirilecek yüksek performanslı ve enerji verimli entegre devre tasarımlarına rehberlik edecek niteliktedir.

Kaynaklar

- Aifer, M., Belateche, Z., Bramhavar, S., Camsari, K. Y., Coles, P. J., Crooks, G., ... & Wright, L. G. (2025). Solving the compute crisis with physics-based ASICs. arXiv preprint arXiv:2507.10463.
- Alkhafaji, F. S., Hasan, W. Z., Isa, M. M., & Sulaiman, N. (2018). Robotic controller: ASIC versus FPGA—A review. *J. Comput. Theor. Nanosci*, 15(1), 1-25.
- Amara, A., Amiel, F., & Ea, T. (2006). FPGA vs. ASIC for low power applications. *Microelectronics journal*, 37(8), 669-677.
- Babu, S. J., Hu, F., Zhu, L., Singhal, S., & Guo, X. (2025). Extending Silicon Lifetime: A Review of Design Techniques for Reliable Integrated Circuits. arXiv preprint arXiv:2503.21165.
- Bhadauria, S., & Chandel, L. K. (2025). Exploring the building blocks of future technologies. *Nanoelectronics: Advanced Concepts and Device Applications*, 19.
- Chaudhary, O. S., Denaï, M., Refaat, S. S., & Pissanidis, G. (2023). Technology and applications of wide bandgap semiconductor materials: current state and future trends. *Energies*, 16(18), 6689.
- Chen, X., Zhang, X., Zhang, L., Li, X., Qi, N., Jiang, H., & Wang, Z. (2009). A wireless capsule endoscope system with low-power controlling and processing ASIC. *IEEE Transactions on Biomedical Circuits and Systems*, 3(1), 11-22.
- ChipVerify. ASIC/SoC chip design flow. Aralık 2025, <https://www.chipverify.com/verilog/asic-soc-chip-design-flow>
- Cisneros, S. O., Leon, E. I. B., & Alvarez, P. M. (2025) *Integrated Circuit Design*.
- Dasgupta, A., Sen, S., Singh, P., & Raman, A. (2025). A Comprehensive Overview of the Foundations of Semiconductor Materials. *Semiconductor Nanoscale Devices: Materials and Design Challenges*, 80-109.
- García, A. C. B., Vilar, A. A., Cao, A. M., Costas, L., García, U. F., Navarro, C. M. R., ... & Barreras, J. V. (2024, November). Wireless System-on-Cell for Smart Battery Management in Electric Vehicles. In *2024 Third International Conference on Sustainable Mobility Applications, Renewables and Technology (SMART)* (pp. 1-9). IEEE.
- Gardenyes, R. B. (2011). Trends and patterns in ASIC and FPGA use in space missions and impact in technology roadmaps of the European Space Agency (Doctoral dissertation, Universitat Politècnica de Catalunya. Escola Tècnica Superior d'Enginyeria Industrial de Barcelona, 2011 (Enginyeria Industrial)).
- Gieseemann, F., Payá-Vayá, G., Blume, H., Limmer, M., & Ritter, W. (2014, July). A comprehensive ASIC/FPGA prototyping environment for exploring embedded processing systems for advanced driver assistance applications. In *2014 International Conference on Embedded Computer Systems: Architectures, Modeling, and Simulation (SAMOS XIV)* (pp. 314-321). IEEE.
- Gupte, S., Kadam, P. A., & Gupte, R. (2025). Evaluating Microcontrollers for Embedded and IoT Applications: Criteria, Trade-offs, and Selection Framework. *Int. J. Res. Appl. Sci. Eng. Technol.(IJRASET)*, 13, 655-660.

- Jiang, W., Jiang, H., Wu, J., & Zhou, P. (2023, May). Accelerating network coding with programmable switch ASICs. In ICC 2023-IEEE International Conference on Communications (pp. 1093-1099). IEEE.
- Kizilyalli, I. C., Spahn, O. B., & Carlson, E. P. (2022). Recent progress in wide-bandgap semiconductor devices for a more electric future. ECS Transactions, 109(8), 3.
- Kommuru, H. B., & Mahmoodi, H. (2009). ASIC design flow tutorial using synopsys tools. Nano-Electronics & Computing Research Lab, School of Engineering, San Francisco State University San Francisco, CA, Spring.
- Mukherjee, S., Pal, D., Bhattacharyya, A., & Roy, S. (2024). Future of the semiconductor industry. In Handbook of Semiconductors (pp. 359-374). CRC Press.
- Prasad, R., & Dhanabal, R. (2011). Low power ASIC design for automation in various industrial applications. International Journal of Advanced Engineering Sciences and Technologies, 6(1), 144-149.
- Rao, C. K., Talluri, A., & Hedayatipour, A. (2025, July). ASIC Design Flow Using Simulink and Cadence Digital IC Design Tools. In 2025 IEEE Computer Society Annual Symposium on VLSI (ISVLSI) (Vol. 1, pp. 1-5). IEEE.
- Richard, C. (2022). Common Circuits and System Components. In Understanding Semiconductors: A Technical Guide for Non-Technical People (pp. 97-135). Berkeley, CA: Apress.
- Schimansky, D., Busca, P., Collonge, M., Fajardo, P., Fischer, P., Ritzert, M., & Williams, M. (2023). Concepts for the data flow control on the XIDER readout ASIC. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 1057, 168720.
- Shetty, A. (2019). ASIC design flow and methodology—an overview. International Journal of Electrical and Electronics Engineering, 6(1), 1-5.
- Supermicro. ASIC. Aralık 2025, <https://www.supermicro.com/en/glossary/asic>.
- Xu, J. (2024, April). Comparison and Application of FPGA and ASIC in Digital System Design. In Proceedings of the International Conference on Decision Science & Management (pp. 216-220).
- Valle, M., Nateri, G., Caviglia, D. D., Bisio, G. M., & Briozzo, L. (1995, March). An ASIC design for real-time image processing in industrial applications. In Proceedings the European Design and Test Conference. ED&TC 1995 (pp. 385-390). IEEE.
- Wilken, F. (2025). Open Source Asic Design Curriculum.
- Zahiri, B. (2003, October). Structured ASICs: opportunities and challenges. In Proceedings 21st International Conference on Computer Design (pp. 404-409). IEEE.
- Zhang, L. L., Beacham, B., Hashemi, M. R., Chow, P., & Leon-Garcia, A. (2000). A scheduler ASIC for a programmable packet switch. IEEE Micro, 20(1), 42-48.
- Zhang, X., Jiang, H., Zhang, L., Zhang, C., Wang, Z., & Chen, X. (2009). An energy-efficient ASIC for wireless body sensor networks in medical applications. IEEE transactions on biomedical circuits and systems, 4(1), 11-18.

BÖLÜM 4

RÜZGAR ENERJİSİ TAHMİNİNDE KULLANILAN FİZİKSEL VE VERİ ODAKLI İSTATİSTİKSEL YÖNTEMLERİN İNCELENMESİ

Merve DEMİRCİ¹, Fatih UYSAL²

¹ Dr. Öğr. Üyesi, Kafkas Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, merve.demirci@kafkas.edu.tr, ORCID: 0000-0001-8192-7366.

² Doç. Dr., Kafkas Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, fatih.uyasal@kafkas.edu.tr, ORCID: 0000-0002-1731-2647.

Giriş:

Gün geçtikçe artan nüfus beraberinde hızla artan bir enerji ihtiyacı oluşturmaktadır. Artan enerji ihtiyacı çevreci, temiz ve sürdürülebilir olmaları nedeniyle son yıllarda yaygın olarak kullanılan yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmaktadır. Bu durum enerji sektöründeki yeni yatırımların yenilenebilir enerji kaynaklarına yönelmesini sağlamakta, yenilenebilir enerji kaynaklarının kullanımını arttırmaktadır. Yenilenebilir enerji kaynaklarından (güneş, rüzgar, dalga, biokütle, jeotermal ve hidro enerji) rüzgar enerjisi ise sürdürülebilir olması, minimum maliyet etkisi ve çevreyi kirletmemesi nedeniyle tercih edilmektedir. Ayrıca rüzgar türbinlerinde meydana gelen teknolojik gelişmeler ve bunun yanında rüzgar enerjisinden elektrik enerjisi üretmek için oluşan maliyetlerin geleneksel elektrik santralleriyle yarışabilecek seviyelerde olması da yenilenebilir enerji kaynakları arasında rüzgar enerjisinin tercih edilmesini sağlamaktadır [Barbosa De Alencar et al., 2017; Cakiroglu et al., 2024].

Son yıllarda artan yenilenebilir enerji yatırımları dünyada ve Türkiye’de hızla artmakta, bununla birlikte rüzgar enerjisinden elde edilen elektrik enerjisinin kurulu güç içerisinde payı da artmaktadır. Dünyada IRENA (International Renewable Energy Agency) 2025 Enerji İstatistik Raporu’na göre 2015 yılında 416 385 MW olan rüzgar enerjisi kapasitesi 2024 yılında 1 132 657 MW’a ulaşmıştır. Rüzgar enerjisi üretimi ise 2015 yılında 827 996 GWh iken 2023 yılında 2 303 935 GWh değerine ulaşmıştır [IRENA, 2025]. Tablo 1’de Türkiye için 2024 yılında yenilenebilir enerji kaynaklarından üretilen elektriğin miktarı ve yenilenebilir enerjinin üretilen elektrik içerisindeki yüzdesi verilmiştir. Tablo 2’de ise Türkiye’de 2014 ve 2024 yıllarında yenilenebilir enerji kaynaklarından üretilen elektrik enerjisi ve kurulu güç içerisindeki yüzdesi sunulmuştur. Rüzgar enerjisinin kurulu güç içerisindeki yüzdesi 2014 yılında %5,2 iken 2024 yılında bu oran iki kattan fazla artarak %11,1 olmuştur [TEİAŞ, 2024].


Tablo 1. 2024 yılı Türkiye yenilenebilir enerji kaynaklarından üretilen elektrik miktarı ve yüzdesi [TEİAŞ, 2024]

	GWh	%
Yenilenebilir+ Atık	9.452,9	5,80
Rüzgar	36.826,4	22,59
Güneş	30.746,0	18,86
Barajlı	57.149,6	35,06
D.Göl Ve Akarsu	17.703,6	10,86
Jeotermal	11.139,9	6,83
TOPLAM	163.018,3	100,00

Tablo 2. 2014 ve 2024 yılların içerisinde yenilenebilir enerji kaynaklarından üretilen enerji miktarı ve kuru güç içerisindeki yüzdesi [TEİAŞ, 2024]

	Hidrolik	Jeotermal	Rüzgar	Güneş
2014	23.643,2	404,9	3.629,7	40,2
%	34,01	0,58	5,2	0,1
2024	32.203,0	1.733,5	12.870,8	20.232,1
%	27,70	1,49	11,1	17,4
Birim: MW				

Rüzgar enerjisi kullanımının artmasıyla birlikte yapısı gereği hava olaylarına bağlı olarak yüksek dalgalanma ve aralıklı olması nedeniyle elektrik şebekesinin dengesi ve güvenilirliğinde istenmeyen durumlar meydana getirmektedir. Bu istenmeyen durumların üstesinden gelmek için rüzgar davranışını önceden tahmin etmek, üretilecek enerji için en az bir gün önceden tahmin yapabilmek önem taşımaktadır. Yapılacak doğru tahminler enerji planlaması, sistemin yönetimi, üretimin sevk ve idaresi için önem taşımaktadır. Rüzgar türbinlerinden üretilecek enerjinin tahmini bu nedenlerden dolayı araştırmacılar için ilgi odağı olmuş, çeşitli yöntemler ve farklı veriler kullanılarak üretilecek enerjiyi tahmin edilmeye yönelik çalışmalar yapılmıştır. Rüzgar enerjisi tahmini üzerine yapılan çalışmalar Şekil 1’de verilen fiziksel modeller, veri odaklı istatistiksel yöntemler olarak ikiye ayrılır [Tascikaraoglu & Uzunoglu, 2014]. Bu yöntemlerin bir arada kullanıldığı hibrit yöntemlerde bulunmaktadır.



Şekil 1. Rüzgar enerjisi tahmin yöntemleri

Fiziksel yöntemlerde, meteorolojik ölçümler atmosferik denklemlerle kullanılarak hava tahminine bağlı olarak rüzgar hızı tahmini yapılır. Rüzgar hızı tahmini yapıldıktan sonraki adımda üretilen enerji tahmini yapılmaktadır. Fiziksel modellerde hesaplama maliyetinin yüksek olması, yerel topografya özelliklerinin tahminde etkisinin sınırlı olması ve tasarımının zaman alıcı olması olası dezavantajlardır. Ayrıca fiziksel tabanlı yöntemler rüzgar türbini özelliklerinin denklemler ve modellemeler kullanılarak rüzgar hızı tahmini yapılmasını da içermektedir [Zhao et al., 2017; Jiang et al., 2021].

Veri odaklı istatistiksel yöntemler geçmiş verileri yapay zeka tabanlı yöntemlerle kullanarak giriş verileri ile çıkış arasında doğrusal olmayan ilişkiler kurarak en doğru tahmin yapmayı amaçlar. Meteorolojik veriler, geçmiş üretim verileri, zaman serileri gibi veriler kullanılarak yapay sinir ağları, makine öğrenmesi yöntemleri, topluluk algoritmaları ve derin öğrenme

yöntemleri eğitilir, sonrasında yeni durumlar için tahmin yapılır [Javed et al., 2022; Li et al., 2022].

Hibrit yöntemler tahmin doğruluğunu arttırmak, var olan metodun eksiklerini gidermek için fiziksel ve istatistiksel yöntemlerin bir arada kullanıldığı yöntemlerdir. Sayısal hava tahmini verileri, yapay sinir ağları, makine öğrenmesi yöntemleri ve derin öğrenme yöntemleri bir arada kullanılmaktadır. Birden fazla algoritmanın bir arada kullanıldığı, farklı işlem adımları içeren yöntemlerdir [Xu et al., 2015; Zjavka, 2015].

Bu çalışma kapsamında, rüzgar türbinlerinin şebekeye bağlantısında ortaya çıkan belirsiz üretim durumunun üstesinde gelmek ve enerji üretimini önceden tahmin ederek kararlı ve güvenli bir bağlantı yapabilmek amacıyla rüzgar enerjisi tahmini için kullanılan fiziksel ve veri odaklı istatistiksel yöntemler, bu yöntemlere ait literatürde var olan çalışmalar incelenmiştir.

2. Fiziksel yöntemler:

Rüzgar hızı ve buna bağlı olarak üretilen rüzgar enerjisinin tahmin edilmesi amacıyla fiziksel yöntemlerde arazi bilgileri, rüzgar çiftliğinin düzeni ve sıcaklık, basınç, nem gibi atmosferik veriler matematiksel ifadelerle kullanılmaktadır. Fiziksel yöntemler şekil 2’de verildiği üzere Sayısal Hava Tahmini ve Mekânsal Korelasyon olarak ikiye ayrılır.

Sayısal hava tahmin modeli en çok kullanılan fiziksel yöntem olup uzun vadeli tahmin yapmak için kullanılmaktadır [Zhao et al., 2017; Dzebre et al., 2021; Zu et al., 2015]. Sayısal hava tahmini yöntemleri var olan belirsizlikler ortadan kaldırmak amacıyla çeşitli yapay zeka tabanlı yöntemlerle bir arada kullanılmaktadır.

Mekânsal korelasyon, bir konumdaki rüzgar hızının yakın konumlarda bulunan diğer rüzgar hızları ile ilişkili olması ilkesine dayanır. Bu yöntem daha çok çoklu türbin içeren rüzgar çiftliklerinde, arazi yapısının uygun olduğu topoğrafyalar için kullanılmaktadır. Sayısal hava tahmin modeline göre hesaplama maliyeti düşüktür fakat uzun vadeli tahmin için yetersiz kalabilir. Mekânsal korelasyon analizi istatistiksel yöntemlerle bir arada kullanılarak tahmin doğruluğu arttırılmaya çalışılmıştır [Zhao et al., 2024; Jiang et al., 2021]



Şekil 2. Fiziksel tahmin yöntemleri.

Zhao ve arkadaşları, çalışmalarında sayısal hava tahmin simülasyonlarının (Weather Research and Forecasting-WRF Modeli) belirsizliklerini ortadan kaldırmak amacıyla Cuckoo Arama Algoritması ile optimize edilmiş bulanık C-ortalamalar kümesi yöntemini kullanmıştır [Zhao et al., 2017]. Zhao ve arkadaşları, rüzgar hızı tahminlerinin doğruluğunu arttırmak amacıyla

Cuckoo Arama algoritması –Bulanık Sistem ve sayısal hava tahmin sonuçlarını kullanmışlardır [Zhao et al.,2016].

Dzebre ve arkadaşları, Gana kıyıları için optimize edilmiş WRF modelinin rüzgar hızı verisi üretmekteki performansını ve uygunluğunu değerlendirmek için analizler yapmışlardır. Simülasyon sonuçları Gana kıyı bölgelerinde farklı noktalardan alınan ölçümlerle karşılaştırılmış, performans kriterleri ile modelin iyi performans gösterdiğini ve güvenilir olduğunu göstermişlerdir [Dzebre et al., 2021].

Xu ve arkadaşları, kısa vadeli rüzgar gücü tahmin işleminde sayısal hava tahmininde hatalı veriyi veri madenciliği yöntemleri ile tespit ederek, rüzgar gücü tahmin doğruluğunu arttırmayı amaçlamaktadır. Sayısal hava tahmininde meydana gelen hataların tanımlanması için K-ortalama kümeleme yöntemini kullanmışlardır [Xu et al., 2015].

Zjavka, çalışmasında sayısal hava tahmin verilerini kullanarak kısa vadeli rüzgar hızı tahminlerinin düzeltilmesini amaçlamaktadır. Sayısal hava tahmin modelleri, geniş ölçekli hava koşullarını tahmin etmekte iyi olsa da arazi koşullarından etkilendiği için bazı durumları tanımlamakta yetersiz kalır. İstatistiksel modeller ise daha kısa vadeli tahmin yapar ama yerel özellikleri tahmin etmekte başarılıdır. Sayısal hava tahmin modellerinin çıktılarını Geliştirilmiş Diferansiyel Polinom Yapay Sinir Ağı kullanarak düzeltmeyi amaçlar [Zjavka, 2015].

Wang ve arkadaşları, rüzgar enerjisi tahmini için sayısal hava tahmin verilerini kullanarak Derin İnanç Ağı yöntemini uygulamışlardır. Sayısal hava tahmin verilerini işlemek için K-ortalama kümeleme algoritmasını kullanmışlar, Morlet Sinir ağı ve Geri Yayılım Sinir ağına göre daha yüksek doğruluk elde etmişlerdir [Wang et al., 2018].

Damousis ve arkadaşları, bulanık mantık ve genetik algoritmayı bir arada kullanarak rüzgar hızını ve buna bağlı olarak rüzgar gücünü tahmin etmeyi amaçlayan bir çalışma yapmışlardır. Çalışmalarında çevredeki meteoroloji istasyonlarından gelen verileri mekânsal korelasyonla bir arada kullanarak, düz ve daha karmaşık arazilerde rüzgar hızı tahminini en doğru şekilde tahmin etmeyi amaçlamışlar, düz arazide mekânsal korelasyonun doğruluğu arttırdığı, karmaşık arazide tahmin doğruluğunu azalttığını göstermişlerdir [Damousis et al., 2004].

Barbounis ve arkadaşı, Yerel Geri Beslemeli Dinamik Bulanık Sinir Ağını rüzgar hızını tahmin etmek için kullanmışlardır. Yunanistan Selanik Körfezi'nde bulunan 3 farklı meteoroloji istasyonundan alınan verileri mekânsal korelasyon için işlemişler, rüzgarın bir noktadan diğerine fiziksel olarak taşındığı gerçeğini yapay zeka mimarisi ile birleştirmişlerdir. Diğer yöntemlerden daha iyi sonuç elde etmişler ve sonuçları karşılaştırmışlardır [Barbounis & Theocharis, 2007].

Zhao ve arkadaşları, türbin değişkenleri ve meteorolojik değişkenler arasındaki mekânsal korelasyonu kuracak Çift Dikkat Tabanlı Mekansal-Zamansal Sinir Ağını kullanarak orta vadeli rüzgar gücü tahmini yapmışlardır. Çin'den elde edilen veri seti ve açık kaynak veri seti ile analizleri yapmışlar, diğer yöntemlere göre daha iyi sonuçlar elde etmişlerdir [Zhao et al., 2024].


Jiang ve arkadaşları, rüzgar hızı tahmini yapmak ve rüzgar hızının dalgalanmanın yapısı nedeniyle oluşan belirsizliğin üstesinde gelmek için mekânsal korelasyon ve Ampirik Mod Ayırıştırma yöntemlerini içeren hibrit bir yöntem önermişlerdir. Önerilen yöntem ile, Çin'in Shandong eyaletindeki bulunan rüzgar çiftliğinin dört mevsime ait verileri ile test edilmiş, Rastgele Ormanlar, Destek Vektör Makinesi ve Yapay Sinir Ağları gibi yöntemlere göre daha yüksek doğrulukta tahminler yapılmıştır [Jiang et al, 2021].

Hu ve arkadaşları, rüzgar hızı tahminindeki belirsizlikleri ve Sayısal hava tahminindeki hataları en aza indirmek için Gauss süreci tabanlı, mekânsal korelasyon ve sayısal hava tahmini

verilerini entegre eden bir yöntem önermiştir. Çin’de bir rüzgar çiftliğinden alınan verilerle testler gerçekleştirildiğinde önerilen yöntem ile tahmin doğruluğunun arttığı gözlemlenmiştir [Hu et al, 2021].

3. Veri odaklı istatistiksel yöntemler:

İstatistiksel yöntemler çok fazla ve doğrusal olmayan verilerin olduğu durumlarda, verileri işleyerek en doğru sonuca ulaşmayı amaçlayan yöntemlerdir. Rüzgar hızı ve rüzgar enerjisi tahmininde yaygın olarak kullanılmaktadır. Veri odaklı istatistiksel yöntemler Şekil 3’te verilen, yapay sinir ağı yöntemleri, makine öğrenmesi yöntemleri, topluluk öğrenme algoritmaları ve derin öğrenme algoritmaları olmak üzere dört ana başlıkta incelenebilir. Bu yöntemlerin performansını arttırmak, hesaplama yükünü azaltmak ve en doğru tahmini yapmak amacıyla farklı veri işleme ve parametre optimizasyon yöntemleri ile birlikte de kullanılmaktadır.



Şekil 3. Veri odaklı istatistiksel yöntemler

3.1.Yapay sinir ağı yöntemleri:

Yapay sinir ağı yöntemleri, veriler arasındaki doğrusal olmayan ilişkiyi iyi analiz etmesi, çok değişkenli verilerle analizler yapabilmesi ve gürültülü verilerle baş edebilmesi nedeniyle sıklıkla tercih edilmekte, tahmin, tanımlama, kontrol ve sınıflandırma işlemlerinde yaygın olarak kullanılmaktadır. Kendi kendine öğrenme yeteneği ve tahminlerde yüksek doğruluk sağlaması avantajlarındanır. Yapay sinir ağları temel olarak üç katmandan oluşmaktadır. Dış dünyadan giriş verilerinin alındığı giriş katmanı, verilerin işlendiği gizli katman ve sonuçların üretildiği çıkış katmanıdır. Gizli katmanda farklı aktivasyon fonksiyonları ve ağırlıklı bağlantılar vasıtasıyla veriler işlenerek çıkış katmanına iletilmektedir. Yapay sinir ağları, rüzgar hızı ve rüzgar enerjisi tahminlerinde de literatürde sıklıkla tercih edilmekte, çalışmalar yapılmaktadır. Literatürde kullanılan yapay sinir ağı yöntemleri Şekil 4’de verilmiştir.



Şekil 4. Rüzgar enerjisi tahmininde kullanılan yapay sinir ağı yöntemleri

Mabel ve arkadaşı, dünyanın en yoğun rüzgar türbini yoğunluğuna sahip Hindistan'ın Tamil Nadu eyaletindeki Muppandal bölgesinde bulunan rüzgar santrallerinin enerji üretimini tahmin etmek için ileri beslemeli ve geri yayımlı Yapay Sinir ağlarını kullanmıştır [Mabel & Fernandez, 2007].

Xu ve arkadaşı, rüzgar enerjisi tahmini için sinir ağının kendi kendine öğrenme yeteneği nedeniyle Elman Sinir Ağını kullanmışlardır. Rüzgar hızı, rüzgar yönü, sıcaklık, nem ve basınç özelliklerini içeren veri seti Çin'de bulunan bir rüzgar santralinden elde edilmiş, modeli optimize etmek için parçacık sürüsü optimizasyon algoritmasını kullanmışlardır [Xu & Mao, 2016].

Shetty ve arkadaşları, rüzgar gücünü tahmin etmek amacıyla, Radyal Taban Fonksiyonu sinir ağı kullanmışlar, öğrenme hızını arttırmak için Aşırı Öğrenme Makinesi, model optimizasyonu için ise Parçacık Sürü Optimizasyon algoritması kullanmışlardır [Shetty et al., 2016].

Bilal ve arkadaşları, Senegal'de farklı dört bölgeden aldığı iklim değişkenlerine bağlı mekânsal ve zamansal verileri sinir ağları ile kullanarak rüzgar türbini çıkış gücü tahmini yapmıştır. Üretilen gücün türbinin bulunduğu bölgenin özelliklerine ve rüzgar yönüne büyük ölçüde bağlı olduğunu göstermişlerdir [Bilal et al., 2018].

Nielson ve arkadaşları, rüzgar türbinlerinin güç üretim tahminlerini iyileştirmek amacıyla atmosferik kararlılık ve hava yoğunluğunu dikkate almış, İleri Beslemeli Sinir Ağı kullanılmıştır. Güç ve rüzgar verileri Amerika Birleşik Devleti Iowa eyaletinde bulunan meteoroloji kulesine sahip bir 2,5MW kapasiteli rüzgar türbininden elde etmişlerdir. Rüzgar hızı verisinin yanında, tahmin modeline hava yoğunluğu, rüzgar sapması, türbülans yoğunluğu gibi parametrelerde verimlidir. Elde edilen sonuçları literatürden farklı yöntemlerle karşılaştırmış, önerilen yöntemin düşük hata oranı, düşük maliyet ve uygulanabilirlik açısından uygun olduğunu göstermişlerdir [Nielson et al., 2020].

Javed ve arkadaşları, çalışmalarında rüzgar türbinlerinin mekanik gücünü rüzgar hızı, kanat eğimi, türbin rotorunun açılma hızı ve güç katsayısı gibi verileri İleri Beslemeli Geri Yayımlı Sinir Ağları ve Özyinelemeli Sinir ağları ile kullanarak rüzgar enerjisini tahmin etmişlerdir. Farklı gizli katman sayısı, aktivasyon fonksiyonu ve öğrenme oranı gibi faktörler ile en iyi tahmine ulaşmayı hedeflemişlerdir. Düşük hesaplama karmaşıklığı, sıcaklık ve basınç gibi


veriler kullanılmadığından sensör maliyetlerinden tasarruf edildiğinden düşük maliyet ve genellenebilir olması gibi avantajlara sahiptir. Uzun kısa süreli Bellek ağlarından daha iyi performans elde etmişlerdir [Javed et al., 2022].

Matip ve arkadaşları, Weibull parametrelerini kullanarak rüzgar gücü tahmini yapmak amacıyla Çok Katmanlı Algılayıcı Sinir ağını, model eğitimi için gradyan geri yayılım algoritmasını kullanmışlardır. [Matip et al., 2022]

Karami ve arkadaşları, güç eğrisine dayalı rüzgar gücü tahmininde belirsizlikleri ortadan kaldırmak amacıyla bayes tabanlı Olasılıksal Sinir Ağı önermişlerdir. Önerilen yöntemi gerçek bir veri seti ile test etmiş ve etkinliğini kanıtlamışlardır. [Karami et al., 2022]

3.2. Makine Öğrenmesi Yöntemleri:

Makine öğrenmesi tabanlı yöntemler geçmiş verileri kullanarak veriler arasındaki doğrusal olmayan ilişkileri tanımlamak için istatistiksel, olasılıksal ve optimizasyon tekniklerini kullanan yöntemlerdir. Makine öğrenmesi yöntemleri geleneksel yöntemlerde denklemlere dayalı olarak yapılan işlemlerin aksine verilerden en önemli özellikleri otomatik olarak belirler ve ilişkiler kurar. Geçmiş verileri kullanarak eğitilen model, yeni verileri tahmin etmek için hazır hale gelir. Rüzgar hızı ve rüzgar enerjisi tahmininde de sıklıkla tercih edilmektedir. Literatürde rüzgar enerjisi tahmininde kullanılan yöntemlere Şekil 5'te örnekler verilmiştir. Makine öğrenmesi algoritmaları hiper parametre ayarı için sıklıkla optimizasyon algoritmaları ile birlikte kullanılmaktadır.



Şekil 5. Makine öğrenmesi yöntemleri

Zameer ve arkadaşları. [16], özellik seçimi ve regresyon için makine öğrenmesi tekniklerinin bir kombinasyonunu kullanan Makine Öğrenmesi Tabanlı Kısa Vadeli Rüzgar Enerjisi Tahmini sistemi önermişlerdir. Destek Vektör Regresyonunun genelleme gücü ile hibrit sinir ağlarının öğrenme kapasitesini Geliştirilmiş Parçacık Sürü Optimizasyonu ile optimize ederek, günlük bazda güvenilir bir kısa vadeli tahmin sistemi oluşturmuşlardır [Zameer et al., 2015].

Demolli ve arkadaşları, dört farklı konum için günlük rüzgar hızı, saatlik rüzgar hızının günlük standart sapması ve üretilen günlük rüzgar enerjisi verilerini kullanmışlardır. Uzun vadeli rüzgar enerjisi tahmini yapmak için k-en yakın komşuluk, Aşırı Gradyan Arttırma (XGBoost), Rastgele Orman ve Destek Vektör Regresyonu yöntemlerini uygulamışlardır [Demolli et al., 2019].

Tan ve arkadaşları, rüzgar gücü tahmini için hızlı öğrenme, hızlı ve güçlü genelleme yeteneği nedeniyle Aşırı Öğrenme Makinesini (Extreme Learning Machine-ELM) tercih etmiş, parametre optimizasyonu için Salp Sürü Algoritmasını kullanmışlardır. Geri yayılım Sinir Ağı, ELM ve parçacık sürü algoritması ile optimize edilmiş ELM ile sonuçları karşılaştırmışlardır [Tan et al., 2020].


Singh ve arkadaşı, SCADA'dan alınan zaman serilerinden oluşan veri setini kullanmışlar, veri setini analiz etmek için grafiksel bir araç tasarlamışlardır. Eksik verileri, mevcut veriler ve teorik bilgilere dayalı olarak doğrusal enterpoasyonla tamamlayıp, min-max Normalizasyon uygulamışlardır. Tahmin için Rastgele Ormanlar, Uzun Kısa Süreli Bellek Ağı ve XGBoost Regresyon algoritması kullanarak, en iyi performansı XGBoost ile elde etmişlerdir [Singh & Rzvan, 2022].

Zheng ve arkadaşları, kısa vadeli rüzgar gücü tahminindeki belirsizlikleri ortadan kaldırmak amacıyla dört aşamalı bir model önermişlerdir. Topluluk Ampirik Mod Ayırıştırması ile veriler bileşenlere ayrılmış, daha az bellek gereksinimi ve daha hızlı öğrenme kapasitesine sahip olduğu için En Küçük Kareler Destek Vektör Makinesi ile tahmin yapılmışlardır. Destek Vektör Makinesinin parametre optimizasyonu için Geliştirilmiş Serçe Arama Algoritmasını kullanmışlar, önerilen hibrit yöntem ile yüksek hassasiyet, genelleme yeteneği ve hızlı yakınsama ile kritik bir model ortaya koymuşlardır [Li et al., 2022]

Liao ve arkadaşları, rüzgar enerjisindeki keskin dalgalanmaları ve belirsizlikleri yönetmek amacıyla elde edilen veri setine ilk olarak gürültü azaltmak amacıyla Tam Topluluk Mod Ampirik Ayırıştırması ve dalgacık dönüşümünü birleştiren bir yöntem uygulamış daha sonra özellik alt kümelerini çıkarmışlardır. Hafif Gradyan Arttırma Makinesi (LightGBM) oluşturulan hibrit yöntem ile tahmin yapmışlar, diğer makine öğrenmesi yöntemlerine göre üstün başarı elde etmişlerdir [Liao et al., 2022].

3.3. Derin Öğrenme Yöntemleri:

Son yıllarda yaygın olarak kullanılan, birden fazla gizli katmana sahip makine öğrenmesi yöntemlerinin bir uzantısıdır. Doğrusal olmayan karmaşık ilişkiler ile zamansal ve mekânsal verileri bir arada işleyebilme, büyük verilerle çalışabilme yeteneğine sahiptir. Çoklu gizli katmana sahip olması sayesinde daha derin özelliklerin çıkarılmasına, sınıflandırma veya tahmin performansının artırılmasına olanak sağlar. Rüzgar enerjisi tahmininde, yaygın olarak kullanılan yapay sinir ağları ve makine öğrenmesi yöntemlerinin yanında var olan eksiklikleri gidermek için Şekil 6'da verilen Derin Öğrenme Yöntemleri son yıllarda sıklıkla kullanılmaktadır.



Şekil 6. Derin Öğrenme Yöntemleri

Liu ve arkadaşları, rüzgar enerjisini tahmin etmek amacıyla Uzun Kısa Süreli Bellek ağını kullanmış, zaman serisini sinyallere ayrıştırmak ve analiz etmek amacıyla Dalgacık Dönüşümünü uygulamıştır. Özyinelemeli Ağları ve Geri yayılım sinir ağlarına göre üstünlüklerini istatistiksel performans metrikleri ile göstermişlerdir [Liu et al., 2019].

Sun ve arkadaşları, gerçek zamanlı rüzgar gücü tahmini için Çin’de bulunan bir santraldeki Dağıtılmış Kontrol sistemlerinden alınan buhar basıncı, sıcaklığı, valf açıklığı, rotor hızı gibi on farklı ölçüm bilgisini kullanmışlardır. Özyinelemeli Sinir Ağı (Recurrent Neural Network-RNN) ve Evrişimsel Sinir Ağını (Convolutional Neural Network-CNN) tahmin için kullanmışlardır. RNN ile en iyi performansı elde etmişlerdir [Sun et al., 2021].

Liu ve arkadaşları, bir rüzgar çiftliğindeki çok sayıda türbin için kısa vadeli güç tahmini yapmak amacıyla türbinler arasındaki benzerlikleri kullanarak tahmin yapan Derin ve Transfer Öğrenme yöntemini önermişlerdir. Önerilen modelde ilk olarak tüm türbinler arasındaki ortak özellikleri belirlemişler, daha sonra her bir türbinin kendine özgü özelliklerini ortaya çıkarmışlardır. Son olarak zamansal özellikler ve belirlenen özellikleri birleştirilerek derin öğrenme modelini oluşturmuşlardır. Önerilen yöntemin düşük veri ihtiyacı, yüksek doğruluk ve hızlı eğitim gibi avantajlarını sonuçlarla göstermişlerdir [Liu et al., 2021].

Yıldız ve arkadaşları, çalışmalarında rüzgar enerjisi tahmini için iki aşamalı bir model önermiştir. İlk aşamada, rüzgar gücü verilerini Varyasyonel Mod Ayrıştırma ile alt frekans bileşenlerine ayırmışlar, daha sonra bu verileri meteorolojik verilerle birleştirilerek 2D görüntülere dönüştürmüşlerdir. İkinci aşamada, Atık tabanlı Evrişimli Sinir Ağı kullanmışlardır. Önerilen yöntemi, popüler derin öğrenme mimarileri ile karşılaştırmışlar ve üstünlüğünü ortaya koymuşlardır [Yıldız et al., 2021].


Hu ve arkadaşları, mekânsal korelasyon verilerini ve sayısal hava tahmin verilerini kullanarak rüzgar enerjisi tahmininde doğruluğu arttırmak amacıyla verilere bir dizi işlem uygulamış, yüksek boyutlu verilerin boyutunu azaltarak hesaplama yükünü düşürmek amacıyla Temel Bileşen Analizi yapmıştır. Mekansal korelasyon ve Sayısal Hava Tahmin bilgilerini Lagrange Çarpınları yöntemi ile ağırlıklandırılarak kullanmış Geliştirilmiş Derin İnanç Ağı ile hibrit bir model oluşturmuşlardır [Hu et al., 2021].

Fahim ve arkadaşları, gerçek zamanlı izleme ve veri akışı sağlamak için 5G Yeni Nesil Radyo Erişim Ağı kullanmışlar, SCADA verileri ile sanal bir rüzgar çiftliği modellemişlerdir. Rüzgar hızını tahmin etmek için klasik yöntemlere göre daha iyi öğrenme yeteneğine sahip Zamansal Evrişimli Ağını (Temporal Convolution Network-TCN), rüzgar gücü tahmini için k-En yakın Komşuluk algoritmasını uygulamışlardır. [Fahim et al., 2022]

Karaman yaptığı çalışmada, farklı giriş verilerinden oluşan iki bağımsız veri setini birleştirmiş, bu verilerle rüzgar enerjisini tahmin etmek amacıyla İleri Beslemeli Sinir Ağı, Özyinelemeli Sinir Ağı, Evrişimli Sinir Ağı ve Uzun Kısa Süreli Bellek Ağı kullanmıştır. Veri setinde bulunan eksiklikleri doldurmak amacıyla K-en yakın komşuluk algoritmasını kullanmış, Uzun Kısa Süreli bellek ile en iyi performansı elde etmiştir. Basit model yapısı ve model verimliliği bakımından önerilen yöntemin etkinliğini kanıtlamıştır [Karaman, 2023].

3.4. Topluluk Öğrenme Algoritmaları:

Topluluk öğrenme algoritmaları, geleneksel bağımsız öğrenme algoritmalarına kıyasla daha yüksek tahmin performansı elde etmek için birden fazla öğrenme yöntemini birleştiren algoritmalarlardır. Rüzgar enerjisi tahmininde yüksek doğrulukta tahmin yapmak amacıyla topluluk öğrenme algoritmaları da kullanılmaktadır. Literatürde rüzgar enerjisi tahmininde kullanılan topluluk öğrenme algoritmaları Şekil 7’de verilmiştir.



Şekil 7. Topluluk öğrenme algoritmaları

Lahouar ve arkadaşları, saatlik rüzgar enerjisi tahmini için meteorolojik verilerden hangilerinin dahil edileceğine korelasyon ve önem ölçütlerine göre karar verilmişler, tahmin için diğer yöntemlerin aksine ayarlanmaya ve optimize edilmeye ihtiyaç duyulmadığından Rastgele Orman algoritmasını seçmiş, performansın yapay sinir ağlarına göre üstün olduğunu göstermişlerdir [Lahouar-2017].

Banik ve arkadaşları, Hindistan Tipura eyaletindeki Agarta şehrine ait bir yıllık verilerini rüzgar hızı ve enerjisi tahmini için topluluk öğrenme algoritmalarından yaygın olarak kullanılan AdaBoost ve XGBoost yöntemleri ile birlikte kullanmışlardır [Banik et al., 2020].

An ve arkadaşları, literatürde bulunan rüzgar enerjisi tahmin modellerinin zayıf genelleme yeteneğinin üstesinden gelmek için parçacık sürü optimizasyonu ile optimize edilmiş Aşırı Öğrenme Makinesi yöntemini AdaBoost algoritması ile birleştirmiştir. Türkiye’de Yalova’dan alınan veri setini kullanılmışlardır. Önerilen yöntemin diğer yöntemlerle karşılaştırıldığında genelleme yeteneği, kararlılık, hata azaltma ve eğitim hızı bakımından üstün olduğunu göstermişlerdir [An et al., 2021].

Alkesaiberi ve arkadaşları, rüzgar gücü tahmininde, rüzgar enerjisinin aralıklı ve dalgalı olmasından kaynaklanan zorlukların üstesinden gelmek için Gauss Süreci Regresyonu ve farklı çekirdek yapılarında Destek Vektör Regresyonunu bireysel tahminci olarak kullanırken, topluluk algoritmalarından Güçlendirilmiş ağaçlar (boosted trees), Torbalanmış ağaçlar (bagged trees), Rastgele Ormanlar (Random Forest) ve XGBoost’u kullanmışlardır. Hiperparametre ayarı için Bayes Optimizasyonu ve üç farklı veri seti kullanmışlardır. Meteorolojik verilerin ve gecikmeli de olsa dinamik olarak tahmine dahil edilen geçmiş verilerin kullanılmasının tahmin doğruluğunu arttırdığını göstermişlerdir [Alkesaiberi et al., 2022].

4. Sonuç

Bu çalışmada, yenilenebilir enerji kaynaklarının kullanımının arttığı son zamanlarda yaygın olarak kullanılan fakat enerji üretiminde doğası gereği dalgalanma ve kesintilere sahip rüzgar türbinlerinde rüzgar enerjisi tahmini için kullanılan yöntemler üzerine bir çalışma yapılmıştır. İlk olarak rüzgar enerjisinden, dünyada ve Türkiye’de üretim miktarlarından bahsedilmiştir. Ardından rüzgar enerjisi tahminin de kullanılan fiziksel ve veri odaklı istatistiksel yöntemlerden bahsedilmiş, literatürde yapılan çalışmalar kısaca özetlenmiştir. İncelenen çalışmalardan, fiziksel yöntemlerin tahmin performansını ve var olan belirsizliklerini ortadan kaldırmak amacıyla istatistiksel yöntemlerle birlikte kullanıldığı görülmüştür. İstatistiksel yöntemlerde ise tahmin performansını arttırmak için veri ön işleme yöntemlerine ait uygulamalar ve yöntemlerin parametre ayarlamasını yapmak için optimizasyon yöntemleri ile birlikte kullanımının yaygın olduğu görülmüştür. Ayrıca bireysel yöntemlerin performansının artırılması için vderin öğrenme ve topluluk öğrenme yöntemlerinin kullanımı yaygınlaşmaktadır. Bu çalışmalar dikkate alındığında, üretilen rüzgar enerjisi tahmini için fiziksel ve istatistiksel yöntemlerin bir arada kullanıldığı, farklı veri özelliklerini içeren veri setlerinin kullanıldığı, veri işleme yöntemlerini içeren metotların kullanılmasının tahmin performansını arttırabileceği öngörülmektedir.

Kaynakça

- Alkesaiberi, A., Harrou, F., & Sun, Y. (2022). Efficient wind power prediction using machine learning methods: A comparative study. *Energies*, 15(7), 2327.
- An, G., Jiang, Z., Cao, X., Liang, Y., Zhao, Y., Li, Z., ... & Sun, H. (2021). Short-term wind power prediction based on particle swarm optimization-extreme learning machine model combined with AdaBoost algorithm. *IEEE access*, 9, 94040-94052.
- Banik, R., Das, P., Ray, S., & Biswas, A. (2020). Wind power generation probabilistic modeling using ensemble learning techniques. *Materials Today: Proceedings*, 26, 2157-2162.
- Barbosa de Alencar, D., de Mattos Affonso, C., Limão de Oliveira, R. C., Moya Rodriguez, J. L., Leite, J. C., & Reston Filho, J. C. (2017). Different models for forecasting wind power generation: Case study. *Energies*, 10(12), 1976.
- Barbounis, T. G., & Theocharis, J. B. (2007). A locally recurrent fuzzy neural network with application to the wind speed prediction using spatial correlation. *Neurocomputing*, 70(7-9), 1525-1542.
- Bilal, B., Ndongo, M., Adjallah, K. H., Sava, A., Kébé, C. M., Ndiaye, P. A., & Sambou, V. (2018, February). Wind turbine power output prediction model design based on artificial neural networks and climatic spatiotemporal data. In *2018 IEEE international conference on industrial technology (ICIT)* (pp. 1085-1092). IEEE.
- Cakiroglu, C., Demir, S., Ozdemir, M. H., Aylak, B. L., Sariisik, G., & Abualigah, L. (2024). Data-driven interpretable ensemble learning methods for the prediction of wind turbine power incorporating SHAP analysis. *Expert Systems with Applications*, 237, 121464.
- Damousis, I. G., Alexiadis, M. C., Theocharis, J. B., & Dokopoulos, P. S. (2004). A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation. *IEEE Transactions on energy conversion*, 19(2), 352-361.
- Demolli, H., Dokuz, A. S., Ecemis, A., & Gokcek, M. (2019). Wind power forecasting based on daily wind speed data using machine learning algorithms. *Energy Conversion and Management*, 198, 111823.
- Dzebre, D. E., Ampofo, J., & Adaramola, M. S. (2021). An assessment of high-resolution wind speeds downscaled with the Weather Research and Forecasting Model for coastal areas in Ghana. *Heliyon*, 7(8).
- Fahim, M., Sharma, V., Cao, T. V., Canberk, B., & Duong, T. Q. (2022). Machine learning-based digital twin for predictive modeling in wind turbines. *IEEE Access*, 10, 14184-14194.
- Hu, S., Xiang, Y., Zhang, H., Xie, S., Li, J., Gu, C., ... & Liu, J. (2021). Hybrid forecasting method for wind power integrating spatial correlation and corrected numerical weather prediction. *Applied Energy*, 293, 116951.
- Hu, S., Xiang, Y., Huo, D., Jawad, S., & Liu, J. (2021). An improved deep belief network based hybrid forecasting method for wind power. *Energy*, 224, 120185.
- IRENA, International Renewable Energy Agency, . Renewable energy statistics 2025.
- Javed, M. Y., Khurshid, I. A., Asghar, A. B., Rizvi, S. T. H., Shahid, K., & Ejsmont, K. (2022). An efficient estimation of wind turbine output power using neural networks. *Energies*, 15(14), 5210.

- Jiang, Z., Che, J., & Wang, L. (2021). Ultra-short-term wind speed forecasting based on EMD-VAR model and spatial correlation. *Energy Conversion and Management*, 250, 114919.
- Karaman, Ö. A. (2023). Prediction of wind power with machine learning models. *Applied Sciences*, 13(20), 11455.
- Karami, F., Kehtarnavaz, N., & Rotea, M. (2022, June). Probabilistic neural network to quantify uncertainty of wind power estimation. In *2022 IEEE 15th Dallas Circuit And System Conference (DCAS)* (pp. 1-7). IEEE.
- Li, Z., Luo, X., Liu, M., Cao, X., Du, S., & Sun, H. (2022). Wind power prediction based on EEMD-Tent-SSA-LS-SVM. *Energy Reports*, 8, 3234-3243.
- Liao, S., Tian, X., Liu, B., Liu, T., Su, H., & Zhou, B. Short-Term Wind Power Prediction Based on LightGBM and Meteorological Reanalysis. *Energies* 2022, 15, 6287.
- Liu, Y., Guan, L., Hou, C., Han, H., Liu, Z., Sun, Y., & Zheng, M. (2019). Wind power short-term prediction based on LSTM and discrete wavelet transform. *Applied Sciences*, 9(6), 1108.
- Liu, X., Cao, Z., & Zhang, Z. (2021). Short-term predictions of multiple wind turbine power outputs based on deep neural networks with transfer learning. *Energy*, 217, 119356.
- Mabel, M. C., & Fernandez, E. (2008). Analysis of wind power generation and prediction using ANN: A case study. *Renewable energy*, 33(5), 986-992.
- Matip, M. J. N., Essiane, S. N., Ngoffe, S. P., & Mougang, Y. C. K. (2022). Estimation of wind power in coastal areas using a Model based on the learning of a Multilayer Perceptron: Case of Douala, Cameroon. In *E3S Web of Conferences* (Vol. 354, p. 01009). EDP Sciences.
- Nielson, J., Bhaganagar, K., Meka, R., & Alaeddini, A. (2020). Using atmospheric inputs for Artificial Neural Networks to improve wind turbine power prediction. *Energy*, 190, 116273.
- Shetty, R. P., Sathyabhama, A. P. S. P., & Rai, A. A. (2016, August). Optimized radial basis function neural network model for wind power prediction. In *2016 second international conference on cognitive computing and information processing (CCIP)* (pp. 1-6). IEEE.
- Singh, U., & Rizwan, M. (2022). SCADA system dataset exploration and machine learning based forecast for wind turbines. *Results in Engineering*, 16, 100640.
- Sun, L., Liu, T., Xie, Y., Zhang, D., & Xia, X. (2021). Real-time power prediction approach for turbine using deep learning techniques. *Energy*, 233, 121130.
- Tan, L., Han, J., & Zhang, H. (2020). Ultra-short-term wind power prediction by salp swarm algorithm-based optimizing extreme learning machine. *IEEE Access*, 8, 44470-44484.
- Tascikaraoglu, A., & Uzunoglu, M. (2014). A review of combined approaches for prediction of short-term wind speed and power. *Renewable and Sustainable Energy Reviews*, 34, 243-254.
- TEİAŞ, Türkiye Elektrik İletim Anonim Şirketi, Türkiye Elektrik Üretim-İletim İstatistikleri 2024.
- Wang, K., Qi, X., Liu, H., & Song, J. (2018). Deep belief network based k-means cluster approach for short-term wind power forecasting. *Energy*, 165, 840-852.

- Xu, Q., He, D., Zhang, N., Kang, C., Xia, Q., Bai, J., & Huang, J. (2015). A short-term wind power forecasting approach with adjustment of numerical weather prediction input by data mining. *IEEE Transactions on sustainable energy*, 6(4), 1283-1291.
- Xu, L., & Mao, J. (2016, May). Short-term wind power forecasting based on Elman neural network with particle swarm optimization. In *2016 Chinese control and decision conference (CCDC)* (pp. 2678-2681). IEEE.
- Yildiz, C., Acikgoz, H., Korkmaz, D., & Budak, U. (2021). An improved residual-based convolutional neural network for very short-term wind power forecasting. *Energy Conversion and Management*, 228, 113731.
- Zameer, A., Khan, A., & Javed, S. G. (2015). Machine Learning based short term wind power prediction using a hybrid learning model. *Computers & Electrical Engineering*, 45, 122-133.
- Zhao, J., Guo, Z. H., Su, Z. Y., Zhao, Z. Y., Xiao, X., & Liu, F. (2016). An improved multi-step forecasting model based on WRF ensembles and creative fuzzy systems for wind speed. *Applied Energy*, 162, 808-826.
- Zhao, J., Guo, Y., Xiao, X., Wang, J., Chi, D., & Guo, Z. (2017). Multi-step wind speed and power forecasts based on a WRF simulation and an optimized association method. *Applied energy*, 197, 183-202.
- Zhao, B., He, X., Ran, S., Zhang, Y., & Cheng, C. (2024). Spatial correlation learning based on graph neural network for medium-term wind power forecasting. *Energy*, 296, 131164.
- Zjavka, L. (2015). Wind speed forecast correction models using polynomial neural networks. *Renewable Energy*, 83, 998-1006.

BÖLÜM 5

ELEKTRİKLİ ŞARJ İSTASYONU İÇEREN GÜÇ SİSTEMLERİNDE OPTİMUM REAKTİF GÜÇ DAĞITIMI OPTİMİZASYONUNU

Mehmet ÇEÇEN¹

¹ Doktor Öğretim Üyesi, Selçuk Üniversitesi, Ilgın Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, mehmet.cecen@selcuk.edu.tr, ORCID: 0000-0003-2344-3018.

1. GİRİŞ

Elektrik enerjisi kullanımı hızla artmaya devam etmektedir. Artan ihtiyacı karşılayabilmek için öncelikle elektrik enerjisinin en verimli şekilde üretilip son kullanıcıya ulaştırılması gerekmektedir. Ulaştırılan elektrik enerjisinin, son kullanıcının güç kalite taleplerini sürekli olarak aynı standartta karşılaması sağlanmalıdır. Güç sisteminde reaktif güç akışı, sistemdeki birçok yükün endüktif olması ile transformatör ve iletim hatları gibi reaktif güç tüketen şebeke bileşenleri nedeniyle engellenemez ve tamamen sıfırlanması da istenmez. Bu nedenle Optimal Reaktif Güç Dağıtımı (ORGD) çalışmaları güç sistemi için önemlidir (Frank & Rebennack, 2016; Newell, Qian, & Raimi, 2016).

Elektrik güç sistemlerinin optimum işletilmesi, güç kalitesi ve sistem kararlılığını sağlayan önemli yöntemlerden biri reaktif güç optimizasyonudur. Bu optimizasyon problemi, güç kaybı ve gerilim değişimi gibi belirli bir amaç fonksiyonunu minimize etmek için jeneratör gerilimleri, transformatör ayar kademeleri ve reaktif kompanzasyon cihazlarının en uygun ayara getirilmesiyle sağlanmaktadır. Bu süreçte sistemin eşitlik ve eşitsizlik kısıtları da yerine getirilmektedir. Transformatör kademe ayarı ve reaktif kompanzasyon cihazları ayırık değerler iken, bara gerilim büyüklükleri ve reaktif güç çıkışları sürekli değişkenlerdir. Bu nedenle ORGD problemi, karışık tamsayıli lineer olmayan programlama (KTLOP) ile modellenilebilir (Khanmiri, Nasiri, & Mobaraki, 2012; Sakr, El-Sehiemy, & Azmy, 2017).

Termal santral içeren sistemlerin ORGD problemini çözmek için geçmişten beri birçok teknik kullanılmıştır. İlk dönemlerde ikinci dereceden programlama (İDP) (Quintana & Santos-Nieto, 2002), iç nokta yöntemi (İNY) (Zhu & Xiong, 2003), doğrusal programlama (DP) (Lee & Yang, 1998) ve Newton Rapson yöntemi (Jan & Chen, 1995) gibi geleneksel metotlar yaygın olarak kullanılmıştır. Daha sonra, genetik algoritma (GA) (Durairaj, Devaraj, & Kannan, 2006), evrimsel strateji (ES) (Wu & Ma, 2002) ve tabu araması (TA) (Hertz & Dewerra, 1987) gibi yöntemler uygulanmıştır. Ancak bu yöntemler, lineer olmayan fonksiyonlar ve ayırık değişkenli sistemler için verimli sonuç verememektedir (Ayan & Kılıç, 2012).

Son zamanlarda, meta-sezgisel optimizasyon algoritmalarının gelişimiyle birlikte ORGD problemlerinin çözümünde daha iyi sonuçlar elde edilmiştir. Yaygın kullanılan metotlar arasında parçacık sürü optimizasyonu (PSO) (Vlachogiannis & Lee, 2006; Zhao, Guo, & Cao, 2005), gri kurt optimizasyonu (GKO) (Sulaiman, Mustaffa, Mohamed, & Aliman, 2015), yapay arı kolonisi (YAK) (Ayan & Kılıç, 2012), harmoni arama algoritması (HAA) (Khazali & Kalantar, 2011), gravitasyon arama algoritması (GAA) (Duman, Güvenç, Sönmez, & Yörükeren, 2012), güve alevi optimizasyonu (GAO) (Mei, Sulaiman, Mustaffa, & Daniyal, 2017) ve arayıcı optimizasyon algoritması (AOA) (Dai, Chen, Zhu, & Zhang, 2009) yer almaktadır. Daha sonra araştırmacılar, klasik meta-sezgisel metotlara göre daha iyi sonuç veren geliştirilmiş metotları ve hibrit metotları da ORGD problemini çözmek için kullanmışlardır. Bu metotlar arasında hibrit gri kurt optimizasyonu-parçacık sürü optimizasyonu (GKO-PSO) (Shaheen, Hasanien, & Alkuhayli, 2021), parçacık sürü optimizasyonu-gravitasyon arama optimizasyonu (PSO-GAO) (Mirjalili & Hashim, 2010), kapsamlı öğrenme-parçacık sürü optimizasyonu (KÖ-PSO) (Mahadevan & Kannan, 2010) ve geliştirilmiş çakal optimizasyonu (GÇO) (Abaza, Fawzy, El-Sehiemy, Alghamdi, & Kamel, 2021) bulunmaktadır.

Elektrikli araçların (EA) sayısının son yıllarda hızla artmasıyla, elektrikli araç şarj istasyonlarının (EAŞİ) güç kapasitelerinde önemli bir artış gözlemlenmektedir. 2010'lu yılların başında 3,7 kW ile 22 kW arasında değişen AC şarj sistemleri baskın iken, günümüzde 50 kW'tan başlayarak 350 kW'a kadar ulaşan DC hızlı şarj istasyonları yaygınlaşmıştır (Kumar & Alok, 2020). Bu güç artışının temel nedeni, elektrikli araç batarya kapasitelerinin genişlemesi ve kullanıcıların şarj sürelerini minimize etme ihtiyacıdır (Tu, Feng, Srdic, & Lukic, 2019). Özellikle ultra-hızlı şarj teknolojileri (>150 kW), batarya yönetim sistemlerindeki gelişmeler sayesinde batarya ömrüne zarar vermeden 15-20 dakika içinde %80 şarj oranına ulaşabilmektedir (Yilmaz & Krein, 2012). Ancak bu yüksek güçlü sistemler, şebeke altyapısı üzerinde önemli yük oluşturarak enerji depolama sistemleri ve akıllı şarj yönetimi gibi destekleyici teknolojilerin entegrasyonunu zorunlu kılmaktadır (Un-Noor,

Padmanaban, Mihet-Popa, Mollah, & Hossain, 2017). Gelecekte, kablosuz şarj ve dinamik şarj sistemlerinin geliştirilmesiyle birlikte şarj istasyonlarının güç kapasitelerinin daha da artması beklenmektedir (Ahmad, Alam, & Chabaan, 2017).

Bu çalışmada, EAŞİ sayılarında meydana gelen hızlı artışın ORGD problemine etkilerini incelemek için geliştirilmiş bir GKO algoritması önerilmiştir. Önerilen yöntemle, ORGD probleminde belirlenen kontrol parametrelerinin optimize edilmesi sağlanacaktır. Amaç fonksiyonu sonuçları, algoritma tarafından belirlenen kontrol parametre değerleri ve güç kaybında meydana gelen değişim incelenmiştir. Önerilen yeni metotla bu çalışma, güç sisteminin kayıplarını ve yük bara gerilimlerinde meydana gelen değişimleri minimize eden en iyi kontrol parametrelerini bulmaya odaklanmıştır. Çalışmada tekil amaç fonksiyonlarının olduğu durumlar ele alınmıştır.

2. MATERYAL METOD

2.1. Amaç Fonksiyonu

Bu çalışmada, ORGD problemi için amaç fonksiyonu, eşitlik ve eşitsizlik kısıtlamalarını dikkate alarak güç kayıplarını minimize etmektir. ORGD problemi fonksiyon $f(x,u)$ 'nın minimizasyonu olarak aşağıdaki gibi tanımlanabilir:

$$\text{Minimize } f(x, u)$$

$$\text{Amaçlar fonksiyonları: } \begin{aligned} g(x, u) &= 0 \\ h(x, u) &\leq 0 \end{aligned} \quad (1)$$

$f(x,u)$ fonksiyonu amaç fonksiyonudur. $g(x,u)$ ve $h(x,u)$ ise sırasıyla eşitlik ve eşitsizlik kısıtlayıcılarıdır. ORGD probleminde, eşitlik kısıtı güç denge denklemleridir. Eşitsizlik kısıtları ise, jeneratör gerilimi, transformatör kademe ayarı ve reaktif kompensatör büyüklüğüdür. x ve u sırasıyla bağımlı değişkenler vektörü ve kontrol değişkenleri vektörüdür. Amaç fonksiyonları, iletim sistemini toplam güç kayıpları F_1 ile gösterilebilir (Khanmiri et al., 2012).

$$F_1 = P_{Loss}(x, u) = \sum_{L=1}^{N_L} P_{Loss} \quad (2)$$

N_L , iletim hatlarının sayısını ifade etmektedir.

2.2. Eşitlik Kısıtlayıcıları

Yük akışının güç eşitliği, üretilen güç ile güç talebi arasındaki farkın güç kaybına eşit olduğunu ifade etmektedir. Eşitlik kısıt denklemleri aşağıdaki gibi ifade edilebilir:

$$P_{Gi} - P_{Di} = V_i \sum_{j \in N_i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (3)$$

$$Q_{Gi} - Q_{Di} = V_i \sum_{j \in N_i} V_j (B_{ij} \cos \theta_{ij} - G_{ij} \sin \theta_{ij}) \quad (4)$$

V_i ve V_j , sırasıyla i . yük barası ve j . yük barası gerilimlerini, B_{ij} ve G_{ij} sırasıyla i . bara ile j . bara arasındaki süseptansı ve kondüktansı ifade eder. Diğer taraftan, P_{Gi} ve P_{Di} , sırasıyla aktif güç üretimi ve aktif yük talebidir. Q_{Gi} ve Q_{Di} ise sırasıyla, reaktif güç üretimi ve reaktif yük talebini ifade etmektedir.

2.3. Eşitsizlik Kısıtlayıcıları

Optimizasyon problemlerinde eşitsizlik kısıtlamaları sistemin işletim kısıtlamalarını temsil eder.

- Jeneratör Kısıtları: bara gerilimleri yanı sıra aktif ve reaktif güç üretimi santral limitleri ile sınırlandırılmalıdır.

$$P_{Gi}^{min} \leq P_{Gi} \leq P_{Gi}^{max} \quad i = 1, \dots, N_G \quad (5)$$

$$Q_{Gi}^{min} \leq Q_{Gi} \leq Q_{Gi}^{max} \quad i = 1, \dots, N_G \quad (6)$$

$$V_{Gi}^{min} \leq V_{Gi} \leq V_{Gi}^{max} \quad i = 1, \dots, N_G \quad (7)$$

N_G sistem jeneratör sayısını gösterir.

•Transformatör Kademe Ayarı: Transformatör kademe ayarı aşağıdaki gibi sınırlanmıştır.

$$T_i^{min} \leq T_i \leq T_i^{max} \quad i = 1, \dots, N_T \quad (8)$$

N_T transformatör sayısını göstermektedir.


•Reaktif Güç Kompanzasyonu:

$$Q_{Ci}^{min} \leq Q_{Ci} \leq Q_{Ci}^{max} \quad i = 1, \dots, N_C \quad (9)$$

N_C reaktif kompensatör sayısını göstermektedir.

2.4. Gri Kurt Optimizasyon (GKO) Algoritması

GKO algoritması ilk olarak Mirjalili ve ark. tarafından 2014 yılında önerilmiştir. Gri kurtlar genellikle sürüler halinde yaşamayı tercih ederler. Ortalama grup büyüklüğü 5 ile 12 kurt arasındadır (Mirjalili, Mirjalili, & Lewis, 2014). Şekil 1'de gösterildiği gibi, güçlü baskılarla karakterize edilen çok katı bir sosyal hiyerarşiye sahiptirler.



Şekil 1. Gri kurt hiyerarşisi.

Gri kurt sürülerinde alfa kurt (erkek ve dişi lider çift), avlanma, uyku yeri ve uyanma zamanlarını belirler. Sürü, alfa kurdun emirlerine uymak zorundadır. Beta kurt, alfaya yardımcı olan ve alfa öldüğünde veya yaşlandığında lider olmaya en uygun adaydır. Alfaya saygı gösterirken diğer kurtlara hükmetmesi gerekir. Omega kurtlar en alt rütbeli olup, tüm kurtlara boyun eğer ve en son yemek yer. Omega kaybederse, sürüde iç çatışmalar başlar. Delta kurtlar ise alfa ve betaya boyun eğer, fakat omegaya hükmeder. Bu grupta gözcüler, muhafızlar, yaşlı kurtlar, avcılar ve bakıcılar bulunur.

Avlanma Evreleri:

- Avın takibi, kovalanması ve yaklaşılması
- Avın hareketsiz kalana kadar takip edilmesi ve kuşatılması
- Saldırı

2.4.1. Sosyal Hiyerarşi

GKO tasarlanırken, kurtların sosyal hiyerarşisini matematiksel olarak modellemek için en uygun çözüm alfa (α) olarak kabul edilir. Buna göre, ikinci ve üçüncü en iyi çözümler sırasıyla beta (β) ve delta (δ) olarak adlandırılır. Geri kalan aday çözümlerin ise omega (ω) olduğu varsayılır. GKO algoritmasında avlanma (optimizasyon), α , β ve δ tarafından yönlendirilir. Diğer kurtlar bu üç kurtu takip eder.

2.4.2. Avın Kuşatılması

Yukarıda belirtildiği gibi, gri kurtlar av sırasında avlarını kuşatırlar. Kuşatma davranışını matematiksel olarak modellemek için aşağıdaki denklemler verilmiştir.

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (10)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (11)$$

t mevcut iterasyonu gösterir, $\vec{A}$ ve $\vec{C}$ vektörleri katsayıları temsil eder, $\vec{X}_p(t)$ avın konum vektörünü ifade eder ve $\vec{X}$ gri kurdun konum vektörünü temsil eder.

$\vec{A}$ ve $\vec{C}$ vektörleri verildiği gibi hesaplanır.

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (12)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (13)$$

$\vec{a}$ vektör bileşeni doğrusal olarak 2'den 0'a iterasyon boyunca azaltılır. r_1 ve r_2 ise [0,1] aralığında rastgele sayılardır.

2.4.3. Avlanma

Gri kurtlar avlarını bulma ve kuşatma yeteneğine sahiptir. Genellikle alfa tarafından yönlendirilirler. Beta ve delta kurtlar da zaman zaman avlanmaya katılabilir. Gri kurtların avlanma davranışını matematiksel olarak simüle etmek için, alfanın avın potansiyel konumu hakkında en iyi aday çözüm olduğu, beta ve deltanın ise daha iyi olduğu varsayılır. Bu nedenle, şimdiye kadar elde edilen en iyi üç çözüm kaydedilir ve diğer arama ajanlarının (omegalar dahil) konumları en iyi arama ajanlarına göre güncellenir. Bu konu için aşağıdaki formüller önerilmektedir.

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (14)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1(\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2(\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3(\vec{D}_\delta) \quad (15)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (16)$$

2.4.4. Ava Saldırı (Sömürü)

Yukarıda belirtildiği gibi, gri kurtlar avları hareket etmeyi bıraktığında saldırarak avlanmayı tamamlarlar. Ava yaklaşmayı matematiksel olarak modellemek için $\vec{a}$ vektörünün değeri azaltılır. $\vec{a}$ vektörünün aralığı, $\vec{a}$ vektörü tarafından küçültülür. Başka bir deyişle, $\vec{a}$ vektörünün 2'den 0'a düştüğü iterasyonlar boyunca, $\vec{A}$ vektörü [-a, a] aralığında rastgele bir değerdir. $\vec{A}$ vektörünün rastgele değerleri [-1,1] aralığında olduğunda, bir arama aracının bir sonraki konumu, mevcut konum ile avın konumu arasındaki herhangi bir nokta olabilir.

2.4.5. Avın Aranması (Keşif)

Gri kurtlar öncelikle alfa, beta ve delta kurtların konumlarına göre arama yaparlar. Saldırı için avı aramak ve yaklaşmak üzere birbirlerinden ayrılırlar. Farklılaşmayı matematiksel olarak modellemek için, 1'den büyük veya -1'den küçük olan $\vec{A}$ vektörünün rastgele değerleri kullanılarak arama ajanının avdan uzaklaşması sağlanır. Bu, keşfi vurgular ve GKO algoritmasının global olarak arama yapmasına olanak tanır.

GKO algoritmasında arama süreci, rastgele bir gri kurt popülasyonu (aday çözümler) oluşturularak başlar. İterasyonlar boyunca alfa, beta ve delta kurtlar avın olası konumunu tahmin ederler. Her adımda, çözümün avdan uzaklığı güncellenir. Keşif ve yakınsamayı sırasıyla vurgulamak için a parametresi 2'den 0'a düşürülür. Geçici çözümler $|\vec{A}| > 1$ olduğunda avdan uzaklaşma, $|\vec{A}| < 1$

olduğunda ise ava yaklaşma eğilimindedir. Son olarak, GKO algoritması bir durdurma kriterine ulaşıldığında sonlandırılır.

2.5. Levy Uçuşu- Gri Kurt Optimizasyon Algoritması (LFGKO)

Bu çalışmada, GKO algoritmasına Levy Flight tabanlı bir iyileştirme uygulanmıştır. Levy Flight, ağır kuyruklu olasılık dağılımlarından üretilen rastgele yürüyüş süreci olup, meta sezgisel algoritmalarda keşif yeteneğini artırmak için yaygın olarak kullanılmaktadır. Önerilen iyileştirmede, Mantegna algoritması kullanılarak Levy uçuşu GKO'nun konum güncelleme mekanizmasına entegre edilmiştir. Konum güncellemesi sırasında kullanılan Levy adım boyutu, arama uzayının boyutlarına göre otomatik olarak ölçeklendirilerek farklı problem türlerine uyum sağlanmaktadır (Mantegna, 1994; Yang & Deb, 2009).

$$\text{Levy}(\lambda) = u / |v|^{1/\beta} \quad (17)$$

Burada $u \sim N(0, \sigma_u^2)$, $v \sim N(0, \sigma_v^2)$ normal dağılımlarından örneklenir ve β tipik olarak 1.5 değerini alır.

3. SİMÜLASYON SONUÇLARI ve TARTIŞMALAR


Önerilen LFGKO metodunun ORGD problemine uygulanması, sistem sınırları dikkate alınarak amaç fonksiyonlarını minimize etmek için kontrol değişkenlerinin optimum değerinin bulunmasını içermektedir. IEEE 14 baralı standart test sistemi kullanılmıştır. MATLAB (MathWorks Inc, 2022) kullanılarak simülasyonlar ve optimizasyon sonuçları elde edilmiştir. Test sistemlerinin yük akışları için Zimmerman ve ark. Tarafından geliştirilen MATPOWER paket programı kullanılmıştır (Zimmerman, Murillo-Sánchez, & Thomas, 2010).

Yapılan çalışmada, önerilen optimizasyon algoritmasının etkinliğini göstermek için 14 baralı test sistemi 10 parametrelili optimizasyon problemi çözülmüştür. Daha sonra, 3 adet EAŞİ ilave edilerek 13 parametre ile 14 baralı test sistemine optimum değerlerle yerleştirilmiş ve güç kaybında meydana gelen değişimler incelenmiştir. EAŞİ yük büyüklükleri [0 MW, 5 MW] aralığında seçilmiştir. Tablo 1, IEEE 14 baralı test sisteminde 10 kontrol parametresi kullanılarak farklı optimizasyon algoritmalarının performanslarını karşılaştırmaktadır. Tabloda temel durum ile PSO, WOA, MGTLBO, FJAYA ve önerilen LFGWO algoritmaları değerlendirilmiştir. Kontrol parametreleri olarak 5 jeneratör bara gerilimi (V_1, V_2, V_3, V_6, V_8), 3 transformatör kademe ayarı ($T_{4-7}, T_{4-9}, T_{5-6}$) ve 2 reaktif güç kompanzasyonu (Q_{c9}, Q_{c14}) optimize edilmiştir. Sonuçlar, LFGWO algoritmasının 12,2139 MW güç kaybı ile en düşük değeri elde ettiğini ve temel duruma göre %8,8038 oranında iyileştirme sağladığını göstermektedir. PSO algoritması 12,2504 MW ile ikinci sırada yer alırken, WOA 12,255 MW, MGTLBO 12,3105 MW ve FJAYA 12,2886 MW güç kaybı değerlerine ulaşmıştır. Önerilen LFGWO algoritması, diğer algoritmalarından daha iyi performans göstererek güç sistemi kayıplarını minimize etmede en etkili yöntem olmuştur.

Şekil 2, IEEE 14 baralı test sisteminde 10 parametrelili optimizasyon problemi için farklı algoritmaların yakınsama eğrilerini göstermektedir. Grafik, iterasyon sayısına (x eksen) karşılık güç kaybı değerlerini (y eksen, MW cinsinden) göstermektedir. Eğriler incelendiğinde, tüm algoritmaların başlangıçta yüksek güç kaybı değerlerinden başlayarak iterasyonlar boyunca hızla azaldığı görülmektedir. Önerilen LFGWO algoritması (kırmızı renkli eğri olarak gösterildiği varsayılabilir), yaklaşık 20-30 iterasyon optimum değere yakınsamakta ve en düşük güç kaybı seviyesine ulaşmaktadır. PSO, WOA, MGTLBO ve FJAYA algoritmaları da benzer yakınsama davranışı göstermekte ancak LFGWO'nun ulaştığı düzeye tam olarak erişememektedirler. Grafik, LFGWO algoritmasının hem yakınsama hızı hem de elde edilen sonuç açısından diğer yöntemlere göre üstünlüğünü görsel olarak ortaya koymaktadır.

Tablo 1. 10 Parametrelili Test Sistemi Optimizasyon Algoritma Sonuçları

Parametre	Temel Durum	PSO	WOA (ben Oualid Medani, Sayah, & Bekrar, 2018)	MGTLBO (Ghasemi, Taghizadeh, Ghavidel, Aghaei, & Abbasian, 2015)	FJAYA (Gafar, El- Sehiemy, & Hasanien, 2019)	LFGWO
V ₁	1.06	1.1	1.1	1.1	1.1	1.1
V ₂	1.045	1.086	1.0859	1.0791	1.0862	1.08641
V ₃	1.01	1.0567	1.0566	1.0484	1.0571	1.05712
V ₆	1.07	1.0892	1.0858	1.0553	1.0597	1.1
V ₈	1.09	1.1	1.1	1.0326	1.1	1.1
T ₄₋₇	0.9467	0.975	0.95853	1.01	1	0.975
T ₄₋₉	0.9524	0.975	1.0453	1.01	1	0.975
T ₅₋₆	0.9091	1.025	1.0163	1.03	1.0545	1.00573
QC ₉	0.18	7.6045	12.497	0.3	2.9986	18.4383
QC ₁₄	0.18	7.027	8.0161	0.07	2.9999	7.16622
P _{kayıp}	13.393	12.2504	12.255	12.3105	12.2886	12.2139
% Azalma	-	8.5313	8.497	8.0826	8.2461	8.8038

**Şekil 2. 10 parametrelili test sistemi optimizasyon algoritmaları yakınsama eğrileri**

Tablo 2, elektrikli araç şarj istasyonları (EAŞİ) içeren sistemde dört farklı optimizasyon algoritmasının (GWO, PSO, WOA ve önerilen LFGWO) performanslarını güç kaybı, hesaplama süresi ve toplam EAŞİ yükü açısından karşılaştırmaktadır. Sonuçlara göre, önerilen LFGWO algoritması 12,37927888 MW güç kaybı ile en iyi performansı göstermiş ve birinci sırada yer almıştır. PSO algoritması 12,47444301 MW ile ikinci, GWO 13,14178965 MW ile üçüncü, WOA ise 13,29379369 MW ile dördüncü sırada yer almıştır. Hesaplama süreleri incelendiğinde, PSO 103,68

saniye ile en hızlı algoritma olurken, LFGWO ve WOA yaklaşık 109 saniye, GWO ise 113 saniye sürmüştür. Toplam EAŞİ yükü açısından bakıldığında, PSO 0,58 MW ile en düşük, LFGWO 1,00 MW, GWO 6,47 MW ve WOA 8,15 MW ile en yüksek değerlere sahiptir. Bu tablo, LFGWO algoritmasının güç kaybını minimize etmede en etkili yöntem olduğunu ortaya koymaktadır.

Tablo 2. Optimizasyon Algoritma Sonuçları

Algoritma	Güç Kaybı (MW)	Süre (saniye)	Toplam EAŞİ (MW)	Sıralama
GWO	13,14178965	113,0088	6,474258859	3
PSO	12,47444301	103,6848429	0,582842805	2
WOA	13,29379369	108,9748571	8,150824375	4
LFGWO*	12,37927888	108,9866904	1,001305019	1

*Önerilen


Tablo 3, IEEE 14 baralı test sistemine 3 adet elektrikli araç şarj istasyonunun eklenmesiyle oluşan 13 parametrelili sistemin optimizasyon sonuçlarını detaylı olarak sunmaktadır. Bu tabloda GWO, PSO, WOA ve önerilen LFGWO algoritmaları karşılaştırılmaktadır.

Tablo 3. 13 Parametrelili Test Sistemi Sonuçları

Parametre	GWO	PSO	WOA	LFGWO
V ₁	1,1	1,101516	1,1	1,1
V ₂	1,076853	1,081146	1,079116	1,086868
V ₃	1,042146	1,044088	1,038439	1,057427
V ₆	1,030705	1,067445	1,038382	1,071655
V ₈	1,053218	1,100144	1,038382	1,07766
Tap ₁	0,991859	0,982865	1,012768	1,024915
Tap ₂	1,019759	0,990723	1,012734	0,975
Tap ₃	1,025	0,993469	1,010978	1,01016
Q ₉ (MVAR)	0,185881	4,809211	15,07448	16,20354
Q ₁₄ (MVAR)	14,7045	15,39792	0	7,642924
EAŞİ ₁ (Bara)	5	9	10	13
EAŞİ ₂ (Bara)	9	14	7	4
EAŞİ ₃ (Bara)	7	4	5	9
EAŞİ ₁ (MW)	2,885601	0,115751	3,094648	1
EAŞİ ₂ (MW)	3,532244	0,304821	0,056176	0
EAŞİ ₃ (MW)	0,056413	0,162271	5	0,001305
EAŞİ ₁ (MVAR)	0,948451	0,038046	1,017162	0,328684
EAŞİ ₂ (MVAR)	1,160993	0,10019	0,018464	0
EAŞİ ₃ (MVAR)	0,018542	0,053336	1,643421	0,000429
Toplam EAŞİ (MW)	6,474259	0,582843	8,150824	1,001305
Toplam EAŞİ (MVAR)	2,127986	0,191571	2,679046	0,329113
Güç Kaybı (MW)	13,14179	12,47444	13,29379	12,37928
Süre (saniye)	113,8009	103,6848	108,9749	108,9867

Kontrol parametreleri olarak 5 jeneratör bara gerilimi, 3 transformatör kademe ayarı, 2 reaktif güç kompanzasyonu ve 3 EAŞİ'nin konumu ve aktif-reaktif güç değerleri optimize edilmiştir. Sonuçlar, önerilen LFGWO algoritmasının 12,37928 MW güç kaybı ile en iyi performansı gösterdiğini ortaya koymaktadır. LFGWO, EAŞİ'leri 13, 4 ve 9 numaralı baralara yerleştirmiş ve toplam 1,001305 MW aktif güç yükü ile optimize edilmiştir. PSO algoritması 12,47444 MW güç kaybı ile ikinci sırada yer alırken, EAŞİ'leri 9, 14 ve 4 numaralı baralara yerleştirmiş ve sadece 0,582843 MW toplam yük kullanmıştır. GWO 13,14179 MW ve WOA 13,29379 MW güç kaybı değerleri ile üçüncü ve

dördüncü sıralarda yer almışlardır. Hesaplama süreleri açısından PSO 103,68 saniye ile en hızlı algoritma olurken, diğer algoritmalar yaklaşık 109-114 saniye arasında değişmektedir.




Şekil 3. Optimizasyon algoritmaları yakınsama eğrileri


Şekil 3, elektrikli araç şarj istasyonları eklendikten sonraki sistemde farklı optimizasyon algoritmalarının yakınsama performanslarını karşılaştırmaktadır. Grafik, iterasyon sayısına göre güç kaybının (MW cinsinden) nasıl değiştiğini göstermektedir. GWO, PSO, WOA ve önerilen LFGWO algoritmaları için ayrı eğriler çizilmiştir. Tüm algoritmalar ilk iterasyonlarda yüksek güç kaybı değerlerinden başlamakta ve iterasyonlar ilerledikçe optimize edilmiş değerlere yakınsamaktadır. Önerilen LFGWO algoritmasının eğrisi, en düşük güç kaybı seviyesine ulaşmakta ve diğer algoritmalarla karşılaştırıldığında daha iyi bir yakınsama karakteristiği sergilemektedir. PSO algoritması ikinci en iyi performansı gösterirken, GWO ve WOA daha yüksek güç kaybı değerlerinde stabilize olmaktadır. Bu görselleştirme, EAŞİ içeren karmaşık sistemlerde bile LFGWO'nun etkinliğini açıkça ortaya koymaktadır.

Şekil 4, farklı optimizasyon algoritmalarının elde ettiği güç kaybı değerlerini bar grafiği formatında karşılaştırmaktadır. Grafik, GWO, PSO, WOA ve LFGWO algoritmalarının performanslarını MW cinsinden güç kaybı açısından yan yana göstermektedir. LFGWO algoritmasının en düşük güç kaybı değerini (yaklaşık 12,38 MW) elde ettiği, bunu PSO'nun (yaklaşık 12,47 MW) takip ettiği görülmektedir. GWO ve WOA algoritmaları sırasıyla yaklaşık 13,14 MW ve 13,29 MW değerleri ile daha yüksek güç kayıplarına sahiptir. Bu görsel karşılaştırma, algoritmaların birbirine olan üstünlüklerini net bir şekilde ortaya koymakta ve LFGWO'nun elektrikli araç şarj istasyonları içeren güç sistemlerinde optimal reaktif güç dağıtım problemi için en etkili çözüm olduğunu göstermektedir. Grafik, sayısal sonuçların görsel olarak daha kolay anlaşılmasını sağlamaktadır.

Şekil 5, optimizasyon algoritmalarının iterasyon sonunda EAŞİ – bara yerleşim ve güç ilişkilerini göstermektedir.



Şekil 4. Optimizasyon algoritmaları güç kaybı karşılaştırmaları



Şekil 5. Optimizasyon algoritmaları EAIŞ – bara yerleşimleri ve güçleri

4. SONUÇLAR

Bu çalışmada, elektrikli araç şarj istasyonları içeren güç sistemlerinde optimal reaktif güç dağıtımı problemi için Levy Flight tabanlı geliştirilmiş gri kurt optimizasyon (LFGWO) algoritması önerilmiştir. IEEE 14 baralı standart test sistemi üzerinde yapılan simülasyonlarda, önce 10 parametrelili temel sistem optimize edilmiş ve LFGWO algoritması 12,2139 MW güç kaybı ile %8,8038 oranında iyileştirme sağlayarak PSO, WOA, MGTLBO ve FJAYA algoritmalarından daha iyi performans göstermiştir. Daha sonra sisteme 3 adet elektrikli araç şarj istasyonu eklenerek 13 parametrelili optimizasyon problemi çözülmüştür. Sonuçlar, LFGWO algoritmasının 12,37928 MW güç kaybı ile en iyi performansı gösterdiğini, bunu sırasıyla PSO (12,47444 MW), GWO (13,14179 MW) ve WOA (13,29379 MW) algoritmalarının takip ettiğini ortaya koymuştur.

Önerilen LFGWO algoritması hem yakınsama hızı hem de elde edilen optimum sonuç açısından klasik GKO ve diğer meta-sezgisel yöntemlere göre üstünlük sağlamıştır. Elektrikli araç şarj istasyonlarının sisteme entegrasyonunun güç kaybı üzerinde önemli etkisi olduğu gözlemlenmiştir. LFGWO algoritması, EAŞİ'lerin optimum konumlarını ve güç değerlerini belirleyerek sistem kayıplarını minimize etmede başarılı olmuştur. Çalışma, artan elektrikli araç sayısı ile güç sistemlerinin verimli işletilmesi için geliştirilmiş optimizasyon algoritmalarının önemini ortaya koymaktadır. Gelecek çalışmalarda, çok amaçlı optimizasyon yaklaşımları ve daha büyük test sistemleri üzerinde önerilen yöntemin etkinliği araştırılabilir.

KAYNAKÇA

- Abaza, A., Fawzy, A., El-Sehiemy, R. A., Alghamdi, A. S., & Kamel, S. (2021). Sensitive reactive power dispatch solution accomplished with renewable energy allocation using an enhanced coyote optimization algorithm. *Ain Shams Engineering Journal*, 12(2), 1723-1739.
- Ahmad, A., Alam, M. S., & Chabaan, R. (2017). A comprehensive review of wireless charging technologies for electric vehicles. *IEEE Transactions on Transportation Electrification*, 4(1), 38-63.
- Ayan, K., & Kılıç, U. (2012). Artificial bee colony algorithm solution for optimal reactive power flow. *Applied Soft Computing*, 12(5), 1477-1482.
- ben Oualid Medani, K., Sayah, S., & Bekrar, A. (2018). Whale optimization algorithm based optimal reactive power dispatch: A case study of the Algerian power system. *Electric Power Systems Research*, 163, 696-705.
- Dai, C., Chen, W., Zhu, Y., & Zhang, X. (2009). Reactive power dispatch considering voltage stability with seeker optimization algorithm. *Electric Power Systems Research*, 79(10), 1462-1471.
- Duman, S., Güvenç, U., Sönmez, Y., & Yörükeren, N. (2012). Optimal power flow using gravitational search algorithm. *Energy conversion and management*, 59, 86-95.
- Durairaj, S., Devaraj, D., & Kannan, P. (2006). Genetic algorithm applications to optimal reactive power dispatch with voltage stability enhancement. *Journal-Institution of Engineers India Part El Electrical Engineering Division*, 87, 42.
- Frank, S., & Rebennack, S. (2016). An introduction to optimal power flow: Theory, formulation, and examples. *IIE transactions*, 48(12), 1172-1197.
- Gafar, M. G., El-Sehiemy, R. A., & Hasanien, H. M. (2019). A novel hybrid fuzzy-JAYA optimization algorithm for efficient ORPD solution. *IEEE Access*, 7, 182078-182088.
- Ghasemi, M., Taghizadeh, M., Ghavidel, S., Aghaei, J., & Abbasian, A. (2015). Solving optimal reactive power dispatch problem using a novel teaching-learning-based optimization algorithm. *Engineering Applications of Artificial Intelligence*, 39, 100-108.
- Hertz, A., & Dewerra, D. (1987). USING TABU SEARCH TECHNIQUES FOR GRAPH-COLORING. *COMPUTING*, 39(4), 345-351. doi:10.1007/BF02239976
- Jan, R.-M., & Chen, N. (1995). Application of the fast Newton-Raphson economic dispatch and reactive power/voltage dispatch by sensitivity factors to optimal power flow. *IEEE transactions on energy conversion*, 10(2), 293-301.
- Khanmiri, D. T., Nasiri, N., & Mobaraki, S. T. (2012). Optimal reactive power dispatch by genetic algorithm and particle swarm optimization considering lost opportunities. *World Acad. Sci., Eng. Technol*, 62, 871-876.
- Khazali, A., & Kalantar, M. (2011). Optimal reactive power dispatch based on harmony search algorithm. *International Journal of Electrical Power & Energy Systems*, 33(3), 684-692.
- Kumar, R. R., & Alok, K. (2020). Adoption of electric vehicle: A literature review and prospects for sustainability. *Journal of Cleaner Production*, 253, 119911.
- Lee, K. Y., & Yang, F. F. (1998). Optimal reactive power planning using evolutionary algorithms: A comparative study for evolutionary programming, evolutionary strategy, genetic algorithm, and linear programming. *IEEE Transactions on power systems*, 13(1), 101-108.
- Mahadevan, K., & Kannan, P. (2010). Comprehensive learning particle swarm optimization for reactive power dispatch. *Applied Soft Computing*, 10(2), 641-652.
- Mantegna, R. N. (1994). Fast, accurate algorithm for numerical simulation of Levy stable stochastic processes. *Physical Review E*, 49(5), 4677.
- MathWorks Inc, M. (2022). MATLAB version: 9.13. 0 (R2022b). In: The MathWorks Inc.
- Mei, R. N. S., Sulaiman, M. H., Mustaffa, Z., & Daniyal, H. (2017). Optimal reactive power dispatch solution by loss minimization using moth-flame optimization technique. *Applied Soft Computing*, 59, 210-222.

- Mirjalili, S., & Hashim, S. Z. M. (2010, 3-5 Dec. 2010). *A new hybrid PSOGSA algorithm for function optimization*. Paper presented at the 2010 International Conference on Computer and Information Application.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *ADVANCES IN ENGINEERING SOFTWARE*, 69, 46-61. doi:10.1016/j.advengsoft.2013.12.007
- Newell, R. G., Qian, Y., & Raimi, D. (2016). *Global energy outlook 2015*. Retrieved from
- Quintana, V., & Santos-Nieto, M. (2002). Reactive-power dispatch by successive quadratic programming. *IEEE transactions on energy conversion*, 4(3), 425-435.
- Sakr, W. S., El-Sehiemy, R. A., & Azmy, A. M. (2017). Adaptive differential evolution algorithm for efficient reactive power management. *Applied Soft Computing*, 53, 336-351.
- Shaheen, M. A., Hasanien, H. M., & Alkuhayli, A. (2021). A novel hybrid GWO-PSO optimization technique for optimal reactive power dispatch problem solution. *Ain Shams Engineering Journal*, 12(1), 621-630.
- Sulaiman, M. H., Mustaffa, Z., Mohamed, M. R., & Aliman, O. (2015). Using the gray wolf optimizer for solving optimal reactive power dispatch problem. *Applied Soft Computing*, 32, 286-292.
- Tu, H., Feng, H., Srdic, S., & Lukic, S. (2019). Extreme fast charging of electric vehicles: A technology overview. *IEEE Transactions on Transportation Electrification*, 5(4), 861-878.
- Un-Noor, F., Padmanaban, S., Mihet-Popa, L., Mollah, M. N., & Hossain, E. (2017). A comprehensive study of key electric vehicle (EV) components, technologies, challenges, impacts, and future direction of development. *Energies*, 10(8), 1217.
- Vlachogiannis, J. G., & Lee, K. Y. (2006). A comparative study on particle swarm optimization for optimal steady-state performance of power systems. *IEEE Transactions on power systems*, 21(4), 1718-1728.
- Wu, Q. H., & Ma, J. (2002). Power system optimal reactive power dispatch using evolutionary programming. *IEEE Transactions on power systems*, 10(3), 1243-1249.
- Yang, X.-S., & Deb, S. (2009). *Cuckoo search via Lévy flights*. Paper presented at the 2009 World congress on nature & biologically inspired computing (NaBIC).
- Yilmaz, M., & Krein, P. T. (2012). Review of battery charger topologies, charging power levels, and infrastructure for plug-in electric and hybrid vehicles. *IEEE transactions on Power Electronics*, 28(5), 2151-2169.
- Zhao, B., Guo, C., & Cao, Y. (2005). A multiagent-based particle swarm optimization approach for optimal reactive power dispatch. *IEEE Transactions on power systems*, 20(2), 1070-1078.
- Zhu, J., & Xiong, X. (2003). Optimal reactive power control using modified interior point method. *Electric Power Systems Research*, 66(2), 187-192.
- Zimmerman, R. D., Murillo-Sánchez, C. E., & Thomas, R. J. (2010). MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education. *IEEE Transactions on power systems*, 26(1), 12-19.

BÖLÜM 6

5G AĞLARDA MAKİNE ÖĞRENMESİ DESTEKLİ OPTİMİZASYON: MEVCUT YAKLAŞIMLAR VE 6G'YE BAKIŞ

Asuman SAVAŞCIHABEŞ¹

¹ Doç. Dr., Nuh Naci Yazgan Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü E-Mail: Asuman83@Gmail.com

1. GİRİŞ

Beşinci nesil (5G) kablosuz haberleşme sistemleri; artan mobil veri trafiği, çok çeşitli hizmet gereksinimleri ve yoğun cihaz bağlantısı gibi zorlukları aynı anda karşılamak üzere tasarlanmıştır[1]. 5G ağları, geliştirilmiş mobil geniş bant (eMBB), ultra güvenilir ve düşük gecikmeli haberleşme (URLLC) ve kitlesel makine tipi haberleşme (mMTC) gibi farklı servis senaryolarını destekleyerek, önceki nesil ağlara kıyasla daha esnek ve yetenekli bir yapı sunmaktadır. Ancak bu çok katmanlı ve heterojen yapı, ağ yönetimi ve kaynak optimizasyonu problemlerini önemli ölçüde karmaşık hale getirmektedir. 5G ağlarında radyo kaynaklarının etkin kullanımı, spektrum verimliliğinin artırılması, gecikmenin minimize edilmesi ve enerji verimliliğinin sağlanması kritik öneme sahiptir[2-3]. Geleneksel optimizasyon yöntemleri genellikle statik varsayımlara dayanmakta ve önceden tanımlanmış kurallar veya matematiksel modeller üzerinden çözüm üretmektedir. Bu yaklaşımlar, dinamik trafik koşulları, zamana bağlı kanal değişimleri ve farklı hizmet kalite gereksinimlerinin bir arada bulunduğu 5G ortamlarında yetersiz kalabilmektedir. Özellikle gerçek zamanlı karar verme gereksinimi, klasik yöntemlerin ölçeklenebilirliğini ve uyarlanabilirliğini sınırlamaktadır. Bu noktada, makine öğrenmesi (ML) tabanlı yaklaşımlar 5G ağlar için güçlü bir alternatif olarak öne çıkmaktadır. Makine öğrenmesi, ağdan elde edilen büyük ölçekli veriler üzerinden öğrenme yeteneği sayesinde, değişen ağ koşullarına uyum sağlayabilen ve çevrim içi kararlar verebilen akıllı optimizasyon mekanizmalarının geliştirilmesine olanak tanımaktadır[4-7]. Denetimli ve denetimsiz öğrenme yöntemleri trafik tahmini, kullanıcı davranışı analizi ve ağ durumu kestirimi gibi alanlarda kullanılırken; pekiştirmeli öğrenme ve derin pekiştirmeli öğrenme teknikleri özellikle kaynak tahsisi, güç kontrolü ve gecikme optimizasyonu gibi karar verme problemlerinde başarılı sonuçlar sunmaktadır[8-10].

Bu çalışma, 5G ağlar için makine öğrenmesi destekli kaynak ve ağ optimizasyonu alanında yapılan çalışmaları kapsamlı bir şekilde derlemeyi amaçlamaktadır. Makalede, farklı makine öğrenmesi yaklaşımlarının 5G/6G ağlardaki kullanım alanları sistematik olarak sınıflandırılmakta, literatürde önerilen yöntemler karşılaştırmalı olarak incelenmekte ve mevcut çalışmaların güçlü ve zayıf yönleri tartışılmaktadır. Ayrıca, bu alandaki açık problemler ve gelecekteki araştırma yönleri ele alınarak, 5G ve ötesi haberleşme sistemleri için makine öğrenmesi tabanlı optimizasyon çalışmalarına rehberlik edilmesi hedeflenmektedir.

2. 5G Ağ Mimarisi ve Optimizasyon Problemleri

5G, uçtan uca (E2E) mimaride **radyo erişim ağı (NG-RAN)** ve **5G çekirdek şebekesi (5GC)** bileşenlerinin birlikte çalıştığı; **ağ dilimleme (network slicing)**, **sanallaştırma (NFV)**, **yazılım tanımlı ağ (SDN)** ve **çok erişimli uç bilişim (MEC)** gibi kavramlarla esnek ve programlanabilir bir ağ yaklaşımı sunar. Bu mimaride temel hedef, farklı hizmet sınıflarının (örn. **eMBB**, **URLLC**, **mMTC**) birbirinden ayrık **QoS/QoE** gereksinimlerini aynı fiziksel altyapı üzerinde karşılayabilmektir. Bu nedenle 5G; kaynakların dinamik tahsisine, çok hedefli optimizasyona ve çevrim-içi (online) karar mekanizmalarına dayanır[11]. 5G ağları, önceki nesil hücreli sistemlere kıyasla daha esnek, yazılım tanımlı ve servis odaklı bir mimari anlayışıyla tasarlanmıştır. Bu mimari yaklaşım, farklı hizmet türlerinin aynı fiziksel altyapı üzerinde eş zamanlı olarak desteklenmesini mümkün kılarken, ağ yönetimi ve kaynak optimizasyonu problemlerini de daha karmaşık hale getirmektedir. Bu bölümde, 5G ağ mimarisinin temel bileşenleri ve bu mimari yapı içerisinde ortaya çıkan başlıca optimizasyon problemleri ele alınmaktadır.

2.1 5G Ağ Mimarisi

5G ağ mimarisi, radyo erişim ağı (Radio Access Network – RAN) ve çekirdek ağ (5G Core – 5GC) olmak üzere iki ana bileşenden oluşmaktadır. RAN tarafında, çoklu giriş-çoklu çıkış (MIMO), masif MIMO ve milimetre dalga (mmWave) teknolojileri sayesinde yüksek veri hızları ve spektrum verimliliği hedeflenmektedir. Ancak bu gelişmiş fiziksel katman teknolojileri, kaynak tahsisi ve girişim yönetimi problemlerini daha karmaşık bir hale getirmektedir.

5G çekirdek ağı, servis tabanlı mimari (Service-Based Architecture – SBA) yaklaşımı ile modüler ve esnek bir yapı sunmaktadır. Yazılım tanımlı ağlar (SDN) ve ağ fonksiyonlarının sanallaştırılması (NFV) teknolojileri sayesinde ağ fonksiyonları dinamik olarak konumlandırılabilen ve ölçeklenebilmektedir. Bu yapı, ağ kaynaklarının daha verimli kullanılmasına olanak tanırken, aynı zamanda gerçek zamanlı optimizasyon gereksinimini de beraberinde getirmektedir. 5G mimarisinin en önemli yeniliklerinden biri **network slicing** kavramıdır. Network slicing, farklı hizmet gereksinimlerine sahip uygulamalar için mantıksal ağ dilimlerinin oluşturulmasını sağlar. Örneğin, düşük gecikme gerektiren URLLC uygulamaları ile yüksek veri hızı odaklı eMBB servisleri aynı fiziksel altyapı üzerinde farklı dilimler aracılığıyla desteklenebilir. Bu durum, dilimler arası kaynak paylaşımı ve hizmet kalitesi garantilerinin sağlanmasını kritik bir optimizasyon problemi haline getirmektedir.

2.2 5G Ağlarında Temel Optimizasyon Problemleri

5G ağlarında karşılaşılan optimizasyon problemleri, ağın farklı katmanlarında ve farklı zaman ölçeklerinde ortaya çıkmaktadır. Bu problemler genellikle çok amaçlı, doğrusal olmayan ve NP-zor yapıda olup, klasik yöntemlerle çözümleri güçtür. 5G optimizasyon problemleri; **fiziksel katman** (güç kontrolü, hüzme yönetimi, MIMO/beamforming), **MAC/PHY** (zamanlama, PRB tahsisi), **RAN** (hücreler arası girişim koordinasyonu, mobilite/handover, yük dengeleme), **çekirdek şebeke** (VNF yerleştirme, yönlendirme), **uç bilişim** (görev boşaltma/offloading, gecikme-enerji dengesi) ve **servis düzeyi** (dilimleme, kabul kontrolü, SLA) gibi çok katmanlı bir uzayda ortaya çıkar. Bu problemlerin ortak özellikleri arasında **çok amaçlı** olmaları (*düşük gecikme*, *daha az enerji*, *spektral verimlilikte artış*, *yüksek güvenilirlik*), **kısıtlı optimizasyon** formunda yazılmaları (*güç/spektrum/hesaplama kısıtları*, *SLA kısıtları*), **belirsizlik** ve **zamanla değişen ortam** içermeleri (*trafik dalgalanması*, *kanal değişimi*, *kullanıcı hareketliliği*), **büyük ölçek** ve **heterojenlik** taşımaları (*çok hücreli topoloji*, *çoklu hizmet sınıfları*, *farklı cihaz profilleri*) olarak karşımıza çıkmaktadır [12].

2.3 Temel Problem Sınıfları ve Hedef Fonksiyonlar

Optimizasyon problemlerinin ana başlıkları şunlardır:

1. RAN Kaynak Yönetimi (RRM)

- PRB/zamanlama, güç kontrolü, kullanıcı eşleştirme, MIMO/beamforming, girişim yönetimi (ICIC/eICIC, CoMP vb.)
- Tipik hedefler: *toplam throughput artışı*, *gecikmenin azaltılması*, *yüksek spektral verimlilik*, *enerji tüketimi optimizasyonu*

2. Mobilite Yönetimi

- Handover kararları, ping-pong azaltma, handover parametre optimizasyonu, kapsama/süreklilik
- Tipik hedefler: *handover başarısızlığı* , *hizmet kesintisi*

3. Yük Dengeleme ve SON (Self-Organizing Networks)

- Trafik dağıtımı, hücre “range expansion”, parametre ayarı, self-optimization
- Tipik hedefler: *hücre tıkanıklığı*, *kullanıcı deneyimi* , *enerji*

4. Network Slicing ve Servis Tabanlı Optimizasyon

- Dilim kaynak ayırma, dilim kabul kontrolü, dilimler arası izolasyon, SLA ihlali minimizasyonu
- Tipik hedefler: *SLA ihlali*, *gelir/utility*, *kaynak kullanımı*

5. MEC/Uç Bilişim Optimizasyonu

- Görev boşaltma, uç sunucu seçimi, önbellekleme, gecikme-enerji dengesi
- Tipik hedefler: *uçtan uca gecikme* , *cihaz enerji tüketimi* , *QoE*

Bu tür sınıflandırmaların RAN tarafı için kapsamlı bir biçimde literatürde derleme makalelerinde yer almıştır[13-15].

Tablo 1. 5G Ağlarında Temel Optimizasyon Problemleri, Hedefler ve Performans Metrikleri

Optimizasyon Problemi	Optimizasyon Hedefi	Başlıca Performans Metrikleri
Kaynak Tahsisi (Resource Allocation)	Kullanıcılar arasında adil ve verimli kaynak paylaşımı	Throughput, Spektrum Verimliliği (bps/Hz), Adalet İndeksi (Jain's Fairness Index), Paket Kayıp Oranı
Güç Kontrolü	İletim gücünün optimize edilmesi ve girişimin azaltılması	Enerji Verimliliği (bit/Joule), SNR, SINR, Toplam Güç Tüketimi
Enerji Verimliliği Optimizasyonu	Ağın toplam enerji tüketiminin minimize edilmesi	Enerji Verimliliği, Karbon Ayak İzi, Batarya Ömrü
Spektrum Paylaşımı	Spektrumun etkin ve dinamik kullanımı	Spektrum Verimliliği, Girişim Seviyesi, Kullanım Oranı
Gecikme Optimizasyonu	Uçtan uca gecikmenin minimize edilmesi	Gecikme (Latency), Kuyruk Gecikmesi, Paket Gecikme Varyansı
Güvenilirlik Optimizasyonu	İletim güvenilirliğinin artırılması	Paket Başarı Oranı, BLER, Hata Olasılığı
Network Slicing	Dilimler arası kaynakların SLA'ya uygun paylaşımı	Dilim İzolasyonu, QoS/QoE Metrikleri, SLA İhlal Oranı
Yük Dengeleme	Hücreler arası trafik yükünün dengelenmesi	Hücre Kullanım Oranı, Throughput Dengesizliği
Mobilite ve Handover Yönetimi	Kesintisiz bağlantı ve servis sürekliliği	Handover Gecikmesi, Handover Başarısızlık Oranı
Çok Amaçlı Optimizasyon	Birden fazla hedefin eş zamanlı optimizasyonu	Pareto Optimum Noktaları, Ağırlıklı Fayda Fonksiyonu

Tablo 1’de, 5G ağlarında yaygın olarak ele alınan optimizasyon problemleri, bu problemlere karşılık gelen temel hedefler ve literatürde sıkça kullanılan performans metrikleri özetlenmiştir. Görüldüğü üzere, birçok optimizasyon problemi birden fazla performans metriğini eş zamanlı olarak etkilemekte ve bu durum çok amaçlı optimizasyon yaklaşımlarını gerekli kılmaktadır. Bu karmaşık ve dinamik yapı, makine öğrenmesi tabanlı yöntemlerin 5G ağ optimizasyonunda neden giderek daha fazla tercih edildiğini açıkça ortaya koymaktadır.

Kaynak tahsisi, 5G ağlarındaki en temel optimizasyon problemlerinden biridir. Zaman, frekans ve uzamsal kaynakların kullanıcılar arasında adil ve verimli bir şekilde paylaşılması gerekmektedir. Kullanıcı sayısının ve trafik türlerinin dinamik olarak değişmesi, bu problemi daha da zorlaştırmaktadır.

Güç kontrolü ve enerji verimliliği optimizasyonu, özellikle yoğun hücre yapılarında ve IoT tabanlı mMTC senaryolarında büyük önem taşımaktadır. Hem baz istasyonları hem de uç cihazlar için enerji tüketiminin minimize edilmesi, ağın sürdürülebilirliği açısından kritik bir hedeftir.

Spektrum paylaşımı ve girişim yönetimi, heterojen ağ yapılarında karşılaşılan bir diğer önemli problemdir. Küçük hücreler, makro hücreler ve farklı frekans bantlarının bir arada kullanılması,

karmaşık girişim senaryolarına yol açmaktadır. Bu durum, spektrumun etkin kullanımı için dinamik ve uyarlanabilir optimizasyon mekanizmalarını gerekli kılmaktadır.

Gecikme ve güvenilirlik optimizasyonu, özellikle URLLC uygulamaları için kritik öneme sahiptir. Endüstriyel otomasyon, otonom araçlar ve uzaktan cerrahi gibi uygulamalarda, milisaniye seviyesinde gecikme ve yüksek güvenilirlik gereksinimleri bulunmaktadır. Bu tür senaryolarda, ağ kararlarının gerçek zamanlı olarak alınması gerekmektedir.

Son olarak, **yük dengeleme ve mobilite yönetimi**, kullanıcı hareketliliğinin yoğun olduğu 5G ağlarında performansı doğrudan etkileyen unsurlardır. Hücreler arası geçişler sırasında kaynakların etkin yönetilememesi, hizmet kalitesinde düşüşe neden olabilmektedir. Bu optimizasyon problemlerinin büyük bir kısmı, belirsizlik içeren, dinamik ve yüksek boyutlu yapıları nedeniyle geleneksel yöntemlerle etkin bir şekilde çözülememektedir. Bu durum, 5G ağlarında makine öğrenmesi tabanlı, veri odaklı ve uyarlanabilir optimizasyon yaklaşımlarının önemini artırmaktadır. Bir sonraki bölümde, bu problemlerin çözümünde kullanılan makine öğrenmesi tekniklerinin temel prensipleri ele alınacaktır.

3. Makine Öğrenmesi Temelleri ve 5G'ye Uygun Öğrenme Paradigmaları

5G ağlarında karşılaşılan optimizasyon problemleri; yüksek boyutlu durum uzayı, belirsizlik, zamana bağlı değişkenlik ve çoklu kısıtlar nedeniyle klasik deterministik yaklaşımlar için önemli zorluklar barındırmaktadır. Bu nedenle, ağdan elde edilen büyük ölçekli veriler üzerinden öğrenme yeteneğine sahip olan makine öğrenmesi (ML) yöntemleri, 5G ağ optimizasyonu için doğal ve güçlü bir çözüm alternatifi sunmaktadır. Bu bölümde, temel makine öğrenmesi paradigmaları ele alınmakta ve bu paradigmaların 5G ağlarındaki uygun kullanım alanları tartışılmaktadır.

3.1 5G Ağ Optimizasyonunda Makine Öğrenmesinin Rolü

Makine öğrenmesi, açıkça tanımlanması zor olan karmaşık ilişki ve karar mekanizmalarını veriye dayalı olarak modelleyebilme yeteneğine sahiptir. 5G ağlarında trafik yoğunluğu, kullanıcı hareketliliği, kanal koşulları ve servis talepleri zamanla değiştiğinden, ağ kararlarının statik kurallarla belirlenmesi çoğu durumda yetersiz kalmaktadır. ML tabanlı yaklaşımlar; ağ durumunu tahmin edebilme, geçmiş deneyimlerden öğrenme ve değişen koşullara uyum sağlama gibi özellikleri sayesinde, 5G ağlarında çevrim içi ve ölçeklenebilir optimizasyon imkânı sunmaktadır.

3.2 Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme, giriş-çıkış çiftlerinden oluşan etiketli veri kümesi üzerinden bir tahmin veya sınıflandırma fonksiyonunun öğrenilmesini amaçlamaktadır. 5G ağlarında denetimli öğrenme yöntemleri; ağ durumunun kestirimi ve performans tahmini gibi dolaylı optimizasyon problemlerinde yaygın olarak kullanılmaktadır.

Başlıca kullanım alanları şunlardır:

- Trafik yükü ve throughput tahmini
- Kanal kalitesi ve bağlantı güvenilirliği kestirimi
- Handover başarısızlığı veya QoS ihlali olasılığının tahmini

Denetimli öğrenme yöntemlerinin en önemli avantajı, eğitim sürecinin kararlı ve yorumlanabilir olmasıdır. Ancak, etiketli veri ihtiyacı ve saha koşullarında veri dağılımının zamanla değişmesi (concept drift), bu yaklaşımın temel sınırlamaları arasında yer almaktadır.

3.3 Denetimsiz ve Öz-Denetimli Öğrenme

Denetimsiz öğrenme, etiketli veri gerektirmeden, verideki gizli yapıları ve örüntüleri ortaya çıkarmayı hedefler. 5G ağlarında büyük miktarda etiketsiz telemetri verisi bulunduğundan, bu paradigmlar özellikle ağ izleme ve analiz uygulamalarında önemlidir. Bu yöntemler Ağ anomalisi ve arıza tespiti, kullanıcı ve trafik profili kümelenmesi, hücre davranışlarının sınıflandırılması gibi alanlarda kullanılmaktadır.

Öz-denetimli öğrenme yaklaşımları ise, etiket üretimini veri üzerinden otomatik olarak gerçekleştirerek, daha sonra denetimli veya pekiştirmeli öğrenme algoritmalarının performansını artırmak amacıyla temsil öğreniminde kullanılmaktadır.

3.4 Pekiştirmeli Öğrenme ve Derin Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme (Reinforcement Learning – RL), bir ajanın çevre ile etkileşime girerek ödül sinyaline dayalı olarak en uygun eylem politikasını öğrenmesini amaçlar. 5G ağ optimizasyonu problemleri çoğunlukla ardışık karar verme yapısına sahip olduğundan, RL ve türevleri bu alanda yaygın olarak tercih edilmektedir. 5G ağ optimizasyonu bağlamında pekiştirmeli öğrenme çerçevesi; **durum (state)**, **eylem (action)** ve **ödül (reward)** bileşenleri üzerinden tanımlanmaktadır. Bu çerçevede, durum uzayı; anlık **kanal ölçümleri**, **radio kaynak doluluk oranları** ve **uçtan uca gecikme değerleri** gibi ağın dinamik özelliklerini temsil eden parametrelerden oluşmaktadır. Ajanın eylem uzayı, **kaynak tahsisi kararları**, **iletim gücü ayarlamaları** ve **handover tetikleme mekanizmaları** gibi ağ kontrolüne yönelik işlemleri kapsamaktadır. Öğrenme sürecini yönlendiren ödül fonksiyonu ise genellikle **toplam veri iletim hızı (throughput)** ve **gecikmenin minimize edilmesi** gibi performans hedeflerini yansıtacak şekilde tanımlanmaktadır. Yüksek boyutlu durum uzaylarında, derin sinir ağları ile desteklenen **Derin Pekiştirmeli Öğrenme (DRL)** yaklaşımları kullanılmaktadır. DRL, özellikle network slicing, dinamik kaynak tahsisi ve gecikme kritik uygulamalarda etkili sonuçlar sunmaktadır. Bununla birlikte, yakınsama süresi ve kararlılık, DRL tabanlı yöntemlerin başlıca zorluklarıdır.

3.5 Çok Ajanlı Öğrenme Yaklaşımları

5G ağları, çok hücreli ve dağıtık bir yapıya sahip olduğundan, optimizasyon kararlarının tek bir merkezi noktadan alınması her zaman mümkün veya verimli değildir. Bu bağlamda, çok ajanlı pekiştirmeli öğrenme (Multi-Agent Reinforcement Learning – MARL) yaklaşımları, her hücre veya ağ elemanının bağımsız bir ajan olarak karar vermesini sağlar. MARL yöntemleri; girişim yönetimi, yük dengeleme ve koordineli handover kararları gibi problemlerde avantaj sağlarken, ajanlar arası etkileşimden kaynaklanan yakınsama ve kararlılık problemleri nedeniyle dikkatli tasarım gerektirmektedir.

3.6 Federated Learning ve Dağıtık Öğrenme

5G ağlarında verinin önemli bir kısmı uç cihazlar, baz istasyonları veya kenar düğümlerinde üretilmektedir. Bu verilerin merkezi bir noktaya taşınması; gizlilik, gecikme ve bant genişliği açısından sorunlara yol açabilmektedir. **Federated Learning (FL)**, veriyi merkezileştirmeden model

güncellemelerinin paylaşılmasını sağlayarak bu sorunları azaltmayı hedefler. FL, özellikle gizlilik hassasiyeti yüksek uygulamalar ve dağıtık RAN mimarileri için uygun bir öğrenme paradigması olarak öne çıkmaktadır. Ancak, heterojen veri dağılımları ve iletişim yükü FL tabanlı sistemlerin temel zorluklarıdır.

3.7 Transfer Learning ve Çevrim İçi Öğrenme

5G ağlarında trafik desenleri ve kullanıcı davranışları zamanla değişebilmektedir. Bu nedenle, yalnızca çevrim dışı (offline) eğitilmiş modellerin uzun vadede performans kaybı yaşaması kaçınılmazdır. **Transfer learning**, benzer ağ senaryolarından elde edilen bilgilerin yeni ortamlara aktarılmasını sağlarken; **çevrim içi öğrenme**, modelin akış verisi ile sürekli güncellenmesine olanak tanır. Bu yaklaşımlar, özellikle hızlı adaptasyon gerektiren dinamik 5G senaryolarında önemli avantajlar sunmaktadır.

3.8 5G İçin Uygun Paradigmanın Seçilmesi

Her makine öğrenmesi paradigması, 5G ağlarındaki farklı optimizasyon problemleri için farklı avantaj ve sınırlamalara sahiptir. Trafik ve kanal tahmini gibi kestirim problemleri için denetimli öğrenme uygunken, çevrim içi ve dinamik karar verme gerektiren senaryolarda pekiştirmeli öğrenme öne çıkmaktadır. Dağıtık mimarilerde ise federated ve çok ajanlı öğrenme yaklaşımları daha uygun çözümler sunmaktadır. Bu nedenle, 5G ağ optimizasyonunda tek bir öğrenme paradigması yerine, probleme özgü ve hibrit yaklaşımların tercih edilmesi gerekmektedir.

Tablo 2. 5G Ağ Optimizasyonunda Makine Öğrenmesi Paradigmalarının Karşılaştırılması

ML Paradigması	5G'de Tipik Uygulama Alanları	Başlıca Avantajlar	Temel Zorluklar / Sınırlamalar
Denetimli Öğrenme	Trafik yükü tahmini, throughput kestirimi, QoS/QoE sınıflandırması, handover başarısızlığı tahmini	Kararlı eğitim, yorumlanabilir sonuçlar, hızlı çıkarım	Etiketli veri gereksinimi, concept drift, saha verisi erişim zorluğu
Denetimsiz Öğrenme	Anomali tespiti, kullanıcı/hücre profillemesi, trafik kümelenmesi	Etiketsiz veriyle çalışabilme, ölçeklenebilirlik	Sonuçların yorumlanması zor, doğrudan karar üretmez
Öz-Denetimli Öğrenme	Temsil öğrenimi, RL için ön eğitim, veri verimliliğinin artırılması	Etiket ihtiyacını azaltır, genelleme yeteneği yüksek	Tasarım karmaşıklığı, ek hesaplama yükü
Pekiştirmeli Öğrenme (RL)	Dinamik kaynak tahsisi, güç kontrolü, handover optimizasyonu	Çevrim içi öğrenme, dinamik ortamlara uyum	Yakınsama süresi, ödül tasarımı hassasiyeti
Derin Pekiştirmeli Öğrenme (DRL)	Network slicing, URLLC gecikme optimizasyonu, çok boyutlu RRM	Yüksek boyutlu problemlerde etkinlik	Kararlılık sorunları, eğitim maliyeti, açıklanabilirlik
Çok Ajanlı Öğrenme (MARL)	Girişim koordinasyonu, hücreler arası yük dengeleme	Dağıtık karar verme, ölçeklenebilirlik	Ajanlar arası etkileşim, yakınsama problemleri
Federated Learning (FL)	Dağıtık RAN öğrenmesi, gizlilik odaklı optimizasyon	Veri gizliliği, iletişim yükü azalması	Heterojen veri, iletişim senkronizasyonu
Transfer Learning	Yeni hücre/senaryo adaptasyonu, hızlı model başlatma	Eğitim süresini azaltır, hızlı uyum	Negatif transfer riski
Çevrim İçi Öğrenme	Zamanla değişen trafik ve kullanıcı davranışı adaptasyonu	Concept drift'e dayanıklılık	Kararlılık ve güvenilirlik gereksinimleri
Hibrit Yaklaşımlar	Tahmin + karar verme (SL + RL), FL + DRL	Performans ve esneklik artışı	Sistem karmaşıklığı, tasarım zorluğu

Tablo 2’de, 5G ağ optimizasyonunda yaygın olarak kullanılan makine öğrenmesi paradigmaları; uygulama alanları, avantajları ve temel zorlukları ile birlikte özetlenmiştir. Görüldüğü üzere, her paradigma farklı optimizasyon problemleri için belirli avantajlar sunmakta; ancak tek başına tüm 5G gereksinimlerini karşılamakta yetersiz kalabilmektedir. Bu durum, 5G ve ötesi ağlarda hibrit ve problem odaklı öğrenme yaklaşımlarının önemini ortaya koymaktadır.

4. Makine Öğrenmesi Temelleri

Makine öğrenmesi (ML), veriden örüntü ve ilişkileri otomatik olarak öğrenerek tahmin ve karar verme yeteneği kazandıran yöntemler bütünü olarak tanımlanmaktadır. 5G ağları bağlamında ML; karmaşık, dinamik ve belirsizlik içeren ağ ortamlarında geleneksel kural tabanlı yaklaşımların yetersiz kaldığı durumlarda etkili çözümler sunmaktadır. Denetimli öğrenme yöntemleri trafik ve kanal durumu tahmini gibi kestirim problemlerinde öne çıkarken, denetimsiz öğrenme yaklaşımları

ağ izleme, anomali tespiti ve kullanıcı profillemesi gibi görevlerde kullanılmaktadır. Öte yandan, 5G ağ optimizasyonu çoğunlukla ardışık ve çevrim içi karar verme gerektirdiğinden, pekiştirmeli öğrenme ve derin pekiştirmeli öğrenme yöntemleri kaynak tahsisi, güç kontrolü ve network slicing gibi kritik problemlerde yaygın olarak tercih edilmektedir. Ayrıca, dağıtık mimari ve gizlilik gereksinimleri nedeniyle federated learning ve çok ajanlı öğrenme yaklaşımları da 5G ve ötesi ağlar için önemli araştırma alanları arasında yer almaktadır [16-19].

5.Sonuç ve Değerlendirme

Bu çalışmada, 5G ağlar için makine öğrenmesi destekli kaynak ve ağ optimizasyonu alanındaki mevcut literatür kapsamlı bir şekilde incelenmiştir. 5G ağlarının; yüksek veri hızı, düşük gecikme, yoğun bağlantı ve enerji verimliliği gibi eş zamanlı ve çoğu zaman çelişen gereksinimleri, geleneksel kural tabanlı ve analitik optimizasyon yöntemlerinin sınırlarını ortaya koymaktadır. Bu bağlamda, veri odaklı ve uyarlanabilir yapıları sayesinde makine öğrenmesi tabanlı yaklaşımlar, 5G ağ optimizasyonu için güçlü ve esnek çözümler sunmaktadır. Çalışma kapsamında, 5G ağ mimarisi içerisinde ortaya çıkan temel optimizasyon problemleri sistematik olarak sınıflandırılmış; bu problemlerin çözümünde kullanılan denetimli, denetimsiz, pekiştirmeli, derin pekiştirmeli, çok ajanlı ve federated learning gibi farklı makine öğrenmesi paradigmaları karşılaştırmalı olarak ele alınmıştır. Yapılan inceleme, belirli bir öğrenme paradigmasının tüm 5G optimizasyon problemleri için tek başına yeterli olmadığını; problem türü, zaman ölçeği, ağ mimarisi ve servis gereksinimlerine bağlı olarak farklı veya hibrit öğrenme yaklaşımlarının tercih edilmesi gerektiğini göstermektedir. Ayrıca, literatürdeki çalışmaların büyük bir kısmının simülasyon tabanlı olduğu, gerçek saha koşullarında uygulanabilirlik, ölçeklenebilirlik, açıklanabilirlik ve güvenilirlik gibi konuların hâlen açık araştırma problemleri arasında yer aldığı görülmektedir. Özellikle federated learning, çevrim içi öğrenme ve açıklanabilir yapay zekâ yaklaşımlarının, 5G ve ötesi ağlarda operasyonel kabul açısından kritik bir rol oynayacağı değerlendirilmektedir.

Sonuç olarak, makine öğrenmesi destekli optimizasyon yaklaşımları 5G ağlarının karmaşık gereksinimlerini karşılamada önemli avantajlar sunmakta olup, bu alandaki araştırmaların 6G vizyonu doğrultusunda daha bütüncül, güvenilir ve saha uyumlu çözümlere evrilmesi beklenmektedir. Bu derleme çalışmasının, hem akademik araştırmalar hem de endüstriyel uygulamalar için yol gösterici bir referans niteliği taşıması hedeflenmektedir. *Gerçek Zamanlı Öğrenme ve Saha Uygulanabilirliği* açısından mevcut çalışmaların büyük çoğunluğu simülasyon tabanlıdır ve gerçek 5G ağlarında karşılaşılan ölçüm hataları, gecikmeler ve eksik veri problemleri yeterince ele alınmamıştır. Gerçek zamanlı, çevrim içi öğrenme yeteneğine sahip ve saha koşullarına dayanıklı modellerin geliştirilmesi önemli bir açık problem olarak öne çıkmaktadır [20,21]. *Ölçeklenebilirlik ve Hesaplama Karmaşıklığı* açısından derin pekiştirmeli ve çok ajanlı öğrenme yöntemleri, büyük ölçekli ve ultra yoğun 5G ağlarında yüksek hesaplama ve bellek gereksinimleri doğurmaktadır. Bu durum, kenar bilişim (MEC) destekli, hiyerarşik ve hafif öğrenme mimarilerine olan ihtiyacı artırmaktadır[22,23]. *Ödül Fonksiyonu Tasarımı ve Çok Amaçlı Optimizasyon* için 5G optimizasyon problemleri genellikle gecikme, enerji verimliliği, güvenilirlik ve kullanıcı deneyimi gibi birbirleriyle çelişen hedefleri içermektedir. Bu hedeflerin tek bir ödül fonksiyonu altında dengelenmesi ve kararlı öğrenmenin sağlanması hâlen açık bir araştırma konusudur [14,15]. Eğitim sırasında kullanılan veri dağılımlarının zamanla değişmesi, ML tabanlı modellerin performansında ciddi düşüşlere yol açabilmektedir. Bu nedenle, transfer learning, çevrim içi öğrenme ve meta-öğrenme yaklaşımlarının 5G ağlarına uyarlanması önemli bir araştırma ihtiyacıdır [26,27]. *Gizlilik, Güvenlik ve Dayanıklılık* için federated learning gibi dağıtık öğrenme yaklaşımları veri gizliliği açısından avantaj sunsa da, model zehirlenme, güvenli model paylaşımı ve heterojen veri dağılımı gibi yeni tehditleri beraberinde getirmektedir. Güvenli ve dayanıklı ML tabanlı optimizasyon mekanizmalarının geliştirilmesi gerekmektedir[28,29]. Son zamanlarda yeni bir kavram olarak yapay zekanın bir türevi olan *Açıklanabilirlik (XAI)* ve *Operasyonel Kabul* alanlarında ML tabanlı optimizasyon çözümlerinin ağ

işletmecileri tarafından benimsenebilmesi için, kararların neden ve nasıl alındığının açıklanabilir olması kritik önemdedir. Açıklanabilir yapay zekâ yaklaşımlarının 5G ağ yönetimiyle entegrasyonu, henüz sınırlı sayıda çalışmada ele alınmıştır [30,31].

Yeni nesil kablosuz sistemlerden 6G haberleşme sistemleri ise, yalnızca veri hızı ve gecikme performansında artış sağlamayı değil; **AI-native, otonom, kendini yöneten ve algılama-haberleşme bütünleşik (ISAC)** ağ mimarilerine dayalı yeni bir paradigma oluşturmayı hedeflemektedir. Bu bağlamda, 5G ağlarında tanımlanan açık optimizasyon problemleri, 6G vizyonunun temel araştırma yönlerini doğrudan şekillendirmektedir.

6G ağlarda öngörülen **otonom ağ işletimi (self-driving networks)**, gerçek zamanlı ve çevrim içi öğrenme yeteneklerini zorunlu kılmaktadır. Ağların insan müdahalesine minimum düzeyde ihtiyaç duyarak dinamik çevresel koşullara uyum sağlayabilmesi, sürekli adaptasyon ve belirsizlik altında karar verebilen öğrenme modellerinin geliştirilmesini gerekli kılmaktadır. Ultra yoğun, hücresiz ve terahertz bantlı 6G mimarileri, **ölçeklenebilirlik** ve **hesaplama karmaşıklığını** kritik bir araştırma konusu hâline getirmektedir. Bu nedenle, dağıtık, hiyerarşik ve kenar-bulut iş birliğine dayalı öğrenme çerçevelerinin 6G ağlarında merkezi bir rol üstlenmesi beklenmektedir. Bununla birlikte, 6G optimizasyonu; iletişim performansının ötesinde **algılama, konumlama, enerji farkındalığı ve uçtan uca servis deneyimi** gibi çok boyutlu hedefleri kapsamaktadır. Bu durum, risk-duyarlı ve bağlam-farkındalıklı çok amaçlı öğrenme yaklaşımlarına olan ihtiyacı artırmaktadır. Sonuç olarak, **gizlilik, güvenlik ve açıklanabilirlik**, 6G ağlarında makine öğrenmesi tabanlı çözümlerin operasyonel kabulü için belirleyici unsurlar olacaktır. Federated learning ve açıklanabilir yapay zekâ yaklaşımlarının, güvenilir ve sürdürülebilir 6G ağlarının temel bileşenleri hâline gelmesi beklenmektedir.

Kaynakça

- [1] C. Zhang, P. Patras, and H. Haddadi, “Deep Learning in Mobile and Wireless Networking: A Survey,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 3, pp. 2224–2287, 3rd Quart., 2019.
- [2] Y. Sun, M. Peng, Y. Zhou, Y. Huang, and S. Mao, “Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3072–3108, 4th Quart., 2019.
- [3] N. C. Luong, D. T. Hoang, S. Gong, D. Niyato, P. Wang, Y.-C. Liang, and D. I. Kim, “Applications of Deep Reinforcement Learning in Communications and Networking: A Survey,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3133–3174, 4th Quart., 2019.
- [4] M. Bennis, M. Debbah, and H. V. Poor, “Ultra-Reliable and Low-Latency Wireless Communication: Tail, Risk, and Scale,” *Proceedings of the IEEE*, vol. 106, no. 10, pp. 1834–1853, Oct. 2018.
- [5] M. Chen, Y. Hao, K. Hwang, L. Wang, and L. Wang, “Artificial Intelligence for Mobile Edge Computing: Survey and Research Outlook,” *IEEE Communications Surveys & Tutorials*, vol. 19, no. 4, pp. 2354–2391, 4th Quart., 2017.
- [6] S. Niknam, H. S. Dhillon, and J. H. Reed, “Federated Learning for Wireless Communications: Motivation, Opportunities, and Challenges,” *IEEE Communications Magazine*, vol. 58, no. 1, pp. 46–51, Jan. 2020.
- [7] Q. Yang, Y. Liu, T. Chen, and Y. Tong, “Federated Machine Learning: Concept and Applications,” *ACM Transactions on Intelligent Systems and Technology*, vol. 10, no. 2, pp. 1–19, Jan. 2019.
- [8] A. Adadi and M. Berrada, “Peeking Inside the Black Box: A Survey on Explainable Artificial Intelligence (XAI),” *IEEE Access*, vol. 6, pp. 52138–52160, 2018.
- [9] R. Schwalbe and B. Schelter, “A Survey on Explainable Artificial Intelligence in Machine Learning,” *IEEE Access*, vol. 8, pp. 22411–22422, 2020.
- [10] J. Park, S. Samarakoon, M. Bennis, and M. Latva-aho, “Learning to Optimize: Training Deep Neural Networks for Wireless Resource Management,” *IEEE Transactions on Signal Processing*, vol. 67, no. 15, pp. 3868–3883, Aug. 2019.
- [11] Olwal, Thomas & Djouani, Karim & Kurien, Anish. (2016). A Survey of Resource Management Toward 5G Radio Access Networks. *IEEE Communications Surveys & Tutorials*. 18. 1-1. 10.1109/COMST.2016.2550765.
- [12] B. Agarwal, M. A. Togou, M. Marco and G. -M. Muntean, "A Comprehensive Survey on Radio Resource Management in 5G HetNets: Current Solutions, Future Trends and Open Issues," in *IEEE Communications Surveys & Tutorials*, vol. 24, no. 4, pp. 2495-2534, Fourthquarter 2022

- [13] M. A. Habibi, M. Nasimi, B. Han, and H. D. Schotten, "A comprehensive survey of RAN architectures toward 5G mobile communication system," *IEEE Access*, vol. 7, pp. 70371–70421, 2019.
- [14] *Cisco Annual Internet Report (2018–2023) White Paper*, Cisco, San Jose, CA, USA, 2020.
- [15] M. Feng, S. Mao, and T. Jiang, "Joint frame design, resource allocation and user association for massive MIMO heterogeneous networks with wireless backhaul," *IEEE Trans. Wireless Commun.*, vol. 17, no. 3, pp. 1937–1950, Mar. 2018.
- [16] C. Zhang, P. Patras, and H. Haddadi, "Deep Learning in Mobile and Wireless Networking: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 21, no. 3, pp. 2224–2287, 2019.
- [17] Y. Sun, M. Peng, Y. Zhou, Y. Huang, and S. Mao, "Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues," *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3072–3108, 2019.
- [18] M. Bennis, M. Debbah, and H. V. Poor, "Ultra-Reliable and Low-Latency Wireless Communication: Tail, Risk, and Scale," *Proceedings of the IEEE*, vol. 106, no. 10, pp. 1834–1853, 2018.
- [19] N. C. Luong *et al.*, "Applications of Deep Reinforcement Learning in Communications and Networking: A Survey,"
- [20] Y. Sun *et al.*, "Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues," *IEEE Communications Surveys & Tutorials*, 2019.
- [21] C. Zhang *et al.*, "Deep Learning in Mobile and Wireless Networking: A Survey," *IEEE Communications Surveys & Tutorials*, 2019.
- [22] N. C. Luong *et al.*, "Applications of Deep Reinforcement Learning in Communications and Networking: A Survey," *IEEE Communications Surveys & Tutorials*, 2019.
- [23] M. Chen *et al.*, "Artificial Intelligence for Mobile Edge Computing: Survey and Research Outlook," *IEEE Communications Surveys & Tutorials*, 2018.
- [24] M. Bennis, M. Debbah, and H. V. Poor, "Ultra-Reliable and Low-Latency Wireless Communication: Tail, Risk, and Scale," *Proceedings of the IEEE*, 2018.
- [25] H. Ye, G. Y. Li, and B.-H. Juang, "Deep Reinforcement Learning Based Resource Allocation for V2V Communications," *IEEE Transactions on Vehicular Technology*, 2019.
- [26] J. Park *et al.*, "Learning to Optimize: Training Deep Neural Networks for Wireless Resource Management," *IEEE Transactions on Signal Processing*, 2019.
- [27] A. Klautau *et al.*, "5G MIMO Data for Machine Learning: Application to Beam Selection Using Deep Learning," *IEEE Transactions on Wireless Communications*, 2018.
- [28] Q. Yang *et al.*, "Federated Machine Learning: Concept and Applications," *ACM/IEEE*, 2019.

- [29]S. Niknam *et al.*, “Federated Learning for Wireless Communications: Motivation, Opportunities, and Challenges,” *IEEE Communications Magazine*, 2020.
- [30]A. Adadi and M. Berrada, “Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI),” *IEEE Access*, 2018.
- [31]R. Schwalbe and B. Schelter, “A Survey on Explainable Artificial Intelligence in Machine Learning,” *IEEE Access*, 2020.