

GEÇİCİ KAPAK

*Kapak tasarımı
devam ediyor.*

BİDGE Yayınları

Yapay Zekâ Tabanlı Sistemler: Teori, Uygulama ve Gelecek Perspektifleri-1

Editör: EYYÜP GÜLBANDILAR

ISBN: 978-625-8567-64-9

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2025-12-25

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /
Ankara



ÖNSÖZ

Yapay zekâ (YZ) ve derin öğrenme paradigmaları, günümüzde teknik birer araç olmanın ötesine geçerek; sağlık bilimlerinden telekomünikasyona, enerji yönetiminden stratejik güvenlik sistemlerine kadar uzanan geniş bir spektrumda yapısal bir dönüşümün ana aktörleri haline gelmiştir. Hesaplama kapasitesindeki eksponansiyel artış ve veri madenciliğindeki metodolojik devrim, geleneksel analitik yaklaşımların yetersiz kaldığı lineer olmayan ve yüksek boyutlu problemlerin çözümünde YZ tabanlı modelleri vazgeçilmez kılmıştır.

Elinizdeki bu çalışma, yapay zekânın teorik müktesebatını ve uygulama sahasındaki güncel izdüşümlerini disiplinler arası bir sentez ile sunmayı gaye edinmektedir. Eserde; tıbbi görüntüleme üzerinden gerçekleştirilen onkolojik teşhis modellemelerinden biyometrik tabanlı demografik analizlere, yazılım güvenliği mimarilerinden karmaşık zaman serisi kestirimlerine kadar uzanan çeşitlilik, YZ'nin operasyonel esnekliğini somut verilerle tevsik etmektedir.

Kitabın ayırt edici niteliklerinden biri de sentetik veri üretimi, IoT entegreli kestirimci bakım stratejileri ve 6G ağ ekosistemlerinde konumlandırılan dağıtık yapay zekâ mimarileri gibi teknolojik öngörü gerektiren başlıkları derinlemesine işlemesidir. Kablosuz ağlarda deneyim kalitesi (QoE) gibi kritik parametrelerin incelenmesi, okuyucuya yalnızca mevcut teknolojileri değil, aynı zamanda yarının araştırma gündemini de ihtiva eden vizyoner bir perspektif sunmaktadır.

Akademik bir titizlikle hazırlanan bu eser; lisansüstü araştırmacılardan sektör paydaşlarına, sistem tasarımcısı mühendislerden kuramsal çalışma yürüten bilim insanlarına kadar geniş bir kitleye hitap eden bir başvuru kaynağıdır. Eserin, yapay zekânın çok katmanlı doğasının anlaşılmasına hizmet etmesini, farklı disiplinler arasında yeni korelasyonlar kurulmasına zemin hazırlamasını ve bilim dünyasına özgün katkılar sunmasını temenni ederiz.

Dr.Eyyüp GÜLBANDILAR

Editör

İÇİNDEKİLER

DERİN ÖĞRENME VE MOBILENETV2 MİMARİSİ KULLANILARAK YÜZ GÖRÜNTÜLERİNDEN YAŞ GRUBU SINIFLANDIRMASI	1
--	---

KIYAS KAYAALP, İLKAY ONAY

YÜZ GÖRÜNTÜLERİ ÜZERİNDEN TEMEL BİLEŞEN ANALİZİ	18
--	----

KENAN DONUK

ÇOKLU MODÜLER YAPILI DİYALOGLARDA YAPAY SİNİR AĞLARI İLE DUYGU ANALİZİ: MELD VE IEMOCAP ÜZERİNE BİR DEĞERLENDİRME	34
---	----

RABİA ŞEVVAL AYDIN, SUDE NUR TUNGAÇ, AYSE BERNA ALTINEL

LSTM VE XGBOOST MODELLERİ İLE HATAY İLİ SICAKLIK VERİLERİNİN ZAMAN SERİSİ TABANLI TAHMİNİ VE MODEL PERFORMANSLARININ KARŞILAŞTIRILMASI	49
---	----

MEHMET ERGÜN AZİZOĞLU, ERDEM ÇOBAN

IOT VE BULUT BİLİŞİM TABANLI KESİTİRİMCİ BAKIM ..	67
---	----

EMİN ÖZTÜRK, AZİZ KUBİLAY OVACIKLI

6G AĞLARINDA PERFORMANS-GÜVENLİK ETKİLEŞİMİ: OPERASYONEL METRİKLERİN GÜVENLİK DOĞRULUĞUNA ETKİSİ	77
--	----

MERT YAĞCIOĞLU

İNSAN KAYNAKLARININ VERİMLİ KULLANIMI İÇİN DOĞRU MESLEK SEÇİMİNE ETKİ EDEN FAKTÖRLERİN ANALİZİ VE ADAYLARLA MESLEK PROFİLLERİ ARASINDAKİ EŞLEŞMELERİN MODELLENMESİ	99
---	----

HİDAYET TAKCI, SERAP BEĞDAŞ

DERİN ÖĞRENMENİN KALP HASTALIKLARI ALANINDA KULLANIMI	121
--	-----

ÖZGÜR TOMAK

BİLİŞİM SİSTEMLERİNDE DERİN ÖĞRENME TABANLI ÖNERİ VE KESTİRİM SİSTEMLERİ: DURUM DEĞERLENDİRMESİ VE GELECEK EĞİLİMLER	141
--	-----

BURCU ÇARKLI YAVUZ

SNACKCHECK: ÜRÜN İÇERİĞİ FİLTRELEME VE YORUMLAMA UYGULAMASI	188
<i>AHSEN GÜNEŞ, AHMET HAKAN GÜNEŞ, KAMİL ORMAN</i>	
6G AĞLARINDA GÖMÜLÜ ZEKA VE DAĞITIK YAPAY ZEKA MİMARİLERİ: LİTERATÜR TARAMASI	201
<i>SEMİH KAHVECİ, RAMAZAN AKKURT</i>	
AÇIKLANABİLİR YAPAY ZEKÂ (XAI) İÇİN MODERN YAKLAŞIMLAR	221
<i>AYŞE GÜL EKER</i>	
SENTETİK TABULAR VERİ ÜRETİMİNDE YENİ NESİL YAKLAŞIMLAR	241
<i>İRFAN KÖSESOY, EREN PARTAL</i>	
VALF NOKTASI YÜKLEME ETKİSİ ALTINDA EKONOMİK YÜK DAĞITIM PROBLEMİNİN GRİ KURT OPTİMİZASYON ALGORİTMASI İLE ÇÖZÜMÜ	261
<i>EMİNE DENİZ ÖZ</i>	

BÖLÜM 1

DERİN ÖĞRENME VE MOBILENETV2 MİMARİSİ KULLANILARAK YÜZ GÖRÜNTÜLERİNDEN YAŞ GRUBU SINIFLANDIRMASI

Kıyas KAYAALP¹

İlkay ONAY²

1. Giriş

Son on yılda yapay zeka ve bilgisayarlı görüş (computer vision) teknolojilerinde yaşanan devrim niteliğindeki gelişmeler, insan yüzü analizine dayalı biyometrik sistemlerin güvenlikten perakendeye, sağlıktan eğlence sektörüne kadar geniş bir yelpazede günlük hayatın bir parçası haline gelmesini sağlamıştır. Yüz tanıma, duygu analizi ve cinsiyet tespiti gibi klasik problemlerin yanı sıra, "Yüzden Yaş Tahmini" (Age Estimation), hem akademik araştırmalarda hem de endüstriyel uygulamalarda giderek artan bir ilgi odağı olmuştur. Bir bireyin yüz görüntüsünden kronolojik veya

¹ Doç.Dr., Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü, Orcid: 0000-0002-6483-1124

² Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü Orcid: 0009-0008-4106-0540

görünen yaşı belirlmeyi amaçlayan bu problem, kimlik tespitinden bağımsız olarak birey hakkında bilgi sağlayan "yumuşak biyometri" (soft biometrics) alanının en zorlu ve karmaşık problemlerinden biri olarak kabul edilmektedir (Eidinger vd., 2014; Rothe vd., 2018).

Yaş tahmin sistemlerinin kullanım potansiyeli oldukça geniştir ve modern toplumun ihtiyaçlarına yönelik pratik çözümler sunmaktadır. Örneğin perakende sektöründe, akıllı vitrinler ve dijital tabelalar aracılığıyla müşterilerin yaş grubuna (çocuk, genç, yetişkin) göre özelleştirilmiş reklam içerikleri sunulabilmektedir. Benzer şekilde, tütün ve alkol gibi yaş kısıtlamalı ürünlerin satışını yapan otomatlarda veya web sitelerinde otomatik yaş doğrulama sistemleri, yasal uyumluluğu sağlamak adına kritik bir rol oynamaktadır. Ayrıca, İnsan-Bilgisayar Etkileşimi (HCI) kapsamında, sosyal robotların karşısındaki kişinin yaşına uygun bir diyalog ve hitap şekli geliştirmesi, kullanıcı deneyimini artıran önemli bir faktördür (Zhang vd., 2017).

Ancak, insan yüzünden hassas ve doğru bir yaş tahmini yapmak, bilgisayarlı gözü disiplini açısından birçok zorluğu bünyesinde barındırır. Yaşlanma; her bireyde farklı hızda ve biçimde ilerleyen, genetik faktörler, sağlık durumu, beslenme alışkanlıkları ve yaşam tarzı gibi içsel etkenlerden etkilenen stokastik (rastgele) ve geri döndürülemez bir biyolojik süreçtir. Biyolojik yaşlanmanın yanı sıra, dışsal faktörler olarak adlandırılan ortam ışıklandırması, kamera açısı, yüz ifadeleri, makyaj kullanımı ve görüntü çözünürlüğü gibi değişkenler, algoritmaların performansını doğrudan ve olumsuz yönde etkileyebilmektedir. Özellikle "görünen yaş" (apparent age) ile "biyolojik yaş" (chronological age) arasındaki fark, modellerin eğitiminde tutarsızlıklara yol açabilmektedir (Rothe vd., 2018).

Literatürdeki ilk çalışmalar, genellikle yüzdeki kırışıklık yoğunluğu, göz-burun-çene arasındaki geometrik oranlar ve cilt

dokusu analizi gibi "el yapımı" (hand-crafted) özniteliklerin çıkarılmasına dayanmaktaydı. Bu yöntemler kontrollü stüdyo ortamlarında belirli bir başarı sağlasa da, ışık ve poz değişimlerinin yoğun olduğu gerçek dünya koşullarında (in-the-wild) yetersiz kalmıştır. Günümüzde ise Derin Öğrenme (Deep Learning) ve özellikle Evrişimli Sinir Ağları (CNN), görüntüden öznitelik çıkarma işlemini insan müdahalesine gerek kalmadan otomatize ederek bu alanda standart yaklaşım haline gelmiştir (Levi & Hassner, 2015). Levi ve Hassner'in (2015) öncü çalışmalarıyla başlayan bu süreç, daha derin ve karmaşık mimarilerin geliştirilmesiyle hız kazanmıştır.

Takip eden yıllarda geliştirilen VGG-Face (Simonyan & Zisserman, 2015) ve ResNet (Residual Networks) (He vd., 2016) gibi derin mimariler, yaş tahmininde insan başarımına yakın hatta onu geçen doğruluk oranlarına ulaşmıştır. Ancak bu modellerin temel dezavantajı, milyonlarca parametreye sahip olmaları ve yüksek işlem gücü (GPU) gerektirmeleridir. Bu durum, söz konusu modellerin akıllı telefonlar, IoT cihazları veya gömülü sistemler gibi sınırlı donanım kaynağına sahip platformlarda gerçek zamanlı olarak çalışmasını zorlaştırmaktadır. Endüstriyel talepler ise sadece yüksek doğruluk değil, aynı zamanda düşük gecikme süresi (latency) ve enerji verimliliği gerektirmektedir.

Bu çalışmada, söz konusu donanım kısıtlarını aşmak ve yaş tahmini problemini mobil cihazlarda çalışabilecek verimlilikte çözmek amacıyla MobileNetV2 mimarisi kullanılmıştır (Sandler vd., 2018). MobileNetV2, standart konvolüsyon işlemleri yerine, hesaplama maliyetini ciddi oranda düşüren "Derinlemesine Ayrılabilir Konvolüsyon" (Depthwise Separable Convolution) tekniğini ve "Tersine Çevrilmiş Artık Bloklar" (Inverted Residual Blocks) yapısını kullanmaktadır. Bu tekniklerin temeli, Xception mimarisinde ortaya konulan prensiplere dayanmaktadır (Chollet, 2017). Çalışmanın temel motivasyonu, kaynak kısıtlı cihazlar için

hafif (lightweight) bir model geliştirirken, UTKFace veri setindeki dengesiz sınıf dağılımının (class imbalance) model başarısı üzerindeki etkilerini analiz etmektir. Modelin eğitiminde, büyük veri setlerinden öğrenilen bilgiyi aktararak eğitim süresini kısaltan ve veri ihtiyacını azaltan Transfer Öğrenme (Transfer Learning) yöntemi benimsenmiştir (Pan & Yang, 2010). Ayrıca, modelin ezberlemesini önlemek ve farklı varyasyonlara karşı dayanıklılığını artırmak için kapsamlı Veri Zenginleştirme (Data Augmentation) stratejileri uygulanmıştır (Shorten & Khoshgoftaar, 2019).

Bu çalışma, hafif mimarilerin yaş tahmini problemindeki etkinliğini göstermesi ve özellikle sınıf dengesizliğinin olduğu durumlarda modelin davranışlarını (örneğin orta yaş grubundaki belirsizlikler) detaylı bir şekilde analiz etmesi bakımından literatüre katkı sağlamayı hedeflemektedir.

2. MATERYAL VE METOT

Bu bölümde, çalışmanın deneysel altyapısını oluşturan veri seti, veri ön işleme adımları, tercih edilen derin öğrenme mimarisi ve eğitim stratejileri detaylandırılmıştır. Önerilen yöntem, donanım kaynaklarını verimli kullanan ve dengesiz veri dağılımını yönetebilen sağlam (robust) bir yapı üzerine kurgulanmıştır.

2.1. Veri Seti (Dataset)

Çalışmada, yaş tahmini ve yüz analizi literatüründe yaygın olarak kabul gören ve geniş çaplı bir veritabanı olan UTKFace veri seti kullanılmıştır (Zhang vd., 2017). Bu veri seti, 0 ile 116 yaş aralığında, farklı ırk, cinsiyet ve etnik kökenlerden bireylere ait yaklaşık 23.000 adet hizalanmış ve kırpılmış yüz görüntüsünü içermektedir. Veri setindeki görüntüler kontrollü stüdyo ortamı yerine, günlük hayattan (in-the-wild) elde edildiği için ışıklandırma, poz, mimik, oklüzyon (kısmi kapanma) ve çözünürlük açısından yüksek varyasyona sahiptir. Bu çeşitlilik, modelin laboratuvar

ortamı dışındaki gerçek dünya senaryolarında da genelleme yapabilmesi açısından kritik öneme sahiptir.

Bu çalışmada, yaş tahmini problemi bir regresyon (kesin sayı tahmini) problemi yerine, biyolojik ve sosyolojik gelişim evreleri dikkate alınarak bir sınıflandırma problemi olarak kurgulanmıştır. Veri seti aşağıdaki 5 temel kategoriye ayrılmıştır:

- Sınıf 1 (0-12 Yaş): Çocukluk dönemi (Hızlı kemik gelişimi).
- Sınıf 2 (13-25 Yaş): Genç/Ergenlik dönemi (Cinsel dimorfizm ve olgunlaşma).
- Sınıf 3 (26-45 Yaş): Yetişkinlik dönemi (Yüz hatlarının oturması).
- Sınıf 4 (46-60 Yaş): Orta Yaş dönemi (Deri elastikiyetinin azalması, ilk yaşlanma belirtileri).
- Sınıf 5 (60+ Yaş): Yaşlılık dönemi (Belirgin kırışıklıklar ve doku kaybı).

Veri seti; modelin öğrenme performansını artırmak ve aşırı öğrenme (overfitting) riskini minimize etmek amacıyla %70 Eğitim, %15 Doğrulama (Validation) ve %15 Test kümesi olarak parçalanmıştır. Ayırma işlemi sırasında, her bir kümedeki sınıf dağılımının orijinal veri setiyle orantılı olmasını sağlayan Katmanlı Örnekleme (Stratified Sampling) yöntemi kullanılarak istatistiksel tutarlılık güvence altına alınmıştır.

2.2. Veri Ön İşleme ve Zenginleştirme (Preprocessing & Augmentation)

Derin öğrenme modellerinin verimli çalışabilmesi için ham görüntüler üzerinde bir dizi ön işleme adımı uygulanmıştır. İlk olarak, tüm görüntüler MobileNetV2 mimarisinin giriş tensör gereksinimlerine uygun olarak 160x160 piksel çözünürlüğüne

yeniden boyutlandırılmıştır (bicubic interpolation). Ardından, piksel yoğunluk değerleri $[0, 255]$ aralığından $[0, 1]$ aralığına normalize edilerek modelin yakınsama (convergence) hızı artırılmıştır.

Eğitim veri kümesi üzerinde, modelin ezberlemesini önlemek ve varyasyonlara karşı dayanıklılığını artırmak amacıyla kapsamlı Veri Zenginleştirme (Data Augmentation) teknikleri uygulanmıştır. Literatürde belirtildiği üzere, veri zenginleştirme, veri setinin yapay olarak büyütülmesini sağlayarak modelin hiç görmediği verilere karşı başarısını artırmaktadır (Shorten & Khoshgoftaar, 2019). Eğitim sürecinde her döngüde (epoch) görüntüler üzerinde rastgele olmak üzere şu işlemler uygulanmıştır:

- Döndürme (Rotation): ± 15 derece (Kamera eğimini simüle etmek için).
- Kaydırma (Shift): %10 oranında yatay ve dikey kaydırma (Yüzün her zaman merkeze odaklanmadığı durumlar için).
- Yatay Çevirme (Horizontal Flip): Görüntünün ayna görüntüsünün alınması.

Doğrulama ve test aşamalarında ise sonuçların tutarlılığı ve tekrarlanabilirliği açısından herhangi bir zenginleştirme işlemi uygulanmamış, sadece normalizasyon yapılmıştır.

2.3. Model Mimarisi (MobileNetV2)

Çalışmada, yüksek hesaplama maliyeti gerektiren VGG (Simonyan & Zisserman, 2015) veya ResNet (He vd., 2016) gibi derin mimariler yerine, mobil cihazlar ve gömülü sistemler için özel olarak optimize edilmiş MobileNetV2 mimarisi tercih edilmiştir (Sandler vd., 2018). MobileNetV2, standart konvolüsyon işlemleri yerine, "Derinlemesine Ayrılabilir Konvolüsyon" (Depthwise Separable Convolution) yapısını kullanarak parametre sayısını ve işlem yükünü (FLOPs) ciddi oranda düşürmektedir. Bu yapının

teorik temelleri Xception mimarisine dayanmaktadır (Chollet, 2017). Ayrıca, modelde kullanılan "Tersine Çevrilmiş Artık Bloklar" (Inverted Residual Blocks), bilginin darboğaz (bottleneck) katmanları arasında kayıpsız aktarılmasını sağlar.

Model tasarımında Transfer Öğrenme (Transfer Learning) yaklaşımı benimsenmiştir (Pan & Yang, 2010). Sıfırdan eğitim (training from scratch) yerine, milyonlarca görüntü içeren ImageNet veri seti (Deng vd., 2009; Russakovsky vd., 2015) üzerinde önceden eğitilmiş ağırlıklar kullanılarak model başlatılmıştır. Bu sayede model, kenar, köşe, doku gibi temel görsel öznitelikleri hazır olarak almış ve sadece yaşa özgü üst düzey öznitelikleri öğrenmeye odaklanmıştır.

MobileNetV2'nin orijinal sınıflandırma katmanı çıkarılmış ve probleme özgü olarak aşağıdaki katmanlar eklenmiştir:

1. Global Average Pooling 2D: Özellik haritalarını tek boyutlu vektöre indirgemek için.
2. Batch Normalization: Katmanlar arası veri dağılımını dengeleyerek eğitimi stabilize etmek için.
3. Dropout (0.5): Ağdaki nöronların %50'si rastgele devre dışı bırakılarak modelin eğitim verisine aşırı uyum sağlaması (overfitting) engellenmiştir.
4. Dense (Output Layer): 5 adet nöron ve Softmax aktivasyon fonksiyonu içeren bu katman, her bir yaş sınıfı için olasılık değeri üretmektedir.

2.4. Eğitim Stratejisi ve Deneysel Kurulum

Modelin eğitimi, Python programlama dili ve TensorFlow/Keras kütüphaneleri kullanılarak NVIDIA GeForce RTX 3070 GPU donanımı üzerinde gerçekleştirilmiştir. Eğitim performansını ve hızını artırmak amacıyla Karma Hassasiyet (Mixed Precision - float16) tekniğinden faydalanılmıştır.

Veri setindeki sınıf dengesizliği (özellikle orta yaş ve 60+ gruplarındaki veri azlığı) problemini yönetmek için Sınıf Ağırlıklandırma (Class Weighting) yöntemi uygulanmıştır. Bu yöntemde, az sayıda örneğe sahip sınıfların eğitim sırasındaki hata katsayıları (loss penalty) artırılarak, modelin çoğunluk sınıfına (Yetişkin) yanlı davranması engellenmiştir.

Eğitim sürecinde optimizasyon algoritması olarak, stokastik gradyan iniş yönteminin daha gelişmiş bir versiyonu olan ve adaptif öğrenme hızına sahip Adam (Adaptive Moment Estimation) algoritması tercih edilmiştir (Kingma & Ba, 2015). Hiperparametreler şu şekilde belirlenmiştir:

- Öğrenme Oranı (Learning Rate): 0.0005
- Batch Boyutu: 64
- Epoch Sayısı: 25

Ayrıca, eğitimin verimliliğini artırmak için Early Stopping (Doğrulama kaybı 5 tur boyunca iyileşmezse eğitimi durdur) ve ReduceLROnPlateau (Doğrulama kaybı durağanlaştığında öğrenme oranını düşür) geri çağırma (callback) fonksiyonları kullanılarak en iyi model ağırlıkları kayıt altına alınmıştır.


3. DENEYSEL BULGULAR

Bu bölümde, önerilen MobileNetV2 tabanlı derin öğrenme modelinin eğitim süreci ve test kümesi üzerindeki performans analizleri sunulmuştur. Deneyler, NVIDIA GeForce RTX 3070 GPU donanımı üzerinde gerçekleştirilmiş olup, modelin performansı; Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1-Skoru ve Karmaşıklık Matrisi (Confusion Matrix) metrikleri kullanılarak değerlendirilmiştir.

3.1. Model Mimarisi (MobileNetV2)

Model, 25 epoch (döngü) boyunca eğitilmiş olup, aşırı öğrenmeyi (overfitting) engellemek amacıyla "Early Stopping" mekanizması aktif edilmiştir. Eğitim ve doğrulama (validation) kümeleri üzerindeki başarımlar ve kayıp (loss) değişimleri Şekil 1'de gösterilmiştir.

Şekil 1. Modelin eğitim ve doğrulama süreçlerine ait doğruluk ve kayıp grafikleri.



Şekil 1 incelendiğinde, eğitimin ilk döngülerinde modelin hızlı bir öğrenme eğilimi gösterdiği ve kaybın (loss) hızla düştüğü görülmektedir. Eğitim doğruluğu (Training Accuracy) ile doğrulama doğruluğu (Validation Accuracy) arasındaki makasın açılmaması, modelin ezberleme yapmak yerine genelleştirme yeteneği kazandığını göstermektedir. Sınıf ağırlıklandırma (Class Weighting) tekniğinin uygulanması sayesinde, veri setindeki dengesizlik eğitim stabilitesini bozmamış ve kaybın düzenli bir şekilde minimize edilmesini sağlamıştır.

3.2. Sınıflandırma Performansı

Eğitilen modelin genelleme başarısını ölçmek amacıyla, eğitim sürecinde modele hiç gösterilmemiş olan %15'lik Test veri kümesi kullanılmıştır. Model, 5 sınıflı sınıflandırma probleminde %51 Genel Doğruluk (Overall Accuracy) oranına ulaşmıştır. Her bir

yaş grubu için elde edilen detaylı performans metrikleri Çizelge 1’de sunulmuştur.

Tablo 1. Yaş sınıflarına göre modelin performans metrikleri.

Yaş Grubu	Precision (Kesinlik)	Recall (Duyarlılık)	F1-Score	Destek (Veri Sayısı)
0-12 (Çocuk)	0.50	0.89	0.64	512
13-25 (Genç)	0.35	0.56	0.43	634
26-45 (Yetişkin)	0.61	0.52	0.56	1569
46-60 (Orta Yaş)	0.51	0.07	0.13	483
60+ (Yaşlı)	0.70	0.44	0.54	359
Ortalama	0.53	0.50	0.51	3557

Tablo 1’deki sonuçlar biyolojik ve morfolojik açıdan analiz edildiğinde şu bulgulara ulaşılmıştır:


1. Çocuk Grubu Başarısı: En yüksek duyarlılık (Recall) oranı 0.89 ile "0-12 Yaş" grubunda elde edilmiştir. Bunun temel nedeni, çocukluk dönemindeki kraniyofasiyal (kafa ve yüz) kemik yapısının ve cilt dokusunun yetişkinlerden belirgin şekilde farklı olmasıdır. Model, çocukları tespit etmekte oldukça başarılıdır; ancak 0.50 seviyesindeki kesinlik değeri, bazı "bebek yüzlü" (baby-face) yetişkinlerin veya gençlerin de model tarafından sehven çocuk sınıfına atandığını göstermektedir.
2. Yetişkin Grubu Dominasyonu: Veri setindeki en kalabalık sınıf olan "26-45 Yaş" grubu, 0.56 F1-Skoru ile dengeli bir performans sergilemiştir. Modelin genel başarısı büyük ölçüde bu sınıfın doğru tahmin edilmesine dayanmaktadır.
3. Orta Yaş Problemi: Çalışmanın en dikkat çekici bulgusu, "46-60 Yaş" grubundaki 0.07 gibi düşük duyarlılık oranıdır. Bu durum, "Orta Yaş" kavramının görsel sınırlarının belirsizliğinden kaynaklanmaktadır. 45 yaşındaki bir birey ile 55 yaşındaki bir birey arasındaki

görsel fark, biyolojik yaşlanma hızına bağlı olarak çok az olabilmektedir. Model, bu aralıktaki yüzleri ayırt etmekte zorlanmış ve bu örnekleri diğer sınıflara atama eğilimi göstermiştir.

3.3. Hata Analizi ve Karmaşıklık Matrisi

Modelin hangi sınıfları birbiriyle karıştırdığını ve hataların dağılımını görselleştirmek için Karmaşıklık Matrisi (Confusion Matrix) oluşturulmuştur (Şekil 2).

Şekil 2. Test verisi üzerindeki Karmaşıklık Matrisi (Confusion Matrix).



Matris incelendiğinde hataların rastgele olmadığı, belirli bir örüntü izlediği görülmektedir:

- Komşu Sınıf Yanılgısı: Hataların büyük çoğunluğu, gerçek yaş grubunun bir alt veya bir üst sınıfına

yapılmıştır. Örneğin, "13-25 Genç" sınıfındaki örneklerin önemli bir kısmı "0-12 Çocuk" veya "26-45 Yetişkin" olarak tahmin edilmiştir. Bu durum, yaşlanmanın sürekli (continuous) bir süreç olması ve keskin sınırlarla ayırlamaması nedeniyle beklenen bir durumdur.

- Orta Yaşın Yutulması: "46-60 Orta Yaş" grubuna ait örneklerin (Recall: 0.07) çok büyük bir kısmının model tarafından "26-45 Yetişkin" sınıfı olarak tahmin edildiği matraste açıkça görülmektedir. Sınıf ağırlıklandırma uygulanmasına rağmen, görsel benzerliklerin yüksek olması ve yetişkin sınıfının veri setindeki baskınlığı bu sonuca yol açmıştır.


3.4. ROC Analizi

Modelin sınıfları birbirinden ayırt etme yeteneğini (discriminative ability) ölçmek için ROC (Receiver Operating Characteristic) eğrileri çizdirilmiştir.

Şekil 3'te görüldüğü üzere, "0-12 Çocuk" ve "60+ Yaşlı" sınıflarının ROC eğrileri sol üst köşeye daha yakındır, bu da modelin en genç ve en yaşlı bireyleri ayırt etmede daha başarılı olduğunu (Yüksek AUC değeri) kanıtlamaktadır. Buna karşın, birbirine geçişin yoğun olduğu orta yaş gruplarında eğriler diyagonale yaklaşmakta, yani modelin ayırt ediciliği düşmektedir.

Sonuç olarak, elde edilen bulgular, yüz görüntülerinden yaş tahmininin özellikle yetişkinlik-yaşlılık geçiş evrelerinde (46-60 yaş) zorlu bir problem olduğunu, ancak çocukluk ve belirgin yaşlılık dönemlerinde önerilen modelin yüksek başarı sağladığını ortaya koymuştur.

Şekil 3. Her bir sınıf için ROC eğrileri ve AUC değerleri.



4. SONUÇ

Bu çalışmada, insan yüzü görüntülerinden yaş tahmini problemini çözmek amacıyla, derin öğrenme tabanlı ve hesaplama maliyeti optimize edilmiş bir yaklaşım sunulmuştur. UTKFace veri seti üzerinde gerçekleştirilen deneylerde, Transfer Öğrenme yöntemiyle eğitilen MobileNetV2 mimarisi kullanılarak bireyler 5 farklı yaş kategorisinde (Çocuk, Genç, Yetişkin, Orta Yaş, Yaşlı) sınıflandırılmıştır. Çalışma sonucunda test veri kümesi üzerinde %51 genel doğruluk oranına ulaşılmıştır.

Elde edilen deneysel bulgular ışığında aşağıdaki temel sonuçlara varılmıştır:

1. Morfolojik Belirginliğin Etkisi: Model, yüz hatlarının, kafa yapısının ve cilt dokusunun en karakteristik olduğu

0-12 Yaş (Çocuk) grubunu tespit etmekte %89 Duyarlılık (Recall) oranıyla üstün bir başarı göstermiştir. Bu durum, derin öğrenme modellerinin belirgin fiziksel değişimleri (kemik gelişimi vb.) öğrenmede oldukça yetenekli olduğunu kanıtlamaktadır.

2. Yaşlanmanın Sürekliliği ve Sınır Problemi: Çalışmanın en zorlu kısmı, 46-60 Yaş (Orta Yaş) aralığının sınıflandırılması olmuştur. Bu grupta elde edilen düşük başarı oranı (%7 Recall), yaşlanmanın keskin sınırlarla ayrılan ayrık (discrete) bir süreç değil, sürekli (continuous) bir biyolojik süreç olduğunu doğrulamaktadır. Karmaşıklık matrisi analizleri, modelin orta yaş grubundaki bireyleri ağırlıklı olarak bir önceki evre olan "Yetişkin" sınıfına atadığını göstermiştir. Bu durum, 40-60 yaş bandındaki görsel yaşlanma belirtilerinin kişiden kişiye büyük farklılıklar göstermesinden kaynaklanmaktadır.
3. Sınıf Dengesizliği Yönetimi: Veri setindeki dengesiz dağılım, Sınıf Ağırlıklandırma (Class Weighting) yöntemi ile kısmen kontrol altına alınmış olsa da, çoğunluk sınıfı olan "Yetişkin" grubunun modelin kararları üzerindeki baskınlığı tam olarak kıılamamıştır. Ancak bu yöntem sayesinde, veri setinde azınlıkta olan çocuk ve yaşlı sınıflarının tamamen göz ardı edilmesi engellenmiştir.
4. Mimari Verimlilik: Kullanılan MobileNetV2 mimarisi ve Karma Hassasiyet (Mixed Precision) eğitimi, modelin NVIDIA RTX 3070 donanımı üzerinde oldukça hızlı eğitilmesini sağlamıştır. Bu, önerilen yöntemin sadece sunucu tabanlı değil, mobil ve gömülü sistemlerde de uygulanabilir potansiyele sahip olduğunu göstermektedir.

Gelecek Çalışmalar İçin Öneriler:

Bu çalışmanın performansını artırmak ve mevcut kısıtları aşmak için ileride yapılacak çalışmalarda şu yöntemler önerilmektedir:

- Kayıp Fonksiyonu: Standart Çapraz Entropi yerine, modelin zorlandığı örneklerle (hard examples) daha fazla odaklanmasını sağlayan Focal Loss fonksiyonunun kullanılması, orta yaş grubundaki başarıyı artırabilir.
- Regresyon Yaklaşımı: Yaşı bir sınıflandırma problemi (kategori tahmini) yerine bir regresyon problemi (tam sayı tahmini) olarak ele alıp, tahmin edilen yaşı hangi aralığa düştüğüne sonradan karar vermek, sınırda kalan örnekler için daha doğru sonuçlar üretebilir.
- Veri Seti Dengesi: Özellikle orta yaş ve yaşlı grubundaki veri sayısının artırılması veya sentetik veri üretimi (GANs) ile veri setinin dengelenmesi modelin yanlılığını azaltacaktır.

Kaynakça

Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (ss. 1251-1258).

Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., ve Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (ss. 248-255).

Eidinger, E., Enbar, R., ve Hassner, T. (2014). Age and gender estimation of unfiltered faces. *IEEE Transactions on Information Forensics and Security*, 9(12), 2170-2179.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., . . . Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems (NIPS)* (ss. 2672–2680).

He, K., Zhang, X., Ren, S., ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (ss. 770-778).

Kingma, D. P., ve Ba, J. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*. San Diego, CA.

Levi, G., ve Hassner, T. (2015). Age and gender classification using convolutional neural networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (ss. 34-42).

Lin, T.-Y., Goyal, P., Girshick, R., He, K., ve Dollar, P. (2017). Focal loss for dense object detection. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (ss. 2980-2988).

Pan, S. J., ve Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.

Rothe, R., Timofte, R., ve Van Gool, L. (2018). Deep expectation of real and apparent age from a single image without facial landmarks. *International Journal of Computer Vision*, 126(2-4), 144-157.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., . . . Fei-Fei, L. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., ve Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (ss. 4510-4520).

Shorten, C., ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(60).

Simonyan, K., ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*. San Diego, CA.

Zhang, Z., Song, Y., ve Qi, H. (2017). Age progression/regression by conditional adversarial autoencoder. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (ss. 5810-5818).

BÖLÜM 2

YÜZ GÖRÜNTÜLERİ ÜZERİNDEN TEMEL BİLEŞEN ANALİZİ

Kenan DONUK¹

Giriş

Veri kümelerindeki yüksek boyutlar ile ortaya çıkan gereksiz ve tekrarlayan veriler, hesaplama maliyetini arttırmakta, veri kümesinin yorumlanabilirliğini düşürmekte, görselleştirmeyi zorlaştırmakta ve makine öğrenmesi uygulamalarında aşırı öğrenmeye yol açarak model performansını düşürmektedir. Bu tür zorlukların üstesinden gelebilmek ve giderek artan yüksek boyutlu veri kümelerinin analizlerini etkili bir şekilde yapabilmek için boyut indirgeme tekniklerine olan ihtiyaç giderek artmıştır. Temelleri 1901 yılında Karl Pearson (F.R.S., 1901) tarafından ortaya atılan ve Harold Hotelling (Hotelling, 1933) tarafından 1933'te geliştirilen Temel Bileşen Analizi (TBA), veri analizinde karşılaşılan “boyutluluk laneti” (Bellman, 1957) fenomenine çözüm getiren istatistiksel tekniklerden biridir. TBA tekniği, orijinal veriyi temsil eden bileşenlerin daha az sayıda ilişkisiz ve varyasyonun en yüksek olduğu yeni bileşenlere (eksenlere) dönüştürülmesi sürecidir (Ringnér, 2008). Bu tekniğin günümüz biliminde veri görselleştirme,

¹Dr. Öğr. Üyesi, Şırnak Üniversitesi, Bilgisayar Müh., 0000-0002-7421-5587

makine öğrenmesi, özellik çıkarımı, veri sıkıştırma, gürültü azaltma gibi bir çok uygulama alanına sahip olduğu görülmektedir. Örneğin, yüz tanıma (Rani & ark., 2022), dolandırıcılık tespiti (Haider & ark., 2024), nörobilim (Viviani, Grön & Spitzer, 2004), biyoteknoloji (Hsu, Huang & Chen, 2014), sinyal işleme (Castells & ark., 2007), finansal veri bilimi (Janićijević, Mizdraković & Kljajić, 2022), gen analizi (Todorov, Fournier & Gerber, 2018), görüntü sınıflandırma (Aslam & Rabie, 2023), görüntü sıkıştırma (Hernandez & Mendez, 2018), sinyal gürültü azaltma (Benesty & ark., 2024) gibi bir çok alanda katkıları mevcuttur. Evrensel bir kullanım alanına sahip olan Temel Bileşen Analizi ile aynı matematiksel modele dayanan (özdeğer-özvektör ayrışımı) disiplinler arası versiyonları da mevcuttur. Akışkanlar mekaniği (Alam & Variyath, 2021) alanında Uygun Ortogonal Ayrıştırma, sinyal işleme (Trudu & ark., 2020) alanında Karhunen-Loève Dönüşümü, iklim (Benestad & ark., 2023) alanında Ampirik Ortogonal Fonksiyonlar örnek olarak gösterilebilir. Bu bölümde, TBA tekniğinin teorik kavramları ve temelleri scikit-learn tarafından sağlanan ve 400 yüz görüntüsü içeren “Olivetti Faces” (Scikit-learn, 2025; Database of Faces, 2025) veri seti üzerinden ele alınarak ilk veri hazırlamadan boyut indirgemeye ve nihai projeksiyona kadar tüm TBA prosedürü anlatılmaktadır. Bu bölüm TBA'nın matematiksel formülasyonunu somut uygulama ile sentezleyerek TBA'nın gerçek dünya uygulamalarında etkili bir şekilde kullanılabilmesi için gerekli olan kavramsal temel ile pratik yeterliliği sağlar.

Kavramsal Çerçeve ve Matematiksel Temel

Veri kümlerindeki gizli kalıpların, karmaşık yapıların en anlamlı biçimde daha az bileşen ile temsil edilmesini sağlayan lineer bir boyut indirgeme yöntemi olan TBA, yüksek boyutlu veri kümelerini maksimum istatistiksel varyansı koruyarak daha düşük boyutlara sıkıştırmaya ve böylece önemli bir bilgi kaybı olmadan yorumlanabilirliği artırmaya yarar. En önemli bileşenlerin korunarak

küçültülmüş alt uzaylara dönüşüm yoluyla karmaşık veri yapıları içindeki örüntüleri, gruplamaları ve aykırı değerleri ortaya çıkararak basit görselleştirme ve keşifsel analiz sağlar. Makine öğrenimi süreçlerinde temel bir ön işleme işlevi görerek, ilişkili özellikler arasındaki çoklu doğrusallığı ele alır ve boyutsallık kontrolü yoluyla aşırı uyumu önler (Han & Joe, 2024). Temel Bileşen Analizi, ilişkili değişkenleri açıklanan varyansa göre sıralanmış ilişkisiz ortogonal bileşenlere dönüştüren bir boyut azaltma tekniğini temsil eder. Bu dönüşüm işleminde kovaryans matris ayrıştırması yoluyla gereksiz veya tekrarlayan veriler etkili bir şekilde ortadan kaldırır. Kovaryans matrisinin özdeğer-özvektör ayrıştırması yoluyla, değişkenliği (varyans) en yüksek tutan eksenler belirlenir. Bu şekilde korelasyonlu özellikler elenerek daha temiz bir temsil elde edilir. Ancak, bu tekniğin etkinliği doğru veri merkezlemeye ve bazı durumlarda da özellik standardizasyonuna bağlıdır. Farklı özellikler arasındaki farklı ölçekler, bazı özelliklerin diğerlerini gölgede bırakarak TBA'nın koruduğu varyans bilgisini bozabilir (Gewers & ark., 2018). Bu nedenle özellik standardizasyonu yaklaşımı ile orijinal ölçüm ölçeklerinden bağımsız olarak değişkenlerin katkısı hizalanır. TBA'da özellik standardizasyonu isteğe bağlı bir ön işlem olsa da veri merkezleme ön işlemi zorunludur (Greenacre & ark., 2022). TBA'nın uygulanması, altı temel aşamadan oluşan sistematik bir hesaplama prosedürünü izler. İlk olarak, TBA'nın çalışmasında zorunlu ve doğru varyans yönünün yakalanmasında etkili bir adım olan veri merkezleme işlemi gerçekleştirilir. Veri merkezleme işlemi her bir özellikten ilgili özelliğin ortalaması çıkarılıp gerçekleştirilir. Daha sonra veri setinde farklı birimlere sahip değişkenler var ise veri standardizasyonu gerçekleştirilir; İkinci olarak kovaryans matrisi ile veri setindeki özellik çiftleri arası ilişkiler ve korelasyonlar hesaplanır. Üçüncü olarak, maksimum varyans yönlerini temsil eden özvektörleri ve her yön boyunca varyansın büyüklüğünü ölçen özdeğerleri çıkarmak için kovaryans matrisine özdeğer ayrıştırması uygulanır. Dördüncü olarak özvektörler, kendilerine karşılık gelen

özdeğerlerine göre azalan düzende sıralanır. Beşinci olarak, k temel bileşen seçimi ile boyut azaltımı sağlanır. Bu seçim genellikle toplam varyansın %95-99'u oranını yakalayan özvektörler korunarak gerçekleştirilir. Son olarak, orijinal veri matrisi matris çarpımı yoluyla seçilen temel bileşenlere yansıtılır. Böylelikle veri seti orijinal d boyutlu uzayından, k 'nin d 'den önemli ölçüde daha küçük olduğu indirgenmiş k boyutlu alt uzaya dönüştürülür, böylece sıkıştırılmış gösterimde maksimum bilgi içeriği korunurken dönüşüm tamamlanır.

Veri Merkezleme

Bu adımın amacı TBA'nın maksimum varyans yönünü, ortalamadan etkilenmeden bulmaktır. TBA'nın teorik geçerliliğinin korunması için zorunlu bir ön işlem adımdır. Veri merkezleme veri kümesindeki her değişkenin veya sütunun ortalamasının sıfıra kaydırılması işlemidir. Bunun için değişkendeki her özellikten değişken ortalaması çıkarılır. Böylelikle veri matrisinin her sütununun ortalaması sıfır olur. Denklem 1 ve 2'de sırasıyla ortalama ve veri merkezleme formülü verilmiştir. Denklemde yer alan X_{ij} , veri matrisindeki i . örneğin j . özelliğini temsil eder. $\bar{X}_j$, tüm örnekler boyunca j . özelliğin ortalamasıdır ve bu ortalama, özelliğin her bir örnek üzerindeki değerlerinin toplanıp örnek sayısı n 'e bölünmesiyle elde edilir. Merkezleme adımında, her bir özellik değerinden o özelliğin ortalaması çıkarılır ve böylece ortalanmış X_c özellikleri elde edilir. Bu durumun daha iyi anlaşılması açısından Şekil 1'de orijinal yüz görüntüsünden ortalama yüzün çıkarılmasıyla merkezlenmiş yüzün elde edilme sürecinin uygulanması gösterilmiştir.

$$\bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij} \quad (1)$$

$$X_c = X_{ij} - \bar{X}_j \quad (2)$$

Şekil 1 Yüz Görüntüsü Merkezleme İşlemi



Veri Standardizasyonu

TBA uygulamasında isteğe bağlı olarak kullanılan standardizasyon, farklı ölçeklerde ölçülen değişkenlerin TBA'ya eşit katkıda bulunmasını sağlayarak, daha geniş sayısal aralıklara veya farklı birimlere (örneğin kilogram, metre) sahip değişkenlerin temel bileşenleri orantısız bir şekilde etkilemesini önler. TBA varyansı en üst düzeye çıkardığı için, standardize edilmemiş veriler yüksek varyanslı özelliklerin baskın olmasına izin vererek, düşük varyanslı ancak bilgilendirici değişkenlerin katkısını engeller. Her özelliğin ortalaması 0 ve standart sapması 1 olacak şekilde dönüştürülmesiyle, standardizasyon boyutlar arasında varyansı eşitleyerek adil ve yorumlanabilir bileşen çıkarımı sağlar. Denklem 3 ve 4'te sırasıyla standardizasyon ve standart sapma denklemleri verilmiştir. Bu denklemlerde Z_{ij} standardize edilmiş değerler, X_{ij} i . gözlemin j . özelliği, $\bar{X}_j$ j . özelliğin ortalaması ve s_j j . özelliğin standart sapmasıdır. Veri merkezleme ve veri standardizasyonunun daha iyi anlaşılabilmesi için Şekil 2'de "Olivetti Faces" veri setindeki 400 görüntünün ortalaması (ortalama yüz) ve orijinal yüz görüntülerinden ortalama yüzün çıkarılması ile merkezleme ve standardizasyon işlemlerinin uygulanması gösterilmiştir.

$$Z_{ij} = \frac{X_{ij} - \bar{X}_j}{s_j} \quad (3)$$

$$s_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2} \quad (4)$$

*Şekil 2 Orijinal-Ortalama-Merkezeleme-Standardizasyon
Sürecindeki Yüz Görüntüleri*



Kovaryans Matrisinin Hesaplanması

Kovaryans matrisi, değişkenlerin bir veri kümesi içinde birlikte nasıl değiştiğini tanımlayan temel bir istatistiksel araçtır. Bir değişkendeki değişikliklerin başka bir değişkendeki değişikliklerle ne ölçüde ilişkili olduğunu ölçer ve böylece paylaşılan değişkenlik örüntülerini ortaya çıkarır. Matristeki her bir eleman, bir çift değişken arasındaki kovaryansı temsil ederek, gereksiz veya ilişkili bilgilerin belirlenmesini sağlar. Pozitif bir kovaryans, iki değişkenin eş zamanlı olarak artma eğiliminde olduğunu gösterirken, negatif bir kovaryans, bir değişken artarken diğerinin azaldığını gösterir. TBA ve benzeri yöntemlerin teorik geçerliliğini açıklayan kovaryans matrisi, ortogonal özvektörlere ve gerçek özdeğerlere sahiptir (Anderson, 1958). Bu özellikler, veri varyansının en üst düzeye çıkarıldığı yönleri belirlemek için çok önemlidir. Standartlaştırılmış veya merkezlenmiş bir veri matrisi Z için, kovaryans matrisi matematiksel olarak Denklem 5'teki gibi formüle edilir. Bu formülde

Z , her sütunu ortalaması çıkarılarak merkezlenmiş $n \times d$ boyutlu veri matrisidir; burada n örnek sayısını, d ise özellik sayısını ifade eder. Z^T bu matrisin transpozudur ve özellikleri satırlara taşır, $Z^T Z$ çarpımı özellik çiftleri arasındaki toplam ortak varyansı verir. Son olarak $\frac{1}{n-1}$ katsayısı bu toplamı örneklem kovaryansına dönüştüren normalize edici terimdir.

$$C = \frac{1}{n-1} Z^T Z \quad (5)$$

Özvektör-Özyüzlerin Hesaplanması

Kovaryans matrisi, veri kümelerindeki değişkenlerin kendileri ve birbirleri arasındaki değişim ilişkisini gösteren bir kare matristir. Bu matristeki her elaman iki özellik arasındaki ilişkiyi temsil ederken, tüm matris veri setinin genel yapısını özetler. En büyük özdeğerle ilişkili olan öncü özvektör, değişkenliğin birincil yönünü yakalarken, sonraki ortogonal vektörler giderek küçülen varyans kaynaklarını temsil eder. Bu ortogonalite, korelasyonsuz temel bileşenleri garanti altına alır ve önemli özdeğerlere sahip olanları koruyarak boyut azaltımına olanak tanır. Her bileşenin göreceli önemi, özdeğerinin normalleştirilmesiyle niceliksel olarak belirlenir. Denklem 6'daki formül, bir özvektör v 'nin kovaryans matrisi C ile çarpıldığında yönünü koruduğu anlamına gelir ve λ , bu yön boyunca varyans miktarıdır. Denklem 7 ise hangi λ değerlerinin bunu mümkün kıldığını gösterir. TBA'da, bu λ değerleri her bir ana bileşenin ne kadar varyansa sahip olduğunu gösterir ve v vektörleri bileşen yönlerini verir. Şekil 3'te örnek bir özvektör-özyüz verilmiştir. 1991 yılında Turk ve Petland tarafından geliştirilen yüz tanıma sistemindeki TBA uygulamasında kullanılan özvektörler, yüz kümesinin temel bileşenleri anlamında özyüzler olarak ifade edildi (Turk & Pentland, 1991).

$$Cv = \lambda v \quad (6)$$

$$\det(C - \lambda I) = 0 \quad (7)$$

Şekil 3 Özvektör-Özyüz



Özvektörlerin-Özyüzlerin Sıralanması


Özvektörlerin/Özyüzlerin hangilerinin en yüksek varyansı karşıladığı veya en fazla bilgi taşıdığını belirlemek için özdeğerler kullanılır. Özdeğerler, temel bileşenleri belirlemek için büyükten küçüğe doğru sıralanır. Bu sıralama, her bileşenin toplam varyansa görece katkısını ortaya koyar ve toplam varyansın önemli bir kısmını karşılayan temel bileşenler seçilerek boyut indirgeme gerçekleştirilir. Özdeğerlerin ($\lambda_1 > \lambda_2 > \dots > \lambda_p$) sıralamasından hesaplanan kümülatif varyans, yeterli veri temsiliyi korurken kaç bileşenin korunması gerektiğine karar vermek için nicel bir temel sağlar. λ_1 en büyük özdeğeri, λ_p ise en küçük özdeğeri temsil eder. En büyük özdeğere bağlı özvektör-özyüz, baskın bileşeni temsil ederken geri kalan özdeğerler azalan değerlerine göre diğer bileşenleri temsil ederler. Denklem 8’de varyans hesaplaması, Şekil 4’te “Olivetti Faces” veri setindeki yüzlerin ilk 20 özvektörlerin/özyüzlerin varyans değerine göre büyükten küçüğe sıralanması ve Şekil 5’te ilk 30 özvektörün-özyüzün varyans sıralaması gösterilmiştir. Sıralamalardaki en yüksek varyansa sahip özyüz, yüzleri birbirinden ayıran en güçlü desenlere sahip yönü ifade etmektedir.

$$\text{Bireysel Varyans}_i = \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \quad (8)$$

Şekil 4 İlk 20 Özyüzün Varyans Oranlarına Göre Sıralı Gösterimi



Şekil 5 İlk 50 Özyüzün Varyans Sıralaması



Temel Bileşen Seçimi


Hesaplama maliyetini azaltmak ve anlamlı bilgileri korurken aşırı uyumu önlemek için yalnızca ilk k sayıda temel bileşen korunur.

Elde edilen tüm bileşenlerin korunması orijinal boyutu değiştirmeyeceğinden TBA'nın boyut azaltma amacına aykırı olacaktır. Genellikle, kümülatif varyans %95-99 olacak şekilde k sayıda temel bileşen seçilir. Bu yaklaşım ile verilerin temel yapısını korunurken gürültü ve gereksiz bilgiler ortadan kaldırılır. K sayıda bileşen kullanmak, hesaplama verimliliğini artırır, model eğitimi hızlandırır, görselleştirmeyi kolaylaştırır ve makine öğrenimi algoritmalarında bir ön işlem olarak modelin genelleme performansını iyileştirir. Denklem 9'da kümülatif varyans hesaplaması, Denklem 10'da temel bileşen sayısı hesaplaması verilmiştir. Ayrıca Şekil 6'da kümülatif varyans ile özyüz sayısı arasındaki ilişki grafiği gösterilmiştir. Grafik incelendiğinde 50 adet özyüz toplam varyansın yaklaşık olarak %90'nını açıklamaktadır.

$$\text{Kümülatif Varyans}_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{j=1}^p \lambda_j} \quad (9)$$

$$\sum_{i=1}^k \lambda_i \approx 0.95 \times \sum_{j=1}^p \lambda_j \quad (10)$$

Şekil 6 Özyüz Sayısı İle Kümülatif Varyans Değişimi



Veri Projeksiyonu

Yüksek boyutlu verilerin yeni bileşenlere veya eksenlere dönüşümünü ifade eder. TBA'daki veri projeksiyonu, kovaryans matrisinin özvektörleri ile elde edilen yönlerden k adet temel bileşen


tarafından tanımlanan daha düşük boyutlu bir alt uzaya yansıtmayı ifade eder. Bu yansıtma, orijinal ilişkili eksenleri veri kümesinin mümkün olan en yüksek varyansını yakalayan ortogonal eksenlerle değiştirilmesi olarak ifade edilir. Sonuç olarak verilerin en bilgilendirici yapısı korunurken verilerin temsili daha kompakt hale getirilir.

Seçilen özvektörlerden oluşan yansıtma matrisi $W \in R^{p \times k}$ Denklem 11’de verilmiştir. Bu matris kullanılarak, merkezlenmiş bir veri matrisi $Z \in R^{n \times p}$, Denklem 12’ki yeni $Y \in R^{n \times k}$ boyutlu uzaya eşlenir. Şekil 7’de 4096 piksel ile temsil edilen her orijinal görüntünün, TBA uygulanmasıyla 50 adet katsayı ile temsil edildiği gösterilmiştir.

$$W = (v_1 \ v_2 \ \dots \ v_k) \quad (11)$$

$$Y = ZW \quad (12)$$

Şekil 7 Orijinal ve TBA Yüz Görüntüleri



Verinin Yeniden İnşası

TBA, yüksek boyutlu verilerdeki varyansın büyük kısmını taşıyan değişkenler ile verinin daha düşük boyutlu yeni bir koordinat sistemine taşınmasıdır. Bu koordinat sistemi ortogonal eksenler oluşturduğundan, orijinal özellik gösterimine yaklaşmak verinin

tersine dönüşümü gerçekleştirilebilir. Tersine dönüşümün doğruluğu, kaç bileşenin korunduğuna bağlıdır. Tüm bileşenlerin korunması kayıpsız bir yeniden yapılandırma sağlarken, daha düşük varyansa sahip bileşenlerin hariç tutulması bazı bilgileri ortadan kaldırır ve yeniden yapılandırma hatasına neden olur. Denklem 13 ve 14 ile verinin yeniden orijinal özellik gösterimine çevrimini, Denklem 15 ise yeniden yapılandırma hatasını vermektedir. Ayrıca Şekil 8’de bu durum görsel olarak verilmiştir.


$$\hat{Z} = YW^T \quad (13)$$

$$\hat{X} = \hat{Z} + \mu \quad (14)$$

$$\text{Yapılandırma Hatası} = \sum_{i=k+1}^p \lambda_i \quad (15)$$

Denklemlerde verilen Y verilerin küçültülmüş boyutlu gösterimini belirtirken, W temel bileşenleri içeren özvektör matrisine karşılık gelir. Y ’nin W^T ile çarpılması, özellik uzayındaki merkezlenmiş örnekleri temsil eden $\hat{Z}$ değerini verir. Orijinal veri alanını geri kazanmak için, merkezleme sırasında çıkarılan ortalama vektör μ geri eklenerek $\hat{X}$ elde edilir. TBA’da kaçınılmaz bir durum olan yapılandırma hatası ise, seçilmeyen bileşenlerle ilişkili özdeğerlerin toplamı ile niceliksel olarak belirlenir. Şekil 8’de gösterildiği gibi orijinal özellik gösteriminin yaklaşık olarak yeniden elde edilebilmesi için ortalama yüzün, her biri ağırlığına göre seçilen temel bileşenlerin toplanmasıyla görüntü yeniden yapılandırılır.

Şekil 8 Verinin/Görüntünün Yeniden Yapılandırılması Süreci



Sonuç

Bu bölümde Temel Bileşen Analizinin teori ve uygulaması için kapsamlı bir rehber sunulmuştur. TBA'nın her aşamasında matematiksel temeller verildikten sonra yüz görüntülerinden oluşan “Olivetti Faces” veri seti aracılığıyla bu temellerin pratik uygulaması sistematik olarak gerçekleştirilerek teorik temeller somutlaştırılmıştır. Veri merkezleme ve kovaryans matrisi hesaplamasından özdeğer ayrıştırmaya, bileşen seçimine ve nihai projeksiyona kadar her bir ardışık adım incelenmiştir. Ancak TBA, her biri farklı özelliklere ve uygulamalara sahip çeşitli boyut indirgeme metodolojileri arasında yalnızca bir yaklaşımı temsil etmektedir. TBA, doğrusal ilişkileri yakalamada ve ortogonal dönüşümler aracılığıyla varyansı en üst düzeye çıkarmada mükemmel olsa da veri tiplerine, dağılımlara ve analiz ihtiyaçlarına uyarlanmış birçok TBA varyantı ortaya çıkmıştır. Örneğin doğrusal olmayan örüntülerin ortaya çıkarılmasında “Kernel PCA-Çekirdek TBA”, gürültü ve aykırı değerlere dayanıklılık için “Robust PCA-Dayanıklı TBA”, yorumlanabilirliği arttırmak için “Sparse PCA-Seyrek TBA”, büyük veri analizlerinde “Incremental PCA-Artırımlı TBA” yaygın olarak kullanılan varyantlardır. Bu bölüm, okuyuculara TBA'yı etkili bir şekilde uygulamak için gerekli teorik anlayışı ve uygulamalı deneyimi sağlayan pratik bir rehber görevi görmektedir.

Kaynakça

Scikit-learn (2025). The Olivetti faces dataset scikit-learn 0.19.2 documentation. (29.11.2025 tarihinde https://scikit-learn.org/0.19/datasets/olivetti_faces.html adresinden ulaşılmıştır).

Alam, J., & Variyath, A. (2021). Low-dimensional representation of fluid flows using proper orthogonal decomposition.

Anderson, T. W. (1958). An introduction to multivariate statistical analysis. John Wiley & Sons.

Aslam, S., & Rabie, T. F. (2023). Principal Component Analysis in Image Classification: A review. *2023 Advances in Science and Engineering Technology International Conferences, ASET 2023*.

Benestad, R. E., Mezghani, A., Lutz, J., Dobler, A., Parding, K. M., & Landgren, O. A. (2023). Various ways of using empirical orthogonal functions for climate model evaluation. *Geoscientific Model Development*, 16 (10), 2899-2913.

Benesty, J., Huang, G., Chen, J., & Pan, N. (2024). Principal Component Analysis in Noise Reduction and Beamforming. *Springer Topics in Signal Processing*, 22, 57-85.

Castells, F., Laguna, P., Sörnmo, L., Bollmann, A., & Roig, J. M. (2007). Principal Component Analysis in ECG Signal Processing. *EURASIP Journal on Advances in Signal Processing*, 2007(1), 074580.

F.R.S., K. P. (1901). LIII. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine Series 1*, 2 (11), 559-572.

Gewers, F. L., Ferreira, G. R., de Arruda, H. F., Silva, F. N., Comin, C. H., Amancio, D. R., & Costa, L. da F. (2018). Principal

Component Analysis: A Natural Approach to Data Exploration. *ACM Computing Surveys (CSUR)*, 54 (4).

Greenacre, M., Groenen, P. J. F., Hastie, T., D'Enza, A. I., Markos, A., & Tuzhilina, E. (2022). Principal component analysis. *Nature Reviews Methods Primers* 2. <https://doi.org/10.1038/s43586-022-00184-w>

Han, Y., & Joe, I. (2024). Enhancing Machine Learning Models Through PCA, SMOTE-ENN, and Stochastic Weighted Averaging. *Applied Sciences* 2024, 14 (21), 9772.

Hernandez, W., & Mendez, A. (2018). Application of Principal Component Analysis to Image Compression. *Statistics - Growing Data Sets and Growing Demand for Statistics*. <https://doi.org/10.5772/INTECHOPEN.75007>

Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24 (6), 417–441.

Hsu, Y. L., Huang, P. Y., & Chen, D. T. (2014). Sparse principal component analysis in cancer research. *Translational Cancer Research*, 3(3). <https://doi.org/10.3978/J.ISSN.2218-676X.2014.05.06>

Janićijević, S., Mizdraković, V., & Kljajić, M. (2022). Principal Component Analysis in Financial Data Science. *Advances in Principal Component Analysis*. <https://doi.org/10.5772/INTECHOPEN.102928>

Bellman, R. (1957). *Dynamic Programming*, Princeton University Press.

Rani, G. E., Sakthimohan, M., Suresh, M. P., Abhiram, M., Surya, K. J., & Kumar, B. Y. A. N. (2022). Face Recognition Using Principal Component Analysis. *2022 2nd International Conference*

on Advance Computing and Innovative Technologies in Engineering, ICACITE 2022, 932-936.

Ringnér, M. (2008). What is principal component analysis? *Nature Biotechnology*, 26(3), 303-304.

Database of Faces (2025). (29.11.2025 tarihinde <https://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html> adresinden ulaşılmıştır).

Todorov, H., Fournier, D., & Gerber, S. (2018). Principal components analysis: theory and application to gene expression data analysis. *Genomics and Computational Biology*, 4 (2), 100041.

Trudu, M., Pilia, M., Hellbourg, G., Pari, P., Antonietti, N., Maccone, C., Melis, A., Perrodin, D., Trois, A. (2020). Performance analysis of the Karhunen-Loève Transform for artificial and astrophysical transmissions: denoising and detection. *Monthly Notices of the Royal Astronomical Society*, 494 (1), 69-83. <https://doi.org/10.1093/mnras/staa694>.

Turk, M., & Pentland, A. (1991). Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, 3 (1), 71-86. <https://doi.org/10.1162/JOCN.1991.3.1.71>

Viviani, R., Grön, G., & Spitzer, M. (2004). Functional principal component analysis of fMRI data. *Human Brain Mapping*, 24 (2), 109-129. <https://doi.org/10.1002/HBM.20074>

Zeeshan Ali Haider, Khan, F. M., Zafar, A., Nabila, & Khan, I. U. (2024). Optimizing Machine Learning Classifiers for Credit Card Fraud Detection on Highly Imbalanced Datasets Using PCA and SMOTE Techniques. *VAWKUM Transactions on Computer Sciences*, 12 (2), 28-49.

BÖLÜM 3

ÇOKLU MODÜLER YAPILI DİYALOGLARDA YAPAY SİNİR AĞLARI İLE DUYGU ANALİZİ: MELD VE IEMOCAP ÜZERİNE BİR DEĞERLENDİRME

Rabia Şevval AYDIN¹
Sude Nur TUNGAÇ²
Ayşe Berna ALTINEL³

Giriş

Günümüzde duygu analizi sağlık alanında psikolojik rahatsızlıkların tespiti ve tedavisi, hukuk alanında suç analizi ve ifade analizi, pazarlama alanında kullanıcı tepkisi, kişi davranış tespiti gibi çeşitli amaçlar ile kullanılmaktadır. Geleneksel duygu analizi çalışmaları genellikle tek tip veri türüne odaklanmaktadır. Konuşmacılardan alınan ifadelerde metin verisi üzerine duygu analizi, mimikler kullanılarak görsel veri ile duygu analizi veya

¹ Marmara Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul/Türkiye, Orcid: 0009-0000-2742-2113, rabia.sevval@marun.edu.tr

² Marmara Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul/Türkiye, Orcid: 0009-0003-7885-1745, stungac@marun.edu.tr

³ Marmara Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul/Türkiye, Orchid: 0000-0001-5544-0925, berna.altinel@marmara.edu.tr

konuşma kayıtlarından ses verisi ile duygu analizi yapılması buna örnek gösterilebilir. Bu projede duygu analizinin diyaloglar üzerine uygulanmasına odaklanılmıştır.

Diyaloglar insan doğası gereği çoklu modüler yapıdadır. Konuşmacılar sözlü ifadelerine ek olarak mimik, ses tonu ve vücut hareketleri kullanarak duygularını karşı tarafa aktarırlar. Bu sebeple karşılıklı konuşmalarda duygu tespiti (ERC-Emotional Recognition in Conversations) çalışmalarında bu yapıya uygun veri seti ve yöntemlerinin kullanılması gerekmektedir (Poria, ve diğerleri, 2019). Bu çalışmada bu alanda önde gelen veri setlerinden MELD veri seti ile IEMOCAP veri seti kullanılmıştır. Projenin temel amacı multimodüler duygu analizi için en iyi performans gösteren yapay sinir ağı yöntemlerini bulmaktır. Bu doğrultuda öncelikle MELD ve IEMOCAP veri setinin farklı modaliteleri incelenerek tek bir modalite üzerinden temel analiz yöntemleri araştırılmıştır. Ardından bu modaliteler birleştirilerek, çoklu modaliteler üzerine yapay sinir ağı modellerinin duygu analizi performansları incelenmiştir.

İlgili Çalışmalar

Yapay sinir ağları ile çoklu modüler yapıda duygu analizi yapılması güncel ve önemli görülen bir konudur. Literatürde bu konuda yapılmış birçok araştırma ve yöntem bulunur.

Duygu analizinde diyalog sürecini anlamak ve duygu akışını takip etmek için Majumder ve ark. (2019) tarafından yapılan çalışmada geliştirilmiş DialogueRNN modelinden bahsedilir. Geliştirilen DialogueRNN modeli ve çalışmada incelenen diğer modeller IEMOCAP ve AVEC veri setleri üzerinde test edildiğinde en başarılı performansı DialogueRNN varyantlarından biri olan BiDialogueRNN+Attn yapısı gösterir.

İkili diyalogların yanında çok kişili diyaloglar üzerinde duygu analizi için Poria ve ark. (2019) tarafından yapılan çalışmada MELD veri seti üzerinde test edilen üç ana model vardır. Bu modeller text-CNN, bcLSTM ve DialogueRNN modelleridir. text-CNN konuşmanın bağlamını dikkate almaz, yani ifadelerin sırasını veya önceki ifadelerin durumlarını kullanmaz. İki yönlü RNN

kullanan bcLSTM ise konuşmayı bir bütün olarak işler, konuşmacı değişikliğini dikkate almaz. DialougeRNN ise çok kişili diyaloglarda konuşmacı durumlarını takip ederek her bir konuşmacı için özel bağlam oluşturur.

Zhang ve ark. (2019) tarafından yapılan çalışmada bağlam duyarlılığı bağımlılıklarının yanı sıra konuşmacı duyarlılığı bağımlılıkları da dikkate alınarak bu özelliklere odaklanan bir model olan ConGCN modeli geliştirilir. Modelde graf bazlı evrişimli sinir ağı kullanılır. Graf tabanlı modellemede her bir ifade ve konuşmacı için birer düğüm bulunur. Bağlamsal bağımlılık için aynı konuşmadaki düğümlerin ilgili kenarları birbirine bağlanırken konuşmacı bağımlılığının sağlanmasında ifade düğümü ile konuşmacı düğümü arasında bir bağlantı oluşturulur. Oluşturulan GCN modelinin performansının MFN, BC-LSTM, CMN, ICON ve DialogueRNN modellerinin performansları ile karşılaştırıldığında en yüksek başarıyı verdiği görülür.

Bai ve ark. (2019) tarafından yapılan çalışmada MELD veri setinde bulunan üç veri türü için de derin öğrenme modülleri yapılandırılarak ince ayar yapılır. Metin modalitesinin ön işleminde GPT, ses modalitesinin ön işleminde WaveRNN, görüntü modalitesinin ön işleminde ise FaceNet modalitesinden yararlanılır. Duygunun tahmini aşamasında çapraz modalite füzyon transformatörü ve füzyon için EmbraceNet mimarisi kullanılır.


Ghosali Majumder, Gelbukh, Mihalcea & Poria (2020) tarafından yapılan çalışmada ise farklı veri setleri üzerinde metin verisi ile yapılan çalışmalarda metnin bağlam durumu, içsel durum, dışsal durum, niyet durumu ve duygu durumu değişkenleri kullanılır. Ayrıca RoBERTa large modelinin ince ayar edilerek bağımsız özellik çıkarımında kullanılmasının başarıyı artırdığı görülür.

Deepanway Ghosal (2020) tarafından yapılan çalışmada konuşmalardaki duygu tanıma problemi (ERC) ele alınmıştır ve bu probleme çözüm olarak konuşmayı hem konuşmacılar arasındaki bağımlılık hem de kendi kendine bağımlılık incelemesi ile duygusal olarak sınıflandıran DialogueGCN modeli tanıtılmıştır.

Yöntem ve Kullanılan Modeller

MELD Veri Seti

Multimodüler yapıda duygu analizi için pek çok veri seti bulunmaktadır. Fakat bu veri setlerinin çoğunluğu tekli ifadeler içermesi sebebiyle sınırlı çalışma imkânı sunmaktadır. Örneğin CMU-MOSEI, CMU-MOSI ve CMU-MOUD veri setleri sadece tekli ifadelerden oluştuğundan dolayı diyalog üzerine analiz imkânı sağlayamamaktadır. IEMOCAP VE SEMAINE veri setleri ikili ifadeler içerdiklerinden diyaloglar üzerine çalışma imkânı sağlamaktadır ancak örnek sayıları MELD veri setine göre çok daha azdır. Örnek sayısına ek olarak IEMOCAP ve SEMAINE veri setleri iki kişilik diyaloglar içerirken MELD veri seti ikiden fazla kişiden oluşan diyaloglara yer verdiği için daha kapsamlı bir çalışma fırsatı sunmaktadır.



Şekil 1: MELD veri setinden diyalog örneği

Kaynak: (Poria, ve diğerleri, 2019)

MELD veri seti hazırlanırken diyaloglar video klipleri ile değerlendirilmiştir. Veri seti Friends adlı televizyon serisine ait 1433 diyalogdan alınmış 13000 ifadeden oluşur. Her bir ifade için 7 duygu (sinir, tiksinti, üzüntü, mutluluk, nötr, şaşkınlık, korku) etiketine ek olarak duygular pozitif, negatif ve nötr sınıflarında gruplandırılmıştır. Sinir, tiksinti, üzüntü, korku duyguları negatif, mutluluk pozitif, nötr ise nötr sınıfı içerisinde gruplanmıştır.


Şaşkınlık hem pozitif hem de negatif olarak ifade edilebilen bir duygu örneğidir. Şekil 1’de veri setine ait örnek bir diyalog yer almaktadır.

Tablo 1’de veri setinde her bir duygu sınıfı için kaç adet ifade olduğu gösterilmektedir.


Tablo 1: MELD veri setinin duygu sınıflarına ait örnek sayıları

Nötr	Şaşkınlık	Korku	Üzüntü	Sevinç	Tiksinti	Sinir
6436	1636	358	1002	2308	361	1697


Konuşmacılara göre ifade yüzdeleri Şekil 2’de yer almaktadır. Ana karakterlere ait olan konuşmalar haricindeki konuşmalar ‘Diğer’ başlığı altında toplanmıştır. Konuşmacılara göre duygu dağılımı ise Şekil 3’te görülmektedir. Konuşmacılara göre his dağılımı Şekil 4’te bulunmaktadır. Bu görsellerin incelenmesi sonucunda veri serinde nötr sınıfına ait verilerin diğer sınıflara oranla daha fazla olduğu gözlemlenmektedir. Korku ve tiksinti sınıflarında ise bu oranın düşük olduğu görülmektedir.



Şekil 2: MELD veri setindeki konuşmacıların ifade dağılım yüzdeleri



Şekil 3: MELD veri setindeki konuşmacıların duygu dağılımları




Şekil 4: MELD veri setindeki konuşmacıların his dağılımları

IEMOCAP Veri Seti

Interactive Emotional Dyadic Motion Capture (IEMOCAP) veri seti 5 erkek, 5 kadın olmak üzere 10 kişilik bir grup tarafından gerçekleştirilen ikili diyalog çiftlerinden oluşur. 151 diyalog verisinde 2 konuşmacı için de video görüntüleri alınarak 302 video kaydı oluşturulmuştur. Her bir diyalog ifadesi sinir, heyecan, korku, üzüntü, sakinlik, şaşkınlık, mutluluk, memnuniyetsizlik, hayal

kırıklığı ve nötr olmak üzere 10 duygu sınıfı ile etiketlenmiştir. Her bir diyalog için ifadelerin yazılı verisi, konuşmacıların ses kayıtları, video kayıtları olmak üzere üç modalite bulunur.

Toplamda 10039 tane veri örneği bulunur. Bu veri örnekleri iki farklı metot altında gruplanır: bir senaryoya bağlı gerçekleşen diyaloglar ve doğaçlama olarak gerçekleştirilen diyaloglar. İfadelerin 4784 tanesi doğaçlama, 5255 tanesi senaryoya bağlıdır. Şekil 5'te her bir grup için duygu etiketlerinin dağılım yüzdeleri gösterilmiştir (Busso, ve diğerleri, 2008).



Şekil 5: IEMOCAP veri setindeki duyguların metot gruplarına göre dağılımları

DialogueRNN/RoBERTa+ DialogueRNN Modeli

DialogueRNN modeli multimodüler duygu sınıflandırmasında diyalogun bağlamını anlamak ve duygu akışını takip etmekte verimli bir yöntem olarak karşımıza çıkar. Bu modelin üç modülü bulunmaktadır.

1. Küresel durum (Global GRU), önceki ifadelerin ve konuşmacının durumunun dikkate alınması ile genel bağlamın temsil edilmesidir. g_t , küresel bağlamdaki zaman adımının t durumunu temsil eder. x_t , güncel girdinin vektörüdür. g_{t-1} , önceki zaman adımındaki küresel bağlam vektörünü ifade eder.

$$g_t = GRU_g(x_t, g_{t-1}) \quad (1)$$


2. Konuşmacı durumu (Speaker GRU), konuşmacının önceki durumunun ve konuşmasının bağlamının ifadesidir. s_t^i , belirli bir konuşmacının belirli bir andaki durumudur. Eğer bir konuşmacı i , t zamanında konuşuyor ise durumu aşağıdaki gibi güncellenir.

$$s_t^i = GRU_s(x_t, s_{t-1}^i) \quad (2)$$

3. Duygu durumu (Emotion GRU) kısmında ise konuşmacının durumunun ve önceki ifadelerin duygusal bağlamının birleştirilmesinin sonucunda duygusal temsili oluşturulmasıdır. e_t , t zamanındaki duygusal durumu temsil eder.

$$e_t = GRU_e(g_t, s_t, e_{t-1}) \quad (3)$$

Şekil 6’da M katılımcısı olan bir konuşmada kişi i konuşmacıdır ve kişiler $j \in [1, M]$ ve $j \neq i$ dinleyicidir. Mevcut ifade bu ifadelerin bir fonksiyon ile modellenmesinden elde edilir.



Şekil 6: DialogueRNN mimarisi ve t zamanı ifade etmek üzere bir diyalogdaki küresel, konuşmacı, dinleyici ve duygu durumlarının güncellenmesi şeması

Kaynak: (Majumder, ve diğerleri, 2019)

DialogueRNN varyantları test edildiğinde en yüksek performansı BiDialogueRNN+Att varyansı elde eder. RoBERTa-large modelinin ince ayar edilmesi ile özellik çıkarılmasının ardından DialogueRNN kullanımında ise performansın artması söz konusudur (Majumder, ve diğerleri, 2019).

COSMIC Modeli

İkiden fazla konuşmacının yer aldığı diyaloglar üzerinde yapılan duygu analizi görevinin karmaşıklığı için COSMIC bu probleme çözüm olarak duygu analizi işleminde konuşmacının ifadesine ait içerik, bağlam ve sezgisel bilgilerden faydalanmıştır. Mevcut konuşma tabanlı duygu tanıma modellerinin temel üç sorununa odaklanmaktadır: yetersiz bağlam takibi, duygu geçişlerinin yetersiz takibi ve yakın duygular arasında ayrım güçlüğü. COSMIC modeli bu konuşmalarda geçen ifadelerin her birini bir olay olarak ele alır. Bu olayın kişinin niyeti, zihinsel durumu ve olayın sonucu gibi çıkarımların kullanılmasını önerir. ATOMIC veri kümesi üzerinde eğitilmiş COMET adlı bilgi çıkarım modeli aracılığıyla elde edilen çıkarımlar kullanılır. COSMIC mimarisinde dört ana bileşen bulunur:

1. Girdi Temsili: Diyaloglar (u_1, p_1) , (u_2, p_2) , ..., (u_3, p_3) yerleştirilir. Burada u_i bir ifadeyi, p_i ise konuşmacıyı temsil eder. Her bir u_i için hedef, uygun duygu sınıfı e_i 'nin tahmin edilmesidir.
2. Commonsense Bilgi Çıkarımı: İfadelerin her biri için COMET modeli, üç tür sezgisel çıkarım yapar. Mental state (m_i) konuşmacının o anda nasıl hissettiğini temsil eder. Intent (t_i) bu ifadenin niyetidir. Event effect (e_i) ise olayın başkasına veya kendine etkisi nedir. COMET, ATOMIC bilgi kümesi üzerinde eğitilmiş dil modeli tabanlı bir yapı olup, doğal dil ifadelerinden bu soyut kavramları çıkarabilmektedir.
3. Diyalog Akışı ve Bağlam Temsili: COSMIC, konuşmacı bazlı bağlam izleme için DialogueRNN benzeri bir yapı kullanır. Her konuşmacının geçmişi ayrı ayrı GRU tabanlı

durum vektörleriyle takip edilir. Bu durumda, her bir ifadenin kendisiyle birlikte mental durum (mental state), niyet (intent) ve durum etki (event effect) vektörleri de modele dahil edilir. Bu sayede konuşmanın akışında yalnızca kelimeler değil, o ifadenin arka planındaki psikolojik ve sezgisel bilgiler de modele dahil edilir.

$$x_i = [u_i; m_i; t_i; e_i^{event}] \quad (4)$$

$$h_i = GRU(x_i; h_{i-1}) \quad (5)$$

4. Duygu Sınıflandırması: Son adımda, her h_i vektörü (bağlamsal temsil), softmax katmanı üzerinden sınıflandırılır:

$$e_i = softmax(Wh_i + b) \quad (6)$$

Eğitim sırasında klasik çapraz entropy kayıp fonksiyonu ($L = -\sum e_i \log e_i$) kullanılır (Ghosal, Majumder, Gelbukh, Mihalcea, & Poria, 2020).

Yapılan Çalışmalar ve Sonuçlar

MELD ve IEMOCAP veri seti üzerinde uygulanan deneylerde çeşitli yöntemler uygulanmıştır. Verilerden özellik elde etme aşamasında yazılı veriler için önceden eğitilmiş GloVe vektörleri ve 1D-CNN kullanılarak metin özellikleri elde edilmiştir. Ses verileri için openSMILE aracı kullanılmıştır. Deneylerde görsel modülü video bazlı konuşmacı tespiti probleminden dolayı kullanılmamıştır.

Model eğitimi için yapay sinir ağları tabanlı modeller ve çoklu modüler yapıya sahip modeller tercih edilmiştir. Model mimarisinde metinsel ve ses verilerini birlikte ve ayrı ayrı işleyebilen yapılar tercih edilmiştir. Bundan dolayı CNN tabanlı bir text-CNN modeli, çift yönlü RNN tabanlı bir bcLSTM modeli ve 3 adet GRU yapısı kullanan DialogueRNN modeli eğitilmiştir. Aynı

zamanda verilerden öznitelik çıkarımı aşamasında RoBERTa modeli kullanılarak elde edilen öznitelikler DialogueRNN modeline verilmiştir. Benzer bir şekilde RoBERTa ile işlenen veriler COSMIC modeli kullanılarak duygu sınıflandırması yapılmasında da kullanılmıştır.

Eğitim sürecinde modellerin aşırı öğrenmesinin önüne geçilmesi adına erken durdurma (early stopping) ve dropout teknikleri kullanılmıştır. text-CNN ve bcLSTM modellerinde optimizasyon algoritması için ‘Adam’ seçilmiştir. Kayıp fonksiyonu olarak ise ‘kategorisel çapraz entropi kaybı (categorical crossentropy)’ tercih edilmiştir.

DialogueRNN ve COSMIC modellerinde ise bu modellerden farklı olarak kayıp fonksiyonunda ‘Masked NLL Loss’ tercih edilmiştir. Çalışmada DialogueRNN modelinin MELD veri setindeki metin, ses ile hem metin hem ses verisi üzerinde çalıştırılması, COSMIC modelinin MELD ve IEMOCAP veri setinde yer alan metin verileri için çalıştırılması, text-CNN ve bcLSTM modellerinin ise MELD veri seti için hem metin hem ses verileri üzerinde çalışmasının ardından multimodal çalıştırılması sağlanmıştır. Base modeller ile MELD veri kümesi üzerinde elde edilen sonuçlar Tablo 2’de karşılaştırılmıştır. DialogueRNN modelinin, RoBERTa+DialogueRNN ve RoBERTa+COSMIC kombinasyonlarının MELD ve IEMOCAP veri seti üzerinde elde ettiği sonuçlar ise Tablo 3’e gösterilmiştir.

Tablo 2: MELD veri setinde base modelinin duygu sınıflandırmasına ait doğruluk ve f1-skorları

Modeller / Duygular	nötr	şaşıрма	korku	üzüntü	sevinç	tiksinti	sinir	doğruluk
Base model text	64.98	0.00	0.00	0.00	0.00	0.00	0.00	48.12
Base model audio	45.78	0.00	0.00	0.00	0.00	0.00	0.00	33.90
Bimodel base text+audio	65.18	1.37	0.00	0.00	12.40	0.00	27.20	48.16

Tablo 3: MELD ve IEMOCAP veri setinde DialogueRNN ve COSMIC modellerinin duygu sınıflandırmasına ait f1-skorları

Modeller / Veri Setleri	MELD			IEMOCAP
	Text	Audio	Multimodal	
DialogueRNN	57.27	43.24	57.68	60.60
RoBERTa+DialogueRNN	47.10	47.47	50.40	-
RoBERTa+COSMIC	64.36	-	-	66.34

Çalışmada base model olarak bcLSTM modeli kullanılmıştır. Base modellerin her biri için epoch sayısı 100, batch sayısı 50 olacak şekilde eğitim gerçekleştirilmiştir. DialogueRNN modeli için ise epoch sayısı 100 iken batch sayısı 30 olacak şekilde eğitim gerçekleştirilmiştir. Son olarak COSMIC modelinin eğitiminde epoch sayısı 60, batch size ise 32 olarak kullanılmıştır.

Sonuç

Elde edilen sonuçlar incelendiğinde duygu sınıfları arasında nötr etiketine sahip verilerin genel olarak sınıflandırmada diğer sınıflara göre daha yüksek başarıya sahip olduğu görülmektedir. Şaşkınlık, korku, üzüntü, tiksinti gibi daha karmaşık duygulara ait verilerin sınıflandırılabilmesi için bcLSTM, textCNN ve DialogueRNN modellerinin kapsamlı duygu analizi için tek başına yetersiz kaldığı görülmüştür.

Her ne kadar DialogueRNN modeli bağlamsal bilgilerin kullanımı açısından başarılı bir yapıya sahip olsa da model tekli modaliteler (sadece ses ya da sadece metin) üzerinde çalıştırıldığında sınırlı performans göstermiştir. Ancak çoklu modaliteler ile çalıştırılarak ses ve metin verileri birlikte kullanıldığında modelin genel doğruluğunun arttığı gözlemlenmiştir. Bu durum, çoklu modalitelerin birlikte kullanılmasının duygu sınıflandırma başarısını olumlu yönde etkilediğini göstermektedir.

COSMIC ile yapılan metin temelli duygu sınıflandırmasının diğer modellere göre çok daha başarılı olduğu gözlemlenmiştir. Bu noktada COSMIC modelinin diğer modellere kıyasla daha yüksek başarı göstermesinin asıl nedeni yalnızca ham metin verisini değil, bununla beraber ortam bilgisi ve kişiler arasındaki ilişkisel bağlam gibi ek bilgileri kullanarak karmaşık duyguların anlaşılmasını sağlamasıdır. Modelin sahip olduğu bu özellik modelin özellikle bağlama duyarlı (şaşkınlık, tiksinti gibi) duyguların sınıflandırılmasında daha yüksek başarıya ulaşmasını sağlamıştır.

Modellerin tamamında modalitelerde tekli kullanım ile ikili kullanım karşılaştırıldığında, tek modalite kullanımından ikili modaliteye geçildiğinde performansın iyileştiği gözlemlenir. Bu duygu analizinde farklı modalitelerin beraber kullanılarak sınıflandırma sürecinin desteklenmesi gerektiği görüşünü desteklemektedir. Özellikle görsel modalitelerin verimli bir şekilde duygu analizi görevine dahil edilmesinin performansa büyük ölçüde katkısı olacağı düşünülmektedir.

COSMIC modelinin metin tabanlı sınıflandırmada sağladığı yüksek başarıdan dolayı, bu modelin farklı modalitelerle desteklenerek genişletilmesiyle multimodüler veriler için duygu analizinde en optimal modelin elde edilmesi önerilmektedir. Bu sayede hem duygu bağlamının hem de ortam dinamiklerinin daha güçlü bir şekilde yakalanması hedeflenmektedir.

Kaynakça/References

Bai, C., Kumar, S., Leskovec, J., Metzger, M., Nunamaker, J. F., & Subrahmanian, V. S. (2019). Predicting the Visual Focus of Attention in Multi-Person Discussion Videos. *Twenty-Eighth International Joint Conference on Artificial Intelligence*, (pp. 4504-4510). Macao.

Busso, C., Bulut, M., Lee, C.-C., Kazemzadeh, A., Mower, E., Kim, S., . . . Narayanan, S. S. (2008, Kasım 5). IEMOCAP: interactive emotional dyadic motion capture database. *Language Resources and Evaluation*, pp. 335–359.

Deepanway Ghosal, N. M. (2019). DialogueGCN: A Graph Convolutional Neural Network for Emotion Recognition in Conversation. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, (pp. 154-164). Hong Kong.

Ghosal, D., Majumder, N., Gelbukh, A., Mihalcea, R., & Poria, S. (2020). COSMIC: COMmonSense knowledge for eMOtion Identification in Conversations. *Findings of the Association for Computational Linguistics: EMNLP 2020*, (pp. 2470-2481). Online.

Majumder, N., Poria, S., Hazarika, D., Mihalcea, R., Gelbukh, A., & Cambria, E. (2019). DialogueRNN: An Attentive RNN for Emotion Detection in Conversations. *Proceedings of the AAAI Conference on Artificial Intelligence*, (pp. 6818-6825). Macao.

Poria, S., Hazarika, D., Majumder, N., Naik, G., Cambria, E., & Mihalcea, R. (2019). MELD: A Multimodal Multi-Party Dataset for Emotion Recognition in Conversations. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, (pp. 527-536). Florence.

Zhang, D., Wu, L., Sun, C., Li, S., Zhu, Q., & Zhou, G. (2019). Modeling both Context- and Speaker-Sensitive Dependence for Emotion Detection in Multi-speaker Conversations. *Twenty-*

Eighth International Joint Conference on Artificial Intelligence, (pp. 5415-5421). Macao.

BÖLÜM 4

LSTM VE XGBOOST MODELLERİ İLE HATAY İLİ SICAKLIK VERİLERİNİN ZAMAN SERİSİ TABANLI TAHMİNİ VE MODEL PERFORMANSLARININ KARŞILAŞTIRILMASI

MEHMET ERGÜN AZİZOĞLU¹

ERDEM ÇOBAN²

1.Giriş

İklim değışikliğı, dünya genelinde sıcaklık artışları, kuraklık riskleri, deniz seviyesi yükselmesi ve ekstrem hava olayları gibi çok boyutlu etkileri beraberinde getirmektedir (IPCC, 2021; Kalkınç et al.,2025). Bu etkilerin yerel düzeyde doğru şekilde modellenmesi ve tahmin edilmesi, tarımsal üretimden enerji planlamasına, su kaynakları yönetiminden kentsel dönüşüme kadar birçok sektörde karar alma süreçlerini doğrudan etkilemektedir (Qiu et al., 2021). Türkiye'nin güneyinde yer alan Hatay ili, Akdeniz iklim kuşağında bulunması ve iklimsel çeşitliliğıyle bu değışimlerden etkilenen bölgelerden biri olarak öne çıkmaktadır. Bu nedenle, bölgeye özgü iklimsel parametrelerin ileri düzey yöntemlerle analiz edilmesi, bölgesel iklim risklerinin anlaşılmasına ve yönetilmesine katkı sunacaktır. Son yıllarda, zamana bağılı iklim verilerinin analizinde geleneksel istatistiksel yaklaşımların yanı sıra yapay zekâ destekli yöntemlerin de hızla yaygınlaştığı görülmektedir (Çoban.,2025). Özellikle uzun vadeli bağımlılıkları yakalamada etkili olan Uzun Kısa Süreli Bellek (LSTM) modelleri, sıcaklık ve güneş ışıınımı gibi çevresel verilerin doğrulukla tahmin edilmesinde sıkça tercih edilmektedir (İnik et al., 2022; Gürlek & Bilgili, 2023; Karevan & Suykens, 2020). Diğer yandan, XGBoost gibi gradyan artırımı algoritmalar, yüksek hesaplama verimliliğı ve kısa dönemli desenleri yakalama kapasitesi sayesinde çeşitli çevresel tahminlerde başarılı sonuçlar vermektedir (Atalay & Zor, 2025; Duman, 2022). ¹Koçak (2024) tarafından Ankara ili verileriyle yürütölen çalışmada, SARIMA ve LSTM modelleri sıcaklık tahmini için karşılaştırılmış, SARIMA modelinin daha küçük veri setlerinde daha başarılı olduğı vurgulanmıştır. Benzer şekilde, Utku (2024) ve Uluocak ve Bilgili (2023) CNN-LSTM hibrit modelinin LSTM, SVM ve RF gibi modellerle karşılaştırıldığında sıcaklık tahminlerinde daha yüksek doğruluk sunduğunu

¹ Haliç Üniversitesi, Mimarlık Faköltesi, Mimarlık Bölümü, İstanbul, Türkiye, Orcid: 0000-0001-9760-2996

² Dr. Öğr. Üyesi, Haliç Üniversitesi, Mimarlık Faköltesi, Mimarlık Bölümü, İstanbul, Türkiye, Orcid: 0000-0002-4526-7273

göstermiştir (Gong et al., 2024). Güneş ışıınımı tahminine yönelik çalışmalarda da (Eşlik et al., 2024), LSTM tabanlı hibrit modellerin geleneksel ARIMA ya da Karar Ağacı gibi algoritmalara kıyasla daha iyi performans sergilediği tespit edilmiştir (Huang et al., 2025). Tüm bu çalışmalar, sıcaklık, güneş ışıınımı, toprak sıcaklığı ve sel gibi meteorolojik ve çevresel parametrelerin tahmininde zaman serisi analizleri ile yapay zekâ algoritmalarının birlikte kullanımının önemini açıkça ortaya koymaktadır (Wang and Guo, 2020). Ayrıca, literatürde hidroelektrik üretim (Atalay & Zor, 2025), sağlık (Duman, 2022) ve enerji tüketimi (Çetiner & Çetiner, 2021) gibi farklı alanlarda da XGBoost ve LSTM gibi modellerin başarısı gösterilmiştir. Geleneksel çalışmaların dışında yapay zeka destekli çalışmalarda da başarılı sonuçlara ulaşılmıştır. Bu çalışmada, Hatay iline ait Ocak 2010 ile Mart 2023 dönemini kapsayan aylık ortalama sıcaklık verileri kullanılarak, LSTM ve XGBoost modelleri ile zaman serisi tahminleri gerçekleştirilmiş ve bu modellerin performansları MSE, MAE ve R^2 gibi değerlendirme ölçütleri kullanılarak karşılaştırılmıştır (Zhang et al., 2023), (Wang et al., 2024). Bu yönüyle çalışma, hem yerel düzeyde sıcaklık tahmini yapılmasına katkı sunmakta hem de farklı makine öğrenmesi modellerinin etkinliğini karşılaştırmalı olarak ortaya koymaktadır. Ayrıca, veri setinin sınırlılığı, mevsimsel etkilerin modellenmesi ve yapay zekâ modellerinin eğitim gereksinimleri gibi faktörler de dikkate alınarak sonuçların yorumlanması sağlanmıştır.

2. Materyal ve Yöntem

Çalışma alanı


Hatay ili, Türkiye'nin güneyinde, Akdeniz'e kıyısı olan ve farklı coğrafi özelliklere sahip bir bölgedir. Hatay, doğusunda Suriye ile kara sınırına sahiptir ve bu nedenle hem Akdeniz'in etkisini hem de Orta Doğu'nun sıcak iklimini barındıran bir yapıya sahiptir. Coğrafi olarak, ilde en dikkat çekici özellik, geniş düzlüklerin yanı sıra dağlık alanların varlığıdır. Amanos Dağları, Hatay'ın güney sınırında yükselirken, bu dağlar, il sınırlarını Suriye'ye kadar uzatarak bölgenin en yüksek noktalarını oluşturur. Hatay'ın kıyı boyunca uzanan Akdeniz'e özgü sahil şeridi, özellikle tarım ve turizm açısından büyük önem taşır. Bu sahil boyunca yer alan Çukurova Ovası, verimli topraklarıyla ünlüdür ve bu sayede Hatay, zeytin, narenciye gibi tarım ürünlerinde önemli bir üretim merkezidir. Ayrıca, dağlık alanlarda farklı ekosistemler ve bitki örtüleri bulunur, bu da bölgenin biyolojik çeşitliliğini artırır. Hatay'ın coğrafyası, aynı zamanda tarihi ve kültürel açıdan da oldukça zengindir. Bu çeşitli coğrafi yapılar, bölgenin hem doğal hem de insani tarihine etki etmiştir. Sonuç olarak, Hatay, dağlar, vadiler, deniz kıyıları ve

verimli ova alanlarıyla oldukça çeşitlenmiş bir coğrafyaya sahip olup, bu özellikleri hem ekolojik hem de ekonomik anlamda önemli bir bölge yapmaktadır.

Hatay, Türkiye'nin güneyinde yer alan ve Akdeniz ikliminin etkisi altında olan bir bölgedir. Yıl boyunca sıcaklıklar oldukça yüksek, özellikle yaz aylarında, bu bölgenin belirgin bir özelliğidir. Yazlar sıcak ve kurak, kışlar ise ılıman ve yağışlı geçer. Akdeniz ikliminin karakteristik özelliklerinden biri olan bol yağışlar, kış mevsiminde daha yoğun olarak görülür. Bunun yanında, Hatay'ın yüksek dağlık alanları, dağ iklimine sahip bölgelerde farklı iklim özellikleri sergileyebilir. Örneğin, dağlık alanlarda sıcaklıklar daha düşük olabilir ve kar yağışı görülebilir. Bölgenin coğrafi yapısı, sıcaklık ve nem oranlarında çeşitliliğe yol açar.

Veri ve Özellikleri

Bu çalışmada, Hatay iline ait 2015–2025 yılları arasındaki günlük ortalama hava sıcaklığı verileri Google Earth Engine üzerinden ERA5-Land veri kümesinden elde edilmiştir. Toplamda 3.643 günlük veri toplanmış ve analiz için hazır hâle getirilmiştir. Veriler, sıcaklık tahmini amacıyla girdi olarak yıl, ay ve gün özellikleriyle yapılandırılmıştır. Zaman serisi modeli geliştirmek üzere veri seti %70 eğitim ve %30 test olmak üzere ikiye ayrılmıştır. Bu yapılandırma, modelin genel performansını değerlendirmek ve genellenebilirliğini test etmek amacıyla uygulanmıştır.




Şekil 1. Hatay iline ait 2015–2025 dönemine ilişkin günlük ortalama sıcaklık değişimi.

Şekil 1 Hatay'da on yıllık süre boyunca gözlenen sıcaklık değerlerinin günlük düzeydeki değişimini yansıtmaktadır. Eğride yıl bazında tekrarlayan dalgalı yapı, bölgenin belirgin mevsimsel iklim desenlerini göstermektedir. Yaz aylarında sıcaklıklar 30 °C'nin üzerine çıkarken, kış aylarında 5 °C seviyelerine kadar düşmektedir. Bu düzenli salınım, zaman

serisinin mevsimselliğe duyarlı olduğunu ve iklimsel tahmin modellerinde bu yapının dikkate alınması gerektiğini göstermektedir. Ayrıca bazı yıllarda gözlenen ani sıcaklık sıçramaları, ekstrem meteorolojik olayların veya veri kaynağı etkilerinin potansiyel göstergesi olarak yorumlanabilir. Şekil genel olarak Hatay’da yıllar boyunca sıcaklık eğilimlerinin büyük ölçüde istikrarlı olduğunu ve güçlü bir mevsimsel yapı barındırdığını ortaya koymaktadır.

2.1 LSTM (Long Short-Term Memory)

LSTM modeli, zaman bağlı verilerde uzun süreli ilişkileri öğrenebilme yeteneğiyle bilinmektedir. Modelin katman yapısı, öğrenme oranı ve epoch sayısı hiperparametre optimizasyonu ile ayarlanmıştır. LSTM (Long Short-Term Memory), derin öğrenme ve özellikle zaman serisi verileriyle çalışırken kullanılan bir tür yapay sinir ağıdır. LSTM, RNN (Recurrent Neural Networks) modelinin bir çeşididir ve özellikle uzun vadeli bağımlılıkları öğrenmede oldukça etkilidir. Geleneksel RNN’ler, önceki adımların bilgilerini hatırlama konusunda sınırlıdır çünkü öğrenme sürecinde uzun vadeli bağımlılıkları tutma yetenekleri yoktur. LSTM, bu sorunu aşmak için özel bir yapıya sahiptir (Yu et al., 2009).



Şekil 2. LSTM çalışma yöntemi

Şekil 2’de LSTM’e ait genel çalışma prensibi diyagram şeklinde gösterilmiştir. Long Short-Term Memory (LSTM) ağlarının temel işlevlerini açıklamak için aşağıdaki denklemler kullanılır. Bu denklemler, LSTM hücrelerinin her bir ögesinin nasıl çalıştığını ve içsel durumları nasıl güncellediğini açıklamaktadır. LSTM, hücre durumu (cell state) adı verilen bir

mekanizma ile verilerin uzun süreli hatırlanmasına olanak tanımaktadır. Hücre durumu, ağın "hafızası" gibi çalışarak ve zaman içinde korunmaktadır. LSTM hücresinin giriş kapısı i_t , hücre durumuna ne kadar yeni bilginin dahil edileceğini belirleyen bir bileşendir. Bu kapı, zaman adımındaki giriş vektörü ve önceki zaman adımındaki gizli duruma bağlı olarak hesaplanır. Giriş kapısı aktivasyonu şu şekilde tanımlanır: (Denklem 1).

$$i_t = \sigma(W_i x_t + v_i h_{t-1} + b_i) \quad (1)$$

Burada; σ , sigmoid aktivasyon fonksiyonu olup, çıktıyı $[0,1]$ aralığına sıkıştırarak hücreye alınacak bilginin derecesini belirler. x_t , t zaman adımımda modele verilen giriş vektörünü ifade eder. h_{t-1} , bir önceki zaman adımımda ait gizli durum (hidden state) bilgisidir. W_i , giriş vektörüne uygulanan ağırlık matrisidir. v_i (veya bazı kaynaklarda U_i), önceki gizli duruma ait ağırlık matrisidir. b_i giriş kapısı için bias terimini temsil etmektedir. LSTM hücresinin önemli bileşenlerinden biri de unutma kapısıdır (forget gate). Unutma kapısı, önceki hücre durumundaki hangi bilgilerin korunacağını ve hangilerinin unutulacağını kontrol eder. Bu kapının aktivasyonu aşağıdaki şekilde tanımlanır: (Denklem 2).

$$f_t = \sigma(W_f x_t + v_f h_{t-1} + b_f) \quad (2)$$

f_t , unutma kapısı aktivasyonudur ve her bir hücre durumu bileşeni için $[0,1]$ aralığında bir değer üretir. Bu değer, hücre durumundaki bilginin ne ölçüde korunacağına karar verir. σ , sigmoid aktivasyon fonksiyonudur; lineer kombinasyonu $[0,1]$ aralığına indirger ve bilgi aktarım miktarını belirler. x_t mevcut zaman adımı t'deki giriş vektörünü ifade eder. h_{t-1} , bir önceki zaman adımımdaki gizli durumdur. W_f , giriş vektörüne uygulanan ağırlık matrisidir. v_f , önceki gizli duruma uygulanan ağırlık matrisidir. b_f , unutma kapısı için bias terimidir. LSTM hücresinde, giriş kapısı ve unutma kapısı ile birlikte hücre aday (candidate cell state) bileşeni de hücre durumunun güncellenmesinde kilit bir rol oynar. Hücre aday, mevcut giriş ve geçmiş duruma bağlı olarak hücreye eklenecek yeni bilgi içeriğini temsil eder. Aşağıdaki Denklem 3'te tanımlanır.

$$\hat{c}_t = \tanh(W_c x_t + v_c h_{t-1} + b_c) \quad (3)$$

$\hat{c}_t$ zaman adımı t'deki hücre aday durumudur. Bu, hücreye dahil edilmek üzere hesaplanan yeni bilgi vektörüdür. $\tanh$, hiperbolik tanjant aktivasyon fonksiyonudur. Çıktıyı $[-1, 1]$ aralığına sıkıştırarak hem pozitif hem negatif bilgi taşımayı mümkün kılar. x_t zaman adımı t'deki giriş

vektörünü ifade eder. h_{t-1} bir önceki zaman adımına ait gizli durumdur. W_c girişe ait ağırlık matrisidir. v_c , önceki gizli duruma ait ağırlık matrisidir. b_c , hücre adayı için bias terimidir.

LSTM mimarisinin temel avantajlarından biri, uzun vadeli bağımlılıkları koruyabilmesidir. Bu yetenek, hücre durumunun güncellenme biçimiyle doğrudan ilişkilidir. Hücre durumu c_t , geçmişten gelen bilgilerin ve yeni öğrenilen bilgilerin dengeli bir biçimde birleştirilmesiyle güncellenir. Bu işlem aşağıdaki denklem 4'te ifade edilir:

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (4)$$

c_t , zaman adımı t 'deki güncellenmiş hücre durumudur. f_t unutma kapısı aktivasyonudur; önceki hücre durumu c_{t-1} 'deki hangi bilgilerin korunacağını belirler. c_{t-1} , bir önceki zaman adımındaki hücre durumudur. i_t giriş kapısı aktivasyonudur; hücreye ne kadar yeni bilginin alınacağını belirler. $\tilde{c}_t$ hücre adayıdır; mevcut zamanda öğrenilen yeni bilgi içeriğini temsil eder. $\odot$, eleman bazında çarpım (Hadamard çarpımı) işlemini ifade eder. Bu formül ile LSTM hücresi, bir yandan geçmişten gelen bilgiyi $f_t \odot c_{t-1}$ terimiyle korurken, diğer yandan yeni bilgiyi $i_t \odot \tilde{c}_t$ terimiyle sisteme dahil eder. Böylece hem unutma hem de öğrenme aynı anda kontrollü biçimde gerçekleştirilmiş olur. Bu yapı, geleneksel RNN'lerin yaşadığı gradyan kaybolması sorununu azaltarak uzun süreli bağımlılıkların etkili bir şekilde öğrenilmesine olanak tanır.

LSTM mimarisinde çıkış kapısı, hücre durumundan ne kadar bilginin dışarıya (yani bir sonraki zaman adımının gizli durumu olarak) aktarılacağını kontrol eder. Bu kapının amacı, güncellenmiş hücre durumundan elde edilen bilgiyi, ağırlık dış katmanlarına veya sonraki zaman adımına aktarılmadan önce filtrelemektir. Çıkış kapısı Denklem 5'te şu şekilde tanımlanır:


$$o_t = \sigma(W_o x_t + v_o h_{t-1} + b_o) \quad (5)$$

o_t , zaman adımı t 'deki çıkış kapısı aktivasyonudur. σ , sigmoid aktivasyon fonksiyonudur; sonucu $[0,1]$ aralığına sıkıştırarak hangi bilginin çıkışa aktarılacağını belirler. x_t , mevcut zaman adımındaki giriş vektörüdür. h_{t-1} , bir önceki zaman adımındaki gizli durumdur. W_o , giriş vektörüne ait ağırlık matrisidir. v_o , önceki gizli duruma ait ağırlık matrisidir. b_o , çıkış kapısına ait bias terimidir.

Bu kapının çıktısı, güncellenmiş hücre durumu c_t 'nin bir tanh aktivasyonundan geçirilmiş haliyle birlikte kullanılarak nihai gizli durum (hidden state) h_t Denklem 6'daki şekliyle hesaplanmaktadır.

$$h_t = o_t \odot \tan h(c_t) \quad (6)$$

Bu yapı sayesinde, LSTM hücresi yalnızca önemli bulduğu bilgiyi bir sonraki zaman adımına veya ağ katmanına aktarır. Çıkış kapısı, öğrenme sürecinde bilginin ne kadarının dışa vurulacağını belirleyerek modelin seçici olmasını sağlar.



Şekil 3. LSTM Akış Diyagramı

2.2 XGBoost

XGBoost, karar ağaçlarını ardışık şekilde eğiterek hata oranını minimize eden ve çok sayıda öznitelik ile çalışabilen güçlü bir algoritmadır. Sıcaklık tahmini için gecikmeli değerler (lag features) ile model beslenmiştir. XGBoost (Extreme Gradient Boosting), karar ağaçlarına dayalı denetimli (supervised) bir makine öğrenmesi algoritmasıdır. Boosting yöntemiyle tahmin hatalarını minimize eder ve genellikle hem sınıflandırma hem de regresyon problemlerinde yüksek performans sağlar.

XGBoost (Extreme Gradient Boosting), karar ağaçları temelli güçlü ve optimize edilmiş bir topluluk öğrenme algoritmasıdır. Bu yöntem, ardışık şekilde eğitilen zayıf öğrenciler (genellikle karar ağaçları) yardımıyla tahmin hatalarını minimize etmeyi amaçlayan bir **boosting** tekniğine dayanmaktadır. Sıcaklık tahmininde, model geçmiş sıcaklık değerlerinin gecikmeli versiyonları (lag features) ile beslenerek zaman serilerinin içsel bağımlılıkları yakalanmıştır. XGBoost, boosting çerçevesinde çalışır; yani her bir zayıf model (karar ağacı), önceki modellerin yaptığı hataları azaltmaya yönelik olarak eğitilir. Bu yaklaşım, modelin kümülatif hatasını azaltmakta etkili bir yol sunar. Bu ardışık modelleme süreci, tahmin performansını artırırken genel hatayı da düşürür. XGBoost, gradyan artırılmalı karar ağaçları (Gradient Boosted Decision Trees, GBDT) temeline dayanmaktadır. Modelin hatasını ölçmek için kullanılan kayıp fonksiyonu, her iterasyonda gradyan inişi (gradient descent) yöntemiyle minimize edilir. Böylece her yeni model, önceki modelin ürettiği hataya karşılık gradyan yönünde iyileştirme sağlar. XGBoost'u klasik gradient boosting algoritmalarından ayıran en önemli özelliklerden biri, düzenleme (regularization) terimlerini içermesidir. Model karmaşıklığını kontrol etmek amacıyla L1 (lasso) ve L2 (ridge) normlarına dayalı ceza terimleri kullanılır. Bu durum, aşırı öğrenme (overfitting) riskini azaltmakta ve modelin genelleme yeteneğini artırmaktadır. XGBoost, derin ve karmaşık karar ağaçları inşa edebilme kapasitesine sahiptir. Bu özellik, veri seti içerisinde yer alan karmaşık ve doğrusal olmayan ilişkilerin başarıyla yakalanmasını sağlar. Özellikle çok sayıda öznitelik içeren veri setlerinde etkili sonuçlar üretir (Chen, T., & Guestrin, C., 2016).

2.2.1. Tahmin Fonksiyonu

XGBoost, toplam K adet zayıf modelin (karar ağaçlarının) çıktılarının toplamını alarak tahmin yapar:

$$\hat{y}_i = \sum_{k=1}^K f_k(\chi_i), f_k \in \mathcal{F} \quad (7)$$

Burada; $\hat{y}_i$, i. gözlem için modelin yaptığı tahmini, K, Toplam ağaç sayısını; f_k , k. karar ağacı (zayıf model), $\mathcal{F}$: Karar ağaçlarının uzayı (örneğin, derinliği sınırlı ağaçlar) temsel etmektedir.

2. Amaç Fonksiyonu (Objective Function)

Modelin öğrenmesi sırasında optimize edilen toplam kayıp fonksiyonu Denklem 8'deki gibidir.

$$\mathcal{L}(\phi) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \Omega(f_k) \quad (8)$$

$\mathcal{L}(\phi)$, Kayıp fonksiyonu (örneğin, mse, logloss); $\Omega(f)$, Model karmaşıklığını cezalandıran düzenleme terimi; $\hat{y}_i^{(t)}$ ise t. iterasyondaki tahmini temsil etmektedir.

3. Model Karmaşıklığı Ceza Terimi (Regularization)

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (9)$$

T Ağaçtaki yaprak sayısını, w_j : j. yaprağın skoru γ , λ : Düzenleme parametrelerini temsil etmektedir. Bu yapı sayesinde XGBoost, yalnızca düşük hataya sahip modelleri değil, aynı zamanda **genelleme kapasitesi yüksek**, aşırı öğrenmeye dirençli modeller üretmeyi amaçlar. Amaç fonksiyonunun ikinci terimi, gereksiz derecede karmaşık ağaçların oluşmasını engeller ve algoritmanın güçlü bir düzenleme mekanizmasına sahip olmasını sağlar.

4. 2. Dereceden Taylor Yaklaşımı ile Optimizasyon

XGBoost'un en önemli özelliklerinden biri, amaç fonksiyonunun ikinci dereceden Taylor açılımı kullanılarak yaklaşıklaştırılmasıdır. Bu yaklaşım, her boosting iterasyonunda yeni eklenecek zayıf öğrenicinin (karar ağacının) modelin toplam kaybını ne ölçüde azaltacağını hızlı ve analitik olarak hesaplamaya olanak tanır. Boosting sürecinde, t. iterasyondaki tahmin $\hat{y}_i^{(t)}$ bir önceki iterasyonun çıktısına $f(i)x(i)$ fonksiyonunun eklenmesiyle güncellenir. Bu durumda, amaç fonksiyonu yaklaşık olarak Denklem 10'daki şekilde ifade edilir.

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n \left[g_i, f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (10)$$


Burada g_i birinci türev (gradient), h_i ikinci türev (hessian), $f_i(x)$ yeni eklenecek ağaç sayısını temsil etmektedir.

5. En İyi Bölünmenin Skoru (Gain)

XGBoost algoritmasında karar ağaçları oluşturulurken, her bir dalın (split) modelin genel kaybını ne kadar azaltacağı değerlendirilerek en uygun bölünme noktası seçilir. Bu işlem sırasında kullanılan ölçüt, split gain olarak adlandırılan kazanç fonksiyonudur. Split gain, önerilen bir bölünmenin modelin amaç fonksiyonunda sağlayacağı iyileşmeyi (kayıp azalımını) hesaplar. Önerilen bir bölünme sonucunda elde edilecek kazanç aşağıdaki Denklem 11'deki şekliyle hesaplanmaktadır.

$$Gain = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (11)$$

G_L , Sol yaprağa düşen örneklerin toplam gradyanı, H_L Sol yaprağa düşen örneklerin toplam Hessian değeri (ikinci türev), G_R Sağ yaprağa düşen örneklerin toplam gradyanı, H_R Sağ yaprağa düşen örneklerin toplam Hessian değeri, λ L2 düzenleme katsayısı (overfitting'i azaltmak için), γ yeni bir yaprak oluşturma maliyetini kontrol eden düzenleme parametresini temsil etmektedir.



Şekil 4. XGBoost Algoritması Akış Şeması

Değerlendirme Ölçütleri

Ortalama Kare Hatası-MSE

Gerçek değerler ile model tarafından tahmin edilen değerler arasındaki farkların karesinin ortalamasını ifade eder. Bu metrik, hata büyüklüğünü dikkate alır ve özellikle büyük hataları daha fazla cezalandırır. Bu yönüyle modelin büyük hatalardan kaçınma performansını vurgular. Küçük hataları göz ardı etmez; ancak hata terimlerinin karesi alındığı için uç değerler (aykırı gözlemler) üzerinde daha hassas bir değerlendirme sunar. MSE, literatürde sıkça kullanılan duyarlı bir doğruluk ölçütüdür. Aşağıdaki Eşitlik 1’de gösterildiği üzere; burada N veri sayısını, y_j gerçek (gözlemlenen) değeri ve $\hat{y}_j$ model tarafından tahmin edilen değeri ifade etmektedir (Denklem 12).

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad (12)$$

R-Kare (R² veya Belirleme Katsayısı)

R² katsayısı, bağımlı değişkendeki varyansın ne kadarının model tarafından açıklandığını gösteren bir performans ölçütüdür. Bir başka deyişle, modelin veriyi ne ölçüde açıkladığını ifade eder. R² değeri, modelin tahmin gücünü değerlendirmede önemli bir göstergedir. Bu değer 1'e yaklaştıkça, model hedef değişkendeki varyansı daha iyi açıklamış olur. R²'nin 0.0 olması modelin veriyi hiç açıklayamadığını, 1.0 olması ise tamamen açıkladığını gösterir. Yorumu oldukça kolaydır ve çoğu durumda modelin başarısı hakkında hızlıca fikir verebilir. Ancak, R² değerinin yüksek olması her zaman modelin üstün olduğunu göstermez. Özellikle aşırı karmaşık modellerde, R² yüksek olsa dahi aşırı öğrenme (overfitting) durumu söz konusu olabilir. Bu nedenle R², diğer performans ölçütleriyle birlikte değerlendirilmelidir (Denklem 13).

$$R^2 = 1 - \frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{\sum_{j=1}^N (y_j - \bar{y})^2} \quad (13)$$

Ortalama Mutlak Hata (MAE – Mean Absolute Error)

Ortalama Mutlak Hata (MAE), bir modelin tahmin performansını değerlendirmede yaygın olarak kullanılan, sezgisel olarak anlaşılması kolay ve yorumlanabilir bir hata metriğidir. Bu metrik, gözlemlenen (y_j) ve model tarafından tahmin edilen ($\hat{y}_j$) değerler arasındaki farkların mutlak değerlerinin aritmetik ortalamasını ifade eder. MAE, tüm hataları eşit ağırlıkla değerlendirir ve tahmin edilen değişkenle aynı birime sahip olması nedeniyle doğrudan fiziksel yorumlamaya olanak tanır (Denklem 14).

$$MAE = \frac{1}{N} \sum_{j=1}^N \left[\frac{|y_j - \hat{y}_j|}{y_j} \right] \quad (14)$$

3. Bulgular ve Değerlendirme


Bu çalışmada, günlük ortalama hava sıcaklığı tahmini amacıyla LSTM ve XGBoost algoritmalarının performansları karşılaştırılmıştır. Modeller, 2015–2025 dönemine ait zaman serisi verileriyle eğitilmiştir. Eğitim verileri üzerinde XGBoost algoritması, yaklaşık 1.91 ortalama kare hatası (MSE) ve 1.02 mutlak hata (MAE) ile oldukça yüksek doğruluk sağlamıştır. Aynı modelin karar katsayısı ise 0.983 düzeyinde gerçekleşmiştir. Buna karşılık, LSTM modeli eğitim aşamasında yaklaşık 6.12 MSE ve 1.86 MAE değerleri üretmiş; karar katsayısı 0.935 olarak hesaplanmıştır. Bu sonuçlar, XGBoost’un eğitim verisine yüksek düzeyde uyum sağladığını göstermektedir. Ancak test verisi üzerinde yapılan değerlendirmede LSTM modeli, yaklaşık 7.01 MSE, 1.99 MAE ve 0.947 karar katsayısı ile daha dengeli bir performans ortaya koymuştur. XGBoost’un test setindeki karşılık gelen değerleri sırasıyla 7.43, 2.06 ve 0.931 olarak bulunmuştur. Tablo X’te ayrıntılı olarak sunulan bu bulgular, XGBoost’un eğitim verisinde üstün başarı gösterdiğini, ancak LSTM modelinin test verisindeki genel başarımıyla daha iyi genellenebilirlik sağladığını ortaya koymaktadır. Bu yönüyle LSTM, uzun dönemli iklimsel tahminler için daha istikrarlı bir seçenek olarak değerlendirilebilir.

Tablo 1. Değerlendirme Metrikleri

	<i>Train</i>			<i>Test</i>		
	MSE	R ²	MAE	MSE	R ²	MAE
<i>LSTM</i>	6.1221	0.935	1.8636	7.0108	0.947	1.9927
<i>XGBOOST</i>	1.9138	0.983	1.0238	7.4388	0.931	2.0695


Tablo 1’de, değerlendirilen modelin eğitim ve test verisi üzerindeki performansı, Ortalama Kare Hatası (MSE), Ortalama Mutlak Hata (MAE) ve Belirleme Katsayısı (R²) ölçütleri kullanılarak sunulmuştur. Modelin eğitim verisindeki MSE ve MAE değerleri sırasıyla 6.1221 ve 1.8636 iken, R² değeri 0.935 olarak elde edilmiştir. Test verisinde ise MSE 7.0108, MAE 1.9927 ve R² 0.947 olarak hesaplanmıştır. Alternatif bir modelin performansı incelendiğinde, eğitim verisi üzerinde daha düşük MSE (1.9138) ve MAE (1.0238) ile birlikte daha yüksek bir R² (0.983) değeri elde ettiği görülmektedir. Ancak test verisinde bu modelin MSE değeri 7.4388’e, MAE değeri 2.0695’e yükselirken R² değeri 0.931’e düşmüştür.

Bu sonuçlar, ilk modelin test verisinde daha düşük hata değerleriyle daha güçlü bir genelleme yeteneğine sahip olduğunu; diğer modelin ise eğitim verisine yüksek düzeyde uyum sağlamakla birlikte test performansında görece bir düşüş yaşadığını göstermektedir. Bu durum, ikinci modelin aşırı öğrenmeye daha yatkın olabileceğine işaret etmektedir.



Şekil 5. LSTM modelinin eğitim (a) ve test (b) veri setleri üzerindeki tahmin performans grafikleri.

Şekilde, LSTM modelinin günlük sıcaklık tahminlerine ilişkin doğruluk düzeyi eğitim ve test veri setleri için ayrı ayrı gösterilmiştir. Eğitim verisinde tahmin edilen sıcaklıklar ile gözlenen değerler arasında yüksek bir doğrusal ilişki gözlenmekte olup, karar katsayısı yaklaşık 0.935 olarak hesaplanmıştır. Test veri seti için ise bu katsayı 0.947 seviyesine ulaşarak modelin güçlü bir genellenebilirlik yeteneğine sahip olduğunu göstermektedir. Her iki grafikte de tahmin değerleri 1:1 doğrusuna yakın konumlanmış olup, sapmaların düşük düzeyde kaldığı görülmektedir. Ayrıca test verisindeki regresyon eğrisinin birime daha yakın eğim göstermesi, modelin gerçek değerlerle daha dengeli tahminler ürettiğini göstermektedir. Bu sonuçlar, LSTM mimarisinin zamana bağlı sıcaklık verilerinde hem öğrenme hem de tahmin açısından başarılı bir yaklaşım sunduğunu ortaya koymaktadır.



Şekil 6. XGBOOST modelinin eğitim (a) ve test (b) veri setleri üzerindeki tahmin performans grafikleri.

Şekilde, XGBoost algoritmasının günlük sıcaklık tahmini performansı hem eğitim hem de test verileri için sunulmaktadır. Eğitim verisi üzerinde model oldukça yüksek bir doğruluk sergilemiş, karar katsayısı 0.983 olarak hesaplanmıştır. Aynı grafik üzerinde gözlenen $y=0.955x+0.90$ denklemi, tahminlerin gerçek değerlere oldukça yakın bir dağılım gösterdiğini işaret etmektedir. Test seti için elde edilen karar katsayısı ise 0.931 olup, modelin genellenebilirlik başarısının yüksek düzeyde olduğunu göstermektedir. Test verisine ilişkin regresyon doğrusunun eğimi 0.880 olup, hafif bir sapma eğilimi görülse de genel dağılım 1:1 doğrusu çevresinde yoğunlaşmaktadır. Bu durum, XGBoost modelinin test verisi üzerinde de kararlı tahminler üretebildiğini, ancak eğitim verisindeki kadar güçlü bir uyum sergileyemediğini ortaya koymaktadır. Genelde her iki grafik de modelin sıcaklık tahminlerinde başarılı sonuçlar verdiğini göstermekte olup, özellikle eğitim aşamasında XGBoost'un yüksek performansı dikkat çekicidir.

4. Sonuç ve Öneriler

Hatay iline ait sıcaklık verileri kullanılarak LSTM ve XGBoost modelleriyle yapılan zaman serisi tahminleri, her iki modelin de yerel iklim verileri üzerinde başarılı olduğunu ortaya koymuştur. Ancak XGBoost algoritması, daha düşük hata oranları ve daha yüksek

determinasyon katsayısı ile LSTM'ye kıyasla üstün performans göstermiştir. Bu çalışma, iklim verilerinin tahmininde yapay zekâ tabanlı yaklaşımlarla elde edilebilecek başarıyı göstermekte ve yerel karar destek sistemlerine bilimsel bir temel sunmaktadır. Gelecekte çok değişkenli (nem, yağış, rüzgâr vb.) modellemelerin entegrasyonu ile tahmin doğruluğunun daha da artması beklenmektedir.

5. Kaynakça

- Ahmed, R., Seraj, S., & Ghosh, S. (2021). Deep learning models for forecasting temperature in climate science. *Environmental Modelling & Software*, 144, 105157. <https://doi.org/10.1016/j.envsoft.2021.105157>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Cheng, L., AghaKouchak, A., & Gilleland, E. (2021). Evaluation of LSTM networks for temperature prediction in varying climates. *Scientific Reports*, 11(1), 12257. <https://doi.org/10.1038/s41598-021-91757-w>
- Çoban, E. (2025). LSTM ve hibrit CNN–LSTM derin öğrenme yaklaşımları ile Isparta ili için zaman serisi tabanlı sıcaklık tahmini. *Uluborlu Mesleki Bilimler Dergisi*, 8(3), 104–117. <https://doi.org/10.71445/umbd.1761095>
- Gong, Y., Zhang, Y., Wang, F., & Lee, C. (2024). Deep learning for weather forecasting: A CNN-LSTM hybrid model for predicting historical temperature data. *Applied and Computational Engineering*, 99(1). <https://doi.org/10.54254/2755-2721/99/20251758>
- Huang, X., Zhuang, X., Tian, F., Niu, Z., Chen, Y., Qian, Z., & Yuan, C. (2025). A hybrid ARIMA-LSTM-XGBoost model with linear regression stacking for transformer oil temperature prediction. *Energies*, 18(6). <https://doi.org/10.3390/en18061432>
- IPCC. (2021). *Climate change 2021: The physical science basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press.
- Karevan, Z., & Suykens, J. A. K. (2020). Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125, 1–9. <https://doi.org/10.1016/j.neunet.2019.12.030>
- Kalkınç, H. Y., Çoban, E., & Güçlü, Y. S. (2025). Wilcoxon testi ve saçılma diyagramı kullanılarak hidrometeorolojik verilerin trend analizi. *Turkish Journal of Civil Engineering*, 36(5), 1–31. <https://doi.org/10.18400/tjce.1630037>

- Liu, H., Yin, J., Zhang, J., & Wang, Y. (2022). Hybrid XGBoost and LSTM model for temperature time series prediction. *Applied Energy*, 306, 117944. <https://doi.org/10.1016/j.apenergy.2021.117944>
- Mishra, S., Singh, N., & Raghuwanshi, N. S. (2020). Predicting daily temperature using LSTM and GRU models. *Meteorological Applications*, 27(3), e1935. <https://doi.org/10.1002/met.1935>
- Qiu, R., Wang, Y., Rhoads, B. L., Wang, D., Qiu, W., Tao, Y., & Wu, J. (2021). River water temperature forecasting using a deep learning method. *Journal of Hydrology*, 595, 126016. <https://doi.org/10.1016/j.jhydrol.2021.126016>
- Uluocak, I., & Bilgili, M. (2024). Daily air temperature forecasting using LSTM-CNN and GRU-CNN models. *Acta Geophysica*, 72, 2107–2126. <https://doi.org/10.1007/s11600-023-01241-y>
- Wang, H., Zhang, J., & Yang, J. (2024). Time series forecasting of pedestrian-level urban air temperature by LSTM: Guidance for practitioners. *Urban Climate*, 50, 102063. <https://doi.org/10.1016/j.uclim.2024.102063>
- Wang, Y., & Guo, Y. (2020). Forecasting method of stock market volatility in time series data based on mixed model of ARIMA and XGBoost. *China Communications*, 17(3), 172–182. <https://doi.org/10.23919/jcc.2020.03.017>
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural Computation*, 31(7), 1235–1270.
- Zhang, N., Mao, T., Chen, H., Lv, L., Wang, Y., & Yan, Y. (2023). Temperature prediction for expressway pavement icing in winter based on XGBoost–LSTNet variable weight combination model. *Journal of Transportation Engineering, Part A: Systems*, 149(2). <https://doi.org/10.1061/jtepbs.teeng-7670>
- Zhao, Y., Chen, M., & Wang, J. (2020). Temperature forecasting using LSTM networks: A case study in China. *Atmosphere*, 11(2), 226. <https://doi.org/10.3390/atmos11020226>

BÖLÜM 5

IOT VE BULUT BİLİŞİM TABANLI KESTİRİMCİ BAKIM

EMİN ÖZTÜRK¹
AZİZ KUBİLAY OVACIKLI²

Giriş

Üretim yapan işletmelerin faaliyetlerini kesintisiz bir şekilde sürdürebilmesi, siparişlerini yönetebilmesi ve bakım masraflarını en aza indirebilmek için dikkat etmeleri gereken en önemli konulardan biri makine sağlığıdır. Özellikle döner makinelerde oluşacak beklenmeyen arızalar, hem iş gücü ve üretim kaybına hem de maliyet artışına yol açmaktadır. Artan maliyetleri düşürmek ve üretim verimliliğini arttırmak için zaman içerisinde makine sağlığını korumaya yönelik farklı bakım yöntemleri geliştirilmiştir. Geleneksel bakım yöntemleri arasında yer alan ve arıza gerçekleşikten sonra müdahaleyi kapsayan arıza bakım ile belirli aralıklarla yapılan periyodik bakım, üretim duruşlarına tam olarak çözüm sağlamamaktadır. Ayrıca arızanın kaynağının doğru

¹ Bilgisayar Mühendisi, Environics Uygulamalı Bilimler A.Ş., Namık Kemal Üniversitesi Teknopark, Orcid: 0009-0008-6107-5993

² Dr., İstanbul Arel Üniversitesi, Mühendislik Mimarlık Fakültesi, Yazılım Mühendisliği Bölümü, Orcid: 0000-0001-6687-7794

şekilde belirlenememesi, gereksiz parça değişimlerine yol açarak bakım maliyetlerini artırmaktadır (Gürsoy & ark., 2019:56).

Geleneksel bakım yöntemlerinin yetersizliği zaman içerisinde daha modern bir yaklaşım olan kestirimci bakım yönteminin ortaya çıkmasını sağlamıştır. Kestirimci bakım, makinelerden sensörler aracılığıyla toplanan titreşim, sıcaklık, ultrases, akım, tork ve debi gibi verilerin analiz edilmesi ile sorunları erken aşamalarda tespit etmeyi hedefleyen modern bir bakım stratejisidir. Bu yöntem sayesinde kontrolsüz üretim duruşlarının önüne geçilmiş ve bakım maliyetlerinde azalmalar sağlanmıştır (Arora & ark., 2024:375).

Yapılan araştırmalar kontrolsüz ve öngörülemeyen duruşların işletmeler için ciddi maliyet artışlarına neden olduğunu göstermektedir. Bakım için yapılan harcamalar, elde edilen ürün maliyetinin %15 ila %60'ını oluşturmaktadır (Romanssini & ark., 2023:1797). Bakım için harcanan zaman, enerji ve iş gücünde oluşan kayba ek olarak ürün maliyetlerinde meydana gelen artışlar da son kullanıcıları olumsuz etkilemektedir. Bu sorunların önüne geçmek ve verimliliği artırmak için özellikle son yıllarda Nesnelerin İnterneti (IoT) alanında yaşanan gelişmelerin de katkısıyla kestirimci bakım alanında yapılan çalışmalarda artış gözlenmektedir.

Endüstri 4.0 kapsamında geliştirilen IoT tabanlı sensörler, kestirimci bakım uygulamalarının yaygınlaşmasında kritik bir öneme sahiptir. Kablosuz sensörler aracılığıyla toplanan veriler bulut ortamına gönderilmekte ve burada analiz edilmektedir. Böylece makinelerin sürekli olarak izlenmesi mümkün hale gelmiştir. Özellikle döner ekipmanlardan elde edilen titreşim verilerinin bulut tabanlı analiz teknikleriyle işlenmesi, arızaların erken aşamalarda tespit edilmesini sağlamaktadır (Ovacıklı & ark., 2025:1).

Bu bölümde, kestirimci bakım ile geleneksel bakım yöntemleri ve IoT cihazlar, bulut bilişim, titreşim analizi yöntemleri ele alınacaktır. Çalışmanın amacı endüstri 4.0 kapsamında gelişen modern bakım yaklaşımlarını incelemek ve işletmelere sağladığı katkıları açıklamaktır.

Bakım Kavramı ve Türleri

Bakım kavramı, makinelerin işlevselliğini sürdürebilmesi için yapılan faaliyetleri ifade etmektedir. Amacı, arıza başlamasını engellemek, oluşan arızaları gidermek ve makinenin performansını korumaktır. Makine bakımı ve sağlığı konularının işletmeler için kritik önemde olmasından dolayı zaman içerisinde pek çok bakım yöntemi geliştirilmiştir. Geleneksel bakım yöntemlerinden olan arızı ve periyodik bakım ile modern bakım yöntemlerinden olan kestirimci bakım en yaygın kullanılan yöntemlerdir.

Arızı bakım, makinede arıza meydana geldikten sonra bakım yapmayı kapsayan bir yaklaşımdır. Bakım yapmak için makinenin beklenmedik bir şekilde durması veya üretim performansında ciddi bir azalma olması beklenir. Sorun meydana geldikten sonra üretimi durdurarak sorunun makinedeki hangi alt bileşenden kaynaklandığı belirlenmeye çalışılır. Sorunlu parçanın yerine yenisinin hemen bulunmaması durumunda üretim sürecinde ciddi aksamalar meydana gelmektedir. Olumsuz yanlarının fazla olmasına rağmen her işletmede makine bakımı alanında bir uzmanın bulunmamasından dolayı (özellikle tekstil sektöründe) az da olsa kullanılan bir yöntemdir. (Ceyhan & Kasapbaşı, 2022:167).

Periyodik bakım, makine için belirlenecek olan periyotlarda bakım yapmayı kapsayan bir yaklaşımdır. Sürekli yapılan bakımlar sayesinde sorunlar oluşmadan önce önlem almak mümkün olmaktadır. Bu sayede beklenmeyen üretim duruşlarının önüne geçilmektedir. Bu yöntemin dezavantajı bakım periyotlarının doğru bir şekilde belirlenmesindeki zorluk ve sorun olmadığı halde

yapılan bakımlardan kaynaklanan maliyet artışıdır (Sunetcioglu & Arsan, 2024:344).

Geleneksel bakım yöntemlerinin işletmeler için kritik önemde olan plansız duruşları ve bakım maliyetlerindeki artışı engelleyememesi kestirimci bakımın ortaya çıkmasını imkan tanımıştır.

Kestirimci bakım, makinelerden toplanan verilerin analiz edilmesi ile oluşacak arızayı erken aşamalarda tespit etmeyi hedefleyen modern bir bakım yöntemidir (Chu & ark., 2024:1). Yöntem sensörler aracılığıyla toplanan sıcaklık, titreşim, ultrases gibi verilerin analiz edilmesi üzerine kuruludur. Temel amacı arızaları erken aşamalarda tespit ederek plansız duruşları önlemek ve bakım maliyetlerinin en aza indirmektir.

Geleneksel bakım yöntemlerinden farklı olarak zaman ve gözleme dayalı bir yaklaşım yerine *veri temelli* bir yaklaşım benimsemektedir. Bu sayede hem gereksiz parça değişiminin önüne geçilmiş hem de makinedeki bileşenlerin verimli bir şekilde kullanılmasını sağlanmaktadır.

IoT ve Bulut Bilişim Temelleri

IoT teknolojileri, işletmelerde yer alan fiziksel cihazların çeşitli haberleşme protokolleri ve internet bağlantısı kullanarak birbirleri ile haberleşmesini sağlayan bir teknolojidir. Endüstri 4.0 ile birlikte işletmelerde dijitalleşme kavramı önem kazanmaya başlamıştır. Özellikle IoT ve bulut bilişim alanında yaşanan gelişmeler dijitalleşme sürecinin hızlanmasını ve kestirimci bakım uygulamalarının yaygınlaşmasını sağlamıştır.

IoT tabanlı sensörler makinelerden sıcaklık, titreşim, ultrases, akustik gibi kestirimci bakım uygulamalarının ihtiyaç duyduğu ve olası mekanik arızalara ait verileri toplamakta ve bulut


ortamına aktarmaktadır. Veriler bulut ortamının yüksek işlem gücünden yararlanılarak analiz edilir.

IoT ve kestirimci bakım ilişkisi

Kestirimci bakımda en önemli unsur ve en temel bileşen doğru parametreler ile toplanmış veridir. Verinin toplanma sürecinde oluşacak herhangi bir sorun yapılacak olan analizleri doğrudan etkilemektedir. Bu hataları önlemek için IoT teknolojileri kritik öneme sahiptir. Makinelerin üzerine yerleştirilen kablosuz sensörler sayesinde gerçek zamanlı ve tam olarak makinenin çalışma koşullarını ifade eden veriler toplanmaktadır (Öztürk & Ovacıklı, 2025). Sensörler toplanan verileri kablosuz haberleşme teknolojisini olan Wi-Fi'yi kullanarak endüstriyel ağ geçitlerine gönderirler (Baloğlu & Karademiroğlu, 2019:22). Ağ geçitlerine ulaşan veriler ara yazılım kullanılarak bulut ortamındaki sunucuya gönderilir. Sunucuya ulaşan veriler kestirimci bakımın yöntemlerinden biri olan titreşim analizi yöntemleri kullanılarak analiz edilir (Yuan & ark., 2021:345). Elde edilen analiz sonuçları geliştirilen web arayüzü sayesinde kullanıcıya bildirilir.

Makineden alınan verinin analiz sürecine kadar takip ettiği yol aşağıdaki şekilde gösterilmektedir.

Şekil 1 Döner ekipmanlardan veri toplanması, buluta aktarılması ve bulut ortamında analiz edilmesi süreci



Kaynak: Yazar tarafından üretildi.

Titreřim Analizi Yöntemleri

Titreřim analizi, sensörler aracılığı ile toplanan titreřim verilerini kullanarak makine saęlığı hakkında çıkarım yapılmasını saęlayan bir kestirimci bakım yöntemidir. Ařaęıda sık kullanılan bazı titreřim analiz yöntemleri açıklanacak ve örnek bir makine verisi üzerinden elde edilen sonuçlar gösterilecektir.

Skewness

Skewness, verinin olasılık daęılımının simetrik bir yapıda olup olmadığını belirlemek için kullanılır. Ařaęıda yer alan denklem ile hesaplanır.

$$Skewness = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^3$$

Sonuç pozitif olması verinin olasılık daęılımının sola yatık, negatif olması ise saęa yatık olduęu anlamına gelmektedir. Düzgün çalışan bir makinede bu deęer sıfıra yakındır.

Kurtosis

Kurtosis, bir daęılımın uç deęerler açısından normal daęılımdan ne kadar farklı olduęunu gösterir. Ařaęıda yer alan denklem ile hesaplanır.

$$Kurtosis = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^4$$

Sonuç 3'ten büyükse daęılım sivri, 3'ten küçük ise daęılım basıktır. Düzgün çalışan bir makinede bu deęer 3'e yakındır.

RMS ivme

RMS (Root Mean Square), toplanan titreřim verisinin ortalama enerji düzeyini belirlemek için kullanılan bir yöntemdir. Ařaęıda yer alan denklem ile hesaplanır.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n a_i^2}$$

Hesaplanan RMS deęerinin dūřuk olması makinenin saęlıklı olduęu anlamına gelirken yūksək RMS deęeri makinede bir arıza olabileceęi ve yūksək titreřim hareketi yaptıęı anlamına gelmektedir.

Crest Factor

Crest factor, verinin toplanması esnasında geręekleřen kısa sūreli fakat yūksək genlikli vuruntuları tespit etmek iin kullanılan bir yōntemdir. Ařaęıda yer alan denklem ile hesaplanır.

$$Crest\ Factor = \frac{Tepe\ Deęeri}{RMS\ Deęeri}$$

Saęlıklı alıřan bir makinede bu deęer 1,4-5 arasındadır. Bunu ūzerinde bir deęerde olması makinedeki olası arızaları iřaret etmektedir.

Titreřim verilerinin analizi

Makinede oluřabilecek arızaları erken ařamalarda tespit edebilmek iin titreřim analizi ıktıları dikkatli bir řekilde incelenmelidir. İstatistiksel titreřim analizi yōntemleri oluřan arızanın tūrū ve řiddeti hakkında bilgi vermektedir (Ovacıklı & ark., 2025:1).

Tablo 1 Analiz sonularının yorumlanması

Arıza Tūrū	Skewness	Kurtosis	RMS İvme	Crest Factor
Rulman Ařınması	Pozitif	4 ve ūzeri	Artar	Artar
Mil Dengesizlięi	Nōtr	3 civarı	Artar	Hafif artar
Hizasızlık	Negatif	3-4 arası	Artar	Artar
Gevřek Baęlantılar	Negatif veya pozitif	4-6 arası	Artar	Belirgin artar
Diřli Ařınması	Pozitif	4 civarı	Artar	Artar
Yaęlama Eksiklięi	Pozitif	4-5 arası	Artar	Artar

Kaynak: Yazar tarafından ūretildi.

Kestirimci Bakımın İşletmelere Faydaları

Makine sağlığının belirli standartlarda tutulması işletme giderlerinin önemli bir kısmını oluşturmaktadır. Makinelerin plansız duruşu ve arızanın tam olarak hangi makine bileşeninden kaynaklandığını tespit etmenin zor olması bakım süresinin uzamasına dolayısıyla bakım giderlerinin artmasına neden olmaktadır. Kestirimci bakım, plansız duruşların önüne geçerek bakım maliyetlerini azaltmayı ve verimliliği arttırmayı hedeflemektedir. Veri üzerinde yapılan analizler sonucunda sorunun tam olarak hangi makine bileşeninden kaynaklandığı belirlenebilir.

Kestirimci bakım sayesinde imalat sanayi gereksiz parça değişimlerinin, üretim ve iş gücü kayıplarının önüne geçmektedir. Kontrolsüz duruşlar önlenerek hem enerji verimliliği artmakta hem de ürün kalitesi üzerindeki olumsuz etkiler ve fiyat baskısı azalmaktadır. Kestirimci bakım, işletmelerin enerji ve diğer kaynaklarını daha verimli kullanmalarını, bakım planlamasını en iyi hale getirmelerini ve uzun vadede rekabet güçlerini artırmalarını sağlamaktadır.

Kaynakça

Arora, J.K. & Rajagopalan, S. & Singh, J. & Purohit, A. (2024). Low-frequency adaptation-deep neural network-based domain adaptation approach for shaft imbalance fault diagnosis. *Journal of Vibration Engineering & Technologies*, 12(1), 375-394.

Baloğlu, A. & Karademiroğlu, O. (2019). Akıllı şehirlerde kablosuz haberleşme teknolojileri ve doğru teknoloji seçimi. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1), 22-29.

Ceyhan, H. & Kasapbaşı, M.C. (2022). Üretim sistemlerinde makine öğrenmesi ile kestirimci bakım uygulaması ve modellemesi. *Avrupa Bilim ve Teknoloji Dergisi*, 33(1), 167-175.

Chu, T. & Nguyen, T. & Yoo, H. & Wang, J. (2024). A review of vibration analysis and its applications. *Heliyon*, 10(2), 1-13.

Gürsoy, M.Ü. (2019). Endüstri için kestirimci bakım. *International Journal of 3D Printing Technologies and Digital Industry*, 3(1), 56-66.

Ovacıklı, A.K. & Yağcıoğlu, M. & Demircioğlu, S. & Kocatekin, T. & Birtane, S. (2025). Supervised Learning-Based Fault Classification in Industrial Rotating Equipment Using Multi-Sensor Data. *MDPI*, 15(13), 1-27.

Öztürk, E. & Ovacıklı, A.K. (2025). Endüstride Bulut Bilişim Tabanlı Kestirimci Bakım ve Denetimsiz Titreşim Analizi Uygulaması. *International Journal of 3D Printing Technologies and Digital Industry*, 9(3).

Romanssini, M. & C. de Aguirre, P.C. & Compassi-Severo, L. & Girardi, A.G. (2023). A review on vibration monitoring

techniques for predictive maintenance of rotating machinery. *MDPI*, 4(3), 1797-1917.

Sunetcioglu, S. & Arsan, T. (2024). Predictive Maintenance Analysis for Industries. *2024 IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom)*, 2024, 344-347, Gürcistan, IEEE.

Yuan, X. & He, Y. & Wan, S. & Qiu, M. & Jiang, H. (2021). Remote vibration monitoring and fault diagnosis system of synchronous motor based on internet of things technology. *JMobile Information Systems*, 2021(1), 345-624.

BÖLÜM 6

6G AĞLARINDA PERFORMANS–GÜVENLİK ETKİLEŞİMİ: OPERASYONEL METRİKLERİN GÜVENLİK DOĞRULUĞUNA ETKİSİ

MERT YAĞCIOĞLI¹

Giriş

Altıncı nesil (6G) mobil ağlar, insan merkezli iletişimden makine merkezli otonom sistemlere geçişi hızlandırarak, toplumun dijital dönüşümünü derinleştirmeyi amaçlayan yeni bir paradigma olarak değerlendirilmektedir (Ata, 2023:1030). 6G'nin hedefleri; terabit düzeyinde veri hızları, mikrosaniye ölçeğinde gecikme süreleri, aşırı bağlantılı akıllı ortamlar ve yerleşik yapay zekâ (AI-native networking) gibi yetenekleri içermektedir. Bu yetenekler sayesinde endüstriyel otomasyon, otonom ulaşım sistemleri, uzaktan cerrahi ve taktiksel iletişim gibi kritik uygulamalarda ultra güvenilir bağlantı (URLLC), devasa makine tipi iletişim (mMTC) ve geniş bant iletişim (eMBB) gereksinimleri aynı anda karşılanabilecektir (Esmaily & ark., 2023:727).

Ancak bu yüksek düzeyde esneklik ve dinamik kaynak paylaşımı, güvenlik açısından yeni zafiyet alanlarını da beraberinde

¹ Dr. Öğr. Üyesi, İstanbul Arel Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0001-6493-6447

getirmektedir. 6G ağıları, yazılım tanımlı ağ (SDN), ağ dilimleme (network slicing), uç bilişim (edge/fog computing) ve merkeziyetsiz yapay zekâ karar sistemleri gibi bileşenlerle yapılandırıldığından, saldırı yüzeyi artık tek bir katmanla sınırlı değildir (Wu & ark.,2022:97). Hem kontrol düzlemi (control plane) hem de veri düzlemi (data plane) üzerinden gelebilecek tehditlerin etkisi çok katmanlı bir şekilde ağın genel güvenlik performansına yansımaktadır.

Bu nedenle, 6G’de güvenliğin değerlendirilmesi yalnızca kriptografik çözümler, saldırı tespit sistemleri veya güvenli protokoller üzerinden yapılamaz; aynı zamanda ağın performans metriklerinin örneğin Packet Delivery Ratio (PDR), Throughput, End-to-End Delay, Energy Efficiency ve Attack Detection Time gibi faktörlerin güvenlik doğruluğu üzerindeki dolaylı etkilerinin de anlaşılması gerekir. Bu metrikler, ağın güvenlik farkındalığına (security awareness) (Chorti & ark., 2022:104) etki eden, dinamik ancak ölçülebilir göstergelerdir.

Örneğin, yüksek paket kaybı oranı veya gecikme varyansı, saldırı tespit sistemlerinde yanlış negatif oranını artırarak güvenliğin zayıflamasına neden olabilir (Şeker & Parmaksız, 2025:818). Benzer şekilde, düşük throughput ve yetersiz bant genişliği, ağın güvenlik olaylarını zamanında işleyememesine, dolayısıyla geç tespit edilen ihlallere yol açabilir. Enerji verimliliği ve ağ yük dengesi gibi operasyonel faktörler de cihazların sensör örnekleme sıklığını ve anomali izleme kapasitesini dolaylı olarak etkiler. Bu nedenle, 6G güvenliği yalnızca bir “saldırı–savunma” problemi değil, aynı zamanda performans–güvenlik etkileşimi problemi haline gelmiştir.

Son yıllarda yapılan çalışmalar, güvenlik doğruluğunun (Accuracy of Security) sadece saldırı tipine veya kullanılan modelin hassasiyetine bağlı olmadığını, aynı zamanda ağın hizmet kalitesi parametrelerinin doğrudan bir fonksiyonu olduğunu göstermektedir. Özellikle QoS (Quality of Service) ve QoE (Quality of Experience)

göstergelerinin güvenlik metrikleriyle birlikte değerlendirilmesi, ağın kendi kendini koruma (self-defending) (Muzafar, Jhanjhi & Talib, 2025:3) ve uyarlama (self-optimizing) (Bhatt & ark., 2025:2) kabiliyetlerinin geliştirilmesinde kritik öneme sahiptir. Bu yaklaşım, literatürde “QoS–Security Co-Design” veya “Cognitive Security Management” olarak adlandırılmaktadır (Li & ark., 2021:7196).

Bu çalışmada, 6G ağlarında güvenlik doğruluğunu etkileyen teknik, operasyonel ve yapısal faktörlerin kapsamlı bir analizi sunulmaktadır. Çalışmanın amacı, herhangi bir makine öğrenmesi modelini kıyaslamak değil, her bir ağ parametresinin güvenlik üzerindeki etkisini açıklamak ve bu etkilere dayalı olarak güvenliği artırıcı stratejik öneriler geliştirmektir.

Yapılan inceleme, Throughput, Packet Delivery Ratio, Packet Loss Rate, Latency, Attack Detection Time, Data Rate, Slice Bandwidth ve Energy Efficiency gibi göstergelerin 6G güvenliğini anlamlı biçimde etkilediğini ortaya koymaktadır (Sak & Akkaş, 2024:6). Bu faktörler hem sistemin saldırı tespit performansını hem de güvenlik olaylarına yanıt hızını belirleyen başlıca değişkenlerdir.


Dolayısıyla, bu çalışma 6G güvenliğine ilişkin geleneksel yaklaşımı genişleterek, ağ performansı ve güvenliğin birlikte modellenmesi gerektiğini savunmaktadır. Böylelikle 6G’nin hedeflediği “akıllı, güvenilir ve otonom” iletişim vizyonuna ulaşmak için, güvenliğin yalnızca bir savunma mekanizması değil, aynı zamanda bir ağ hizmet kalitesi boyutu olarak ele alınması önerilmektedir (Karahan & ark., 2025:2).

Veri ve Metrikler

Bu çalışmada kullanılan veri kümesi, 6G ağ ortamında ölçülen performans, güvenilirlik, enerji verimliliği ve saldırı tespitiyle ilişkili çeşitli teknik göstergeleri kapsamaktadır. Bu göstergeler, ağ güvenliğini doğrudan etkileyen operasyonel faktörlerin bütüncül bir görünümünü sunmaktadır. Her bir özellik,

ağın güvenlik doğruluğunu temsil eden “Accuracy of Security (%)” değişkeniyle anlamlı bir ilişki göstermektedir.

Figure 1 Korelasyon Matrisi (Sayısal Özellikler)



Şekil 1’de görülen korelasyon matrisi, 6G ağında ölçülen performans, güvenilirlik, enerji ve tespit metrikleri arasındaki doğrusal ilişkileri göstermektedir. Özellikle Throughput, PDR ve Energy Efficiency değişkenlerinin Accuracy of Security ile pozitif yönde yüksek korelasyon sergilemesi, ağ güvenliğinin doğrudan operasyonel kararlılıkla bağlantılı olduğunu göstermektedir. Buna karşılık Packet Loss Rate ve End-to-End Delay gibi değişkenler negatif korelasyon göstererek ağ tıkanıklığının güvenliği zayıflatıcı etkisini doğrulamaktadır.

Ağ Performansı Metrikleri

Ağ performansını temsil eden Throughput (Mbps), Data Rate (Mbps) ve Slice Bandwidth (Mbps) gibi değişkenler, 6G altyapısında

güvenlik doğruluğunu önemli ölçüde etkileyen parametrelerdir (Porambage & ark., 2021:1102). Yüksek throughput, veri paketlerinin kayıpsız ve zamanında aktarılmasını sağlar. Bu durum, saldırı tespiti sistemlerinin eksiksiz veri üzerinde çalışmasını mümkün kılar. Düşük throughput veya yetersiz bant genişliği koşullarında, veri akışı kesintiye uğrar ve güvenlik analizlerinde örnekleme tutarsızlıkları oluşur. Böyle bir durumda tespit modelleri hatalı sonuçlar üretebilir, özellikle saldırı davranışlarının bütünsel profili bozulur. Dolayısıyla, yüksek throughput ve geniş dilim bant genişliği, ağ güvenliğinin istikrarını güçlendiren temel unsurlardır. Bu nedenle, 6G mimarilerinde güvenlik bileşenleri için asgari bant genişliği garantileri tanımlanmalı ve trafik yükü arttığında otomatik ölçeklendirme politikaları devreye alınmalıdır.


Güvenilirlik ve Hizmet Kalitesi Metrikleri

6G ağlarında Packet Delivery Ratio (PDR), Packet Loss Rate (%), Latency (ms) ve End-to-End Delay (ms) parametreleri, güvenlik doğruluğu üzerinde doğrudan belirleyici olan kalite göstergeleridir. PDR'nin yüksek olması, ağ üzerindeki veri akışının kesintisiz ve eksiksiz gerçekleştiğini gösterir. Böyle bir ortamda, güvenlik izleme sistemleri doğru ve eksiksiz örnekler üzerinde çalıştığından, saldırıların tespit edilme olasılığı artar. Buna karşılık, yüksek paket kaybı oranı, güvenlik sistemine eksik veri sunarak anomali imzalarının bozulmasına neden olur. Latency ve gecikme varyansı (jitter) ise özellikle zaman kritik uygulamalarda güvenlik analizinin doğruluğunu doğrudan etkiler. Gecikmenin artması, tespit sürecinin senkronizasyonunu bozar ve olayların gerçek zamanlı analiz edilmesini engeller. Bu nedenle, ağ güvenliği yalnızca saldırı tespiti mekanizmalarının başarısına değil, aynı zamanda ağın hizmet kalitesi parametrelerinin sürdürülebilirliğine de bağlıdır.

Güvenlik Tespiti Metrikleri

Attack Detection Time (ms), IGJO-SVM Prediction Score ve Intrusion Probability gibi göstergeler, ağın saldırılara ne kadar hızlı ve doğru tepki verdiğini ölçen parametrelerdir. Özellikle tespit süresi, ağın savunma refleksiyle doğrudan ilişkilidir. Saldırı tespiti ne kadar kısa sürede yapılırsa, ağın veri bütünlüğü o kadar yüksek oranda korunur. Uzun tespit süreleri ise saldırının daha fazla katmana yayılmasına ve daha geniş sistem etkilerine neden olur. Yüksek IGJO-SVM skoru, sistemin anomali algılamasında daha hassas çalıştığını gösterir; ancak bu durumun yüksek yanlış alarm oranı (false positive) ile dengelenmesi gerekir. Dolayısıyla, güvenlik doğruluğunun sürdürülebilmesi için tespit modülleri, performans metrikleriyle eşzamanlı olarak optimize edilmelidir.

Figure 2 Rastgele Orman Özelliklerin Önemi



Şekil 2, 6G ağında güvenliğe en fazla katkı sağlayan değişkenleri sıralamaktadır. Throughput, PDR, Energy Efficiency ve Packet Loss Rate öne çıkan en etkili faktörlerdir. Bu sonuç, ağın performans metrikleri ile güvenlik başarımı arasında güçlü bir

karşılıklı bağımlılık olduğunu göstermekte ve QoS tabanlı güvenlik optimizasyonunun gerekliliğini vurgulamaktadır.

Enerji Verimliliği ve Sistem Sürdürülebilirliği Metrikleri

6G ağlarında Energy Efficiency (J/bit), Power Consumption (W) ve Transmission Cost (Joule) gibi göstergeler, güvenliğin sürekliliği açısından kritik öneme sahiptir. Enerji verimliliği yüksek sistemlerde sensörler ve izleme modülleri daha uzun süre aktif kalabilir; böylece saldırı tespiti kesintisiz şekilde sürdürülebilir. Buna karşılık, enerji verimliliğinin düşük olduğu durumlarda cihazlar güç tasarrufu kiplerine geçerek izleme sıklığını azaltır, bu da güvenlik zafiyetine yol açar. Dolayısıyla, 6G güvenlik mimarisinde enerji yönetimi yalnızca performans veya sürdürülebilirlik açısından değil, aynı zamanda ağın savunma kapasitesini koruma açısından da ele alınmalıdır.

Dilim ve Mimari Parametreler


6G mimarisinde yer alan Slice ID, Network Load Category ve Resource Allocation Type gibi parametreler, ağın sanallaştırılmış yapısının güvenlik karakteristiğini belirler. Farklı dilimler farklı güvenlik önceliklerine ve kaynak izolasyon düzeylerine sahiptir. Örneğin, URLLC dilimleri düşük gecikme ve yüksek güvenilirlik sayesinde daha yüksek güvenlik doğruluğu sergilerken, eMBB veya mMTC dilimleri daha yüksek kapasiteye karşılık daha fazla saldırı yüzeyi sunabilir. Bu farklılıklar, ağ güvenliğinin yalnızca genel politikalarla değil, dilim düzeyinde özelleştirilmiş kurallarla yönetilmesi gerektiğini göstermektedir. Her dilim kendi kimlik yönetimi, erişim politikası ve izleme parametreleriyle izole edilmelidir.

Hedef Değişken: Accuracy of Security (%)

Tüm bu değişkenlerin birleşik etkisi, ağın genel güvenlik başarımını temsil eden “Accuracy of Security (%)” göstergesinde

somutlaşır. Bu metrik, saldırı tespiti, yanıt süresi, veri bütünlüğü ve kaynak verimliliği gibi alt bileşenlerin bileşkesidir. Yapılan analizler, güvenlik doğruluğunun özellikle PDR, Latency, Attack Detection Time, Energy Efficiency ve Throughput ile yüksek derecede ilişkili olduğunu göstermiştir. Bu bulgu, 6G ağlarında güvenliğin yalnızca yazılım veya algoritma düzeyinde değil, ağın operasyonel parametreleriyle birlikte yönetilmesi gerektiğini ortaya koymaktadır.

Figure 3 Toplam Özellik Önem Eğrisi – Rastgele Orman Modeli



Şekil 3’te görüldüğü üzere, toplam özellik önem eğrisi, en etkili birkaç değişkenin modelin açıklayıcı gücünün büyük bölümünü temsil ettiğini göstermektedir. İlk 8–9 değişken toplam varyansın %85’inden fazlasını açıklamaktadır. Bu bulgu, 6G güvenlik değerlendirmesinde çok sayıda parametre yerine birkaç kritik göstergenin optimize edilmesinin yeterli olabileceğini göstermektedir.

Bulgular ve Etki Analizi

Bu çalışmadan elde edilen bulgular, 6G ağında güvenlik doğruluğunun yalnızca saldırı tespit mekanizmalarının başarısıyla değil, ağın performans, güvenilirlik ve enerji yönetimi gibi

operasyonel parametreleriyle de yakından ilişkili olduğunu göstermektedir. Özellikle Packet Delivery Ratio (PDR), Latency, Throughput, Attack Detection Time ve Energy Efficiency gibi değişkenler, ağın genel güvenlik seviyesini belirleyen başlıca göstergeler olarak öne çıkmaktadır. Bu bulgular, 6G'nin güvenliğinin statik kurallardan ziyade, dinamik ağ koşullarına duyarlı olarak optimize edilmesi gerektiğini ortaya koymaktadır.


Ağ performansını temsil eden Throughput değişkeni, güvenlik doğruluğu ile doğrudan pozitif bir ilişki göstermektedir. Yüksek throughput değerleri, veri akışının kesintisiz olmasını ve saldırı tespit sistemlerinin eksiksiz veri örnekleri üzerinde çalışabilmesini sağlar. Buna karşılık, düşük throughput koşullarında tespit sistemleri eksik veya gecikmeli veriyle beslendiği için yanlış negatif oranı artar. Bu durum, özellikle gerçek zamanlı anomali tespit algoritmalarında güvenlik doğruluğunun düşmesine yol açar. Dolayısıyla, 6G ağlarında belirli bir minimum throughput seviyesinin korunması hem hizmet kalitesi hem de güvenlik bütünlüğü açısından kritik bir gerekliliktir.

Benzer biçimde, Packet Delivery Ratio (PDR) güvenlik doğruluğunu önemli ölçüde etkileyen bir başka parametredir. PDR'nin yüksek olması, veri paketlerinin kayıpsız iletilmesini ve ağın izleme sistemine eksiksiz veri sağlandığını gösterir. Bu durumda, saldırı tespit sistemleri daha net sinyaller üzerinden çalışarak güvenlik kararlarını daha isabetli verebilir. PDR'nin düşmesi ise özellikle zaman serisi tabanlı tespit sistemlerinde örnekleme tutarlılığını bozar ve anomali profillerinin yanlış değerlendirilmesine neden olur. Bu nedenle PDR yalnızca performans ölçütü olarak değil, güvenlik farkındalığını temsil eden bir ağ sağlığı göstergesi olarak da değerlendirilmelidir.

Packet Loss Rate (paket kaybı oranı) güvenlik doğruluğu ile negatif yönde ilişkilidir. Artan paket kaybı, veri bütünlüğünü zayıflatır ve özellikle denetimli öğrenmeye dayalı güvenlik

algoritmalarında eksik özellik kümelerine yol açar. Paket kayıpları, saldırı tespitinde yanılma oranlarını artırdığı gibi, ağır savunma refleksini de geciktirir. Yüksek paket kaybı, çoğu durumda yalnızca tıkanıklık veya donanım hatasından değil, potansiyel saldırı girişimlerinden de kaynaklanabilir. Bu nedenle 6G ağlarında paket kaybı oranı, ağır saldırı duyarlılığını gösteren tamamlayıcı bir güvenlik metriği olarak ele alınmalıdır.

Figure 4 SHAP Özeti: Özelliğin Güvenlik Doğruluğu Üzerindeki Etkisi



SHAP özeti, her bir özelliğin güvenlik doğruluğu üzerindeki etkisinin yönünü ve büyüklüğünü görsel olarak sunmaktadır. Pozitif SHAP değerleri güvenliği artırıcı, negatif değerler ise zayıflatıcı yönde etki yapmaktadır. Throughput ve PDR artışı güvenliği güçlendirirken, Latency ve Packet Loss Rate'in yüksek değerleri güvenlik doğruluğunu düşürmektedir. Bu sonuçlar, performans göstergelerinin doğrudan güvenlik karar mekanizmalarına entegre edilmesi gerektiğini desteklemektedir.


Gecikme (Latency) ve uçtan uca gecikme (End-to-End Delay), 6G güvenliğinde en kritik zaman duyarlı parametreler

arasında yer almaktadır. Gecikmenin artması, saldırı tespit sistemlerinin verileri zamanında işlemesini engelleyerek savunma zincirini zayıflatır. Özellikle otonom sistemlerde ve URLLC dilimlerinde milisaniyelik gecikmeler dahi güvenlik ihlallerinin gözden kaçmasına yol açabilir. Gecikmenin azaltılması yalnızca kullanıcı deneyimi açısından değil, saldırı tespiti doğruluğu bakımından da gereklidir. Bu nedenle, 6G çekirdek ağ mimarisinde güvenlik tepkilerinin “gerçek zamanlı” biçimde üretilmesi için gecikme eşiği belirlenmeli ve bu eşik aşıldığında sistem kendini yeniden yapılandırabilecek esneklikte tasarlanmalıdır.

Attack Detection Time (saldırı tespit süresi) güvenlik doğruluğuyla ters orantılı bir ilişkiye sahiptir. Tespit süresi ne kadar kısa olursa, saldırının etkisi o denli sınırlı kalır ve güvenlik doğruluğu artar. Tespit süresinin uzaması, saldırının daha fazla katmana yayılmasına ve ağın geri yüklenme süresinin uzamasına neden olur. Bu nedenle, 6G ağlarında saldırı tespit mekanizmalarının çevrimdışı değil, sürekli akış tabanlı (streaming-based) bir mimaride çalışması büyük önem taşımaktadır. Böylece saldırı anında sistem yalnızca pasif alarm üretmekle kalmaz, aynı zamanda otonom olarak önleyici aksiyonlar da devreye sokabilir.

Enerji verimliliği (Energy Efficiency), 6G’nin sürdürülebilir güvenlik anlayışında belirleyici bir rol oynamaktadır. Yüksek enerji verimliliği, ağ düğümlerinin izleme ve analiz işlevlerini kesintisiz şekilde sürdürmesini sağlar. Enerji açısından verimsiz çalışan sistemlerde sensörler ve izleme modülleri sık sık düşük güç moduna geçerek örnekleme sıklığını düşürür, bu da güvenlik sinyallerinin eksik kalmasına neden olur. Dolayısıyla enerji verimliliği, yalnızca ekonomik veya çevresel bir kazanım değil, aynı zamanda ağ güvenliğinin sürekliliğini destekleyen temel bir unsurdur.

Figure 5 Gerçek ve Tahmin – Rastgele Orman Modeli



Gerçek ve tahmin değerlerinin karşılaştırıldığı bu grafik, modelin ağ güvenlik doğruluğunu tahmin etme başarısını değerlendirmektedir. Noktaların sıfır çizgisi etrafında simetrik dağılması, modelin hatalarının rastgele olduğunu ve sistematik bir yanlılık bulunmadığını göstermektedir. Böylece Random Forest modelinin 6G güvenliği tahmininde dengeli bir performans sergilediği anlaşılmaktadır.

6G mimarilerinde bulunan Slice ID, Network Load ve Resource Allocation Type gibi yapısal parametreler, güvenlik doğruluğunu dolaylı biçimde etkileyen faktörlerdir. Farklı ağ dilimleri, farklı güvenlik profillerine ve izolasyon seviyelerine sahiptir. Örneğin, URLLC dilimleri düşük gecikme garantileri sayesinde daha yüksek güvenlik doğruluğu gösterebilirken, eMBB dilimleri daha geniş bant genişliği sunmalarına rağmen saldırı yayılımı açısından daha yüksek risk taşıyabilir. Bu durum, güvenliğin ağ genelinde tek tip politika yerine, dilim bazlı bir yaklaşımla yönetilmesi gerektiğini göstermektedir.

Son olarak, ağ tıkanıklığı (network congestion) ve trafik yoğunluğu, güvenlik performansını doğrudan etkileyen bir diğer faktördür. Yoğun trafik altında paket kaybı ve gecikme varyansı

artar; bu da IDS sistemlerinin verileri düzenli aralıklarla işleyememesine neden olur. Aşırı yüklenmiş ağ koşullarında güvenlik bileşenlerinin işlem gücü azalır, tespit pencereleri uzar ve saldırılar daha geç fark edilir. Bu nedenle 6G çekirdek ağında, trafik yüküne bağlı olarak güvenlik modüllerine öncelik tanıyan akıllı kaynak yönetim politikaları uygulanmalıdır.

Genel olarak değerlendirildiğinde, bu bulgular 6G güvenliğinin yalnızca tehditlerin algılanmasına dayalı bir problem olmadığını, aksine ağın işletimsel dinamikleriyle yakından bağlantılı karmaşık bir süreç olduğunu göstermektedir. Güvenlik doğruluğunu artırmak için ağ performans göstergeleriyle güvenlik tespiti mekanizmaları arasındaki etkileşimin sürekli izlenmesi ve yönetilmesi gerekmektedir. Böylece 6G ağları, yalnızca yüksek hız ve düşük gecikme hedeflerini değil, aynı zamanda dinamik olarak kendini koruyabilen bir güvenlik bilincini de gerçekleştirebilecektir.

Politika Tasarımı ve Güvenliği Artırıcı Önlemler

6G ağlarında güvenliğin sürdürülebilir biçimde sağlanabilmesi, yalnızca saldırı tespit sistemlerinin doğruluğuna değil, aynı zamanda ağın kendi operasyonel parametrelerinin dinamik biçimde yönetilmesine bağlıdır. Elde edilen bulgular, ağın performans metrikleriyle güvenlik başarımı arasında güçlü bir ilişki olduğunu göstermektedir. Bu doğrultuda geliştirilen politika önerileri, 6G ağlarında proaktif, öngörücü ve kendini uyarlayabilen (self-optimizing) bir güvenlik mimarisi oluşturmayı hedeflemektedir.

Hizmet Düzeyi Guardrail’leri

6G ağ güvenliğinin en önemli bileşenlerinden biri, ağın temel performans göstergeleri için belirli güvenlik eşiği değerlerinin tanımlanmasıdır. Bu eşiğin altına düşüldüğünde sistemin otomatik olarak güvenlik önlemlerini devreye sokması gerekmektedir. “SLO Guardrail” olarak adlandırılan bu yaklaşım, hizmet kalitesi ile

güvenlik performansı arasındaki dengenin gerçek zamanlı biçimde korunmasını sağlar.

Matematiksel olarak bu yaklaşım şu şekilde ifade edilebilir:

$$\text{Security State (S)} = \begin{cases} \text{Optimal,} & \text{if } PDR \geq P^*, \text{ Loss} \leq L^*, \text{ Latency} \leq D^*, \text{ DetectTime} \leq T^* \\ \text{Degraded,} & \text{otherwise} \end{cases} \quad (1)$$

Burada P^*, L^*, D^*, T^* parametreleri sırasıyla hedeflenen paket teslim oranı, maksimum kayıp oranı, gecikme sınırı ve saldırı tespit süresi eşiğini temsil etmektedir. Sistem “Degraded” durumuna geçtiğinde; saldırı tespit modülünün hassasiyeti artırılır, güvenlik trafiğine daha fazla bant genişliği tahsis edilir ve gerekli durumlarda dilim ölçeklendirmesi yapılır.

Bu tür bir koruma çerçevesi, güvenlik doğruluğundaki ani düşüşlerin yalnızca tespit edilmesini değil, aynı zamanda önleyici müdahale mekanizmalarıyla dengelenmesini sağlar. Böylece ağ, değişen trafik koşullarına ve tehdit seviyelerine otomatik olarak tepki verebilir.

Ortak-Uyarlamalı Güvenlik Yönetimi

6G’de ağ güvenliğinin performansla birlikte yönetilmesi için “QoS–Security Co-Adaptation” yaklaşımı önerilmektedir. Bu yaklaşımda güvenlik politikaları, ağın performans göstergelerine bağlı olarak dinamik biçimde güncellenir. Örneğin, Packet Delivery Ratio (PDR) düşmeye başladığında sistem yalnızca yeniden iletim (retransmission) miktarını değil, aynı zamanda saldırı tespit sisteminin örnekleme oranını da otomatik olarak artırır. Benzer şekilde, Latency belirli bir eşiğin üzerine çıktığında IDS penceresi daraltılarak erken uyarı eşiği yeniden kalibre edilir.

Bu ortak-uyarlamalı sistem, 6G çekirdek ağında bir “kendi kendini düzenleyen güvenlik döngüsü” (self-regulating security loop) oluşturur. Döngü üç aşamadan oluşur:

- a. **Gözlem (Observe):** Ağ metriklerinin (PDR, Latency, Attack Detection Time, Energy Efficiency) sürekli olarak izlenmesi,
- b. **Değerlendirme (Evaluate):** Gözlemlenen metriklerin belirlenen guardrail eşikleriyle karşılaştırılması,
- c. **Uyarlama (Adapt):** Gerekli görüldüğünde ağ parametrelerinin ve IDS eşiklerinin otomatik biçimde yeniden ayarlanması.

Bu yapı sayesinde 6G güvenliği statik kurallara değil, ağın kendi dinamik davranışına dayalı olarak şekillenir.

Enerji-Farkında Güvenlik

Enerji verimliliği, 6G güvenliğinin sürekliliğini etkileyen stratejik bir faktördür. Düşük güç moduna giren uç cihazlar veya sensörler, izleme sıklığını düşürdüğü için saldırı tespit zincirinde “görsel boşluklar” yaratabilir. Bu nedenle, enerji yönetimi politikaları güvenlik öncelikleriyle uyumlu biçimde planlanmalıdır.

Önerilen yaklaşımda, cihazların enerji durumuna göre görev öncelikleri dinamik biçimde yeniden dağıtılır. Kritik önemdeki güvenlik akışları, cihazın düşük güç moduna geçmesinden önce tamamlanır. Ayrıca, enerji kısıtlı dönemlerde güvenlik modüllerine ayrılan işlem gücü artırılarak ağın savunma refleksi korunur. Bu sayede enerji verimliliği hedefleri ile güvenlik bütünlüğü arasında denge sağlanır.

Dilim Bazlı Güvenlik Politikaları

6G'nin ağ dilimleme mimarisi, güvenliğin farklı hizmet türleri için özelleştirilebilmesini mümkün kılar. Bu çalışmanın bulguları, güvenlik doğruluğunun dilim tipine göre değiştiğini göstermektedir. Örneğin, URLLC dilimleri düşük gecikme avantajı sayesinde yüksek güvenlik başarımı sergilerken, eMBB dilimleri yüksek bant genişliği nedeniyle daha geniş saldırı yüzeyine sahiptir.

Bu nedenle, her dilim için bağımsız güvenlik politikalarının tanımlanması önerilmektedir. Her dilim kendi kimlik yönetimi (identity management), anahtar rotasyonu (key rotation) ve erişim kontrol politikası (access control) mekanizmasına sahip olmalıdır. Ayrıca, dilimler arası veri alışverişi sırasında “Zero-Trust Slice Design” ilkesi uygulanmalı; hiçbir dilim diğerine varsayılan olarak güvenmemelidir.

Proaktif Tehdit Önleme ve Olay Tepkisi

Son olarak, güvenlik doğruluğunu sürekli yüksek tutmak için proaktif önlem ve olay tepkisi mekanizmalarının bütünleştirilmesi önerilmektedir. Bu kapsamda, ağ yöneticileri saldırı olasılığını temsil eden göstergeleri (örneğin IGJO-SVM Prediction Score veya Intrusion Probability) izleyerek potansiyel tehditlere karşı önceden aksiyon alabilir.


Bu yaklaşımda sistem yalnızca saldırıyı tespit ettiğinde değil, saldırı ihtimalinin arttığı durumlarda da politika değişikliğine gidebilir. Örneğin, tehdit skoru belirli bir eşiğin üzerine çıktığında IDS modülü daha hassas çalışmaya başlar, güvenlik trafiği için daha fazla bant genişliği ayrılır ve şüpheli akışlar mikro-izolasyon (micro-segmentation) politikalarıyla sınırlandırılır.

Bu tür proaktif yönetim stratejileri, 6G ağlarını “reaktif” savunma modelinden “öngörücü” güvenlik modeline taşır. Böylece ağ hem performans hem de güvenlik boyutunda kendi durumunu sürekli optimize eden bir yapıya dönüşür.

Genel Değerlendirme

Tüm bu politikalar birlikte değerlendirildiğinde, 6G ağ güvenliğinin geleneksel anlamda statik bir kural setiyle değil, veriye dayalı, kendini uyarlayan ve durumsal farkındalığa sahip bir çerçeveye sağlanabileceği sonucuna varılmaktadır. Bu çalışma, ağ güvenliği ile hizmet kalitesi arasındaki karşılıklı bağımlılığı açık biçimde ortaya koymuş; 6G'nin hedeflediği “akıllı, güvenilir ve otonom” iletişim vizyonuna ulaşmak için güvenliğin ağ yönetiminin doğal bir parçası haline gelmesi gerektiğini vurgulamıştır.

Figure 6 Radar Tablosu – Kategori Bazında Güvenlik Doğruluğu ile Ortalama Korelasyon



Radar grafiği, farklı metrik kategorilerinin güvenlik doğruluğuna ortalama etkilerini göstermektedir. Performans ve Güvenilirlik kategorileri en yüksek katkıyı sunarken, Enerji ve Tespit kategorileri

destekleyici düzeyde etkili olmuştur. Bu durum, 6G güvenliğinin temelinde hizmet kalitesi ve gecikme metriklerinin yer aldığını, enerji ve tespit boyutlarının ise sürdürülebilirliği desteklediğini göstermektedir.

Sonuç

Bu çalışma, 6G ağlarında güvenlik doğruluğunu etkileyen temel ağ parametrelerini inceleyerek, güvenliğin yalnızca saldırı tespit algoritmalarına değil, ağın performans, enerji verimliliği ve hizmet kalitesi gibi operasyonel göstergelerine de güçlü biçimde bağlı olduğunu ortaya koymuştur. Elde edilen sonuçlar, 6G güvenlik anlayışının geleneksel “reaktif savunma” yaklaşımından uzaklaşarak, proaktif, öngörücü ve kendi kendini uyarlayan bir güvenlik mimarisine evrilmesi gerektiğini göstermektedir.

Analizler, özellikle Packet Delivery Ratio (PDR), Throughput, Packet Loss Rate, Latency, Attack Detection Time ve Energy Efficiency değişkenlerinin güvenlik doğruluğu üzerinde belirleyici rol oynadığını göstermiştir. Bu faktörler, ağın saldırıları tespit etme, tepki verme ve olay sonrası iyileşme kabiliyetlerini doğrudan etkilemektedir. Dolayısıyla, ağ güvenliği artık sadece tehdit tespiti veya kriptografik koruma düzeyinde değil, aynı zamanda operasyonel ağ davranışlarının bütüncül optimizasyonu bağlamında değerlendirilmelidir.

Çalışma, bu amaçla SLO tabanlı güvenlik guardrail’leri ve QoS–Security Co-Adaptation yaklaşımlarını önermektedir. Bu çerçevede 6G ağı, kendi performans göstergelerini sürekli izleyen ve güvenlik seviyesindeki düşüşleri önceden öngörerek kendini yeniden yapılandırabilen otonom bir yapıya kavuşturulabilir. Böyle bir sistemde, ağ parametreleri yalnızca veri aktarımını değil, aynı zamanda güvenlik tepkilerinin hızını ve doğruluğunu da belirleyen aktif girdiler haline gelir.

Ayrıca, dilim bazlı güvenlik yönetimi (slice-specific policies) kavramı, 6G'nin modüler mimarisine uygun şekilde güvenliğin ölçeklenebilir biçimde uygulanabileceğini göstermiştir. Her ağ dilimi, kendi hizmet tipine (eMBB, URLLC, mMTC) uygun güvenlik profiline sahip olmalı ve “Zero-Trust” ilkeleri çerçevesinde bağımsız olarak yönetilmelidir. Bu yaklaşım, ağın farklı hizmet senaryolarında bütünsel güvenlik tutarlılığı sağlamasına olanak tanır.

Enerji verimliliği de 6G güvenliğinin sürdürülebilirliği açısından kritik bir boyut olarak öne çıkmıştır. Enerji-farkında güvenlik planlaması sayesinde, sistemin izleme ve tespit modülleri güç kısıtlamalarına rağmen etkinliğini koruyabilmektedir. Böylece hem çevresel sürdürülebilirlik hem de siber dayanıklılık hedefleri birlikte desteklenmektedir.

Sonuç olarak, bu çalışma 6G ağlarının güvenliğini yalnızca bir savunma problemi olarak değil, çok katmanlı, kendini optimize eden bir sistem mühendisliği problemi olarak ele almaktadır. 6G'nin hedeflediği ultra güvenilir ve düşük gecikmeli iletişim ortamına ulaşmak için, ağın güvenlik bileşenlerinin performans, enerji ve hizmet kalitesi metrikleriyle birlikte yönetilmesi zorunludur.

Gelecekte yapılacak çalışmaların, bu kavramsal çerçevenin uygulamalı doğrulamasına odaklanması önerilmektedir. Özellikle gerçek zamanlı telemetri verileriyle desteklenen yapay zekâ tabanlı karar sistemleri, 6G ağlarında otonom güvenlik yönetiminin temel bileşeni olacaktır. Bunun yanı sıra, enerji optimizasyonu, tehdit önceliklendirmesi ve dilim bazlı kaynak tahsisini birlikte optimize eden çok amaçlı güvenlik kontrol algoritmaları geliştirmek, 6G sonrası (Beyond 6G) güvenlik mimarileri için önemli bir araştırma yönü oluşturmaktadır.

Bu çalışma, 6G ağ güvenliği alanına yalnızca belirli bir saldırı türünü değil, ağın bütünsel dinamiklerini analiz eden sistematik bir bakış

açısı kazandırmış ve güvenliğin, ağ performansının ayrılmaz bir boyutu olduğunu vurgulamıştır.

Kaynakça

- Ali Esmaeily, H. V. (2023, 03 09). Beyond 5G Resource Slicing With Mixed-Numerologies for Mission Critical URLLC and eMBB Coexistence. *IEEE Open Journal of the Communications Society*, s. 727-747.
- Arsenia Chorti, A. N. (2022, 04 25). Context-Aware Security for 6G Wireless: The Role of Physical Layer Security. *IEEE Communications Standards Magazine*, s. 102-108.
- Ata, S. Ö. (2023, 12 13). 6G Ağlarda Araçların Haberleşmesi: Gelişimi, Etkinleştirici Teknolojiler ve Güvenlik. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, s. 1029-1048.
- Hüseyin Parmaksız, H. Ş. (2025). 5G Çekirdek Ağında Yapay Sinir Ağı Modeli ile Saldırı Tespiti. *5TH INTERNATIONAL ARTIFICIAL INTELLIGENCE AND DATA SCIENCE CONGRESS (ICADA 2025)* (s. 817-835). İzmir: İzmir Kâtip Çelebi University.
- Pawani Porambage, G. G. (2021, 05 10). The Roadmap to 6G Security and Privacy. *IEEE Open Journal of the Communications Society*, s. 1094-1122.
- Rakshesh P Bhatt, D. G. (2025). Self-Optimizing 6G RAN: A Unified Approach with Image and Video Analytics. *2025 5th International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)* (s. 1-6). Fez, Morocco: IEEE.
- Saira Muzafar, N. J. (2025). SDN Based Network Management and Security in 6G Networks. *2025 International Conference on Metaverse and Current Trends in Computing (ICMCTC)* (s. 1-6). Subang Jaya: IEEE.

- Semih Sak, M. A. (2024, 06 11). 6G'de Nesnelerin İnterneti Teknolojisinin Medikal Alandaki Gelişmeleri. *Bilgisayar Bilimleri ve Mühendisliği Dergisi*, s. 1-8.
- Sümeyle Nur Karahan, İ. Y. (2025). Artificial Intelligence for Edge Computing in 6G Technology. *2025 33rd Signal Processing and Communications Applications Conference (SIU)* (s. 1-4). İstanbul: IEEE.
- Wen Wu, C. Z. (2022, 04 04). AI-Native Network Slicing for 6G Networks. *IEEE Wireless Communications*, s. 96-103.
- Yuanzhe Li, J. H. (2021, 03 03). Cognitive Service Architecture for 6G Core Network. *IEEE Transactions on Industrial Informatics*, s. 7193-7203.

BÖLÜM 7

İNSAN KAYNAKLARININ VERİMLİ KULLANIMI İÇİN DOĞRU MESLEK SEÇİMİNE ETKİ EDEN FAKTÖRLERİN ANALİZİ VE ADAYLARLA MESLEK PROFİLLERİ ARASINDAKİ EŞLEŞMELERİN MODELLENMESİ

HİDAYET TAKCI¹
SERAP BEĞDAŞ²

¹ Prof.Dr., Sivas Cumhuriyet Üniversitesi, Mühendislik Fak Bilgisayar Müh Bölümü, Orcid:0000-00002-4448-4284

² Öğr.Gör, Sivas Cumhuriyet Üniversitesi, Teknik bilimler MYO Bilgisayar Programcılığı Bölümü, Orcid: 0000-0001-8433-7599

Giriş

Türk Dil Kurumu (TDK, 2016) meslek kavramını “Belli bir eğitim ile kazanılan sistemli bilgi ve becerilere dayalı, insanlara yararlı mal üretmek, hizmet vermek ve karşılığında para kazanmak için yapılan, kuralları belirlenmiş iş” şeklinde tarif etmiştir. Herhangi bir eğitim kurumu olmadan da uzun yıllar verilmiş olan mesleki eğitim şu anda çıraklık eğitimi veren kurumlarda, meslek liselerinde, meslek yüksekokullarında ve teknik üniversitelerde verilmektedir.

Mesleki eğitimin gerekliliği tartışılmaz fakat ülkemiz kaynaklarının daha verimli kullanımı için kimin hangi meslek alanında daha başarılı olabileceği belirlenmeli ve ilgili kişilere bu eğitim verilmelidir. Bu konuda akla gelen en temel çözüm önerisi meslek kavramının tanımında da ifade edildiği gibi; mesleğin sadece bilgiye değil aynı zamanda “...becerilere dayalı...” olması gerekliliğidir. Bireyler beceri ve yeteneklerine uygun işler yaptığında hem daha faydalı hem de daha mutlu ve başarılı olabilecektir. Örneğin, mühendis olacak kişinin “soyut düşünebilme” becerisine sahip olması veya “ikna becerisi” olan birisinin avukat olması verimlilik ve fayda için daha uygun olacaktır.

Bireyler için doğru meslek seçimi çok faktörlü bir problemdir. Meslek seçimini etkileyen en önemli faktörlerden birisi **aile** faktörüdür. Ailenin sosyal ve ekonomik durumu çocuğun meslek seçimine etki edebilmektedir. Gelir düzeyi düşük ailelerin çocukları daha erken vakitte aile ekonomisine katkı sağlamaya yönlendirilmekte veya çocuk kendi isteği ile o yola girmektedir. Diğer taraftan idealist ve ekonomik durumu nispeten iyi olan aileler ise çocuklarını iyi bir eğitim sonrası daha prestijli bir yerde görmek istiyor. Bu durum da meslek seçimlerini ve mesleki eğitim alma şekillerini doğrudan etkiliyor.

Aile faktörü ile de ilişkili diğer faktör **çevre** faktörü. Çocuk veya ailesi çevreden etkilenerek meslek seçimini ona göre şekillendirebiliyor. Çevreden etkilenme hem aile seviyesinde hem de çocuğun kendi ruh dünyasında karşılık buluyor. Özellikle rol model olarak örnek alınan birilerinin varlığı çocuktaki meslek seçimine etki

ediyor. Global bir köye dönen internet sayesinde çevre etkisinin daha da arttığını söylemek mümkün.

Meslek seçiminde aile açısından olsun çocuk açısından olsun önemli faktörlerden birisi hiç şüphesiz **mesleğin maddi getirisi**dir. Ayakta kalabilmek için insanlar genellikle daha fazla maddi kazanç sağlayan işlere yöneliyor. Bu kimi zaman ihtiyaçtan kimi zaman da yüksek beklentilerden kaynaklanabiliyor.

Maddi tatmin kadar olmasa da bir başka önemli faktör de **manevi tatmin**. Özellikle ekonomik durumu daha iyi olan ailelerin çocuklarında kendini manevi açıdan tatmin edecek mesleklere yönelim de fazlaca olabilmektedir. Akademisyenlik bu kapsamda ele alınabilir. Uzun yıllar sonra daha iyi imkânlar sağlayan akademisyenlik bir nevi manevi tatmin için yapılan mesleklerden. Gerçi son dönemde nispeten iyileşen koşullar nedeniyle maddi tatmin aracı olarak de görülebilmekte.

Çevre faktörüne yakın konulardan bir diğeri **arkadaş faktörü**dür. Arkadaş faktörü de meslek seçimini etkileyen önemli faktörlerden birisi.

Bu listeyi uzatmak mümkün bununla birlikte konuyu daha da netleştirebilmek için meslek seçimine etki eden faktörleri belki dâhili ve harici faktörler olarak değerlendirmek daha uygun olacaktır. Dâhili faktörler mesleği icra edecek kişiyle doğrudan ilişkili faktörler (çocuğun maddi ve manevi beklentileri gibi) olarak görülebilir. Burada meslek seçiminin baş aktörü çocuğun bizzat kendisidir. Toplumda başına buyruk diye de tabir edebileceğimiz cesur gençler meslek seçiminde genellikle meslek seçimini sadece dâhili faktörlere uygun olarak yapmaktadırlar. Doğru veya yanlış olduğunu zaman gösterecektir. Harici faktörler ise mesleği icra edecek kişiyi etkileyen faktörlerdir. Aile, arkadaş, çevre ve öğretmen bunlara örnektir. Ailenin ekonomik nedenlerle yönlendirmesi veya öğretmenin aday tanıyarak onun iyiliğine tavsiyeler vermesi buna dâhildir.

Aileler eskisine göre daha bilinçli fakat hala yapılması gereken bazı işler bulunuyor. Bunlardan bazıları şöyle özetlenebilir:

- Adaylar hakkında daha fazla veri toplanmalı fakat bu iş yapılırken adaya yeni yük getirilmemeli ve kişisel veriler ile ters düşmeyecek şekilde veri toplama yapılmalıdır.
- Adayı tek başına değerlendirmek yeterli değildir. Onu ailesiyle ve hatta çevresi ile tanıyıp değerlendirmeye ihtiyaç vardır. Bu nedenle aday aileleri hakkında da veri toplanmalı ve aday verisi olarak kayıt altına alınmalıdır.
- Adayların genetik yatkınlığına kadar akla gelebilecek bütün verileri toplanmalı ve bunlar birleştirilmelidir.
- Toplanan veriler büyük veri imkânları ile depolanmalı, büyük veri analitiği yöntemleri ile analiz edilmeli ve yapay zekâ teknikleriyle verilerden çıkarımlar yapılmalıdır.
- Adaylara sadece ders notlarıyla ilgili değil aynı zamanda becerileriyle ilgili de karneler de düzenlenmelidir.
- Adaylar hakkında elde edilen olumlu/olumsuz geri bildirimler anında velilerle paylaşılmalıdır.

Faktörlerin çokluğu ve rehberlik yetersizliği nedeniyle meslek seçimi konusunda çoğu zaman hatalar yapılabilmektedir. Bunun sonucu olarak da genç nüfusun hatalı istihdamı sorunu ortaya çıkmaktadır. İşsizlik oranlarına ek olarak işe yerleşenlerin iş ile uyumsuzlukları sorunu daha da büyümektedir.

Doğru meslek seçimi konusunda geleneksel olarak çeşitli çalışmalar yapılmaktadır. Başta rehber öğretmenler adaylara tecrübeleri eşliğinde tavsiyelerde bulunarak onları yönlendirmektedir. Adayların başarı durumları takip edilmekte ve başarı durumuna uygun olarak meslek ve bölüm tavsiyeleri yapılmaktadır. Meslek seçiminde başarı için kimi yerde adaylara yönelik olarak akademik benlik anketi uygulanmaktadır (Kuzgun, 2006).

Mevcut durumdaki sorunların çözümü için yapılması gereken en önemli iş adaylarla ve mesleklerle ilgili daha fazla veri toplamak ve bunları zeki veri analiz araçları yardımıyla doğru şekilde eşleştirmektir.

Geçmiş çalışmalar

Meslek seçimi kimi zaman doğru parametrelerle yapılsa da ülkemizde hala bu konuda hatalar yaşandığı bir gerçektir. Ailelerin beklentileri ve adayların sınavlardan aldığı puanlar meslek seçiminde genellikle en önemli parametreler haline gelmiştir. Bununla birlikte ailenin beklentisi dikkate alınırken adayın kendi beklentileri bile göz ardı edilebilmektedir. Bunun doğal bir sonucu olarak da kendi isteğinden önce ailesinin isteğini yerine getirmek durumunda olan aday psikolojik açıdan sorunlar yaşayabilmekte ve başarısız olabilmektedir. Her ne kadar konu meslek seçimi olsa dahi sonuçları itibariyle rehberlik ve psikolojik danışmanlığın alanına da giren çalışmalar karşımıza çıkabilmektedir.

Doğru meslek seçiminin ilk aşaması adayın yeteri kadar tanınması olup bu konuda bazı çalışmalar yapılmıştır. Bu çalışmalardan birisi öğretmenlerin adaylar hakkında tutmuş oldukları **Öğrenci Gelişim Dosyaları**dır. Günümüzde bu dosyaların gördüğü vazifeyi e-okul sistemi yerine getirmektedir (<https://e-okul.meb.gov.tr/>). Gerek okul yönetimine yardımcı gerekse velilere bilgi desteği veren sistemin şu anda aktif olarak kullanıldığı görülmektedir. E-okul sistemi güncel tutulabildiği takdirde adaylar hakkında iyi bir veri kaynağı olarak görev üstlenebilecektir. Bununla birlikte meslek seçimi konusunda tek başına yeterli bir veri kaynağı değildir.

Adaylar hakkında her dönem toplanan verilerin zamanında ve düzenli olarak kaydedildiği dosyalara **Toplu Dosya** adı verilmektedir. Toplu Dosyalar adaylar için gelişim tarihçesini tutarlar. Bu dosyalar başta gizlilik kaygısı olmak üzere çeşitli nedenlerle adaylar hakkındaki tüm verileri tutmaz. Kayıt altına

alınan veriler ancak gizlilik derecesi düşük verilerdir. Toplanan verilerin sınıflandırılması, ayıklanması ve analitik olarak değerlendirilmesi ihtiyacı vardır. Toplu dosyalarda yer alan bilgiler adayların gelişim düzeylerine göre değişiklik gösterir. Örneğin, ilköğretim düzeyinde bedensel gelişim tarihçesi önemli yer tutarken, ortaöğretim düzeyinde geleceğe ilişkin planlar daha ayrıntılı yer alır.

Toplu dosyalarda temel olarak;

Aday kimlik ve aile bilgileri (nüfus kayıt, ailenin ekonomik durumu vs.),

Adayın devam ettiği okullar (eğitim geçmişi),

Adayın bedensel, ruhsal, bilişsel, dilse, sosyal, duygusal gelişimi,

Adayın ilgi ve yetenekleri,

Öğrenme stil ve alışkanlıkları,

Ders başarı durumları,

Boş zaman etkinlikleri,

Gelecek planları ve mesleki eğilimleri,

Test sonuçları,

Disiplin durumu vs. bilgiler tutulur.

Toplu dosyaların; okul yöneticilerine, öğretmenlere, velilere ve adaylara çeşitli faydaları bulunmaktadır. Örneğin, bu veriler sayesinde okul yöneticileri adayları daha yakından tanıyabilmekte, öğretmenler adayların gelecek planları ve yeteneklerini bilmekte, veliler çocuklarının okuldaki gelişimini takip edebilmektedir. Toplu dosyalarla ilgili en önemli kaygı kişisel verilerin tutulmasından dolayı verilerin gizliliğinin sağlanmasıdır. Bu anlamda Avrupa ülkelerinde kullanılan PIA (Privacy Impact Assessment) (Wright,

2012) ve ülkemizde uygulanan KVKK (Yazıcıoğlu, M. B.,2024) kapsamı yardımcı olacaktır.

Gerek e-okul konusunda gerekse toplu dosyalar konusunda edinilen tecrübe az değildir. Adaylar hakkında veri toplanması yeni bir konu değildir. Adayı değerlendirme ve testlerle onun hakkında bilgi elde etme de bu konuda yapılan başka bir çalışmadır. Bugüne kadar pek fazla yapılamayan bir çalışma ise toplanan verilerin bir sistematik dâhilinde farklı açılardan ele alınması ve analiz edilmesidir. Veri analizinde sıklıkla istatistik biliminden faydalanılsa da zeki veri analiz araçları olan veri madenciliği yöntemleri bize bu alanda daha fazla katkı sağlayacaktır. Hatta alana özel veri madenciliği çalışmaları eğitimsel veri madenciliği adıyla literatürde bilinmektedir.

Veri ve Yöntem

Bir adayın doğru mesleği tercih edebilmesi ancak onun en doğru şekilde tanınmasıyla mümkün olabilecektir. Adayın tanınmasından kasıt onun temel üç alandaki bilgilerinin elde edilmesidir: Yetenekleri, Beklentisi ve İlgi Alanları.

Bu çalışmada eksiksiz veri toplamının ilk aşaması aday verilerinin kapsamlı şekilde ele alınmasıdır. Örneğin adaya ait demografik veriler, yetenek ölçümleri, zekâ testi ve beklenti verileri doğru şekilde toplanmalıdır. Bunlar doğru ve eksiksiz şekilde toplanmadığı takdirde öğrencinin hangi mesleğe daha uygun olduğunun tespiti mümkün olamayacaktır.

Veri kaynakları

Doğru meslek seçiminde en önemli iki unsur aday ve meslek bileşenidir. Adaylar doğru ve eksiksiz şekilde anlaşılabilirdiği ve meslekler için uygunluğu doğru ölçülebildiği takdirde onların en doğru istihdamını sağlamak mümkün olabilecektir.

Aday özellikleri

Geçmiş çalışmalardan farklı bir sınıflandırma olarak çalışmamızda aday verileri statik özellikler ve dinamik özellikler olarak ele alınacaktır. Adayın kendisinde bulunan özelliklere ait veriler statik, kendi dışındaki olaylar nedeniyle gösterdiği tepkiler ve davranışlar ile elde edilen veriler ise dinamik özellikler olarak ele alınacaktır. Bu kapsamda örnek olarak; demografik veriler statik, adayın sınavlarda aldığı notlar ise dinamik özellikler olarak işleme alınacaktır.

Aday statik özellikleri

Statik özellikler doğuştan gelen özellikler olarak da görülebilir. Kişilerin zekâsı ve diğer psikolojik özellikleri ile ailesi ve genetik yapısı gibi bilgiler statik özellikler içerisinde ele alınacaktır.

Kategorik olarak ele almak gerekirse statik özellikler aşağıdaki alt kırımlar halinde karşımıza çıkacaktır.

Demografik veriler (ailevi özellikler, çevre özellikleri)

Psikometrik özellikler

Yetenekler (doğuştan gelen özellikler)

Demografik özellikler

Demografik veriler adayın cinsiyet, yaş, aile ve çevresi ile ilgili verilerden oluşur. Birçok çalışmada demografik verilerin başarıya etki eden faktörler olduğu görülmüştür (Corbett, 2001). Demografik veriler kapsamında ele alınan cinsiyet faktörünün önemli bir belirleyici olduğu geçmiş çalışmalarda görülmüştür. Cinsiyet faktörünün önemli olmasının nedeni kız ve erkek öğrencilerin farklı öğrenme davranışlarına sahip olmasıdır. Meit ve arkadaşları (2001) tarafından yapılan bir çalışmada genellikle kız öğrencilerinin daha disiplinli bir çalışma davranışı gösterdiği ve daha başarılı olduğu görülmüştür.

Psikometrik özellikler

Psikometri, kişilerin hangi mesleğe daha uygun olduğunu öğrenmek için testler sunar (Çoban, 2015). Genellikle insan kaynakları tarafından işe alımlarda ve terfilerde kullanılan psikometrik testler aday ile meslek arasındaki uyumu ölçmekte kullanılabilir. Psikometrik veriler statik ve dinamik özellikler şeklindeki gruplamada statik olarak ele alınmasının nedeni doğrudan adayla ilgili olmasından dolayıdır.

Yetenekler

Yetenekler adayların gelecekteki performansı konusunda önemli faktörlerden biridir. Yeteneklerin yeterince dikkate alınmaması sebebiyle adaylar kendi yetenekleri dışında mesleklerde istihdam edilmekte ve verimlilik düşüşleri oluşabilmektedir. Her ne kadar mevcut sınav sistemleri kimi yerde yetenekleri ölçmeye çalışsa da yapılan çalışmalar yeterli değildir. Anlık değil de süreç içerisinde yetenek ölçümleri yapılmalıdır. Bir alana yerleşecek aday için sadece bilgi değil aynı zamanda yetenek skorları da denkleme girmelidir. Adayların yeteneklerinin bir süreç içerisinde takibinde öğretmenlere büyük görev düşmektedir. Öğretmenler kendileri için bu işe özel geliştirilmiş bir yazılım sistemi içerisinde fark ettikleri en küçük bir yetenek parıltısını sisteme doğal dilde metin olarak, görüş olarak girmelidir. Askeri okullar, güzel sanatlar fakültesi ve beden eğitimi bölümleri yetenekleri dikkate alarak sınavlar yapmaktadır fakat yetenekler mühendislik, tıp, veterinerlik hatta diğer alanlar için de yapılmalıdır.

Öğrenci dinamik özellikleri

Bu çalışmada dinamik özellikler zamana ve şartlara bağlı olarak değişebilen özellikleri ifade için kullanılmaktadır. Meslek seçimine etki eden dinamik özellikleri iki ana başlık halinde ele almak mümkündür.

Beklentiler (dış etkilere göre deęiřir)

İlgi alanları (aile ve çevre)

Beklentiler

Meslek seçimine etki eden faktörlerden birisi hiç şüphesiz beklentilerdir. Beklentiler adayları en fazla motive edecek unsurlardan birisidir. Tek başına ve doğrudan meslek seçimine etki etmese dahi istenen mesleğin ihtiyaç duyduğu gayret ve çalışmayı adaya verecektir.

Beklentiler başlığı da kendi içerisinde iki alt kategori şeklinde ele alınabilir. Bunlardan birincisi ailenin beklentileri dięeri ise öğrencinin beklentileridir. Meslek seçimi sırasında ailenin beklentileri öğrencinin beklentilerinin önüne geçebilmektedir. Bunun bir nedeni seçim yapacak olan öğrencinin öngörüsünün daha düşük olduęu düşüncesidir. Bu noktada yapılması gereken öğrencinin bilinç seviyesine göre seçimi kimi zaman öğrenciye kimi zaman da ailesine bırakmak olabilir.

Beklentiler konusunda bugüne kadar öne çıkan konuların en başında ekonomik beklenti yer almıştır. Ekonomik beklentinin ilk sırada yer alması Maslov'un ihtiyaçlar piramidi (Parıltı, 1999) ile de ilgili olarak görülebilir.

İlgi alanları


Beklentiler ile ilgi alanları birbirine yakınsayan iki konu olmakla birlikte aralarında önemli bir ayrım vardır. Beklenti daha faydacı bir yaklaşım iken ilgi alanı daha çok manevi tatmin ve merak ile ilgili olabilir. Kimi zaman beklentiler ilgi alanına şekil verirken çoęu zaman ilgi alanı mevcut şartlardan bağımsız gelişir. İlgi alanları yetenekler ve dış çevre kaynaklı da olabilir. Yetenek kaynaklı durumda hızlı koşabilen bir adayın spor alanlarına yönelmek istemesi örnek gösterilebilir. Çevre kaynaklı durumda ise son

dönemde çok moda olduğu için adayların drone sürücüsü olmak istemesi örnek olarak gösterilebilir.

Yetenekler ile ilgi alanları zaman zaman birbirine karıştırılsa dahi arada önemli bir fark şöyle ifade edilebilir. Bir kimse matematik alanına ilgi duyabilir fakat yeteneği yoksa başarılı olamayabilir. Ya da çok para kazanmak için tıp alanına ilgi duyabilir fakat yeteneği yoksa kendini çok zorlayarak doktor olsa bile mesleğinde başarılı olmayabilir. Başarılı olsa dahi başkasına faydası olan fakat kendisine faydası olmayan bir insan ortaya çıkabilir.

Faktörleri aşağıdaki çizimle bir arada görebiliriz:

Şekil 1. Meslek seçimine etki eden faktörlerin şematik gösterimi



Meslek özellikleri

Öğrencileri tanımak için çeşitli özellikler bulunduğu gibi meslekleri tanımak için de çeşitli özellikler bulunmaktadır. Mesleklere etki eden özelliklerden tespit edilebilenler aşağıda verilmiştir.

Mesleğin görev ve amacı

Mesleğin hangi ihtiyaca cevap verdiği, topluma veya bireylere ne şekilde hizmet edeceği bu konuyla ilgilidir. Örneğin, doktorun amacı hastaları tedavi etmek, öğretmenin amacı insanlara bir şeyler öğretmek, mühendisin amacı sorunlara çözüm üretmektir.

Dolayısıyla bir adayın hangi mesleğe daha uygun olduğunu tespit edebilmek için çoktan seçmeli ya da kapalı uçlu bir soru ile “ne yapmaktan zevk alırsın, ya da neler yapmak seni mutlu eder?” sorusu yöneltilmelidir.

Mesleğin gerektirdiği bilgi ve beceriler (yetkinlikler)

Bir mesleği iyi şekilde icra edebilmek için gereken bir bilgi birikimi vardır. Aynı zamanda mesleğin gerektirdiği teknik beceriler ve uygulamalı bilgi ihtiyacı bulunmaktadır.

Bu durumu ölçebilmek için adaya meslekle ilgili olarak “sahip olduğu deneyimi ve teknik becerileri” sorulmalıdır. Ayrıca teknik becerilerini daha iyi ölçebilmek için bazı test sonuçları istenebilir.

Mesleğin gerektirdiği diploma ve sertifikalar

Ülkemizde ve dünyada mesleki eğitim veren kurumlar bulunmakta olup bu kurumlar diploma ve sertifikalar vermektedir. Bu diploma ve sertifikalar meslekle ilgili bilgi vericidir.

Adayın diploma ve sertifikaları “sahip olduğunuz diploma ve sertifikalar nelerdir?” sorusuyla ya da bir sistem üzerinden diploma ver sertifikalarını girilmesiyle kayıt altına alınabilir.

Kullanılan araç ve teknolojiler

Mesleklerin icrası sırasında kullanılması gereken cihazlar, ekipmanlar, yazılımlar ya da teknolojiler bulunur. Bir mesleği yapmaya aday olan kişilerden mesleğin gerektirdiği araç ve teknolojilerden ne kadarına hakim olduğu sorulmalıdır.

Bu konudaki seviyeyi tespit edebilmek için “mesleğe spesifik olarak x cihazını kullanabiliyor musun, y teknolojisine hakim misin?” gibi sorular sorulabilir.

Çalışma ortamı

Her mesleğin icrası bir ortamda gerçekleşir. Kimi meslekler kapalı ortamlarda kimisi de açık ortamlarda çalışmayı gerektirir. Ofis, fabrika, saha, hastane, laboratuvar ya da başka bir ortamı aday tercih edebilir.

Adaylara tercih ettiği çalışma ortamları da sorulmalı ve anketle bu durum kayıt altına alınmalıdır. Sorulabilecek bir soru “hangi ortamlarda çalışmayı tercih edersin?” olabilir.

Görev ve sorumluluklar

Doğası itibariyle her meslek için ihtiyaç duyulan görev ve sorumluluklar aynı değildir. Yapılan işin hassasiyeti görev ve sorumlulukları etkiler. Mesleklerin kendilerine has rutinleri vardır.

Adaylara bu rutinler sorulmalı ve ayrıca mesleğin gerektirdiği sorumluluklar konusundaki tutumu öğrenilmelidir. Deyim yerindeyse “günlük x, y, z işlerini yapmaktan zorlanır mısın?” ya da “çalıştığın birimin bütün sorumluluğunu almak ister misin?” gibi sorular sorulabilir.

Mesleğe uygun kişilik özellikleri

Bazı meslekler sabır, bazıları analitik düşünme, bazıları da iletişim becerisi ya da dikkat ve yaratıcılık ister. Örneğin bir öğretmen sabırlı ve iletişim becerisi yüksek olmalıdır, mühendis analitik düşünebilmelidir.

Bu konuyla ilgili bilgi girişi için meslekler ve kişilik özellikleri bir matris şeklinde verilmeli ve aday bunun üzerinde işaretleme yapmalıdır.

Mesleki riskler ve zorluklar

Mesleklerin kendilerine has riskleri ve zorlukları olabilir. Örneğin kimi meslekler fiziksel riskler içerebilirken kimi meslekler stresli olabilir. Ayrıca bazı meslek alanları teknolojiye hızlıca uyum gerektirebilir.

Adaylar bu gibi risklere karşı tepkilerini sisteme girmelidir.

Kariyer gelişimi ve uzmanlaşma alanları

Adayların çoğu kariyer gelişimini destekleyen mesleklerde çalışmak isterler. Kariyer gelişimi en büyük beklentilerden biridir. O nedenle mesleklerin kariyer gelişimine verecekleri katkılar adaylar için önemli olmaktadır. Örneğin yazılım geliştirme alanında junior ile başlayan serüven kimi zaman yazılım mimari ya da kıdemli proje yöneticisine kadar gitmektedir.

Toplumsal ve ekonomik değer

Mesleğin toplumdaki yeri ve mesleğin sağlayacağı ekonomik katkı düzeyi de adaylar için cazip gelmektedir. Ayrıca meslekteki istihdam potansiyeli adaylar için önemlidir. Yine bu madde de beklentilerle ilişkilidir.

Eğitimsel veri madenciliği

İnsan eliyle ve basit uygulamalar ile yapılamayacak karmaşıklıkta analitik işlemler için olası seçeneklerden birisi hiç şüphesiz güçlü veri tabanı tasarımı ve doğru şekilde kurgulanmış sorgulardır. Yapısal olarak kayıt altına alınan veriler sorgulama ve analiz araçları ile birlikte kullanılarak büyük miktarda bilgi elde edilebilir. Sorgular yardımıyla dahi elde edilemeyecek türden anlamlı bilgiler ise adına veri madenciliği dediğimiz akıllı veri analiz araçları ile yerine getirilebilir.

Veri madenciliği; istatistik, yapay zekâ, makine öğrenmesi, veri tabanı sistemleri ve görselleştirme gibi alanların bir araya

gelmesiyle ortaya çıkmış, büyük hacimli veri içerisinde gizli kalmış fakat faydalı olabilecek örüntüleri keşfetmek için ortaya konmuş, otomatik veya yarı otomatik yöntemler topluluğudur (Witten ve Frank, 1999). Veri madenciliği bugüne kadar; tıp, bankacılık, sigortacılık, güvenlik gibi birçok alanda başarıyla uygulanmıştır.

Veri madenciliğinin başarıyla uygulandığı alanlardan birisi de eğitim alanıdır. Eğitim verileri üzerinde klasik veri madenciliği teknik ve uygulamaları uygulanabildiği gibi alana özel teknikler de bulunmaktadır. Alana özel tekniklerin de içinde yer aldığı bu özel veri madenciliği türü Eğitimsel Veri Madenciliği adıyla bilinmektedir.

Eğitimde veri madenciliği tekniklerinin kullanımıyla ilgili çeşitli çalışmalar dikkat çekicidir. Bu çalışmalardan birinde sık örüntü madenciliği tekniği kullanılmış ve öğrencilerin birlikte aldığı dersler tespit edilebilmiştir (Zaiane, 2001). Tarihsel veri kullanılarak sınıflayıcıların eğitildiği bir başka çalışmada öğrenciler önceden tanımlı kategorilere ayrılabilmiştir (Cha ve diğerleri, 2006). Diğer çalışmalarda; tahmin modelleri yardımıyla öğrencilerin bir dersi geçip geçemeyeceği önceden ortaya konabilmiş (Hamalainen ve Vinni) ve kümeleme analizi yardımıyla öğrenciler benzerliklerine göre farklı öbeklerde kümelenebilmiştir (Perera ve diğerleri, 2009). Ayrıca; ders kitaplarının iyileştirilmesi (Agrawal ve diğerleri, 2011), öğrenci katılımını artırmak için sosyal ağ analizi (Rabbany ve diğerleri, 2011) ve eğitim yazılımında öğrenci bilgilerinin birleştirilmesi (Pardos ve diğerleri, 2011) gibi çalışmalar da bu alanda yapılmıştır.

Önerilen sistem

Önerilen sistem aşağıdaki alt bileşenleri içermelidir:

- Aday profili oluşturma
- Meslek profili oluşturma

- Uygunluk skorlama
- Sıralama ve eşleştirme
- Karar destek ve öneri sistemi

Aday profili oluşturma

Bu aşamada adaya ait tüm veriler toplanmalıdır. Aday profili oluşturma aşamasında toplanması gereken veriler aşağıdaki gibidir:

- Kişilik özellikleri
- Yetkinlikler (bilgi + beceri)
- Dijital beceriler
- Çalışma ortamı tercihleri
- Eğitim durumu, sertifikalar
- Mesleki ilgi alanları
- Risk toleransı, stres yönetimi
- Kariyer beklentileri
- Ekonomik beklentiler

Aday profili oluşturma aşamasının çıktısı aşağıdaki vektör olacaktır.

Aday Özellik Vektörü $A = [a_1, a_2, \dots, a_n]$

Meslek profili oluşturma

Her mesleğin gerektirdiği “özel isterler” bu aşamada öğrenilecek ve meslek profili olarak kaydedilecektir. Meslek profilinde olabilecek alanlar aşağıda verilmiştir.

- Zorunlu bilgi ve beceri seti
- Kişilik özellikleri

- Çalışma ortamı türü
- Risk ve stres seviyeleri
- Toplumsal ve ekonomik beklenti uyumu
- Diploma / sertifika gereksinimleri
- Teknoloji kullanım seviyesi

Meslek profili oluşturma aşamasının çıktısı aşağıdaki gibi olacaktır:

Meslek Özellik Vektörü $M_i = [m_1, m_2, \dots, m_n]$

Uygunluk Skorlama Motoru

Aday özellikleri ve meslek özellikleri açığa çıkarıldıktan sonra her aday için mesleğe dayalı skorlar elde edilir. Aday özellikleri her bir adayın meslek faktörlerine karşı verdiği cevabı içerir, meslek özellikleri ise her bir faktör için mesleğin o faktöre verdiği ağırlık şeklinde sunulur.

Aday ve meslek arasındaki eşleşmelerde ağırlıklı kosinüs benzerliği ya da Öklid mesafesi gibi uzaklık tabanlı yöntemler kullanılabilir. Eşleştirmede kural tabanlı yöntemi kullanımı ya da makine öğrenmesi yöntemlerinin kullanımı da mümkün olabilecektir.

Aday-meslek-skoru = $\text{similarity}(A, M_i)$ gibi verilebilir. A aday özelliklerini M_i ise bir meslek için mesleğe dair ağırlık bilgilerini tutmaktadır.

Sıralama ve eşleştirme

Her aday için tüm mesleklere dayalı skorlar hesaplanır:

Aday $X \rightarrow \{\text{Skor_X_Mühendis}, \text{Skor_X_Öğretmen}, \dots, \text{Skor_X_Eczacı}\}$

Daha sonra en yüksek skorlar sıralanır ve eşik değeri uygulanır. En son aşamada da meslek önerileri sunulur. Bu adım için çıktı kişiselleştirilmiş meslek sıralaması olacaktır.

Karar destek ve öneri sistemi

Skorlama sisteminin çıktısı olarak adaya şunlar sunulur:

- En uygun 3 meslek
- Uzak olduğu meslekler
- Uygunluk gerekçeleri (açıklamalı)
- Gelişim önerileri
- Eksik yetkinlikleri tamamlamak için yol haritası

Örneğin:

“Öğretmenlik için %78 uygunluk skorunuz var. Sınıf yönetimi ve iletişim becerisi alanlarında yüksek puan aldınız. Ancak ders planlama bölümünde orta seviyedesiniz. Bu alanda gelişim önerilir.”

Sonuç

Verinin her alanda arttığı günümüzde veriler arasında ilişkiler kurmak klasik yöntemlerle mümkün değildir. Bunun için veri madenciliği ve makine öğrenmesi gibi yöntemlere ihtiyaç vardır. Bu çalışmada eğitim alanıyla ilgili önemli bir problemin çözümü için veri madenciliği yöntemleri önerilmiştir.

Problemin çözümü eşleştirme sisteminin kurulmasıyla mümkün olacaktır. Mesleklere talip olan adaylar ve mesleklerin eşleştirilmesi doğru adayın doğru mesleğe yerleştirilmesinde önemli bir problemi çözecektir. Yerleştirmenin başarısı için aday ve meslek özellikleri dikkatli şekilde ele alınmalıdır. Bir yandan adayların sahip olduğu özellikler bulunurken diğer taraftan mesleklerin adaylardan beklediği özellikler bulunmaktadır. Meslekler ihtiyaç

duydukları aday profilini çizmekte ve adaylar da bu profile göre eşleşmelerini ölçmektedir. Her mesleğin her bir özellik için kendine has ağırlıkları olabilir. Örneğin iletişim yeteneği öğretmenlik mesleği için farklı mühendislik için farklı bir ağırlıkta olabilir. Adayın iletişim yeteneği ise meslekten bağımsız olarak bellidir. Dolayısıyla bir meslek bir özellik için farklı ağırlıkta isterlere sahiptir, aday her bir meslek için kendi özelliklerini sunduğunda meslek sayısı kadar skor hesap edilecektir.

Sistem içerisinde ne kadar meslek için profil ortaya konmuşsa aday için o kadar skor elde edilebilecektir. Skor değeri benzerlik tabanlı ise bir aday bir mesleğe ne kadar uygunsa skoru o kadar yüksek çıkacaktır. Bunun sonucunda bir skor sıralaması elde edilerek adaya olası meslekler sunulacak ve bunlar içerisinde seçim imkânı adaya sağlanacaktır.

Sistemin başarısı doğru veri girişlerine bağlı olarak çalışacaktır. Meslekler kendileri için ihtiyaç duyulan özellikleri ne kadar iyi tanımlarsa adaylar kendi özelliklerini ne kadar iyi doldurursa o kadar doğru bir eşleştirme ve istihdam mümkün olabilecektir.

Kaynakça

Türk Dil Kurumu. (2016, Temmuz 10). *Meslek* [Güncel Türkçe Sözlük].

http://www.tdk.gov.tr/index.php?option=com_gts&kelime=MESLEK

Kuzgun, Y. (2006). *Mesleki ve teknik öğretim kurumları ve meslekler rehberi*. İstanbul: Milli Eğitim Basımevi.

Wright, D. (2012). The state of the art in privacy impact assessment. *Computer Law & Security Review*, 28(1), 54–61. <https://doi.org/10.1016/j.clsr.2011.11.007>

Corbett, T. (2001). Cognitive computer tutors: Solving the two-sigma problem. In *Proceedings of the International Conference on User Modeling* (pp. 137–147). Springer.

Meit, S. S., Borges, N. J., & Early, L. A. (2007). Personality profiles of incoming male and female medical students: Results of a multi-site 9-year study. *Medical Education Online*, 12(1), Article 4462. <https://doi.org/10.3402/meo.v12i.4462>

Çoban, A. (2015, Temmuz 10). *Psikometrik testler*. http://www.adnancoban.com.tr/psikometrik_testler.html

Parıltı, C. (1999). Maslow'un ihtiyaçlar hiyerarşisi kuramında kendini gerçekleştirme ihtiyacı. *Kamu İş İş Hukuku ve İktisat Dergisi*, 4, 267–277.

Witten, I. H., & Frank, E. (1999). *Data mining: Practical machine learning tools and techniques with Java implementations*. San Francisco, CA: Morgan Kaufmann.

Zaiane, O. R. (2001). Web usage mining for a better web-based learning environment. In *Proceedings of the Conference on Advanced Technology for Education* (pp. 60–64). Banff, Alberta.

Cha, H. J., Kim, Y. S., Park, S. H., Yoon, T. B., Jung, Y. M., & Lee, J. H. (2006). Learning styles diagnosis based on user interface behaviors for the customization of learning interfaces in an intelligent tutoring system. In M. Ikeda, K. D. Ashley, & T. W. Chan (Eds.), *Intelligent Tutoring Systems. ITS 2006. Lecture Notes in Computer Science* (Vol. 4053, pp. 513–524). Springer. https://doi.org/10.1007/11774303_51

Hämäläinen, W., & Vinni, M. (2006). Comparison of machine learning methods for intelligent tutoring systems. In M. Ikeda, K. D. Ashley, & T. W. Chan (Eds.), *Intelligent Tutoring Systems. ITS 2006. Lecture Notes in Computer Science* (Vol. 4053, pp. 525–534). Springer. https://doi.org/10.1007/11774303_52

Perera, D., Kay, J., Koprinska, I., Yacef, K., & Zaïane, O. R. (2009). Clustering and sequential pattern mining of online collaborative learning data. *IEEE Transactions on Knowledge and Data Engineering*, 21(6), 759–772. <https://doi.org/10.1109/TKDE.2008.138>

Agrawal, R., Gollapudi, S., Kannan, A., & Kenthapadi, K. (2011). Data mining for improving textbooks. *ACM SIGKDD Explorations Newsletter*, 13(2), 7–19. <https://doi.org/10.1145/2076036.2076039>

Rabbany, R., Takaffoli, M., & Zaïane, O. R. (2011). Social network analysis and mining to support the assessment of on-line student participation. *ACM SIGKDD Explorations Newsletter*, 13(2), 20–29. <https://doi.org/10.1145/2076036.2076040>

Pardos, Z. A., Gowda, S. M., Baker, S. J., & Heffernan, N. T. (2011). The sum is greater than the parts: Ensembling models of student knowledge in educational software. *ACM SIGKDD Explorations Newsletter*, 13(2), 37–44. <https://doi.org/10.1145/2076036.2076042>

Yazıcıoğlu, M. B. (2024). ISO 27001, KVKK, and GDPR: A Comparison of Information Security and Data Protection Standards.

BÖLÜM 8

DERİN ÖĞRENMENİN KALP HASTALIKLARI ALANINDA KULLANIMI

ÖZGÜR TOMAK¹

Giriş

Dünya Sağlık Örgütü'ne (WHO, 2022) göre tahmini 19,8 milyon kişi kardiyovasküler hastalıklardan hayatını kaybetti ve bu sayı, küresel ölümlerin yaklaşık %32'sini oluşturmaktadır. Bu ölümlerin %85'i kalp krizi ve felçten kaynaklandı. Bu hastalıkların büyük bir bölümü, kalbin elektriksel aktivitesinden kaynaklanan ritim bozuklukları yani aritmiler ile ilişkilidir. EKG sinyallerinin doğru yorumlanması, aritmilerin erken tespitinde hayati rol oynar. EKG, kalp kasılırken ve gevşerken üretilen elektriksel impulsları kaydederek ritim, iletim ve miyokardiyal sağlık hakkında değerli bilgiler sağlar. Aritmiler veya düzensiz kalp ritimleri, kalbin normal elektriksel iletim yollarını bozar. Bunlar zararsız varyasyonlar olarak veya acil müdahale gerektiren hayatı tehdit eden durumlar olarak ortaya çıkabilir. Büyük EKG veri setlerinin artan erişilebilirliği ve yapay zekadaki gelişmeler, otomatik aritmi

¹ Dr. Öğretim Üyesi, Mühendislik Fakültesi, Giresun Üniversitesi, Bilgisayar Mühendisliği Bölümü, Giresun, Türkiye, Orcid: 0000-0003-2993-6913

tespitini önemli ölçüde iyileştirerek tanısal verimliliği ve doğruluğu artırmıştır. Tıbbi teknoloji alanındaki ilerlemeler, kardiyovasküler hastalıkların erken teşhisinde ölçülebilir bir iyileşmeye yol açmıştır. Sağlığı izlemek için tasarlanan yeni teknoloji sayesinde birçok insanın hayatını kurtarmak mümkündür. Son zamanlarda, artan veri miktarı, yeni donanım ve algoritmalar ile derin öğrenme, biyomedikal sinyallerin analizinde kullanılmakta ve faydalı bulunmaktadır.

Aritmi


Aritmi, kalbin elektriksel iletim sistemindeki bozukluklar sonucu ortaya çıkan ve kalp atım düzeninde anormalliklere neden olan klinik bir durumdur. Kardiyolojinin en önemli ve yaygın karşılaşılan problemlerinden biri olan aritmiler, asemptomatik hafif formlardan hayatı tehdit eden ciddi durumlara kadar geniş bir yelpazede görülebilmektedir. Aritmilerin erken teşhis edilmesi sayesinde pek çok hayat kurtarılabilecektir. Bu süreçte doktorların aritmileri doğru ve kısa zamanda teşhis etmesine yardım edebilecek otomatik teşhis sistemlerine ihtiyaç vardır.

Sağlıklı bir kalpte, elektriksel uyarı sinoatriyal (SA) düğümde başlar ve belirli bir yol izleyerek tüm kalp kasına yayılır. Bu iletim sırası şu şekildedir: Sinoatriyal düğüm → Atrioventriküler düğüm → His demeti → Sağ ve sol dal demetleri → Purkinje lifleri

Aritmi Gelişim Mekanizmalarına bakarsak: Anormal Otomatisite, kalp hücrelerinin normalden farklı depolarizasyon özellikleri göstermesidir. Tetiklenmiş Aktivite, erken veya gecikmiş afterdepolarizasyonlar şeklinde ifade edilebilir. Re-entry (Girişim) Mekanizmaları ise elektriksel uyarının dairesel yollar oluşturmasıdır. Son olarak iletim Blokları, iletim sistemindeki kısmi veya tam tıkanıklıklar olarak tanımlanabilir.


Şekil 1’de normal EKG yapısı görülmektedir. Şekildeki analiz, EKG’deki tipik grafik-kâğıt sunum formatını kullanmaktadır. EKG kâğıdı ayarlanırken genellikle hızı 25 mm/s olacak şekilde ayarlanır. Şekildeki kutu boyutu 1 mm²’dir. Yani her kutu 0.04 saniyeye karşılık gelir. Şekil 2’de EKG’de bulunan farklı dalgalar gösterilmiştir. EKG kaydındaki farklı dalga konumları P, Q, R, S, T ve U harfleriyle işaretlenmiştir. (Goldberger, Goldberger & Shvilkin, 2017: 45)

Şekil 1. Normal EKG kaydı



Kaynak: (Goldberger, Goldberger & Shvilkin, 2017: 45)

Şekil 2. EKG'de bulunan farklı dalgalar



Kaynak: (Goldberger, Goldberger & Shvilkin, 2017: 45)

Bu Konuda Yapılmış Çalışmalar

Jun & ark., tarafından EKG sinyallerinden prematüre ventriküler kasılma (PVK) atımlarını tanımak için bir derin sinir ağı önerilmiştir. Bu derin sinir ağı tasarımı, 6 gizli katmana sahiptir ve normal ve PVK atımları arasında sınıflandırma yapmak için EKG'lerden çıkarılan 6 özellik kullanılarak eğitilmiştir. (Jun & ark., 2016: 860)

Kiranyaz, Ince & Gabbouj,, MIT-BIH aritmi veritabanı ile 1-boyutlu Evrişimli Sinir Ağları (ESA) sınıflandırıcı uygulamıştır. Bu mimari, sırasıyla %97.6 ve %99 doğrulukla supraventriküler ektopik atımları (SVEB) ve ventriküler ektopik atımları (VEB) tespit edebilmiştir. (Kiranyaz, Ince & Gabbouj, 2015: 666)

(Pourbabae, Roshtkhari & Khorasani, tarafından normal atımları ve paroksizmal atriyal fibrilasyonu (PAF) sınıflandırmak için ham EKG sinyallerinden özellik çıkarmak üzere bir derin ESA eğitilmiştir. (Pourbabae, Roshtkhari & Khorasani, 2016: 5059) Böyle bir ağın derinliğinin artırılması, büyük bir veri seti ile hesaplama maliyetini artıracaktır.

Tajbakhsh & ark., ince ayar ile aktarım öğrenmesinin dezavantajlara çözüm sağladığını ve sınırlı veri ile derin öğrenmeyi mümkün kıldığını göstermiştir. Aktarım öğrenmesinde, önceden eğitilmiş bir derin ESA göreve adapte edilmiş ve özellik çıkarmak için kullanılmıştır. (Tajbakhsh & ark., 2016: 1300)

Zhang & ark., hastaya özgü bir EKG sınıflandırıcı önermiştir. SVEB ve VEB atımlarını tespit etmede daha iyi bir doğruluk iddia etmişlerdir. Bu sınıflandırıcı, bir kümeleme tekniği ve tekrarlayan sinir ağlarına dayanmaktadır ve sırasıyla %99.3 ve %99.7 doğrulukla SVEB ve VEB'leri tespit etme performansına ulaşmıştır. (Zhang & ark., 2017: 64)

Zabihi & ark., rastgele orman sınıflandırıcısına dayalı elle seçilmiş özellik seçimi ve çıkarım yöntemi önermiştir. (Zabihi & ark., 2017: 2)

Rajkumar, Ganesan & Lavanya tarafından Derin Öğrenme kullanan bir EKG sinyal sınıflandırma yaklaşımı geliştirilmiştir. ESA, MIT-BIH Veritabanı'ndan elde edilen veri seti kullanılarak eğitilmiş ve test edilmiş ve sinyalden yedi aritmi sınıfı sınıflandırılmıştır. ELU aktivasyon fonksiyonunun %93.6 doğrulukla daha iyi sonuçlar verdiği bulunmuştur. (Rajkumar, Ganesan & Lavanya, 2019: 366)

Wang ve arkadaşları EKG sinyallerini iki boyutlu görüntüler şeklinde sınıflandırmışlardır. ResNet ve DenseNet ağlarını kullanarak yapılan çalışmada, görüntü işleme yöntemleri kullanarak yapılan sınıflandırılmanın sonucunda daha yüksek

değerde doğruluk başarılarına ulaştığı görülmüştür (W. Wang & Najafizadeh, 2022).

Ahmed & ark., kardiyak aritmilerin sınıflandırılmasında MIT-BIH veri setinden alınan verileri kullanmıştır. Model performansı değerlendirilmiş, model doğruluğu, kesinlik, duyarlılık, F1 skoru, ortalama ve AUC-ROC için karmaşıklık matrisi kullanılmıştır. Deney sonuçları, modelin eğitim ve test veri setlerinde sırasıyla 1.00 ve 0.99 doğruluklar ile bir performans elde ettiğini ve aritmi teşhisi için otomatik ve hızlı bir alternatif olabileceğini göstermiştir. (Ahmed & ark., 2023: 562)

Reznichenko, Whitaker, & Zhou, PhysioNet Kardiyoloji Yarışması 2020'den halka açık bir veri seti kullanmıştır. Derin öğrenme yaklaşımı için, her EKG kanalından özellik çıkarmak üzere bir ESA eğitilmiş ve bu özellikler daha sonra sınıflandırma için bir ileri beslemeli sinir ağına beslenmiştir. Geleneksel makine öğrenmesi yaklaşımında ise, elle çıkarılan özellikler kullanılarak bir rastgele orman sınıflandırıcı kullanılmıştır. Her iki yöntem için de, özylenelemeli özellik eleme yoluyla optimal EKG kanalı alt kümeleri belirlenmiştir. (Reznichenko, Whitaker, & Zhou, 2025)

Derin Öğrenmenin Sağlık Alanındaki Araştırmalarda Kullanımı

Sağlık hizmetlerinde dijitalleşmenin hız kazanmasıyla birlikte son yıllarda çeşitli tıbbi testlerin bilgisayar ortamında kaydedilmesi ve uzun süreli arşivlenmesi mümkün hâle gelmiştir. Hastanelerden laboratuvarlara kadar geniş bir yelpazede elde edilen veriler; görüntüleme sonuçları, genom dizileri, biyomedikal sinyaller ve hasta geçmişi gibi çok çeşitli veri türlerini içermekte ve giderek büyüyen “büyük veri” yapıları oluşturmaktadır. Bu zengin veri çeşitliliği, derin öğrenme modellerinin gerektirdiği yüksek hacimli ve kapsamlı veri kümelerine ulaşmayı kolaylaştırmıştır. Aynı zamanda CPU–GPU birlikte kullanımına olanak tanıyan modern

donanımlar ve Google, Amazon gibi kuruluşların sunduğu bulut tabanlı hesaplama servisleri, bu modellerin eğitime duyulan yüksek işlem gücü ihtiyacını büyük ölçüde karşılayabilmektedir.

Elde edilen büyük ölçekli biyomedikal veriler, başlangıçta yalnızca temel istatistiksel yöntemler veya geleneksel makine öğrenmesi algoritmalarıyla analiz edilirken, son yıllarda derin öğrenme yöntemlerinin sağladığı performans ve otomatik özellik çıkarımı yetenekleri nedeniyle biyoenformatik alanında yaygın şekilde kullanılmaya başlanmıştır. Derin öğrenmenin hızlı yükselişi, esasen üç temel unsurun birleşimiyle mümkün olmuştur: büyük verinin erişilebilirliği, paralel işlem kapasitesi sağlayan modern donanımlar ve yüksek performanslı öğrenmeyi mümkün kılan gelişmiş eğitim algoritmaları.

Bu gelişmeler, sağlık alanında çeşitli yapay zekâ uygulamalarının ortaya çıkmasını sağlamıştır. Örneğin IBM'in geliştirdiği Watson for Oncology, hastaya özgü tıbbi verileri analiz ederek klinisyenlere tedavi seçenekleri konusunda öneriler sunmaktadır. (Ferrucci & ark., 2010: 65) Google DeepMind tarafından geliştirilen AlphaGo sisteminin başarısının ardından, şirket bünyesinde DeepMind Health adlı birim kurulmuş ve tıbbi görüntüleme ile klinik karar destek sistemlerine yönelik ileri seviye yapay zekâ çalışmaları hız kazanmıştır. (Silver & ark., 2016: 485)

Derin öğrenme modellerinin eğitimi, katmanlara ait ağırlıkların optimizasyonuna dayanır. Eğitim süreci ileri yayılım, kayıp fonksiyonunun hesaplanması, geri yayılım, ağırlık güncellemeleri aşamalarından oluşur:

İleri yayılım : Girdi veri katmanlar boyunca ileri iletilir ve tahmin üretilir.

Kayıp fonksiyonunun hesaplanması: Üretilen tahmin ile gerçek etiket arasındaki hata ölçülür.

Geri yayılım: Hata sinyalleri katmanlar boyunca geriye doğru iletilir ve her ağırlığın gradyanı hesaplanır (Hecht-Nielsen, 1989).

Ağırlık güncellemeleri: SGD ve varyantları (momentum, Adam vb.) kullanılarak parametreler güncellenir. (Bottou, 1991: 12)

Aşırı öğrenmenin önlenmesinde dropout gibi yöntemler kullanılmaktadır.

Derin öğrenme, büyük veri ve yüksek işlem gücünün birleşimiyle biyoinformatikte devrim niteliğinde gelişmeler sağlamıştır. Genomikten proteomik analizlere, tıbbi görüntülemeye kadar geniş bir alanda yüksek başarı elde eden bu yöntemler, gelecekte klinik karar destek sistemlerinin temel bileşenlerinden biri hâline gelmeye adaydır. Bununla birlikte açıklanabilirlik, güvenilirlik ve etik uygulamalar derin öğrenme sistemlerinin biyomedikal alanda yaygın olarak benimsenmesi için önemli araştırma alanları olmaya devam etmektedir. Bu alanda yapılan çalışma sayısı her geçen gün artmaktadır. Böylece bu konu hakkında çok hızlı gelişmeler görmemiz mümkündür.

Evrişimli Sinir Ağları

Evrişimli Sinir Ağları, derin öğrenme paradigmasının en başarılı ve yaygın uygulama alanı bulan mimarilerinden biridir. Goodfellow, Bengio & Courville, tarafından belirtildiği üzere, ESA'ların temel ayırt edici özelliği, geleneksel matris çarpımı yerine en az bir katmanda konvolüsyon operatörünü kullanmalarıdır. (Goodfellow, Bengio & Courville, 2016: 150) Bu yapı, biyolojik görsel sistemden ilham alınarak geliştirilmiş olup, özellikle görsel veri işleme ve bilgisayarlı görü uygulamalarında olağanüstü başarılar sergilemiştir.

ESA mimarisi, memeli beyninin görsel korteksindeki hiyerarşik bilgi işleme mekanizmalarını taklit etmektedir. Görsel uyarılar, retinadan birincil görsel kortekse doğru ilerledikçe, nöronların alıcı alanları giderek genişlemekte ve işlenen öznitelikler karmaşıklaşmaktadır. O'Reilly, Munakata, Frank & Hazy, bu süreci şu şekilde açıklamaktadır: (O'Reilly, Munakata, Frank & Hazy, 2012: 45)

Birincil Görsel Korteks Seviyesi: Basit öznitelik dedektörleri (yönlendirilmiş kenarlar, köşeler)

Orta Seviye Görsel Bölgeler: Temel özniteliklerin birleşiminden oluşan şekil primitifleri

Üst Düzey Görsel Bölgeler: Karmaşık nesne tanıma ve sınıflandırma birimleri

Bu hiyerarşik organizasyon, ESA'larda katmanlar arası ilerledikçe özniteliklerin soyutluk seviyesinin artması şeklinde modellenmiştir.


Ağırlık paylaşımı mekanizması, ESA'ların aynı kapasiteye sahip tam bağlantılı ağlara kıyasla çok daha az parametreyle çalışmasını sağlar. Bu durum eğitim süresinde önemli kısaltma, bellek gereksiniminde azalma ve aşırı öğrenme riskinde düşüşü sağlar. Teorik olarak, yeterli kapasiteye sahip bir tam bağlantılı sinir ağı ESA ile eşdeğer performans sergileyebilir. Ancak pratikte, daha fazla parametre, optimizasyon zorluğunda artış, eğitim gürültüsüne duyarlılık ve genelleme performansında düşüşe neden olur.

ESA'lar, görsel algılamada şekil değişiklikleri ve geometrik bozulmalara karşı doğal dayanıklılık sergiler. Bu özellik, ağırlık paylaşımı ve yerel bağlantı prensipleri sayesinde, özniteliklerin uzaysal konumdan bağımsız olarak öğrenilmesinden kaynaklanır. ESA, derin öğrenmenin temel taşlarından biri olarak, hem teorik sağlamlık hem de pratik uygulanabilirlik açısından öne çıkmaktadır.

Biyolojik görsel sistemden esinlenen mimarisi, parametre verimliliği ve uzaysal değişmezlik özellikleri, ESA'ları görsel veri işleme için ideal kılmaktadır. Süregelen araştırmalar, bu mimarilerin sınırlamalarını aşmaya ve yeni uygulama alanları geliştirmeye devam etmektedir.

ESA mimarisi seçildikten sonra, belirlenecek pek çok parametre (başlangıç değerleri, öğrenme oranı, gizli birimler sayısı, katman sayısı gibi) vardır. Bunlarda yapılacak değişiklikler sonucu etkileyebilir. Derin öğrenme sürecini hızlandırmak amacındaki yaklaşımları üç gruba ayrılabiliriz. Bunlar ise gelişmiş optimizasyon algoritması, dağıtılmış ve de paralel olan bilgi işlem ve de özel donanımlardır. Şekil 3'de el ile yazılan rakamların tanınmasında kullanılan LeNet-5 ağı görülmektedir.

Şekil 3. LeNet-5 ağı



Kaynak: (LeCun & ark., 1998: 2280)

Evrışim Katmanı

Evrışim katmanları, girdilerinin (örneğin, görüntüler veya öznitelik haritaları) birden fazla uzamsal ilişkisinden yararlanır. Evrışim süreci, seyrek etkileşimler, parametre paylaşımı ve eşdeğer temsil olarak adlandırılan ve bir makine öğrenme sistemi geliştirmeye yardımcı olabilecek üç fikri destekler. (Goodfellow, Bengio & Courville, 2016: 150) Bir filtrenin evrışiminin girdi ve çıktısına aktivasyon haritası veya öznitelik haritası denir. Katmandaki her filtrenin oluşturulan öznitelik haritası vardır ve

beraber çıktının derinliğini belirlerler. Aktivasyon haritasının boyutu, girdi, filtre boyutuna ve de adıma bağlıdır. Öznitelik haritasına ait birimler aynı parametreleri paylaşır, bu parametre paylaşımıyla bellek tasarrufu sağlanır. (LeCun & ark., 1998: 2280) Evrişim, Denklem 1'de gösterildiği gibi hesaplanır. Burada, sinyal y ile, filtre f ile, y 'nin eleman sayısı N ile ve çıktı vektörü x ile temsil edilir.

$$x_n = \sum_{k=1}^{N-1} y_k f_{n-k} \quad (1)$$

ESA modeli, geri yayılım tekniği kullanılarak eğitilir. Sonraki katman ise nöronuna ait girdi haritası, ileri yayılımda, Denklem 2'deki gibi, önceki katmanın nöronlarına ait çıktı haritaları ile bireysel bölgesel evrişimin birleştirilmesiyle elde edilir. (Kiranyaz, Ince & Gabbouj, 2015: 666)

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} conv2D(w_{ik}^{l-1}, s_i^{l-1}) \quad (2)$$

Buradaki conv2D sınır noktalarda sıfırla doldurma yapılmayan düzenli 2 boyutlu konvolüsyondur, x_k^l girişimizdir, b_k^l ise tabaka l 'nin k th nörondaki sapmadır, s_i^{l-1} $l-1$ katmanında i th nöronuna ait çıktıdır, w_{ik}^{l-1} tabaka $l-1$ 'in i 'inci nöronundan, l tabakasına ait k 'inci nöronun ağırlığıdır.

Düzeltilmiş Doğrusal Birimler (ReLU)

ReLU fonksiyonu, $f(x) = \max(0, x)$ uygulayarak doğrusal olmayan özelliği çoğaltır. Bu noktada, negatif girdi değerleri sıfıra düzeltilir. Ağ, doyumluk fonksiyonları kullanarak $f(x) = \tanh(x)$ gibi doyum olmayan fonksiyonlardan çok daha hızlı çalışabilir ve sistem bu katmanın kullanımıyla daha hızlı öğrenir. Denklem 3'te

gösterildiği gibi, negatif sayılarda küçük, sıfırdan farklı α eğimi kullanılabilir.

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha x, & \text{diğer durumlar} \end{cases} \quad (3)$$

Havuzlama Katmanı

Hacmin doğrusal olmayan örnekleme, önceki katmanın çıktısındaki dikdörtgen alanlardaki ortalama veya maksimum değerleri örnekleme için havuzlama katmanında küçük filtreler kullanılarak yapılır. Havuzlama ile boyut, parametre ve hesaplama miktarını azaltmak ve aşırı uyumu önlemek için küçültülür.

Tam Bağlı Katman

Bu katmandaki nöronlar, önceki katmanların tüm aktivasyonlarına tamamen bağımlıdır. Matematiksel anlamda önceki öznitelik katmanına ait ağırlığı toplar, belirli bir çıktının sonucunu belirlemede bileşenlerin karışımını gösterir.

Dropout Katmanı

Ağa ait gizli katmanların indeks değeri $\in \{1, \dots, L-1\}$. şeklindedir. l katmanına girdi vektörleri $z^{(l)}$, l katmanından çıktı vektörleri ise $y^{(l)}$, l katmanındaki ağırlıklar $W^{(l)}$, l katmanındaki sapmalar da $b^{(l)}$ olarak tanımlanır. Eğer f aktivasyon fonksiyonuysa, standart sinir ağına ait ileri besleme Denklem 4 ve 5'te tanımlandığı gibi olabilir (Srivastava, Hinton, Krizhevsky, Sutskever & Salakhutdinov, 2014).

$$z_i^{(l+1)} = w_i^{(l+1)} y_l + b_i^{(l+1)} \quad (4)$$

$$y_i^{l+1} = f(z_i^{(l+1)}) \quad (5)$$

Tam bağı katman parametrelerinin çoğu kapsandığından, aşırı miktarda uyum eğilimindedir. Aşırı miktarda uyumu azaltmanın bir yöntemi Dropout'tur. Her eğitim kademesinde, bireysel düğümlerin ağdan kaldırma olasılığı $1-p$ 'dir veya p olasılıkla da tutulur, böylece indirgenmiş bir ağ kalır. Kaldırılan düğüme giden ve de gelen kenarlar kaldırılır. Bu aşamada, yalnızca indirgenmiş ağ verileri ile eğitim yapılır. Dropout, aşırı uyumu azaltır.

Softmax

Genelde, ağın son katmanı, sınıflandırma amacını gerçekleştiren softmax fonksiyonudur. Olasılıkta, kategorik bir dağılım, softmax fonksiyonunun çıktısıyla temsil edilebilir. (Bishop & Nasrabadi, 2006: 738) Çok terimli lojistik regresyonda ve doğrusal ayırtaç analizinde, fonksiyonun girdisi K 'nın farklı doğrusal fonksiyonlarının sonucudur ve bir örnek vektörü x ve j sınıfı için bir ağırlık vektörü w 'nun tahmin edilen olasılığı Denklem 6'daki gibidir. Bu, K doğrusal fonksiyonunun ve softmax fonksiyonunun birleşimi olarak görülebilir. Fonksiyon, w ile vektörlerin ve x tarafından tanımlanan bir doğrusal operatörün uygulanmasına eşdeğerdir.

$$P(y = j|x) = \frac{e^{x^T w_j}}{\sum_{k=1}^K e^{x^T w_k}} \quad (6)$$

Geometrik anlamda, softmax köşegen boyunca sabit yapıdadır. Toplam sıfır olarak varsayıldığında girişin

normalizasyonu yapılır. Sonrasında softmax sıfır olan noktalarda hiper düzlemi alır. Softmax ölçeklendirme durumunda değişmez değildir. Bu süreç denklem 7’de gösterilmiştir.

$$\sigma(z + j)_j = \frac{e^{z_j + c}}{\sum_{k=1}^K e^{z_j + c}} = \frac{e^{z_j} \cdot e^c}{\sum_{k=1}^K e^{z_j} \cdot e^c} = \sigma(z)_j \quad (7)$$

Örnek Evrişimli Sinir Ağı Mimarisi


Derin öğrenmeyi kullanırken, tüm veriyi bir seferde öğrenmek ve işlemek, bellek kullanımı veya zaman nedeniyle zorlu bir iştir. Geri yayılım ve geri gradyan değerleri hesaplanır ve ağırlık değerleri öğrenme aşamasının her tekrarında güncellenir. Hesaplama kademesinde ne kadar çok veri olursa, hesaplama ise o kadar uzun sürecektir. Bu nedenle, veriyi küçük parçalara bölüp ve bu küçük parçalarda öğrenme yapılır. Şekil 4’de ESA kullanarak EKG sinyali sınıflandırması blok yapı olarak verilmiştir.

Yapılan örnek çalışmada St. Petersburg Kardiyoloji Tekniği Enstitüsü’ne ait 12 kanallı olan aritmi veri tabanı kullanılmıştır. Bu veri tabanında 32 tane Holter kayıtlarından elde edilen 75 açıklamalı kayıt bulunmaktadır. Her kayıt 30 dakika uzunluğundadır ve 257 Hz’de örneklenmiştir. 12 standart kanal içermektedir. (Goldberger & ark., 2000: 217) Hastalarda kalp pili bulunmamaktadır. En çok görülen aritmi ventriküler ektopik atımdır.

Önişleme aşamasında ilk olarak detrend fonksiyonu kullanılmış ve doğrusal eğilim ortadan kaldırılmıştır. Doğrusal olmayan eğilimse sinyalizme düşük derecede bir polinom eklenmesi ve çıkarılması yöntemiyle giderildi. Taban düzeltmesi, yani sinyalin ortalamasının, sinyalden çıkarılması durumu Denklem 8’de verilmiştir.

$$Sinyal_{temel\ çizgi\ düzeltmesi} = Sinyal - ortalama(Sinyal) \quad (8)$$

Şekil 4. ESA kullanarak EKG sinyali sınıflandırması



Örnek mimari, çarpma ve toplama gerektiren bir boyutlu evrişim işlemleri gerektirir. 257 Hz'de örneklenen EKG sinyalleri, her R-R aralığında parçalanır ve ESA yapısına bir giriş olarak verilir. Pan Tompkins Algoritması sinyallerdeki QRS kompleksini saptayan gerçek zamanlı bir yöntemdir. (Pan & Tompkins, 1985: 230) ESA, basit ancak etkili bir yaklaşım olan Momentumlu Stokastik Gradyan İnişi kullanılarak optimize edildi. Momentum ile olasılıksal

azalmadaki salınımlar azaltılarak tutarlı ve hızlı bir optimizasyon yapılabilir. Evrişim çekirdek katmanının boyutu 5'tir. Parametreler geri yayılım ile güncellenir. Güncellenirken ters yönde türev alınarak fark bulunur. Bu değer daha sonra öğrenme oranı ile çarpılır. Yeni değer, bulunan değerın ağırlık parametrelerinden çıkarılması ile hesaplanır. Burada kullanılan öğrenme oranı sabit bir değer olan $3e^{-5}$ 'tir. Tam bağılı katmanın nöron sayısı 40'tır. Grup boyutu 64'tür. Tam bağılı katmandaki dropout oranı 0.80'dir. Girdi için Z-skoru normalizasyonu kullanıldı. Doğrulama kaybı 20 epoch boyunca düşmeyi bıraktığında eğitimi durdurmak için karar verme kriteri kullanıldı. Modelin doğruluk eğrisi 10. epoch sonrası doygunluğa ulaşmaktadır. Eğitim ve test setlerimiz %30 ve %70 oranında ayrıldı. ESA mimarimizin doğruluğu %90.7'dir. ESA mimarisinin doğruluğuna ait grafik Şekil 5'de verilmiştir.

Performans ölçmek için doğruluk, hassaslık ve özgünlük değerleri kullanılmıştır.. TP (True Positive) gerçek pozitif değerini, FP (False positive) yanlış pozitif değerini, TN (True negative) gerçek negatif değerini ve FN (False negative) yanlış negatif değerini ifade eder. (Tomak, 2025: 98) Doğruluk, duyarlılık, özgünlük ve F1 skor için matematiksel ifadeler Denklem 9-12'de verilmiştir. Örnek mimari 0.91 doğruluk, 0.93 duyarlılık, 0.91 özgünlük, 0.92 F1 skor değerine sahiptir.


$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (9)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (10)$$

$$\text{Özgünlük} = \frac{TN}{TN+FP} \quad (11)$$

$$\text{F1 skor} = 2 * \frac{\text{Hassaslık} * \text{Özgünlük}}{\text{Hassaslık} + \text{Özgünlük}} \quad (12)$$

Şekil 5. EKG verisini özellik olarak kullanan ESA mimarisinin doğruluğu



Model; evrişim, havuzlama, dropout ve tam bağlı katmanlarından oluşan standart bir yapı temelinde, Z-skoru normalizasyonu ve momentum tabanlı stokastik gradyan inişi kullanılarak optimize edilmiştir. Doğrulama kaybının 20 epoch boyunca azalmasının durmasına ilişkin erken durdurma kriteri ile aşırı uyumun önüne geçilmeye çalışılmıştır. Elde edilen sonuçlar, modelin %90.7 doğruluk oranına ulaştığını göstermektedir. Yüksek kapasitelere sahip ağlar ve büyük veri setleriyle çalışan söz konusu yaklaşımlar, eğitimi zorlaştıran önemli hesaplama maliyetleri gerektirmektedir. Bu bağlamda, bu çalışmada kullanılan model daha düşük parametrelili bir mimari ile rekabetçi bir performans sergilemiştir. Modelin tasarımında kullanılan dropout oranı tam bağlı katmanda aşırı uyumu azaltmayı hedeflemiştir. Derin öğrenmede, dropout'un %40–80 aralığında kullanılması sık tercih edilen bir uygulama olup, farklı değerlerin sistematik olarak denenmesi performans artışı sağlayabilir. Tüm süreç parametrelerinin değişik değerler ile denenmesiyle geliştirilebilir ve daha iyi performansa ulaşılabilir.

Kaynakça

Ahmed, A. A., Ali, W., Abdullah, T. A., & Malebary, S. J. (2023). Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model. *Mathematics*, 11(3), 562.

Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4). Springer.

Bottou, L. (1991). Stochastic gradient learning in neural networks. **Proceedings of Neuro-Nimes*, 91*(8), 12.

Ferrucci, D., Brown, E., Chu-Carroll, J., Fan, J., Gondek, D., Kalyanpur, A. A., ... Welty, C. (2010). Building Watson: An overview of the DeepQA project. *AI Magazine*, 31(3), 59–79.

Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215–e220.

Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2017). *Clinical electrocardiography: A simplified approach* [E-Book]. Elsevier Health Sciences.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Jun, T. J., Park, H. J., Minh, N. H., Kim, D., & Kim, Y. H. (2016, December). Premature ventricular contraction beat detection with deep neural networks. In *2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 859–864). IEEE.

Kiranyaz, S., Ince, T., & Gabbouj, M. (2015). Real-time patient-specific ECG classification by 1-D convolutional neural

networks. *IEEE Transactions on Biomedical Engineering*, 63(3), 664–675.

Jun, T. J., Park, H. J., Minh, N. H., Kim, D., & Kim, Y. H. (2016, December). Premature ventricular contraction beat detection with deep neural networks. In *2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 859-864). IEEE.

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.

O'Reilly, R. C., Munakata, Y., Frank, M. J., & Hazy, T. E. (2012). *Computational cognitive neuroscience*.

Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering*, 32(3), 230–236.

Pourbabae, B., Roshtkhari, M. J., & Khorasani, K. (2016, July). Feature learning with deep convolutional neural networks for screening patients with paroxysmal atrial fibrillation. In *2016 International Joint Conference on Neural Networks (IJCNN)* (pp. 5057–5064). IEEE.

Rajkumar, A., Ganesan, M., & Lavanya, R. (2019, March). Arrhythmia classification on ECG using Deep Learning. In *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)* (pp. 365–369). IEEE.

Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... Dieleman, S. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural

networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.

Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE Transactions on Medical Imaging*, 35(5), 1299–1312.

Tomak, Ö. (2025). Fındık meyvesinin sınıflandırılmasında Shufflenet ve Densenet derin öğrenme algoritmalarının performansının karşılaştırılması. *Hendese Teknik Bilimler ve Mühendislik Dergisi*, 2(2), 96–102..

Zabihi, M., Rad, A. B., Katsaggelos, A. K., Kiranyaz, S., Narkilahti, S., & Gabbouj, M. (2017, September). Detection of atrial fibrillation in ECG hand-held devices using a random forest classifier. In *2017 Computing in Cardiology (CinC)* (pp. 1–4). IEEE.

Zhang, C., Wang, G., Zhao, J., Gao, P., Lin, J., & Yang, H. (2017, February). Patient-specific ECG classification based on recurrent neural networks and clustering technique. In *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)* (pp. 63–67). ACTA Press.

BÖLÜM 9

BİLİŞİM SİSTEMLERİNDE DERİN ÖĞRENME TABANLI ÖNERİ VE KESTİRİM SİSTEMLERİ: DURUM DEĞERLENDİRMESİ VE GELECEK EĞİLİMLER

BURCU ÇARKLI YAVUZ¹

Giriş

Bilişim sistemleri, kurumsal ve bireysel karar verme süreçlerinin merkezinde yer alan, büyük hacimli ve çeşitli veri akışlarını yöneten yazılım ve donanım bileşenlerinden oluşan karmaşık yapılardır. İşlemsel kayıtlar, kullanıcı etkileşim verileri ve çevresel sensör ölçümleri gibi çok farklı veri kaynakları, hem mevcut durumu izlemek hem de geleceğe yönelik tahminlerde bulunmak için temel birer girdi hâline gelmiştir (Laudon & Laudon, 2022). Bu bağlamda, öneri sistemleri ve kestirim (tahmin) sistemleri, bilişim sistemlerinin ürettiği veriyi katma değere dönüştüren başlıca analitik bileşenler olarak öne çıkmaktadır.

Öneri sistemleri, kullanıcılara kişiselleştirilmiş ürün, hizmet veya içerik önermek amacıyla geliştirilen ve özellikle e-ticaret,

¹ Dr. Öğr. Üyesi, Sakarya Üniversitesi Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilişim Sistemleri Mühendisliği Bölümü, Orcid: 0000-0003-4089-024X

çevrimiçi medya platformları, eğitim ve sosyal ağ uygulamalarında yaygın olarak kullanılan araçlardır (Ricci, Rokach, & Shapira, 2015). Kestirim sistemleri ise, talep miktarı, kullanıcı trafiği, arıza olasılığı, trafik yoğunluğu veya enerji tüketimi gibi geleceğe dönük nicel değişkenlerin önceden tahmin edilmesini hedefler (Hyndman & Athanasopoulos, 2018). Geleneksel olarak bu sistemler istatistiksel modelleme ve klasik makine öğrenmesi yöntemleri ile tasarlanmıştır. Ancak veri hacminin, boyutunun ve çeşitliliğinin artması, ilişkilerin doğrusal olmayan ve zaman bağımlı yapılar sergilemesi, bu geleneksel yaklaşımların sınırlarını görünür kılmıştır.

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla veriden otomatik temsil (representation) öğrenebilen ve özellikle yüksek boyutlu, yapılandırılmamış verilerde (metin, görüntü, ses vb.) güçlü performans sergileyen bir yöntem ailesi olarak, öneri ve kestirim uygulamalarının niteliğini önemli ölçüde dönüştürmüştür (LeCun, Bengio, & Hinton, 2015). Kullanıcı ve öge (item) gömme (embedding) vektörlerinin, sıralı kullanıcı davranışlarının ve zengin bağlamsal bilgilerin aynı anda modellenebilmesi, derin öğrenme tabanlı yöntemlerin klasik yaklaşımlara kıyasla genellikle daha yüksek doğruluk ve esneklik sunmasını mümkün kılmaktadır (Zhang, Yao, Sun, & Tay, 2019; Lim & Zohren, 2021).

Bu bölümde, bilişim sistemlerinde derin öğrenme tabanlı öneri ve kestirim sistemlerine bütüncül bir bakış sunulmaktadır. Öncelikle öneri sistemlerinde kullanılan temel kavramlar ve derin öğrenme mimarileri ele alınmakta, ardından kestirim ve zaman serisi problemleri için geliştirilen derin öğrenme tabanlı yöntemler tartışılmaktadır. Devamında, bu modellerin bilişim sistemleri mimarilerine entegrasyonu ve literatürden seçilmiş üç vaka çalışması ayrıntılı biçimde incelenmektedir. Son olarak, performans ve ölçeklenebilirlik gibi pratik zorluklar ile gizlilik, güvenlik ve etik

boyutlar değerlendirilecek; araştırma boşlukları ve gelecek çalışmalara ilişkin öneriler sunulacaktır.

Öneri Sistemlerinde Temel Kavramlar ve Derin Öğrenme Yaklaşımları

1. Öneri Sistemlerinin Rolü ve Temel Kavramlar

Öneri sistemleri, kullanıcıların ilgi alanlarına ve ihtiyaçlarına uygun ürün, hizmet veya içeriğin otomatik olarak seçilip sunulmasını amaçlayan yazılım bileşenleridir. E-ticaret, çevrimiçi medya platformları, sosyal ağlar, eğitim sistemleri ve kurumsal bilgi yönetimi uygulamaları gibi pek çok bilişim sisteminde, kullanıcı deneyimini kişiselleştirmek, etkileşimi artırmak ve gelirleri yükseltmek için kritik bir rol oynarlar (Aggarwal, 2016). Öneri sistemleri sayesinde, kullanıcıların karşılaştığı bilgi fazlalığı azaltılmakta, arama maliyetleri düşürülmekte ve kullanıcı ile sistem arasındaki etkileşim daha verimli hâle gelmektedir.

Tipik bir öneri sistemi senaryosunda üç temel bileşen bulunur: kullanıcı, öge (item) ve kullanıcı–öge etkileşimi. Kullanıcı–öge etkileşimi; tıklama, görüntüleme, satın alma, puan verme, favorilere ekleme veya içerik üzerinde geçirilen süre gibi farklı biçimlerde ortaya çıkabilir. Bu etkileşimler çoğunlukla seyrek (sparse) bir kullanıcı–öge matrisi ya da olay (event) akışı şeklinde temsil edilir (Adomavicius & Tuzhilin, 2005). Öneri sistemlerinin temel görevi, gözlemlenmiş etkileşimlerden yola çıkarak, gözlemlenmemiş ancak kullanıcının ilgisini çekme olasılığı yüksek ögeleri öngörmektir.

2. Geleneksel Öneri Sistemi Yaklaşımları

Derin öğrenme tabanlı yöntemlere geçişi anlamlandırmak için, geleneksel öneri sistemi yaklaşımlarının kısaca özetlenmesi yararlıdır (Ricci ve ark., 2015; Aggarwal, 2016):

- İçerik tabanlı filtreleme (content-based filtering):

Öğeler, içerik özellikleri (metinsel açıklamalar, kategoriler, teknik özellikler vb.) ile temsil edilir. Kullanıcı profili, kullanıcının geçmişte etkileşimde bulunduğu öğelerin içerik özelliklerinin bir bileşimi olarak oluşturulur. Sistem, kullanıcı profiline içerik benzerliği yüksek öğeleri önermeye çalışır. Erken dönem çalışmalarda TF-IDF ve bag-of-words gibi temsiller kullanılırken, daha yakın zamanda kelime ve cümle gömme yöntemleri ile daha zengin temsil vektörleri elde edilmektedir (Lops, de Gemmis, & Semeraro, 2011).

- İşbirlikçi filtreleme (collaborative filtering):

Bu yaklaşımda, öğelerin içerik özelliklerinden ziyade kullanıcı-öge etkileşim desenleri kullanılır. “Benzer kullanıcılar benzer öğeleri tercih eder” veya “benzer öğeler genellikle aynı kullanıcılar tarafından tercih edilir” varsayımına dayanarak kullanıcı-temelli veya öge-temelli benzerlik hesaplamaları ve matris ayrıştırma (matrix factorization) teknikleri uygulanır (Koren, Bell, & Volinsky, 2009). Kullanıcılar ve ürünler, düşük boyutlu gizli (latent) faktör vektörleri ile temsil edilir; bu vektörler arasındaki iç çarpım ya da benzerlik ölçütleri, tahmini etkileşim skorlarının hesaplanmasında kullanılır.

- Hibrit yaklaşımlar:


İçerik tabanlı ve işbirlikçi filtreleme yöntemlerinin güçlü yönlerini birleştirmeyi amaçlayan hibrit yaklaşımlarda, örneğin matris ayrıştırma modellerinin kullanıcı/öge latent vektörleri içerik özellikleriyle zenginleştirilebilir veya işbirlikçi filtreleme tahminleri, içerik tabanlı benzerlik skorlarıyla birleştirilebilir (Burke, 2002).

Bu geleneksel yöntemler uzun yıllar boyunca başarılı sonuçlar elde etmiş olsa da, yüksek boyutlu, heterojen ve zaman bağımlı verilerle başa çıkma konusunda sınırlılıklar taşımaktadır. Özellikle karmaşık kullanıcı davranış kalıplarını, bağlamsal bilgiyi

ve çok modlu (metin, görüntü vb.) veriyi aynı anda modelleme gereksinimi, derin öğrenme tabanlı öneri sistemlerine olan ilgiyi artırmıştır.

Şekil 1'de görüldüğü gibi, klasik öneri sistemi işlem hattı basit, verimli ve yorumlanabilir bir yapıya sahiptir; ancak sınırlı özellik ifade gücü nedeniyle karmaşık kullanıcı davranışlarını modellemede yetersiz kalabilir. Buna karşın, derin öğrenme tabanlı işlem hattı zengin temsiller ve uzun menzilli örüntüleri yakalama kapasitesi sunmakla birlikte, daha yüksek karmaşıklık ve hesaplama maliyeti gerektirmektedir.

Şekil 1. Klasik ve derin öğrenme tabanlı bir öneri sistemi işlem hattının karşılaştırılması



3. Derin Öğrenme Tabanlı Öneri Sistemlerinin Ortaya Çıkışı

Derin öğrenme, çok katmanlı yapay sinir ağlarıyla veriden otomatik özellik (feature) ve temsil (representation) öğrenebilmesi sayesinde, öneri sistemlerinde yeni bir paradigma sunmuştur. Kullanıcı ve öğelere ilişkin özelliklerin yanı sıra, kullanıcıların zaman içindeki etkileşim dizileri, bağlam (örneğin zaman, konum, cihaz türü) ve içerik verileri (metin, görsel, ses) derin sinir ağı mimarileri aracılığıyla ortak bir vektör uzayında temsil edilebilmektedir. Böylece:

- daha zengin kullanıcı ve öğe gömmeleri,
- doğrusal olmayan ve karmaşık ilişkilerin modellenmesi,
- zaman bağımlı davranış kalıplarının yakalanması

mümkün olmakta; bu da pek çok uygulamada klasik yöntemlere kıyasla performans artışıyla sonuçlanmaktadır (He ve ark., 2017; Covington, Adams, & Sargin, 2016).

Derin öğrenme tabanlı öneri sistemleri genel olarak şu başlıklarda sınıflandırılabilir:

- gömme (embedding) tabanlı modeller,
- autoencoder ve derin faktörleştirme yaklaşımları,
- sıralı (sequence-aware) öneri sistemleri,
- graf sinir ağları (Graph Neural Networks, GNN) ve Transformer tabanlı mimariler (Wu, Sun, Zhang, Xie, & Cui, 2023; Zhang ve ark., 2024).

4. Gömme (Embedding) Tabanlı Modeller

Gömme tabanlı yaklaşımlarda, kullanıcılar ve öğeler, düşük boyutlu, yoğun (dense) vektörler olarak temsil edilir. Klasik matris ayrıştırma yöntemlerinin sinir ağı tabanlı genellemesi olarak görülebilecek bu modellerde, kullanıcı ve öğe gömmeleri sinir ağı

katmanları ile birlikte uçtan uca öğrenilir (He ve ark., 2017). Örneğin, bir kullanıcı ve bir öğe gömme vektörü birleştirilerek (concatenation) veya element bazlı çarpma/toplama gibi işlemlerle bütünleştirildikten sonra çok katmanlı algılayıcı (MLP) katmanlarına beslenir; tahmini etkileşim skoru bu ağın çıktısı olarak elde edilir.

Bu tür modeller, hem kullanıcı/öge kimliklerini hem de demografik bilgiler, kategori etiketleri ve metin temelli özellikler gibi ek bilgileri aynı temsil uzayında birleştirebilme esnekliği sağlar. Ayrıca gömme yaklaşımı, öneri sistemlerinin arama sıralaması veya tıklama tahmini gibi diğer görevlerle ortak temsiller üzerinden bütünleşmesine de imkân tanır (Cheng ve ark., 2016).

5. Autoencoder ve Derin Faktörleştirme Yaklaşımları

Autoencoder tabanlı öneri sistemlerinde, kullanıcı–öge etkileşim vektörleri sıkıştırma (encoding) ve yeniden yapılandırma (decoding) süreçlerinden geçirilerek, kullanıcının tercih profilini temsil eden gizli bir vektör uzayına gömülür. Kullanıcının gözlemlenmiş etkileşimleri girdi olarak kullanılır; ağın çıktısında, kullanıcının tüm öğelere yönelik tahmini tercih vektörü elde edilir. Kayıp fonksiyonu, gözlemlenmiş etkileşimlerin doğru yeniden yapılandırılmasını hedefler; böylece ağ, kullanıcı tercihlerinin düşük boyutlu ve anlamlı bir temsilini öğrenir (Sedhain, Menon, Sanner, & Xie, 2015).

Derin faktörleştirme (deep factorization) yaklaşımları ise klasik faktörleştirme yöntemlerinin derin ağ katmanları ile zenginleştirilmiş hâli olarak düşünülebilir. Kullanıcı ve öğe gömmelerinin yanı sıra; etkileşim bağlamı, cihaz türü ve kampanya bilgisi gibi ek özellikler, derin sinir ağı mimarileri ile işlenerek daha esnek ve ifade gücü yüksek modeller elde edilir (He ve ark., 2017; Rendle, 2010).

6. Sıralı (Sequence-Aware) Öneri Sistemleri

Birçok uygulama alanında kullanıcı davranışları, bağımsız etkileşimlerden ziyade zaman içinde gerçekleşen etkileşim dizileri olarak ortaya çıkmaktadır. Örneğin, bir kullanıcının bir e-ticaret platformunda ardışık şekilde incelediği veya satın aldığı ürünler, gelecekte ilgi gösterebileceği ürünlere ilişkin önemli ipuçları barındırır. Bu nedenle, sıralı öneri sistemlerinde hedef, yalnızca statik kullanıcı-öğe ilişkilerini değil, kullanıcı davranışlarının zaman içindeki evrimini de modellemektir (Quadrona, Cremonesi, & Jannach, 2018).

Derin öğrenme bağlamında, sıralı öneri sistemleri için sıklıkla kullanılan mimariler:

- Tekrarlayan sinir ağları (RNN, LSTM, GRU):

Kullanıcının geçmiş etkileşim dizisi bir zaman serisi olarak ele alınır ve her adımda güncellenen gizli durum vektörleri aracılığıyla gelecekteki etkileşimler tahmin edilir. LSTM ve GRU gibi kapalı yapılar, uzun bağımlılıkların modellenmesinde avantaj sağlar (Hidasi, Karatzoglou, Baltrunas, & Tikk, 2016).

- Konvolüsyonel yaklaşımlar (CNN/TCN tabanlı):

Zaman eksenini üzerinde kayan pencereler ve filtreler kullanılarak kısa ve orta vadeli davranış kalıpları yakalanabilir. Özellikle çok sayıda kısa oturumdan oluşan veri setlerinde etkilidir (Tang & Wang, 2018; Bai, Kolter, & Koltun, 2018).

- Transformer tabanlı sıralı öneri modelleri:

Dikkat (attention) mekanizması, kullanıcının geçmiş etkileşim dizisindeki öğeler arasındaki ilişkileri esnek ve konumdan bağımsız biçimde modellemeye olanak tanır. Bu sayede, uzun dizilerdeki uzak bağımlılıkların yakalanması kolaylaşmakta, paralelleştirilebilir yapı sayesinde de eğitim verimliliği artmaktadır (Kang & McAuley, 2018; Sun ve ark., 2019; Petrov & Macdonald, 2024).

Sıralı öneri sistemleri, oturum (session) tabanlı öneriler, kısa süreli kampanyalar, içerik akışları ve gerçek zamanlı etkileşimlerin yoğun olduğu senaryolarda önemli performans kazanımları sunmaktadır (Quadrana ve ark., 2018).

7. Graf Tabanlı ve Hibrit Derin Öğrenme Yaklaşımları

Son yıllarda, kullanıcı-öğre etkileşimlerinin ve öğeler arasındaki ilişkilerin doğal olarak bir grafik yapısı oluşturduğu fikrinden hareketle, graf sinir ağları (Graph Neural Networks, GNN) tabanlı öneri sistemleri önem kazanmıştır. Bu yaklaşımlarda kullanıcılar ve öğeler düğümler; aralarındaki etkileşimler veya ilişkiler ise kenarlar olarak modellenir. GNN mimarileri aracılığıyla, graf üzerinde komşuluk bilgisi çoklu geçişler boyunca birleştirilerek zengin kullanıcı ve öğre temsilleri elde edilir (Wu ve ark., 2023).

Metin, görsel ve ses gibi çok modlu içeriklerin derin öğrenme ile işlenmesi ve bu temsillerin öneri modellerine entegre edilmesiyle oluşturulan hibrit derin öğrenme tabanlı öneri sistemleri, özellikle içerik zenginliği yüksek alanlarda (örneğin dijital medya platformları) önemli bir araştırma alanı oluşturmaktadır (Zhang ve ark., 2019).

Tablo 1, bu bölümde ele alınan başlıca derin öğrenme mimarilerini özetlemektedir.

Tablo 1. Derin Öğrenme Mimarileri

Mimari	Tipik Kullanım Alanları	Başlıca Güçlü Yönler	Başlıca Sınırlılıklar	Temsili Çalışmalar
CNN	Görsel (görüntü tabanlı) öneriler, yerel örüntü çıkarımı, oturum (session) tabanlı öneri sistemleri	Yerel örüntüleri ve uzamsal korelasyonları yakalar; verimli evrimsel (convolutional) işlemler	Uzun menzilli zamansal bağımlılıkları modellemede daha az uygun	Zhang ve diğ. (2019); He ve diğ. (2016)
RNN / LSTM / GRU	Sıralı öneri, zaman serisi tahmini, tıklama akışı	Sıralı ve zamansal bağımlılıkları modelleyebilir; değişken	Eğitim yavaş olabilir; kaybolan gradyan sorunu (azaltılmış ama tamamen çözülmemiş);	Hidasi ve diğ. (2016); Donkers ve diğ. (2017)

	(clickstream) modelleme	uzunluklu dizileri işleyebilir	sınırlı paralelleştirilebilirlik	
Otomatik Kodlayıcı (Autoencoder)	Temsil (representation) öğrenme, boyut indirgeme, ortak filtreleme (collaborative filtering)	Sıkıştırılmış (kompakt) gizli temsiller öğrenir; gürültü giderme ve eksik veri tamamlama için etkilidir	Sıralı düzeni (zaman sırasını) göz ardı edebilir; performans dar boğaz (bottleneck) katmanının tasarımına çok bağlıdır	Sedhain ve diğ. (2015); Li ve diğ. (2017)
Dönüştürücü Tabanlı (Transformer, örn. BERT4Rec)	Sıralı ve oturum tabanlı öneri, bağlamsal dizi modelleme	Uzun menzilli bağımlılıkları yakalar; öz-dikkat (self-attention) sayesinde paralel çalıştırılabilir; esnek girdi temsilleri	Yüksek hesaplama ve bellek maliyeti; hiperparametreler ve veri ölçeğine karşı hassastır	Sun ve diğ. (2019); Kang ve McAuley (2018)
GNN	Grafik tabanlı öneri (kullanıcı-öge grafikleri, bilgi grafikleri, sosyal ağlar)	Yüksek dereceli bağlantıları (high-order connectivity) kullanır; karmaşık ilişkileri ve heterojen grafikleri doğal biçimde modeller	Büyük ölçekli grafalarda ölçeklenebilirlik sorunları; graf yapısının/kurulumunun kalitesine karşı hassas	Wu ve diğ. (2020); Wang ve diğ. (2019)
Hibrit / Ansambl (Ensemble)	Hibrit öneri sistemleri, çoklu-modlu (multi-modal) öğrenme, sağlamlık (robustluk) artırma	Birden fazla modelin güçlü yönlerini birleştirir; yan bilgi ve heterojen sinyalleri entegre edebilir	Artan model karmaşıklığı ve eğitim maliyeti; yorumlamak ve ayarlamak (tune etmek) daha zordur	Burke (2002); Zhang ve diğ. (2020)

Öneri sistemlerinde klasik yöntemlerden derin öğrenme tabanlı gömme, autoencoder, sıralı ve graf mimarilerine uzanan güçlü bir evrim söz konusudur. Bir sonraki bölümde, benzer bir dönüşümün zaman serisi tabanlı kestirim ve tahmin problemlerinde nasıl gerçekleştiği ele alınacaktır.

Kestirim (Tahmin) Sistemleri ve Zaman Serisi Analizi için Derin Öğrenme Yöntemleri

1. Kestirim Sistemlerinin Bilişim Sistemlerindeki Rolü

Kestirim (tahmin) sistemleri, biliřim sistemlerinde kayıt altına alınan tarihsel verilerden yararlanarak geleceęe yönelik nicel deęiřkenlerin öngörölmesini amaçlayan analitik bileřenlerdir. Talep miktarı, kullanıcı trafięi, tıklanma oranı, satış hacmi, enerji tüketimi, ekipman arıza olasılığı, aę yoğunluęu veya gecikme süreleri gibi pek çok büyüklük, operasyonel ve stratejik karar süreçleri açısından kritik öneme sahiptir. Doğru ve güvenilir tahminler; kaynak planlama, kapasite yönetimi, envanter kontrolü, dinamik fiyatlandırma, bakım planlama ve hizmet kalitesi optimizasyonu gibi alanlarda doğrudan deęer üretir.

Geleneksel olarak kestirim problemleri, zaman serisi analizine dayalı istatistiksel yöntemler (örneğin ARIMA, Exponential Smoothing) ve klasik makine öğrenmesi yaklaşımları (örneğin regresyon modelleri, aęaç tabanlı yöntemler) kullanılarak ele alınmıştır (Box, Jenkins, Reinsel, & Ljung, 2016). Ancak veri kaynaklarının çeřitlenmesi, örnekleme sıklığının artması, çok deęiřkenli zaman serilerinin yaygınlaşması ve karmařık, doğrusal olmayan iliřkilerin ortaya çıkması, bu geleneksel yöntemlerin sınırlılıklarını belirgin hâle getirmiştir. Bu bağlamda, derin öğrenme tabanlı yöntemler, yüksek boyutlu ve karmařık zaman serilerinin modellenmesinde güçlü bir alternatif olarak öne çıkmaktadır (Fawaz ve ark., 2019; Lim & Zohren, 2021).

2. Kestirim Problemlerinin Sınıflandırılması

Biliřim sistemlerinde karşılaşılan kestirim problemleri farklı boyutlara göre sınıflandırılabilir (Lim & Zohren, 2021):

- Tahmin ufkuna göre:
 1. Kısa vadeli tahmin (dakika, saat, gün)
 2. Orta/uzun vadeli tahmin (hafta, ay, yıl)
- Çıkış boyutuna göre:

1. Tek adımlı tahmin (bir sonraki zaman noktasının tahmini)
 2. Çok adımlı tahmin (birden fazla gelecekteki zaman noktasının tahmini)
- Değişken sayısına göre:
 1. Tek değişkenli (univariate) zaman serisi
 2. Çok değişkenli (multivariate) zaman serisi
 - Görev türüne göre:
 1. Regresyon tabanlı tahmin (sürekli değerler)
 2. Sınıflandırma tabanlı tahmin (olay/olay değil, kategori tahmini)

Bu çeşitlilik, derin öğrenme yöntemlerinin esnek mimari yapıları sayesinde farklı kestirim senaryolarına uyarlanabilmesini kolaylaştırmaktadır.

3. Zaman Serisi için LSTM ve GRU Tabanlı Modeller

Zaman serisi verilerinde ardışık gözlemler arasındaki bağımlılıkların modellenmesi, klasik tam bağılı sinir ağlarının (feed-forward) doğrudan kullanımını güçleştirmektedir. Bu nedenle, tekrarlayan sinir ağları (Recurrent Neural Networks, RNN) ve özellikle LSTM (Long Short-Term Memory) ile GRU (Gated Recurrent Unit) gibi kapılı RNN mimarileri, zaman serisi kestiriminde yaygın olarak kullanılmaktadır (Hochreiter & Schmidhuber, 1997; Cho ve ark., 2014).

LSTM ve GRU mimarileri, geçmişteki gözlemlerden gelen bilginin hangi ölçüde saklanacağı veya unutulacağına kapılar aracılığıyla karar vererek uzun dönemli bağımlılıkların öğrenilmesini mümkün kılar. Bilişim sistemlerinde kullanıcı trafiğinin zamana göre dalgalanması, mevsimsellik etkileri ve sistem

yükü ile arıza kayıtları arasındaki ilişkiler bu tür modellerle yakalanabilmektedir. Girdi olarak çoğunlukla geçmiş zaman dilimlerine ait gözlemler bir pencere (window) şeklinde modele beslenir; model, hedeflenen bir veya daha fazla gelecek zaman adımını çıktıda üretir.

4. CNN ve TCN Tabanlı Zaman Serisi Modelleri

Zaman serisi için konvolüsyonel sinir ağlarının (CNN) kullanımı, özellikle son yıllarda popülerlik kazanmıştır. Bir boyutlu konvolüsyon katmanları (1D-CNN), zaman eksenini üzerinde kayan filtreler kullanarak kısa ve orta vadeli yerel kalıpları yakalamak için etkilidir (Fawaz ve ark., 2019). CNN tabanlı zaman serisi modelleri; yüksek paralelleştirme imkânı, görece az parametre ile hızlı eğitim ve kısa vadeli örüntülerin etkin yakalanması gibi avantajlar sunar.

Zaman konvolüsyonel ağlar (Temporal Convolutional Networks, TCN), genişletilmiş (dilated) konvolüsyonlar ve uygun dolgu stratejileri kullanarak hem kısa hem de uzun vadeli bağımlılıkları derin konvolüsyon katmanları üzerinden modelleyebilir. TCN'ler, istikrarlı gradyan akışı ve yüksek paralelleştirilebilirlik gibi avantajları nedeniyle bazı senaryolarda RNN tabanlı modellere kıyasla daha iyi performans ve eğitim verimliliği sağlayabilmektedir (Bai ve ark., 2018).

5. Transformer Tabanlı Zaman Serisi Yaklaşımları

Transformers, başlangıçta doğal dil işleme görevleri için geliştirilmiş olsa da (Vaswani ve ark., 2017), çok başlı dikkat (multi-head attention) mekanizması sayesinde zaman serisi analizinde de güçlü araçlar hâline gelmiştir. Ardışık hesaplama gerektirmemesi ve giriş dizisinin tüm konumları arasındaki ilişkileri aynı anda modelleyebilmesi, özellikle uzun dizilerde önemli avantajlar sağlar (Lim & Zohren, 2021; Nie ve ark., 2023; Liu ve ark., 2024).

Zaman serisi için uyarlanmış Transformer tabanlı modellerde genellikle:

- zaman adımlarına pozisyon bilgisi kazandırmak için konumsal kodlama (positional encoding),
- mevsimsellik ve trend bileşenlerini modelleyen özel katmanlar,
- çok değişkenli girdiler için birlikte dikkat (joint attention) mekanizmaları

kullanılmaktadır. Bu tür modeller uzun ufuklu ve çok değişkenli tahmin problemlerinde öne çıkmakla birlikte, yüksek hesaplama ve bellek gereksinimleri nedeniyle pratik uygulamalarda model boyutu, pencere uzunluğu ve veri örnekleme stratejilerinin dikkatle seçilmesini gerektirir.

6. Özellik Mühendisliği, Dış Değişkenler ve Bağlamsal Bilgi

Derin öğrenme yöntemleri veriden otomatik temsil öğrenme kabiliyetine sahip olmakla birlikte, zaman serisi kestiriminde özellik mühendisliği ve bağlamsal bilgilerin (context) modele dâhil edilmesi hâlen önemli bir rol oynamaktadır. Yalnızca ham ölçüm değerleri değil; zamanla ilgili özellikler (günün saati, haftanın günü, ay, tatil bilgisi), iş yükü ile ilişkili kategorik değişkenler (kullanıcı segmenti, bölge, sunucu grubu) ve dışsal (exogenous) değişkenler (hava durumu, kampanya dönemleri, sistem konfigürasyon değişiklikleri) tahmin performansını önemli ölçüde etkileyebilmektedir (Lim & Zohren, 2021).

Bu tür bağlamsal bilgiler, genellikle ek giriş kanalları veya gömme vektörleri şeklinde temsil edilerek ana zaman serisi verisi ile birlikte işlenir.

7. Multi-Task ve Çok Adımlı Kestirim Stratejileri

Bilişim sistemlerinde çoğu zaman yalnızca tek bir büyüklüğün değil, birden fazla ilgili çıktının aynı anda tahmini gerekli olabilmektedir. Örneğin, hem tıklanma oranının hem de gelir tahmininin yapılması veya farklı coğrafi bölgeler için talep tahminlerinin birlikte üretilmesi söz konusu olabilir. Bu durumda çok görevli öğrenme (multi-task learning) yaklaşımları kullanılabilir. Ortak bir temsil katmanı üzerinde, her çıktı için ayrı bir baş (head) tanımlanarak görevler arası paylaşılan bilginin genelleme yeteneğini artırması hedeflenir (Ruder, 2017).

Çok adımlı kestirim (multi-step forecasting) problemlerinde ise, gelecekteki birden fazla zaman noktasının tahmini gereklidir. Bu durumda, doğrudan (direct), tekrarlayan (recursive) ve hibrit stratejiler kullanılmakta; derin öğrenme modelleri bu üç strateji ile de uyumlu biçimde tasarlanabilmektedir (Lim & Zohren, 2021).

8. Kestirim Performansının Değerlendirilmesi ve Uygulama Bağlamı

Derin öğrenme tabanlı kestirim sistemlerinin değerlendirilmesinde sadece istatistiksel hata metrikleri değil, iş bağlamına özgü sonuçlar da dikkate alınmalıdır. Yaygın metrikler arasında MAE, RMSE ve MAPE gibi hata temelli ölçütler ile açıklanan varyans oranı (R^2) ve sapma (bias) gibi göreceli performans ölçütleri yer alır (Box ve ark., 2016). Bununla birlikte, kapasite planlaması, envanter yönetimi veya SLA ihlalleri gibi uygulama sonuçları da performans değerlendirmesine dâhil edilmelidir.

Tablo 2, farklı modelleme yaklaşımlarının temel uygulama alanlarındaki yaygınlığını karşılaştırmaktadır.

Tablo 2. Uygulama alanları $\times$ yöntemler

Alan	İçerik tabanlı	Ortak filtreleme	Hibrit	Graf Tabanlı (GNN)	NLP Tabanlı / Sıralı (örn. BERT4Rec)
E-ticaret	Yaygın olarak kullanılır (ürün)	Yaygın olarak kullanılır	Çok yaygın	Giderek daha fazla kullanılıyor	Artan benimsenme (oturum)

	açıklamaları, görseller)	(kullanıcı-öğre etkileşimleri)		(kullanıcı-öğre grafikleri, bilgi grafikleri)	tabanlı ve tıklama akışı modelleme)
Eğitim (e-öğrenme)	Öğrenme kaynakları ve ders içerikleri için kullanılır	Öğrenci-öğre etkileşim kayıtları	Gelişmekte	Kullanıcı-kaynak grafikleri, kavram grafikleri	Öğrenme izlerinin sıralı modellenmesi
Sağlık	Sınırlı fakat artan kullanım (klinik notlar, görüntüleme)	Hasta-hizmet / hasta-ilaç etkileşimleri	Gelişmekte	Hasta benzerlik grafikleri, tıbbi bilgi grafikleri	Metin tabanlı klinik kayıtlar; zamansal olay dizileri
Finans	Haberler, raporlar, metin tabanlı açıklamalar	İşlemsel ve davranışsal veriler	Gelişmekte	Finansal işlem ağları, varlık grafikleri	Zamana göre sıralanmış olaylar; haber odaklı dizi modelleme
Sosyal medya	Kullanıcı profilleri, paylaşımlar, multimedya içerikler	Takip / arkadaşlık / etkileşim verileri	Çok yaygın	Sosyal grafikler, etkileşim grafikleri	Kullanıcı etkinlik akışlarının sıralı modellenmesi
Akıllı ulaşım	Rota ve ilgi noktası (POI) tanımları	Geçmiş kullanım kayıtları	Gelişmekte	Yol ve POI grafikleri, hareketlilik ağları	Araç ve kullanıcı yörüngeleri diziler olarak

Zaman serisi kestirimi alanında LSTM/GRU, CNN/TCN ve Transformer tabanlı derin mimariler güçlü alternatifler sunmakta; bağlamsal bilgi, çok görevli öğrenme ve uygun değerlendirme metrikleriyle birlikte ele alındığında bilişim sistemleri için yüksek katma değer üretmektedir. Bir sonraki bölümde bu modellerin bilişim sistemleri mimarisindeki konumu ve tasarım kararlarını şekillendiren güncel eğilimler tartışılacaktır.

Bilişim Sistemleri Mimarisi İçinde Öneri ve Kestirim Motorları ve Güncel Eğilimler

1. Bilişim Sistemleri Mimarisi İçinde Öneri ve Kestirim Motorlarının Konumlanması

Kurumsal bilişim sistemleri çoğu zaman üç katmanlı bir mimari çerçevede ele alınmaktadır: Veri katmanı, uygulama/iş mantığı katmanı ve sunum (arayüz) katmanı.

Derin öğrenme tabanlı öneri ve kestirim motorları, bu katmanların kesişiminde konumlanan ve farklı kaynaklardan gelen veriyi işleyerek karar süreçlerini besleyen analitik bileşenlerdir:

- Veri katmanı:

İşlem kayıtları, kullanıcı–öge etkileşim geçmişi, sensör verileri, log kayıtları ve haricî veri kaynakları (meteorolojik veriler, sosyal medya akışları, pazar verileri) yer alır. Bu veriler veri ambarı veya veri gölü (data lake) yapılarında toplanmakta, ETL/ELT süreçleri ile temizlenip dönüştürülmektedir.

- Uygulama/iş mantığı katmanı:

Derin öğrenme tabanlı modellerin eğitimi ve çıkarım (inference) süreçlerini yöneten servisler burada bulunur. Genellikle mikroservis mimarisi çerçevesinde tasarlanmış, ölçeklenebilir öneri motorları, tahmin servisleri ve model yönetim bileşenlerinden oluşur.

- Sunum katmanı:

Öneri sistemlerinde kişiselleştirilmiş ürün listeleri, “sizin için seçtiklerimiz” panelleri veya hedefli kampanyalar; kestirim sistemlerinde ise gösterge panoları, uyarı mekanizmaları ve karar destek ekranları bu katmanda kullanıcıya sunulur.

Bu çerçevede, model seçimi, özellik seçimi, açıklanabilirlik ve hesaplama maliyeti gibi teknik kararlar yalnızca veri bilimi perspektifinden değil, aynı zamanda sistem mimarisi, hizmet seviyesi hedefleri ve kurumsal kısıtlar açısından da değerlendirilmelidir.

2. Model Seçimi ve Zaman Çözünürlüğü İlişkisi

Zaman serisi tabanlı kestirim uygulamalarında model seçiminin, veri setinin zaman çözünürlüğü ile yakından ilişkili olduğu görülmektedir. Geniş zaman aralıklarında (günlük, haftalık

vb.) gürültünün azalması ve eğilim bileşenlerinin güçlenmesi, çoğu durumda doğrusal modellere veya düzenlileştirilmiş klasik regresyon yaklaşımlarına avantaj sağlayabilmektedir. Buna karşın, saatlik ya da dakikalık gibi yüksek frekanslı verilerde, doğrusal olmayan ilişkiler ve kısa süreli dalgalanmalar belirgin hâle geldiğinden bellekli derin öğrenme modelleri (LSTM vb.) daha başarılı sonuçlar verebilmektedir.

Güneş enerjisi üretim kestirimi üzerine yapılan bir çalışmada, günlük verilerde Ridge regresyonun, saatlik verilerde ise LSTM mimarisinin en başarılı yaklaşımlar olduğu gösterilmiştir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025). Bu bulgu, derin öğrenme yöntemlerinin her zaman “en iyi” seçenek olmayabileceğini, veri çözünürlüğü ve problem doğasına uygun model seçiminin kritik önem taşıdığını vurgulamaktadır.

Benzer şekilde, farklı bir uygulama alanında kalite kontrol süreçlerinde süreç dışı durumların nedenlerini belirlemek için topluluk makine öğrenimi modellerinin etkinliği gösterilmiştir (Demircioğlu Diren & Boran, 2024). Bu tür yaklaşımlar, öneri ve kestirim sistemlerinde derin modellerle birlikte veya onların yerine klasik ve topluluk (ensemble) yöntemlerin de güçlü birer alternatif olabileceğini göstermektedir.

3. Özellik (Öznitelik) Seçimi ve Meta-Sezgisel Optimizasyon

Derin öğrenme tabanlı sistemlerin başarısı yalnızca model mimarisine değil, aynı zamanda kullanılan özellik kümesine de doğrudan bağlıdır. Yüksek boyutlu veri kümelerinde tüm değişkenlerin modele dâhil edilmesi hem hesaplama maliyetini artırmakta hem de aşırı öğrenme (overfitting) riskini büyütmektedir. Bu nedenle, tıbbi karar destek sistemleri ve müşteri davranışı modelleme gibi alanlarda, sınıflandırma veya regresyon modeli öncesinde özellik seçimi adımı kritik bir ön işleme bileşeni hâline gelmiştir.

Meta-sezgisel optimizasyon algoritmaları bu bağlamda öne çıkmaktadır. Nüfus tabanlı, doğa esinli bu yöntemler; arama uzayının geniş olduğu, amaç fonksiyonunun analitik olarak türetilmediği veya birden çok hedefin (doğruluk, maliyet, özellik sayısı vb.) birlikte optimize edilmesi gereken durumlarda güçlü bir çerçeve sunar. Deniz Yırtıcıları Algoritması (Marine Predators Algorithm, MPA) (Faramarzi ve ark., 2020) ve Balina Optimizasyon Algoritması (Whale Optimization Algorithm, WOA) (Mirjalili & Lewis, 2016) gibi yeni nesil meta-sezgiseller, özellik seçimi problemini, sınıflandırma başarımı ile seçilen özellik sayısı arasında denge kuran bir optimizasyon görevi olarak ele alabilmektedir.

Perinatal dönemde anksiyete ve depresyon tespitine yönelik bir çalışmada, MPA + kNN tabanlı özellik seçimi ile 147 özellikten yalnızca beşinin seçilmesine karşın %98'in üzerinde doğruluk elde edilmesi, derin/öğrenme tabanlı kestirim sistemlerinde akıllı özellik seçiminin ne derece kritik olduğunu ortaya koymaktadır (Oğur ve ark., 2023). Benzer biçimde, SaaS ortamında müşteri kaybı (churn) kestiriminde WOA tabanlı özellik seçimiyle, 17 değişkenli tam modele kıyasla 3–10 özellikten oluşan alt kümelerle hem daha yorumlanabilir hem de daha başarılı modeller geliştirilebildiği gösterilmiştir (Kotan ve ark., 2025).

Özetle, MPA ve WOA gibi meta sezgisel optimizasyon algoritmaları, öneri ve tahmin uygulamalarında özellik seçimi ve hiperparametre ayarlaması için giderek daha fazla kullanılmaktadır.

Tablo 3, temsili meta sezgisel algoritmaların ve makine öğrenimi ve derin öğrenme modelleriyle birlikte kullanıldığında tipik rollerinin bir özetini sunmaktadır.

Tablo 3 – Özellik seçimi ve hiperparametre ayarlaması için makine öğrenimi ve derin öğrenme modelleriyle birlikte kullanılan temsili meta sezgisel optimizasyon algoritmaları

Meta-sezgisel (yöntem)	Optimizasyon Hedefi	Tipik Uygulama Bağlamı	Avantajlar	Zorluklar
Deniz Yırtıcıları Algoritması (MPA)	Hiperparametre ayarlama, özellik (feature) seçimi	Hibrit öneri, kullanıcı davranışı tahmini	Yerel minimumlardan kaçınır; iyi keşif-sömürü (exploration-exploitation) dengesi sağlar	Ek hesaplama yükü getirir; parametre ayarlarına karşı hassastır
Balina Optimizasyon Algoritması (WOA)	Ağırlık başlatma, hiperparametre arama	Derecelendirme (puan) tahmini, talep tahmini	Uygulaması basittir; dışbükey olmayan (non-convex) uzaylarda rekabetçi performans sunar	Erken yakınsama riski vardır; dikkatli ayarlama gerektirir
Parçacık Sürü Optimizasyonu (PSO)	Ağ ağırlıkları, öğrenme oranı planları	Zaman serisi ve dizi modelleme, kullanıcı etkinliği tahmini	Sezgisel sürü dinamikleri; davranışı iyi incelenmiştir	Durgunluğa girebilir; performans sürü yapılandırmasına bağlıdır
Genetik Algoritma (GA)	Mimari arama, özellik alt kümesi seçimi	Model mimarisi tasarımı, çoklu-modlu (multi-modal) öneri	Esnek temsil; çok amaçlı (multi-objective) optimizasyonu destekler	Kodlama tasarımı karmaşık olabilir; hesaplama açısından maliyetlidir

4. Alan Uzmanı Bilgisi, Açıklanabilirlik ve Karar Destek

Derin öğrenme modellerinin yüksek doğrulukları yanında çoğu zaman “kara kutu” niteliğinde olmaları, özellikle sağlık, enerji ve kritik iş süreçlerinde açıklanabilirlik (explainability) ihtiyacını gündeme getirmektedir. Model çıktılarının alan uzmanlarıyla birlikte değerlendirilmesi ve seçilen özelliklerin klinik ya da işlevsel karşılığının sorgulanması, karar destek sistemlerine entegrasyonda önemli bir ara adım işlevi görmektedir.

Perinatal anksiyete ve depresyon çalışmasında, MPA + kNN ile seçilen beş özelliğin (örneğin, daha önce psikiyatrik tedavi almış olma, gebelik döneminde psikiyatrik tanı alma, eşin madde kullanımı vb.) psikiyatristler tarafından klinik olarak anlamlı bulunması, sadece model doğruluğunun değil, aynı zamanda modelin gerçek yaşam pratikleriyle uyumunun da önemini

göstermektedir (Oğur ve ark., 2023). SaaS müşteri kaybı çalışmasında ise “ürün sayısı”, “müşteri sayısı” ve “pazar yeri sayısı” gibi değişkenlerin churn üzerinde belirleyici olması, yöneticilerin somut aksiyonlar (yeni pazar yerleri açma, ürün çeşitlendirme vb.) tasarlamasını kolaylaştıran açıklanabilir çıkarımlar sunmaktadır (Kotan ve ark., 2025).

5. Hesaplama Maliyeti, Genelleme ve Uygulama Kısıtları

Derin öğrenme tabanlı öneri ve kestirim sistemlerinin yaygınlaştırılmasında hesaplama maliyeti, gerçek zamanlı gereksinimler ve kurumsal altyapının sınırlılıkları kritik rol oynar. Güneş enerjisi kestirimi çalışmasında, LSTM modelleri saatlik veride en yüksek doğruluğu sağlarken, eğitim süresi ve bellek kullanımının klasik regresyon ve ağaç tabanlı yöntemlere kıyasla belirgin biçimde daha yüksek olduğu raporlanmıştır (Çarklı Yavuz & Aksoy Tırmıkçı, 2025). Buna karşılık Ridge regresyonun günlük tahminlerde hem çok yüksek doğruluk hem de çok düşük hesaplama maliyeti ile çalışabilmesi, birçok pratik senaryoda derin modeller yerine daha yalın yöntemlerin tercih edilebileceğini göstermektedir.

SaaS churn kestiriminde WOA ile özellik azaltımı, eğitim ve çıkarım süresini kısaltarak, gerçek zamanlıya yakın karar destek uygulamalarının geliştirilmesini kolaylaştırmaktadır (Kotan ve ark., 2025). Burada model doğruluğu, hesaplama maliyeti ve yorumlanabilirlik arasında problem bağlamına uygun bir denge kurulması gerekir.

6. Genel Değerlendirme

Genel olarak bakıldığında, derin öğrenme tabanlı öneri ve kestirim sistemleri:

- yüksek frekanslı, karmaşık ve doğrusal olmayan veri kümelerinde belirgin performans avantajı sağlayabilmekte,

- meta-sezgisel tabanlı özellik seçimi ile birleştirildiklerinde, geleneksel yöntemlere kıyasla daha az girdiyle daha yüksek doğruluk sunabilmekte,
- ancak hesaplama maliyeti, açıklanabilirlik ve uygulama bağlamına ilişkin kısıtlar nedeniyle her problem için “tek doğru çözüm” olmaktan uzaktır.

Model mimarisi, veri çözünürlüğü, özellik seçimi, açıklanabilirlik ve hesaplama maliyeti birlikte ele alınmadan, derin öğrenme tabanlı sistemlerin kurumsal bilişim mimarilerine sürdürülebilir biçimde entegre edilmesi mümkün değildir. Bir sonraki bölümde bu çerçeve, üç gerçek hayat vaka çalışması üzerinden somutlaştırılacaktır.

Vaka Analizleri

Bu bölümde, derin öğrenme tabanlı öneri ve kestirim sistemlerinin farklı alanlardaki uygulamalarını gösteren üç özgün çalışma vaka analizi biçiminde sunulmaktadır:

1. Güneş enerjisi üretim kestirimi için makine öğrenmesi ve derin öğrenme modellerinin karşılaştırılması (Çarklı Yavuz & Aksoy Tırmıkçı, 2025),
2. Perinatal dönemde anksiyete ve depresyon tespiti için MPA + kNN tabanlı özellik seçimi ve sınıflandırma (Oğur ve ark., 2023),
3. SaaS ortamında müşteri kaybı (churn) kestirimi için WOA tabanlı özellik seçimi ve çoklu sınıflandırma algoritmaları (Kotan ve ark., 2025).

Her vaka için problem tanımı, veri yapısı, kullanılan yöntemler, elde edilen bulgular ve derin öğrenme/öneri-kestirim sistemleri bağlamındaki çıkarımlar ele alınmaktadır.

1. Vaka 1: Güneş Enerjisi Üretim Kestiriminde Makine Öğrenmesi ve Derin Öğrenme Modellerinin Karşılaştırılması

Problem Tanımı ve Veri Seti

Birinci vaka çalışmasında amaç, yenilenebilir enerji entegrasyonu ve şebeke kararlılığı açısından kritik öneme sahip olan güneş enerjisi üretimini, meteorolojik veriler kullanarak hem günlük hem de saatlik düzeyde tahmin etmektir. Çalışmada, Kartepe bölgesinde yer alan bir güneş enerjisi santraline ait 2014–2020 yılları arasındaki üretim verileri, aynı döneme ait yüksek çözünürlüklü meteorolojik verilerle birleştirilmiştir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025).

Kullanılan başlıca öznitelikler:

- Hava sıcaklığı, bağıl nem, yağış miktarı,
- Bulutluluk oranı, güneşlenme süresi, kısa dalga radyasyon,
- Rüzgâr hızı ve yönü,
- Bağımlı değişken olarak enerji üretimi (kWh).

Yaklaşık 2.500 günlük ve 61.000'den fazla saatlik gözlem içeren iki ayrı veri kümesi oluşturulmuştur. Saatlik veri setinde gece saatlerine karşılık gelen yüksek oranlı sıfır üretim değerleri, değerlendirme metrikleri ve modelleme stratejisi açısından ayrıca dikkate alınmıştır.

Yöntemler ve Modelleme Yaklaşımı

Vaka çalışmasında hem klasik zaman serisi hem de modern makine öğrenmesi ve derin öğrenme yöntemleri karşılaştırmalı olarak değerlendirilmiştir:

- Doğrusal modeller: Lineer regresyon, Ridge, Lasso
- Ağaç tabanlı yöntem: XGBoost

- Derin öğrenme: LSTM ağırları
- Klasik zaman serisi: ARIMA, SARIMA
- Otomatik zaman serisi: Prophet

Modelleme sürecinde:

- Zaman damgasından takvim özellikleri (ay, hafta günü, yıl günü, saat) türetilmiş,
- Gecikmeli değişkenler ve hareketli ortalamalarla zaman bağımlılıkları yakalanmış,
- Ölçekleme ve aykırı değer azaltımı uygulanmış,
- Zaman serisine özgü genişleyen pencere (expanding window) çapraz doğrulama kullanılmıştır.

LSTM modeli için çok katmanlı bir mimari (örneğin iki LSTM katmanı ve yoğun çıktı katmanı), Huber kaybı ve Adam optimize edicisi kullanılmış; erken durdurma ve öğrenme oranı ayarlamalarıyla genelleme performansı iyileştirilmiştir.

Bulgular ve Tartışma

Günlük kestirim sonuçları, Ridge regresyonun çok yüksek doğrulukla ($R^2 \approx 0.9997$, düşük RMSE değerleriyle) en başarılı yöntem olduğunu göstermiştir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025). Günlük toplulaştırma, meteorolojik değişkenlerle enerji üretimi arasındaki ilişkinin büyük ölçüde doğrusal bir yapıya büründüğünü ortaya koymaktadır.

Saatlik kestirimde ise LSTM modeli $R^2 \approx 0.96$ seviyesinde en yüksek performansı sergilemiş; XGBoost buna çok yakın fakat bir miktar daha düşük başarı sağlamıştır. ARIMA ve SARIMA gibi tek değişkenli klasik zaman serisi modelleri, hem günlük hem de saatlik veride negatif R^2 değerleri ile ortalama tahmininden bile daha kötü sonuçlar üretmiştir.

Bu vaka, derin öğrenme tabanlı kestirim sistemlerinin:

- yüksek frekanslı, karmaşık verilerde ciddi avantaj sağladığını,
- ancak günlük gibi daha “düzgün” veri yapısında düzenlileştirilmiş doğrusal modellerin daha uygun ve ekonomik olabileceğini,
- meteorolojik (dışsal) değişkenlerin modele entegrasyonunun performans için kritik olduğunu

göstermektedir.

2. Vaka 2: Perinatal Dönemde Anksiyete ve Depresyonun MPA + kNN ile Tespiti

Problem Tanımı ve Veri Seti

İkinci vaka çalışmasında amaç, perinatal dönemde (gebelikten doğum sonrası 12. aya kadar) görülen anksiyete ve depresyon riskini, klinik ve ölçek temelli verilerden yararlanarak otomatik bir sınıflandırma sistemi ile tespit etmektir (Oğur ve ark., 2023). Çalışma, hem anne hem de bebek sağlığı üzerinde ciddi etkileri olan perinatal psikiyatrik durumların erken dönemde belirlenmesi için karar destek sunmayı hedeflemektedir.

Veri seti, Sakarya Üniversitesi Araştırma Hastanesi kadın doğum polikliniklerine başvuran 393 gebenin:

- Sosyodemografik ve klinik veri formu (SDVF),
- Edinburgh Doğum Sonrası Depresyon Ölçeği (EPDS),
- Perinatal Anksiyete Tarama Ölçeği’nin Türkçe formu (PASS-TR)

üzerinden toplanan yanıtlarından oluşturulmuştur. Ölçeklerin kesme puanları kullanılarak, “anksiyete ve/veya depresyon var” (1) ve “her ikisi de yok” (0) olmak üzere ikili bir sınıf etiketi tanımlanmıştır. Ön-

işleme sonrası kategorik değişkenlere uygulanan One-Hot kodlama ile başlangıçtaki 57 özellik 147 boyutlu bir özellik uzayına genişlemiştir.

Yöntem ve Hibrit MPA + kNN Yaklaşımı

Yüksek boyutlu bu veri setinde, tüm özelliklerle doğrudan modelleme yapmak hem hesaplama maliyeti hem de genelleme açısından dezavantajlı olacağından, özellik seçimi için Marine Predators Algorithm (MPA) (Faramarzi ve ark., 2020) kullanılmış ve k-en yakın komşu (kNN) sınıflandırıcısı ile bütünleştirilerek hibrit bir yaklaşım geliştirilmiştir.

Özellik seçimi sürecinde:

- Her bir özellik alt kümesi, MPA içindeki bir “av” pozisyonu olarak temsil edilmiştir.
- Amaç fonksiyonu; kNN doğruluğunu maksimize ederken seçilen özellik sayısını minimize eden iki terimli bir uygunluk fonksiyonu olarak tanımlanmıştır.
- Süreç, belirli bir ajan sayısı ve iterasyon ile nüfus tabanlı bir arama olarak yürütülmüş; ikili eşikleme ile sürekli konumlar $\{0,1\}$ özellik seçimine dönüştürülmüştür.
- Nihai model, 10 katlı çapraz doğrulama ve uygun k değeri için kNN sınıflandırıcı ile değerlendirilmiştir.

Karşılaştırma için, tüm özellikler ve Chi-kare tabanlı iki farklı özellik alt kümesi de aynı sınıflandırıcı ile test edilmiştir.

Bulgular ve Tartışma

Sonuçlar, tüm özelliklerle yapılan sınıflandırmada doğruluğun görece düşük kaldığını; MPA + kNN ile seçilen yalnızca 5 özellik kullanıldığında ise doğruluğun %98’in üzerine çıktığını göstermiştir (Oğur ve ark., 2023). Chi-kare ile seçilen 4 ve 14

özellikli alt kümeler de yüksek performans üretmiş olmakla birlikte, MPA tabanlı hibrit yaklaşım genel olarak en yüksek doğruluk ve F1 skorunu sağlamıştır.

En dikkat çekici bulgu, MPA + kNN ile seçilen beş özelliğin tamamının, alan uzmanı psikiyatristlerce klinik açıdan anlamlı ve tanı sürecinde kritik kabul edilen değişkenler olmasıdır. Bu sonuç, meta-sezgisel özellik seçiminin, yalnızca model başarımını artırmakla kalmayıp aynı zamanda klinik açıklanabilirliği güçlendirdiğini göstermektedir.

3. Vaka 3: SaaS Ortamında Müşteri Kaybı (Churn) Kestirimi için WOA Tabanlı Özellik Seçimi

Problem Tanımı ve Veri Seti

Üçüncü vaka çalışmasında amaç, B2B yazılım hizmeti sunan bir SaaS sağlayıcısının kurumsal müşterileri için churn riskini, kullanım ve işlem verilerine dayalı olarak tahmin etmek ve karar vericilere daha az sayıda fakat daha anlamlı gösterge ile destek sunmaktır (Kotan ve ark., 2025).

Veri seti, bir bulut tabanlı ERP sağlayıcısının yaklaşık 1.100 müşterisine ait 17 özelliği içermektedir. Örnek olarak:

- Sistem üzerinde tanımlı ürün sayısı,
- Son kullanıcı müşteri sayısı,
- Sipariş, teklif, fatura ve ödeme belgesi sayıları,
- Kullanılan pazar yeri sayısı,
- Nakit kasa sayısı, e-posta entegrasyonu sayısı, özel rapor sayısı,
- Kullanıcı sayısı, destek talebi (ticket) sayısı,
- Müşteri statüsü (churn / churn değil).

Veri ön-işleme adımlarında churn sınıfları dengelenmiş ve anomali/aykırı değerler temizlenmiştir.

WOA Tabanlı Özellik Seçimi ve Sınıflandırma

Özellik seçimi için Balina Optimizasyon Algoritması (Whale Optimization Algorithm, WOA) (Mirjalili & Lewis, 2016) kullanılmış ve kNN ile bütünleştirilmiştir. WOA, öz nitelik alt kümelerini arayan ajan “balinaların” konumlarını, sürü içi etkileşim ve baloncuk-ağ (bubble-net) avlanma stratejileri ile güncelleyerek optimum çözümü arayan bir meta-sezgisel olarak tasarlanmıştır.

Çalışmada:

- WOA, 17 özellikten oluşan tam uzayda alt kümeler üretmiştir.
- Uygunluk fonksiyonu; kNN hatasını ve seçilen özellik sayısının oranını ceza terimiyle birleştiren çift bileşenli bir fonksiyon olarak tanımlanmıştır.
- WOA ile elde edilen en iyi üç alt küme (örneğin 3, 5 ve 10 özellik içeren WOA-1, WOA-2, WOA-3) yanında; tüm özellikler ve Chi-kare tabanlı alt kümeler de karşılaştırmaya dâhil edilmiştir.
- Tahmin için kNN, Karar Ağaçları, Naive Bayes, Rastgele Ormanlar ve Yapay Sinir Ağı kullanılmış; 10 katlı çapraz doğrulama ile AUC, doğruluk, kesinlik, duyarlılık ve F1 skorları hesaplanmıştır (Kotan ve ark., 2025).

Bulgular ve Tartışma

Sonuçlar, WOA ile seçilmiş özellik kümelerinin çoğu durumda:

- tam 17 özellikli modele kıyasla daha yüksek doğruluk ve F1 skoru ürettiğini,

- Chi-kare tabanlı alt kümelerle benzer ya da daha iyi AUC değerleri sağladığını

göstermiştir. Örneğin, Rastgele Orman sınıflandırıcısında tam model ile elde edilen F1 skoru ile WOA-3 (10 özellik) ile elde edilen F1 skoru arasında WOA lehine anlamlı bir iyileşme raporlanmıştır (Kotan ve ark., 2025).

Ayrıca, Rastgele Orman ile hesaplanan özellik önem ağırlıkları, “müşteri sayısı”, “ürün sayısı” ve “pazar yeri sayısı” değişkenlerinin churn üzerinde en belirleyici faktörler olduğunu ortaya koymuştur. Bu bulgu, SaaS bağlamında:

- sisteme daha fazla ürün entegre eden,
- daha fazla nihai müşteriye hizmet veren,
- birden fazla pazar yerinde satış yapan kullanıcıların

hizmeti bırakma olasılığının daha düşük olduğu yönünde işlevsel bir içgörü sunmaktadır.

Vaka Analizlerinin Genel Değerlendirmesi

Üç vaka birlikte değerlendirildiğinde:

- veri çözünürlüğü ve model seçimi ilişkisi (günlük vs. saatlik güneş enerjisi verisi),
- meta-sezgisel özellik seçimi ile yüksek doğruluk ve açıklanabilirlik (perinatal çalışma),
- işletme verisi üzerinde çalışan meta-sezgisel tabanlı özellik seçiminin yönetsel yorumlanabilirliği artırması (SaaS churn)

gibi temalar öne çıkmaktadır. Bir sonraki bölümde bu tür sistemlerin performans, ölçeklenebilirlik ve pratik zorlukları daha genel bir çerçevede tartışılacaktır.

Performans, Ölçeklenebilirlik ve Pratik Zorluklar

1. Performans Değerlendirme Metrikleri

Öneri ve kestirim sistemlerinin başarımı, bağlam duyarlı bir çerçeve içinde değerlendirilmelidir.

- Öneri sistemlerinde:

İsabet oranı (precision@k), yakalama oranı (recall@k), ortalama doğruluk (MAP), normalize edilmiş sıralama kalitesi (NDCG), kapsama oranı (coverage) ve çeşitlilik (diversity) gibi metrikler kullanılır (Aggarwal, 2016). Derin öğrenme tabanlı öneri sistemleri çoğu zaman NDCG ve MAP gibi sıralama duyarlı metriklerde klasik yöntemlere kıyasla anlamlı iyileşmeler sağlayabilmektedir (He ve ark., 2017; Covington ve ark., 2016).

- Zaman serisi kestiriminde:

MAE, RMSE, MAPE ve R^2 gibi hata ve açıklanan varyans ölçütleri yaygındır (Box ve ark., 2016). Güneş enerjisi üretim kestirimi vakasında, günlük ve saatlik tahminler için RMSE ve R^2 kullanılarak günlük düzeyde Ridge regresyonun, saatlik düzeyde ise LSTM modelinin üstünlüğü gösterilmiştir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025).

- Sınıflandırma temelli kestirimlerde:

Doğruluk, duyarlılık (sensitivite), özgüllük (specificity), F1 skoru ve AUC gibi metrikler önemlidir. Perinatal anksiyete ve depresyon tespitinde doğruluk, duyarlılık ve F1 skoru; SaaS churn kestiriminde ise bunlara ek olarak AUC değeri kullanılmıştır (Oğur ve ark., 2023; Kotan ve ark., 2025).

Tek bir metrik yerine, hem doğruluk/hata ölçütlerini hem de iş gereksinimlerini yansıtan daha geniş bir performans setinin birlikte kullanılması, derin öğrenme tabanlı sistemlerin kurumsal bağlamda daha sağlıklı değerlendirilmesini mümkün kılar.

2. Ölçeklenebilirlik: Veri Hacmi, Model Boyutu ve Altyapı Gereksinimleri

Büyük ölçekli bilişim sistemlerinde öneri ve kestirim motorlarının başarısı, doğruluk kadar ölçeklenebilme yeteneklerine de bağlıdır. Kullanıcı–öge etkileşim matrislerinin milyonlarca kullanıcı ve ürünü içerebildiği, saniyede binlerce isteğin geldiği veya sensör ağlarından sürekli yüksek frekanslı veri akışının olduğu senaryolarda, derin öğrenme tabanlı modellerin eğitimi ve gerçek zamanlı çıkarımı ciddi hesaplama kaynakları gerektirebilir.

Ölçeklenebilirlik açısından kritik noktalar:

- Veri işleme hattı:

Büyük hacimli etkileşim ve zaman serisi verilerinin çevrim dışı (batch) ve çevrim içi (stream) işleme boru hatları üzerinden, hatasız ve düşük gecikmeyle modele beslenmesi gerekir.

- Model eğitimi:

Özellikle Transformer tabanlı yapılar milyonlarca parametre içerebilir. Bu durumda GPU/TPU hızlandırmalı dağıtık eğitim, mini-batch stratejileri ve öğrenme oranı planlaması gibi teknikler kaçınılmaz hâle gelir (Vaswani ve ark., 2017; Lim & Zohren, 2021).

- Model çıkarımı (inference) ve gecikme:

Öneri sistemleri çoğu zaman milisaniye mertebesinde yanıt süreleri gerektirir. Bu nedenle eğitimde kullanılan kompleks bir model, üretim ortamında daha hafif bir türeviyle (model küçültme, kuantizasyon, bilgi damıtma vb.) temsil edilebilir. SaaS churn vakasında WOA ile azaltılmış özellik kümeleri üzerinde çalışan sınıflandırıcılar, hem eğitim hem de çıkarım süresinde iyileşme sağlayarak, ölçeklenebilir karar destek uygulamaları için daha uygun bir yapı sunmuştur (Kotan ve ark., 2025).

Bu çerçevede, derin öğrenme tabanlı öneri ve kestirim sistemlerinin tasarımında model karmaşıklığı ile altyapı kapasitesi arasında sürdürülebilir bir denge kurulması zorunludur (Kreuzberger, Köhl, & Hirschl, 2023).

3. Çevrim İçi Öğrenme, Kavram Kayması ve Güncelleme Stratejileri

Bilişim sistemlerinde veri dağılımları zaman içinde değişebilir; kullanıcı tercihleri, pazar koşulları, teknoloji ve mevzuat gibi faktörler nedeniyle, daha önce geçerli olan örüntüler güncelliğini yitirebilir. Bu olgu kavram kayması (concept drift) olarak adlandırılır ve hem öneri sistemlerinde hem kestirim uygulamalarında önemli bir zorluk alanıdır.

Kavram kaymasıyla başa çıkmak için:

- periyodik yeniden eğitim,
- kayar pencere (sliding window) yaklaşımı,
- çevrim içi / artan öğrenme (online/incremental learning)

gibi stratejiler kullanılmaktadır (Bai ve ark., 2018; Lim & Zohren, 2021). Ancak bu stratejilerin tümü ek hesaplama maliyeti ve operasyonel karmaşıklık getirir. Özellikle sağlık ve finans gibi regülasyonun güçlü olduğu alanlarda, model versiyonlarının, eğitim verisi dönemlerinin ve performans değişimlerinin izlenmesi ve belgelendirilmesi kritik öneme sahiptir (Oğur ve ark., 2023).

4. Veri Kalitesi, Önyargılar ve Gerçek Dünya Kısıtları

Derin öğrenme tabanlı öneri ve kestirim sistemlerinin performansı, girdisi olan verinin kalitesiyle sınırlıdır. Eksik, hatalı, tutarsız veya önyargılı veri setleri; hem istatistiksel performansı düşürebilir hem de etik ve hukuki açıdan sorunlu sonuçlara yol açabilir.

Sık karşılaşılan veri kaynaklı zorluklar:

- eksik ve dengesiz veriler,
- kayıt ve ölçüm hataları (sensör arızaları, log kesintileri),
- belirli kullanıcı gruplarının veya kurum tiplerinin veri setlerinde yeterince temsil edilmemesi (temsil önyargısı).

Bu bağlamda veri kalitesi yönetimi, veri yönetişimi süreçleri ve veri toplama stratejilerinin tasarımı, derin öğrenme tabanlı sistemlerin başarısında en az model seçimi kadar belirleyici hâle gelmiştir (Mehrabı ve ark., 2021).

Performans metrikleri, ölçeklenebilirlik, kavram kayması ve veri kalitesi gibi faktörler, derin öğrenme tabanlı öneri ve kestirim sistemlerinin gerçek hayata aktarımında temel belirleyicilerdir. Bir sonraki bölümde gizlilik, güvenlik ve etik boyutlar ele alınacaktır.

Gizlilik, Güvenlik ve Etik Boyutlar

Gizlilik ve Kişisel Verilerin Korunması

Öneri ve kestirim sistemleri çoğu zaman kullanıcıların davranış geçmişi, demografik bilgileri, konum verileri, tıbbi kayıtları veya finansal işlemleri gibi kişisel veriler üzerinde eğitilmektedir. Bu durum, veri koruma mevzuatları (örneğin KVKK, GDPR) ve kurumsal gizlilik politikaları açısından çeşitli yükümlülükler doğurmaktadır.

Başlıca ilkeler:

- Veri minimizasyonu:

Belirli bir görev için gerçekten gerekli olmayan kişisel verilerin toplanmaması ve saklanmaması, hem riskleri hem hukuki sorumlulukları azaltır. Perinatal anksiyete ve depresyon tespiti için yapılan çalışmada, MPA + kNN ile yalnızca beş nitelik üzerinden yüksek doğruluğa ulaşılması, veri minimizasyonu ilkesinin teknik

olarak da mümkün ve rasyonel olduğunu göstermektedir (Oğur ve ark., 2023).

- Anonimleştirme ve takma adlandırma:

Özellikle sağlık ve finans alanlarında, bireyleri doğrudan tanımlayan bilgiler modelleme sürecine dâhil edilmemeli; bunun yerine anonimleştirilmiş veya takma ad (pseudonym) kullanılmış kayıtlar üzerinden çalışılmalıdır.

- Erişim kontrolü ve veri paylaşımı:

Model geliştiricilerinin kişisel verilere erişimi “bilmesi gereken” ilkesi doğrultusunda sınırlandırılmalı; üçüncü taraflarla veri paylaşımı söz konusu olduğunda hukuki ve teknik kısıtlar açıkça tanımlanmalıdır.

Güneş enerjisi üretim kestirimi veya SaaS churn gibi alanlarda verinin kişisel nitelikte olmaması gizlilik risklerini görece azaltmakla birlikte, kurumsal gizlilik (müşteri sözleşmeleri, ticari sırlar vb.) açısından yine de dikkat gerektirir.

2. Model Güvenliği ve Kötüye Kullanım Riskleri

Derin öğrenme tabanlı öneri ve kestirim sistemleri, model ve altyapı güvenliği açısından da çeşitli tehditlere açıktır. Örneğin, öneri sistemlerinde sahte hesaplar ve manipülatif etkileşimler aracılığıyla belirli ürün veya içeriklerin öne çıkarılması, modelin çıktılarının kötüye kullanılmasına yol açabilir (Aggarwal, 2016). Benzer biçimde, kestirim sistemlerine yanlış veya yanıltıcı veri enjekte edilmesi, kapasite planlama ve risk yönetimi kararlarını olumsuz etkileyebilir.

Başlıca riskler:

- veri enjeksiyonu ve zehirleme saldırıları (data poisoning),
- model hırsızlığı ve tersine mühendislik,

- adversarial örnekler.

Bu risklerle mücadele için giriş doğrulama mekanizmaları, anomali tespiti, model ve veri bütünlüğü kontrolleri, güçlü kimlik doğrulama ve yetkilendirme politikaları gereklidir.

3. Önyargı, Adalet ve Ayrımcılık Riskleri

Veri odaklı karar destek sistemleri, eğitim verisinde var olan önyargıları farkında olmadan yeniden üretebilir veya güçlendirebilir. Belirli demografik grupların, coğrafi bölgelerin veya kurum tiplerinin veri setlerinde yeterince temsil edilmemesi, bu gruplar için öneri kalitesinin veya tahmin doğruluğunun sistematik olarak düşük olmasına neden olabilir (Mehrabi ve ark., 2021).

Dikkat edilmesi gerekenler:

- veri setinin hedef kitleyi yeterince temsil edip etmediği (temsil adaleti),
- farklı gruplar için hata oranlarının sistematik farklılık gösterip göstermediği (çıktı adaleti),
- gerekirse ek adalet kısıtları içeren (fairness-aware) modellerin geliştirilmesi.

Öneri sistemleri bağlamında ayrıca, sadece “en çok kârlı” ürünleri ön plana çıkaran bir strateji, uzun vadede kullanıcı deneyimini bozabilir ve az temsil edilen niş içeriklerin görünürlüğünü azaltarak ekosistem düzeyinde adalet sorunları doğurabilir (Burke, 2002; Quadrana ve ark., 2018).

4. Klinik ve Kurumsal Karar Destek Bağlamında Etik Sorumluluk

Derin öğrenme tabanlı öneri ve kestirim sistemlerinin ürettiği çıktılar, özellikle sağlık ve kritik iş süreçlerinde, doğrudan insan hayatını ve kurumsal sürdürülebilirliği etkileyen kararları

biçimlendirebilmektedir. Bu nedenle bu tür sistemlerin kullanımı etik sorumluluk çerçevesinde değerlendirilmelidir.

Perinatal anksiyete ve depresyon vakasında geliştirilen MPA + kNN tabanlı model, klinisyenlere yüksek doğrulukla riskli olguları işaret eden bir karar destek aracı sunmaktadır (Oğur ve ark., 2023). Ancak bu durum, nihai tanı sorumluluğunun tamamen modele devredilebileceği anlamına gelmemelidir. Benzer şekilde, SaaS churn veya enerji üretim tahmini gibi alanlarda, model çıktıları otomatik kararlar için kullanılmadan önce belirli eşik değerleri ve insan denetim mekanizmaları ile desteklenmelidir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025; Kotan ve ark., 2025).

5. Şeffaflık, Açıklanabilirlik ve Kullanıcı Güveni

Derin öğrenme tabanlı sistemlerin “kara kutu” doğası, kullanıcılar ve karar vericiler nezdinde güvensizlik yaratabilir. Özellikle, “neden bu ürün bana önerildi?” ya da “neden bu hasta ‘riskli’ olarak sınıflandırıldı?” sorularının cevaplanamaması, sistemlerin benimsenmesini zorlaştırır.

Bu sorunu hafifletmek için açıklanabilir yapay zekâ (Explainable AI, XAI) yöntemleri yaygınlık kazanmıştır. Özellikle tablo verileri ve zaman serileri üzerinde:

- özellik önem ağırlıkları,
- yerel açıklama yöntemleri (LIME, SHAP),
- örnek tabanlı açıklamalar

kullanılarak model kararlarının en azından kısmen yorumlanması mümkündür (Linardatos, Papastefanopoulos, & Kotsiantis, 2021). SaaS churn vakasında Rastgele Orman sınıflandırıcısı ile hesaplanan özellik önem ağırlıklarının, işletme birimleri açısından kolay anlaşılır ve eyleme dönüştürülebilir içgörüler sağlaması buna iyi bir örnektir (Kotan ve ark., 2025). Perinatal çalışmada ise MPA + kNN

ile seçilen beş özelliğin klinik açıdan anlamlı bulunması, modelin açıklanabilirliğini ve klinik güvenilirliğini güçlendirmiştir (Oğur ve ark., 2023).

Gizlilik, güvenlik, adalet ve açıklanabilirlik, derin öğrenme tabanlı öneri ve kestirim sistemlerinin yalnızca teknik değil, aynı zamanda etik ve hukuki açıdan da sağlam temellere oturmasını gerektirir. Son bölümde, bu bütün çerçeve ışığında araştırma boşlukları ve gelecek çalışma yönleri tartışılacaktır.

Araştırma Boşlukları ve Gelecek Çalışmalar

1. Öneri Sistemlerinde Gelişen Mimariler ve Uygulama Boşlukları

Öneri sistemleri literatüründe, klasik içerik tabanlı ve işbirlikçi filtreleme yaklaşımlarından gömme tabanlı derin modeller, GNN ve Transformer temelli sıralı öneri sistemlerine uzanan güçlü bir teorik gelişim gözlenmektedir (Zhang ve ark., 2019; Wu ve ark., 2023; Petrov & Macdonald, 2024). Bununla birlikte, bu gelişmiş mimarilerin kurumsal bilişim sistemlerinde geniş ölçekte ve sistematik biçimde hayata geçirilmesi hâlen sınırlıdır.

Özellikle:

- GNN ve hibrit mimarilerin ERP, CRM, B2B SaaS gibi büyük ölçekli kurumsal ortamlara entegrasyonunun maliyetleri ve bakım gereksinimleri,
- açıklanabilir ve güvenilir öneri sistemlerinin tasarımı,
- çok kanallı ve çok modlu öneri sistemlerinin kurumsal bağlamda uygulanması

önemli araştırma ve uygulama boşlukları olarak durmaktadır (Burke, 2002; Quadrana ve ark., 2018; Zhang ve ark., 2024).

2. Zaman Serisi Kestiriminde Uzun Ufuk, Belirsizlik ve Çok Görevli Öğrenme

Derin öğrenme tabanlı zaman serisi kestiriminde LSTM, GRU, CNN/TCN ve Transformer mimarilerinin kısa ve orta vadeli tahminlerde güçlü performans sergilediği çok sayıda çalışma ile gösterilmiştir (Fawaz ve ark., 2019; Lim & Zohren, 2021; Nie ve ark., 2023; Liu ve ark., 2024). Buna karşın:

- uzun vadeli kestirim ve belirsizlik modelleme (olasılıksal tahmin, güven aralıkları),
- farklı zaman ölçeklerinde (saatlik ve günlük gibi) ve farklı bölgeler/segmentler için eş zamanlı tahmin yapan çok görevli (multi-task) modeller,
- kavram kaymasına duyarlı, kendi kendini güncelleyebilen adaptif derin zaman serisi modelleri

konularında, özellikle kurumsal bilişim sistemleri bağlamında geniş ölçekli uygulamalara ihtiyaç vardır.

3. Meta-Sezgisel Özellik Seçimi ve Derin Öğrenme Entegrasyonu

Bu bölümde sunulan iki vaka (perinatal anksiyete/depresyon tespiti ve SaaS churn kestirimi), meta-sezgisel optimizasyon algoritmalarının (MPA, WOA) özellik seçimi bağlamında güçlü bir çerçeve sunduğunu göstermektedir (Oğur ve ark., 2023; Kotan ve ark., 2025). Ancak bu yaklaşımın derin öğrenme mimarileriyle bütünleştirilmesi henüz başlangıç aşamasındadır.

Gelecek çalışmalar için:

- derin ağların ara katmanlarından elde edilen gömme temsilleri üzerinde meta-sezgisel tabanlı seçim ve boyut indirgeme,

- meta-sezgisel algoritmaların kararlılık (stability) ve genellenebilirlik analizleri,
- doğruluk, açıklanabilirlik, veri toplama maliyeti ve karar verme süresini birlikte optimize eden çok amaçlı (multi-objective) meta-sezgisel çerçeveler

önemli araştırma başlıkları olarak öne çıkmaktadır.

4. Alan Uzmanı İşbirliği, Açıklanabilirlik ve Kullanıcı Merkezli Tasarım

Vaka çalışmalarında görüldüğü üzere, derin öğrenme tabanlı modellerin çıktılarının alan uzmanlarıyla birlikte yorumlanması, hem modelin açıklanabilirliğini artırmakta hem de pratik uygulama değeri yaratmaktadır (Oğur ve ark., 2023; Kotan ve ark., 2025). Buna karşın, birçok akademik çalışmada model değerlendirmesi ağırlıklı olarak istatistiksel metrikler üzerinden yapılmakta; klinisyenler, mühendisler veya yöneticiler gibi nihai kullanıcıların geri bildirimleri sınırlı kalmaktadır.

Gelecek çalışmalar için:

- ortak tasarım (co-design) yaklaşımlarının yaygınlaştırılması,
- etkileşimli açıklama sistemlerinin (kullanıcının “özellik değişseydi ne olurdu?” sorusuna yanıt alabildiği arayüzler) geliştirilmesi,
- derin öğrenme tabanlı sistemlerin uzun vadeli etkilerini inceleyen boylamsal çalışmaların artırılması

önemli yönelimlerdir.

Önceki bölümlere dayanarak, derin öğrenmeye dayalı öneri ve tahmin sistemlerinin temel avantajları ve kalan zorlukları aşağıdaki gibi özetlenebilir (Tablo 4).

Tablo 4 – Avantajlar ve Zorluklar

Avantajlar	Zorluklar ve açık sorunlar
• Farklı (heterojen) verilerden zengin, yüksek boyutlu temsiller (embeddings) öğrenme yeteneği; • Karmaşık ve yüksek derecede doğrusal olmayan ortamlarda gelişmiş doğruluk; • Zamansal, sıralı ve bağlamsal bilgilerin daha iyi modellenmesi; • Çoklu-modlu (metin, görsel, grafik, zaman serisi) öğrenmeyi destekleme; • Ham günlük (log) verilerden önerilere kadar uçtan uca öğrenme potansiyeli	• Eğitim ve dağıtım için yüksek veri ve hesaplama gereksinimleri; • Karmaşık derin modellerin sınırlı yorumlanabilirliği ve açıklanabilirliği; • Hiperparametre ayarlama ve mimari arama süreçlerinin hala güç olması; • Büyük ölçekli dağıtımlarda gizlilik, adalet ve etik konular; • Mevcut bilgi sistemleri ve eski (legacy) altyapılarla entegrasyon

5. Bu Bölümün Katkıları ve Genel Değerlendirme

Bu kitap bölümü, bilişim sistemlerinde derin öğrenme tabanlı öneri ve kestirim sistemlerine ilişkin literatürü bütüncül bir bakış açısıyla ele alarak; temel kavramlar ve model ailelerini, gerçek dünyadan üç somut vaka çalışmasıyla birlikte değerlendirmeyi amaçlamıştır. Öneri sistemleri ve zaman serisi kestirimine yönelik derin mimariler, bilişim sistemleri mimarisindeki konumları, performans ve ölçeklenebilirlik boyutları ile birlikte tartışılmış; gizlilik, güvenlik ve etik sorularına dikkat çekilmiştir.

Sunulan vaka analizleri:

- güneş enerjisi üretim kestiriminde veri çözünürlüğü ve model seçimi ilişkisinin,
- perinatal anksiyete ve depresyon tespitinde meta-sezgisel özellik seçimi ve klinik açıklanabilirliğin,
- SaaS ortamında müşteri kaybı kestiriminde ise işletme verisi üzerinde çalışan meta-sezgisel tabanlı özellik seçiminin

nasıl pratik sonuçlara dönüştürülebileceğini göstermektedir (Çarklı Yavuz & Aksoy Tırmıkçı, 2025; Oğur ve ark., 2023; Kotan ve ark., 2025).

Gelecek alıřmaların, burada tartıřılan arařtırma bořluklarını ele alırken yalnızca teknik performansa deęil, aynı zamanda kurumsal entegrasyon, kullanıcı güveni, etik sorumluluk ve açıklanabilirlik boyutlarına da bütüncül bir bakıř aısıyla yaklaşması beklenmektedir. Böylece, derin öğrenme tabanlı öneri ve kestirim sistemlerinin, biliřim sistemleri içinde sürdürülebilir, güvenilir ve toplum yararına hizmet eden bileřenler hâline gelmesi mümkün olacaktır.

Kaynakça

- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state of the art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749. <https://doi.org/10.1109/TKDE.2005.99>
- Aggarwal, C. C. (2016). *Recommender systems: The textbook*. Springer.
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint*, arXiv:1803.01271. <https://arxiv.org/abs/1803.01271>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331–370. <https://doi.org/10.1023/A:1021240730564>
- Cheng, H.-T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., ... Shah, H. (2016). Wide & deep learning for recommender systems. In *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems (DLRS '16)* (pp. 7–10). ACM. <https://doi.org/10.1145/2988450.2988454>
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. In *Proceedings of EMNLP 2014* (pp. 1724–1734). <https://doi.org/10.3115/v1/D14-1179>

Covington, P., Adams, J., & Sargin, E. (2016). Deep neural networks for YouTube recommendations. In *Proceedings of RecSys '16* (pp. 191–198). ACM. <https://doi.org/10.1145/2959100.2959190>

Çarklı Yavuz, B., & Aksoy Tirmıkçı, C. (2025). Comparative analysis of machine learning and deep learning models for solar energy forecasting: A meteorological data-driven approach. *Journal of Mathematical Sciences and Modelling*, 8(3), 153–166. <https://doi.org/10.33187/jmsm.1726677>

Demircioğlu Diren, D., & Boran, S. (2024). Classification of quality defects using multivariate control chart with ensemble machine learning model. *Journal of Intelligent Systems: Theory and Applications*, 7(2), 129–144. <https://doi.org/10.38016/jista.1516453>

Faramarzi, A., Heidarinejad, M., Mirjalili, S., & Gandomi, A. H. (2020). Marine Predators Algorithm: A nature-inspired metaheuristic. *Expert Systems with Applications*, 152, 113377. <https://doi.org/10.1016/j.eswa.2020.113377>

Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L., & Muller, P.-A. (2019). Deep learning for time series classification: A review. *Data Mining and Knowledge Discovery*, 33(4), 917–963. <https://doi.org/10.1007/s10618-019-00619-1>

He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural collaborative filtering. In *Proceedings of WWW '17* (pp. 173–182). <https://doi.org/10.1145/3038912.3052569>

Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2016). Session-based recommendations with recurrent neural networks. In *Proceedings of ICLR 2016*. <https://arxiv.org/abs/1511.06939>

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- Kang, W.-C., & McAuley, J. (2018). Self-attentive sequential recommendation. In *Proceedings of ICDM 2018* (pp. 197–206). IEEE. <https://doi.org/10.1109/ICDM.2018.00035>
- Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), 30–37. <https://doi.org/10.1109/MC.2009.263>
- Kotan, M., Seymen, Ö. F., Çallı, L., Kasım, S., Yavuz, B. Ç., & Özçelik, T. Ö. (2025). A novel methodological approach to SaaS churn prediction using Whale Optimization Algorithm. *PLOS ONE*, 20(5), e0319998. <https://doi.org/10.1371/journal.pone.0319998>
- Kreuzberger, D., Kühl, N., & Hirschl, S. (2023). Machine learning operations (MLOps): Overview, definition, and architecture. *IEEE Access*, 11, 31866–31879. <https://doi.org/10.1109/ACCESS.2023.3262138>
- Laudon, K. C., & Laudon, J. P. (2022). *Management information systems* (17th ed.). Pearson.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lim, B., & Zohren, S. (2021). Time series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2021). Explainable AI: A review of machine learning interpretability methods. *Entropy*, 23(1), 18. <https://doi.org/10.3390/e23010018>
- Liu, Y., Hu, T., Zhang, H., Wu, H., Wang, S., Ma, L., & Long, M. (2024). iTransformer: Inverted Transformers are effective for time

series forecasting. In *Proceedings of ICLR 2024*.
<https://openreview.net/forum?id=JePfAI8fah>

Lops, P., de Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor (Eds.), *Recommender systems handbook* (pp. 73–105). Springer. https://doi.org/10.1007/978-0-387-85820-3_3

Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), Article 115. <https://doi.org/10.1145/3457607>

Mirjalili, S., & Lewis, A. (2016). The Whale Optimization Algorithm. *Advances in Engineering Software*, 95, 51–67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>

Nie, Y., Nguyen, N. H., Sinthong, P., & Kalagnanam, J. (2023). A time series is worth 64 words: Long-term forecasting with Transformers. In *Proceedings of ICLR 2023*. <https://openreview.net/forum?id=Jbdc0vTOcol>

Oğur, N. B., Kotan, M., Balta, D., Çarklı Yavuz, B., Oğur, Y. S., Uslu Yuvacı, H., & Yazıcı, E. (2023). Detection of depression and anxiety in the perinatal period using Marine Predators Algorithm and KNN. *Computers in Biology and Medicine*, 161, 107003. <https://doi.org/10.1016/j.compbiomed.2023.107003>

Petrov, A., & Macdonald, C. (2024). Generative sequential recommendation with GPTRec. In *Proceedings of ECIR 2024* (pp. 3–19). Springer. https://doi.org/10.1007/978-3-031-56027-9_1

Quadrana, M., Cremonesi, P., & Jannach, D. (2018). Sequence-aware recommender systems. *ACM Computing Surveys*, 51(4), Article 66. <https://doi.org/10.1145/3190616>

Rendle, S. (2010). Factorization machines. In *Proceedings of ICDM 2010* (pp. 995–1000). IEEE. <https://doi.org/10.1109/ICDM.2010.127>

Ricci, F., Rokach, L., & Shapira, B. (Eds.). (2015). *Recommender systems handbook* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4899-7637-6>

Ruder, S. (2017). An overview of multi-task learning in deep neural networks. *arXiv preprint*, arXiv:1706.05098. <https://arxiv.org/abs/1706.05098>

Sedhain, S., Menon, A. K., Sanner, S., & Xie, L. (2015). AutoRec: Autoencoders meet collaborative filtering. In *Proceedings of WWW 2015 Companion* (pp. 111–112). <https://doi.org/10.1145/2740908.2742726>

Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., & Jiang, P. (2019). BERT4Rec: Sequential recommendation with bidirectional encoder representations from Transformer. In *Proceedings of the 28th ACM International Conference on Information and Knowledge Management (CIKM '19)* (pp. 1441–1450). ACM. <https://doi.org/10.1145/3357384.3357895>

Tang, J., & Wang, K. (2018). Personalized top-N sequential recommendation via convolutional sequence embedding. In *Proceedings of WSDM 2018* (pp. 565–573). ACM. <https://doi.org/10.1145/3159652.3159656>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... Polosukhin, I. (2017). Attention is all you need. In *Proceedings of NeurIPS 2017* (pp. 5998–6008).

Wu, S., Sun, F., Zhang, W., Xie, X., & Cui, B. (2023). Graph neural networks in recommender systems: A survey. *ACM Computing Surveys*, 55(5), Article 97. <https://doi.org/10.1145/3535101>

Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), Article 5. <https://doi.org/10.1145/3285029>

Zhang, Y., Feng, F., He, X., Wei, T., Song, C., Ling, G., & Zhang, Y. (2024). Causal inference in recommender systems: A survey and future directions. *ACM Transactions on Information Systems*, 42(4), Article 89. <https://doi.org/10.1145/3639473>

BÖLÜM 10

SNACKCHECK: ÜRÜN İÇERİĞİ FİLTRELEME VE YORUMLAMA UYGULAMASI

Ahsen GÜNEŞ¹
Ahmet Hakan GÜNEŞ²
Kamil ORMAN³

Giriş

Kronik hastalıkların (diyabet, hipertansiyon, çölyak hastalığı, laktoz intoleransı vb.) modern toplumlarda giderek artış göstermesi, bireylerin günlük yaşamlarında tükettikleri gıda ürünlerini sağlık durumlarına göre seçmeleri gerekliliğini doğurmuştur. Özellikle atıştırmalık ürünlerin içerik bilgilerinin karmaşık yapısı, etiketlerin okunmasının zorluğu ve ürün çeşitliliğinin fazlalığı, kullanıcının doğru ve bilinçli tercih yapmasını güçleştirmektedir. Bu durum, kişiselleştirilmiş beslenme önerileri sunan dijital sağlık uygulamalarına olan ihtiyacı artırmaktadır.

¹ Lisans Öğrencisi, Erzincan Binali Yıldırım Üniversitesi, Bilgisayar Mühendisliği Bölümü, Orcid: 0009-0006-4440-5757

² Lisans Öğrencisi, Erzincan Binali Yıldırım Üniversitesi, Bilgisayar Mühendisliği Bölümü, Orcid: 0009-0004-1072-6910

³ Doç. Dr., Erzincan Binali Yıldırım Üniversitesi, Bilgisayar Mühendisliği Bölümü, Orcid: 0000-0002-7236-9988

Literatürde sađlık odaklı beslenme uygulamalarının sayısı artmakla birlikte, mevcut sistemlerin önemli bir kısmı kullanıcıların sađlık profilleriyle uyumlu ürün filtreleme, ürün içerik analizi ve görsel ürün tanıma gibi ileri teknolojileri yeterince entegre edememektedir. Wang Y., vd. ve Klasnja ve Pratt' in sundukları çalışmalar kişiselleştirilmiş sađlık uygulamalarının kullanıcının yaşam kalitesini artırmada önemli rol oynadığını vurgulasa da, bu çalışmalar görsel tanıma teknolojileri ve yapay zekâ destekli içerik analiziyle sınırlı entegrasyona sahiptir (Wang Y. vd., 2020, Klasnja ve Pratt, 2012).

Bu çalışma, söz konusu eksiklikleri gidermeye yönelik olarak kullanıcıların sađlık profilleri doğrultusunda ürün içeriklerini analiz eden, ürünleri filtreleyen ve görsel tanıma aracılığıyla hızlı ürün sorgulama imkânı sađlayan bir mobil uygulama geliştirmeyi amaçlamaktadır. Projede Google Cloud AutoML ve TensorFlow Lite kullanılarak ürün tanıma modeli oluşturulmuş, ürün içerikleri yapay zekâ ile yorumlanmış, tüketilebilirlik skorları belirlenmiş ve SQLite tabanlı bir veritabanına entegre edilmiştir. Mobil uygulama Android Studio ortamında Java dili ile geliştirilmiştir.

Bu yönleriyle çalışma, sađlık verileri ile ürün içerik bilgilerinin yapay zekâ destekli yorumlanmasını sađlayan yenilikçi bir yaklaşım sunmakta, kullanıcıların sađlık durumlarına uygun gıda tercihleri yapmasını kolaylaştırarak mobil sađlık teknolojileri alanında önemli bir katkı sağlamaktadır.

Amaç

Bu çalışmanın temel amacı, kullanıcıların sağlık profillerine uygun olarak gıda ürünlerinin özellikle atıştırma ürünlerinin içeriklerini analiz eden, bu analizlere dayanarak ürünleri tüketilebilir veya tüketilemez şeklinde sınıflandıran, aynı zamanda görsel tanıma yoluyla ürün içeriklerine hızlı erişim sağlayan bir mobil uygulama geliştirmektir.

Aşağıdaki alt amaçlar doğrultusunda çalışmanın kapsamı şekillendirilmiştir:

- Kullanıcıların sağlık profillerini dikkate alarak ürünlerin zararlı içeriklerini belirleyen ve tüketilebilirlik skorlarını hesaplayan bir yapay zekâ modeli oluşturmak.
- Ürünlerin manuel arama, kategori filtreleme veya görsel tanıma aracılığıyla hızlı şekilde bulunabilmesini sağlamak.
- Kullanıcıya, satın almak istediği ürünün içerik bilgisi, zararlı bileşenleri ve kişiye özel tüketim önerilerini anlaşılır bir arayüzle sunmak.
- Alışveriş sırasında ürün etiketlerini inceleme gereksinimini ortadan kaldırarak daha hızlı ve bilinçli karar verme süreci oluşturmak.
- Kişiselleştirilmiş beslenme önerilerini mobil ortama taşıyarak kronik hastalık yönetimini desteklemek.

Materyal ve Yöntem

a. Veri Toplama Süreci

Veri toplama faaliyetleri 2025 yılının Ocak–Şubat aylarında gerçekleştirilmiştir. Veri kaynakları üç temel başlıkta toplanmıştır:

- Ürün içerik verileri

Migros'un çevrim içi satış platformundan alınan ürün içerikleri ve besin değerleri, yapay zekâ yardımıyla sağlığa zararlı içeriklerin ve hastalığa göre tüketilebilirlik skorlarının hesaplanması için işlenmiştir.

- Kullanıcı profilleri

Kullanıcıların kronik hastalık bilgileri ve beslenme tercihleri uygulamaya kayıt esnasında alınmıştır.

- Görsel veri seti

Ürün görselleri manuel olarak çekilmiş, Google AutoML üzerinde eğitilen görüntü işleme modelinin oluşturulmasında kullanılmıştır.

b. Kullanılan Teknolojiler ve Platformlar

SQLite: Ürün ve kullanıcı verilerinin depolanması.

Android Studio & Java: Mobil uygulamanın geliştirilmesi.

Google Cloud AutoML: Görsel ürün tanıma modelinin eğitimi.

TensorFlow Lite: Eğitilen modelin uygulamaya entegre edilmesi.

DB Browser: Veritabanı tasarımı ve veri düzenleme işlemleri.

c. Veri Setinin Hazırlanması

Migros platformundan çekilen ürün içerikleri yapay zekâ aracılığıyla analiz edilerek her ürün için:

- Zararlı içerik listesi,
- Hastalıklara göre tüketilebilirlik skorları,

- Ürün içerik özetleri,

oluşturulmuştur. Bu bilgiler Şekil 1’de gösterildiği gibi yapılandırılmış bir veri setine dönüştürülmüş ve SQLite veritabanına aktarılmıştır.

	id	isim	kategori	içindekiler	gsz	shz	chz	thz	lz	y	sy	cy	ty	liy	urunresim
	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre	Filtre
1	al...	Et...	ciko...	Su, ...	Şek...	Yü...		Dü...	Ya...	1	3	0	0	3	ur_urun1.jpg
2	go...	Go...	ciko...	Şeker,...	Şek...	Yü...			ta...	1	3	0	0	3	ur_urun2.jpg
3	al...	Et...	ciko...	Su, ...	Şek...	Yü...	Bu...		Sü...	1	3	3	0	3	ur_urun3.jpg
4	ul...	Ül...	ciko...	Şeker,...	Şek...	Or...	Bu...		ta...	1	2	3	0	3	ur_urun4.jpg
5	sn...	Sn...	ciko...	şeker,...	şek...	Yü...		Or...	ya...	1	3	0	2	3	ur_urun5.jpg
6	ne...	Ne...	ciko...	Tam ...	Şek...	Yü...	Ta...	Or...	ta...	1	3	3	2	3	ur_urun6.jpg
7	bo...	Bo...	ciko...	şeker,...	Şek...	Yü...	bu...	Dü...	ta...	1	3	3	0	3	ur_urun7.jpg
8	zu...	Zü...	ciko...	Hurma,	Hur...	Yü...				1	3	0	0	0	ur_urun8.jpg
9	zu...	Zü...	ciko...	Hurma,...	Hur...	Yü...				1	3	0	0	0	ur_urun9.jpg
10	zu...	Zü...	ciko...	Hurma,...	Hur...	Yü...				1	3	0	0	0	ur_urun10.jpg
11	ci...	Ci...	cips...	Patate...	Bit...	Dü...		Yü...		1	0	0	3	0	ur_urun11.jpg
12	la...	La...	cips...	Patate...	Tuz	Dü...		Yü...		1	0	0	3	0	ur_urun12.jpg
13	do...	Do...	cips...	Mısır,...		Dü...		Dü...		1	0	0	0	0	ur_urun13.jpg
14	ch...	Ch...	cips...	Patate...	Bit...	Dü...		Yü...		1	0	0	3	0	ur_urun14.jpg

Şekil 1 Kullanılan SQL veritabanı

d. Yapay Zekâ Süreci

Uygulamanın karar mekanizmasını oluşturan yapay zekâ modeli:

- Ürün içeriklerini,
- Kullanıcıların hastalık profillerini,
- Zararlı içerik ve tüketilebilirlik skorlarını,

birlikte değerlendirerek kişiye özel tüketim yorumları üretmektedir.

Bu model, bulanık mantık yaklaşımına benzer bir yapı ile çalışmakta ve kullanıcıya ürünün:

- Tüketilebilir,

- Kontrollü tüketilebilir,
- Tüketilmemelidir,

şeklinde kategorize edilen çıktılarını sunmaktadır.


e. Görsel Tanıma Süreci

Google AutoML üzerinde eğitilen model TensorFlow Lite formatına dönüştürülerek uygulamaya entegre edilmiştir. Kullanıcı kamerayla bir ürünün fotoğrafını çektiğinde sistem ilgili ürünü tanır ve eşleşen ürünle ilgili içerik bilgilerini sunar. Benzerlik eşiği %90'ın altında olan durumlarda kullanıcı bilgilendirilir.

f. Uygulama Arayüzü Tasarımı

Uygulama aşağıdaki temel arayüzlerden oluşmaktadır:


- Ana ekran



Şekil 2 Snackchek uygulaması açılış(a) ve karşılama(b) ekranları


Uygulama açıldığında 5 saniye splash ekranı görüntülenmekte (Şekil 2-a) ve karşılama ekranına yönlendirilmektedir (Şekil 2-b).

- Giriş ve kayıt ekranları




Şekil 3 Snackchek uygulaması giriş(a) ve kayıt(b) ekranları

- Ürün arama, filtreleme ve sıralama ekranları



Şekil 4 Snackchek uygulaması ürün arama(a) ve filtreleme(b) ekranları

- Ürün içerik ekranı




(a)

(b)

(c)

Şekil 5 Snackchek uygulaması ürünlerin içeriklerinin kullanıcıya gösterildiği ekran (a), zararlı içerik gösterim ekranı(b), ürün tüketim yorumu ekranı

- Profil görüntüleme ve güncelleme ekranları



(a)

(b)

Şekil 7 Kullanıcının profilini görüntüleyebildiği (a) ve güncelleyebildiği (b) arayüz ekranı

Her arayüz sade, kullanıcı dostu ve tüm yaş gruplarına uygun tasarlanmıştır.

Literatürdeki benzer uygulamalar ve kıyaslanma

a. NutrifyAI (Han ve arkadaşları, 2024)

Bu sistem, yapay zekâ destekli yemek tanıma ve besin analizini bir araya getirerek kullanıcılara kişiselleştirilmiş öğün önerileri sunmaktadır. YOLOv8 modeli ile gıdalar yüksek doğrulukla tanınmakta, Edamam API üzerinden alınan besin bilgileri ile kullanıcıya özel öğün planlaması yapılmaktadır. Gerçek zamanlı çalışması sayesinde bireylerin daha sağlıklı ve bilinçli beslenme kararları almasına yardımcı olmaktadır.

b. Smart Dietary Assistant (Nossair ve El Housni, 2024)

Bu uygulama, özellikle diyabet hastaları için kişiselleştirilmiş beslenme önerileri sunmayı hedeflemektedir. Grounding DINO modeli kullanılarak etiketlenmemiş veriler üzerinde yüksek doğrulukta gıda tanıma gerçekleştirilir. Uygulama, kullanıcı profiline göre beslenme önerileri sunarak sağlıklı yaşam tarzı seçimlerini desteklemektedir.

c. Spokin Uygulaması

Spokin, gıda alerjisi olan bireyler için geliştirilmiş bir mobil uygulamadır. Kullanıcılar, alerji türlerini profillerinde tanımlayarak kendilerine uygun ürünleri filtreleyebilir ve diğer kullanıcıların deneyimlerine dayalı değerlendirmelerden yararlanabilirler. Uygulama, 78 farklı alerjeni takip edebilme özelliği ile kullanıcıların güvenli gıda seçeneklerine ulaşmasını sağlar.

d. FoodAI (Singapore Agency for Science, Technology and Research, 2020)

FoodAI, kullanıcıların akıllı telefonları aracılığıyla çektikleri gıda fotoğraflarını analiz eden bir sistemdir. Derin öğrenme teknikleri ile gıda öğeleri tespit edilmekte ve besin değerleri hesaplanmaktadır. Ayrıca, kullanıcının sağlık durumuna göre özelleştirilmiş diyet planları sunabilmekte, bu sayede sağlık hedeflerine uygun beslenme desteklenmektedir.

e. CalorieMama AI (Azumio Inc.)

CalorieMama AI, gıda tanıma ve kalori hesaplama konusunda güçlü bir yapay zekâ uygulamasıdır. Mobil cihazlar üzerinden fotoğrafla gıda tanıma gerçekleştirilirken, geniş veri tabanı sayesinde besin içeriklerine erişim sağlanmaktadır. Kullanıcıların diyet hedeflerine uygun kişiselleştirilmiş öneriler sunmakta ve beslenme alışkanlıklarının iyileştirilmesine destek olmaktadır.

Geliştirilen SnackCheck uygulaması ile kullanıcıların Şeker hastalığı, Çölyak hastalığı, Hipertansiyon ve Laktoz intoleransı rahatsızlıkları dikkate alınarak uyarılarda bulunacak bir mobil sağlık uygulaması geliştirilmiş ve yukarıdaki benzer uygulamalar ile kıyaslanma tablosu aşağıda verilmiştir.

Tablo 1 SnackCheck uygulamasının diğer benzer uygulamalar ile kıyaslanması

Uygulama	Görüntü Tanıma	Kişisel Profil	Hastalık Odaklı	AI Karar Sistemi	Açıklama
NutrifyAI	✓	✓	Sınırlı (beslenme tipi)	✗	Reçete öneriyor
Smart Dietary Asst.	✓	✓	✓ (diyabet)	✗	Diyabete odaklı
Spokin	✗	✓	✓ (alerji)	✗	Topluluk temelli
FoodAI	✓	✗	✗	✗	Görüntü tanıma güçlü
CalorieMama	✓	✗	✗	✗	Sadece kalori
Uygulama (SnackCheck)	✓ (AutoML-TFLite)	✓	✓ (çoklu hastalık)	✓ (bulanık mantık)	Kapsamlı filtreleme, yorum

Sonuç

Bu çalışma kapsamında geliştirilen mobil uygulama, kullanıcıların sağlık profilleri ile ürün içerik bilgilerini bütünleştirerek kişiye özel beslenme yönlendirmesi sunan yenilikçi bir sistem ortaya koymuştur. Uygulama, manuel arama veya görsel tanıma yoluyla ürünleri tespit edebilmekte, hastalıklara göre zararlı içerikleri belirleyebilmekte ve kullanıcıya kişiselleştirilmiş tüketim önerileri sunmaktadır.

Literatürdeki benzer uygulamalarla karşılaştırıldığında bu çalışmanın:

- Çoklu hastalık profili desteği,
- Yapay zekâ ile analiz edilen özgün veri seti,
- Görsel ürün tanıma entegrasyonu,
- Tüketilebilirlik skorlarına dayalı yorum üretme kabiliyeti,

açısından daha kapsamlı bir çözüm sunduğu görülmektedir.

Geliştirilen sistem, kullanıcıların alışveriş sırasında daha bilinçli tercihler yapmasına yardımcı olmakta ve özellikle kronik hastalığı bulunan bireylerin yaşam kalitesine katkı sağlamaktadır. Ayrıca, ürün içeriklerinin yapay zekâ ile analiz edilmesi sağlık teknolojilerinde büyük bir yenilik alanı oluşturmakta ve ileride yapılacak çalışmalara ışık tutmaktadır.

Kaynakça

C. H. (2019). FoodAI: Food image recognition via deep learning for smart food logging. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*, 2260–2268. <https://doi.org/10.1145/3292500.3330734>

Calorie Mama Food AI: Food image recognition and calorie counter using deep learning. Azumio, Inc. Erişim adresi: <https://www.caloriemama.ai/>

Han, M., & Chen, J. (2024). NutrifyAI: An AI-Powered System for Real-Time Food Detection, Nutritional Analysis, and Personalized Meal Recommendations. *arXiv*. <https://doi.org/10.48550/arXiv.2408.10532>

<https://migros.com.tr>

Klasnja, P., & Pratt, W. (2012). Healthcare in the pocket: Mapping the space of mobile-phone use in health and medicine. *Journal of Biomedical Informatics*, 45(1), 184–192. <https://doi.org/10.1016/j.jbi.2011.08.017>

Nossair, A., & El Housni, H. (2024). Eating Smart: Advancing Health Informatics with the Grounding DINO-based Dietary Assistant App. *International Journal of Scientific Research and Innovative Studies*, 3(3), 26–34.

Spokin: Manage food allergies. (Sürüm 5.14.0) Erişim adresi: <https://www.spokin.com/>

Wang, Y., Min, J., Khuri, J., Xue, H., Xie, B., Kaminsky, L., & Wang, Y. (2020). Effectiveness of mobile health interventions on diabetes and obesity treatment and management: Systematic review of systematic reviews. *JMIR mHealth and uHealth*, 8(4), e15400. <https://doi.org/10.2196/15400>

BÖLÜM 11

6G AĞLARINDA GÖMÜLÜ ZEKA VE DAĞITIK YAPAY ZEKA MİMARİLERİ: LİTERATÜR TARAMASI

SEMİH KAHVECİ¹
RAMAZAN AKKURT²

Giriş

Kablosuz iletişim teknolojileri, her on yılda bir gerçekleşen nesil geçişleriyle birlikte toplumsal ve endüstriyel yaşamı kökten değiştiren yenilikler sunmuştur (Gupta & Jha, 2015). 5G ağları, yüksek bant genişliği ve düşük gecikme süreleri ile Nesnelerin İnterneti (IoT) ekosistemini genişletmiş olsa da geleceğin hiper-bağlantılı dünyasının gereksinim duyduğu tam otonom, ultra-güvenilirlik ve gerçek zamanlı bağlamsal farkındalık taleplerini karşılamakta yetersiz kalmaktadır. Bu noktada 2030'lu yıllarda ticarileşmesi beklenen 6G teknolojisinin iletişimi sadece veri transferi odaklı bir süreç olmaktan çıkarıp bilgi ve zekanın dağıtımını üzerine kurulu yeni bir paradigmaya taşımayı hedeflemektedir

¹ Arş. Gör. Dr., Mersin Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği, Orcid: 0000-0002-1495-6295

² Arş. Gör., Mersin Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği, Orcid: 0000-0003-2319-9887

(Latva-aho & Leppänen, 2019; Saad vd., 2019). Bu yeni dönemin en belirgin özelliği Yapay Zeka ve Makine Öğrenmesi algoritmalarının ağın merkezinden (Core) en uç noktalarına (Edge) kadar her katmana derinlemesine entegre edilmesidir. Yerel Yapay Zeka olarak adlandırılan bu yaklaşım ağın değişen çevresel koşullara, trafik yoğunluğuna ve kullanıcı taleplerine milisaniyeler içerisinde insan müdahalesi olmaksızın adapte olabilmelerini sağlamaktadır. Geleneksel merkezi bulut tabanlı zeka modellerinin yarattığı gecikme ve güvenlik risklerine bir çözüm olarak ise Dağıtık Yapay Zeka mimarileri öne çıkmaktadır.

Bu çalışmada, 6G ağlarında gömülü zeka ve dağıtık yapay zeka mimarilerini ele alan güncel literatür sistematik bir şekilde incelenmiştir. Çalışma kapsamında kendi kendini iyileştiren (self-healing) ağ mimarileri, enerji verimliliği için sürdürülebilir yapay zeka çözümleri, siber güvenlik tehditlerine karşı geliştirilen proaktif savunma mekanizmaları ve üretken yapay zekanın iletişimdeki rolü gibi kritik temalar alanın önde gelen araştırmacılarının bulguları ışığında sentezlenmiştir. Bu çalışmanın genel perspektifi 6G'nin teorik vizyonu ile pratik uygulama zorlukları arasındaki ilişkiyi ortaya koyarak gelecekteki araştırmalar için bir yol haritası sunmaktır.

Literatür Çerçevesi

Çalışma kapsamında ele alınan yayınların genel çerçevesi tablo 1'de sunulmuştur. Khara ve diğer araştırmacılar tarafından ele alınan çalışmada 6G ağ mimarisinin "Yerel Yapay Zeka" (Native AI) entegrasyonu sayesinde nasıl otonom, kendi kendini organize eden ve iyileştiren (self-healing) bir yapıya dönüşeceği incelenmiştir (Khara vd., 2024). Çalışma karasal, uydu ve su altı ağlarını kapsayan bütünleşik bir 6G mimarisi önererek dağıtık yapay zeka ve mobil uç bilişimin (MEC) ağın her katmanına entegrasyonunu ve bunun gerekliliklerini detaylandırmaktadır. Özellikle kanal tahmini ve

konumlandırma gibi işlemler için Konvolüsyonel Sinir Ağları (CNN) gibi denetimli öğrenme yöntemleri önerilirken kaynak yönetimi için pekiştirmeli öğrenme tekniklerinin kullanıldığı spesifik bir eşleştirme tablosu sunulmuştur. Ayrıca Neredeyse Sıfır Güçlü (AZP) IoT cihazlarının donanım kısıtlamaları, güvenlik tehditleri ve gerçek zamanlı veri işleme zorluklarına dikkat çekilerek ağ dilimleme ve dijital ikiz teknolojilerinin bu süreçteki kritik rolleri vurgulanmıştır. Janbi ve diğer araştırmacılar, 6G ve Internet of Everything (IoE) ortamları için "Hizmet Olarak Dağıtık Yapay Zeka" (DAIaaS) çerçevesini önererek yapay zeka eğitim ve çıkarım süreçlerinin cloud, fog ve edge katmanları arasında nasıl dağıtılması gerektiğini incelemişlerdir (Janbi vd., 2020). Çalışmada smart airport ve smart district gibi gerçek hayat senaryoları üzerinden geliştirilen modellerle merkezi cloud tabanlı sistemlere kıyasla edge ve fog computing entegrasyonunun etkileri analiz edilmiştir. iFogSim simülasyon aracı kullanılarak yapılan testlerde önerilen dağıtık mimarinin uçtan uca gecikmeyi, ağ kullanımını ve enerji tüketimini önemli ölçüde azalttığı ve özellikle yoğun edge cihaz senaryolarında gecikmenin saniyeler mertebesinde milisaniyeler seviyesine düştüğü gözlemlenmiştir. Bu bulgular 6G'nin sunduğu ultra düşük gecikme ve yüksek bant genişliği olanaklarının yapay zeka hizmetlerinin ağı kenarlarına taşınmasıyla birleştiğinde akıllı şehir uygulamaları için sürdürülebilir ve yüksek performanslı çözümler sunduğunu ortaya koymaktadır. Letaief ve diğer araştırmacılar, 6G ağlarının "connected things" kavramından "connected intelligence" vizyonuna evrilmesinde Edge AI teknolojisinin dönüştürücü rolünü ve bu süreçteki temel uygulama zorluklarını kapsamlı bir şekilde incelemişlerdir (Letaief vd., 2022). Çalışmada merkezi cloud tabanlı yapay zeka sistemlerinin neden olduğu yüksek gecikme, bant genişliği darboğazları ve gizlilik sorunlarına çözüm olarak model training ve inference işlemlerinin ağı kenarlarına taşınması önerilmektedir. Özellikle Federated Learning ve split learning gibi merkeziyetsiz öğrenme tekniklerinin

veriyi kaynağında işleyerek gizliliği koruduğu ve iletişim yükünü azalttığı vurgulanmıştır. Yazarlar sensing, communication, computation ve intelligence bileşenlerini bütünleşik bir mimaride birleştiren bütüncül bir sistem tasarımı sunarken Over-the-Air Computation ve semantic communication gibi yenilikçi fiziksel katman teknolojilerinin önemine dikkat çekmişlerdir. Bu yaklaşım otonom sürüş ve endüstriyel IoT gibi ultra düşük gecikme gerektiren uygulamalar için ölçeklenebilir ve güvenilir bir altyapı sağlamayı hedeflemektedir. Yang ve diğer araştırmacılar tarafından yürütülen çalışmada, 6G ağlarının "knowledge discovery", "smart resource management" ve "automatic network adjustment" yeteneklerine kavuşması amacıyla dört katmanlı bir "AI-Enabled Intelligent Architecture" önerilmiştir (Yang vd., 2020). Önerilen bu mimari fiziksel ortamdan veriyi algılayan Intelligent Sensing Layer, büyük veriyi işleyen Data Mining and Analytics Layer, ağın kendi kendini optimize etmesini sağlayan Intelligent Control Layer ve kullanıcılara özelleştirilmiş hizmetler sunan Smart Application Layer yapılarından oluşmaktadır. Çalışmada özellikle Fog-RAN kaynak yönetimi problemi bir Markov Decision Process (MDP) olarak modellenmiş ve bu problemin çözümü için Q-learning ile SARSA gibi Reinforcement Learning algoritmaları entegre edilmiştir. Heterojen IoT senaryolarında gerçekleştirilen simülasyon sonuçları önerilen yapay zeka tabanlı yaklaşımın ağın hizmet kalitesini (QoS) artırdığını ve IoV (Internet of Vehicles) gibi dinamik ortamlarda sinyal girişimini minimize ederek daha güvenilir bir iletişim altyapısı sağladığını göstermektedir. Alhammedi ve diğer araştırmacılar tarafından yapılan bu çalışmada, 6G kablosuz ağlarında yapay zekanın (AI) rolü, sunduğu fırsatlar ve karşılaşılan temel zorluklar kapsamlı bir şekilde incelenmiştir (Alhammedi vd., 2024). Çalışma Terahertz Communication, Reconfigurable Intelligent Surfaces (RIS) ve hyper-connected edge computing gibi gelişmekte olan teknolojilerin AI ile entegrasyonunu detaylandırarak bu birleşimin ağ performansını nasıl optimize ettiğini analiz

etmektedir. Özellikle big data analytics, mobility management ve intelligent resource management gibi uygulama alanlarında AI algoritmalarının veri trafiğini yönetme ve kullanıcı deneyimini iyileştirme potansiyeli vurgulanmıştır. Yazarlar massive data handling, enerji verimliliği ve AI algoritma karmaşıklığı gibi teknik engellerin yanı sıra güvenlik ve gizlilik sorunlarına da dikkat çekerek bu zorlukların aşılması için çözüm önerileri sunmuşlardır. Son olarak intelligent spectrum management, autonomous networks ve AI-enabled satellite networks gibi gelecek trendleri tartışılarak kendi kendini iyileştiren (self-healing) ve organize eden 6G sistemlerinin vizyonu ortaya konmuştur.

Tablo 1: 6G literatür çerçevesi

Yazarlar	Yıl	Çalışma Kapsamı	Odak Kavram
Khara vd.	2024	Native AI (Yerel Yapay Zeka) ile otonom ve kendi kendini iyileştiren 6G mimarisi (Abdulraheem, ve diğerleri, 2024)	Embedded Intelligence
Janbi vd.	2020	Cloud, Fog ve Edge katmanları arasında "Hizmet Olarak Dağıtık Yapay Zeka" (DAIaaS)	Distributed AI
Letaief vd.	2022	Merkeziyetsiz öğrenme ve Edge AI ile "Connected Intelligence" vizyonu	Distributed AI
Yang vd.	2020	4 katmanlı akıllı ağ mimarisi ve kaynak yönetimi için pekiştirmeli öğrenme	Embedded Intelligence
Alhammadi vd.	2024	6G'de yapay zeka entegrasyonu, fırsatlar, zorluklar ve spektrum yönetimi	Embedded Intelligence
Sanjalawe vd.	2025	6G ve AI yakınsaması: İletişim optimizasyonu ve güvenlik (Genel Derleme)	Embedded Intelligence
Duan vd.	2022	Bilişsel zeka tabanlı, kendi kendine evrimleşen dağıtık ağ mimarisi	Distributed AI
Ioannou vd.	2022	D2D (Cihazdan Cihaza) iletişimi yöneten dağıtık yapay zeka ajanları	Distributed AI
Sanjalawe vd.	2025	Akıllı şebekeler (Smart Grids) için güvenli ve akıllı enerji sistemleri	Embedded Intelligence

Karachalios vd.	2023	Uçtan uca kaynak yönetimi için dağıtık makine öğrenimi ve Native AI bileşenleri	Distributed AI
Mohsin vd.	2025	Ambient Intelligence (Ortam Zekası) ve Generative AI (Üretken Yapay Zeka)	Embedded Intelligence
Ogenyi vd.	2025	Semantic Communication ve AI-Native mimarilerin entegrasyonu	Embedded Intelligence
Psaromanolakis vd.	2023	MLOps destekli, gömülü zekaya sahip Edge yönetim platformu (π -Edge)	Embedded Intelligence
Vandikas vd.	2025	Gizlilik odaklı dağıtık zeka (Distributed Intelligence) ve model yaşam döngüsü	Distributed AI
Liu vd.	2025	Entegre Algılama ve Edge AI (ISEA) ile görev odaklı algılama	Embedded Intelligence
Talwar vd.	2021	Dağıtık zeka çağında bağlanabilirlik ve kodlanmış dağıtık hesaplama	Distributed AI
Dede vd.	2025	Core Network (Çekirdek Ağ) için AI-Native otomasyon ve güvenlik	Embedded Intelligence
You vd.	2025	Sürdürülebilir (Green) 6G ve her yerde bulunan zeka (Ubiquitous Intelligence)	Embedded Intelligence
Calvanese Strinati vd.	2025	6GARROW projesi: AI-Native cihaz ve ağ bütünleşmesi	Embedded Intelligence
Paolini vd.	2023	Tehdit tespiti için derin gömüler (Deep Embeddings) ve gerçek zamanlı kümeleme	Embedded Intelligence
Butt & Shah	2025	Yapay zeka ve 6G yakınsaması ile endüstriyel dönüşüm	Embedded Intelligence

Sanjalawe ve diğer araştırmacılar tarafından ele alınan çalışmada, 6G ağlarına Artificial Intelligence (AI) entegrasyonunun iletişim optimizasyonu, dinamik kaynak tahsisi ve güvenlik gibi kritik alanlardaki rolü ve gereklilikleri kapsamlı bir şekilde incelenmiştir (Sanjalawe vd., 2025). Çalışma Machine Learning, Deep Learning ve Reinforcement Learning gibi teknolojilerin predictive maintenance, trafik yönetimi ve energy efficiency gibi uygulamalarda nasıl kullanıldığını detaylandırmaktadır. Özellikle intelligent network slicing, spectrum management ve dinamik algoritmalarla desteklenen resource allocation süreçlerinde AI'nın

sağladığı verimlilik vurgulanmıştır. Güvenlik tarafında ise intrusion detection, anomaly detection ve blockchain tabanlı decentralized security mekanizmaları ile 6G ağlarının karşılaşacağı tehditlere yönelik çözümler sunulmuştur. Yazarlar ayrıca computational overhead ve data privacy gibi uygulama zorluklarına dikkat çekerek gelecekteki araştırmalar için Quantum AI ve Federated Learning gibi teknolojilerin potansiyelini tartışmışlardır. Duan ve diğer araştırmacılar tarafından hazırlanan çalışmada, 5G mimarisinin yüksek karmaşıklık, düşük bilişsel yetenek ve zayıf anlık tepki gibi kısıtlamalarını aşmak amacıyla "Physical Network Layer" ve "Intelligent Decision Layer" olmak üzere iki temel katmandan oluşan bilişsel zeka tabanlı dağıtık bir 6G ağ mimarisi önerilmiştir (Duan vd., 2022). Çalışmada, ağın kendi kendine evrimleşmesini (self-evolution) ve öngörülemeyen karmaşık servislere uyum sağlamasını mümkün kılmak için çekirdek ağı ve edge (uç) birimlere entegre edilmiş bir "Cognitive Network Function" (CNF) yapısı sunulmaktadır. Önerilen bu mimari, Knowledge Graph ve hafif sıklet karar verici ajanlar (decision-making agents) kullanarak ağ kaynaklarını ve zeka servislerini dinamik olarak yönetmeyi, böylece ağı pasif bir iletişim borusu olmaktan çıkarıp proaktif, kendi kendini optimize eden otonom bir sisteme dönüştürmeyi hedeflemektedir. Simülasyon sonuçları, bu bilişsel mimarinin değişen hizmet gereksinimlerine ve ağ koşullarına mevcut statik mimarilere kıyasla çok daha hızlı ve verimli bir şekilde adapte olabildiğini göstermektedir. Ioannou ve diğer araştırmacılar, dinamik 5G/6G ortamlarında Device-to-Device (D2D) iletişimini yönetmek için makine öğrenimi ile genişletilmiş bir "Distributed Artificial Intelligence Solution" (DAIS) planı önermişlerdir (Ioannou vd., 2022). Çalışmada, merkezi cloud yapılarından edge noktalarına kaydırılan zeka ile User Equipment (UE) üzerinde çalışan Belief-Desire-Intention (BDI) ajanlarının, iletim modu seçimini otonom olarak nasıl gerçekleştirdiği incelenmiştir. Önerilen bu dağıtık yapı, cihazların hareketliliği, hızı ve yön değişimleri gibi

dinamik faktörleri hesaba katarak Spectral Efficiency (SE) maksimizasyonu ve Power Consumption (PC) minimizasyonu hedefler. Simülasyon sonuçları, geliştirilen çerçevenin Distributed Sum Rate (DSR) ve Single Hop Relay Approach (SHRA) gibi yöntemlere kıyasla daha kararlı kümeler ve verimli backhauling bağlantıları oluşturduğunu, böylece kendi kendini organize eden ağların (self-organizing networks) performansını artırdığını göstermektedir. Sanjalawe ve diğer araştırmacılar, Smart Grid altyapılarının 6G ve Artificial Intelligence (AI) entegrasyonu ile nasıl daha güvenli, otonom ve sürdürülebilir hale geleceğini kapsamlı bir şekilde incelemişlerdir (Sanjalawe vd., 2025:43). Çalışma geleneksel şebekelerin sınırlılıklarını aşmak için ultra-reliable low-latency communication (URLLC), massive Machine-Type Communications (mMTC) ve native AI gibi 6G yeteneklerinin enerji sistemlerine nasıl uyarlanabileceğini kapsamaktadır. Özellikle forecasting, anomaly detection ve grid optimization süreçlerinde AI tabanlı iyileştirmeler ele alınırken bu teknolojilerin getirdiği system heterogeneity ve veri gizliliği gibi zorluklara dikkat çekilmiştir. Yazarlar latency, trust ve interoperability sorunlarını çözmek amacıyla edge intelligence ve explainable cybersecurity çözümlerini birleştiren "SAFES-6G" adında yeni bir kavramsal çerçeve önermişlerdir. Sonuç olarak edge-native intelligence ve privacy-preserving analytics (örneğin Federated Learning) gibi teknolojilerin geleceğin dirençli enerji sistemlerini inşa etmede kritik fırsatlar sunduğu vurgulanmıştır. Karachalios ve diğer araştırmacılar, 6G ağlarında uçtan uca kaynak yönetimi için dağıtık makine öğrenimi ve yerel yapay zeka (Native AI) olanaklarını kapsamlı bir şekilde incelemişlerdir (Karachalios vd., 2023). Çalışma merkezi cloud tabanlı çözümlerin yetersiz kaldığı karmaşık ve dinamik 6G senaryolarında ölçeklenebilir ve esnek bir yapı sunan dağıtık Reinforcement Learning (RL) çerçevelerine odaklanmaktadır. Yazarlar mevcut literatürü altı farklı metodolojik çerçeve altında sınıflandırarak bu yaklaşımların iletişim yükü, ölçeklenebilirlik ve

modülerlik açısından performanslarını değerlendirmişlerdir. Ayrıca AI plane, knowledge reuse ve Digital Twin Networks (DTN) gibi 6G'ye özgü yerel yapay zeka bileşenlerinin bu dağıtık algoritmaları nasıl desteklediği ve ağı kendi kendini yöneten otonom bir yapıya kavuşmasındaki rolleri detaylandırılmıştır. Sonuç olarak önerilen bütünleşik yaklaşımın geleceğin karmaşık ağ gereksinimlerini karşılamada geleneksel yöntemlere kıyasla daha etkin bir çözüm sunduğu vurgulanmıştır. Mohsin ve diğer araştırmacılar, 6G ağlarının "Ambient Intelligence" (AmI) vizyonunu gerçekleştirebilmesi için Generative AI (GenAI) teknolojilerinin sadece destekleyici bir araç değil aynı zamanda temel bir yapı taşı olduğunu savunarak bu entegrasyonun algılama ve akıl yürütme süreçlerini nasıl dönüştürdüğünü incelemişlerdir (Mohsin vd., 2025). Çalışma GANs, VAEs ve diffusion models gibi temel üretken mimarilerin eksik sensör verilerinin sentezlenmesi, kullanıcı niyetinin semantik mesajlara dönüştürülmesi ve proaktif ağ kontrolü için gelecek durumların tahmin edilmesi gibi kritik AmI(Ambient intelligence) görevlerindeki rollerini detaylandırmaktadır. Özellikle edge ve fog computing, IoT swarms ve Intelligent Reflecting Surfaces (IRS) gibi 6G enabler'larının bu dağıtık üretken modelleri nasıl barındırabileceği ve hızlandırabileceği üzerinde durulmuştur. Yazarlar enerji verimli on-device training, sentetik verilerin güvenilirliği ve federated generative learning gibi açık araştırma zorluklarına dikkat çekerek GenAI tabanlı proaktif ekosistemlerin 6G'yi basit bir iletişim ağından öte insan davranışlarıyla uyumlu akıllı bir ortama dönüştüreceğini vurgulamışlardır. Ogenyi ve diğer araştırmacılar, 6G ağlarının geleneksel veri odaklı iletişimden anlam ve bağlamın merkeze alındığı "intelligence-native" mimarilere dönüşümünü ve bu süreçte Semantic Communication, Reconfigurable Intelligent Surfaces (RIS) ve Edge Intelligence teknolojilerinin entegrasyonunu incelemişlerdir (Ogenyi vd., 2025:15). Çalışmada semantic encoding ile gereksiz veri iletiminin azaltılması, RIS ile kablosuz yayılım ortamının dinamik olarak

kontrol edilmesi ve edge intelligence sayesinde yapay zeka çıkarımlarının son kullanıcıya yakınlaştırılması gibi mekanizmaların ultra düşük gecikmeli ve bağlam duyarlı (context-aware) sistemleri nasıl mümkün kıldığı detaylandırılmıştır. Geleneksel Quality of Service (QoS) metriklerinin ötesine geçerek "semantic fidelity" gibi yeni performans ölçütlerinin önemini vurgulayan yazarlar bu bütünleşik yapının "adversarial attacks" ve "model poisoning" gibi yeni güvenlik tehditlerine karşı nasıl korunması gerektiğini de tartışmışlardır. Sonuç olarak kuantum uyumlu semantik kanallar ve biyolojik tabanlı bilişsel ağlar gibi gelecek vizyonları ile 6G'nin sadece bir iletişim altyapısı değil otonom kararlar alabilen akıllı bir ekosistem olacağı öngörülmüştür. Psaromanolakis ve diğer araştırmacılar, insan odaklı 6G ağlarının gerektirdiği ileri düzey otomasyon ihtiyacını karşılamak amacıyla MLOps işlevleriyle donatılmış ve "yerel zeka" (native intelligence) barındıran " π -Edge" adlı bir Edge Management Platform önermişlerdir (Psaromanolakis vd., 2023:6). Çalışma mevcut ağ otomasyon çözümlerinde AI/ML süreçleri ile Network Service Management katmanının birbirinden kopuk olmasının yarattığı verimsizlikleri ele alarak MLOps servislerini platformun ayrılmaz birer mikro servisi olarak entegre eden cloud-native bir mimari sunmaktadır. Önerilen bu yapı PaaS ve FaaS hizmetlerinin yaşam döngüsü yönetimini (LCM) otomatikleştirirken performans tahmini ve anomali tespiti için N-BEATS gibi gelişmiş Deep Learning modellerini kullanmaktadır. Gerçek bir multimedya streaming senaryosu üzerinde yapılan testler platformun kaynak kullanımını proaktif bir şekilde yönetebildiğini ve Zero-touch MLOps yaklaşımıyla ağın Quality of Service (QoS) seviyesini kesintisiz sürdürebildiğini doğrulamıştır.

Vandikas ve diğer araştırmacılar, veri gizliliği ve yasal kısıtlamalar nedeniyle mobil ağlarda önemi artan "Distributed Intelligence" (DI) yaklaşımlarının 6G ağlarına entegrasyonunu ve bu alandaki standardizasyon çalışmalarını kapsamlı bir şekilde

değerlendirmişlerdir (Vandikas vd., 2025). Çalışmada Machine Learning Model Lifecycle Management (ML LCM) süreçlerinin Core Network katmanından Radio Access Network (RAN) uçlarına kadar genişletildiği bir senaryo kurgulanmış ve bu yapının performansı, hesaplama yükü, bellek kullanımı ve iletişim ayak izi gibi metrikleri içeren yeni bir Key Performance Indicators (KPIs) seti ile analiz edilmiştir. Özellikle "secondary carrier prediction" kullanım durumu üzerinde gerçekleştirilen testlerde centralized ve distributed mimariler arasındaki model efficiency ve computational footprint dengesi incelenmiştir. Ek olarak Federated Learning ve Split Learning gibi tekniklerin getirdiği avantajlar ve zorluklar ortaya konmuştur. Sonuçlar model sıkıştırma ve verimli iletişim protokolleri gibi iyileştirmelerin DI tekniklerinin 6G'nin "AI-native" vizyonuna ulaşmasındaki kritik rolünü doğrulamaktadır.

Liu ve diğer araştırmacılar tarafından hazırlanan bu çalışmada, 6G ağlarında "Integrated Sensing" ve "Edge AI" teknolojilerinin birbirini tamamlayan iki temel fonksiyon olarak nasıl birleştiği ve "Integrated Sensing and Edge AI" (ISEA) adı verilen görev odaklı yeni bir paradigmayı nasıl oluşturduğu kapsamlı bir şekilde incelenmiştir (Liu vd., 2025). Çalışma algılama verilerinin Edge AI modellerini eğitmek için yakıt görevi gördüğü Edge AI modellerinin ise algılama verilerinden anlamsal özellikler çıkarmak için kullanıldığı karşılıklı bir ilişkiyi temel alarak communication, AI computation ve sensing süreçlerinin bütünleşik tasarımını önermektedir. Yazarlar ISEA'nın tasarım prensiplerini, mimari yapılarını ve Digital Air Interface ile Over-the-Air Computation gibi teknik bileşenlerini detaylandırırken, bu yapının standardizasyon süreçlerine ve endüstriyel ilerlemelerine de değinmişlerdir. Son olarak foundation models entegrasyonu, ultra-low-latency gereksinimleri ve Integrated Sensing and Communications (ISAC) ile yakınsama gibi gelecekteki araştırma fırsatları tartışılarak ISEA'nın 6G'nin akıllı algılama vizyonunu

gerçekleştirmedeki kritik rolü vurgulanmıştır. Talwar ve diğer araştırmacılar, 6G ağlarının "pervasive distributed intelligence" vizyonuna ulaşması için iletişim, hesaplama ve yapay zeka (AI) yeteneklerinin nasıl bütünleştirilmesi gerektiğini incelemişlerdir (Talwar vd., 2021). Çalışma ağların sadece veri iletimi sağlayan yapılar olmaktan çıkıp uçtan uca programlanabilir "Intelligent Distributed Network" (IDN) platformlarına dönüşeceğini öngörerek bu dönüşümü destekleyecek üç kritik teknoloji alanına odaklanmaktadır. Özellikle ağ kapsamını ve dayanıklılığını artırmak için "Integrated Access and Backhaul" (IAB) kullanan mesh tabanlı topolojiler önerilirken heterojen edge computing ortamlarında işlem gecikmelerini (stragglers) azaltmak için "coded distributed computing" tekniklerinin avantajları vurgulanmıştır. Ayrıca bant genişliği kısıtlı ortamlarda verimli ve hızlı model eğitimi sağlamak amacıyla "Federated Learning" ve analog "Over-the-Air Computation" yöntemlerinin entegrasyonu detaylandırılmıştır. Sonuç olarak bu teknolojilerin bir araya gelmesiyle 6G'nin hem insan hem de makine kullanıcıları için ölçeklenebilir, güvenilir ve yüksek performanslı bir "connected intelligence" altyapısı sunacağı belirtilmiştir. Dede ve diğer araştırmacılar, 6G Core Network mimarisinin "AI-native" bir yapıya dönüşümünü ele alarak bu yeni mimarinin otomasyon, güvenlik ve sürdürülebilirlik gereksinimlerini nasıl karşılayacağını incelemişlerdir (Dede vd., 2025). Çalışma 5G standartlarında tanımlanan Network Data Analytics Function (NWDAF) bileşeninin 6G döneminde nasıl daha proaktif ve merkezi bir role bürüneceğini ve Service Based Architecture (SBA) ile nasıl bütünleşeceğini irdelemektedir. Yazarlar ağın "zero-touch" otomasyon yeteneğine kavuşması için Machine Learning modellerinin yaşam döngüsü yönetiminin (LCM) çekirdek ağı entegrasyonunu tartışmış ve özellikle anomaly detection ve intelligent network slicing gibi kullanım senaryoları üzerinde durmuşlardır. Sonuç olarak güvenlik ve veri gizliliği zorluklarını aşmak için Federated Learning ve Explainable AI (XAI)

gibi güvenilir yapay zeka yaklaşımlarının geleceğin ölçeklenebilir ve enerji verimli çekirdek ağlarının temelini oluşturacağı vurgulanmıştır. You ve diğer araştırmacılar tarafından gerçekleştirilen çalışma da 6G ağlarının evriminde belirleyici olan iki ana trend "ubiquitous intelligence" ve "sustainability" kavramlarının kesişim noktaları ele alınmıştır (You vd., 2025). Çalışma AI teknolojilerinin physical layer'dan uygulama katmanına kadar ağın her noktasına yerleştirilmesini hedeflerken bu durumun getirdiği yüksek veri işleme ve hesaplama yükünün enerji tüketimini artırma riskine dikkat çekmektedir. Yazarlar 6G'nin sadece yüksek performanslı değil aynı zamanda "green" ve çevre dostu olması gerektiğini savunarak enerji verimliliğini artıran yeni mimarilerin ve "green intelligent communications" yöntemlerinin gerekliliğini vurgulamışlardır. Özellikle AI modellerinin eğitimi ve çıkarımı sırasında oluşan karbon ayak izini azaltmak için kaynakların optimize edildiği sürdürülebilir bir 6G ekosistemi vizyonu ortaya konmuştur. Calvanese Strinati ve diğer araştırmacılar, 6G ağlarının "AI-native" bir yapıya dönüşümü için cihaz ve ağ entegrasyonunu merkeze alan "6GARROW" proje vizyonunu ve "Integrated Device-Network" yaklaşımını tanıtmışlardır (Calvanese Strinati vd., 2025). Çalışma akıllı telefonlardan otonom araçlara kadar çeşitli cihazların ve ağ altyapısının (RAN ve Core Network) bütünleşik bir şekilde yapay zeka yetenekleriyle donatılmasını önererek geleneksel statik yapılandırmaların yerini dinamik ve otonom adaptasyonun alacağını vurgulamaktadır. 6GARROW projesi kapsamında geliştirilen bu bütüncül yaklaşım ağın değişen çevresel koşullara ve kullanıcı taleplerine gerçek zamanlı olarak yanıt vermesini sağlarken enerji verimliliğini artırmayı ve gecikmeyi düşürmeyi hedeflemektedir. Yazarlar bu entegrasyonun "spatio-temporal" iletişim ve sürükleyici kullanıcı deneyimleri gibi yenilikçi servisleri mümkün kılacağını ve böylece 6G'nin sadece bir iletişim ağı olmaktan çıkıp akıllı ve işbirlikçi bir ekosisteme dönüşeceğini belirtmişlerdir.

Paolini ve diğer araştırmacılar, 6G ağlarında siber güvenlik tehditlerini tespit etmek amacıyla deep embeddings temelli gerçek zamanlı bir kümeleme yaklaşımı geliştirmişlerdir (Paolini vd., 2023). Çalışmada geleneksel denetimli öğrenme yöntemlerinin henüz bilinmeyen "zero-day" saldırılarını yakalamadaki yetersizliğine çözüm olarak etiketlenmemiş verilerle çalışabilen denetimsiz bir "Deep Embedding Clustering" (DEC) algoritması önerilmiştir. Bu yöntem yüksek boyutlu ağ trafiği verilerini bir autoencoder yardımıyla daha düşük boyutlu bir gizli uzaya (latent space) sıkıştırarak anomali tespitini hızlandırmakta ve verimliliği artırmaktadır. CIC-IDS2017 veri seti üzerinde yapılan testler önerilen modelin yüksek doğruluk oranlarına ve milisaniyeler mertebesinde işlem süresine ulaştığını ve bu sayede 6G'nin katı gecikme gereksinimlerini karşılayarak "edge" noktalarında konuşlandırılabilir bir çözüm sunduğunu göstermektedir. Butt ve Shah tarafından yapılan çalışmada Artificial Intelligence (AI) ile 6G ağlarının yakınsaması ve bu birleşimin hesaplama ve iletişim sistemlerinde yaratacağı dönüştürücü etkiler incelenmiştir (Butt & Shah, 2025). Çalışma telekomünikasyon, healthcare ve smart cities gibi endüstrilerin bu entegrasyonla nasıl şekilleneceğini analiz ederek THz communication, massive MIMO, edge computing ve quantum computing gibi temel teknolojilerin 6G'nin kapasitesini nasıl artıracığını detaylandırmaktadır. Yazarlar AI destekli 6G ağlarının ultra yüksek hız, gerçek zamanlı veri işleme ve gelişmiş ağ yönetimi gibi avantajlar sunarken aynı zamanda veri güvenliği ve gizliliği konusunda yeni zorluklar getirdiğine dikkat çekmişlerdir. Sonuç olarak AI entegrasyonunun 6G ağlarını sadece optimize etmekle kalmayıp kendi kendini yönetebilen ve iyileştirebilen akıllı ekosistemlere dönüştürerek toplumsal ve endüstriyel alanda devrim yaratacağı vurgulanmıştır.

Sonuçlar

6G ağları üzerine yapılan bu literatür taraması telekomünikasyon dünyasında önemli bir dönüşümün yaşandığını göstermektedir. İletişim ağları artık pasif veri taşıyıcıları değil algılayan, öğrenen ve karar veren akıllı organizmalara dönüşmektedir. İncelenen çalışmalar Yerel Yapay Zeka ve Dağıtık Yapay Zeka teknolojilerinin entegrasyonunun ağ yönetiminde sıfır dokunuşlu (zero-touch) otomasyonu ve ultra-düşük gecikmeli hizmetleri mümkün kıldığını doğrulamaktadır. Literatürden elde edilen temel çıkarımlar şunlardır: İlk olarak, zekanın buluttan ağına uçlarına (Edge/Fog) kaydırılması hem veri gizliliğini korumakta hem de iletişim darboğazlarını aşarak gerçek zamanlı uygulamaların (örneğin otonom araçlar, uzaktan cerrahi) önünü açmaktadır. Federated Learning gibi dağıtık öğrenme teknikleri bu süreçte veriyi kaynağında işleyerek güvenlik ve verimlilik dengesini sağlamaktadır. İkinci olarak, 6G'nin sadece performans odaklı değil aynı zamanda sürdürülebilir bir teknoloji olması gerektiği vurgusu öne çıkmaktadır. Yapay zeka modellerinin eğitimi ve işletimi sırasında ortaya çıkan enerji maliyetleri Yeşil 6G (Green 6G) vizyonu çerçevesinde optimize edilmeli ve donanım kısıtlı cihazlar için hafif (lightweight) algoritmalar geliştirilmelidir. Son olarak, ağların yapay zekayla birlikte siber tehditlerin de evrim geçirdiği görülmektedir. Bu nedenle yapay zeka destekli saldırılara karşı yine yapay zeka tabanlı proaktif ve kendi kendini savunan güvenlik mimarilerinin geliştirilmesi kritik bir gerekliliktir. Özetle, 6G çağı fiziksel ve dijital dünyaların iç içe geçtiği bağlantılı zekanın her an her yerde erişilebilir olduğu yeni bir endüstriyel devrimi işaret etmektedir. Bu dönüşümün başarısı sadece iletişim teknolojilerindeki ilerlemelere değil yapay zeka, veri bilimi ve donanım mühendisliği disiplinlerinin ortak çalışmasına bağlı olacaktır. Gelecek çalışmaların özellikle heterojen ağlarda yapay

zeka modellerinin genelleştirilebilirliği ve kuantum sonrası güvenlik standartları üzerine yoğunlaşması beklenmektedir.

Kaynakça

- Abdulraqueb, A., Ibraheem, S., A, E.-S. A., Hadri, A. M., Hilmi, I. Z., Lida, K., & Ali, S. S. (2024). Artificial intelligence in 6G wireless networks: Opportunities, applications, and challenges. *International Journal of Intelligent Systems*, 8845070.
- Butt, I. N., & Shah, S. (2025). The Convergence of Artificial Intelligence and 6G Networks: A Transformative Shift in Computing and Communications. *Journal of Engineering and Computational Intelligence Review*, 3(1), 68-81.
- Dede, R., Ak, N., Güllü, M., Yazıcı, İ., & Duru, İ. (2025). AI For Core Network in 6G. (s. 1-9). IEEE.
- Duan, X., Sun, T., Liu, C., Ma, X., Hu, Z., Lu, L., . . . Wang, S. (2022). Cognitive intelligence based 6G distributed network architecture. *China Communications*, 19(6), 137-153.
- Gupta, A., & Jha, R. K. (2015). A survey of 5G network: Architecture and emerging technologies. *IEEE access*, 3, 1206-1232.
- Ioannou, I. I., Christophorou, C., Vassiliou, V., Lestas, M., & Pitsillides, A. (2022). Dynamic D2D communication in 5G/6G using a distributed AI framework. *IEEE Access*, 10, 62772-62799.
- Janbi, N., Katib, I., Albeshri, A., & Mehmood, R. (2020). Distributed artificial intelligence-as-a-service (DAIaaS) for smarter IoE and 6G environments. *Sensors*, 20(20), 5796.
- Karachalios, O. A., Zafeiropoulos, A., Kontovasilis, K., & Papavassiliou, S. (2023). Distributed machine learning and native AI enablers for end-to-end resources management in 6G. *Electronics*, 12(18), 3761.

- Khara, A., Javid, I., Khara, S., & Prasad, R. (2024). Research Issues and Challenges in AI-Embedded 6G Network Architecture. (s. 1-5). IEEE.
- Latva-Aho, M., & Leppänen, K. (2019). Key drivers and research challenges for 6G ubiquitous wireless intelligence. *University of Oulu White Paper*.
- Letaief, K. B., Shi, Y., Lu, J., & Lu, J. (2021). Edge artificial intelligence for 6G: Vision, enabling technologies, and applications. *IEEE journal on selected areas in communications*, 40(1), 5-36.
- Liu, Z., Chen, X., Wu, H., Wang, Z., Chen, X., Niyato, D., & Huang, K. (2025). Integrated sensing and edge AI: Realizing intelligent perception in 6G. *IEEE Communications Surveys & Tutorials*.
- Mohsin, M. A., Ahmad, J., Nawaz, M. H., & Jamshed, M. A. (2025). Towards 6G Intelligence: The Role of Generative AI in Future Wireless Networks. *arXiv preprint arXiv:2508.19495*.
- Ogenyi, F. C., Ugwu, C. N., & Ugwu, O. P.-C. (2025). A comprehensive review of AI-native 6G: integrating semantic communications, reconfigurable intelligent surfaces, and edge intelligence for next-generation connectivity. *Frontiers in Communications and Networks*, 6, 1655410.
- Paolini, E., Valcarenghi, L., Maggiani, L., & Andriolli, N. (2023). Real-time clustering based on deep embeddings for threat detection in 6G networks. *IEEE Access*, 11, 115827-115835.
- Psaromanolakis, N., Theodorou, V., Laskaratos, D., Kalogeropoulos, I., Vlontzou, M.-E., Zarogianni, E., & Samaras, G. (2023). MLOps meets edge computing: an edge platform with

embedded intelligence towards 6G systems. (s. 496-501). IEEE.

- Saad, W., Bennis, M., & Chen, M. (2019). A vision of 6G wireless systems: Applications, trends, technologies, and open research problems. *IEEE network*, 34(3), 134-142.
- Sanjalawe, Y., Fraihat, S., Abualhaj, M., Makhadmeh, S., & Alzubi, E. (2025). A review of 6G and AI convergence: Enhancing communication networks with artificial intelligence. *IEEE Open Journal of the Communications Society*.
- Sanjalawe, Y., Fraihat, S., Makhadmeh, S. N., & Alzubi, E. (2025). AI-powered smart grids in the 6G era: A comprehensive survey on security and intelligent energy systems. *IEEE Open Journal of the Communications Society*.
- Strinati, E. C., Cassiau, N., Chae, C.-B., Dal Zotto, P., di Pietro, N., Dufrène, L.-A., . . . Kim, S.-L. (2025). AI-Native 6G Networks: The 6GARROW Integrated Device-Network Approach. (s. 115-120). IEEE.
- Talwar, S., Himayat, N., Nikopour, H., Xue, F., Wu, G., & Ilderem, V. (2021). 6G: Connectivity in the era of distributed intelligence. *IEEE Communications Magazine*, 59(11), 45-50.
- Vandikas, K., Larsson, H., Ickin, S., Riaz, H., Temesgene, D. A., Ghadikolaie, H. S., . . . Palaios, A. (2025). On the adoption of Distributed Intelligence towards 6G networks. *IEEE Access*.
- Yang, H., Alphones, A., Xiong, Z., Niyato, D., Zhao, J., & Wu, K. (2020). Artificial-intelligence-enabled intelligent 6G networks. *IEEE network*, 34(6), 272-280.

You, X., Huang, Y., Zhang, C., Wang, J., Yin, H., & Wu, H. (2025).
When AI meets sustainable 6G. *Science China Information
Sciences*, 68(1), 110301.

BÖLÜM 12

Açıklanabilir Yapay Zekâ (XAI) İçin Modern Yaklaşımlar

AYŞE GÜL EKER¹

Giriş

Yapay zekâ tabanlı sistemler sağlık, finans, hukuk ve kamu hizmetleri gibi yüksek riskli alanlarda yaygınlaştıkça, bu sistemlerin yalnızca doğru sonuçlar üretmesi yeterli görülmemektedir. Verilen kararların neden ve nasıl üretildiğinin anlaşılabilir olması, kullanıcı güveni, kurumsal sorumluluk ve etik ilkeler açısından kritik hâle gelmiştir. Özellikle derin öğrenme temelli modellerin kara kutu niteliği, yüksek doğruluk ile düşük şeffaflık arasında belirgin bir gerilim yaratmaktadır (Arrieta ve diğ., 2020). Bu bağlamda açıklanabilir yapay zekâ (Explainable Artificial Intelligence, XAI), model kararlarının insan tarafından anlaşılabilir biçimde sunulmasını amaçlayan yöntemler bütünü olarak öne çıkmaktadır.

Açıklanabilirlik, günümüzde güvenilir yapay zekâ çerçevesinin temel bileşenlerinden biri olarak ele alınmaktadır. Güvenilir yapay zekâ; yalnızca teknik performansı değil, aynı

¹Dr., Kocaeli Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0003-0721-2631

zamanda şeffaflık, hesap verebilirlik, adalet ve etik uygunluğu kapsayan çok boyutlu bir yaklaşımı ifade eder (Ali ve diğ., 2023). Bu çerçevede XAI, karar süreçlerinin denetlenebilirliğini artırarak hem geliştiriciler hem de son kullanıcılar için ortak bir güven zemini oluşturur. Literatürde, açıklanabilirliğin eksikliğinin; hatalı kararların tespit edilmesini, veri ve model kaynaklı ayrımcılığın ortaya çıkarılmasını ve özellikle kritik alanlarda yasal gereklilikler ile hesap verebilirlik ilkeleriyle uyumu zorlaştırarak ciddi riskler doğurduğu vurgulanmaktadır (Dwivedi ve diğ., 2023).

Son yıllarda XAI yaklaşımları, yalnızca modelin iç yapısını açığa çıkarmayı değil, aynı zamanda farklı kullanıcı profillerine uygun açıklamalar sunmayı hedefleyecek biçimde evrilmiştir. Bu durum, açıklanabilirliğin tekil bir teknik problem değil, insan-merkezli bir tasarım ve değerlendirme konusu olduğunu göstermektedir. Bu bölümde ele alınacak modern XAI yaklaşımları; güvenilir yapay zekâ hedefleriyle ilişkileri, güçlü yönleri ve sınırlılıkları dikkate alınarak incelenecektir. Böylece açıklanabilirliğin, güncel yapay zekâ sistemlerinde neden vazgeçilmez bir gereklilik hâline geldiği bütüncül bir çerçevede ortaya konacaktır.


Örnek Bazlı Açıklanabilirlik için Modelden Bağımsız Yerel Analiz: LIME Yaklaşımı

Bir yapay zekâ modelinin ürettiği her bir tahminin hangi gerekçelere dayanarak oluşturulduğunu anlamak, özellikle karar destek sistemleri, risk analizi ve insan denetimi gerektiren uygulamalar açısından kritik öneme sahiptir. Geleneksel performans ölçütleri, bir modelin ne kadar doğru çalıştığını gösterebilse de, neden belirli bir kararın üretildiği sorusuna doğrudan yanıt vermez. Bu noktada yerel açıklama yöntemleri devreye girer. Yerel açıklama yaklaşımları, modelin tüm karar uzayını açıklamaya çalışmak

yerine, belirli bir örnek için verilen tekil bir tahmine odaklanarak daha anlaşılır ve pratik açıklamalar sunmayı amaçlar.

LIME (Local Interpretable Model-Agnostic Explanations), bu yerel açıklama yaklaşımını benimseyen ve açıklanabilir yapay zekâ literatüründe en yaygın kullanılan yöntemlerden biridir (Ribeiro, Singh, & Guestrin, 2016)). LIME'in temel varsayımı, karmaşık ve yorumlanması güç bir modelin davranışının, belirli bir veri örneğinin yakın çevresinde daha basit ve yorumlanabilir bir modelle yeterince iyi temsil edilebileceğidir. Başka bir ifadeyle LIME, “model genel olarak nasıl çalışıyor?” sorusundan ziyade, “bu özel tahmin neden böyle çıktı?” sorusuna yanıt arar. Bu yönüyle LIME, özellikle kullanıcıların tekil kararları sorguladığı senaryolarda sezgisel bir açıklama aracı olarak öne çıkar.

Resim 1 :LIME yaklaşımında, karmaşık küresel model davranışının tekil bir tahmin etrafında basit bir yerel modelle yaklaşık olarak temsil edilmesi



Resim 1, LIME yaklaşımının temel fikrini görsel olarak özetlemektedir. Görselde, karmaşık ve doğrusal olmayan bir küresel modelin karar sınırı ile bu modelin tekil bir veri örneği etrafındaki yerel davranışı birlikte gösterilmektedir. LIME, modelin tüm karar uzayını açıklamaya çalışmak yerine, yalnızca ilgili örneğin yakın çevresine odaklanarak bu bölgede basit ve doğrusal bir yerel yaklaşım oluşturur. Bu yerel yaklaşım, söz konusu tahminin hangi özelliklere dayanarak üretildiğini anlaşılır biçimde ortaya koyarken, açıklamanın yalnızca yerel bağlamda geçerli olduğunu da açıkça vurgular.

LIME yaklaşımında açıklama süreci birkaç temel adımdan oluşur. Öncelikle açıklanmak istenen veri örneğinin etrafında, girdiler üzerinde küçük ve kontrollü değişiklikler yapılarak yapay veri örnekleri oluşturulur. Bu örnekler, orijinal model tarafından değerlendirilir ve her biri için karşılık gelen tahmin çıktıları elde edilir. Ardından bu yerel veri kümesi kullanılarak, genellikle doğrusal bir model veya küçük bir karar ağacı gibi basit ve yorumlanabilir bir açıklayıcı model öğrenilir. Bu açıklayıcı model, yalnızca ilgili örneğin yakın çevresinde geçerli olacak şekilde tasarlanır ve karmaşık modelin yerel davranışını yaklaşık olarak temsil eder. Açıklayıcı modelin katsayıları veya karar kuralları incelendiğinde, hangi özelliklerin tahmine ne yönde katkı sağladığı açık biçimde görülebilir (Salih ve diğ., 2024).

LIME'in önemli avantajlarından biri, modelden bağımsız (agnostik) bir yapıya sahip olmasıdır. Bu özellik, yöntemin yalnızca belirli bir model türüne bağlı kalmadan; karar ağaçları, destek vektör makineleri, topluluk yöntemleri ve derin öğrenme modelleri dâhil olmak üzere çok farklı makine öğrenmesi yaklaşımlarına uygulanabilmesini mümkün kılar. Bu esneklik, LIME'in farklı problem alanlarında hızlı biçimde kullanılmasını ve geliştiriciler tarafından kolayca benimsenmesini sağlamıştır. Ayrıca LIME,

açıklamaları genellikle görsel veya tablo tabanlı biçimde sunduğundan, teknik olmayan kullanıcılar için de anlaşılabilir bir anlatım sağlar.

Bununla birlikte, literatürde LIME’in bazı sınırlılıkları da ayrıntılı biçimde ele alınmaktadır. Özellikle yerel veri örneklerinin rastgele üretilmesi, elde edilen açıklamaların kararlılığını ve tekrarlanabilirliğini olumsuz yönde etkileyebilir. Aynı veri örneği için farklı çalıştırmalarda farklı açıklamalar elde edilmesi, kullanıcı güvenini zedeleyebilecek bir durum olarak değerlendirilir. Ayrıca LIME tarafından sunulan yerel açıklamaların, modelin genel davranışı hakkında yanıltıcı bir bütüncül algı oluşturma riski bulunmaktadır. Bu nedenle açıklamaların, yalnızca yerel bağlamda geçerli olduğunun açıkça belirtilmesi önemlidir (Saarela ve diğ., 2024).

Güncel açıklanabilir yapay zekâ araştırmaları, LIME gibi yerel açıklama yöntemlerini tek başına yeterli çözümler olarak görmekten ziyade, bu yöntemleri küresel açıklama yaklaşımları ve farklı değerlendirme ölçütleri ile birlikte ele alma eğilimindedir. Açıklamaların kararlılığını artırmaya yönelik yöntemler, yerel ve küresel açıklamaların birleştirilmesi ve kullanıcıya sunulan açıklamaların bağlamsal olarak zenginleştirilmesi, bu alandaki başlıca araştırma yönelimleri arasında yer almaktadır. Bu çerçevede LIME, sınırlılıklarına rağmen, örnek bazlı açıklanabilirlik açısından önemli ve öğretici bir başlangıç noktası olarak kabul edilmektedir.

Özellik Katkı Tabanlı Açıklamalar: SHAP Yaklaşımı

Yerel açıklama yöntemleri içerisinde LIME, sezgisel ve pratik bir çözüm sunmasına rağmen, açıklamaların kararlılığı ve tutarlılığı konusunda bazı sınırlılıklar barındırmaktadır. Bu sınırlılıkları ele almak üzere geliştirilen SHAP (SHapley Additive exPlanations) yaklaşımı, açıklanabilir yapay zekâ literatüründe

özellik katkılarını daha sistematik ve teorik temelli biçimde ele alan bir yöntem olarak öne çıkmaktadır. SHAP'in temel amacı, bir modelin ürettiği tahminde her bir özelliğin katkı düzeyini adil ve tutarlı bir biçimde hesaplamak ve bu katkıları kullanıcıya anlaşılır şekilde sunmaktır.


SHAP yaklaşımı, kökenini oyun teorisinde yer alan **Shapley değeri** kavramından almaktadır. Bu çerçevede her bir özellik, modelin ürettiği tahminde bir “oyuncu” olarak değerlendirilir ve ilgili tahmine yaptığı katkı, diğer özelliklerle olan tüm olası kombinasyonlar dikkate alınarak hesaplanır (Lundberg & Lee, 2017). Bu yaklaşım, özellik katkılarının hem yerel hem de küresel düzeyde tutarlı biçimde yorumlanabilmesini sağlar. Bir başka deyişle SHAP, tekil bir tahmine yönelik yerel açıklamalar üretirken, bu açıklamaların modelin genel davranışıyla da tutarlı olmasını amaçlar.

SHAP'in önemli avantajlarından biri, eklenebilir açıklama modeli (additive explanation model) çerçevesinde çalışmasıdır. Bu sayede model çıktısı, bir temel değer ile her bir özelliğin katkısının toplamı şeklinde ifade edilebilir. Ortaya çıkan açıklamalar, özelliklerin tahmini hangi yönde ve ne ölçüde etkilediğini açıkça göstermesi bakımından özellikle karar destek sistemlerinde ve düzenleyici gereksinimlerin bulunduğu alanlarda tercih edilmektedir. Literatürde SHAP'in, LIME'a kıyasla daha tutarlı ve teorik olarak gerekçelendirilmiş açıklamalar sunduğu sıkça vurgulanmaktadır (Hassija ve diğ., 2024).

Şekil 2'de, SHAP yaklaşımı kullanılarak tekil bir örnek için hesaplanan yerel öznitelik katkıları örnekleyici olarak gösterilmektedir. Görselde her bir öznitelik, modelin ürettiği tahmine olan katkısına göre pozitif veya negatif yönde temsil edilmektedir. Pozitif katkılar tahmin değerini artıran, negatif katkılar

ise azaltan öznitelikleri ifade etmektedir. Bu gösterim sayesinde model çıktısının, bir temel değer etrafında her bir özneliğin katkılarının toplamı olarak nasıl oluştuğu açık biçimde görülebilmektedir. Böylece SHAP, tekil tahminler için açıklama sunarken, açıklamaların modelin genel davranışıyla tutarlı olmasını da sağlamayı amaçlamaktadır.

Resim 2 :SHAP ile tekil bir tahmin için yerel öznitelik katkıları



Bununla birlikte SHAP yaklaşımı da tamamen sorunsuz değildir. Özellikle tüm olası özellik kombinasyonlarının dikkate alınması gerekliliği, yöntemin hesaplama maliyetini önemli ölçüde artırabilmektedir. Bu nedenle pratik uygulamalarda KernelSHAP, TreeSHAP gibi farklı yaklaşım veya modele özgü varyantlar

geliştirilmiştir(Lundberg & Lee, 2017). Ayrıca SHAP tarafından üretilen açıklamaların, yüksek boyutlu veri setlerinde kullanıcı tarafından yorumlanması zorlaşabilir. Bu durum, SHAP açıklamalarının görselleştirme ve özetleme teknikleriyle desteklenmesini gerekli kılmaktadır.

Genel olarak SHAP, özellik katkılarını tutarlı ve teorik temelli biçimde sunması sayesinde, güvenilir yapay zekâ hedefleriyle güçlü bir uyum sergileyen açıklanabilirlik yaklaşımlarından biri olarak kabul edilmektedir. Özellikle yerel ve küresel açıklamaları bir arada ele alabilme yeteneği, SHAP’i modern XAI yöntemleri arasında merkezi bir konuma taşımaktadır.

Karşı-Olgusal Açıklamalar

Açıklanabilir yapay zekâ yaklaşımlarının önemli bir kısmı, modelin bir tahmini neden ürettiğini açıklamaya odaklanırken, karşı-olgusal (counterfactual) açıklamalar farklı bir soruyu merkeze alır: Bu sonucun değişmesi için neyin farklı olması gerekirdi?”. Bu yaklaşım, özellikle kararların bireyleri doğrudan etkilediği kredi değerlendirme, işe alım veya sağlık gibi alanlarda, kullanıcılar açısından daha sezgisel ve eyleme dönük açıklamalar sunar. Karşı-olgusal açıklamalar, modelin iç yapısını açığa çıkarmadan, verilen bir kararın hangi asgari değişikliklerle farklı bir sonuca dönüşebileceğini göstermeyi amaçlar.

Karşı-olgusal açıklamaların temel çerçevesi, bir veri örneği için model çıktısını değiştirecek en küçük ve anlamlı girdi değişikliklerini bulmaya dayanır. Bu açıklamalar genellikle üç temel özelliği sağlamayı hedefler: açıklamanın geçerli olması (çıktıyı gerçekten değiştirmesi), mümkün olan en az değişikliği içermesi ve gerçekçi olması. Erken dönem çalışmalar, karşı-olgusal açıklamaların temel ilkelerini sistematik biçimde ortaya koyarak, bu tür açıklamaların modelin iç yapısına erişmeden, modelden bağımsız

bir şekilde üretilebileceğini göstermiştir. (Wachter, Mittelstadt, & Russell, 2017). Bu yönüyle karşı-olgusal açıklamalar, kara kutu modeller için özellikle cazip bir çözüm sunmaktadır.

Karşı-olgusal açıklamaların önemli bir avantajı, kullanıcı-merkezli olmalarıdır. Örneğin bir kredi başvurusu reddedildiğinde, “model bu kararı neden verdi?” sorusundan ziyade, “kredinin onaylanması için ne değişmeliydi?” sorusu, kullanıcı açısından daha anlaşılır ve doğrudan bir geri bildirim sağlar. Bu nedenle literatürde karşı-olgusal açıklamalar, adalet, hesap verebilirlik ve şeffaflık gibi güvenilir yapay zekâ ilkeleriyle yakından ilişkilendirilmektedir (Karimi, Schölkopf, & Valera, 2020). Ayrıca bu yaklaşım, açıklamaların yalnızca teknik uzmanlara değil, kararların muhatabı olan bireylere de hitap edebilmesini mümkün kılar.

Son yıllarda karşı-olgusal açıklamaların, yalnızca girdi değişikliklerine dayalı açıklamalar sunmanın ötesine geçmesi gerektiği yönünde güçlü bir literatür oluşmuştur. Bu çalışmalar, karşı-olgusal açıklamaların nedensel ilişkilerle desteklenmediği durumlarda, kullanıcıya sunulan önerilerin gerçek dünyada uygulanabilir olmayabileceğini vurgulamaktadır. Bu bağlamda, açıklanabilir yapay zekâ ile nedensel çıkarım yaklaşımlarını birleştiren yeni karşı-olgusal çerçeveler önerilmekte; böylece model çıktılarının ardındaki neden-sonuç ilişkilerinin daha anlamlı biçimde temsil edilmesi hedeflenmektedir (Baron, 2023). Bu eğilim, karşı-olgusal açıklamaların güvenilir yapay zekâ hedefleriyle daha güçlü bir uyum sergilemesini sağlamaktadır.

Bununla birlikte karşı-olgusal açıklamaların da sınırlılıkları bulunmaktadır. Özellikle yüksek boyutlu veya karmaşık veri yapılarında, üretilen karşı-olgusal örneklerin gerçekçi olmaması veya uygulamada mümkün olmayan değişiklikler önermesi önemli bir sorun olarak öne çıkmaktadır. Ayrıca birden fazla geçerli karşı-

olgusal açıklamanın bulunması, hangi açıklamanın sunulması gerektiği konusunda yeni tasarım ve etik sorular doğurmaktadır. Bazı araştırmalar, karşı-olgusal açıklamaların gerçekçi ve uygulanabilir olmasını sağlamak amacıyla alan kısıtlarını, nedensel ilişkileri ve kullanıcı açısından anlamlı değişiklikleri dikkate alan daha gelişmiş karşı-olgusal üretim yöntemlerine odaklanmaktadır (Molnar, 2020; Karimi ve diğ., 2020).

Açıklanabilirlikte Görselleştirme Teknikleri

Açıklanabilir yapay zekâ yöntemlerinin etkinliği, yalnızca hangi açıklamanın üretildiğine değil, bu açıklamanın kullanıcıya nasıl sunulduğuna da doğrudan bağlıdır. Özellikle karmaşık modeller söz konusu olduğunda, sayısal çıktılar veya metinsel açıklamalar tek başına yeterli olmayabilir. Görselleştirme teknikleri, model davranışını görsel temsiller aracılığıyla ifade ederek, kullanıcıların açıklamaları daha hızlı ve sezgisel biçimde kavramasını sağlar. Bu nedenle modern XAI literatüründe görselleştirme, açıklamanın ayrılmaz bir bileşeni olarak ele alınmaktadır (Saarela & Podgorelec, 2024).


Bu bölümde ele alınan görselleştirme yaklaşımları, açıklamaların yerel ve küresel düzeyde nasıl sunulduğunu, farklı model türleri için hangi görsel stratejilerin tercih edildiğini ve bu görsellerin hangi riskleri barındırdığını ortaya koymaktadır.

1. Özellik Katkılarının Genel Olarak Görselleştirilmesi

Genel açıklamalar, modelin genel davranışını ve hangi özniteliklerin karar sürecinde daha baskın rol oynadığını anlamayı amaçlar. Bu bağlamda en yaygın kullanılan görselleştirme yaklaşımlarından biri, SHAP tabanlı öznitelik katkı dağılım grafikleridir. Özellikle özet (summary) grafikler ve arı sürüsü (beeswarm) görselleştirmeleri,


tüm veri kümesi boyunca özniteliklerin modele olan katkılarını aynı anda göstermektedir. Bu tür grafikler, yalnızca hangi özniteliklerin önemli olduğunu değil, aynı zamanda öznitelik değerlerinin model çıktısını hangi yönde etkilediğini de ortaya koyar.

Resim 3 :SHAP özet grafiği :Özniteliklerin model çıktısı üzerindeki ortalama etkileri.



Örneğin bir kredi değerlendirme modelinde, modelin hangi özniteliklere daha fazla ağırlık verdiğini anlamak amacıyla SHAP tabanlı görselleştirmelerden yararlanılabilir. Resim 3’te sunulan SHAP özet grafiğinde, modelin tahminleri üzerinde en etkili olan özniteliklerin görelî önem sıralaması gösterilmektedir. Ortalama mutlak SHAP değerlerine göre kredi tutarı ve vadesiz hesap tutarının Ancak bu tür bir özet grafik, özniteliklerin nasıl etki ettiğini değil, yalnızca ne ölçüde etkili olduklarını ortaya koymaktadır. Bu nedenle Şekil 4’te gösterilen SHAP arı sürüsü görselleştirmesi ile her bir öznitelik değerinin model çıktısını hangi yönde etkilediği daha ayrıntılı biçimde incelenebilmektedir. model çıktısı üzerinde en baskın etkiye sahip olduğu görülmektedir.

Resim 4 : SHAP arı sürüsü (beeswarm) görselleştirme: Öznitelik katkılarının veri kümesi boyunca dağılımı



Görsel incelendiğinde kredi tutarı ve vadesiz hesap tutarının model çıktısı üzerinde en geniş etki aralığına sahip olduğu, bu özniteliklerdeki yüksek ve düşük değerlerin tahmini farklı yönlerde etkilediği görülmektedir. Yaş değişkeninin katkıları daha sınırlı bir aralıkta yoğunlaşırken, konut tipi ve meslek özniteliklerinin model çıktısı üzerindeki etkilerinin görece düşük olduğu anlaşılmaktadır.

Bu görselleştirmeler, küresel model davranışını tek bir bakışta özetleyebilmeleri nedeniyle model doğrulama, hata analizi ve model karşılaştırması gibi süreçlerde yaygın olarak kullanılmaktadır. Bununla birlikte, bu tür görsel açıklamaların sunduğu katkıların nedensel bir etkiyi değil, modelin öğrendiği istatistiksel bağıntıları yansıttığı açıkça belirtmeli; aksi takdirde açıklamaların yanlış nedensel çıkarımlara yol açabileceği göz önünde bulundurulmalıdır (Verma ve diğ., 2022).


2. Tekil Tahminler için Yerel Görselleştirmeler

Yerel açıklamalarda görselleştirme, tek bir tahminin nasıl oluştuğunu adım adım göstermeyi hedefler. SHAP için yaygın

olarak kullanılan güç grafiği (force plot) ve şelale grafiği (waterfall plot) türü görseller, model çıktısını bir temel değer etrafında öznitelik katkılarının toplamsal etkisi olarak sunar. Bu yaklaşım, kullanıcıya bir tahminin hangi özniteliklerin katkısıyla yükseldiğini veya düştüğünü açık biçimde gösterir.


Kredi örneğinde tekil bir başvuruya ilişkin kararın hangi özniteliklerden nasıl etkilendiğini anlamak amacıyla da SHAP tabanlı görselleştirmelerden yararlanılabilir. Güç grafikleri, tekil bir tahminin, modelin ortalama çıktısından başlayarak hangi özniteliklerin etkisiyle ve hangi yönde şekillendiğini görsel olarak gösteren yerel açıklama yöntemleridir. Bu grafiklerde her bir öznitelik, tahmini artıran veya azaltan bir itme kuvveti olarak temsil edilir.

Resim 5 : SHAP güç (force) grafiği görselleştirmesi



Resim 5’te, seçilen tekil bir örnek için hesaplanan SHAP force grafiği verilmiştir. Görsel incelendiğinde kredi tutarı ve yaş değişkenlerinin tahmini belirgin biçimde negatif yönde etkilediği, buna karşılık vadesiz hesap tutarı, meslek ve konut tipi gibi özniteliklerin tahmini sınırlı ölçüde pozitif yöne ittiği görülmektedir. Bu karşıt etkilerin birleşimi sonucunda model çıktısı düşük bir değer almıştır.

Resim 6 : SHAP şelale (waterfall) grafiği görselleştirmesi



Resim 6’da, tekil bir örnek için oluşturulan SHAP waterfall (şelale) grafiği verilmiştir. Grafik, modelin ortalama çıktı değerinden başlayarak her bir özneliliğin katkısının sırayla eklenmesiyle nihai tahmine nasıl ulaşıldığını göstermektedir. Kredi tutarı ve yaş değişkenlerinin tahmini güçlü biçimde negatif yönde etkilediği, buna karşılık vadesiz hesap tutarı, meslek ve konut tipi gibi özneliliklerin tahmini sınırlı ölçüde pozitif yönde dengelediği görülmektedir. Bu katkıların toplamı sonucunda model çıktısı düşük bir değerde oluşmuştur.

Bu tür görselleştirmeler, özellikle kararların bireysel düzeyde sorgulandığı uygulamalarda (örneğin kredi başvuruları veya risk skorlaması) yüksek açıklayıcılık sunar. Yerel görselleştirmelerin en önemli avantajı, karmaşık modellerin tekil tahminler üzerindeki etkilerini, toplamsal ve sezgisel özellik katkıları üzerinden ayrıştırarak kullanıcıya sunabilmesidir.(Lundberg & Lee, 2017).

3. Derin Öğrenme Modelleri için Isı Haritaları

Görüntü, metin veya sinyal verisi üzerinde çalışan derin öğrenme modellerinde, açıklanabilirlik çoğu zaman girdinin hangi bölümlerinin karar üzerinde etkili olduğunu göstermekle sağlanır.

Bu amaçla kullanılan ısı haritaları, modelin giriş uzayındaki dikkatini görsel olarak temsil eder. Grad-CAM ve benzeri yöntemler, sınıf aktivasyonlarını giriş verisi üzerine bindirerek, modelin karar verirken hangi bölgeleri daha fazla dikkate aldığını gösterir.

Resim 7 : Grad-CAM görselleştirmesi: Derin öğrenme modelinin sınıflandırma kararını verirken görüntü üzerinde en fazla dikkate aldığı bölgeleri gösteren ısı haritası.



Resim 7’de, önceden ImageNet veri kümesi üzerinde eğitilmiş VGG16 modeli kullanılarak üretilen Grad-CAM ısı haritası gösterilmektedir. Görselde, modelin ilgili sınıfa ait tahmini oluştururken görüntünün hangi bölgelerine daha fazla odaklandığı renk yoğunlukları ile ifade edilmektedir. Isı haritası, modelin karar sürecinde özellikle filin kulak ve gövde bölgelerini ayırt edici özellikler olarak kullandığını ortaya koymaktadır.

Isı haritaları, özellikle alan bilgisine sahip kullanıcılar için modelin tahmin sürecinde hangi uzamsal bölgelerden etkilendiğini değerlendirme olanağı sunar. Ancak bu görselleştirmeler, kararın nedensel gerekçesini değil, yalnızca modelin dikkat dağılımını yansıtır. Bu nedenle, ısı haritaları tek başına açıklayıcı kanıt olarak

değil, diğer XAI yöntemleriyle birlikte tamamlayıcı araçlar olarak kullanılmalıdır (Iqbal ve diğ., 2024).

Sonuç ve Gelecek Çalışmalar

Bu bölümde, açıklanabilir yapay zekâ (XAI) alanında öne çıkan modern yaklaşımlar, güvenilir yapay zekâ hedefleri çerçevesinde bütüncül bir bakış açısıyla ele alınmıştır. LIME ve SHAP gibi örnek bazlı ve özellik katkı temelli yöntemler, model kararlarının yerel ve küresel düzeyde anlaşılmasını sağlarken; karşı-olgusal açıklamalar, kullanıcı açısından daha eyleme dönük ve sezgisel bir açıklama perspektifi sunmaktadır. Görselleştirme teknikleri ve Grad-CAM gibi yöntemler ise özellikle karmaşık modellerde açıklamaların kullanıcı tarafından algılanabilirliğini artıran tamamlayıcı araçlar olarak öne çıkmaktadır.

Elde edilen değerlendirmeler, açıklanabilirliğin tek başına bir teknik çıktı değil, kullanıcı profili, uygulama alanı ve kararın bağlamı ile birlikte ele alınması gereken çok boyutlu bir tasarım problemi olduğunu göstermektedir. Yerel açıklamalar bireysel kararların sorgulanması açısından güçlü bir araç sunarken, küresel açıklamalar model doğrulama, hata analizi ve adalet değerlendirmeleri için vazgeçilmezdir. Bu nedenle modern XAI yaklaşımlarının, tek bir yönteme dayalı çözümler yerine, birden fazla açıklama tekniğinin birlikte kullanıldığı hibrit çerçeveler üzerinden ele alınması gerektiği ortaya çıkmaktadır.

Gelecek çalışmalarda, açıklanabilir yapay zekâ yöntemlerinin nedensel çıkarım yaklaşımlarıyla daha sıkı biçimde bütünleştirilmesi önemli bir araştırma yönelimi olarak değerlendirilmektedir. Ayrıca büyük dil modelleri ve üretici yapay zekâ sistemleri için açıklanabilirlik mekanizmalarının geliştirilmesi, XAI alanının güncel ve kritik araştırma başlıkları arasında yer almaktadır. Bunun yanı sıra açıklamaların doğruluğu, kararlılığı ve

kullanıcı üzerindeki etkilerinin sistematik biçimde değerlendirilmesine yönelik standart ölçütlerin geliştirilmesi, güvenilir yapay zekâ hedeflerine ulaşmada belirleyici olacaktır.

Sonuç olarak, açıklanabilir yapay zekâ, yalnızca model içgörüsü sunan bir teknik araç değil; etik, hukuki ve toplumsal boyutları olan, yapay zekâ sistemlerinin sorumlu biçimde tasarlanması ve kullanılması için temel bir gereklilik olarak konumlanmaktadır

Kaynakça

Ali, S., Abuhmed, T., El-Sappagh, S., Muhammad, K., Alonso-Moral, J. M., Confalonieri, R., Guidotti, R., Del Ser, J., Díaz-Rodríguez, N. A., & Herrera-Triguero, F. (2023). Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence. *Information Fusion*, Article 101805.<https://doi.org/10.1016/j.inffus.2023.101805>

Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115.<https://doi.org/10.1016/j.inffus.2019.12.012>

Baron, S. (2023). Explainable AI and causal understanding: Counterfactual approaches considered. *Minds and Machines*, 33, 347–377. <https://doi.org/10.1007/s11023-023-09637-x>

Dwivedi, R., Dave, D., Naik, H., Singhal, S., Omer, R., Patel, P., Qian, B., Wen, Z., Shah, T., Morgan, G., & Ranjan, R. (2023). Explainable AI (XAI): Core ideas, techniques, and solutions. *ACM Computing Surveys*, 55(9), Article 194, 1–33. <https://doi.org/10.1145/3561048>

Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., Scardapane, S., Spinelli, I., Mahmud, M., & Hussain, A. (2024). Interpreting black-box models: A review on explainable artificial intelligence. *Cognitive Computation*, 16, 45–74. <https://doi.org/10.1007/s12559-023-10179-8>

Iqbal, S., Qureshi, A. N., Alhussein, M., Aurangzeb, K., & Anwar, M. S. (2024). AD-CAM: Enhancing interpretability of convolutional neural networks with a lightweight framework—from black box to glass box. *IEEE Journal of Biomedical and Health Informatics*, 28(1), 514–526.

Karimi, A.-H., Barthe, G., Schölkopf, B., & Valera, I. (2021). Algorithmic recourse: From counterfactual explanations to interventions. *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT)*, 353–362.

Karimi, A.-H., von Kügelgen, J., Schölkopf, B., & Valera, I. (2020). Algorithmic recourse under imperfect causal knowledge: A probabilistic approach. *Advances in Neural Information Processing Systems (NeurIPS 2020)*.

Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 2017)* (pp. 4765–4774). Red Hook, NY: Curran Associates Inc.

Molnar, C. (2023). *Interpretable machine learning: A guide for making black box models explainable* (3rd ed.). Retrieved from <https://christophm.github.io/interpretable-ml-book/>

Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?” Explaining the predictions of any classifier. *KDD*.

Saarela, M., & Podgorelec, V. (2024). Recent applications of explainable AI (XAI): A systematic literature review. *Applied Sciences*, 14(19), 8884.

Salih, A. M., Raisi-Estabragh, Z., Boscolo Galazzo, I., Radeva, P., Petersen, S. E., Lekadir, K., & Menegaz, G. (2024). A perspective on explainable artificial intelligence methods: SHAP and LIME. arXiv preprint, arXiv:2305.02012v3.

Verma, S., Boonsanong, V., Hoang, M., Hines, K. E., Dickerson, J. P., & Shah, C. (2022). Counterfactual explanations and algorithmic recourse for machine learning: A review. *ACM Computing Surveys*, 55(6), Article 122. <https://doi.org/10.1145/3542929>

Wachter, S., Mittelstadt, B., & Russell, C. (2017). Counterfactual explanations without opening the black box: Automated decisions and the GDPR. *Harvard Journal of Law & Technology*, 31(2), 841–887.

BÖLÜM 13

SENTETİK TABULAR VERİ ÜRETİMİNDE YENİ NESİL YAKLAŞIMLAR

İRFAN KÖSESOY¹
EREN PARTAL²

Giriş

Veri odaklı yöntemler, modern bilimsel araştırmaların ve endüstriyel uygulamaların temel dinamiklerinden biri hâline gelmiştir. Ancak pek çok alanda gerçek dünyanın verisine erişim; mahremiyet kısıtları, yasal düzenlemeler, etik kaygılar, dengesiz sınıf dağılımları ve yüksek toplama maliyetleri gibi nedenlerle ciddi biçimde sınırlanmaktadır. Özellikle sağlık hizmetleri, finansal işlemler, siber güvenlik analizi ve otonom sistemler gibi kritik sektörlerde veri paylaşımı çoğu zaman mümkün değildir. Bu durum, makine öğrenimi modellerinin eğitilmesini güçleştirmekte, araştırmaların ilerlemesini yavaşlatmakta ve kurumlar arası iş birliğini kısıtlayan yapısal engeller ortaya çıkarmaktadır (Goyal & Mahmoud, 2024).

¹ Dr. Öğretim Üyesi, Kocaeli Üniversitesi, Yazılım Mühendisliği, Orcid: 0000-0001-5219-5397

² Kocaeli Üniversitesi, Yazılım Mühendisliği, Orcid: 0009-0005-3964-5310

Bu bağlamda sentetik veri üretimi, gerçek verinin istatistiksel özelliklerini koruyan ancak kişisel veya kurumsal gizliliği ihlâl etmeyen alternatif bir çözüm olarak giderek önem kazanmaktadır. Sentetik veri, veri yetersizliği, gizlilik gereksinimleri ve paylaşım engelleri gibi problemleri ortadan kaldırarak araştırmacılara esneklik sağlamakta; model geliştirme süreçlerini daha erişilebilir, güvenli ve ölçeklenebilir hâle getirmektedir (Chen, Lu, Chen, Williamson, & Mahmood, 2021). Bununla birlikte, özellikle tablo tipi (tabular) veriler—hem kategorik hem sürekli değişkenleri bir arada barındırdığı, çok modlu dağılımlar ve karmaşık değişken ilişkileri içerdiği için—sentetik üretimi en zor veri türlerinden biri olarak kabul edilmektedir (Xu, Skoularidou, Cuesta-Infante, & Veeramachaneni, 2019).

Geçmişte karar ağaçları, Bayesian ağları ve copula tabanlı modeller gibi istatistiksel yöntemler tabular veri için yaygın şekilde kullanılmıştır. Bu yöntemlerde her bir sütun bağımsız bir rastgele değişken olarak ele alınmış ve değişkenler arası ortak dağılımın modellenmesi hedeflenmiştir. Ancak bu geleneksel teknikler, varsaydıkları dağılım şekilleri ve getirdikleri yapısal kısıtlar nedeniyle karmaşık, doğrusal olmayan veya yüksek boyutlu ilişkileri temsil etmekte yetersiz kalmış; sonuç olarak ürettikleri sentetik veriler hem gerçekçilik hem de istatistiksel bütünlük açısından sınırlı kalmıştır (Miletic & Sariyar, 2024).

Derin öğrenme tabanlı üretken modellerin ortaya çıkışı, sentetik veri üretiminde yeni bir paradigma oluşturmuştur. Özellikle Generative Adversarial Networks (GAN) (Park et al., 2018), Variational Autoencoder (VAE) (Apellániz, Parras, & Zazo, 2024) türevleri ve daha yakın dönemde geliştirilen difüzyon modelleri (Hengrui Zhang et al., 2024), veri dağılımını herhangi bir belirli fonksiyonel forma bağlı olmaksızın uçtan uca öğrenebilme yeteneği sayesinde tabular verinin karmaşık yapısını çok daha başarılı şekilde yakalayabilmektedir. Bu modeller, değişkenler arası ilişkileri, çok

modlu dağılımları, dengesiz sınıfları ve yüksek boyutlu yapıların nüanslarını temsil ederek daha gerçekçi ve daha faydalı sentetik örnekler üretme potansiyeline sahiptir.

Bu çalışma, derin öğrenme tabanlı sentetik veri üretimi yaklaşımlarını kapsamlı biçimde incelemeyi; klasik istatistiksel yöntemler ile modern üretken modelleri karşılaştırmayı; tabular veriye özgü zorlukları ele alarak güncel çözümlerin güçlü ve zayıf yönlerini tartışmayı amaçlamaktadır. Nihai hedef, gizliliği koruyan, istatistiksel olarak tutarlı, yüksek kullanım değerine sahip ve pratik veri analiz süreçlerini destekleyen sentetik verilerin nasıl üretilebileceğine dair sistematik bir çerçeve sunmaktır.

Sentetik Veri Üretiminin Teorik Temelleri ve Derin Öğrenme Yaklaşımları

Sentetik veri üretimi, veri gizliliği, veri dengesizliği ve etik kısıtlar nedeniyle gerçek veri erişiminin zorlaştığı günümüz veri yönetimi ortamında kritik bir araştırma alanı hâline gelmiştir. Bu bölüm, sentetik veri üretimini mümkün kılan temel teorik ilkeleri inceleyerek modelleme yaklaşımlarının matematiksel ve istatistiksel arka planını açıklamayı amaçlamaktadır. Olasılık dağılımlarının temsilinden latent uzay kavramına, veri bağımlılıklarının modellenmesinden örnekleme prensiplerine kadar uzanan bu temeller hem klasik yöntemlerin hem de güncel derin öğrenme tabanlı yaklaşımların anlaşılması için gereklidir.

Bölümün devamında, GAN, VAE ve son dönemde öne çıkan difüzyon modelleri gibi modern üretken yöntemler ayrıntılı biçimde

ele alınacaktır. Bu çerçevede her bir yöntemin tabular veri üzerindeki performansı, öğrenme kapasitesi, avantajları, sınırlılıkları ve kullanım senaryoları tartışılacaktır.

Tabular Verinin Yapısal Özellikleri

Tablo tipi (tabular) veriler; sürekli, kategorik, binary ve ordinal olmak üzere farklı türlerde değişkenleri aynı yapıda bir araya getirebilen heterojen veri biçimleridir. Bu veri türünde her bir sütun bağımsız bir özelliği, her bir satır ise bir gözlemi temsil eder. Ancak tabular veriyi sentetik olarak üretmeyi zorlaştıran temel unsur, bu heterojen özelliklerin istatistiksel olarak birbirleriyle ilişkili olması ve çoğu zaman karmaşık bağımlılık yapıları sergilemesidir.

Sürekli değişkenler, normal dağılımdan uzak, çok modlu veya uzun kuyruklu dağılımlara sahip olabilirken; kategorik değişkenler sınıf dengesizliği, nadir kategori (rare category) veya yüksek kardinalite gibi sorunlar gösterebilir. Ek olarak, tablodaki değişkenler arasındaki ilişkiler çoğu zaman lineer olmayan, koşullu bağımlılıklar içeren ve klasik istatistiksel modellerle ifade edilmesi güç yapılardır. Örneğin bazı değişkenler yalnızca belirli alt gruplarda ilişki gösterirken, başka değişkenler karmaşık etkileşimlerle veri bütünlüğünü belirler (Fonseca & Bacao, 2023).

Bu özellikler bir arada değerlendirildiğinde, tabular verinin yalnızca dağılımlarının değil, değişkenler arası korelasyon ve bağımlılık yapılarını da koruyacak biçimde modellenmesi gerekmektedir. Dolayısıyla sentetik tabular veri üretimi hem heterojen veri tipleri hem de karmaşık çok değişkenli ilişki ağları nedeniyle diğer veri türlerine kıyasla daha güç bir problem olarak karşımıza çıkmaktadır (Manousakas, Sergi, & Aydoğru, n.d.).

Geleneksel İstatistiksel Yaklaşımlar

Sentetik veri üretimi alanında derin öğrenme yöntemlerinin ortaya çıkışından önce, tabular verinin dağılımını modellemek

amacıyla çeşitli klasik istatistiksel yaklaşımlar geliştirilmiştir. Bu yöntemlerin temel prensibi, veri setindeki her bir sütunu ayrı bir rastgele değişken olarak ele almak ve bu değişkenler arasındaki bağımlılık yapılarını parametrik ya da yarı-parametrik modellerle tanımlamaktır. Karar ağacı tabanlı modeller, Bayes ağları ve copula temelli yaklaşımlar, uzun süre boyunca bu amaçla en çok kullanılan yöntemler arasında yer almıştır. Ancak bu teknikler, özellikle yüksek boyutlu, heterojen ve karmaşık bağımlılıklar içeren tabular veri kümelerinde önemli sınırlılıklar göstermiş; gerçek veriyi tam olarak taklit etmede yeterli esneklik sunamamıştır (Xu et al., 2019). Aşağıdaki alt başlıklarda, geleneksel yöntemlerin temel çalışma mantıkları ve kısıtları ele alınmaktadır.

Karar Ağacı Tabanlı Modeller


Karar ağacı tabanlı yöntemler, tabular verinin yapısını modellemek için kullanılan en eski ve en yaygın istatistiksel yaklaşımlardan biridir. Bu modeller, veri uzayını ardışık bölmelere ayırarak her bir alt bölgede nispeten homojen dağılımlar oluşturmayı hedefler (Peng & Hanke, n.d.). Temel fikir, hedef değişkeni veya değişkenler arasındaki koşullu ilişkileri en iyi açıklayan bölme noktalarını seçerek veriyi hiyerarşik bir yapı hâline getirmektir. Aşağıdaki şekil 1 de karar ağacı tabanlı sentetik veri üretim sürecinin genel akışı gösterilmiştir.

Şema, giriş değişkenlerinin karar ağacı bölme noktalarına göre ayrılması ve yaprak düğümlerde koşullu dağılımlardan örnekleme yapılarak sentetik verilerin üretilmesi sürecini göstermektedir. Sentetik veri üretimi bağlamında karar ağaçları genellikle iki şekilde kullanılmıştır:

1. Her değişken için koşullu dağılımı tahmin etmek amacıyla ağaç modellerinin kullanılması

2. Tüm veri setinin yapısını yakalamak için rastgele orman veya hibrit tabanlı yaklaşımlarla çoklu ağaç yapılarının bir araya getirilmesi.

Şekil 1. Karar ağacı tabanlı sentetik tabular veri üretim sürecinin akış şeması.



Özellikle CART (Classification and Regression Trees) (Deconinck, Hancock, Coomans, Massart, & Vander Heyden, 2005) ve Random Forest gibi yöntemler, belirli değişkenlerin diğerlerine koşullu bağımlılıklarını yakalamada başarılıdır. Ancak bu yöntemler, verideki karmaşık çok değişkenli etkileşimleri tam olarak öğrenmekte sınırlı kalır; çünkü bölme işlemi çoğunlukla eksen hizalıdır ve değişkenler arasındaki doğrusal olmayan ilişkileri temsil etmekte yetersizdir.

Bir diğer önemli sınırlılık ise, karar ağacı modellerinin her yaprağı bağımsız bir dağılım varsayımıyla üretmesi nedeniyle, veri setinin genel korelasyon yapısını korumakta yetersiz kalmasıdır. Üretilen sentetik örnekler çoğu zaman gerçek veri dağılımına yakın olsa da özellikle yüksek boyutlu veri kümelerinde varyans çökmesi, yapay örneklerin birbirine fazla benzemesi veya marjinal dağılımların bozulması gibi sorunlar ortaya çıkabilmektedir.

Bu nedenlerle karar ağacı tabanlı modeller, sentetik tabular veri üretiminde anlaşılır ve uygulanabilir olmaları bakımından avantaj sağlasa da derin öğrenme tabanlı üretken modellerin sunduğu esnekliği ve çok değişkenli bağımlılıkları yakalama kapasitesini sağlayamamaktadır.

Bayes Ağları

Bayes ağları, değişkenler arasındaki koşullu bağımlılıkları ve olasılık ilişkilerini modellemek için kullanılan grafik tabanlı istatistiksel yaklaşımlardır. Bu ağlar, her bir düğümün bir değişkeni, düğümler arasındaki yönlü kenarların ise değişkenler arasındaki koşullu olasılık ilişkilerini temsil ettiği yönlendirilmiş döngüsel olmayan grafikler (DAG) kullanır (Cai, Huang, & Xie, 2017). Bayes ağları, tabular veri üzerinde değişkenler arası karmaşık ilişkileri yakalamak ve yeni veri örnekleri üretmek için yaygın olarak uygulanmıştır. Özellikle sınıf dengesizliği, eksik veri ve veri gürültüsü gibi sorunlar karşısında, ağın koşullu olasılık tablosu üzerinden örnekleme yapılarak gerçekçi sentetik veriler üretilebilir.

Klasik istatistiksel yöntemlerin aksine, Bayes ağları değişkenler arasındaki bağımlılıkları açık bir biçimde modelleme ve veriye dayalı olarak güncelleme avantajı sağlar. Ancak bu yöntemler, değişken sayısı arttıkça ağ yapısının öğrenilmesi ve olasılık tablosunun yönetimi açısından hesaplama maliyeti ve karmaşıklık sorunlarıyla karşılaşabilir. Yüksek boyutlu ve heterojen tabular veri setlerinde, karmaşık bağımlılık yapılarını tam olarak yakalamak genellikle zordur; bu da sentetik veri üretiminde sınırlılıklar doğurabilir.

Copula Temelli Modeller

Copula temelli yaklaşımlar, tabular verideki değişkenler arasındaki bağımlılık yapılarını modellemek ve farklı marjinal dağılımları bir araya getirerek çok değişkenli dağılımlar oluşturmak için kullanılan istatistiksel yöntemlerdir. Copula fonksiyonları, her

bir deęiřkenin marjinal daęılımını ayrı ayrı tanımlayabilme ve deęiřkenler arasındaki baęımlılıkları kopula fonksiyonları ile ifade etme esneklięi sunar (Li, Zhao, & Fu, 2020). Bu özellik, heterojen veri tiplerinin bir arada bulunduęu tabular veri kümelerinde sentetik veri üretimi için önemli bir avantaj sağlar.

Copula temelli modeller, özellikle deęiřkenler arasındaki lineer olmayan ve karmařık korelasyon yapılarını yakalamada kullanılır. Örneęin, finansal risk modellemesinde farklı varlık sınıfları arasındaki baęımlılıkları veya biyomedikal veride klinik göstergeler arasındaki iliřkileri modellemek için tercih edilir. Ancak, bu modellerin etkinlięi büyük ölçüde doęru baęımlılık yapısını ve uygun copula tipini seçmeye baęlıdır. Yüksek boyutlu veri setlerinde modelin parametrik karmařıklıęı ve örnekleme süreci hesaplama açısından zorluklar yaratabilir.

Geleneksel İstatistiksel Yaklaşımların Kısıtlamaları

Geleneksel istatistiksel yöntemler uzun yıllar boyunca tabular verinin daęılımını modellemek için temel araçlar olarak kullanılsa da modern veri bilimi uygulamalarının gerektirdięi esneklik ve ifade gücünü çoęu durumda karşılayamamaktadır. Bu tekniklerin en önemli sınırlılıklarından biri hesaplama maliyetidir. Özellikle Bayes aęları ve copula temelli modeller gibi yöntemlerde deęiřkenler arasındaki olası baęımlılık yapılarını doęru biçimde temsil etmek, deęiřken sayısı arttıkça hesaplama açısından son derece pahalı hâle gelir. Çok boyutlu copula modelleri, deęiřken sayısıyla birlikte üstel biçimde karmařıklařan bir baęımlılık uzayı gerektirir ve bu durum pratik uygulamalarda ciddi performans sorunlarına yol açabilir.

Bir dięer temel sınırlılık, yöntemlerin esneklik kapasitesidir. Klasik istatistiksel yaklaşımlar çoęu zaman belirli bir daęılım ailesini (örneęin Gaussian copula veya eksponansiyel aile daęılımları) varsayarak çalışır; bu durum gerçek dünyada sıklıkla

karşılaşılan çok modlu, karmaşık yapılı dağılımların doğru şekilde temsil edilmesini güçleştirir. Ayrıca kategorik değişkenlerin, özellikle yüksek kardinaliteli veya nadir kategori içeren durumlarda, doğal biçimde modellenememesi bu yöntemlerin tabular veri için kullanımını daha da sınırlamaktadır.

Tüm bunlara ek olarak, geleneksel modellerin değişkenler arasındaki non-lineer ve koşullu bağımlılıkları yakalama kapasitesi sınırlıdır. Karar ağaçları belirli non-lineer ilişkileri temsil edebilse de karmaşık etkileşim yapıları sınırlı derinlikte kaybolur; Bayes ağları ise bağımlılık yönlerinin önceden belirlenmesini gerektirdiğinden çok değişkenli non-lineer ilişkileri temsil etmede yetersiz kalabilir. Copula tabanlı modeller, bağımlılık yapısını soyutlayabilseler bile seçilen copula fonksiyonunun temsil gücü gerçek veri ilişkilerinin karmaşıklığını çoğu zaman karşılamaz.

Bu nedenlerle geleneksel yöntemlerle üretilen sentetik veriler, gerçek veri dağılımındaki ince yapısal özellikleri çoğu durumda yeterince yakalayamaz ve elde edilen verinin hem gerçekçilik düzeyi hem de pratik kullanım değeri sınırlı kalır.

Derin Öğrenme Tabanlı Üretken Modeller

Derin öğrenme tabanlı üretken (generative) modeller, yüksek boyutlu ve karmaşık yapıya sahip veri kümelerinde gerçekçi örnekler üretme kapasitesi sayesinde sentetik veri üretiminin temel yöntemleri hâline gelmiştir. Geleneksel istatistiksel yaklaşımların çoğu, doğrusal olmayan ilişkileri, heterojen veri tiplerini ve çok değişkenli bağımlılık yapılarını modellemekte sınırlı kalırken, derin öğrenme mimarileri bu karmaşık ilişkileri temsil edecek esnek fonksiyonel yapılar sunar (Goodfellow et al., 2020). Bu sayede, tabular veride sık görülen multimodal dağılımlar, eksik değer yapıları, kategorik–sayısal değişken kombinasyonları ve yüksek boyutluluk gibi zorluklar daha etkili bir şekilde ele alınabilmektedir.

Bu bölümde, modern üretken model aileleri ve tabular veri üretimi için geliştirilen güncel yaklaşımlar ayrıntılı biçimde incelenecektir.

Varyasyonel Otodolayıcılar (Variational Autoencoders, VAE)

VAE modelleri, olasılıksal üretken modelleme yaklaşımını derin öğrenme ile birleştiren temel yöntemlerden biridir. Bir VAE, veriyi daha düşük boyutlu bir latent uzaya haritalayan bir enkoder ağı ile bu temsilden yeniden örnek üretmeyi amaçlayan bir dekoder ağı olmak üzere iki temel bileşenden oluşur (Wang & Nguyen, 2025). Enkoder ağı, her bir gözlem için tek bir nokta yerine, latent uzaydaki temsilin bir dağılım tarafından tanımlandığını varsayar; genellikle bu dağılım Gaussian olarak modellenir ve ortalama (μ) ile varyans (σ^2) parametreleri üretilir. Bu sayede model, verideki belirsizliği ve çeşitliliği latent uzayda açıkça temsil edebilir.

VAE'ler, sentetik veri üretiminde önemli avantajlar sunar. Sürekli ve düzenli bir latent uzay oluşturarak interpolasyon ve yeni veri üretimi için uygun bir yapı sağlar. Olasılıksal öğrenme yapısı, veri dağılımını geniş bir şekilde temsil eder ve eğitim süreci GAN'lara kıyasla daha kararludur.

Buna karşın VAE'lerin bazı sınırlılıkları da vardır. Üretilen örnekler genellikle aşırı yumuşama (over smoothing) gösterir ve gerçek veriye kıyasla daha bulanık, ortalamaya yakın hale gelir. Karmaşık ve çok modlu dağılımları tam temsil etmekte zorlanabilirler ve latent uzayın Gaussian dağılımına zorlanması, bazı karmaşık tabular veri yapılarında kısıtlayıcı olabilir. Standart VAE'ler ayrıca kategorik değişkenlerin ayrık doğasını yakalamakta güçlük çekebilir.

Genel olarak, VAE'ler güçlü ve esnek bir Üretken model sunarken, veri yapısına ve uygulama gereksinimlerine bağlı olarak sınırlamaları da göz önünde bulundurulmalıdır.

Üretken Çekişmeli Ağlar (Generative Adversarial Networks, GAN)

GAN, üretken modelleme alanında önemli bir yaklaşım olarak öne çıkar ve temel olarak jeneratör ile diskriminatör olmak üzere iki karşıt ağdan oluşur. Jeneratör, rastgele gürültüden gerçekçi veri örnekleri üretmeye çalışırken, diskriminatör ise bu örneklerin gerçek mi yoksa sentetik mi olduğunu ayırt etmeye çalışır. Bu karşılıklı rekabet süreci, modelin veri dağılımını öğrenmesini sağlar (Karthika & Durgadevi, 2021).

GAN'ların en bilinen sınırlamalarından biri, mod çökmesi (mode collapse) problemidir; bu durumda jeneratör, veri dağılımının yalnızca sınırlı bir kısmını öğrenir ve çeşitlilik düşük sentetik örnekler üretir. Özellikle tabular verilerde klasik GAN'lar yeterince etkili olamayabilir; bu nedenle CTGAN ve TVAE gibi tabular veri için özel olarak geliştirilmiş varyantlar kullanılır. Bu modeller hem sayısal hem de kategorik değişkenleri içeren heterojen veri yapıları üzerinde başarılı performans göstermektedir.

Difüzyon Modelleri

Difüzyon modelleri, son yıllarda üretken modelleme alanında öne çıkan yaklaşımlardan biri olarak dikkat çekmekte olup, veri dağılımını öğrenmek ve yüksek kaliteli örnekler üretmek için istatistiksel ve fiziksel süreçlerden yararlanmaktadır. Bu modellerin temel mantığı, veriyi kademeli olarak gürültüyle bozmak ve ardından bu süreci tersine çevirerek orijinal veri dağılımını yeniden oluşturmaktır. Difüzyon süreci, ileri ve ters difüzyon olmak üzere iki aşamada gerçekleşir. İleri difüzyon aşamasında gerçek veri her adımda gürültü eklenerek sistematik biçimde bozulur ve süreç sonunda tamamen rastgele gürültüye dönüşür (Croitoru, Hondru, Ionescu, & Shah, 2023).

Ters difüzyon aşamasında ise model, bu gürültülü veriyi adım adım temizleyerek başlangıçtaki veri dağılımına benzer

örnekler üretir. Bu iki yönlü mekanizma, özellikle yüksek boyutlu veri ve görüntü üretiminde oldukça etkili sonuçlar vermektedir. Modellerin bu yapısı, veri dağılımının karmaşık yapısını doğal bir süreçle yakalamalarını sağlar.

Difüzyon modellerinin önemli bir uzantısı olan skor tabanlı yaklaşımlar ise tersine çevirme sürecini farklı bir perspektiften ele alır. Bu yöntemde model, her adımda veri noktalarının olasılık yoğunluğu gradyanını (skor) tahmin ederek gürültülü veriyi temizler. Böylece veri dağılımının geometrik özellikleri daha doğru temsil edilir ve üretilen örnekler daha gerçekçi hale gelir.

Tabular Veri İçin Özel Modeller Ve Hibrit Yaklaşımlar

Tabular veriler, sürekli ve kategorik özelliklerin bir arada bulunması, çok modlu dağılımlar ve dengesiz sınıf yapıları gibi nedenlerle üretken modelleme açısından önemli zorluklar içerir. Bu nedenlerle klasik üretken modeller, görüntü veya metin gibi tek tip veri modlarından farklı olarak yapısal veride doğrudan uygulanamayabilir. Son yıllarda bu zorlukları ele alan ve tabular veri için özelleştirilmiş mimariler geliştirilmiştir. Bu mimariler, GAN tabanlı modeller, VAE tabanlı modeller, skor tabanlı modeller ve akış tabanlı yaklaşımlar olmak üzere dört ana kategori altında toplanabilir. Aşağıda bu yöntemler kısaca açıklanmakta ve ilgili akademik literatür örnekleri ile desteklenmektedir (Wang, Chukova, Simpson, & Nguyen, 2024).

GAN Tabanlı Modeller

GAN tabanlı modeller, tabular veri dağılımını doğrudan öğrenmek ve yeni örnekler üretmek için jeneratör–ayırıcı (generator–discriminator) yapısını kullanır. Bu yaklaşımlar, verinin karmaşık istatistiksel yapısını taklit edebilme yeteneği ile öne çıkar.

CTGAN (Conditional Tabular GAN)

Sürekli ve kategorik özelliklerin birlikte bulunması nedeniyle karmaşık ve çok modlu dağılımlar sergileyen tabular verinin doğru biçimde modellenebilmesi için CTGAN, moda özgü normalleştirme (mode-specific normalization) adı verilen özel bir normalizasyon stratejisi kullanır. Bu yöntem, her bir sürekli değişkenin dağılımında yer alan potansiyel modları istatistiksel olarak belirleyerek, her modu kendi lokal yapısına uygun şekilde ölçeklendirilmiş bir temsil alanına dönüştürür. Böylece model, hem veri içindeki çoklu modları kaybetmeden öğrenebilir hem de karmaşık dağılım biçimlerini jeneratör üzerinde daha istikrarlı biçimde yakalayabilir. Bu yaklaşım, özellikle geleneksel normalizasyon tekniklerinin başarısız olduğu çok modlu tabular veri senaryolarında CTGAN’e belirgin bir avantaj sağlamaktadır (Xu et al., 2019).

CopulaGAN

CopulaGAN, SDV (Synthetic Data Vault) kütüphanesinde sunulan CTGAN modelinin geliştirilmiş bir versiyonu olup, tabular verilerdeki çok değişkenli bağımlılık yapılarını daha doğru temsil edebilmek için kopula teorisini GAN’larla birleştirir. Model, değişkenler arasındaki karmaşık korelasyonları açıkça modelleyen bir kopula bileşeni ile sentetik veri üretim sürecini yönlendiren bir üretici–ayırıcı (generator–discriminator) mimarisini entegre şekilde kullanır. Bu sayede geleneksel GAN tabanlı yöntemlerin çoğu zaman yakalayamadığı yüksek boyutlu bağımlılık ilişkilerini koruyarak, orijinal veri kümesinin istatistiksel özelliklerine daha yakın sentetik örnekler üretilebilir. CopulaGAN, özellikle finans, sağlık ve sosyal bilimler gibi değişkenler arası ilişkilerin kritik önem taşıdığı alanlarda, gizlilik koruma gereksinimleri ile analitik doğruluğu dengeleyen güçlü bir sentetik veri üretim aracı olarak öne çıkmaktadır (Harshini Sivakami, Nivedhidha, Ramkumar, & Emil Selvan, 2023).

GAN tabanlı yöntemlerin avantajı örnekleme hızları ve yüksek örnek üretim kalitesi olmasıdır; dezavantajı ise eğitimde stabilitenin bazen zor olmasıdır (Wang et al., 2024).

VAE Tabanlı Modeller

VAE tabanlı modeller, veriyi olasılık dağılımları üzerinden kodlayıp latent temsilde öğrenip yeniden üretir; bu da veri dağılımı hakkında daha iyi istatistiksel kontrol sağlar.

TVAE (Tabular VAE)

Tabular verilerin heterojen yapısını modellemek ve sentetik veri üretmek için tasarlanmış VAE tabanlı üretken modeldir. TVAЕ, enkoder-dekoder mimarisi kullanarak her satırı düşük boyutlu olasılık dağılımı üzerine kodlar ve latent uzayda örnekleme mümkün kılar; ardından dekoder bu latent temsillerden yeni tabular örnekler üretir. Bu olasılıksal yapı, VAE'nin latent uzay düzenleme ve yeniden örnekleme yeteneklerini kullanarak karmaşık veri ilişkilerini öğrenmesine olanak tanır ve hem sürekli hem de kategorik değişkenlerdeki dağılım özelliklerini daha iyi yakalamayı hedefler (Wang & Nguyen, 2025).

Hibrit ve Gelişmiş Modeller

Hibrit modeller, tek bir üretken yaklaşımın sınırlılıklarını aşmak ve tabular verinin karmaşık yapısını daha doğru temsil etmek amacıyla birden fazla modelleme paradigmasını bir araya getiren yaklaşımlar olarak öne çıkar. Bu tür modellerde çoğunlukla VAE'nin istatistiksel olarak sağlam ve düzenli bir latent uzay oluşturma kapasitesi, GAN'ın yüksek doğrulukta ve gerçekçi örnek üretme becerisiyle bütünleştirilir. VAE bileşeni, veriyi düşük boyutlu ve sürekli bir latent temsile dönüştürürken, GAN bu temsilleri daha keskin, daha ayrıntılı ve orijinal dağılıma daha yakın sentetik örneklerle dönüştürür. Benzer biçimde, VAE-Diffusion gibi modellerde VAE latent düzenlemeyi sağlarken, difüzyon bileşeni

çok modlu dağılımları daha istikrarlı biçimde yeniden oluşturarak genel üretim kalitesini artırır. Bu hibrit yapıların temel avantajı, hem istatistiksel tutarlılığı hem de yüksek çeşitliliği aynı anda sunarak özellikle tıbbi veriler gibi karmaşık ve dengesiz dağılımlar içeren tabular veri setleri için güçlü bir alternatif üretmesidir.

Bu yaklaşımın önemli örneklerinden biri olan TabTransGAN, GAN mimarisini Transformer katmanlarıyla entegre ederek tabular verideki uzun menzilli bağımlılıkların daha etkili biçimde modellenmesini sağlar. Transformer'ın dikkat mekanizması sütunlar arasındaki karmaşık ilişkileri öğrenirken, GAN bileşeni yüksek kaliteli örnek üretimini mümkün kılar. Bu birleşim, özellikle çok boyutlu ve korelasyon yoğun veri setlerinde geleneksel GAN tabanlı yöntemlere kıyasla daha dengeli, daha çeşitli ve analitik olarak daha kullanılabilir sentetik veri üretimi sunar. Literatürde TabTransGAN'ın bu avantajlarını ortaya koyan çalışmalar, hibrit mimarilerin tabular veri üretiminde yeni bir standart oluşturma potansiyeline sahip olduğunu göstermektedir (Hanbing Zhang et al., 2025).

Hibrit modellere bir diğer örnek, T-VAE-GAN yaklaşımıdır. Bu modelde VAE, veri dağılımının daha genel ve düzgün bir temsilini elde etmek için kullanılırken, GAN bileşeni bu temsil üzerinden daha gerçekçi örnekler üretir. Bu iki yapının hiyerarşik olarak birleştirilmesi hem dağılımın istatistiksel özelliklerinin korunmasını hem de örneklerin görsel ve yapısal kalite bakımından zenginleşmesini sağlar. Literatürde bu tür birleşik modellerin özellikle yüksek kaliteli örnek üretimi gerektiren senaryolarda etkili olduğu gösterilmiştir (Anshelevich & Katz, n.d.).

Hibrit modeller içerisinde yer alan önemli bir diğer yaklaşım ise VAE-GMM tabanlı hibrit tasarımlardır. Bu tür modellerde VAE, veriyi latent uzaya kodlarken, bu latent uzay tek bir Gaussian dağılımı yerine Gaussian Mixture Model (özellikle Bayesian GMM) ile daha esnek ve çok modlu bir yapıda modellenir. Böylece

karmaşık ve çok modlu tabular veri dağılımlarının temsili güçlendirilir; VAE'nin düzenli latent uzay oluşturma avantajı GMM'nin çok modlu dağılımları yakalama kapasitesiyle birleşir. Bu entegre yapı, tek başına VAE veya tek başına istatistiksel yöntemle elde edilmesi zor olan yüksek kalitede sentetik veri üretimini mümkün kılar (Apellániz et al., 2024).

Bu bölümde ele alınan GAN, VAE, difüzyon ve hibrit tabanlı yaklaşımlar, tabular veri sentezinin giderek derinleşen metodolojik çerçevesini ortaya koymaktadır. Her bir model ailesi, tabular verinin heterojen yapısından kaynaklanan özgül zorluklara yönelik farklı çözüm stratejileri sunmakta; bazıları çok modlu dağılımların yakalanmasında, bazıları istatistiksel tutarlılığın korunmasında, bazıları ise yüksek kaliteli ve çeşitli örnekler üretmede öne çıkmaktadır. Bununla birlikte hiçbir yaklaşım tek başına tüm veri türleri ve kullanım senaryoları için ideal bir çözüm sunmamaktadır; bu durum hibrit yöntemlerin yükselişini hızlandırmakta ve gelecekteki araştırmaların çoklu mimarilerin tamamlayıcı yönlerini daha verimli biçimde bütünleştirmeye odaklanacağını göstermektedir. Genel olarak değerlendirildiğinde, tabular veri için geliştirilen modern üretken modeller, veri gizliliği, veri paylaşımı ve veri yetersizliği gibi giderek daha kritik hâle gelen problemlere güçlü ve esnek çözümler sunmakta hem akademik araştırmalar hem de gerçek dünya uygulamaları için yeni imkânlar yaratmaktadır.

Kaynakça

Anshelevich, D., & Katz, G. (n.d.). Generating Synthetic Tabular Data Using a VAE-GAN Architecture Generating Synthetic Tabular Data Using a VAE-GAN Architecture A R T I C L E I N F O. Retrieved from <https://ssrn.com/abstract=4902016>

Apellániz, P. A., Parras, J., & Zazo, S. (2024). An improved tabular data generator with VAE-GMM integration. Retrieved from <http://arxiv.org/abs/2404.08434>

Cai, B., Huang, L., & Xie, M. (2017). Bayesian Networks in Fault Diagnosis. *IEEE Transactions on Industrial Informatics*, 13(5), 2227–2240. doi:10.1109/TII.2017.2695583

Chen, R. J., Lu, M. Y., Chen, T. Y., Williamson, D. F. K., & Mahmood, F. (2021, June 1). Synthetic data in machine learning for medicine and healthcare. *Nature Biomedical Engineering*. Nature Research. doi:10.1038/s41551-021-00751-8

Croitoru, F. A., Hondru, V., Ionescu, R. T., & Shah, M. (2023). Diffusion Models in Vision: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(9), 10850–10869. doi:10.1109/TPAMI.2023.3261988

Deconinck, E., Hancock, T., Coomans, D., Massart, D. L., & Vander Heyden, Y. (2005). Classification of drugs in absorption classes using the classification and regression trees (CART) methodology. *Journal of Pharmaceutical and Biomedical Analysis*, 39(1–2), 91–103. doi:10.1016/j.jpba.2005.03.008

Fonseca, J., & Bacao, F. (2023). Tabular and latent space synthetic data generation: a literature review. *Journal of Big Data*, 10(1). doi:10.1186/s40537-023-00792-7

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139–144. doi:10.1145/3422622

Goyal, M., & Mahmoud, Q. H. (2024, September 1). A Systematic Review of Synthetic Data Generation Techniques Using Generative AI. *Electronics* (Switzerland). Multidisciplinary Digital Publishing Institute (MDPI). doi:10.3390/electronics13173509

Harshini Sivakami, V., Nivedhidha, M., Ramkumar, M. P., & Emil Selvan, G. S. R. (2023). CopulaGAN Boosted Random Forest based Network Intrusion Detection System for Hospital Network Infrastructure. In 2023 14th International Conference on Computing Communication and Networking Technologies, ICCCNT 2023. Institute of Electrical and Electronics Engineers Inc. doi:10.1109/ICCCNT56998.2023.10306951

Jamotton, C., & Hainaut, D. (2024). Variational AutoEncoder for synthetic insurance data. *Intelligent Systems with Applications*, 24. doi:10.1016/j.iswa.2024.200455

Karthika, S., & Durgadevi, M. (2021). Generative Adversarial Network (GAN): A general review on different variants of GAN and applications. In *Proceedings of the 6th International Conference on Communication and Electronics Systems, ICCES 2021*. Institute of Electrical and Electronics Engineers Inc. doi:10.1109/ICCES51350.2021.9489160

Li, Z., Zhao, Y., & Fu, J. (2020). SynC: A Copula based Framework for Generating Synthetic Data from Aggregated Sources. In *IEEE International Conference on Data Mining Workshops, ICDMW* (Vol. 2020-November, pp. 571–578).

Manousakas, D., Sergi, S., & Aydıno, S. (n.d.). On the Usefulness of Synthetic Tabular Data Generation.

Miletic, M., & Sariyar, M. (2024). Challenges of Using Synthetic Data Generation Methods for Tabular Microdata. *Applied Sciences* (Switzerland), 14(14). doi:10.3390/app14145975

Park, N., Mohammadi, M., Gorde, K., Jajodia, S., Park, H., & Kim, Y. (2018). Data synthesis based on generative adversarial networks. In *Proceedings of the VLDB Endowment* (Vol. 11, pp. 1071–1083). Association for Computing Machinery. doi:10.14778/3231751.3231757

Peng, T., & Hanke, F. (n.d.). Towards a Synthetic Data Generator for Matching Decision Trees.

Wang, A. X., Chukova, S. S., Simpson, C. R., & Nguyen, B. P. (2024). Challenges and opportunities of generative models on tabular data. *Applied Soft Computing*, 166. doi:10.1016/j.asoc.2024.112223

Wang, A. X., & Nguyen, B. P. (2025). TTVAE: Transformer-based generative modeling for tabular data generation. *Artificial Intelligence*, 340. doi:10.1016/j.artint.2025.104292

Xu, L., Skoularidou, M., Cuesta-Infante, A., & Veeramachaneni, K. (2019). Modeling Tabular data using Conditional GAN. Retrieved from <http://arxiv.org/abs/1907.00503>

Zhang, Hanbing, Jing, Y., Zhang, F., Li, Z., Wang, X. S., Chen, Z., & Lv, C. (2025). TabTransGAN: A hybrid approach integrating GAN and transformer architectures for tabular data

synthesis. *Information Processing and Management*, 62(5).
doi:10.1016/j.ipm.2025.104220

Zhang, Hengrui, Zhang, J., Srinivasan, B., Shen, Z., Qin, X., Faloutsos, C., ... Karypis, G. (2024). Mixed-Type Tabular Data Synthesis with Score-based Diffusion in Latent Space. Retrieved from <http://arxiv.org/abs/2310.09656>

BÖLÜM 14

Valf Noktası Yükleme Etkisi Altında Ekonomik Yük Dağıtım Probleminin Gri Kurt Optimizasyon Algoritması ile Çözümü

Emine DENİZ ÖZ¹

Giriş

Teknoloji geliştikçe dünya üzerindeki elektrikli araç ve aletlerin kullanımı artmaktadır. Elektrikli araç ve aletlerin enerji tüketimi geçmiş yıllara oranla çok daha fazla artış göstermektedir. Bu artışlar elektrik enerji üretim sistemlerinin optimize edilmesini kritik hale getirmektedir. Literatürde enerji sistemlerinin daha ekonomik ve verimli kullanılması için Ekonomik Yük Dağıtım (EYD) problemine çözümler sunulmaktadır (Parouha & Das, 2016; Zou ve diğerleri, 2016).

EYD'nin amacı, sistemden istenilen elektrik gücünün minimum maliyetle ve yüksek güvenilirlikle karşılanmasını sağlamaktır. EYD problemleri ilk olarak klasik optimizasyon metotları ile çözülmüştür (Wood, Wollenberg & Sheblé, 2013). Lambda iterasyon gibi klasik yöntemler büyük sistemlerde yüksek hesaplama sürelerine ihtiyaç duymaktadır. Bu yüzden yapay sinir

¹ Arş. Gör, Kütahya Dumlupınar Üniversitesi, Bilgisayar Mühendisliği, Orcid: 0000-0003-0670-3578

ağları ile çözüm bulmaya çalışılmıştır (Saeed, 2019). Yapay sinir ağlarında öğrenme oranlarının doğru seçilememesinden dolayı iterasyon sayısı artmış ve çözüm süresi uzamıştır. Elektrik sistemlerinin daha basit olduğu zamanlarda Lagrange metodu (Lin ve diğerleri, 2023) ve Newton tabanlı çözücüler (Qin ve diğerleri, 2019) kararlı ve hesaplama maliyeti düşük çözüm hattı sunmuşlardır. Elektrik sistemleri karmaşıklaşmaya başladığında maliyet fonksiyonları doğrusallığını yitirmiştir. Doğrusal olmayan maliyet fonksiyonları için klasik optimizasyon yöntemleri yerine sezgisel optimizasyon yöntemleri kullanılmaya başlanmıştır (Yang, Hosseini & Gandomi, 2012).

Doğrusal olmayan çözüm uzayları için genetik algoritma, diferansiyel evrim (Noman & Iba, 2008), harmoni arama (Wang & Li, 2013) ve parçacık sürüsü (Mahor, Prasad & Rangnekar, 2009) gibi yöntemler daha iyi keşif-sömürü dengesi kurarak klasik optimizasyon yöntemlerinin yerine geçmiştir. Sezgisel optimizasyon algoritmaları genellikle çözüm uzayını ararken valf noktası gibi maliyete etki edecek bileşenleri göz ardı etmektedir. Valf noktası, maliyetin güce göre ani artış gösterdiği bölgedir. EYD problemleri valf noktası yüzünden doğrusal olmayan bir hale gelmektedir.

Bu çalışmada sezgisel optimizasyon algoritmalarından Gri Kurt Optimizasyon (Grey Wolf Optimization - GWO) algoritması kullanılarak bir keşif davranışı modelleneyecektir. GWO algoritmasının maliyet fonksiyonuna, valf noktası yükleme bileşenleri eklenerek dengeli bir keşif süreci oluşturulacaktır. Valf noktası yükleme bileşenlerinin maliyet fonksiyonuna eklenmesi, GWO'nun sürü davranışını daha hassas hale getirilmesi ve alfa-beta-delta yönetim optimizasyonu daha stabil yönetilmesini sağlayacaktır.

Ekonomik Yük Dağıtım Problemi

Elektrik sistemlerinde minimum üretim maliyeti, maksimum güvenilirlik ve güç rezervinin paylaşımı çok kritiktir (El-Keib, Ma & Hart, 2002). Elektrik enerjisinin ekonomik dağıtımı, üretimde kalite ve verimlilik için önemlidir. Üretim ünitelerinin güç toplamı, elektrik kayıplarına ve sistemin toplam yüküne bağlıdır. Bu yüzden operasyonel faaliyetler sırasında ekonomik yük dağıtımı, sistemin beklenen yüküne uyum sağlamalıdır.

Bir sistemdeki farklı birimler arasındaki güç yükünü minimum yakıt maliyeti ile karşılamak için birimlerin çıkış seviyelerinin optimizasyonuna ekonomik yük dağıtımı denir. EYD problemi, toplam yakıt maliyetini minimize ederek sistemdeki güç talebini ve iletim kayıplarını karşılar. Denklem 1’de verildiği üzere çalışan tüm birimlerin maliyet fonksiyonlarının toplamı sistemin toplam yakıt maliyetini verir.

$$F_T = \sum_{i=1}^N F_i(P_i) \quad \text{Denklem 1}$$

Birim i için maliyet fonksiyonu F_i , birimin güç çıkışı için P_i kullanılır. Her birim için $F_i(P_i)$ denklem 2’de verilen ikinci dereceden bir denklem ile ifade edilir.

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i \quad \text{Denklem 2}$$

Denklem 2’deki P_i , birimin minimum ve maksimum sınırları arasında olmalıdır ve a_i , b_i ve c maliyet katsayılarıdır. Klasik EYD problemleri maliyet fonksiyonunu dışbükey (convex) düzeyde ele almaktadır. Fakat gerçek dünyadaki santrallerde valflerin açılıp kapanması maliyet fonksiyonunu dışbükey olmayan (non-convex) bir yapıya taşır. Bu yüzden bu çalışmada Denklem 3’teki $F_i(P_i)$ eşitliği kullanılarak valf noktaları ele alınmıştır.

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i + |e_i \times \sin(f_i \times (P_i^{min} - P_i))| \quad \text{Denklem 3}$$

Valf noktası etkisini modelleyen katsayılar e_i ve f_i , i biriminin çıkış gücü P_i ve minimum üretim limiti P_i^{min} ile gösterilmektedir. EYD için toplam güç denklem 4'teki gibi talep edilen güç ile kayıp gücün toplamıdır.

$$\sum_{i=1}^N P_i = P_D + P_L \quad \text{Denklem 4}$$

Denklem 4'teki P_L sistemin toplam güç kayıplarıdır ve P_D ise sistemin toplam güç talebidir. Denklem 5'te sistemin toplam güç kayıp formülü verilmektedir.

$$P_L = \sum_i^N \sum_j^N B_{ij} P_i P_j + \sum_i^N B_{i0} P_i + B_{00} \quad \text{Denklem 5}$$

Denklem 5'teki P_i i. birimin ürettiği güç miktarını, P_j j. Birimin ürettiği güç miktarını göstermektedir. B-Katsayılarından B_{ij} , farklı birimlerin üretimlerinin birbirleriyle etkileşimi sonucu oluşan kayıpların kuadratik temsildir. B_{i0} , yük akış modellemesinden gelen lineer düzeltme terimidir. B_{00} ise sabit kayıp bileşenidir.

Gri Kurt Optimizasyon Algoritması

2014 yılında Mirjalili ve arkadaşları tarafından Gri kurt optimizasyon (GWO) algoritması önerilmiştir (Mirjalili ve diğerleri, 2014). Bu algoritma, gri kurtların sosyal hiyerarşisini, avlanma süreçlerini ve grup özelliklerini taklit eder.

Gri kurtlarda hiyerarşi α, β, γ ve ω gruplarından oluşur. α , baskın kurt olarak sürüyü yönetme kapasitesine sahiptir. Hiyerarşinin ikinci seviyesindeki β , karar verme ve diğer sürü

faaliyetlerinde α 'ya yardımcı olan ast kurtlardır. ω , en düşük rütbeli kurttur ve diğer tüm kurtlara boyun eğer.

Kurtlarda avlanma süreçleri ise avı takip etme, kovalama ve yaklaşma, av hareket etmeyi bırakana kadar takip etme, çevreleme ve avına saldırma aşamalarından oluşur.

GWO, çok boyutlu bir arama alanında hareket etmek için gri kurtların davranışına bakar. GWO'da α, β, γ ve ω kurtlarının konumları birbirinden farklı olarak kabul edilir ve avın kurtlara olan uzaklığı amaç fonksiyonunun değerini belirler. Her bir kurdun yinelemeler boyunca daha iyi bir konuma hareket etmesi ile en iyi çözümler kaydedilir. GWO'nun amacı en kısa yoldan ava ulaşmaktır. Kurtların hareketi keşif, kuşatma, avlanma ve sömürü aşamalarından oluşur.

Kurtlar keşif sürecinde birbirlerinden ayrılıp daha sonra saldırı için birleşirler. Kurtların birbirinden uzaklaşması için matematiksel olarak 1'de büyük ve -1'den küçük rastgele sayılar kullanılır. Avı aramak için ise rastgele ağırlık sağlayacak değer kullanılır. Keşif süreci GWO algoritmasında rastgele bir popülasyon oluşturur.

Kuşatma süreci α, β ve γ kurtların avı çevrelemek için konumlarını güncellemesi ile başlar. Denklem 6 ve 7, çevreleme davranışının matematiksel temsilini göstermektedir.

$$\vec{D} = |\vec{C} \cdot \vec{X_p}(t) - \vec{X}(t)| \quad \text{Denklem 6}$$

$$\vec{X}(t + 1) = \vec{X_p}(t) - \vec{A} \cdot \vec{D} \quad \text{Denklem 7}$$

t o anki iterasyonu, $\vec{A}$ ve $\vec{C}$ katsayı vektörlerini, $\vec{X_p}$ avın konum vektörünü, $\vec{X}$ ise kurdun konum vektörünü temsil etmektedir.

Avlanma aşamasında α kurtlar rehberlik eder, β ve γ kurtlar daha sonra katılır. α, β ve γ avın konumunu tahmin eder ve diğer kurtların avın etrafındaki konumları rastgele güncellenir.

Av hareket etmeyi bıraktığında kurtlar ava saldırır. Ava yaklaşmak matematiksel olarak modellendiğinde $[-2a, 2a]$ aralığında rastgele bir değer atanır. Yinelemeler boyunca a değeri azaltılır.

Bu çalışmada Gri kurt optimizasyon algoritması, denklem 8'deki amaç fonksiyonunu en aza indirmek için uygulandı.

$$f = \sum_{i=1}^N F_i(P_i) + q_1 \left(\text{abs} \left(\sum_{i=1}^N P_i - P_D - P_L \right) \right) \quad \text{Denklem 8}$$

Denklem 8'deki q_1 yük dengesine uymayan çözümleri cezalandırmak için kullanılır.

Nümerik Çalışma

Bu çalışmada valf noktasını dikkate alan GWO tasarlanmış ve çıkan sonuçlar Parçacık Sürü Optimizasyonu (Particle Swarm Optimization - PSO), Yapay arı koloni algoritması (Artificial Bee Colony – ABC), Ateş böceği algoritması (Firefly Algorithm) ve Guguk kuşu arama (Cuckoo Search) gibi optimizasyon algoritmaları ile kıyaslanmıştır. Çalışmada 2 farklı üretim sistemi ele alınmıştır: 3 üniteli üretim sistemi ve IEEE 30-Bus (6 üniteli) üretim sistemi.

3 Üniteli Test Sistemi

Algoritmanın doğruluğunu test etmek için ilk olarak küçük ölçekli bir test sistemi tablo 1'deki değerler ile oluşturuldu.

Tablo 1: 3 Üniteli Test Sistem Değerleri

Ünite	a	b	c	e	f	Pmin	Pmax
1	0.008	7.0	200	30	0.04	10	85
2	0.009	6.3	180	20	0.05	10	80
3	0.007	6.8	140	20	0.06	10	70

1. üretim biriminin maliyeti en yüksek 3. Üretim biriminin maliyeti en düşüktür. Algoritmanın yükü daha düşük maliyetli üretim birimine kaydırması beklenir.

IEEE 30-Bus (6 Üniteli) Test Sistemi

IEEE 30-Bus literatürde standart kıyaslama olarak kabul edilir. 3 üniteli sisteme göre çok daha büyük güç talepleri için kullanılır. Tablo 2’de 6 üniteli test sisteminin maliyet katsayıları ve üretim limitleri verilmiştir.

Tablo 2: 6 Üniteli Test Sistem Değerleri


Ünite	a	b	c	e	f	Pmin	Pmax
1	0.00375	2.00	0	50	0.06	50	200
2	0.01750	1.75	0	40	0.07	20	80
3	0.06250	1.00	0	20	0.08	15	50
4	0.00834	3.25	0	15	0.09	10	35
5	0.02500	3.00	0	10	0.09	10	30
6	0.02500	3.00	0	10	0.09	12	40

6 üniteli test sistemi gerçek bir elektrik şebekesinin basitleştirilmiş halidir. Daha yüksek boyutlu problemlerde bu test sistemi kullanılmalıdır.

GWO Uygulaması

Bu çalışmada GWO algoritması ile valf noktası etkisini de içeren EYD probleminin çözümü gösterilmiştir. Şekil 1’de GWO algoritması parametrelerin tanımlanmasıyla başlatılıp, rastgele popülasyonunun üretilmesiyle tetiklenmiştir. Daha sonra kurtların maliyet fonksiyonu Denklem 8 kullanılarak hesaplanmıştır. Maliyet fonksiyonlarına göre liderlik edecek α, β ve γ kurtları sıralanır. Yineleme boyunca a katsayı güncellenir ve kalan sürünün konumu liderlik eden kurdun konumuna göre güncellenir. Bu döngü maksimum iterasyon sayısına ulaşana kadar devam eder. GWO algoritmasında, popülasyon boyutunu 30 ve maksimum iterasyon sayısı 500 alınarak çalıştırılmıştır.

Şekil 1: Valf noktası etkili GWO algoritması



Sonuçlar

Bu çalışmada 2 farklı üniteli test sisteminde EYD problemi modellenmiş ve birbirinden farklı optimizasyon algoritmaları ile çalıştırılmıştır. Çalışma, EYD problemlerinin parabol olmadığı ve bu yüzden çok modlu ele alınması gerektiği vurgulamak için en iyi sonuç veren GWO algoritmasının maliyet fonksiyonunu değiştirmiştir. Tablo 3 ve 4'te 2 farklı test sistemi için optimizasyon algoritmalarının sonuçları verilmiştir.

3 üniteli test sistemi daha basit bir sistem olduğu için çözümler Tablo 4'e göre daha düşüktür.

Tablo 3: 3 üniteli test sisteminde algoritma sonuçları

Algoritma	En iyi	Ortalama	Standart Sapma
Parçacık Sürü Optimizasyonu	1600.60	1609.13	8.231
Yapay arı koloni algoritması	1600.51	1607.34	11.676
Ateş Böceği Algoritması	1600.47	1617.34	10.746
Guguk Kuşu Arama	1600.46	1600.46	2.7e-6
Gri Kurt Optimizasyon	1599.85	1600.05	0.0755
Valf Noktası Etkili GWO	1612.4241	1612.4300	0.0030

Tablo 4'e bakıldığında klasik GWO valf noktalarını atlanabilir gürültü olarak görüp düşük maliyetli ama fiziksel olarak olmayan noktaya yakın çözümler bulmuştur. Valf Noktası Etkili GWO, çok düşük standart sapma ile gerçek maliyet eğrisine en yakın çözüm kümesini üretmiştir.

Tablo 4: 6 üniteli test sisteminde algoritma sonuçları

Algoritma	En iyi	Ortalama	Standart Sapma
Parçacık Sürü Optimizasyonu	8401.45	8722.04	177.652
Yapay arı koloni algoritması	8372.27	8457.16	57.726
Ateş Böceği Algoritması	8388.45	8631.82	176.83
Guguk Kuşu Arama	8356.06	8356.06	0.008
Gri Kurt Optimizasyon	8313.98	8314.01	0.0189
Valf Noktası Etkili GWO	8320.3877	8320.4921	0.0685

Kaynakça

El-Keib, A. A., Ma, H., & Hart, J. L. (2002). Environmentally constrained economic dispatch using the Lagrangian relaxation method. *IEEE transactions on Power Systems*, 9(4), 1723-1729.

Lin, F. J., Liao, J. C., Zhang, Y. M., & Huang, Y. C. (2023). Optimal economic dispatch and power generation for microgrid using novel lagrange multipliers-based method with HIL verification. *IEEE Systems Journal*, 17(3), 4533-4544.

Mahor, A., Prasad, V., & Rangnekar, S. (2009). Economic dispatch using particle swarm optimization: A review. *Renewable and sustainable energy reviews*, 13(8), 2134-2141.

Mirjalili, Seyedali, Seyed Mohammad Mirjalili, and Andrew Lewis. "Grey wolf optimizer." *Advances in engineering software* 69 (2014): 46–61.

Noman, N., & Iba, H. (2008). Differential evolution for economic load dispatch problems. *Electric power systems research*, 78(8), 1322-1331.

P Parouha, R. P., & Das, K. N. (2016). DPD: An intelligent parallel hybrid algorithm for economic load dispatch problems with various practical constraints. *Expert Systems With Applications*, 63, 295–309. <https://doi.org/10.1016/j.eswa.2016.07.012>

Saeed, I. K. (2019). Artificial Neural Network Based on Optimal Operation of Economic Load Dispatch in Power System. *ZANCO J. Pure Appl. Sci*, 31, 94-102.

Qin, J., Wan, Y., Yu, X., & Kang, Y. (2019). A Newton method-based distributed algorithm for multi-area economic dispatch. *IEEE Transactions on Power Systems*, 35(2), 986-996.

Zou, D., Li, S., Wang, G. G., Li, Z., & Ouyang, H. (2016). An improved differential evolution algorithm for the economic load

dispatch problems with or without valve-point effects. *Applied Energy*, 181, 375-390.

Yang, X. S., Hosseini, S. S. S., & Gandomi, A. H. (2012). Firefly algorithm for solving non-convex economic dispatch problems with valve loading effect. *Applied soft computing*, 12(3), 1180-1186.

Wang, L., & Li, L. P. (2013). An effective differential harmony search algorithm for the solving non-convex economic load dispatch problems. *International Journal of Electrical Power & Energy Systems*, 44(1), 832-843.

Wood, A. J., Wollenberg, B. F., & Sheblé, G. B. (2013). *Power generation, operation, and control*. John Wiley & sons.

GEÇİCİ KAPAK

*Kapak tasarımı
devam ediyor.*