



**DERİN PEKİŞTİRMELİ ÖĞRENME İLE
TELEKOMÜNİKASYON SAHALARININ
ÖNCELİKLENDİRİLMESİ**

Sadrettin ÇODUR

Danışman: Prof. Dr. Burak ERKAYMAN

Doktora Tezi

Endüstri Mühendisliği Ana Bilim Dalı

2025

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

**DERİN PEKİŞTİRMELİ ÖĞRENME İLE TELEKOMÜNİKASYON SAHALARININ
ÖNCELİKLENDİRİLMESİ**

(Prioritization of Telecommunication Sites with Deep Reinforcement Learning)

DOKTORA TEZİ

Sadrettin ÇODUR

Danışman: Prof. Dr. Burak ERKAYMAN

Erzurum

Temmuz, 2025

KABUL VE ONAY TUTANAĞI

Sadrettin ODUR tarafından hazırlanan ‘‘Derin Pekiřtirmeli ğrenme ile Telekomünikasyon Sahalarının Önceliklendirilmesi’’ başlıklı alışması 25/07/2025 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Endüstri Mühendisliđi Ana Bilim Dalı, Endüstri Mühendisliđi Bilim Dalında Doktora tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Muhammed Emre KESKİN <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır.
Jüri Üyesi:	Prof. Dr. Burak ERKAYMAN <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır.
Jüri Üyesi:	Doç. Dr. Tolga AYDIN <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır.
Jüri Üyesi:	Doç. Dr. Mahmut TUTAM <i>Erzurum Teknik Üniversitesi</i>	Aslı ıslak imzalıdır.
Jüri Üyesi:	Dr. Öğr. Üyesi Nadide ađlayan ÖZAYDIN <i>Erzurum Teknik Üniversitesi</i>	Aslı ıslak imzalıdır.
		Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliđi’nin ilgili maddelerinde belirtilen şartları yerine getirdiđini onaylarım.

Prof. Dr. Alper NUHOĐLU
Enstitü Müdürü

Aslı ıslak imzalıdır.

Bu alışma Bilimsel Arařtırma Projeleri (BAP) kapsamında desteklenmiştir.
Proje Kodu: FDK-2022-10716.

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriř, çizelge, řekil ve fotođrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Doktora Tezi olarak Prof. Dr. Burak ERKAYMAN danışmanlığında sunulan “Derin Pekiştirmeli Öğrenme ile Telekomünikasyon Sahalarının Önceliklendirilmesi” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	%2	30
Kuramsal Temeller	%1	30
Materyal ve Metot	%3	35
Araştırma Bulguları ve Tartışma	%2	20
Sonuçlar	%0	20
Tezin Geneli	%6	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Sadrettin ÇODUR	Prof. Dr. Burak ERKAYMAN
25.7.2025	25.7.2025
İmza: Aslı ıslak imzalıdır.	İmza: Aslı ıslak imzalıdır.

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi nedeni ile Enstitü Yönetim Kurulunun/.../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

Enstitü Yönetim Kurulunun/.../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŐEKKÜR

Doktora tez alıőmamın gerekleőmesinde desteklerini esirgemeyen kiői ve kurumlara iten Őukranlarımı sunarım.

Öncelikle, tez alıőmamın her aőamasında bilgi ve tecrübeleriyle yol gösteren, bilimsel rehberlięi ve yapıcı eleőtiriyle alıőmamın geliőmesinde büyük katkısı olan deęerli danıőmanım Prof. Dr. Burak ERKAYMAN'a teőekkürlerimi sunarım. Kıymetli vaktini alıőmamıza ayıran tez izleme komitesi üyeleri sayın Prof. Dr. M. Emre KESKİN ve Do. Dr. Tolga AYDIN'a en derin minnettarlıęımı ifade ederim.

Bu alıőma, Atatürk Üniversitesi Bilimsel Araőtırma Projeleri Koordinasyon Birimi tarafından FDK-2022-10716 numaralı proje kapsamında desteklenmiőtir. Projeye verdikleri destek için müteőekkirim.

Akademik yolculuęum boyunca bana her zaman sevgiyle destek olan, sevgi ve sonsuz motivasyonuyla bana güç veren sevgili eőtım Gamze ODUR'a ve hayatımın en anlamlı ilham kaynaęı olan sevgili kızım Defne ODUR'a sonsuz teőekkür ederim. Ayrıca, her koőtulda yanımda olan ve bana inanan sevgili aileme teőekkürlerimi sunarım.

Sadrettin ODUR

ÖZET

DOKTORA TEZİ

DERİN PEKİŞTİRMELİ ÖĞRENME İLE TELEKOMÜNİKASYON SAHALARININ ÖNCELİKLENDİRİLMESİ

Sadrettin ÇODUR

Danışman: Prof. Dr. Burak ERKAYMAN

Amaç: Bu çalışmanın temel amacı, Türkiye’de Mersin iline ait telekomünikasyon sahalarının 5G altyapı geçiş sürecine yönelik olarak önceliklendirilmesini sağlamak üzere, veri odaklı ve öğrenen bir karar destek modeli geliştirmektir. Bu kapsamda, çok sayıda performans ve potansiyel belirteci dikkate alınarak, geleneksel sıralama yöntemlerinin ötesinde, adaptif ve dinamik öğrenmeye dayalı bir model önerilmektedir.

Yöntem: Çalışmada, pekiştirmeli öğrenme tabanlı bir yaklaşım olarak Yakın Politika Optimizasyonu (YPO) algoritması kullanılmıştır. Ajan tabanlı bir simülasyon ortamı tasarlanarak, sahalara ait demografik, kapasite, trafik yükü, gelir, büyüme potansiyeli gibi çok boyutlu veriler işlenmiş; ayrıca stokastik özellikler de modele eklenmiştir. Modelin başarımı, uzman sıralamaları ile karşılaştırılarak Spearman korelasyonu üzerinden ölçülmüştür.

Bulgular: Geliştirilen YPO tabanlı model, uzman görüşleriyle yüksek derecede örtüşen sıralamalar üretmiş ve özellikle nüfus artışı, konut gelişim hızı, veri kullanımı gibi parametrelerin saha önceliği üzerindeki etkisini güçlü biçimde yansıtmıştır. Korelasyon katsayısı %88’a ulaşan model elde edilmiş ve veriye dayalı öğrenmenin karar destek sürecinde sağladığı katkılar ortaya konmuştur.

Sonuç: Bu tez çalışması, 5G altyapı yatırımları gibi yüksek maliyetli ve stratejik kararların, pekiştirmeli öğrenme temelli modellerle daha objektif, esnek ve dinamik biçimde yönlendirilebileceğini göstermektedir. Geliştirilen simülasyon ortamı ve YPO algoritmasına dayalı önceliklendirme yaklaşımı, yalnızca mevcut verilerle değil, geleceğe yönelik olasılıklarla da uyumlu kararlar üretme potansiyeli taşımaktadır. Bu yönüyle çalışma, telekomünikasyon sektöründe yapay zekâ destekli planlama uygulamalarına önemli bir katkı sağlamaktadır.

Anahtar Kelimeler: 5G Önceliklendirme, Ajan Tabanlı Simülasyon, Derin Pekiştirmeli Öğrenme, Pekiştirmeli Öğrenme, Spearman Korelasyonu, Stokastik Karar Destek Sistemleri, Telekom Altyapı Planlaması, Yakın Politika Optimizasyonu (YPO).

Temmuz 2025, 83 sayfa

ABSTRACT

DOCTORAL DISSERTATION

PRIORITIZATION OF TELECOMMUNICATION SITES WITH DEEP REINFORCEMENT LEARNING

Sadrettin ÇODUR

Supervisor: Prof. Dr. Burak ERKAYMAN

Purpose: The primary objective of this study is to develop a data-driven and adaptive decision support model to prioritize telecommunication sites in Mersin, Türkiye, for the transition to 5G infrastructure. In this context, a model based on adaptive and dynamic learning is proposed, going beyond traditional ranking methods by taking into account a wide range of performance indicators and potential determinants.

Method: The study employs Proximal Policy Optimization (PPO), a reinforcement learning-based algorithm. An agent-based simulation environment was designed to process multidimensional data (demographics, capacity, traffic load, revenue, growth potential, etc.) from sites. Stochastic features were also integrated into the model. Performance was evaluated using Spearman correlation by comparing model outputs against expert rankings.

Findings: The developed PPO-based model generated rankings highly consistent with expert evaluations. It strongly reflected the impact of parameters such as population growth, housing development rate, and data usage on site priority. A model achieving a correlation coefficient of 88% was obtained, demonstrating the value of data-driven learning in decision support processes.

Results: This thesis shows that high-cost strategic decisions (e.g., 5G infrastructure investments) can be guided more objectively, flexibly, and dynamically using reinforcement learning models. The proposed simulation environment and PPO-based prioritization approach generate decisions compatible not only with current data but also with future scenarios. Thus, the study significantly contributes to artificial intelligence assisted planning applications in telecommunications.

Keywords: 5G Prioritization, Agent-Based Simulation, Deep Reinforcement Learning, Proximal Policy Optimization (PPO), Spearman Correlation, Stochastic Decision Support Systems, Reinforcement Learning, Telecommunications Infrastructure Planning.

July 2025, 83 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ.....	x
GİRİŞ.....	1
KURAMSAL TEMELLER.....	6
Veri Çıkarma.....	8
Tez Kapsamında Yürütülen Yayınlar.....	16
Araştırmanın Yenilikçi Yönleri.....	16
5G İletişim Teknolojisi	17
Endüstri 4.0 ve Yeni İletişim Teknolojilerinin Rolü.....	19
Türkiye’de Endüstri 4.0 ve 5G Uygulamaları.....	20
MATERYAL ve METOT	22
Veri Seti ve Özellikleri.....	22
Özellik seçimi	25
SHAP ile Model Açıklama.....	26
Rastgele Orman tabanlı SHAP yöntemiyle özellik seçimi süreci	28
Rastgele Orman tabanlı SHAP yöntemiyle öznitelik seçim sürecinin çıktıları	29
Stokastik özelliklerin modele eklenmesi	31
Ajan Tabanlı Simülasyon Modeli	32
RL’nin Temelleri ve Evrimi.....	35
Özel RL ortamı	37
Yazılım ortamı ve özellik seçimi süreci	38
RL yaklaşımıyla saha önceliklendirme süreci	41
Modelin Eğitimi ve Uygulaması	43
Türkiye’de Mevcut 5G Altyapısı: Durum Analizi.....	48

ARAŞTIRMA BULGULARI VE TARTIŞMA.....	51
Korelasyon Performansı ve Sıralama Başarısı.....	51
Veri Kullanımı ve Modelin Pratikliği	51
Hata Metrikleri ve İstatistiksel Başarı.....	52
Ödül Fonksiyonu ve Öğrenme Dinamikleri.....	56
Karar Destek Sistemlerine Uygunluk.....	57
SONUÇLAR VE ÖNERİLER	58
Sonuçlar.....	58
Öneriler	60
Uygulama tabanlı öneriler	60
Bilimsel geliştirme önerileri	60
Politika ve yatırım stratejisi önerileri	60
Ekonomik genişleme ve maliyet odaklı modelleme önerileri	60
KAYNAKLAR.....	62
ÖZGEÇMİŞ.....	70

TABLolar DİZİNİ

Tablo 1. En Sık Kullanılan Anahtar Kelimeler	8
Tablo 2. Ar-Ge Uzmanları Tarafından Kullanılması Öngörülen Veriler	23
Tablo 3. Rastgele Orman Tabanlı SHAP Yöntemi Sonucunda Öne Çıkan Öznitelikler ve Açıklamaları	31
Tablo 4. Trafik Ortamına Göre Uygunluk Testi Sonuçları.....	32
Tablo 5. Sıralama Yöntemlerinin Korelasyon ve Hata Metrikleri Karşılaştırması	53
Tablo 6. RSR ile Model Performansı Sınıflandırması	55



ŞEKİLLER DİZİNİ

Şekil 1. Web of Science veri tabanında yapılan sorgu sonucunda elde edilen yayınların yıllara göre dağılımı.	7
Şekil 2. Literatürde en sık kullanılan anahtar kelime bulutu.....	7
Şekil 3. Birincil çalışmaların seçim süreci.	8
Şekil 4. Endüstri 1.0'dan 5.0'a Sanayi Devrimlerinin zaman çizelgesi ve temel özellikleri. ..	18
Şekil 5. Rastgele Orman tabanlı SHAP yöntemiyle öznelik seçimi akış şeması.	27
Şekil 6. Uzman sıralamasını belirlemede etkili öznelikler.....	30
Şekil 7. Telekomünikasyon saha önceliklendirme problemine uygulanan öğrenme sürecinin akış şeması.	39
Şekil 8. Normalize bant genişliği ile mobil gelir arasındaki doğrusal ilişki.	43
Şekil 9. Normalize bant genişliği dağılımı.	44
Şekil 10. Performans göstergeleri arasındaki korelasyon matrisi.	45
Şekil 11. Trafik yoğunluğuna göre downlink PRB kullanım oranı (NET_02) dağılımı.	46
Şekil 12. Downlink PRB kullanım oranı (NET_02) dağılımı ve kritik eşik.	46
Şekil 13. Türkiye mobil şebeke kapsama haritası (2G–5G).	49
Şekil 14. Türkiye'de 5G baz istasyonu kurulum dağılımı.	49
Şekil 15. Korelasyon metrikleri grafiği.	53
Şekil 16. Hata metrikleri grafiği.	54
Şekil 17. Radar grafiği: normalize edilmiş performans profili.	56
Şekil 18. Yalnızca rekor gelişmelerde gözlemlenen YPO tabanlı sıralama korelasyonu artışı.	57

KISALTMALAR VE SİMGELER DİZİNİ

1G – 6G	:1st to 6th Generation Mobile Networks – Birinci nesilden altıncı nesile mobil iletişim teknolojileri
ABM	:Agent Based Modeling – Ajan Tabanlı Modelleme
ABS	:Agent Based Simulation – Ajan Temelli Simülasyon
AHP	:Analytic Hierarchy Process – Analitik Hiyerarşi Süreci
BDI Modeli	:Belief-Desire-Intention Model – İnanç-Arzu-Niyet Modeli
CPS	:Cyber Physical Systems – Siber Fiziksel Sistemler
dB	:Decibel - Sinyal gücü/kayıbı ölçü birimi
DDPG	:Deep Deterministic Policy Gradient – Derin Deterministik Politika Gradyanı
DDQL	:Double Deep Q-Learning – Çift Derin Q-Öğrenme
DES	:Discrete Event Simulation – Ayrık Olay Simülasyonu
DRL	:Deep Reinforcement Learning - Derin Pekiştirmeli Öğrenme
eMBB	:Enhanced Mobile Broadband – Gelişmiş Mobil Geniş Bant
ENV	:Traffic Environment -Trafik yoğunluğuna göre bölge sınıflandırması
Erlang	:Erlang Unit - Trafik yoğunluğu ölçü birimi
FUCOM	:Full Consistency Method – Tam Tutarlılık Yöntemi
G5	:5G Metric - 5G ile ilişkili metrikler (aday müşteri, trafik, kullanım vs.)
GB	:Gigabyte - Veri miktarı ölçü birimi (1 GB = 1024 MB)
GBM	:Gradient Boosting Machines - Gradyan Güçlendirme Makineleri
GBPO	:Güven Bölgesi Politika Optimizasyonu - Trust Region Policy Optimization
GEO	:Geographic/Structural Attribute - Coğrafi ve yapısal veri metrikleri
ID	:Identifier - Kimlik bilgisi / benzersiz tanımlayıcı
IIoT	:Industrial Internet of Things – Endüstriyel Nesnelerin İnterneti
IoT	:Internet of Things – Nesnelerin İnterneti
kbps	:Kilobits per Second - Veri iletim hızı ölçü birimi
LOC	:Location - İstasyonun bulunduğu ilçe
LTE	:Long Term Evolution - 4G altyapısının temelini oluşturan mobil iletişim teknolojisi
MAE	:Mean Absolute Error – Ortalama Mutlak Hata
ML	:Machine Learning – Makine Öğrenmesi

MLP	: Multi-Layer Perceptron (Regressor) - Çok Katmanlı Algılayıcı (Regresyon Modeli)
mMTC	:Massive Machine-Type Communication – Yoğun Makine Türü İletişim
mMWave	:Millimeter Wave – Milimetre Dalga (yüksek frekanslı kablosuz iletim)
MSE	:Mean Squared Error – Ortalama Kare Hatası
NET	:Network Metric - Şebeke performansı ve kullanım metrikleri
POI	:Point of Interest -Önemli yer bilgisi (kamu binaları, hastaneler, AVM vb.)
PRB	:Physical Resource Block - Fiziksel Kaynak Bloğu
QoE	:Quality of Experience – Deneyim Kalitesi
QoS	:Quality of Service – Hizmet Kalitesi
R ² Skoru	:Coefficient of Determination – Determinasyon Katsayısı
REV	:Revenue/User Metric - Gelir ve kullanıcı istatistikleri
RL	:Reinforcement Learning – Pekiştirmeli Öğrenme
RMSE	:Root Mean Squared Error – Kök Ortalama Kare Hatası
ROAD	:Road Type or Road Metric -Yol sınıflandırmaları (otoyol, ara yol, köy yolu vb.)
ROAM	:Roaming Metric - Roaming verileri (veri hacmi, kullanıcı sayısı)
RSR	:Ratio of the Root Mean Square Error to the Standard Deviation of measured data - RMSE'nin gözlem standart sapmasına oranı
RSRP	:Reference Signal Received Power - Referans sinyal alma gücü
RSRQ	:Reference Signal Received Quality - Referans sinyal kalite oranı
SD	:System Dynamics – Sistem Dinamiği
SHAP	:SHapley Additive exPlanations – Shapley Katkısal Açıklamaları
SINR	:Signal to Interference plus Noise Ratio – Sinyal gürültü oranı
TOPSIS	:Technique for Order Preference by Similarity to Ideal Solution – İdeal Çözüme Benzerliğe Göre Tercih Tekniği
UE	:User Equipment - Kullanıcı ekipmanı (cep telefonu, modem vb.)
URLLC	:Ultra-Reliable Low-Latency Communication – Ultra Güvenilir ve Düşük Gecikmeli İletişim
V2I	:Vehicle-to-Infrastructure Communication – Araçtan Altyapıya İletişim
V2V	:Vehicle-to-Vehicle Communication – Araçtan Araca İletişim
V2X	:Vehicle-to-Everything Communication – Araçtan Her Yere İletişim
VoLTE	:Voice over LTE - LTE üzerinden ses iletimi
YPO	: Yakın Politika Optimizasyonu - Proximal Policy Optimization
YZ	: Yapay Zekâ – Artificial Intelligence

GİRİŞ

Toplumların dijitalleşmesinde mobil iletişim teknolojileri belirleyici bir rol üstlenmektedir. Her yeni nesil teknoloji ile bireysel yaşamın ve endüstriyel dinamiklerin şekillenmesinde önemli etkiye sahip olmuştur (Gawas, 2015). Mobil kablosuz iletişim sistemlerinin birinci nesli (1G), analog tabanlı teknolojidir ve yalnızca ses iletişimini sağlamıştır. 2,4 kbps düşük bağlantı hızına sahip olması ve düşük güvenlik özellikleri sebebiyle kısa sürede yeni özelliklere ihtiyaç doğmuştur. İkinci nesil (2G) ise dijital tabanlı bir teknoloji olup kısa mesaj gönderimine olanak tanımıştır. 1G sistemleri neredeyse tamamen analog yapıda ve sınırlı özelliklere sahipken, 2G sistemleri dijital olması sayesinde iletişimi şifreleyerek dinlemelere karşı koruma sağlamış, tespit edilen hataların düzeltilmesine olanak tanımış, daha net ses iletimi sunmuş ve kullanıcıların aynı frekans kanallarını eş zamanlı olarak paylaşabilmesine imkân vermiştir. Üçüncü nesil (3G) teknoloji ile veri iletim hızı ve kapasitesinde kayda değer artışlar sağlanmış; multimedya destekli hizmetlerin sunulmasına olanak tanınmıştır. Dördüncü nesil (4G) ise teknolojisine internet altyapısını entegre ederek kablosuz mobil internet hizmeti sunmuş, bant genişliği artırılmış ve kaynaklara erişim maliyetleri azaltılmıştır (Gawas, 2015; Adebisola *et al.*, 2020). Ancak tarım, endüstri, tıp ve trafik gibi ortamlarda nesnelerin internetini (IoT) kullanan cihaz sayısındaki hızlı artış ve yeni nesil bilgi işlem uygulamalarının (örneğin artırılmış gerçeklik, sanal gerçeklik, otonom araçlar) doğuşu mevcut iletişim altyapısının kapasite sınırlarını zorlamıştır (Ning *et al.*, 2019; Chen *et al.*, 2020; Hu *et al.*, 2023). Bu gelişmeler, yalnızca hızın artırılmasını değil, aynı zamanda gecikmenin azaltılmasını, daha fazla cihazın aynı anda bağlanabilmesini ve ağ güvenilirliğinin yükseltilmesini zorunlu kılmıştır. Bu ihtiyaçlar doğrultusunda, beşinci nesil (5G) mobil iletişim teknolojisi doğmuştur.

5G teknolojisinin yeteneği, yalnızca önceki nesillerdeki mobil iletişim teknolojilerine göre daha yüksek veri hızları sunmakla kalmamakta; aynı zamanda düşük gecikme süresi, yüksek bağlantı yoğunluğu, daha yüksek kapsama alanı ve gelişmiş ağ güvenilirliği gibi hedeflere odaklanmaktadır. Bu teknoloji, üç ana kullanım senaryosu etrafında şekillenmektedir: Geliştirilmiş Mobil Geniş Bant (eMBB), Ultra Güvenilir Düşük Gecikmeli İletişim (URLLC) ve Yoğun Makine Türü İletişim (mMTC) (Agiwal *et al.*, 2016; Kutscher, 2016).

- eMBB: 5G'nin sunduğu gigabit düzeyindeki veri hızları, yüksek çözünürlüklü video akışı, bulut tabanlı oyunlar ve sanal gerçeklik deneyimleri gibi yoğun veri gerektiren uygulamalara olanak tanımaktadır (Kutscher, 2016, Zhang *et al.*, 2020).

- URLLC: Özellikle otonom araçlar, uzaktan cerrahi operasyonlar ve endüstriyel otomasyon gibi zaman kritik uygulamalar için milisaniye altı gecikme süreleri sağlanarak güvenlik ve performans standartları yükseltilmektedir (Zhang *et al.*, 2020; Hu *et al.*, 2023).

- mMTC: Milyonlarca IoT cihazının eş zamanlı iletişimini destekleyerek, tarım, sağlık, enerji ve şehir yönetimi gibi alanlarda dijitalleşmenin temel taşı oluşturulmaktadır (Ahmad *et al.*, 2019; Chen *et al.*, 2020).

5G'nin bu teknik yetenekleri yalnızca kullanıcı deneyimlerini iyileştirmekle kalmamakta, aynı zamanda akıllı tarım sistemlerinde, sanayide Endüstri 4.0 uygulamalarında, sağlıkta uzaktan müdahale sistemlerinde ve ulaşımda sürücüsüz araç teknolojilerinde gelişimi hızlandırarak toplumun ve ekonominin dönüşümünü tetiklemektedir (Lundgren *et al.*, 2022; Singh *et al.*, 2023). 5G'nin yüksek frekans bantlarını (mmWave) kullanması, kapsama alanının daralmasına yol açmakta; bu da mevcut baz istasyonlarının 5G'ye uyum kapasitesinin yeniden analiz edilmesini gerektirmektedir (Agiwal *et al.*, 2016; Nguyen *et al.*, 2021). Bu durum, yalnızca yeni altyapı yatırımlarını değil, aynı zamanda mevcut sahaların hangi öncelikle 5G'ye geçirileceğinin stratejik olarak belirlenmesini de zorunlu kılar. 5G hizmet kalitesinin sürdürülebilmesi için mevcut sahaların trafik yoğunluğu, veri tüketim potansiyeli ve nüfus gelişim dinamikleri gibi faktörler dikkate alınarak önceliklendirilmesi kritik bir önem taşımaktadır (Aktaş *et al.*, 2023; Çodur *et al.*, 2024).

Akademik araştırmalar, 5G teknolojisinin potansiyel uygulamaları üzerine önemli bulgular ortaya koymuştur (Azimi *et al.*, 2021; Lundgren *et al.*, 2022; Singh *et al.*, 2023; Abba Ari *et al.*, 2025). Ancak, 5G ağlarının etkin şekilde dağıtılması ve işletilmesi için gerekli olan sistematik, ölçeklenebilir ve veri odaklı saha planlaması konusunda literatürde belirgin boşluklar bulunmaktadır (Chiaraviglio *et al.*, 2018; Barakabitze *et al.*, 2020; Ahamed and Faruque, 2021). 5G konuşlandırmasının başarısı, yalnızca teknik altyapıya değil, aynı zamanda hizmet alanlarının stratejik önceliklendirilmesine, yoğun veri kullanım alanlarının doğru tespitine ve ağın dinamik yönetimine de bağlıdır (Aktaş *et al.*, 2023; Çodur *et al.*, 2024).

Sonuç olarak, 5G teknolojisi mobil iletişim teknolojilerinde devrim niteliğinde bir sıçrama sunmakta, toplumların hizmet ve üretim kalitesini büyük oranda etkilemektedir. Ancak bu potansiyelin gerçeğe dönüşebilmesi için yalnızca teknik yenilikler yeterli değildir. Aynı zamanda alt yapının planlanması ve saha yönetimi gibi stratejik kararlarda da akılcı çözümlerin geliştirilmesi gerekmektedir. Bu nedenle, 5G'nin sunduğu olanaklardan tam anlamıyla

yararlanabilmek için yapay zekâ (YZ) destekli, öğrenebilen karar destek mekanizmalarına duyulan ihtiyaç her zamankinden daha kritiktir. Bu doğrultuda, bu tez kapsamında Ajan Tabanlı Simülasyon (ABS) ve Yakın Politika Optimizasyonu (YPO) tabanlı bir pekiştirmeli öğrenme (RL) yaklaşımı geliştirilmiş ve mevcut sahalar, uzman görüşleriyle uyumlu bir şekilde 5G'ye geçiş önceliğine göre sıralanmıştır.

Bir ajan, programlamada nesne, yöntem, işlev gibi kavramlara benzeyen ama onlara göre daha gelişmiş ve bağımsız çalışan bir yazılım bileşenidir. Bir nesne, bazı özellikleri ve işlevleri barındırırken, bir yazılım ajanı, belirli amaçlara yönelik hareket eden daha karmaşık bir yapıdır. Ajanlar, ne yaptıklarıyla, yani verdikleri tepkiler ile tanımlanır; sınıf ve yöntem tanımlamaktan ziyade, ne tür eylemler gerçekleştireceği önemlidir (Abar *et al.*, 2017). Bir ajanın temel özellikleri arasında özerklik, duyarlılık, iletişim yeteneği, sezgi ve karar alma kapasitesi yer almaktadır. Özerklik, ajanın dış müdahaleye gerek duymadan karar verebilmesi anlamına gelirken; duyarlılık ve iletişim, ajanın ortamı algılayabilmesini ve diğer ajanlarla bilgi alışverişi yapabilmesini sağlar. Sezgi, ajanın geleceği öngörerek uygun stratejiler belirleyebilmesini, karar alma ise karmaşık durumlarda rasyonel seçimler yapabilmesini ifade eder (Abar *et al.*, 2017).

ABS, ajanların birbirleriyle ve çevreyle olan etkileşimlerini bir ortam içinde canlandırarak sistemin nasıl davrandığını anlamaya çalışan bir modelleme metodudur. Bir ajanın kararlarını anlamamız için ajanın temsil ettiği BDI (inançlar-istekler-niyetler) modelini kavrayabilmemiz gereklidir. Bu modele göre bir ajan:

-İnançlar: Kendisi ve çevresi hakkında bildikleri (Bant genişliği, mobil gelir, trafik yoğunluğu, kullanıcı sayısı vb.),

-İstekler: Ulaşmak istediği hedefler (5G'ye öncelikli geçiş, yüksek öncelik puanı elde etme, kapasitenin artırılması),

-Niyetler: Ulaşmaya karar verdiği hedefler (YPO algoritmasıyla en iyi kararı verecek şekilde politikayı güncelleme süreci).

Olmak üzere üç önemli ana yapıya sahiptir (O'Hare and Jennings, 1996; O'Hare *et al.*, 2003). Bu çerçevede, ajanların mantıklı ve stratejik karar alma yetilerini simüle etme konusunda önemli bir katkı sunar.

Ajan Tabanlı Modelleme (ABM), karmaşık sistemlerin dinamiklerini bireysel davranışlar ve etkileşimler üzerinden analiz etmek için geniş bir alanda kullanılan bir yaklaşımdır (Chen, 2012). ABS olarak da adlandırılan bu modelleme yönteminin kökeni, 1940'lı yıllarda geliştirilen hücreli otomatlara kadar uzanmaktadır (Neumann, 1951). Bu erken

dönem sistemlerinde, ızgara üzerindeki komşu hücreler sabit durumlar (örneğin 'açık' veya 'kapalı') sergilemekte ve komşularıyla etkileşime girerek bir sonraki durumu belirlemektedir. Ancak bu modeller, ajanların özerk karar alma yeteneklerini içermemektedir.

1987 yılında Reynolds'un geliştirdiği Boids algoritması, ABS için bir dönüm noktası olmuştur. Bu algoritma, ajanlara bireysel algılama, çevresel tepki verme ve etkileşim kurma yetenekleri kazandırarak ortaya çıkan kolektif davranışların benzetimini mümkün kılmıştır (Reynolds, 1987). Ancak ABS'nin sosyal bilimler, kentsel analiz, ekonomi ve organizasyonel davranış gibi alanlarda yaygın biçimde kullanılması 1990'lı yılları bulmuştur (Chen, 2012).

Günümüzde problemler giderek daha karmaşık bir hal almaya başladı (Macal and North, 2009). Bu karmaşık problemlerin çözümlenmesinde ortaya çıkan özellikleri anlamak için ABS vazgeçilmez bir stratejik araç haline gelmiştir. Telekomünikasyon sektörü de doğası gereği karmaşık bir sistem yapısına sahiptir (Zhang et al., 2019). Bu sistemde her bir saha, kullanıcı grubu veya altyapı birimi, çevresel koşullara, veri tüketim eğilimlerine ve yerleşim alanlarındaki gelişim oranlarına göre değişen davranışlar sergileyen birer "ajan" olarak modellenebilmekte; çevresel faktörlere, veri tüketim alışkanlıklarına, konut gelişim oranlarına bağlı olarak farklı davranışlar sergileyebilmektedir. Söz konusu davranışlar, sahaların performansını, yük dağılımını ve nihayetinde hizmet kalitesini doğrudan etkileyebilmektedir. ABS, bu farklılıkları temsil edebilme özelliği sayesinde, özellikle 5G'ye geçiş sürecinde sahaların stratejik olarak önceliklendirilmesine olanak tanımaktadır. Bu kapsamda ABS, otonom ajanları içeren dinamik süreçleri modellemek için kullanılan hesaplamalı bir çerçeve sunmaktadır. Her bir ajan, karşılaştığı durumlara dışsal bir müdahale olmaksızın tepki verebilmekte ve bu sayede simülasyon ortamında gerçek hayattaki bireylerin veya birimlerin davranışları daha gerçekçi bir şekilde temsil edilebilmektedir (Macal and North, 2014). ABS'nin bu özelliği sayesinde yalnızca bireysel karar alma süreçlerinin değil, aynı zamanda sosyal ve örgütsel davranışların, piyasa yapılarının ve teknik altyapı sistemlerinin modellenmesinde de yaygın olarak kullanılmaktadır (Bonabeau, 2002). Bu doğrultuda, "ajan" kavramı geniş bir temsil kapasitesine sahiptir ve farklı bağlamlarda insanlar, kullanıcı grupları, işletmeler veya teknik bileşenler olarak kurgulanabilir (Macal and North, 2014, Gilbert and Troitzsch, 2005).

RL, bir ajanın belirli bir ortamda çevresiyle etkileşime girerek, zaman içinde ödül maksimizasyonuna dayalı bir strateji geliştirmesini sağlayan bir makine öğrenmesi (ML) yöntemidir (Kaelbling et al., 1996; Sutton and Barto, 2018). Bu yaklaşım, bir yazılım ajanın belirli bir hedefe ulaşmak üzere davranışlarını deneme-yanılma süreciyle geliştirerek ödül fonksiyonunu en üst düzeye çıkarmasını temel alır (Lopes et al., 2018).

RL'nin temel bileşenleri; ajan, çevre, durum (state), eylem (action) ve ödül (reward) olarak tanımlanır. Ajan her adımda mevcut durumu gözlemler, bir eylem gerçekleştirir ve bu eylem sonucunda ödül alarak bir sonraki duruma geçer. Bu süreç, genellikle Markov Karar Süreci çerçevesinde modellenir (Lopes *et al.*, 2018).

Son yıllarda RL algoritmaları; video oyunları, otonom sürüş, zamanlama optimizasyonu ve doğal dil işleme gibi alanlarda önemli başarılar sergilemiştir (Gu *et al.*, 2021). Bu başarıların temelinde, özellikle politika temelli algoritmalar ve bunların YPO gibi gelişmiş versiyonları yer almaktadır (Bøhn *et al.*, 2019).

YPO, karar alma ve kontrol problemleri için yüksek başarı sağlayan, deneme-yanılma yöntemiyle öğrenmeyi dengeli şekilde sürdüren bir RL algoritmasıdır (Meng *et al.*, 2023). YPO'nun temel amacı, ajanın politikasını çok büyük adımlarla değiştirmeden kademeli olarak güncelleyerek öğrenme sürecini kararlı hale getirmektir (Ye *et al.*, 2020). YPO'nun en güçlü yönlerinden biri, geniş görev yelpazesinde sağlam hiperparametre ayarlarıyla tutarlı performans sergilemesidir (Bøhn *et al.*, 2019). Bu özelliği sayesinde YPO büyük ölçekli araştırma laboratuvarlarında varsayılan algoritma olarak benimsenmiştir. Ayrıca YPO, düşük hesaplama karmaşıklığı ile operasyonel verimliliği artırmakta, kaynak tüketimini azaltmakta ve endüstriyel karar alma süreçlerini iyileştirmektedir (Ye *et al.*, 2020; Kalusivalingam *et al.*, 2020).

RL algoritmaları karmaşık ve belirsiz gerçek dünya ortamlarında da başarıyla uygulanmaktadır (Hwangbo *et al.*, 2017). 5G gibi karmaşık sistemlerde RL, uygun politika optimizasyonu yaparak karar süreçlerini iyileştirebilir.

Bu tez çalışmasında YPO algoritması, ABS çerçevesinde modellenmiş bir telekomünikasyon sahası önceliklendirme problemine entegre edilmiştir. Amaç, eğitim sürecinde uzman görüşleriyle uyumlu sıralamalar üretebilecek politika fonksiyonlarını öğrenerek, sahalarda 5G'ye geçiş önceliğini tahmin etmektir. Ajanlar, sahalara ait demografik ve operasyonel özellikleri gözlemleyerek politika parametrelerini güncellemektedir. Çıktılar, Spearman korelasyonu üzerinden uzman sıralamalarıyla karşılaştırılarak değerlendirilmiştir. Bu yapı sayesinde, klasik sabit kurallara dayalı karar sistemlerinden farklı olarak, çevresel değişimlere uyum sağlayan, öğrenen ve stokastik özellikler barındıran bir karar destek yaklaşımı geliştirilmiştir.


KURAMSAL TEMELLER

Yeni nesil iletişim yüksek hızda veri iletimi sayesinde akıllı şehir, otonom sistemler, Endüstri 4.0, dijital dönüşüm süreçleri, enerji verimliliği ve karbon salınımının azaltılmasını mümkün kılmaktadır. Bu çok yönlü etkileri sebebiyle günümüzde 5G ve ötesi ağ teknolojilerinin planlanması toplum, çevre ve sanayi üzerindeki dönüştürücü rolü açısından stratejik bir araştırma alanı haline gelmiştir. Bu nedenle, iletişim teknolojileri üzerine yapılan akademik çalışmalar son yıllarda belirgin bir artış gözlemlenmektedir.

PubMed, Web of Science ve Google Scholar gibi diğer veri tabanları belirgin avantajlar sağlarken (Harzing 2016), kapsamlı içeriği, disiplinler arası indeksleme sistemi ve yüksek düzeyde hakemli literatür içermesi nedeniyle bu bölümdeki 5G ve ötesi altyapı yatırımlarına yönelik akademik yayınları sistematik bir biçimde analiz etmek amacıyla Web of Science veri tabanı tercih edilmiştir. Analiz sürecinde, aşağıdaki gelişmiş arama sorgusu kullanılarak ilgili literatür taranmıştır:

- ("5G" OR "beyond 5G" OR "6G" OR "next-generation network" OR "mobile communication" OR "wireless infrastructure") AND ("infrastructure" OR "deployment" OR "site selection" OR "network planning" OR "resource allocation") AND ("decision making" OR "prioritization" OR "ranking" OR "site planning" OR "investment planning")

2025 yılı mayıs ayında yapılan tarama sonucunda toplam 603 makale tespit edilmiştir. Şekil 1’de gösterilen yayınların yıllara göre dağılımı incelendiğinde, bu konuda 2016 yılından itibaren belirgin bir artış gözlemlenmiştir. Yayınların yıllara göre katlanarak artması, akademik çalışmalarda konuya olan ilginin arttığı açıkça görülmektedir. 2025 yılının henüz tamamlanmamış olması sebebiyle ilgili yıldaki veriler görece olarak daha düşük kalmıştır.



Şekil 1. Web of Science veri tabanında yapılan sorgu sonucunda elde edilen yayınların yıllara göre dağılımı.

İncelenen alan, son on yılda artan akademik ilgiyle dikkat çekmektedir. Bu ilgi, ilgili makale sayısındaki artış ve konuya özgü bölümleri içeren konferansların sayısının çoğalmasıyla somut biçimde desteklenmektedir. Şekil 1’de bu duruma ilişkin veriler sunulmaktadır.

Makalelerin incelenbilmesi amacıyla, R programlama dili kullanılmıştır. Programdan elde edilen Şekil 2’de sunulan kelime bulutu, 5G ve ötesi iletişim teknolojilerini üzerinde yapılan çalışmalarda öne çıkan odakları ortaya koymaktadır. Burada filtrelenen 603 makale içerisinde en sık kullanılan terimler görselleştirilmektedir. Sırasıyla resource-allocation (kaynak tahsisi), 5g, internet, management (yönetim) ve networks (ağlar) gibi terimlerin ön plana çıktığı görülmektedir. Bu durum ağ kaynaklarının etkin bir şekilde tahsis edilmesi ve 5G alt yapılarının yönetimi gibi konuların literatürde öncelikli konular arasında yer aldığını göstermektedir. Tablo 1’de ise en çok kullanılan ilk on anahtar kelimenin görülme sıklıkları detaylandırılmıştır. Bu veriler, literatürde yer alan çalışmaların karar verme, ağ planlaması, optimizasyon gibi konulara odaklandığı hususunu desteklemektedir.



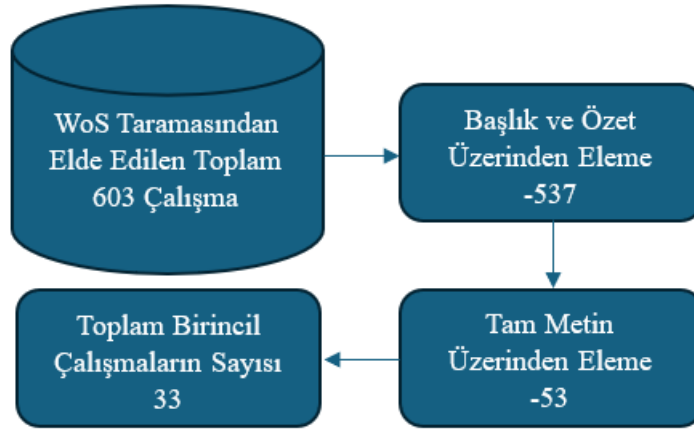
Şekil 2. Literatürde en sık kullanılan anahtar kelime bulutu.

Tablo 1. En Sık Kullanılan Anahtar Kelimeliler

Sıra	Anahtar Kelime	Frekans
1	Resource Allocation (Kaynak Tahsisi)	76
2	5g	67
3	İnternet	48
4	Management (Yönetim)	41
5	Networks (Ağlar)	38
6	Challenges (Zorluklar)	36
7	Optimization (Optimizasyon)	33
8	Communication (İletişim)	30
9	Allocation (Tahsis)	27
10	Architecture (Mimari)	24

Veri Çıkarma

Her ne kadar araştırma sorgusu ile filtrelemeden 603 yayına ulaşılmış olsa da, konumuz ile bağlantısı olan makalelerin tespiti için öncelikle başlıklar ve özetler gözden geçirilmiştir. Bu ön eleme süreci sonunda tez ile tematik olarak uyumlu 80 çalışma seçilmiş, ardından çalışmanın metodolojik güvenilirliğini artırmak amacıyla daha derinlemesine analiz yapılarak 2 adeti bu tez kapsamında üretilmiş yayınlar olmak üzere 33 çalışma, ayrıntılı inceleme ve karşılaştırmalı değerlendirme için temel alınmıştır. Söz konusu seçim aşamaları Şekil 3'te gösterilmektedir. Aşağıda ele alınan çalışmalar hakkında özet bilgiler verilmiştir:



Şekil 3. Birincil çalışmaların seçim süreci.

Dighriri *et al.* (2018), çalışmalarıyla 5G ağlarında dilimleme altyapısı altında kaynak tahsisini hem dilimler arası hem de dilim içi öncelik düzeylerini dikkate alarak optimize etmeyi amaçlayan iki katmanlı bir kaynak tahsis mekanizması önermişlerdir. Önerilen yöntem, dilimlerin hizmet ihtiyaçlarını ve kullanıcıların hizmet kalitesi (QoS) gereksinimlerini temel alarak, kaynak tahsisini dinamik biçimde gerçekleştirmektedir. Modelde, hizmet dilimleri bir kabul kontrol mekanizmasına QoS taleplerini bildirir; ardından algoritma, kaynakları en yüksek kullanıcı memnuniyeti (QoE) sağlayacak şekilde tahsis eder. Çalışma ayrıca, akıllı trafik izleme, akıllı sağlık hizmetleri ve akıllı telefon senaryolarını içeren çeşitli uygulama türleri için önceliklendirme stratejileri geliştirmiştir. Simülasyonlara dayalı değerlendirmeler, önerilen

yöntemin QoE ve ağ kaynaklarının etkin kullanımı açısından anlamlı iyileştirmeler sağladığını ortaya koymuştur.

Oughton and Frias (2018), Birleşik Krallık'ta 5G altyapısının coğrafi yayılımı, maliyeti ve uygulanma sürecini inceleyen kapsamlı bir senaryo analizi gerçekleştirmiştir. Çalışma; sermaye yoğunluğu, altyapı paylaşımı ve kırsal alanlarda hedeflenen kullanıcı hızları gibi değişkenleri dikkate alarak, 2020–2030 dönemi için bir maliyet modeli sunmuştur. Elde edilen bulgulara göre, %90'lık nüfus kapsamı 2027 yılında sağlanabilmekte; ancak son %10'luk kesimin kapsamı için maliyetler hızla artmaktadır. Çalışma, altyapı paylaşımının özellikle kırsal alanlarda maliyet verimliliği sağladığını ortaya koyarak, kamu politikalarına dair önemli çıkarımlar sunmaktadır.

Malandrino *et al.* (2019), 5G hizmetlerinde operasyonel esnekliği artırmak amacıyla, aynı hizmetin farklı kaynak düzeylerine sahip sürümleri arasında geçiş yapılmasına olanak tanıyan bir hizmet geçişi yaklaşımı önermektedir. Bu sayede, kaynak kısıtı durumlarında hizmetin tamamen kesilmesi yerine, daha az kaynakla sürdürülebilen alternatif sürümler devreye alınarak hizmet sürekliliği korunabilmektedir. Yapılan analizler, bu yaklaşımın dilim esnekliğini artırdığını ve operatör gelirini olumlu yönde etkilediğini ortaya koymaktadır.

Othman and Nayan (2019), 5G ağlarında özellikle kamu güvenliği hizmetlerinin sürekliliği açısından ağ dilimleme ve kaynak yönetimi stratejilerinin önemini vurgulamaktadır. Çalışmada, olağan ve afet koşullarında hizmet önceliklendirmesinin etkili bir şekilde yapılabilmesi için çeşitli kontrol ve kaynak tahsis mekanizmalarının birlikte değerlendirilmesi gerektiği belirtilmektedir. Bulgular, kamu güvenliği hizmetlerinde kalite, güvenilirlik ve öncelik kriterlerinin birlikte ele alınmasının ağ performansını önemli ölçüde artırdığını göstermektedir.

Thantharate *et al.* (2019), 5G ağlarında ağ dilimleme işlemlerini optimize etmek amacıyla derin öğrenme tabanlı bir model olan DeepSlice'ı geliştirmiştir. Bu model, gelen trafiği analiz ederek bilinmeyen cihazlar için en uygun dilimi tahmin edebilmekte, ayrıca yük dengeleme ve dilim arızası durumunda yeniden yönlendirme yeteneklerine sahiptir. Model, evrimsel sinir ağı tabanlı bir yapay sinir ağı mimarisi kullanarak QoS ve anahtar performans göstergesi bilgilerini (ör. gecikme, paket kaybı, cihaz türü) değerlendirir ve eMBB, URLLC, mMTC gibi dilimler arasında en uygun eşleşmeyi gerçekleştirir. Yapılan simülasyonlarda %90'ın üzerinde doğrulukla tahmin yapılmış; bilinmeyen cihazlar için %95 dilim tahsis başarımları raporlanmıştır. Ek olarak, yük aşımı veya dilim arızası durumlarında ana dilim aracılığıyla bağlantılar kesintisiz sürdürülmüştür.

Wang *et al.* (2020), 5G makro ve mikro baz istasyonlarının konumlandırma problemini maliyet ve sinyal kapsamı açısından iki amaçlı karma tamsayılı doğrusal olmayan bir optimizasyon modeli ile ele almıştır. Önerilen yöntem, makro ve mikro baz istasyonlarının birlikte çalıştığı heterojen bir 5G ağı kurmayı hedeflemekte olup, minimum maliyet ve maksimum kapsama oranını dengeleyecek şekilde çözümler üretmektedir. Çalışmada, yer seçimi için örtüşen kapsama alanları dikkate alınarak kapsama tabanlı bir algoritma uygulanmış; çeşitli senaryolar altında beş örnek çözüm incelenmiştir. Bu senaryolar altında elde edilen çözümlerle hem bütçe sınırlamaları hem de QoS eşikleri göz önünde bulundurularak kapsamlı bir fayda-maliyet analizi gerçekleştirilmiş, en uygun kurulum planı belirlenmiştir.

Wang *et al.* (2020), çoklu erişim kenar bilişim destekli 5G ağlarında ağ dilimleme kapsamında kaynak tahsisi problemini derin pekiştirmeli öğrenme (DRL) çerçevesinde ele almıştır. Çalışmada, bir mobil sanal ağ işletmecisinin bant genişliği ve işlem gücü tahsisi kararlarını, kullanıcı dilim isteklerine ve QoS gereksinimlerine göre dinamik biçimde belirlemesi hedeflenmiştir. Bu amaçla derin deterministik politika eğimi (DDPG) algoritması kullanılarak sürekli eylem alanlarında politika güncellemesi yapılmıştır. Simülasyon sonuçları, önerilen algoritmanın hem toplam fayda açısından üstün performans gösterdiğini hem de kaynak kullanım verimliliğini artırdığını ortaya koymuştur.

Azimi *et al.* (2021), 5G radyo erişim ağlarında dilimleme bağlamında enerji verimliliğini artırmaya yönelik bir kaynak tahsis yöntemi önermiştir. Çalışmada, kullanıcıların ihtiyaç duyduğu güç ve kaynak bloklarının etkin şekilde belirlenmesi hedeflenmiş ve iletim gücü ile kanal koşulları dikkate alınarak enerji tasarrufu sağlanmıştır. Yapılan simülasyonlar, önerilen yaklaşımın enerji verimliliği, kullanıcı kabul oranı ve dilim izolasyonu gibi performans kriterlerinde mevcut yöntemlere kıyasla daha başarılı sonuçlar verdiğini ortaya koymuştur.

Boujelben (2021), 5G ağlarında farklı hizmet türlerine ait çoklu QoS taleplerinin karşılanmasına yönelik olarak, heterojen veri akışlarının etkin şekilde yerleştirilmesini sağlayan bir algoritma önermektedir. Önerilen yaklaşım, kaynak kullanımını en aza indirirken hizmet kalitesini korumayı amaçlamaktadır. Gerçek zamanlı uygulamalarda kullanılabilirliği test edilen bu yöntem, düşük kaynak fazlalığı ve yüksek çözüm doğruluğu ile dikkat çekmiş, 5G ağlarında kaynak yönetimi açısından umut verici sonuçlar ortaya koymuştur.

Guan *et al.* (2021) ise, 6G ağları bağlamında özelleştirilmiş dilimleme süreçlerine YZ tabanlı kaynak yönetimi entegrasyonunu önermiştir. Bu çalışmada DRL yöntemleri kullanılarak iki katmanlı bir kaynak yönetim çerçevesi geliştirilmiştir. Birinci katman, uzun vadeli gelir maksimizasyonu hedefiyle kaynak tahsisi kararlarını alırken, ikinci katman yerel düzeyde dilim adaptasyonları yaparak servis kalitesini sürdürmeyi hedeflemektedir.

Simülasyon sonuçları, önerilen yaklaşımın hem gelirleri artırmada hem de hizmet kalitesini korumada geleneksel yöntemlerden üstün olduğunu göstermektedir.

Liu *et al.* (2021), kitlesel IoT uygulamalarının gereksinimlerini karşılayabilecek bir çözüm olarak, 6G kapsamında kendini evrimleştiren ağlar kavramını önermektedir. Bu ağların, çevresel değişimlere karşı özerk algılama, karar verme ve yapılandırma yeteneklerine sahip olması gerektiği vurgulanmıştır. Çalışmada, görev aktarımı ve kaynak tahsisi gibi karmaşık yönetim süreçlerinin daha etkin yürütülebilmesi için dağıtık yaklaşımların önemi ele alınmış ve önerilen yöntemlerin kullanıcı deneyimi kalitesi ile yakınsama hızı açısından mevcut çözümlere kıyasla üstün performans sergilediği gösterilmiştir.

Xiao *et al.* (2021), 5G kullanıcılarının şebekede kalma süresini artırmak amacıyla, hibrit bir akıllı optimizasyon yöntemiyle 5G anten ışınlarının ayarlarını optimize eden kapsamlı bir sistem önermiştir. Çalışma; 5G kullanıcılarının 4G hücrelerine geçişini azaltmak ve kapsama boşluklarını gidermek için, zayıf kapsama alanlarını belirleyerek 5G baz istasyonlarının azimut, eğim açısı ve ışın genişliği gibi parametrelerini adaptif olarak optimize etmektedir. Önerilen yaklaşım, geleneksel yöntemlere kıyasla yerel minimumlardan kaçınma yeteneğini belirgin ölçüde artırmıştır. Simülasyon sonuçları, kentsel yollar ve yüksek binalı ortamlar gibi karmaşık senaryolarda performans göstergelerinde kayda değer iyileşmeler sağlandığını göstermiştir. Ayrıca, ortalama 5G kapsama süresinde %5.1'lik bir artış raporlanmıştır.

Shokrnezhad and Taleb (2022), bulut ve ağ kaynaklarının bütünleşik olarak yönetimine odaklanarak, 5G sonrası teknolojiler ortamında düşük gecikmeli hizmetler için iletişim ve hesaplama kaynaklarının birleşik tahsisine yönelik bir çözüm önermiştir. Çalışmada, kaynak yerleştirme, trafik önceliklendirme ve yönlendirme gibi faktörler dikkate alınarak, toplam maliyeti minimize etmeyi hedefleyen bir model geliştirilmiştir. Simülasyon sonuçları, önerilen çözümün yakınsal optimal sonuçlar sunduğunu ve hesaplama açısından verimli olduğunu göstermektedir.

Rasheed (2022), 5G tabanlı araçtan-her-şeye (V2X) haberleşmesinde güvenilirlik, gecikme ve veri oranı gibi QoS ihtiyaçlarını karşılamak üzere bir DRL algoritması önermiştir. Çalışma, araçtan araca iletişim (V2V) ve araçtan altyapıya iletişim (V2I) modları arasında dinamik seçim yapılmasını sağlayan Markov Karar Süreci ile formüle edilmiştir. V2V bağlantıları, trafik yoğunluğu, parazit seviyesi ve kanal koşullarına göre kendi kaynak bloğu, mod ve iletim gücünü belirleyen birer ajan olarak modellenmiştir. Çift zaman ölçekli öğrenme yapısı ile, büyük zaman ölçeğinde grafik tabanlı kümeler oluşturulmuş, küçük zaman ölçeğinde ise küme içinde federasyonlu öğrenme uygulanmıştır. Simülasyon sonuçları, önerilen yöntemin

diğer merkezi ve dağıtık algoritmalara göre daha düşük gecikme (0.2 ms) ve üç kat daha yüksek veri aktarım oranı (6 Gbps) sağladığını göstermiştir.

Ahmed *et al.* (2023), 6G V2V iletişim sistemlerinde, değişken kanal koşulları, hareketlilik ve yüksek girişim ortamları gibi zorlukları aşmak amacıyla yönlü antenler ile bütünleştirilmiş DRL tabanlı bir sistem modeli önermiştir. Önerilen sistem, hiyerarşik DRL mimarisi kullanarak, yüksek seviye ajanda ışın seçimi, alt seviye ajanda ise modülasyon-kodlama ayarlaması ve güç tahsisi işlemlerini optimize etmektedir. Ayrıca, Pareto tabanlı çok-amaçlı optimizasyon, gecikme, enerji tüketimi ve spektral verimlilik gibi metrikler arasında denge sağlamaktadır. Simülasyonlar, modelin özellikle güvenilirlik, gecikme, ve enerji tüketimi gibi alanlarda geleneksel 5G tabanlı yaklaşımlardan üstün olduğunu göstermiştir.

Khani *et al.* (2023), 5G bulut tabanlı radyo erişim ağı mimarisi içinde DRL algoritmalarının kaynak tahsisine uygulanmasını derinlemesine inceleyen sistematik bir literatür taraması gerçekleştirmiştir. Çalışma, güncel DRL algoritmalarını karşılaştırmalı olarak değerlendirmiş, algoritmaların QoS, enerji verimliliği ve kaynak kullanımındaki performanslarını örneklerle tartışmıştır. Ayrıca çalışmada DRL'nin bulut tabanlı radyo erişim ağı mimarisi içinde ölçeklenebilirlik, yakınsama, adalet ve güvenlik gibi zorlukları ve çözüm stratejileri detaylı biçimde sunulmuştur.

Shakya *et al.* (2023), 5G ağ dilimleme senaryolarında kaynak yerleştirme ve fiyatlandırma kararlarını incelemek üzere yeni bir ajan tabanlı simülasyon çerçevesi geliştirmiştir. Bu sistem, baz istasyonları, son kullanıcılar, dilimler, ağ operatörleri ve istemciler gibi çeşitli aktörleri bağımsız karar verici ajanlar olarak modellemektedir. Dilimlerin yerleştirilmesinde basit yük dengeleme, fiyatlandırmada ise klasik Q-learning tabanlı RL algoritması uygulanmıştır. Operatör ajanı, dilimlerin ağ durumu ve müşteri fayda fonksiyonu göz önünde bulundurularak optimum fiyat politikasını öğrenmektedir. Bu yapı, 5G ağlarında merkezi olmayan fiyatlandırma stratejileri ve karar destek sistemleri için ileri düzey modelleme imkânı sunmaktadır.

Shokrnezhad *et al.* (2023), gecikmeye duyarlı 5G ve ötesi hizmetleri için hem iletişim hem de bilişim kaynaklarının eşzamanlı tahsisini kapsayan birleştirilmiş kaynak tahsisi problemine odaklanmıştır. Bu kapsamda, hizmetlerin yerleştirilmesi, trafik önceliklendirmesi ve yol seçimi dahil olmak üzere çok katmanlı bir karar çerçevesi geliştirilmiştir. Problem, tam bilgiye sahip sistemler için kapasite ve gecikme kısıtları altında karma tamsayı doğrusal olmayan bir model olarak formüle edilmiştir. Kısmi bilgi senaryoları için ise, çift derin Q-öğrenme (DDQL) temelli bir mimari geliştirilmiş ve sistem kaynakları hakkında ön bilgi olmadan yakın optimal çözümlere ulaşıldığı gösterilmiştir. Simülasyon sonuçları, önerilen

mimarinin, yüksek oranda talepli ortamlarda bile kaynak tahsisinde gecikme, maliyet ve QoE açısından literatürdeki birçok yaklaşıma kıyasla üstün performans sunduğunu ortaya koymuştur.

Tufeanu *et al.* (2023), 5G ağlarında çok etmenli ortamlarda dilim yönetimi için YZ destekli bir model önermiştir. Bu model aktör-kritik yapılar kullanarak dilimlerin kaynak tahsisini gerçek zamanlı olarak optimize etmektedir. Yapılan deneysel çalışmalarda, bu yapının gecikmeyi %60'a kadar azalttığı, kaynak kullanımını ve QoS seviyelerini artırdığı gösterilmiştir. Bu sonuçlar, metodun geleneksel yöntemlere kıyasla çok daha etkili bir dilim yönetimi sunduğunu ortaya koymuştur.

Wang and Ferrús (2023), 5G radyo erişim ağlarında görev kritik ve ticari hizmetlerin aynı altyapı üzerinden güvenli şekilde sunulmasını sağlayan bir önceliklendirme ve dilimleme mekanizması geliştirmiştir. Simülasyon sonuçları, yalnızca önceliklendirme kullanan çözümlere kıyasla, düşük engellenme oranları, yüksek ortalama veri hızı elde edildiğini göstermektedir. Ayrıca önerilen yapı, ağ dilimleme kullanıldığında trafik izolasyonu sağlayarak ticari trafik performansını görev kritik trafik yoğunluğundan etkilenmeyecek şekilde korumaktadır.

Han and Wang (2024), 6G iletişim ağlarında cihaz ve hizmet çeşitliliğini dikkate alarak, kullanıcılar için farklılaştırılmış QoS sunumunu sağlamak amacıyla yeni bir kaynak tahsis çerçevesi önermişlerdir. Çalışmada, talep farkındalıklı önceliklendirme mekanizması ve çeşitlilik, eşitlik ve kapsayıcılık temelli bir metrik geliştirilmiştir. Kullanıcılar, hizmet türlerine göre özelleştirilmiş fayda modelleriyle değerlendirilmiş; ardından kapsayıcılık metriği kullanılarak ağ çapında kullanıcı memnuniyeti ortalaması ile kullanıcılar arası eşitsizlik (varyans) arasında denge kurulmuştur.

Kamruzzaman *et al.* (2024), cihazdan cihaza iletişim katmanları ile zenginleştirilmiş 3 katmanlı heterojen hücreli ağlarda girişim yönetimi için DRL algoritması geliştirmiştir. Çalışma, kaynak tahsisi, güç kontrolü ve mod seçimi gibi problemleri eş zamanlı optimize eden bir çözüm sunmaktadır. Simülasyon sonuçlarına göre önerilen DRL algoritması, klasik yöntemlere kıyasla %52,7'ye varan daha yüksek toplam veri aktarım hızı sağlamış ve ağ yoğunluğu arttıkça bile QoS gereksinimlerini başarıyla karşılamıştır.

Karuppiyan *et al.* (2024), 5G ağlarında dinamik kaynak tahsisi sorununu çözmek için geliştirdikleri modeli tanıtmışlardır. Bu hibrit modelde, evrişimli sinir ağı katmanları karmaşık ağ verilerinden anlamlı özellikler çıkarmak için kullanılırken, DDQL algoritması ise alınan bu özelliklere göre kaynak tahsisi kararları vermektedir. Model, gerçek zamanlı değişkenlere adaptasyon göstererek gecikme sürelerini en aza indirmiş, tahsis başarısını ve QoS skorlarını

iyileştirmiştir. MSE değeri 0.035, RMSE değeri 0.188 ve R^2 skoru %51.7 ile değerlendirilmiş; özellikle yüksek sinyal gücü duyarlılığı, düşük gecikme, daha iyi QoS ve karar hassasiyeti gibi özellikleriyle öne çıkmıştır. Modelin, klasik algoritmalarından daha dinamik ve ölçeklenebilir olduğu deneysel olarak gösterilmiştir.

Mbulwa *et al.* (2024), 5G ve sonrası mobil iletişim sistemlerinde el değiştirme süreçlerinin karmaşıklığını ele alarak, özellikle küçük hücre mimarisi ve yer-kara uydu ağlarının entegrasyonu ile artan hareketlilik yönetimi zorluklarına dikkat çekmişlerdir. Çalışmada, hem el değiştirme ölçüm aşamasında hem de karar verme aşamasında kendini optimize eden bir çerçeve önerilmiştir. Bu çerçeve, sinyal seviyesi, kanal kalitesi, kullanıcı ve baz istasyonu hareketliliği gibi çoklu kriterlere dayalı ölçümlerle el değiştirme kontrol parametrelerinin otomatik ayarlanmasını ve en iyi hedef baz istasyonunun seçimini optimize etmeyi amaçlamaktadır. Önerilen yaklaşım, farklı altyapı türleri (bulut, uç, sis ağları) üzerinde uygulanabilir olmasıyla altyapıdan bağımsız bir çözüm sunmakta ve 5G sonrası ağlarda QoE ve QoS iyileştirmelerine katkı sağlamaktadır.

Vilà *et al.* (2024), çok hücreli 5G ve sonrası radyo erişim ağı senaryolarında kaynak paylaşımı için önerilen RL çözümüne, yeni hücrelerin eklenmesi durumunda transfer öğrenme destekli bir yeniden eğitim mekanizması entegre etmiştir. Bu amaçla transfer RL tekniği önerilmiştir. Yapay sinir ağının girdi/çıkış katmanları hücre sayısına göre değiştiği için, ağırlıkların kısmi aktarımıyla yeni ortama adapte olunmaktadır. Gerçekleştirilen deneysel çalışmalar, transfer RL yönteminin klasik sıfırdan eğitimle kıyaslandığında eğitim süresini %54 ile %79 oranında azalttığını, performans açısından ise başarı oranlarının %95 ile %96 arasında değiştiğini göstermiştir.

Abba Ari *et al.* (2025), çalışmalarında 5G ve sonrası ağlarının gelişimiyle birlikte ortaya çıkan kaynak tahsisi ve dinamik ağ dilimleme gereksinimlerine odaklanmışlardır. Bu kapsamda, büyük veri setlerinin analizinde ve karar verme süreçlerinin iyileştirilmesinde YZ ve ML tekniklerinin rolünü ele almışlardır. Çalışma, özellikle RL, federe öğrenme ve meta-öğrenme gibi farklı öğrenme yaklaşımlarının 5G sonrası ağ ortamlarına entegrasyonuna yönelik zorlukları ve fırsatları incelemektedir. Makalede, mevcut yaklaşımların sınırlılıklarına dikkat çekilmiş; gelecekteki ağların verimliliğini artırmak amacıyla yeni algoritmaların geliştirilmesinin ve bu alandaki pratik uygulamaların yaygınlaştırılmasının gerekliliği vurgulanmıştır.

Kholidy (2025), açık 5G ağlarında güvenli ve dağıtık bir dilimleme yönetim modeli geliştirmiştir. Model, dilim barındırma kararlarını çok ölçütlü değerlendirme ile desteklemiş ve güvenli federe öğrenme yapısıyla güncellemeleri senkronize ederek saldırılara karşı dirençli

hale gelmiştir. Elde edilen sonuçlara göre %28,2'ye varan daha yüksek kabul oranı sağlamıştır. Ayrıca blockchain destekli, dağıtık ve güvenli bir federe öğrenme yapısı sunarak 5G alanındaki model güncellemelerini güvenli biçimde senkronize etmektedir. Akıllı sözleşmeler sayesinde sadece yüksek doğruluklu yerel modellerin güncellemeye katkı sağlamasına izin verilmiştir. Model, yüksek saldırı ortamlarında bile federe öğrenmeyi bozulmadan sürdürebilmektedir.

Mahmood and Rehman (2025), 5G ağlarında kaynak tahsis stratejisi seçim problemini bipolar fuzzy set yapısı altında ele alarak, tanjant trigonometrik bipolar bulanık toplama (birleştirme) operatörleri temelli çok nitelikli karar verme yaklaşımı geliştirmişlerdir. Bu kapsamda; dört farklı operatör tanımlanmış, her birinin monotonluk, idempotentlik ve sınırlıklık özellikleri matematiksel olarak ispatlanmıştır. Sunulan vaka çalışmasında dört strateji değerlendirilmiş tüm operatörlerde en yüksek skoru alan yöntem belirlenmiştir. Ayrıca çalışma, önerilen yaklaşımı mevcut yöntemlerle karşılaştırarak, özellikle negatif özelliklerin de dikkate alınması açısından üstünlük sağladığını ortaya koymuştur.

Metre *et al.* (2025), çalışmalarında 5G ve ötesi kablosuz ağlarda kanal kaynaklarının etkin kullanımını sağlamak için statik ve dinamik ağ dilimleme tekniklerini karşılaştırmalı olarak incelemiştir. Çalışma, dinamik ağ dilimleme kapsamında bant genişliği tahsisini sağlamak amacıyla yumuşak bilişim yöntemlerinin entegrasyonuna odaklanmıştır. Bu bağlamda 10 farklı dilimleme algoritması değerlendirilmiş; öncelik tabanlı, gecikme duyarlı ve melez yaklaşımlar gibi yöntemlerin performansları analiz edilmiştir. Elde edilen sonuçlar, özellikle öncelik tabanlı dilimleme algoritmasının hem QoS hem de kullanıcı deneyimi QoE açısından dengeli ve verimli bir kaynak tahsisi sunduğunu göstermektedir. Makale ayrıca, bant genişliği kullanım oranı, gecikme tatmini, adil dağıtım ve kullanıcı doyumunu gibi performans metriklerini kapsamlı biçimde değerlendirerek kâr maksimizasyonu sağlayabilecek ağ dilimleme stratejilerini ortaya koymaktadır.

Mushtaq *et al.* (2025), çok kullanıcı, çok hizmetli ve çok cihazlı 6G kablosuz ağlar için hizmet önceliği temelli kaynak tahsisi problemini çözmek amacıyla yeni bir yöntem önermiştir. Bu yöntem, kaynak tahsisini karmaşık bir tamsayı programlama problemi olarak ele almakta ve kullanıcı öncelikleriyle sistem kaynaklarını dengelemeyi hedeflemektedir. Çalışma, aktif ve operasyonel maliyetlerin yanı sıra kullanıcı önceliklerini göz önünde bulundurarak çok boyutlu bir fayda fonksiyonu tanımlar. Simülasyon sonuçları, önerilen yöntemin geleneksel dallan-sınırla ve gevşetme yöntemlerine göre %15–18 oranında daha yüksek hizmet ataması sağladığını göstermektedir.

Jyoti *et al.* (2025), 5G radyo erişim ağlarında dinamik kaynak tahsisi problemini çözmek için farklı optimizasyon algoritmalarının güçlü yönlerini birleştirerek önerdikleri ağ koşullarına

göre adaptif davranabilen bir kaynak tahsisi modeli sunmuştur. Optimizasyon hedefi, hem ortalama veri aktarım oranını maksimize etmek hem de sinyal kaybını minimize etmektir. Simülasyonlar, veri aktarım oranı ve sinyal kaybı açısından önemli performans iyileştirmeleri sağlandığını göstermektedir.

Tez Kapsamında Yürütülen Yayınlar

Bu tez kapsamında, bir uluslararası dergi makalesi ve bir konferans bildirisi yayımlanmıştır:

1. Aktaş *et al.* (2023)

Bu bildiri, 5G altyapı yatırımlarını hangi hizmet noktalarında başlatması gerektiğini belirlemek amacıyla Analitik Hiyerarşi Süreci (AHP) kullanılarak kriter ağırlıklarının tespit edildiği ve İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS) metoduyla alternatif hizmet noktalarının önceliklendirildiği bir çok kriterli karar verme çerçevesi geliştirilmiştir.

2. Çodur *et al.* (2024)

Bu makale, 5G geçiş sürecinde hangi hizmet noktalarına öncelik verilmesi gerektiğini belirlemek amacıyla Tam Tutarlılık Yönetmi (FUCOM) ve Kosinüs Benzerliği yöntemlerini bütünleştiren yenilikçi bir model sunmaktadır. Çalışmanın katkısı, karar verici uzmanların sezgisel değerlendirmelerini sayısal analizle birleştiren çok kriterli bir karar verme çerçevesi oluşturmasıdır.

Araştırmanın Yenilikçi Yönleri

Eğitim hedefi: Literatürdeki modeller genel olarak veri hızı, gecikme süresi veya hizmet kalitesi QoS gibi performans metriklerini maksimize etmeye çalışmaktadır. Bu çalışma ise öznitelik ağırlıkları üzerinden sıralama korelasyonunu öğrenen bir YZ modeli olması bakımından literatürdeki örneklerden farklıdır.

Girdi Özellikleri: Literatürdeki çalışmalar genellikle sabit veri setleri veya simülasyon çıktıları üzerinden çalışmaktadır. Tezde yürütülen çalışmamızda ise bazı özellikler (nüfus artışı ve konut gelişimi) deneysel dağılımlarla trafik ortamı ve ilçe düzeyinde stokastik verilerden üretilmektedir. Böylece model gerçek dünyaya benzer bir varyasyonla çalışmaktadır, bu da modelin genellenebilirliğini artırır. Ayrıca bu tez kapsamında yürütülen çalışmalar dışında, saha bazlı sıralamaların ele alındığı bir başka çalışmaya literatürde rastlanmamaktadır.

Ödül Yapısı: Literatürdeki çalışmalarda modeller tek bir kritere göre model ödüllendirilirken, çalışmada hedefimiz uzman sıralamalarıyla olan korelasyonu artırmaktır.

Korelasyonda yapılan iyileştirilmeler ödüllendirilmektedir. Ajanların belirlediği ağırlıkların çeşitliliği (entropi) teşvik edilerek keşif artmaktadır. Bu çok bileşenli ödül yapısı sayesinde, performans iyileştirilirken keşif – istikrar dengesi de sağlanır.

Ortam Yapısı: Genellikle YPO ortamları tek ajanlı olurken, bu çalışmada her ajan farklı ağırlık setleriyle öğrenir. Bu yaklaşım öğrenme sırasında çeşitliliği artırır. Bu sayede model öğrenme sırasında çeşitliliği artırır, aşırı uyum (overfitting) riskini azaltır ve kollektif karar yetkisini güçlendirir.

Öğrenme Stratejisi: Çalışmada ajan ağırlıkları her adımda kontrollü olarak güncellenir. `update_min`, `update_max`, `weight_min`, `weight_max` gibi sabitlerle ağırlık mutasyonları sınırlandırılmıştır. Bu sayede, model öğrenme sürecinde gelişimi güzel, ani ve dengesiz değişikliklerden kaçınırken, her adımda stabiliteyi korur.

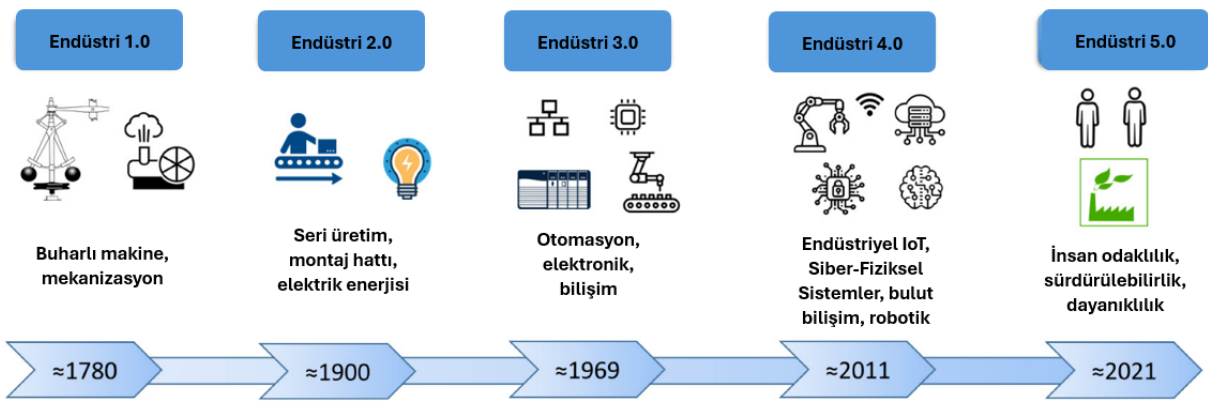
Veri Kaynağı: Çalışmada telekomünikasyon şirketinden alınmış Mersin iline ait gerçek saha verileri kullanılmaktadır. Bu durum modelin çıktılarının gerçek dünya ile uyarlabilirliğini artırır. Literatürde çoğunlukla kullanılan ortamların sınırlılıklarını aşar ve veriye dayalı politika öğrenimi açısından güçlü bir yapıya sahiptir.

5G İletişim Teknolojisi

Beşinci nesil kablosuz iletişim teknolojisi olan 5G, selefi 4G'ye kıyasla çok daha yüksek hızlar, düşük gecikme süreleri ve büyük cihaz kapasitesi sunmayı hedefleyen kapsamlı bir ağ dönüşümüdür. 5G, yeni radyo erişim teknolojisi sayesinde 4G'nin yaklaşık 10 katı hız kapasitesine ulaşabilmektedir. Bunun yanı sıra 4G'ye kıyasla 4-5 kat daha düşük gecikme değerleri elde edilebilmektedir (Chávez-Santiago *et al.*, 2015; Anonymous, 2023). Bu iyileştirmeler, URLLC gerektiren uygulamalarda (ör. otonom araç kontrolü, uzaktan cerrahi) ve gerçek zamanlı geri bildirim zorunlu senaryolarda 5G'yi kritik bir teknoloji haline getirmektedir (Varga *et al.*, 2020). Ayrıca 5G ağları, mmWave gibi daha önce mobil iletişimde kullanılmamış yüksek frekans bantlarını da kullanıma açarak çok geniş bant genişlikleri sağlamaktadır (Sag, 2025). Bu yüksek frekanslar sayesinde veri kapasitesi ve hızlar katlanarak artarken, küçük hücre yapılanması ile kapsama sağlanması gereği ortaya çıkmıştır. Çünkü mmWave sinyallerin menzili kısa olup yapı duvarlarına penetrasyonu zayıftır; bu nedenle 5G mimarisi makro hücrelerin yanı sıra yoğun küçük hücre dağıtımlarını ve ışın oluşturma ile çoklu anten teknolojilerini entegre ederek kapsama alanını ve veri iletim kapasitesini artırır.

5G'nin getirdiği yeniliklerden biri de şebeke dilimleme ve sanallaştırma gibi esnek ağ mimarileriyle çalışmasıdır. 5G çekirdek şebekesi, önceki nesillerden farklı olarak yazılım tanımlı ağ ve ağ fonksiyon sanallaştırması prensipleri üzerine inşa edilmiştir. Bu sayede tek bir

fiziksel altyapı üzerinde birden fazla sanal alt-ağ (dilim) oluşturularak her birinin farklı hizmet gereksinimlerine göre özelleştirilmesi mümkündür (Varga *et al.*, 2020). Bu mimari esneklik 5G'yi farklı sektör ve kullanım senaryolarının tek bir birleşik platform üzerinden karşılanmasına imkân tanıyan bir teknoloji haline getirmektedir. Endüstri 4.0 ve 5.0 süreçlerinde yeni nesil haberleşme altyapıları önemli bir rol üstlenmekte; bu bağlamda 5G, dijitalleşme, otomasyon ve IoT gibi bileşenlerin uygulanmasını mümkün kılarken, aynı zamanda Endüstri 4.0 sonrası dönemde şekillenen insan merkezli, sürdürülebilir ve esnek üretim modellerinin hayata geçirilmesinde de kritik bir etkinleştirici olarak konumlanmaktadır (Rao and Prasad, 2018). Şekil 4'te Endüstri 1.0'dan 5.0'a kadar olan dönemler kronolojik olarak sunulmuş; her bir endüstri devriminde öne çıkan teknolojik ilerlemeler görselleştirilmiştir.



Şekil 4. Endüstri 1.0'dan 5.0'a Sanayi Devrimlerinin zaman çizelgesi ve temel özellikleri. (Folgado *et al.*, 2024)

5G'nin teknik özellikleri sadece hız ve gecikme ile sınırlı değildir. Aynı zamanda cihaz yoğunluğu ve enerji verimliliği alanlarında da büyük iyileştirmeler sunar. Standartlara göre 5G, kilometrekare başına 1 milyon cihaz bağlantısını destekleyebilecek şekilde tasarlanmıştır ki bu sayı 4G'nin destekleyebildiğinden yaklaşık 100 kat fazladır. Bu sayede IoT teknolojisinde ihtiyaç duyulan aşırı uç cihaz yoğunluğu da 5G ile karşılanabilecektir (Varga *et al.*, 2020). Benzer şekilde, 5G ağlarının birim veri başına enerji tüketimi de önemli ölçüde azaltılmış olup 4G'nin gerektirdiği enerji miktarının yaklaşık %10'u seviyesine indirgenmiştir (Anonymous, 2023). Bu performans iyileştirmeleri, 5G'yi sadece bir mobil genişbant teknolojisi değil, aynı zamanda kritik altyapılar için güvenilir bir haberleşme omurgası haline getirmektedir (Varga *et al.*, 2020).

Sonuç olarak, 5G iletişim teknolojisi; yüksek veri hızı, düşük gecikme, yüksek bağlantı yoğunluğu ve güvenilirlik alanlarındaki üstün performansı ile, günümüz ve gelecek dijital uygulamalarının omurgasını oluşturacak şekilde tasarlanmıştır. Gerek bireysel mobil genişbant deneyimini geliştirmesi, gerekse akıllı şehirler, otonom sistemler ve Endüstri 4.0 gibi geniş ölçekli alanlara yayılması sayesinde 5G, bir önceki nesil iletişim altyapılarının sınırlarını

ortadan kaldırmaktadır. (Rao and Prasad, 2018;Varga *et al.*, 2020). Özellikle sanayi ve imalat sektörlerinde, gerçek zamanlı veri alışverişi ve otomasyon gereksinimleri düşünüldüğünde, 5G'nin mevcut iletişim teknolojilerinin eksikliklerini gideren birleştirici bir platform sunduğu vurgulanmaktadır (Rao and Prasad, 2018).

Endüstri 4.0 ve Yeni İletişim Teknolojilerinin Rolü

Endüstri 4.0, üretim endüstrisinde otomasyon ve veri alışverişine dayalı dördüncü büyük devrimi tanımlayan kavramdır. Bu kavram ilk olarak Almanya'da ortaya atılmış ve endüstriyel üretimin dijital dönüşümünü ifade etmektedir. Endüstri 4.0'ın temel vizyonu, "akıllı fabrika" (smart factory) kavramını gerçeğe dönüştürmektir. Akıllı fabrikalarda fiziksel süreçler siber-fiziksel sistemler (CPS) tarafından sürekli izlenir, fiziksel dünyanın sanal bir kopyası oluşturulur ve bu sistemler merkezi olmayan kararlar alabilir (Vaidya and Ambad, 2018; Culot *et al.*, 2020). Bu sayede üretim sistemleri, sadece birbirine bağlanmış olmaktan öteye geçip, toplanan verileri kendi aralarında iletişim kurarak analiz eden ve bu bilgilerden çıkarımlar yaparak otonom aksiyonlar alan bir yapıya kavuşur (Rao and Prasad, 2018). Endüstri 4.0, IoT, YZ ve ML, robotik ve otonom sistemler, bulut ve uç bilişim, büyük veri analitiği ve artırılmış gerçeklik gibi birçok gelişen teknolojinin entegre şekilde kullanılmasını içerir. Bu yönüyle, Endüstri 4.0 tek bir yeni teknoloji değil, çok sayıda farklı teknolojinin bütünleşik ve eşgüdümlü kullanımına dayanan bir paradigmadır (Folgado *et al.*, 2024). Tüm bu bileşenlerin ve üretilen verinin operasyonel faydaya dönüşebilmesi ise yüksek performanslı bir iletişim altyapısının varlığına bağlıdır.

Bağlantı, Endüstri 4.0'ın temel bir gereksinimidir. Mevcut endüstriyel tesislerde yaygın olarak kullanılan Wireless Fidelity (Wi-Fi) gibi kablosuz teknolojiler, özellikle uzak ve hareketli cihazların bulunduğu IoT uygulamalarında gereken geniş kapsama alanını ve yüksek güvenilirliği her zaman sağlayamamaktadır (Lekshmi, 2023). Öte yandan, geleneksel kablolu iletişim yöntemleri yeni ekipmanların entegrasyonunda yüksek kurulum maliyeti getirmekte ve cihazların fiziksel kablolarla bağlı olmasından ötürü esneklik kısıtları yaratmaktadır; bu nedenle tamamen kablolu bir altyapı Endüstri 4.0'ın dinamik ve esnek yapısı için uygun görülmemektedir. Bunun yerine, endüstriyel tesislerde ister sabit ister hareketli olsun tüm ekipman ve sensörlerin kesintisiz şekilde haberleşebilmesini sağlamak amacıyla gelişmiş kablosuz iletişim teknolojileri ön plana çıkmaktadır (Vitturi *et al.*, 2019).

Bu nedenle hücreli haberleşme altyapıları kritik bir rol oynamaktadır. Özellikle 4G/5G gibi hücreli teknolojiler, geniş alanlara yayılan çok sayıda cihazın yüksek bant genişliğiyle kablosuz olarak birbirine bağlanabilmesi potansiyeliyle dikkat çekmektedir. Endüstriyel Nesnelerin İnterneti (IIoT) uygulamalarında amaç, genellikle düşük donanım maliyetine ve

kısıtlı enerji kaynağına sahip binlerce sensör ve cihazın ağa dahil edilmesi ve bunun gecikme, güvenilirlik gibi kritik gereksinimleri karşılayacak şekilde gerçekleştirilmesidir. Bu ihtiyaçları karşılamak, IIoT'nin yaygın şekilde hayata geçirilmesi için kilit bir zorluktur ve yeni nesil iletişim teknolojileri bu noktada devreye girmektedir (Sisinni *et al.*, 2018).

Nitekim Endüstri 4.0 vizyonunda fabrikalardaki sensörler, makineler ve insan operatörler IIoT aracılığıyla birbirine kesintisiz bağlanarak gerçek zamanlı veri alışverişi yapabilmektedir. Bu sayede üretim süreçlerinin optimizasyonu, kalite kontrolü ve kestirimci bakım gibi uygulamalar mümkün hale gelerek imalatta esneklik ve verimlilik artışı sağlanmaktadır. Başka bir deyişle, fiziksel dünyadaki süreçlerin dijital bir ağ üzerinden anlık olarak izlenmesi ve yönetilmesi, Endüstri 4.0'ın merkezinde yer almaktadır (Lundgren *et al.*, 2022).

Bu gereksinimleri desteklemek üzere son dönemde geliştirilen yeni iletişim teknolojileri, Endüstri 4.0'ın en önemli kolaylaştırıcıları olarak görülmektedir. Özellikle 5G mobil iletişim ağları, endüstriyel iletişimde güvenilir ve gerçek zamanlı veri iletimini mümkün kılan kritik bileşenlerdir (Singh *et al.*, 2023). Bu sayede çok sayıda endüstriyel makine ve cihaz internete bağlanarak üretim hatlarının daha hızlı, esnek ve duyarlı hale gelmesi mümkün olmaktadır.

Yeni iletişim teknolojileri içinde özellikle 5G öne çıkmaktadır. 5G teknolojisi, önceki nesil hücreli şebekelere kıyasla çok daha yüksek hız, daha geniş kapasite ve çok daha düşük gecikme sunacak şekilde tasarlanmıştır. Bu sayede 5G, yalnızca geleneksel mobil genişbant hizmetlerini hızlandırmakla kalmayıp, aynı zamanda büyük ölçekli makineler arası iletişim servislerini de destekleyebilmektedir. Bu nedenle 5G makineler, sistemler ve cihazlar arasında kesintisiz veri alışverişi gerçekleştirebildiğinden, Endüstri 4.0 odaklı akıllı üretim uygulamaları için ideal bir çözüm konumuna gelmektedir (Agiwal and Saxena, 2016).

Sonuç olarak, Endüstri 4.0'ın başarısı, yeni nesil iletişim teknolojilerinin endüstriyel ortamlara entegre edilmesine bağlıdır. Bu nedenle 5G başta olmak üzere gelişmiş kablosuz ağların yaygınlaştırılması ve bu ağların etkin bir şekilde planlanıp yönetilmesi, dijital dönüşümün gerektirdiği bağlantı ihtiyacını karşılamak için kritik bir rol oynamaktadır.

Türkiye'de Endüstri 4.0 ve 5G Uygulamaları

Her ne kadar Endüstri 4.0 ve 5G teknolojileri küresel ölçekte yaygınlaşmaya başlamış olsa da, bu dönüşüm gelişmiş ve gelişmekte olan ülkeler açısından farklı dinamiklerle ilerlemektedir. Türkiye gibi gelişmekte olan ülkelerde, Endüstri 4.0'a geçiş süreci yalnızca teknolojik değil, aynı zamanda kurumsal, altyapısal ve beşerî sermaye ile ilgili çok boyutlu bir

dönüşüm gerektirmektedir (Gülseren and Sağbaş, 2019). Özellikle dijital altyapı eksiklikleri, iletişim şebekelerinde bölgesel eşitsizlikler ve sanayide teknoloji adaptasyonunun sınırlı olması bu sürecin önündeki temel engeller arasında yer almaktadır (Zielinski, *et al.*, 2019).

Türkiye’de son yıllarda yapılan yatırımlarla 5G’ye geçiş çalışmaları hız kazanmış, test ağları kurulmuş ve yerli teknolojilere öncelik verilerek sahada pilot uygulamalar başlatılmıştır. Ancak ticari düzeyde 5G uygulamaları henüz sınırlı bölgelerde ve özel projeler kapsamında yürütülmektedir (Özaktaş and Ardıyok). Bu durum, teknolojik planlamaların bölgesel önceliklendirme ve kaynak planlanması çerçevesinde yapılmasını zorunlu kılmaktadır. Özellikle 5G altyapısının kurulacağı sahaların önceliklendirilmesi, sınırlı kaynakların en etkili şekilde kullanılması açısından kritik önem taşımaktadır. Bu noktada, ABM ve RL gibi veri odaklı karar destek modelleri, sahaya özel çözümler üretilmesini ve altyapı planlamasında dinamik ve öğrenen yapılar geliştirilmesini mümkün kılmaktadır.

MATERYAL ve METOT

Veri Seti ve Özellikleri

Bu çalışmada kullanılan veri seti, Türkiye’de faaliyet gösteren bir telekomünikasyon şirketinden temin edilen saha bazlı ölçüm verilerinden oluşmaktadır. Kullanılan veri kümesi Mersin iline ait altyapı metriklerini içermektedir. Tablo 2’ de operatör çalışanı olan Ar-Ge uzmanlarının sıralama için kullanmamızı ön gördüğü ölçümler bulunmaktadır. Bu veriler Rastgele Orman tabanlı Shapley Katkısız Açıklamaları (SHAP) algoritması kullanılarak 5 adet deterministik veriye indirilmiştir. Ardından geleceği daha iyi modelleyebilmek adına sahaya ait nüfus artışı ve konut gelişme oranı stokastik olarak deneysel dağılım uyumu incelenerek, modele dahil edilmiştir. Bu modelin gerçek dünyaya daha uygun hareket etmesini aynı zamanda 5G’nin ötesini modellerken şirkete destek sağlayacaktır.

Söz konusu veri kümesi, telekomünikasyon sahalarına ait çok boyutlu özellikleri içeren kapsamlı bir yapıya sahiptir. Öznitelik adlarının başında yer alan kısaltmalar, ait oldukları veri grubunu ifade eden sistematik bir etiketleme yaklaşımını yansıtmaktadır. Örneğin, “NET” ile başlayan öznitelikler, baz istasyonlarının şebeke performansı ve kullanım düzeyine ilişkin teknik ölçümleri (örneğin tahsis edilen bant genişliği, LTE veri hacmi, PRB kullanım oranı) kapsamaktadır. “REV” ön ekiyle tanımlanan öznitelikler ise gelir istatistikleri ve taşınabilir internet kullanıcıları gibi ekonomik ve abone bazlı göstergeleri içermektedir. “G5” ile başlayan değişkenler, 5G’ye ilişkin aday ve mevcut kullanıcı verileri, 5G veri tüketimi ve trafiği gibi yeni nesil iletişim teknolojilerine dair ayrıntılı bilgileri temsil etmektedir. Hizmet kalitesi, hız testleri ve sinyal gücü gibi parametreleri içeren metrikler “QOS” etiketiyle gösterilmiş; bu başlık altında kullanıcı bazlı indirme ve yükleme hızları, ortalama RSRP, SINR ve RSRQ gibi göstergelere yer verilmiştir.

Veri setinde ayrıca istasyonun bulunduğu fiziksel ve yapısal çevreyi tanımlamak amacıyla “GEO” ve “POI” etiketli öznitelikler kullanılmıştır. GEO grubu, bina türleri, kat sayıları ve toplam yapı hacimleri gibi mekânsal verileri içerirken, POI grubu kamu kurumları, sağlık kuruluşları, eğitim yapıları, ulaşım altyapıları ve ticari merkezler gibi kritik kentsel noktaların sayısal dağılımını temsil etmektedir. “ROAD” etiketi ise bölgedeki yol türlerine göre toplam uzunluk bilgilerini içeren altyapı verilerini sınıflandırmakta; yerel sokaklardan otoyollara kadar farklı yol kategorileri bu grup altında tanımlanmaktadır. Roaming (dolaşım) verileri ise “ROAM” etiketiyle temsil edilmekte olup, dolaşımdaki kullanıcı sayısı ve veri tüketimini içermektedir. Diğer yandan, “ENV”, “LOC” ve “ID” gibi temel etiketler, sırasıyla trafik ortamı tipi, coğrafi konum (ilçe) ve istasyon tanımlayıcılarını belirtmektedir. Tüm bu

niteliklere ek olarak, saha uzmanlarının deęerlendirmelerine dayalı olarak oluřturulan RANK_01 adlı deęiřken, her bir istasyonun öncelik düzeyini 1 ile 576 arasında deęiřen sıralı bir deęerle temsil etmektedir. Verilerin eęitim sürecine hazırlanmasında RobustScaler kullanılarak aykırı deęerlerin etkisi minimize edilmiřtir.

Tablo 2. Ar-Ge Uzmanları Tarafından Kullanılması Öngörülen Veriler

Öznitelik Adı	Açıklama	Birim
Temel Bilgiler		
ID_01	Baz istasyonunun adı	-
ENV_01	Trafik yoğunluęuna göre bölge sınıflandırması	-
LOC_01	İstasyonun bulunduęu ilçe	-
Şebeke Performansı ve Kullanımı		
NET_01	Tahsis edilen bant genişlięi	MHz
NET_02	Downlink (İndirme) Fiziksel Kaynak Blok Kullanım Oranı (medyan)	%
NET_03	Kullanıcı ekipmanı (UE) aęırlıklı Downlink PRB (Fiziksel Kaynak Bloęu - Physical Resource Block) Kullanım Oranı (medyan)	%
NET_04	VoLTE (Voice over LTE) trafik yoğunluęu (medyan)	Erlang
NET_05	3G trafik yoğunluęu (medyan)	Erlang
NET_06	LTE veri hacmi (medyan)	GB
NET_07	Tařınabilir internet kullanıcı hizmetinin tükettięi veri hacmi	GB
NET_08	3G veri hacmi	GB
Gelir ve Kullanıcı İstatistikleri		
REV_01	Mobil gelir gerçekleřen tutar	TL
REV_02	Tařınabilir internet kullanıcı sayısı	Adet
REV_03	Tařınabilir internet hizmetindeki azalma	Adet
5G İliřkili Metrikler		
G5_01	5G aday müřterilerin veri kullanımı	GB
G5_02	5G aday müřterilerin trafięi (İndirme/Yükleme)	GB
G5_03	5G'ye sahip müřterilerin veri kullanımı	GB
G5_04	5G'li müřterilerin trafięi	GB
G5_05	5G'siz müřterilerin veri kullanımı	GB
G5_06	5G'siz müřterilerin trafięi	GB
Hız Testi ve Kalite Metrikleri		
QOS_01	Kullanıcı Bazlı Medyan İndirme Hızı	kbps
QOS_02	Kullanıcı Bazlı Medyan Yükleme Hızı	kbps
QOS_03	Ortalama RSRP (Referans Sinyal Alma Gücü)	dB
QOS_04	Ortalama RSRQ (Referans Sinyal Kalite Oranı)	dB
QOS_05	Ortalama SINR (Sinyal-Gürültü Oranı)	dB
QOS_06	Toplam indirme hacmi	GB
Coęrafi ve Yapısal Veriler		
GEO_01	Belirli kategoriye girmeyen dięer bina türlerinin sayısı	Adet
GEO_02	Okul, lise, kolej gibi eęitim binalarının sayısı	Adet

Tablo 2. (devamı)

GEO_03	Konferans, toplantı, etkinlik alanlarının sayısı	Adet
GEO_04	Cami, kilise, sinagog gibi dini yapıların sayısı	Adet
GEO_05	Valilik, kaymakamlık, emniyet gibi kamu kurum binalarının sayısı	Adet
GEO_06	Konut olarak kullanılan bina sayısı (apartman, müstakil ev vb.)	Adet
GEO_07	Liman yapıları veya liman destek binalarının sayısı	Adet
GEO_08	Otel, motel gibi konaklama tesislerinin sayısı	Adet
GEO_09	Ofis plazalarının sayısı	Adet
GEO_10	Rezidans tipi yüksek standartlı konutların sayısı	Adet
GEO_11	Hastane, klinik, sağlık ocağı gibi tesislerin sayısı	Adet
GEO_12	Fabrika, atölye gibi sanayi tesislerinin sayısı	Adet
GEO_13	Kapalı spor salonu, kompleks vb. yapıların sayısı	Adet
GEO_14	Stadyum yapılarının sayısı	Adet
GEO_15	Otobüs, tren vb. ulaşım terminal binalarının sayısı	Adet
GEO_16	Alışveriş merkezi, market, mağaza gibi yapılar	Adet
GEO_17	Müze, kültürel miras, turistik merkez yapıları	Adet
GEO_18	Üniversite kampüs binaları	Adet
GEO_19	Yukarıdaki tüm kategorilere ait bina sayısının toplamı	Adet
GEO_20	Bölgedeki en yüksek binanın kat sayısı	Kat
GEO_21	Tüm binaların ortanca (medyan) kat sayısı	Kat
GEO_22	Binaların hacimlerinin toplamı	Metreküp (m ³)
POI_01	Mağaza, AVM, market gibi alışveriş noktalarının sayısı	Adet
POI_02	Kışla, askeri üs vb. askeri yapıların sayısı	Adet
POI_03	Tren garı, istasyon veya raylı sistem bağlantı noktaları	Adet
POI_04	İskele, liman gibi deniz ulaşımı noktaları	Adet
POI_05	Cami, kilise, sinagog gibi ibadethaneler	Adet
POI_06	Okul, üniversite, kurs merkezi vb.	Adet
POI_07	Sinema, tiyatro, eğlence parkı vb.	Adet
POI_08	Elektrik santrali, trafo, dağıtım merkezi	Adet
POI_09	Banka, ATM, finans kuruluşu	Adet
POI_10	Havalimanı, havaalanı veya hava ulaşım noktası	Adet
POI_11	Otoyol, ana arter bağlantı noktası gibi ulaşım altyapısı	Adet
POI_12	Konut bölgeleri, toplu konut siteleri	Adet
POI_13	Kütüphane, kültür merkezi, müze vb.	Adet
POI_14	Diğer önemli yerler (coğrafi veya yön bulma açısından önemli)	Adet
POI_15	Belediye, kaymakamlık, nüfus müdürlüğü vb.	Adet
POI_16	Hastane, sağlık ocağı, poliklinik	Adet
POI_17	Fabrika, organize sanayi bölgesi vb.	Adet
POI_18	Dernek, vakıf, oda vb. kuruluşlar	Adet

Tablo 2. (devamı)

POI_19	Huzurevi, sosyal hizmet binası, yardım kuruluşu	Adet
POI_20	Spor salonu, stadyum, antrenman alanı	Adet
POI_21	Atıksu arıtma, su deposu, çöp toplama noktası vb.	Adet
POI_22	Seralar, çiftlikler, tarım alanları	Adet
POI_23	Müze, ören yeri, anıt vb.	Adet
POI_24	Baz istasyonu, haberleşme altyapısı noktaları	Adet
POI_25	Ticari plaza, dükkanlar, iş merkezleri	Adet
POI_26	Restoran, kafe, fast-food zincirleri	Adet
POI_27	Park, bahçe, mesire alanı gibi açık alanlar	Adet
ROAD_01	Şehir içi ana ulaşım koridorları	Metre
ROAD_02	Geniş, ağaçlıklı ve genellikle merkezi bölgelerdeki bulvarlar	Metre
ROAD_03	Mahalle aralarındaki veya ticari bölgelerdeki orta ölçekli caddeler	Metre
ROAD_04	Şehirler arası bağlantı sağlayan devlet karayolları	Metre
ROAD_05	Siteler, sanayi bölgeleri gibi özel alanların iç yolları	Metre
ROAD_06	İl sınırları içinde bakımı il yönetimince yapılan yollar	Metre
ROAD_07	Köy yerleşimlerine hizmet veren dar yollar	Metre
ROAD_08	Toplu konut siteleri içindeki özel yollar	Metre
ROAD_09	Yüksek hızlı, çok şeritli otoyollar	Metre
ROAD_10	Otoyollara erişim sağlayan bağlantı yolları.	Metre
ROAD_11	Yerel erişim için kullanılan dar sokaklar.	Metre
Roaming ve Arka Plan Verileri		
ROAM_01	Roaming veri hacmi (Yükleme/İndirme).	GB
ROAM_02	Roaming kullanıcı sayısı	Adet
G5_07	Rakip operatörlerin 5G test sayısı	Adet
G5_08	Firmanın 5G test sayısı	Adet
Sınıflandırma verileri		
RANK_01	Uzman değerlendirmesine göre istasyon sıralaması	Sıra değeri

Özellik seçimi

Bu çalışmada veri ön işleme, model eğitimi ve özellik seçimi adımlarını içeren bir metodoloji izlenmiştir. Veri %80 eğitim – %20 test olarak ayrılmıştır. Özniteliklerin önem derecelerini belirlemek amacıyla, Rastgele Orman (Random Forest) algoritması kullanılarak regresyon modeli eğitilmiştir. Modelin yorumlanabilirliğini artırmak için, her bir özneliğin hedef değişkene olan katkısı SHAP yöntemi ile analiz edilmiştir. Rastgele Ormanlar, çok sayıda karar ağacının rasgele alt kümeler ve örnekler üzerinde eğitilmesi esasına dayanan bir yöntemdir. Bu topluluk modeli, bireysel ağaçların başarısını ve korelasyonunu birleştirerek yüksek genel başarı sağlar. Dahili hata tahminleri ve ağaçların ortaklığı kullanılarak her özneliğin önemli olup olmadığı belirlenebilir (Breiman, 2021).

Farklı regresyon algoritmalarının SHAP tabanlı öznitelik seçimi üzerindeki etkilerini değerlendirmek amacıyla, Destek Vektör Makineleri (SVM), Gradyan Güçlendirme Makineleri (GBM), Çok Katmanlı Algılayıcı (MLP Regressor), Lasso Regresyon ve Rastgele Orman modelleri ayrı ayrı eğitilmiş ve her biri için SHAP değerleri hesaplanmıştır. Elde edilen sonuçlara göre, en yüksek sıralama doğruluğu %88 Spearman korelasyon katsayısı ile Rastgele Orman modelinden elde edilmiştir. Bu nedenle, öznitelik seçiminde Rastgele Orman temelli SHAP çıktıları esas alınmıştır. Rastgele Orman modeli, veri setindeki doğrusal olmayan ilişkileri ve öznitelikler arası etkileşimleri etkili bir biçimde yakalayabildiği için, diğer modellere göre daha iyi ve anlaşılır sonuçlar üretmiştir. Bu durum, YPO temelli pekiştirmeli öğrenme ortamına daha anlamlı ve etkili bir öznitelik temsili sağlanmasına olanak tanımıştır.


SHAP ile Model Açıklama

SHAP, ML modellerinin tahminlerini açıklamak amacıyla oyun teorisindeki Shapley değerlerine dayanan bir açıklayıcı YZ yöntemidir. Shapley değeri, 1953 yılında Lloyd Shapley tarafından koalisyon oyunlarında her oyuncunun toplam kazanç üzerindeki adil katkısını belirlemek amacıyla geliştirilmiştir (Shapley,1953). Bu yaklaşım, bir özelliğin model tahminine katkısını, tüm olası özellik kombinasyonları içindeki marjinal katkıların ağırlıklı ortalaması olarak hesaplar. Lundberg and Lee (2017), bu teorik temeli kullanarak SHAP yöntemini geliştirmiş ve özellikle karmaşık yapay öğrenme modellerinin karar mekanizmalarını şeffaflaştırmak için uygulamaya sunmuştur. SHAP yöntemi, bir modelin tek bir gözlem için yaptığı tahmine her özelliğin ne ölçüde katkı sağladığını sayısal olarak ortaya koyar. Böylece modelin iç işleyişi hem lokal (bireysel örnek düzeyinde) hem de global (genel model davranışı düzeyinde) açıklanabilir hale gelir.

Bu çalışmada, SHAP analizinden yalnızca özellik seçimi amacıyla yararlanılmıştır. Eğitilen Rastgele Orman modeli üzerinden her bir öznitelik için SHAP değerleri hesaplanmış; bu değerlerin mutlak ortalamaları alınarak her değişkenin sıralama tahmini üzerindeki göreceli katkı düzeyi belirlenmiştir. Elde edilen sonuçlar doğrultusunda, modele en fazla etki eden değişkenler ön plana çıkarılmış ve özellik seçim sürecinde karar destekleyici bir araç olarak kullanılmıştır.

SHAP analizi sayesinde, karmaşık modellerin “kara kutu” niteliği kısmen çözülmekte; model tahminlerine yön veren öznitelikler, açıklanabilir ve güvenilir şekilde belirlenebilmektedir (Lundberg and Lee, 2017; Wang *et al.*, 2024). Şekil 5, Rastgele Orman

algoritması kullanılarak gerçekleştirilen SHAP tabanlı öznitelik seçiminin işlem adımlarını göstermektedir.



Şekil 5. Rastgele Orman tabanlı SHAP yöntemiyle öznitelik seçimi akış şeması.

1. Başla: Modelleme süreci, veri dosyasının sisteme alınması ve temel bağımlılıkların yüklenmesiyle başlar. Bu adım, tüm işlemlerin tetikleyicisi ve algoritmik sürecin başlangıç noktasıdır.
2. Veri Girişi: Ham veriler, dosya üzerinden modele aktarılır. Bu veri seti; baz istasyonu adları, bölgesel bilgiler, trafik değerleri, kullanıcı sayıları, bant genişlikleri ve diğer performans ölçütlerini içerir. Uzman görüşlerine dayalı referans sıralama ise hedef değişkeni temsil etmektedir.
3. Giriş ve Hedef Değişkenlerinin Ayrılması: Modelleme süreci için bağımsız değişkenler (girdiler) ile bağımlı değişken (çıkıtı) ayrıştırılır. ID_01 (Baz istasyonunun adı), LOC_01 (İstasyonun bulunduğu ilçe) ve RANK_01 (Uzman değerlendirmesine göre istasyon sıralaması) dışındaki sütunlar modelin girişini oluştururken, RANK_01 değişkeni hedef olarak belirlenir.
4. Kategorik Verilerin Sayısallaştırılması: Giriş değişkenleri arasında yer alan kategorik (metinsel) sütunlar, modelin işleyebilmesi için sayısal değerlere dönüştürülmüştür. Bu işlem, her bir kategorik değer için belirli bir tamsayıya karşılık gelmesini sağlamıştır.
5. Eğitim ve Test Verilerinin Ayrılması: Veri seti, modelin başarısını değerlendirebilmek amacıyla %80 eğitim ve %20 test olacak şekilde iki alt kümeye ayrılmıştır. Bu sayede model yalnızca eğitim verisiyle öğrenme yapmış ve daha önce görmediği test verisiyle değerlendirilmiştir.
6. Rastgele Orman Modelinin Eğitilmesi: Ağaç tabanlı bir ML algoritması olan RandomForestRegressor, eğitim verisi üzerinde çalıştırılmış ve hedef değişkeni tahmin etmeyi öğrenmiştir. Bu model, birçok karar ağacının birleşimiyle daha sağlam ve kararlı sonuçlar üretmeyi amaçlamaktadır.
7. SHAP Değerlerinin Hesaplanması: Model eğitildikten sonra, her bir özelliğin modelin tahminine olan katkısını ölçmek amacıyla SHAP analizi yapılmıştır. SHAP, her bir özelliğin tahmin üzerindeki marjinal katkısını ayrıntılı biçimde hesaplamaktadır.
8. Özellik Önem Sıralamasının Yapılması: Hesaplanan SHAP değerlerinin mutlak ortalamaları alınarak, özelliklerin model üzerindeki etkisi görece olarak sıralanmıştır. Bu sıralama, hangi değişkenlerin karar verme sürecinde daha belirleyici olduğunu göstermektedir.
9. Sonuçların Kaydedilmesi: Özellik önem sıralaması sonuçları, analizlerin tekrar edilebilirliğini ve dokümantasyonunu sağlamak amacıyla veriler kaydedilmiştir.

Rastgele Orman tabanlı SHAP yöntemiyle özellik seçimi süreci

1. Veriyi yükle:

- Veri setini oku.
2. Giriş ve Hedef Değişkenlerini Belirle:
- ID_01 (site isimleri), LOC_01 (İstasyonun bulunduğu ilçe) ve RANK_01 dışındaki tüm sütunları giriş değişkenleri (X) olarak ayır.
 - RANK_01 sütununu hedef değişken (y) olarak belirle.
3. Kategorik Değişkenleri Sayısal Hale Getir (Label Encoding):
- Giriş verilerindeki tüm kategorik sütunları tespit et.
 - Her bir kategorik sütunu etiketleyerek sayısal değerlere dönüştür.
4. Veriyi Eğitim ve Test Setlerine Ayır:
- Giriş (X) ve hedef (y) verilerini %80 eğitim, %20 test olarak böl.
5. Modeli Eğit:
- Rastgele Orman regresyon modelini tanımla ve eğitim verisi üzerinde modeli eğit.
6. SHAP Açıklayıcıyı Oluştur:
- Eğitim verisine dayalı olarak SHAP değerlerini hesapla.
7. Özellik Önemini Belirle:
- Tüm SHAP değerlerinin mutlak değerlerinin ortalamasını al.
 - Bu ortalama değerlere göre özellikleri önem sırasına göre sırala.
8. En Önemli 5 Özelliği Yazdır:
- Ortalama SHAP değerine göre en yüksek ilk 5 özelliği ekrana yazdır.
9. SHAP Bar Grafiği Göster:
- En önemli 10 özelliği gösteren bir SHAP çubuk grafik oluştur.
 - Grafiği ekrana çiz.

Rastgele Orman tabanlı SHAP yöntemiyle öznitelik seçim sürecinin çıktıları


Şekil 6'da SHAP analizi sonucunda elde edilen öznitelik önem sıralaması sunulmaktadır. (Grafikte yalnızca en yüksek katkıya sahip ilk sekiz öznitelige yer verilmiş olup, kalan özniteliklerin katkı düzeyi düşüklüğü nedeniyle görsel sadeleştirme amacıyla "...” sembolü ile temsil edilmiştir.) Şekilde her bir öznitelik için hesaplanan ortalama mutlak SHAP değeri, ilgili değişkenin model tahminlerine ne ölçüde katkı sağladığını göstermektedir. "+" işaretiyle belirtilen bu skorlar, her bir gözlemde hesaplanan SHAP değerlerinin mutlak

ortalamları üzerinden elde edilmektedir. Bu deęer ne kadar yüksekse, söz konusu özneliđin sıralama tahminine olan etkisi o denli güçlü kabul edilmektedir (Lundberg and Lee, 2017).

Grafik incelendiđinde, ilk beş öznelik olan NET_06, REV_01, NET_01, G5_01 ve G5_03, model çıktısı üzerinde baskın ve belirgin bir etkiye sahiptir. Bu ilk beş öznelikten sonra SHAP deęerlerinde keskin bir düşüş gözlenmektedir. Görüldüğü üzere, bu ani düşüş, modelin performansını etkileyen anlamlı deęişkenlerin sayısının sınırlı olduğunu ortaya koymaktadır. Tablo 3'te bu öznelikler açıklamalarıyla birlikte verilmiştir.

Bu gözleme dayanarak, yalnızca ilk beş öznelik modele dahil edilmiştir. Bu özneliklerle geliştirilen modelin tahmin başarımı, Spearman korelasyon katsayısı açısından daha yüksek seviyelere ulaşmıştır. Aksine, daha fazla öznelik eklendiğinde modelin korelasyon performansında anlamlı bir artış gözlenmemiş, hatta bazı durumlarda korelasyon deęeri düşmüştür. Bu durum, yüksek boyutlu veri setlerinde düşük katkılı özneliklerin modele dahil edilmesinin, genelleme gücünü azaltabileceği ve model performansını olumsuz yönde etkileyebileceği yönündeki literatür bulgularıyla örtüşmektedir (Guyon and Elisseeff, 2003; Kuhn and Johnson, 2013).

Sonuç olarak, SHAP analizi sadece öznelik önem sıralamasının elde edilmesini deęil, aynı zamanda modelde yer alacak özneliklerin rasyonel bir biçimde seçilmesini sağlamıştır. Bu analiz doğrultusunda, yalnızca anlamlı katkı sağlayan deęişkenlerin dahil edilmesiyle modelin hem şeffaflığı hem de genellenebilirliği artırılmıştır.



Şekil 6. Uzman sıralamasını belirlemede etkili öznelikler.

Tablo 3. Rastgele Orman Tabanlı SHAP Yöntemi Sonucunda Öne Çıkan Öznitelikler ve Açıklamaları

Öznitelik Adı	Açıklama	Birim
NET_06	LTE veri hacmi	GB
REV_01	Mobil gelir gerçekleşen tutar	TL
NET_01	Tahsis edilen bant genişliği	MHz
G5_01	5G aday müşterilerin veri kullanımı	GB
G5_03	5G'ye sahip müşterilerin veri kullanımı	GB

Stokastik özelliklerin modele eklenmesi

Modelin çevresel değişkenliği daha gerçekçi biçimde temsil edebilmesi amacıyla, veri setine iki adet stokastik özellik eklenmiştir: Population_Growth (nüfus artış oranı) ve Housing_Development_Rate (konut gelişim hızı). Yapılan Kolmogorov-Smirnov dağılım analizleri sonucunda, trafik ortamı türlerine ait konut gelişim hızı ve nüfus artış oranı verilerinin tamamının gamma dağılımına uyduğu istatistiksel olarak belirlenmiştir ve bu bilgiler Tablo 4'te sunulmuştur. Bu analizde her trafik tipi için uygunluk testleri yapılmış, sonuçlara göre tüm gruplarda H_0 hipotezi reddetmek için yeterli kanıt bulunamamıştır. Böylece gamma dağılımı, trafik ortamına göre değişen çevresel varyasyonları temsil etmek için uygun bir dağılım olarak kabul edilmiştir. Bu özellikler, ENV_01 (Trafik yoğunluğuna göre bölge sınıflandırması), LOC_01 (İstasyonun bulunduğu ilçe) kombinasyonlarına bağlı olarak tanımlanan gamma dağılımı parametreleri (şekil ve ölçek) kullanılarak simüle edilmiştir. Gamma dağılımı, yalnızca pozitif sürekli değerler üretmesi ve varyansı kontrol edebilme imkânı sağlamaktadır.

Bu stokastik verinin modele eklenmesi yaklaşımı sayesinde, her bir eğitim döngüsünde çevresel koşullardaki varyasyonlar taklit edilerek modelin genelleme kapasitesi artırılmıştır. Aynı zamanda, bu olasılıksal yapı modelin gerçek dünya belirsizliklerine daha yakın davranmasını sağlayarak yalnızca mevcut 5G planlamasına değil, gelecekteki ağ stratejilerine de katkı sunacaktır.

Nüfus artışının dağılıma uygunluğu için kurulan hipotezler:

H_0 : Trafik ortamı tipine ait nüfus artış oranı verileri gamma dağılımına uymaktadır.

H_1 : Trafik ortamı tipine ait nüfus artış oranı verileri gamma dağılımına uymamaktadır.

Konut gelişim hızının dağılıma uygunluğu için kurulan hipotezler:

H_0 : Trafik ortamı tipine ait konut gelişim hızı verileri gamma dağılımına uymaktadır.

H_1 : Trafik ortamı tipine ait konut gelişim hızı verileri gamma dağılımına uymamaktadır.

Tablo 4. Trafik Ortamına Göre Uygunluk Testi Sonuçları

Trafik Ortamı	Uygunluk Testi Sonucu	Her İki Öznitelik İçin Hipotez Durumu	Her İki Öznitelik İçin Açıklama
Trafik Ortamı 1	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 2	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 3	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 4	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 5	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 6	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.
Trafik Ortamı 7	$p > 0.05$	H_0 'ı reddetmek için yeterli kanıt yoktur.	Verilerin gamma dağılımına uymadığına dair yeterli kanıt yoktur.

Kolmogorov-Smirnov uygunluk testinden elde edilen sonuçlara göre, tüm trafik ortamı türleri için hem nüfus artış oranı hem de konut gelişim hızı değişkenleri açısından gamma dağılımına uymadığına dair istatistiksel olarak anlamlı bir kanıt elde edilememiştir. Diğer bir ifadeyle, test sonucunda H_0 hipotezi reddedilememiştir. Bu durum, her iki değişkenin de gamma dağılımı varsayımı altında modellenmesinin istatistiksel açıdan makul olduğunu göstermektedir.

Ajan Tabanlı Simülasyon Modeli

ABS, özellikle karmaşık sistemlerin modellenmesinde son yıllarda giderek artan bir ilgi gören, yenilikçi ve güçlü bir simülasyon tekniğidir. Temelde, ABS, otonom ve heterojen "ajanlar" tarafından oluşturulan sistemlerin davranışını taklit etmek için kullanılır (Macal, 2010; Macal and North, 2010; Anonymous, 2024). Bu ajanlar, bireysel düzeyde tanımlanmış belirli kurallar, hedefler, özellikler (nitelikler) ve karar verme mekanizmaları ile donatılmış varlıklardır. Ajanların bu şekilde modellenmesi sayesinde, dinamik, doğrusal olmayan ve belirsizlik içeren sistemlerin daha gerçekçi bir biçimde analiz edilmesi mümkün hale gelir (Macal and North, 2010). Ayrıca ajanlar, deneyimlerinden "ders çıkarabilir", çevrelerindeki değişikliklere tepki verebilir ve uyum sağlamak için davranışlarını değiştirebilirler (Macal, 2010). Bu sürekli etkileşimlerin ve adaptasyonların bir sonucu olarak, sistem düzeyinde genellikle doğrusal olmayan, öngörülmesi zor davranışlar ve özellikler ortaya çıkar. ABS'nin temel amacı, sistem dinamiklerini nasıl şekillendirdiğini, karmaşık sosyal, ekonomik, biyolojik veya fiziksel sistemlerin bir bütün olarak nasıl işlediğini ve zaman içinde nasıl evrildiğini gözlemlemek ve anlamaktır (Macal, 2010; Klügl, 2016).

ABS'nin kökenleri, Thomas Schelling'in 1971'de geliştirdiği ve basit bireysel tercihlerin (örneğin, belirli bir oranda kendine benzeyen komşu isteme) nasıl sistem düzeyinde yaygın ayrılmaya yol açabileceğini gösteren ayrışma modeline uzanır (Schelling, 1971). 1980'lerin sonlarından itibaren daha yaygın olarak kullanılmaya başlanmıştır. Bu dönemde özellikle sosyal bilimler alanında (sosyoloji, ekonomi, psikoloji vb.) artan sayıda modelin geliştirilmesine zemin hazırlamıştır (Klügl, 2016). Başlangıçta modellerin sosyal bilimler dışında uygulaması sınırlı olsa da zamanla bilgisayarların gücünün artmasıyla birlikte karmaşık sistemlerin modellenmesinde popüler ve güçlü araçlar haline geldi. Günümüzde ABS yazılım seçenekleri, simülasyon sonuçlarının analiz teknikleri, araştırma fırsatları ve başarılı uygulama örneklerinin tartışılması gibi çok çeşitli konuları kapsamaktadır (Heath and Hill, 2010).

ABS uygulama alanı, genişliği bakımından dikkat çekicidir ve sürekli olarak büyümektedir (Macal and North, 2010). İnsan sosyal sistemleri (göç, kültürel yayılım, sosyal ağ dinamikleri, kolektif hareket, isyan modellenmesi), ekonomik sistemler (pazar dinamikleri, tüketici davranışı, tedarik zinciri optimizasyonu, finansal piyasalar), biyolojik sistemler (ekolojik sistemler, popülasyon dinamiği, bağışıklık sistemi tepkisi, kanser hücresi büyümesi), fiziksel sistemler (trafik akışı, kent dinamiği, enerji şebekeleri), organizasyonel sistemler (kurumsal davranış, işbirlikçi ağlar) ve hatta tarihsel rekonstrüksiyonlar (eski uygarlıkların çöküşü) ile gelecek senaryoları (yeni ürün pazar penetrasyonu, politikaların etki analizi) gibi son derece farklı disiplin ve bağlamlarda başarıyla uygulanmaktadır (Macal and North, 2009). Bu çeşitlilik, ABS'nin modelleme gücünün bir kanıtıdır.

ABS, geleneksel simülasyon tekniklerinden metodolojik olarak belirgin şekilde ayrılır ve onları tamamlayıcı niteliktedir (Macal, 2016). Ayrık Olay Simülasyonu (DES) genellikle kuyruk sistemleri gibi belirli olaylarla tetiklenen süreçlere odaklanır ve varlıkların (müşteri, parça) pasif olduğu sistemlerde etkilidir. Sistem Dinamiği (SD) stoklar, akışlar ve geri besleme döngüleri üzerinden makro düzeydeki davranışları, sürekli zamanlı diferansiyel denklemlerle modeller; mikro düzeydeki bireysel etkileşimleri ve heterojenliği doğrudan temsil etmez. Monte Carlo Simülasyonu belirsizliği modellemek için olasılık dağılımları ve rastgele örnekleme kullanır ancak genellikle zaman dinamiklerini veya ajanlar arası etkileşimleri içermez. ABS ise, özellikle sistem davranışının, bağımsız, karar verebilen, birbirleriyle ve çevreleriyle etkileşen, bireyler veya alt birimler (ajanlar) arasındaki etkileşimlerin sistem davranışlarını nasıl şekillendirdiğini analiz etme potansiyeli nedeniyle tamamlayıcı ve genişletici bir rol üstlenmektedir (Macal and North, 2010; Macal, 2016).

Ajanların model odaklı davranışı sayesinde ABS, gerçek sistem dinamiklerini iyi biçimde taklit eder. Hanappi (2017) bu durumu, bir ajanın içsel bilinç düzeyinin dışındaki

maddi dünyayı, kendi içsel bilgi işleme süreçlerinden ayırma kapasitesi olarak açıklar. Yani, ajanlar çevrelerinin dinamiklerini temsil eden dahili modeller kullanabilirler. Bu model, dış dünyadan gelen algıların (gözlemlerin) nasıl seçildiğini, bu algıların dahili modele nasıl entegre edildiğini ve nihayetinde belirli bir bağlamda hangi eylemin tanınıp seçileceğini belirler. ABS, bu bilişsel süreçlerin zaman içindeki evrimini (öğrenme, adaptasyon) ve bunun sistem düzeyindeki sonuçlarını keşfetmek için güçlü bir çerçeve sunar. Bu, ajanların yalnızca reaktif değil, aynı zamanda proaktif ve hedef yönelimli olmalarını sağlar.

Gerçek dünya sistemlerinin işleyişini anlamak ve süreçlerini iyileştirmek için modelleme teknikleri sıklıkla kullanılır. Her modelleme yönteminin gerçeği kaçınılmaz olarak basitleştirir, ancak ideal bir yöntemin esnek ve mantıksal olarak titiz olması gerekmektedir (Tesfatsion, 2023). ABS bu avantajları sağlar. Ajanların karmaşıklık düzeyi, etkileşim kuralları, çevrenin temsili ve ölçek araştırma sorusuna göre özelleştirilebilir. Bu nedenle, ABS yalnızca açıklayıcı değil, aynı zamanda keşfedici ve öngörücü bir araç olarak, karar verme süreçlerine değerli çıktılar sağlayabilir.

Sonuç olarak, ABS, birey bazlı karar alma süreçlerini temel alan ve karmaşık sistem davranışlarını anlamaya yönelik güçlü bir yaklaşımdır. Bireylerin mikro düzeydeki kararlarının makro sistem çıktıları üzerindeki etkilerini analiz etme kapasitesi sayesinde, özellikle karmaşık, değişken ve belirsiz ortamlarda sistem analizine derinlik kazandırır. Bu nedenle ABS, sadece mevcut sistemleri anlamak için değil, aynı zamanda geleceğe dönük stratejik planlamalarda da değerli bir araç olarak konumlandırılmaktadır.

Bu çalışmada, her biri farklı ağırlık kombinasyonlarına sahip iki bağımsız ajanın bulunduğu ajan tabanlı bir simülasyon ortamı tasarlanmıştır. Ajanlar, mevcut saha özelliklerine dayalı olarak sahalara skor atamakta ve bu skorlar üzerinden sıralama gerçekleştirmektedir. Ajanların karar verme mekanizması, kendilerine ait ağırlık vektörleri ile veri özelliklerinin kombinasyonunu almaya dayanır. Ajanlar, her adımda eylem alanından aldıkları sinyaller doğrultusunda ağırlıklarını güncelleyerek daha yüksek korelasyonlu sıralamalara ulaşmayı hedeflemektedir. Ortamın her adımında güncellenen skorlar üzerinden sıralamalar yeniden hesaplanmakta ve bu sıralamaların uzman sıralamasıyla benzerliği, ajanların ödül fonksiyonlarını belirlemektedir.

RL'nin Temelleri ve Evrimi

YZ ve ML temel yaklaşımlarından biri olan RL, özellikle karmaşık karar verme ve kontrol problemlerinde gösterdiği başarı sayesinde dikkat çekici bir araştırma alanı hâline gelmiştir. Kavramsal kökeni, sibernetik biliminin erken dönemlerine ve psikoloji, istatistik, sinirbilim gibi disiplinlerdeki öğrenme davranışına yönelik çalışmalara dayanmaktadır. Özellikle ML alanında, bir görev için doğrudan açık talimatlar sunmadan, ödül ve ceza mekanizmalarıyla bir ajanın eğitilmesini mümkün kılması, bu yöntemi hem ilgi çekici hem de pratik uygulamalarda oldukça güçlü kılmıştır (Kaelbling *et al.*, 1996; Barto, 1997).

RL modelinde ajan çevresiyle deneme-yanılma yoluyla etkileşime girer ve bu etkileşim sayesinde davranış stratejilerini öğrenir. Bu öğrenme modelinin temel mantığı ajanların çevresinden aldığı pekiştirme sinyalleri sayesinde hangi eylem/eylemlerin daha faydalı olacağını keşfetmeye çalışır. Bu yönüyle RL denetimli öğrenme modellerinden ayrılır. Denetimli öğrenmede, sistem "bilgili bir öğretmen" tarafından her girdi (input) için doğru çıktının (output) ne olması gerektiği açıkça belirtilerek eğitilir. Oysa RL'de ajan yalnızca eylemi takiben aldığı ödül ve yeni durumu gözlemler; hangi eylemin daha iyi olduğu bilgisi önceden sunulmaz (Kaelbling *et al.*, 1996; Barto, 1997).

RL sistemlerinin temel amacı, toplam pekiştirme sinyalini maksimize eden politikayı öğrenmektir. Bu amaçla geliştirilen algoritmalar, Markov Karar Süreçleri adı verilen matematiksel bir çerçeve ile modellenir. RL'nin temel bileşenleri; bir durum kümesi (S), bir eylem kümesi (A), bir geçiş olasılığı (T) ve bir ödül fonksiyonu (R) olarak özetlenebilir. Ajanın amacı, beklenen indirgenmiş toplam ödülü maksimize eden optimal politikayı bulmaktır.

RL'nin bir diğer katkısı kendi deneyimlerinden öğrenmesidir. Yapay öğrenme modellerinin çoğu bilgili bir öğretmenin desteğiyle öğrenir. Yani eğitim için her girdinin doğru çıktının ne olmasının gerektiği açıkça belirtilmelidir (Barto, 1997). Ancak RL'nin önemli özelliklerinden biri keşif (exploration) ve kullanma (exploitation) arasında çevresini aktif olarak keşfetme zorunluluğudur. Hangi eylemin hangi durumda ne gibi sonuçlar ve ödüller getireceğini deneyerek öğrenir. RL bu soruna çeşitli çözümler geliştirerek öğrenmenin başarısını arttırmaya çalışır. Ayrıca RL ajanı, durumu kendi eylemlerinden etkilenen dinamik bir çevreyle sürekli ve sıralı bir etkileşim içindedir. Bu, statik veri kümeleri üzerinde çalışan çoğu öğrenme yönteminden farklıdır.

YZ araştırmalarının temel hedeflerinden biri, uzun süreli etkileşimlerde çevresine uyum sağlayabilen, kendi kararlarını alabilen ve kendi deneyimlerinden öğrenerek performansını zaman içinde iyileştirebilen otonom ajanlar geliştirmektir. RL, bu hedef doğrultusunda, ilkesel ve matematiksel olarak sağlam bir çerçeve sunar (Arulkumaran *et al.*, 2017). Bu çerçeve,

yalnızca robotik sistemlerde değil, aynı zamanda finansal piyasa modellemeleri, enerji optimizasyonu ve endüstriyel süreç kontrolü gibi çok çeşitli uygulamalarda etkili biçimde kullanılmaktadır.

Son yıllarda, derin öğrenme teknikleriyle birleştirilen RL yöntemleri, özellikle yüksek boyutlu ve karmaşık çevrelerde başarılı sonuçlar vermiştir. Bu sistemler koordinasyon sağlama, oyunlarda insanüstü performans gösterme, tıbbi teşhis destek sistemlerinde karar verme süreçlerini iyileştirme gibi farklı alanlarda başarıyla uygulanmaktadır (Arulkumaran *et al.*, 2017; Cheng *et al.*, 2021).

RL algoritmaları genel olarak iki ana kategoriye ayrılabilir:

1. Model Bazlı RL: Ajanın çevrenin dinamiklerini öğrenmeye veya tahmin etmeye çalıştığı bir model oluşturulur. Bu model daha sonra optimal politikayı tespit etmek için kullanılır. Model doğruysa verimli çalışır, ancak modeli karmaşık çevrelerde eğitmek çok zor olabilir.

2. Model-Free RL: Ajan, çevrenin açık bir modelini öğrenmeden doğrudan optimal politikayı veya durum-eylem değer fonksiyonunu (Q-fonksiyonu) öğrenir. Bu, genellikle daha esnek ve pratik bir yaklaşımdır. Algoritmaları şunlardır:

- Değer Tabanlı (Value-Based): Optimal Q-fonksiyonunu ($Q(s,a)$) tahmin etmeye odaklanır. Optimal politika, her durumda en yüksek Q-değerine sahip eylemi seçmektir. Temporal Difference (TD) Learning, Q-Learning, Deep Q-Networks (DQN) bu sınıftadır.

- Politika Tabanlı (Policy-Based): Doğrudan parametrik bir politikayı ($\pi(a|s)$) optimize eder. Gradyan bazlı yöntemlerle (örneğin, Politika Gradyanı - Policy Gradient) politika parametreleri güncellenir. REINFORCE buna örnektir.

- Aktör-Kritik (Actor-Critic): Hem bir değer fonksiyonunu (Kritik - Critic, genellikle $V(s)$ veya $Q(s,a)$) hem de bir politikayı (Aktör - Actor) birlikte öğrenir. Kritik, aktörün aldığı eylemleri değerlendirerek politika güncellemelerine rehberlik eder. Advantage Actor-Critic (A2C/A3C), YPO (Cheng *et al.*, 2021'in çalıştığı gibi) ve Soft Actor-Critic (SAC) bu hibrit yaklaşımın popüler örnekleridir. Politika optimizasyonunu daha kararlı hale getirmek için çeşitli varyantlar ve iyileştirmeler (Cheng *et al.*, 2021'deki "Authentic Boundary" gibi) sürekli geliştirilmektedir.

RL, karar verme ve kontrol problemlerine yönelik güçlü ve esnek bir yaklaşım sunmakta; ajanın çevresiyle etkileşim kurarak kendi deneyimlerinden öğrenmesine olanak tanımaktadır. Özellikle bu çalışmada olduğu gibi derin öğrenme ile birleştiğinde hem kuramsal hem de uygulamalı bağlamda pek çok yeni araştırma alanı doğurmakta ve bu alanlarda

çözümlerin önünü açmaktadır. Bu çalışmanın literatüre özgün katkısı: (1) Uzman sıralaması ile ML çıktılarının Spearman korelasyonunu doğrudan optimize eden DRL mimarisi, (2) Talep dalgalanmalarını modellemek için stokastik özellik üretiminin çok-ajanlı öğrenmeye entegrasyonu. Bu hibrit yaklaşım, özellikle gelişmekte olan ülkelerdeki telekom yatırım verimliliği literatüründeki kritik bir boşluğu doldurmaktadır.

Özel RL ortamı

DRL alanında en çok ilgi gören algoritmalarından biri, YPO algoritmasıdır. Schulman *et al.* tarafından 2017 yılında önerilen YPO, güvenli politika güncelleme yöntemlerinin istikrarını korurken, uygulama açısından çok daha basit ve esnek bir çözüm sunmaktadır. YPO'nun temel başarısı güçlü teorik temellere dayanması kadar, pratik uygulamalarda da üstün performans göstermesinden kaynaklanmaktadır (Schulman *et al.*, 2017; Wang *et al.*, 2020). Bu özellikleriyle YPO çok çeşitli zorlu karar alma problemlerinde iyi performans gösteren bir algoritma haline gelmiştir (Wang *et al.*, 2020; Meng *et al.*, 2023).

YPO algoritmasının çıkış noktası, klasik Actor–Critic (AC) mimarisidir. Bu mimaride, sistem iki bileşenden oluşur: Aktör (Actor) bileşeni, öğrenilen politika doğrultusunda eylemleri seçerken, Değerlendirici (Critic) bileşeni, eylemlerin ne kadar “iyi” olduğunu yani gelecekte beklenen ödülünü tahmin eder. Critic bileşeni tipik olarak değer fonksiyonu öğrenirken, Actor bu bilgiye dayanarak politika parametrelerini günceller. YPO, bu yapının üzerine inşa edilmiştir ve actor–critic tabanlı algoritmalar arasında en çok kullanılanlardan biridir (Gu *et al.*, 2021).

YPO'nun ortaya çıkışındaki temel itici güç, GBPO (Güven Bölgesi Politika İyileştirmesi- Trust Region Policy Optimization)'nin matematiksel güçlüğü ve uygulama zorluğudur. Schulman *et al.* (2017), GBPO gibi öncül yöntemlerin sağladığı kararlı öğrenme garantilerini korurken, hesaplama karmaşıklığını önemli ölçüde azaltan ve uygulanmasını son derece basitleştiren yenilikçi bir yaklaşım sunmuştur (Schulman *et al.*, 2017; Wang *et al.*, 2020). Bu özellikleri, YPO'yu karmaşık simülasyon ortamlarından gerçek dünya robotiğine kadar çok çeşitli zorlu ardışık karar alma problemlerinde en iyi performans gösteren bir algoritma haline getirmiştir (Wang *et al.*, 2020; Meng *et al.*, 2023). YPO, hesaplama zorluğunu aşmak için kırpma (clipping) tabanlı bir hedef fonksiyonu kullanır. Bu yöntem, politika güncellemesinin belirli bir aralıkla sınırlanmasını sağlar ve bu sayede hem politika değişimleri kontrollü biçimde yapılır hem de eğitim kararlılığı sağlanır.

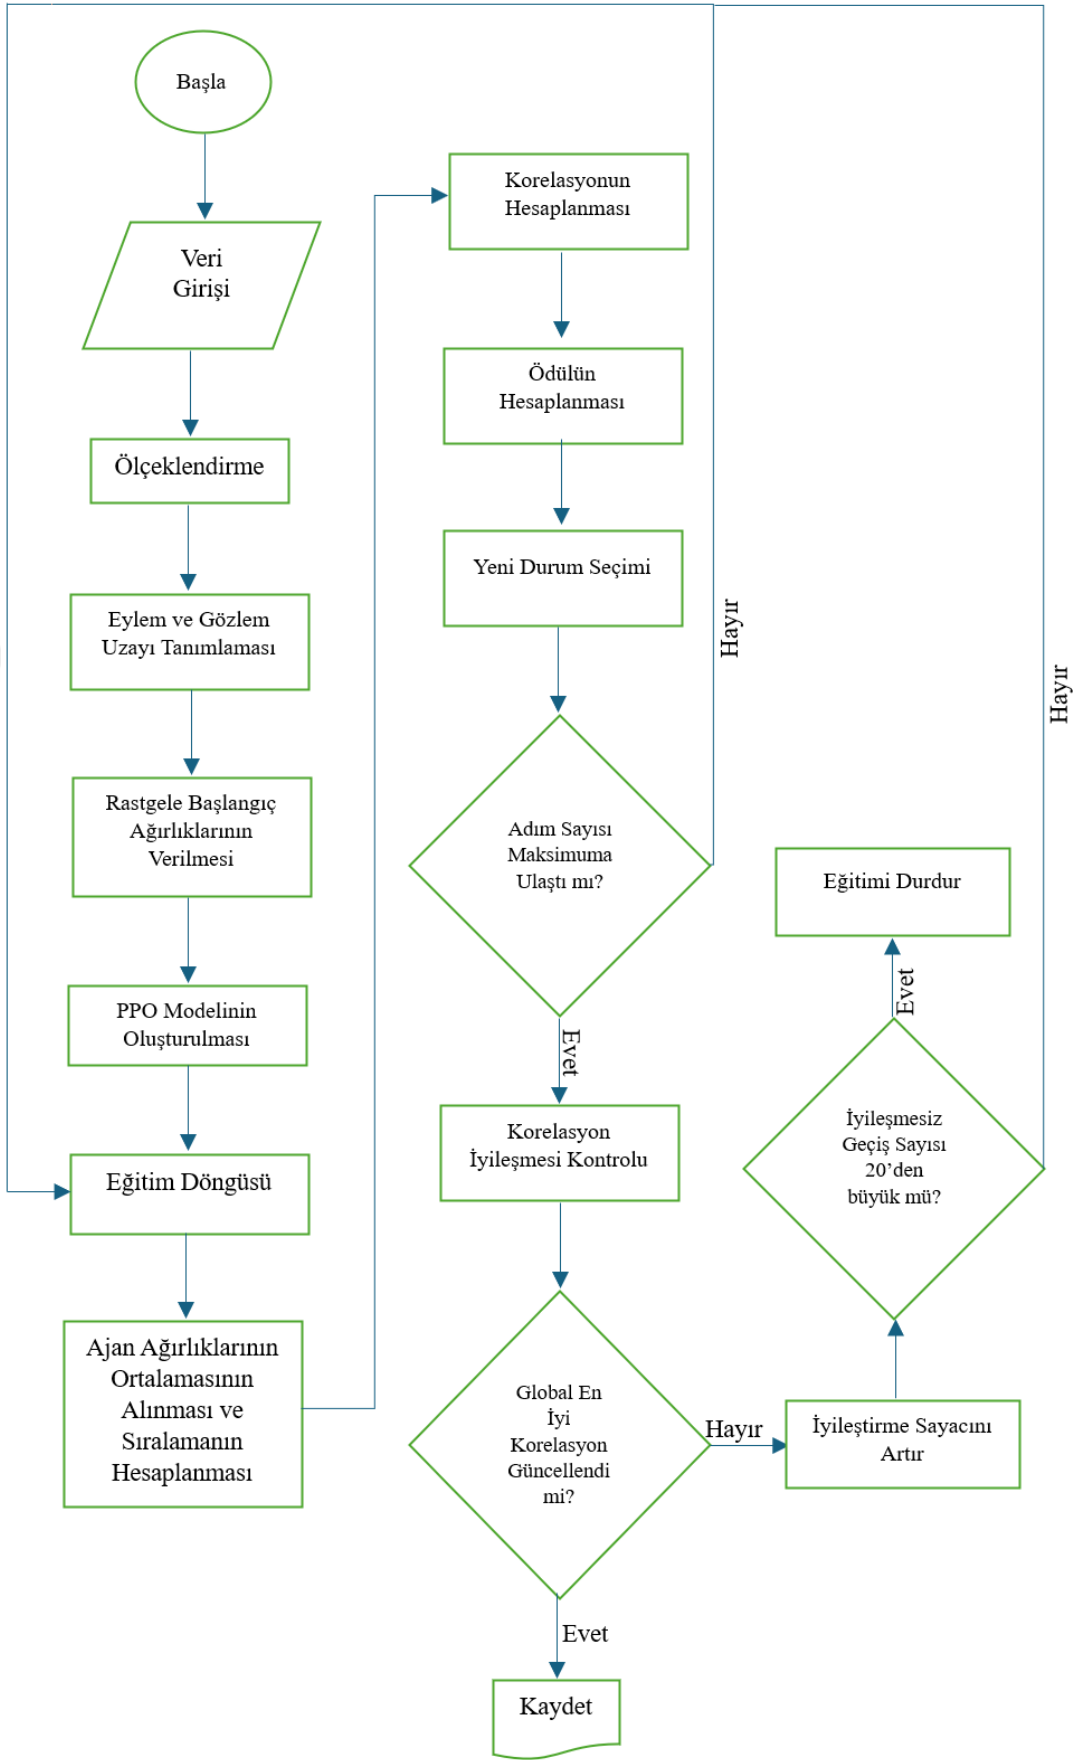
Özetle YPO, DRL literatüründe hem teorik hem de uygulamalı olarak güçlü bir yere sahiptir (Engstrom *et al.*, 2019; Zakharenkov and Makarov, 2021). Uygulama kolaylığı, istikrarlı politika güncellemeleri, örnek verimliliği, esnek mimarilerle entegrasyon kabiliyeti ve

farklı problem türlerine uyarlanabilirliği sayesinde YPO, günümüz RL sistemlerinin temel yapı taşlarından biri hâline gelmiştir. Bu çalışmada YPO, telekomünikasyon sektöründe 5G yatırım önceliklendirme kararlarını desteklemek amacıyla geliştirilmiş özel bir ortamda uygulanmıştır. Geliştirilen ortam, nüfus artışı ve konut gelişim oranları gibi demografik değişkenlerin Gamma dağılımı ile stokastik biçimde simüle edildiği bir karar problemine entegre edilmiştir. Ajanlar, farklı özellikler için ağırlık vektörlerini güncelleyerek uzman sıralamasına yakın bir önceliklendirme elde etmeye çalışmakta, bu süreçte Spearman korelasyonu ödül işlevi olarak kullanılmaktadır. Bu yapılandırma, dinamik çevre koşullarına karşı adaptif karar verme yeteneği kazandırmakta ve sahadan elde edilen uzman sıralamaları ile yüksek benzerlikte çözümler üretmektedir.

Şekil 7’ de çalışmada takip edilen akış diyagramı verilmiştir. Akış diyagramının altında yatan algoritmik yapının daha iyi anlaşılmasına katkı sağlamak amacıyla süreç açıklanmıştır.

Yazılım ortamı ve özellik seçimi süreci

Model, Python programlama dili kullanılarak hayata geçirilmiştir. Modelin uygulanmasında, veri işleme ve matematiksel hesaplamalar için NumPy ve Pandas kütüphaneleri kullanılmış; istatistiksel analizler SciPy kütüphanesi aracılığıyla gerçekleştirilmiştir. Verilerin dayanıklı biçimde ölçeklenmesi Scikit-learn kütüphanesinden RobustScaler sınıfı ile yapılmıştır. Ayrıca, veri setindeki kategorik değişkenlerin sayısallaştırılmasında LabelEncoder, eğitim ve test veri kümelerinin oluşturulmasında ise train_test_split kullanılmıştır. Özellik seçimi sürecinde, RandomForestRegressor modeli eğitilerek, tahmin performansı yüksek özniteliklerin belirlenmesi sağlanmıştır. Bu modele entegre olarak SHAP kütüphanesi ile özniteliklerin hedef değişken üzerindeki görelî katkısı (SHAP değerleri) hesaplanmış; en anlamlı öznitelikler bu değerlere göre sıralanmıştır. Ortalama SHAP değerlerine dayalı sıralama sonucunda, ilk 5 özniteliğin karar sürecine en yüksek katkıyı sağladığı görülmüştür. Bu yaklaşım, modelde kullanılacak özniteliklerin seçilmesinde nesnel ve açıklanabilir bir yöntem sağlamıştır. Geliştirilen modelin öğrenme süreci ise açık kaynaklı Stable-Baselines3 kütüphanesi kullanılarak YPO algoritması ile yapılandırılmış, simülasyon ortamı Gym kütüphanesi ile özelleştirilmiştir. Ortamın vektörleştirilmesi DummyVecEnv sınıfı ile sağlanmış, karar politikası olarak MlpPolicy kullanılmıştır. Ayrıca, model çıktılarının Excel formatında dışa aktarımı için os ve pandas modüllerinin dosya yazım fonksiyonlarından faydalanılmıştır. Tüm bu yazılım altyapısı, veri temelli ve öğrenen bir karar destek sistemi geliştirilmesine olanak sağlamıştır.



Şekil 7. Telekomünikasyon saha önceliklendirme problemine uygulanan öğrenme sürecinin akış şeması.

1. Başla: Modelleme süreci, veri setinin işlenmesi ve ortamın hazırlanması ile başlar. Bu adım, tüm süreçlerin ilk tetiklendiği yapıdır.

2. Veri Girişi: Modelin eğitimi için gerekli olan ham veri dosyaları sisteme dahil edilir. Bu veriler arasında istatistiksel özellikler, kullanıcı sayıları, bant genişlikleri ve bölgesel değişkenler yer almaktadır. Aynı zamanda stokastik dağılım parametrelerini içeren ek veri de bu aşamada modele yüklenir.

3. Ölçeklendirme: Modelde yer alan sayısal değişkenler, daha tutarlı ve karşılaştırılabilir hale getirilmek amacıyla yeniden ölçeklendirilir.

4. Eylem ve Gözlem Uzaylarının Tanımlanması: Öğrenme ortamının tanımlanması kapsamında ajanların eylem ve gözlem uzayları oluşturulur. Bu uzaylar, modelin hangi bilgilere göre karar vereceğini ve nasıl müdahale edebileceğini belirleyen yapısal alanlardır.

5. Başlangıç Ağırlıklarının Atanması: Modelde görev yapan ajanlara başlangıçta rastgele ağırlık vektörleri atanır. Bu ağırlıklar, karar verme sürecinde hangi değişkenin ne derece etkili olacağını temsil eder ve öğrenme sürecinde dinamik olarak güncellenir.

6. YPO Modelinin Oluşturulması: Öğrenme aşamasında, avantajlı politikalar üzerinde istikrarlı güncellemeler yapabilen YPO algoritması tercih edilir. Bu sayede ajanlar çevreyle etkileşim kurarak ağırlıkların kademeli olarak geliştirmesini sağlar.

7. Eğitim Döngüsü: Model belirli bir süre boyunca çevreyle etkileşime girer. Her döngüde yeni bir karar alınır, buna göre ödül hesaplanır ve bu ödüle göre politika güncellenir. Bu süreç, model performansı artana veya belirli bir durdurma koşulu sağlanana dek devam eder.

8. Ağırlıkların Güncellenmesi: Eğitim sırasında ajanlar, almış oldukları eylemler doğrultusunda ağırlıklarını günceller. Bu güncellemeler, modelin tahmin performansını iyileştirmeye yönelik yönlendirilmiştir.

9. Korelasyonun Hesaplanması: Modelin çıktısı olan tahmini sıralama ile uzmanlar tarafından belirlenmiş referans sıralama arasındaki ilişki, Spearman korelasyon katsayısı ile hesaplanır. Bu metrik, modelin başarısını sayısal olarak ölçmek amacıyla kullanılır.

10. Ödülün Hesaplanması: Modelin ödülü, temel olarak elde edilen korelasyon katsayısına dayalıdır. Bununla birlikte, korelasyonda sağlanan ilerlemeler için ek bonuslar ve çeşitliliği teşvik eden entropi temelli ödüller de ödül fonksiyonuna dahil edilmiştir.

11. Yeni Gözlem Seçimi: Her adımda, öğrenmenin sürekliliğini sağlamak adına çevreden yeni bir gözlem alınır. Bu sayede modelin veri üzerindeki kapsayıcılığı ve genelleme kabiliyeti artar.

12. Adım Sayısının Kontrolü: Belirlenen maksimum adım sayısına ulaşıp ulaşılmadığı kontrol edilir. Bu eşik, eğitim sürecinin uzunluğunu sınırlamak ve işlem maliyetlerini dengelemek amacıyla kullanılmaktadır.

13. Korelasyon İyileşmesi Kontrolü: Modelin elde ettiği korelasyonun, önceki en iyi sonuçlara kıyasla iyileşme gösterip göstermediği değerlendirilir. Eğer anlamlı bir iyileşme mevcutsa, sistem bu başarıyı kaydeder.

14. Sonuçların Kaydedilmesi: Yeni bir en iyi korelasyon değeri elde edilmesi durumunda, modelin tahmin ettiği sıralamalar ve ilişkili skorlar bir dosyaya kaydedilir. Bu işlem, daha sonra yapılacak analizler ve model karşılaştırmaları için referans oluşturur.

15. İyileştirme Sayacının Güncellenmesi: Eğer model, belirli bir sayıda ardışık döngüde gelişme gösteremezse bu durum izlenir ve sayaç artırılır. Bu sayaç, eğitim sürecinin erken durdurulması için bir kriter olarak kullanılır.

16. İyileştirme Olmayan Geçiş Sayısının Kontrolü: İyileşme göstermeden geçen döngü sayısı, önceden tanımlanmış eşik değeri aştığında eğitim süreci durdurulur. Bu yaklaşım, öğrenmenin tıkanmaya başladığı noktada işlem maliyetlerini azaltmayı hedefler.

17. Eğitimi Durdur: Son aşamada, model eğitiminin sona erdiği durumlarda sistem kapanır. Bu durum ya maksimum adım sayısına ulaşıldığında ya da ardışık iyileşmesiz geçiş sınırı aşıldığında gerçekleşir.

RL yaklaşımıyla saha önceliklendirme süreci

1. Veriyi yükle:
 - a. Dinamik veri setini oku.
 - b. İlçe ve trafik çevresine göre gamma parametrelerini içeren dosyayı oku.
2. YPO ortamını tanımla:
 - a. Gözlem ve aksiyon uzaylarını tanımla (özellik sayısı kadar).
 - b. RobustScaler ile veriyi normalize et.
 - c. Rastgele başlangıç ağırlıkları ata (her ajan için).
 - d. Korelasyon ve ödül bileşenlerini ayarla:
 - Korelasyon katsayısı (Spearman)
 - İyileştirme bonusu
 - Entropi bonusu
3. Ortamı sıfırla:

- a. Rastgele bir gözlem seç.
- b. Bu gözlemlerle başlangıç durumunu oluştur.
- c. Tahmin edilen sıralamayı hesapla.
- d. Başlangıç korelasyonunu kaydet.

4. Adım at:

Her eğitim adımı için şu işlemleri gerçekleştir:

- a. Rastgele güncelleme faktörü belirle.
- b. Ajan ağırlıklarını aksiyonlara göre güncelle.
- c. Tahmin edilen sıralamayı yeniden hesapla.
- d. Yeni korelasyonu ölç.
- e. Ödülü hesapla:
 - Korelasyon değeri
 - İyileşme bonusu (varsa)
 - Ağırlıkların entropisi
- f. Eğer önceki en iyi korelasyonu geçerse:
 - Yeni sıralamayı kaydet.
- g. Yeni durumu döndür.

5. Eğitim döngüsü:

Maksimum aşama sayısına ulaşılmadığı sürece ve modelde iyileşme olduğu sürece döngü devam et.

- a. YPO modelini belirli zaman adımları boyunca eğit.
- b. Yeni global korelasyonu al.
- c. Önceki en iyi değerle karşılaştır.
- d. Eğer iyileşme yoksa:
 - Sayaç arttır, erken durdurmayı kontrol et.
- e. Aksi hâlde sayaç sıfırla.
- f. Yeni korelasyonu listeye ekle.


6. Durdurma:

- a. Eğer art arda belirli sayıda iyileşme olmazsa:
 - Erken durdurmayı tetikle.
- b. Eğitim tamamlandı mesajı göster.

Modelin Eğitimi ve Uygulaması

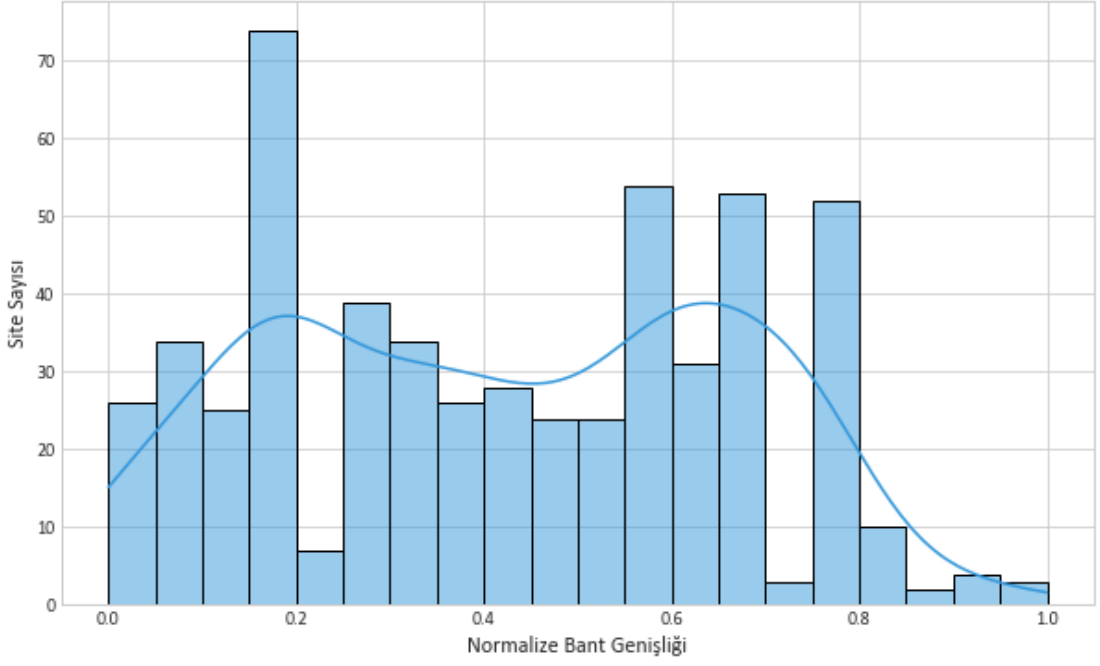
Firmadan alınan ve Tablo 2’ de gösterilen veriler incelenerek, aşağıdaki çıkarımlar yapılmıştır.

Şekil 8’deki görselde, normalize edilmiş bant genişliği ile normalize edilmiş mobil gelir gerçekleşmesi arasındaki ilişki bir dağılım grafiği ve üzerine oturtulmuş bir regresyon çizgisi aracılığıyla gösterilmektedir. Görselde doğrusal bir eğilim dikkat çekmektedir; yani bant genişliği arttıkça mobil gelirdede artış gözlemlenmektedir. Regresyon doğrusu ve çevresindeki güven aralığı, bu ilişkinin istatistiksel olarak anlamlı olduğunu göstermektedir. Korelasyon matrisiyle birlikte değerlendirildiğinde, bant genişliği ile mobil gelir arasında anlamlı ve pozitif bir korelasyon olduğu ($r \approx 0.70$) anlaşılmaktadır. Bu durum, bant genişliği tahsisinin gelir üzerinde doğrudan bir etkisi olabileceğini işaret etmektedir.



Şekil 8. Normalize bant genişliği ile mobil gelir arasındaki doğrusal ilişki.

Şekil 9’da verilen histogram, tüm bölgelerdeki sahaların normalize bant genişliği değerlerini göstermektedir. Veri dağılımı incelendiğinde, bant genişliğinin tüm sahalar arasında eşit şekilde dağılmadığı ve bazı değerlerde kümelenmelerin olduğu görülmektedir. Özellikle 0.2 ve 0.6–0.8 aralığında belirgin yığılmalar vardır. Bu, sahaların bir kısmında yüksek bant genişliği tahsisi yapılmışken, diğer bir kısmının düşük bant genişliği ile çalıştığını ortaya koymaktadır. Bu eşitsizlik, özellikle düşük bant genişliği tahsis edilen sahaların servis kalitesi ve kullanıcı deneyimi açısından dezavantajlı olabileceğini göstermektedir. Ayrıca bu durum, kaynak planlaması ihtiyacına işaret etmektedir. (“Site” terimi, belirli bir coğrafi konumda yer alan ve mobil haberleşme hizmeti sunan sahaları ifade etmektedir.)




Şekil 9. Normalize bant geniřliđi dađılımı.

Şekil 10'da verilen ısı haritası, mobil řebeke performansına iliřkin temel gstergeler arasındaki korelasyon iliřkilerini grselleřtirmektedir. En yksek korelasyon deđerlerinden bazıları řunlardır:


- Mobil Gelir Gerçekleřmesi (REV_01) – VoLTE Trafik Yođunluđu (NET_04): 0.90
- Mobil Gelir Gerçekleřmesi (REV_01) – LTE Veri Kullanımı (NET_06): 0.88
- Veri indirme ynndeki kaynak kullanım oranı (NET_02) – LTE Veri Kullanımı (NET_06): 0.83

Bu bulgular, gelir performansının yalnızca kapsama deđeril aynı zamanda hizmet kullanım yođunluđu ve fiziksel kaynak kullanımı ile de yakından iliřkili olduđunu gstermektedir. Bant geniřliđi ve PRB kullanımı gibi fiziksel kaynak gstergeleri ile gelir arasında da anlamlı bir iliřki bulunmaktadır. Bu tr korelasyon yapıları, çok deđerlikenli modeller iin deđerli temel girdiler sađlar.



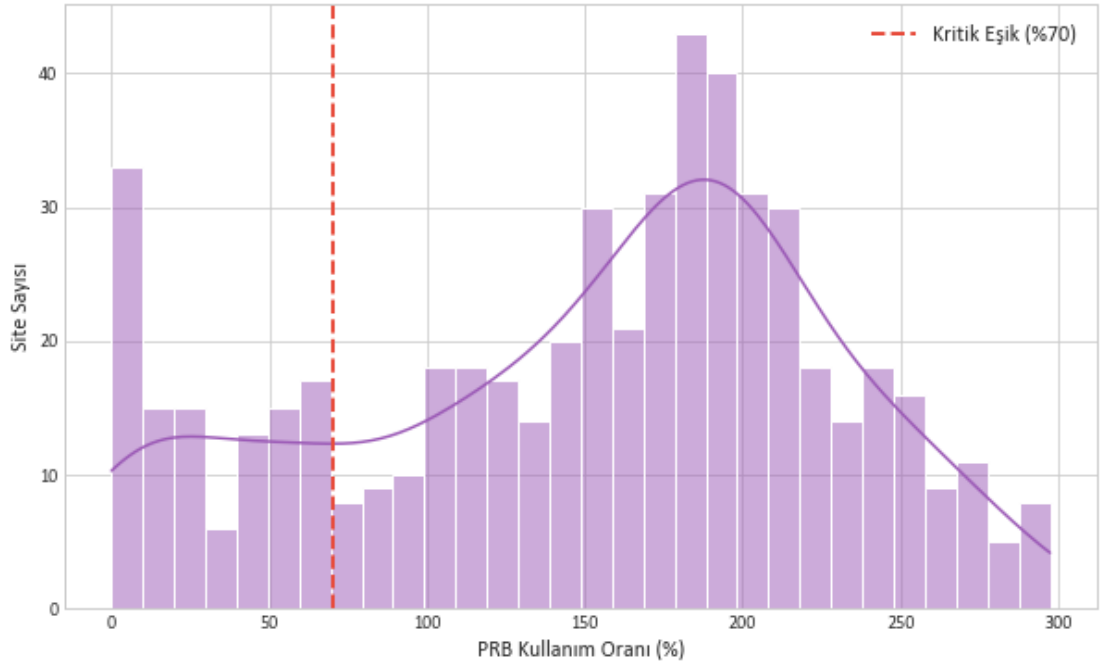
Şekil 10. Performans göstergeleri arasındaki korelasyon matrisi.

DL PRB (veri indirme yönündeki kaynak kullanım oranı), mobil şebeke performansının temel göstergelerinden biri olarak değerlendirilmekte olup, %70 seviyesi literatürde kritik eşik olarak kabul edilmektedir. Bu eşik değeri, kapasite yetersizliklerinin ve kullanıcı deneyiminde bozulmaların başladığı noktayı temsil eder (Nabi *et al.*, 2023; Siomin and Yuan, 2007; Flattie, 2019). Şekil 11’de, operatörün yedi farklı trafik ortamına göre sınıflandırdığı alanlarda DL PRB kullanım oranlarının dağılımı sunulmaktadır. Görsel incelendiğinde, bazı yüksek yoğunluklu ortam kategorilerinde PRB kullanım oranlarının medyan değerinin %150’ye kadar çıktığı ve büyük ölçüde kritik eşik olan %70’in üzerinde seyrettiği gözlenmektedir. Bu durum, ilgili bölgelerde kapasite baskısının yoğun olduğunu ve altyapının sınır seviyelerde çalıştığını ortaya koymaktadır. Buna karşılık, düşük yoğunluklu trafik ortamlarında PRB kullanım oranlarının bu bölgelere oranla daha düşük seviyelerde kaldığı ve kaynak kullanımında esneklik sağlandığı anlaşılmaktadır. Bu bulgular, kapasite planlamasında trafik ortamlarına göre farklılaştırılmış stratejilerin gerekliliğini açıkça ortaya koymakta; özellikle yoğun bölgelerde kapasite artırımı veya optimizasyon ihtiyacına işaret etmektedir.



Şekil 11. Trafik yoğunluğuna göre downlink PRB kullanım oranı (NET_02) dağılımı.

Şekil 12, sahalardaki downlink PRB kullanım oranının (NET_02) genel dağılımını göstermektedir. Görselde %70'lik bir kırmızı kesikli çizgi ile belirlenen kritik eşik, kaynak kullanımının sürdürülebilirlik sınırlarını vurgulamaktadır. Verilerin büyük kısmının bu eşik değerinin çok üzerinde yer alması, sistem kaynaklarının genel olarak yüksek yoğunlukla kullanıldığını ortaya koymaktadır. Bu da mevcut sistemin yoğun talep altında çalıştığını ve kapasite artırımı için potansiyel baskıların olabileceğini göstermektedir.



Şekil 12. Downlink PRB kullanım oranı (NET_02) dağılımı ve kritik eşik.

Mobil Őebeke performans verileri üzerinde geręekleŐtirilen ęalıŐmalar, sahalarn etkinlięini belirleyen temel faktörlerin ęok boyutlu ve dinamik olduęunu ortaya koymaktadır. Ele alınan iŐletmenin verileri üzerinde yapılan gorsel ve istatistiksel analizler, özellikle bant geniŐlięi, PRB kullanım oranı, mobil gelir geręekleŐmesi, kullanıcı sayısı ve veri kullanımı gibi metrikler arasındaki korelasyonların, aęın yüklenme ve gelir üretme kapasitesinin sahalarn arasında homojen daęılmadıęını göstermektedir. PRB kullanımının %70'in üzerinde olduęu sahalarn yoğun trafik baskısı altında olduęu ve bu durumun hizmet kalitesinde düşüŐ riski yarattıęı tespit edilmiŐtir. Bant geniŐlięi ile mobil gelir arasında pozitif yönlü bir korelasyonun ($r \approx 0.70$) bulunması, aę kapasitesinin gelir üretimi üzerinde belirleyici bir kaldıraç etkisine sahip olduęunu ortaya koymaktadır. Ancak aynı bant geniŐlięi düzeyinde farklı gelir seviyelerine sahip sahalarn gözlenmesi, saha performansının yalnızca tek bir metrik (örneğin gelir) üzerinden deęerlendirilmesinin ciddi anlamda yanıltıcı sonuçlar doğurabileceęine iŐaret etmektedir.

Özellikle mobil gelire odaklanan tek boyutlu analizler, Őebeke performansının bütüncül deęerlendirilmesine engel teşkil etmektedir. Gelir metrięi, teknik performansın yanı sıra kullanıcı profili, tarife politikaları, kampanya uygulamaları ve sosyoekonomik koŐullar gibi ęok sayıda dıŐsal etkene baęlı olarak deęiŐkenlik göstermektedir. Bu durum, teknik açıdan düşük performans sergileyen bir baz istasyonunun yüksek gelir üretmesi veya yüksek teknik kapasiteye sahip bir istasyonun düşük gelir elde etmesi gibi ęeliŐkili örneklerin ortaya ęıkmasına neden olabilmektedir. Ayrıca kısa vadeli gelir odaklı yaklaŐımlar, uzun vadeli kullanıcı memnuniyeti, aę sürdürülebilirlięi ve hizmet kalitesi gibi stratejik hedeflerin ihmal edilmesine yol aęabilmektedir. Gelire dayalı sıralamalar, bazı sahalarn yatırım önceliklerinin yanlış belirlenmesine ve bu nedenle hem teknik kapasite kullanımı hem de hizmet kalitesi açısından sistem bütünlüęünün zedelenmesine neden olabilir. Dolayısıyla mobil gelir, önemli bir gösterge olmakla birlikte, performans analizlerinde yalnız başına referans alınması uygun deęildir.

Bu ęok boyutlu ve nedensel olarak karmaŐık yapıyı analiz etmek ve saha önceliklendirme kararlarını daha tutarlı, dengeli ve öngörülebilir bir temele oturtmak amacıyla, bu ęalıŐmada YPO algoritmasına dayalı bir RL ortamı geliŐtirilmiŐtir. Model, ęeŐitli öznitelikleri birlikte dikkate alarak aęırlıklandırmalı kararlar vermekte ve farklı senaryolarda performans farklılıklarını öęrenerek saha sıralamasını dinamik biçimde dinamik biçimde iyileŐtirmeye yönelik tahminlerde bulunmaktadır. Böylece, yalnızca gelir gibi tekil metriklere dayalı karar verme süreçlerinin ötesine geçilmekte ve aęın genel verimlilięini artıracak daha

bütüncül bir yaklaşımla karar destek sağlanmaktadır. Modelin etkinliğini destekleyen bulgular ise aşağıdaki gibi özetlenebilir:

1. Çok Boyutlu Özellik Kümesi: İncelenen verilerden görüldüğü üzere şirket geliri yüksek olan sahalara yatırım yapmaktadır. Model, sadece gelir ya da trafik yüküne değil; aynı zamanda nüfus büyüme potansiyeli ve konut gelişim oranı gibi geleceğe dönük öznitelikleri de dikkate almaktadır. Modele dahil edilen stokastik veriler, belirsizliği modelleyen esnek bir yapı sunmaktadır.

2. Spearman Korelasyonuna Dayalı Performans Ölçütü: YPO ajanları, uzman sıralamalarıyla olan sıralama benzerliğini (Spearman ρ) maksimize edecek şekilde optimize edilmektedir. Bu, modelin yalnızca sayısal başarı değil, insan uzmanlığıyla uyumlu davranış öğrenmesi anlamına gelmektedir.

3. Özelleştirilebilir Ödül Fonksiyonu: Modelde kullanılan ödül fonksiyonu, korelasyon iyileşmesini teşvik ettiği gibi, ağırlıkların çeşitliliğini de artırmak üzere entropi bonusu içermektedir. Böylece, modelin farklı stratejileri keşfetmesi sağlanmakta ve yerel minimumlara sıkışması engellenmektedir.

4. Karar Destek Sistemi Olarak Kullanılabilirlik: Modelin çıktısı olan sıralamalar, operatör karar vericilerinin saha yatırımı ve kapasite artışı gibi müdahale planlarını sayısal verilere dayalı şekilde önceliklendirmesine olanak tanımaktadır. Bu, ağ planlamasında sezgisel yaklaşımlar yerine veriye dayalı stratejilerin önünü açar.

Elde edilen görsel bulgular ve korelasyon analizleri, tek boyutlu metriklerin saha başarımını olumsuz etkilediğini açıkça ortaya koymaktadır. Yani saha sıralaması yaparken, tek ölçüte dayalı sıralama yöntemi yeterli değildir. YPO algoritmasıyla eğitilen RL modeli, bu karmaşık ilişkiyi öğrenerek saha sıralamasını hem uzman görüşleriyle uyumlu hem de geleceğe dönük karar almayı destekleyecek şekilde gerçekleştirmektedir. Bu yaklaşım, mobil ağ planlamasında akıllı otomasyonun ve YZ destekli karar sistemlerinin uygulanabilirliğini güçlü biçimde desteklemektedir.

Türkiye'de Mevcut 5G Altyapısı: Durum Analizi

Şekil 13'te Türkiye genelinde mobil şebeke teknolojilerinin (2G, 3G, 4G, 4.5G, 5G) coğrafi kapsama alanlarını göstermektedir. Farklı renkler her bir erişim teknolojisini temsil ederken, yoğunluk şehir merkezlerinde artmakta; kırsal bölgelerde ise seyrekleşmektedir (Renkler farklı erişim teknolojilerini temsil eder. <https://www.nperf.com/tr/> adresinden uyarlanmıştır).



Şekil 13. Türkiye mobil şebeke kapsama haritası (2G–5G).

Şekil 14’te Türkiye genelinde kurulu olan 5G baz istasyonlarının konumları gösterilmektedir. Şekilden de görüldüğü üzere mevcut durumda Türkiye’de 5G erişimi sınırlıdır (Renkler 5G erişim teknolojisini temsil eder. <https://www.nperf.com/tr/> adresinden uyarlanmıştır).



Şekil 14. Türkiye’de 5G baz istasyonu kurulum dağılımı.

Son yıllarda dijital dönüşüm süreçleriyle paralel olarak küresel ölçekte önem kazanan 5G teknolojisi, yalnızca daha yüksek veri hızları sağlamakla kalmamakta; aynı zamanda endüstriyel otomasyon, IoT, uzaktan sağlık hizmetleri, akıllı şehir uygulamaları ve otonom ulaşım gibi alanlarda da çığır açan fırsatlar sunmaktadır. Bu yönüyle 5G, yalnızca bir iletişim altyapısı değil, aynı zamanda dijital ekonominin yeniden yapılandırılmasında stratejik bir kaldıraç işlevi görmektedir (Singh *et al.*, 2023; Çodur *et al.*, 2024).

Türkiye özelinde değerlendirildiğinde, 5G’nin potansiyelinden tam anlamıyla yararlanabilmesi için altyapı yatırımlarının kararlılıkla yönlendirilmesi gerekmektedir. Türkiye’nin neredeyse hiçbir şehrinde henüz 5G bağlantısı sağlanmamaktadır. Bu durum,

teknolojik eşitsizliklerin giderilmesi ve dijital uçurumun azaltılması açısından ciddi bir planlama ihtiyacını ortaya koymaktadır (Çodur *et al.*, 2024).

Türkiye'deki sınırlı 5G kapsama alanı, yalnızca fiziksel altyapı eksikliklerinden değil; aynı zamanda frekans tahsisi, düzenleyici belirsizlikler, yüksek yatırım maliyetleri ve özel sektörün dönüşüm kapasitesine ilişkin sınırlılıklardan da kaynaklanmaktadır. Özellikle gelişmekte olan ekonomilerde yaygın olarak gözlenen bu engeller, yalnızca teknik değil; finansal ve yönetsimsel düzeyde de ele alınmalıdır (Forge *et al.*, 2020; Rahman *et al.*, 2021).

Bu noktada, Türkiye'nin 5G'ye geçiş sürecinde izlenmesi gereken yol haritasının ele alınması gerekmektedir. Geliştirilecek yatırım planları, mevcut baz istasyonu altyapısının güçlendirilmesini içermelidir. Ayrıca, nüfus büyüme projeksiyonları, konut gelişim eğilimleri ve bölgesel veri kullanım senaryoları gibi parametrelerin, yatırım önceliklendirme modellerine entegre edilmesi önerilmektedir (Aktaş *et al.*, 2023; Çodur *et al.*, 2024).

ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, tez kapsamında geliştirilen YPO tabanlı DRL modelinin çıktıları analiz edilmekte ve aynı sıralama problemi için literatürde ele aldığımız (Aktaş *et al.*, 2023; Çodur *et al.*, 2024) metotlarla karşılaştırmalı olarak tartışılmaktadır. Elde edilen bulgular, modelin hem pratik uygulama açısından hem de istatistiksel doğruluk bakımından anlamlı avantajlar sunduğunu göstermektedir.

Korelasyon Performansı ve Sıralama Başarısı

Tez kapsamında geliştirilen modelin başarımı, uzmanlar tarafından belirlenen sıralamalarla olan benzerlik düzeyi üzerinden Spearman korelasyon katsayısı ile ölçülmüştür. Modelin nihai çıktılarında elde edilen korelasyon değeri 0,88 olarak tespit edilmiştir. Bu oran, özellikle sıralama problemlerinde yüksek kabul edilen bir başarı düzeyidir (Mukaka, 2012). Korelasyonun bu kadar yüksek çıkması, modelin öğrenme süreci boyunca uzman kararlarını büyük ölçüde taklit edebildiğini, fakat bunu tamamen veri temelli ve öznellikten arındırılmış biçimde gerçekleştirdiğini göstermektedir.

Aktaş *et al.* (2023) tarafından geliştirilen AHP-TOPSIS yöntemi ile yapılan çalışmalarda, uzman kararları belirli ağırlık katsayılarıyla hesaplanarak TOPSIS yöntemi üzerinden sıralama yapılmıştır. Bu yöntem uzman görüşlerine fazlasıyla bağımlı olup her karar vericinin öznel yargıları sonucunda farklı sonuçlar doğurabilmektedir. Ayrıca aynı çalışmada kullanılan 48 kriterin tamamı deterministik olup, değişkenler arası ilişkiler modele dışsal olarak entegre edilmiştir. Benzer şekilde, Çodur *et al.* (2024) tarafından önerilen FUCOM-Kosinüs benzerliği yöntemi de 36 deterministik veriye dayalı olarak çalışmakta ve kriter ağırlıkları yine uzmanların beyanına göre belirlenmektedir. Bu durum, sıralamaların tekrarlanabilirliğini ve genellenebilirliğini sınırlamaktadır.

Bu noktada YPO algoritmasının sağladığı avantaj ortaya çıkmaktadır: Ajanlar, herhangi bir ön tanımlı ağırlık setine ihtiyaç duymadan, öğrenme süreci boyunca kendi politika parametrelerini optimize ederek sıralama üretmektedir. Bu durum hem uzman müdahalesini azaltmakta hem de karar verme sürecini daha esnek hale getirmektedir.

Veri Kullanımı ve Modelin Pratikliği

Modelin önemli bir avantajı, çok az sayıda ama bilgi yoğunluğu yüksek özellik kullanmasıdır. Çalışmada toplamda yalnızca 5 deterministik ve 2 stokastik özellik ile sıralama

yapılabilmektedir. Bu yönüyle model, Aktaş *et al.* çalışmasında kullanılan 48 değişkene ve Çodur *et al.* çalışmasındaki 36 değişkene kıyasla oldukça yalın bir yapı sunmaktadır. Özellikle telekomünikasyon sektörü gibi veri temin sürecinin zor, pahalı ve zaman alıcı olduğu alanlarda daha az veriyle çalışan ama daha yüksek performans sunan bir modelin geliştirilmesi önemli bir katkı olarak değerlendirilebilir.

Bununla birlikte, veri seçim sürecinde yalnızca istatistiksel önemlilik değil, aynı zamanda karar destek açısından etkili olan değişkenlerin tercih edilmesi sağlanmıştır. SHAP analizi ile belirlenen en etkili beş özellik, modelin karar üretme kapasitesini yeterince temsil edecek şekilde seçilmiştir. Bu özellikler: NET_06 (LTE veri hacmi) REV_01 (mobil gelir gerçekleşen tutar), NET_01 (Tahsis edilen bant genişliği), G5_01 (5G aday müşterilerin veri kullanımı), G5_03 (5G'ye sahip müşterilerin veri kullanımı). Diğer yandan, çevresel belirsizliklerin modellenmesi amacıyla nüfus artışı ve konut gelişim hızı değişkenleri gamma dağılımına bağlı stokastik veriler olarak modele entegre edilmiştir.

Bu hibrit yapı, modelin yalnızca mevcut koşullara göre değil, aynı zamanda olası gelecek senaryolarına göre de karar verebilmesini sağlamaktadır. Bu sayede sadece bugünün yatırımları değil, geleceğin yatırım stratejileri için de değerli bir altyapı oluşturulmuştur.


Hata Metrikleri ve İstatistiksel Başarı

Model performansını değerlendirmek amacıyla sıralama doğruluğu analizlerinde sıklıkla tercih edilen MAE (Mean Absolute Error) ve RMSE (Root Mean Square Error) hata metrikleri dikkate alınmıştır. Önerilen yöntem, önceki sıralama algoritmalarıyla kıyaslandığında hem ortalama mutlak hata hem de karekök hata düzeyinde daha düşük değerler üretmiş, bu sayede tahmin edilen sıralamanın uzman sıralamalarına yüksek oranda yaklaştığı gösterilmiştir. Sıralama korelasyon testleri, modelin uzman değerlendirmeleriyle yüksek düzeyde uyum içinde olduğunu göstermektedir. Elde edilen Spearman $\rho = 0.879$ ve Kendall $\tau = 0.706$ değerleri, literatürde iki test içinde “çok güçlü” aralığında tanımlanmaktadır (Kolesov *et al.*, 2022; Wicklin, 2023; Ripberger *et al.*, 2025). Bu durum, modelin sıralama yapısının genel eğilimlerini yüksek doğrulukla yakaladığını ortaya koymaktadır. Tablo 5, literatürde raporlanan yöntemlerle bu çalışmada geliştirilen modelin korelasyon katsayıları ve hata ölçütleri bakımından karşılaştırılmasını sunmaktadır.


Tablo 5. Sıralama Yöntemlerinin Korelasyon ve Hata Metrikleri Karşılaştırması

Metot	Spearman ρ	p (Spearman)	Kendall's τ	p (Kendall)	RMSE	MAE
Fucom – Kosinus benzerliği (Çodur <i>et al.</i> , 2024)	0.734	P < 0.001	0.536	P < 0.001	121.36	92.60
AHP-TOPSIS (Aktaş <i>et al.</i> , 2023)	0.758	P < 0.001	0.564	P < 0.001	115.62	85.94
Önerilen YPO tabanlı model	0.879	P < 0.001	0.706	P < 0.001	81.92	58.01

Şekil 15, sıralama yöntemleri ile uzman değerlendirmeleri sonucu oluşturulan sıralamalar arasındaki uyumu, Spearman ve Kendall korelasyon katsayıları aracılığıyla karşılaştırmaktadır.

**Şekil 15.** Korelasyon metrikleri grafiği.

RMSE ve MAE değerlerinin grafiksel gösterimi olan Şekil 16, modellerin tahmin ettikleri sıralamaların uzman sıralamalarından ortalama sapma düzeylerini yansıtır. YPO modelinin RMSE = 81.92 ve MAE = 58.01 değerleri, diğer yöntemlere göre oldukça düşüktür. Bu durum, modelin yalnızca genel eğilimi değil, bireysel sıraları da daha doğru tahmin edebildiğini göstermektedir.



Şekil 16. Hata metrikleri grafiği.

Öte yandan, hata metriklerinin yorumlanabilirliğini artırmak amacıyla normalize edilmiş hata oranları da hesaplanmıştır (Taheri *et al.*, 2023). Sıralama değerlerinin 1 ile 576 arasında değiştiği dikkate alındığında:

- $RMSE \approx 81.92 / 576 \approx \%14,2$, yani modelin sıralama tahminleri ortalama $\%14,2$ sapma ile gerçekleşmiştir.
- $MAE \approx 58.01 / 576 \approx \%10,1$, yani ortalama sapma, sıralama aralığının yaklaşık $\%10$ 'una denk gelmektedir.

Bu oranlar, sıralama doğruluğunun yüksek olduğunu göstermekle birlikte, mükemmel sıralamanın henüz tam olarak elde edilemediğini işaret etmektedir. Ancak burada temel hedef, yalnızca matematiksel uyumu maksimize etmek değil, aynı zamanda insan davranışını modelleyerek uzman karar süreçlerine yaklaşımdır. Nitekim sıralamaları yapan saha uzmanları, verilere büyük ölçüde hâkim olsalar da değerlendirmelerinde belirli ölçüde öznel yaklaşımlar sergileyebilmektedir. Bu nedenle, modelin hatalarının bağlam içinde anlamlı olup olmadığını değerlendirmek için gözlemlenen sıralama verisinin standart sapması ile karşılaştırma yapılmıştır.

Moriassi *et al.* (2007) tarafından önerilen model değerlendirme kılavuzuna göre, RMSE ve MAE değerleri, gözlemlenen verilerin standart sapmasının yarısından küçükse 'düşük hata' olarak kabul edilmektedir. Uzman sıralamasının standart sapması $\approx 166,42$ olarak hesaplandığında:

- $0,5 \times \text{Standart Sapma} = 83,21$
- $RMSE = 81,92 < 83,21$

- MAE = 58,01 < 83,21 olarak bulunur. O halde bu hatalar kabul edilebilirdir.

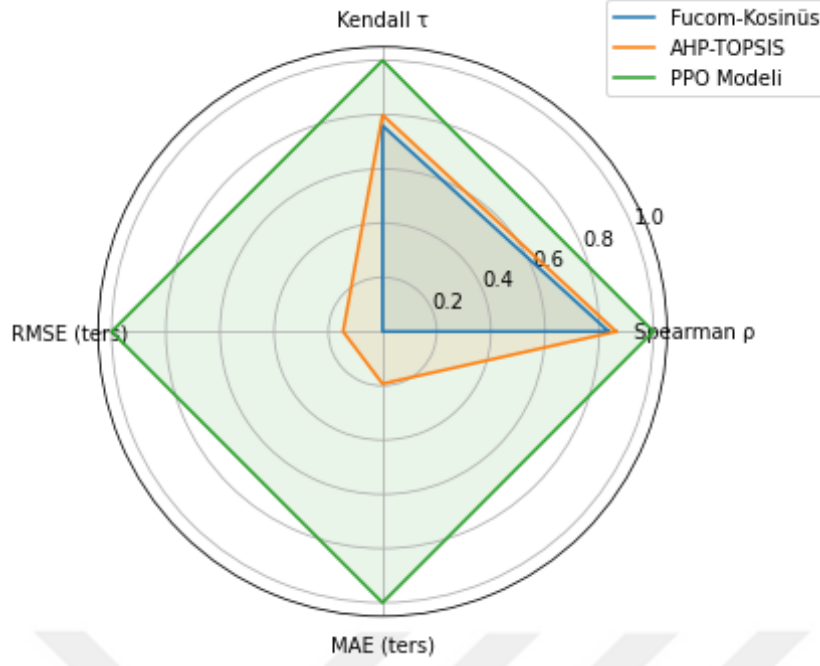
Ayrıca, RSR (RMSE/Standard Sapma) ≈ 0.49 değeri, Moriasi *et al.* (2007) sınıflandırmasına göre “çok iyi” hata düzeyi kategorisinde yer almaktadır. Bu sınıflandırma, RMSE'nin gözlem standart sapmasına oranı (RSR) temel alınarak model doğruluğunun niteliksel olarak değerlendirilmesini sağlar. Tablo 6, Moriasi *et al.* (2007) tarafından önerilen RSR (RMSE/Standart Sapma) temelli model performansı sınıflandırmasını sunmaktadır.

Tablo 6. RSR ile Model Performansı Sınıflandırması

RSR Aralığı	Değerlendirme
$0.00 \leq RSR \leq 0.50$	Çok İyi
$0.50 < RSR \leq 0.60$	İyi
$0.60 < RSR \leq 0.70$	Tatmin Edici
$RSR > 0.70$	Yetersiz

Sonuç olarak, önerilen YPO tabanlı model, yalnızca korelasyon katsayılarıyla değil, aynı zamanda hata metrikleri açısından da istatistiksel olarak güvenilir bir sıralama performansı sergilemiştir. RMSE ve MAE değerleri bağlam içinde normalleştirildiğinde ve veri setinin varyansıyla kıyaslandığında, modelin hata düzeyinin kabul edilebilir ve anlamlı olduğu görülmektedir. Bu tür normalizasyonlar, özellikle sıralama problemlerinde ölçekten bağımsız performans yorumlaması sağladığı için veri bilimi ve mühendislik literatüründe yaygın bir yaklaşımdır (Tsuang *et al.*, 2009).

Şekil 17, her yöntemin dört farklı metrik açısından normalize edilmiş başarı profilini sunar. Korelasyon katsayıları (Spearman ve Kendall) doğrudan normalize edilirken (fayda/kâr), hata metrikleri (RMSE ve MAE) ters normalize edilmiştir (zarar/maliyet). Bu ters normalizasyon, hata değerlerinin düşük olmasının performans açısından yüksek başarı anlamına geldiği varsayımıyla gerçekleştirilmiştir. Bu sayede tüm metrikler aynı ölçekte yorumlanabilir hâle gelmiş, grafik yüzeyinde daha büyük alan kaplayan modellerin genel performans açısından daha başarılı olduğu görselleştirilmiştir. YPO modeli tüm metriklerde normalize başarıya en çok yaklaşan yöntem olmuş, bu da onun genel olarak en üstün sıralama başarısını sunduğunu teyit etmektedir.



Şekil 17. Radar grafiği: normalize edilmiş performans profili.


Ödül Fonksiyonu ve Öğrenme Dinamikleri

Modelin öğrenme başarısında önemli bir etken, geliştirilmiş ödül fonksiyonudur. Temel ödül, uzman sıralaması ile model çıktısı arasındaki Spearman korelasyonuna dayandırılmış; ancak buna ek olarak, ajanların farklı ağırlık setlerini keşfetmesini teşvik eden entropi bazlı bonuslar da tanımlanmıştır. Böylece modelin yerel minimumlara sıkışması engellenmiş ve daha geniş bir politika arama alanı oluşturulmuştur.

Bu yapı, YPO algoritmasının doğası gereği sağladığı istikrarlı öğrenme süreciyle birleşerek hem kararlı hem de çeşitli karar kurallarının üretilmesini sağlamıştır. Eğitim süreci boyunca korelasyonun düzenli olarak arttığı, belirli eşiklerin aşılması durumunda modelin yeni sıralamaları kaydederek daha yüksek performansa ulaştığı gözlemlenmiştir.

Şekil 18 YPO algoritmasıyla gerçekleştirilen RL sürecinde, modelin yalnızca yeni bir Spearman korelasyon rekoru elde ettiği adımlardaki performans gelişimini göstermektedir. Yatay eksen, doğrudan eğitim adımları değil, yalnızca iyileşme sağlanan sıralı noktalar (rekor artışları) yer almaktadır. Dikey eksen ise, modelin tahmin ettiği saha sıralaması ile uzmanlar tarafından belirlenen sıralama arasındaki Spearman korelasyon katsayısını temsil etmektedir. Başlangıç korelasyonu, eğitim süreci başlamadan önce modelin rastgele atanan ağırlıklarla oluşturduğu sıralamanın uzman sıralamasıyla olan benzerliği esas alınarak hesaplanmıştır. Bu değer, modelin öğrenme sürecine sıfırdan başladığını ve ilk performans düzeyini nesnel biçimde ortaya koymaktadır. Grafik incelendiğinde, modelin başlangıç korelasyon değerinden itibaren kademeli olarak daha iyi sıralamalar öğrenerek performansını istikrarlı biçimde

geliştirdiği görülmektedir. Modelin başlangıçta ulaştığı görece yüksek korelasyon değeri, eğitim öncesi rastgele başlatılan ağırlıkların, SHAP analizi ile seçilmiş olan ve uzman sıralamasıyla ilişkili olduğu bilinen anlamlı özellikler üzerinde işlem yapmasından kaynaklanmaktadır. Bu durum, veri ön işleme sürecinde gerçekleştirilen nitelikli öznelik seçiminin, modelin yalnızca eğitimle değil başlangıçta güçlü bir sıralama performansı göstermesini mümkün kıldığını ortaya koymaktadır. Elde edilen sonuçlar, önerilen modelin uzman görüşleriyle yüksek derecede örtüşen sıralamalar oluşturabildiğini ve zamanla bu başarıyı artırdığını ortaya koymaktadır.



Şekil 18. Yalnızca rekor gelişmelerde gözlemlenen YPO tabanlı sıralama korelasyonu artışı.

Karar Destek Sistemlerine Uygunluk

Modelin sektörel karşılığı değerlendirildiğinde, sahalardaki yatırım kararlarının sezgisel yöntemler yerine veri temelli sistemlerle desteklenmesi gerektiği açıktır. Bu tez kapsamında geliştirilen model, operatörlerin yatırım planlama süreçlerinde bir karar destek sistemi olarak kullanılmaya uygundur. Modelin çıktısı, sahalara dair öncelik sıralaması ve buna eşlik eden skorlar olup; bu skorlar üzerinden saha bazlı kaynak tahsisi, altyapı genişletme ya da kapasite planlaması yapılabilmektedir.

Ayrıca modelin gerçek saha verileri ile eğitilmiş olması, çıktılarının doğrudan saha operasyonlarına entegre edilebilmesini mümkün kılmaktadır. Bu yönüyle model sadece akademik bir katkı değil, aynı zamanda ticari uygulanabilirliğe sahip bir çözüm önerisi olarak öne çıkmaktadır.

SONUÇLAR VE ÖNERİLER

Sonuçlar

Bu doktora çalışması kapsamında, Türkiye'deki telekomünikasyon sahalarının 5G altyapısına geçiş sürecinde önceliklendirilmesine yönelik olarak YZ destekli, veri temelli ve öğrenen bir karar destek modeli geliştirilmiştir. Özellikle YPO algoritması temel alınarak tasarlanan bu model, ajan tabanlı bir simülasyon ortamında eğitilmiş ve hem deterministik hem de stokastik verilerle beslenmiştir. Modelin genel yapısı, uzman sıralamalarıyla yüksek düzeyde örtüşen kararlar üretme kapasitesine sahiptir. Bu bölümde, çalışmanın temel çıktıları ve bu çıktılar üzerinden elde edilen bilimsel sonuçlar çok boyutlu bir şekilde ele alınmaktadır.

Öncelikle, modelin başarı düzeyi Spearman korelasyon katsayısı ile değerlendirilmiş ve uzmanların sağladığı sıralama ile YPO modeli tarafından üretilen sıralamalar arasında 0,88 düzeyinde bir korelasyon elde edilmiştir. Bu sonuç, sıralama problemlerinde yüksek başarı kriteri olarak değerlendirilmektedir. Literatürde korelasyon katsayısının 0,80 ile 1,00 arasında olması çok güçlü ilişki olarak kabul edildiği dikkate alındığında, elde edilen korelasyonun yüksek güvenilirlikte bir tahmin gücü sunduğu söylenebilir. Benzer şekilde Kendall's Tau ($\tau = 0.706$) katsayısı da iki sıralama arasındaki uyumun yüksek derecede tutarlı olduğunu göstermektedir. Elde edilen bu yüksek korelasyon değerleri, modelin yalnızca istatistiksel doğruluğunu değil, aynı zamanda uzman görüşleriyle örtüşen güvenilir bir karar destek mekanizması oluşturma potansiyelini de ortaya koymaktadır.

Geliştirilen modelin öne çıkan bir diğer yönü, veri verimliliğidir. Literatürde daha önce benzer amaçlarla yürütülen çalışmalarda oldukça yüksek sayıda değişkene ihtiyaç duyulmuştur. Örneğin, Aktaş *et al.* (2023) tarafından AHP-TOPSIS yöntemi ile yapılan çalışmada 48 farklı kriterin, Çodur *et al.* (2024) tarafından FUCOM-Kosinüs benzerliği yönteminde ise 36 kriterin analiz sürecine dâhil edildiği görülmektedir. Buna karşın bu tez kapsamında önerilen model yalnızca 5 deterministik ve 2 stokastik veri ile sıralama tahminini gerçekleştirmektedir. Bu durum, hem verilerin toplanma ve işleme sürecini sadeleştirmekte hem de uygulama açısından zaman ve kaynak verimliliği sağlamaktadır. Özellikle sektör koşullarında büyük veri kümelerinin toplanması ve uzman görüşlerinin organize edilmesi zorlayıcı olabileceği için, daha az veriyle yüksek doğruluk sağlayan sistemlerin önemi giderek artmaktadır.

Modelde kullanılan stokastik veriler, sistemin geleceğe dönük tahmin kapasitesini güçlendiren önemli bir bileşendir. Nüfus artış oranı ve konut gelişim hızı gibi iki temel sosyo-

demografik deęişken, stokastik temelli parametrelerle modellenmiş ve her eğitim döngüsünde farklı varyasyonlar olarak sistemin çevresel deęişkenliğe uyum sağlaması mümkün kılınmıştır. Bu durum, geleneksel modellerin deterministik doğasının aksine, sistemin daha dinamik ve adaptif bir yapıya kavuşmasına imkân vermiştir. Özellikle 5G yatırımlarının geleceęe dönük projeksiyonlar ile yapılması gerektięi düşünöldüğünde, bu özellik modelin özğün katkılarında biri olarak öne çıkmaktadır.

Geliştirilen modelin hata analizinde kullanılan metriklerden MAE ve RMSE deęerlerinin kabul edilebilir olduęu görölmüştür. Bu metriklerde sağlanan düşöklük, modelin sıralama tahminlerini yalnızca doğru sınıflandırmakla kalmayıp aynı zamanda öngörödeki sapmaları da minimumda tuttuęunu göstermektedir. Bu da modelin sahada karar alıcılara güvenilir çıktılar sunabileceęi anlamına gelir.

Modelin eğitim sürecinde kullanılan ödöl fonksiyonu, yalnızca korelasyonun artırılmasını deęil, aynı zamanda öğrenme sürecinde çeşitlilik (entropi) sağlayacak şekilde tasarlanmıştır. Bu çok bileşenli ödöl yapısı sayesinde ajanlar farklı stratejileri keşfetme olanaęı bulmuş; model, belirli bir çözüm yoluna sıkışmadan farklı veri senaryoları altında da yüksek performans göstermeye devam etmiştir. Bu durum modelin genellenebilirliğini ve esneklik düzeyini artırmıştır.

Tüm bu bulgular ışığında, çalışmanın ulaştığı temel sonuçlar şunlardır:

1. YPO tabanlı RL modeli, uzman sıralamalarıyla yüksek derecede uyumlu tahminler üretebilmekte ve sıralama problemlerinde kullanılabilir olacak etkili bir araç nitelięi taşımaktadır.
2. Kullanılan düşük sayıda özellik ile yüksek doğruluk düzeyine ulaşılması, modelin uygulama açısından maliyet ve zaman tasarrufu sağladığını göstermektedir.
3. Stokastik özelliklerin modellenmesi, sistemin yalnızca mevcut koşullara deęil, aynı zamanda gelecek projeksiyonlara da uyum sağlayabileceğini ortaya koymaktadır.
4. Modelin hata metriklerinde gösterdiği başarı, öngörü istikrarı ve güvenilirliği açısından önemli bir göstergedir.

YPO algoritmasının sunduęu politika güncelleme kararlılığı ve entropi odaklı öğrenme mekanizması, geleneksel sıralama modellerine göre daha geniş bir keşif ve adaptasyon yeteneęi sunmaktadır.

Öneriler

Bu çalışmanın bulguları doğrultusunda hem akademik hem de sektörel düzeyde çeşitli önerilerde bulunmak mümkündür. Aşağıda kısa, orta ve uzun vadeli öneriler başlıklar hâlinde sunulmaktadır:

Uygulama tabanlı öneriler

Geliştirilen model, Türkiye’de faaliyet gösteren telekomünikasyon firmalarının mevcut saha planlaması ve yatırım önceliklendirme süreçlerine entegre edilebilir. Bu sayede kararlar sezgisel yaklaşımlar yerine, veri ve öğrenme temelli mekanizmalarla desteklenmiş olur.

Mevcut model, bir karar destek sistemi olarak arayüzlü bir yazılım ortamına dönüştürülerek saha mühendislerinin ve planlama yöneticilerinin günlük operasyonel kararlarına yardımcı olacak şekilde kullanılabilir.

Modelin farklı coğrafi bölgelerde yeniden eğitilerek test edilmesi, yapının genellenebilirliğini sınamak açısından önemlidir.

Bilimsel geliştirme önerileri

Modelin yalnızca sıralama değil, aynı zamanda sınıflandırma ya da tahminleme yapabilecek bir genişletilmiş versiyonu geliştirilebilir. Bu, örneğin “bir saha kaç ay içinde 5G yatırımına hazır hale gelecektir?” gibi öngörülerini mümkün kılacaktır.

Politika ve yatırım stratejisi önerileri

Türkiye'deki 5G geçiş sürecinde, altyapı yatırımlarının hangi sırayla ve hangi sahalarda yapılması gerektiği gibi stratejik kararlar bu modelle desteklenerek kamusal ve özel yatırımcılar için bilimsel zemin oluşturulabilir.

Telekomünikasyon altyapısı gibi yüksek maliyetli alanlarda, sınırlı kaynakların maksimum fayda sağlayacak şekilde yönlendirilmesi amacıyla model çıktıları kamu ve özel sektör tarafından ortak karar mekanizmalarında kullanılabilir.

Ekonomik genişleme ve maliyet odaklı modelleme önerileri

Geliştirilen modelin sağladığı otomasyon ve yüksek doğruluk, yalnızca karar kalitesini değil, aynı zamanda operasyonel süreçlerin maliyet etkinliğini de artırmaktadır. Geleneksel yöntemlerle yürütülen saha önceliklendirme süreçlerinde saha uzmanlarının yoğun katılımına ihtiyaç duyulmakta, bu da zaman ve insan kaynağı açısından önemli maliyetler doğurmaktadır. Modelin veri temelli yapısı sayesinde uzman müdahalesine olan ihtiyaç azalarak, yatırım kararlarında görevli personelin iş yükü düşmekte ve bu durum maaş, zaman ve planlama

kaynaklı operasyonel maliyetlerde azalma potansiyeli sunmaktadır. Bu bağlamda, gelecekte yapılacak çalışmalarda modelin yalnızca sıralama doğruluğu değil, aynı zamanda maliyet-etkinlik üzerinden de geliştirilmesi önerilmektedir. Özellikle her bir sahanın yatırım maliyetleri, işletme giderleri ve tahmini gelirlerinin modele entegre edilmesiyle, yatırım geri dönüşü odaklı kararlar üretmek mümkün olacaktır. Bu tür bir bütünsel yaklaşım, yalnızca doğru sıralama kararlarını değil, aynı zamanda kaynakların en verimli şekilde kullanılmasını sağlayarak toplam yatırım performansını artıracaktır. Ayrıca önerilen sistemin bu yönde genişletilmesi, kamu ve özel sektörde karar vericiler için daha sürdürülebilir, hesap verebilir ve rasyonel planlamaların yapılabilmesine imkân tanıyacaktır.



KAYNAKLAR

- Abar, S., Theodoropoulos, G. K., Lemarinier, P., & O'Hare, G. M. (2017). Agent Based Modelling and Simulation tools: A review of the state-of-art software. *Computer Science Review*, 24, 13-33.
- Abba Ari, A. A., Samafou, F., Ndam Njoya, A., Djedouboum, A. C., Aboubakar, M., & Mohamadou, A. (2025). IoT-5G and B5G/6G resource allocation and network slicing orchestration using learning algorithms. *IET Networks*, 14(1), e70002.
- Adebusola, J. A., Ariyo, A. A., Elisha, O. A., Olubunmi, A. M., & Julius, O. O. (2020, March). An overview of 5G technology. In *2020 international conference in mathematics, computer engineering and computer science (ICMCECS)* (pp. 1-4). IEEE.
- Agiwal, M., Roy, A., & Saxena, N. (2016). Next generation 5G wireless networks: A comprehensive survey. *IEEE communications surveys & tutorials*, 18(3), 1617-1655.
- Agiwal, M., Roy, A., & Saxena, N. (2016). Next generation 5G wireless networks: A comprehensive survey. *IEEE communications surveys & tutorials*, 18(3), 1617-1655.
- Ahamed, M. M., & Faruque, S. (2021). 5G network coverage planning and analysis of the deployment challenges. *Sensors*, 21(19), 6608.
- Ahmad, I., Shahabuddin, S., Kumar, T., Okwuibe, J., Gurtov, A., & Ylianttila, M. (2019). Security for 5G and beyond. *IEEE Communications Surveys & Tutorials*, 21(4), 3682-3722.
- Ahmed, T. H., Tiang, J. J., Mahmud, A., Gwo Chin, C., & Do, D. T. (2023). Deep reinforcement learning-based adaptive beam tracking and resource allocation in 6g vehicular networks with switched beam antennas. *Electronics*, 12(10), 2294.
- Aktaş, S., Çodur, S., Erkayman, B., Yıldız, G., Gemalmaz, A., & Dikel, A. (2023, July). Evaluation of 5G Infrastructure Investment Options Using the AHP-TOPSIS Method. In *2023 31st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Anonymous, 2023. 5G vs 4G. Cisco. Erişim adresi: <https://www.cisco.com/site/us/en/learn/topics/networking/5g-vs-4g.html> (15.06.2025).
- Anonymous, 2024. Agent-based model. Wikipedia, https://en.wikipedia.org/wiki/Agent-based_model (24.06.2025).
- Arulkumaran, K., Deisenroth, M. P., Brundage, M., & Bharath, A. A. (2017). Deep reinforcement learning: A brief survey. *IEEE Signal Processing Magazine*, 34(6), 26-38.
- Azimi, Y., Yousefi, S., Kalbkhani, H., & Kunz, T. (2021). Energy-efficient deep reinforcement learning assisted resource allocation for 5G-RAN slicing. *IEEE Transactions on Vehicular Technology*, 71(1), 856-871.
- Barakabitze, A. A., Ahmad, A., Mijumbi, R., & Hines, A. (2020). 5G network slicing using SDN and NFV: A survey of taxonomy, architectures and future challenges. *Computer Networks*, 167, 106984.
- Barto, A. G. (1997). Reinforcement learning. In *Neural systems for control* (pp. 7-30). Academic Press.

- Bøhn, E., Coates, E. M., Moe, S., & Johansen, T. A. (2019, June). Deep reinforcement learning attitude control of fixed-wing UAVs using proximal policy optimization. In 2019 international conference on unmanned aircraft systems (ICUAS) (pp. 523-533). IEEE.
- Bonabeau, E. (2002). Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the national academy of sciences*, 99(suppl_3), 7280-7287.
- Boujelben, Y. (2021). Scalable and QoS-aware resource allocation to heterogeneous traffic flows in 5G. *IEEE Internet of Things Journal*, 8(20), 15568-15581.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Chávez-Santiago, R., Szydełko, M., Kliks, A., Foukalas, F., Haddad, Y., Nolan, K. E., Kelly, M.Y., Masonta, M.T., & Balasingham, I. (2015). 5G: The convergence of wireless communications. *Wireless Personal Communications*, 83, 1617-1642.
- Chen, L. (2012). Agent-based modeling in urban and architectural research: A brief literature review. *Frontiers of Architectural Research*, 1(2), 166-177.
- Chen, X., Ng, D. W. K., Yu, W., Larsson, E. G., Al-Dhahir, N., & Schober, R. (2020). Massive access for 5G and beyond. *IEEE Journal on Selected Areas in Communications*, 39(3), 615-637.
- Cheng, Y., Huang, L., & Wang, X. (2021). Authentic boundary proximal policy optimization. *IEEE Transactions on Cybernetics*, 52(9), 9428-9438.
- Chiaraviglio, L., Cacciapuoti, A. S., Di Martino, G., Fiore, M., Montesano, M., Trucchi, D., & Melazzi, N. B. (2018). Planning 5G networks under EMF constraints: State of the art and vision. *Ieee Access*, 6, 51021-51037.
- Çodur, S., Erkeyman, B., Alp, S. S., Özenir, O., Pamucar, D., Yıldız, G., Gemalmaz, A., Dikel, A., Simic, V., Akın, H., Yılmaz, Y., Türk, Y., & Aktaş, S., (2024), Application of the full consistency method (FUCOM)-Cosine similarity framework in 5G infrastructure investment planning: An approach for telecommunication quality improvements, *Heliyon*, 10(9).
- Culot, G., Nassimbeni, G., Orzes, G., & Sartor, M. (2020). Behind the definition of Industry 4.0: Analysis and open questions. *International Journal of Production Economics*, 226, 107617.
- Dighriri, M., Alfoudi, A. S. D., Lee, G. M., Baker, T., & Pereira, R. (2018, May). Resource allocation scheme in 5G network slices. In 2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA) (pp. 275-280). IEEE.
- Engstrom, L., Ilyas, A., Santurkar, S., Tsipras, D., Janoos, F., Rudolph, L., & Madry, A. (2019, May). Implementation matters in deep rl: A case study on ppo and trpo. In *International conference on learning representations*.
- Folgado, F. J., Calderón, D., González, I., & Calderón, A. J. (2024). Review of Industry 4.0 from the perspective of automation and supervision systems: Definitions, architectures and recent trends. *Electronics*, 13(4), 782.
- Folgado, F. J., Calderón, D., González, I., & Calderón, A. J. (2024). Review of Industry 4.0 from the perspective of automation and supervision systems: Definitions, architectures and recent trends. *Electronics*, 13(4), 782.
- Gawas, A. U. (2015). An overview on evolution of mobile wireless communication networks: 1G-6G. *International journal on recent and innovation trends in computing and communication*, 3(5), 3130-3133.

- Gilbert, N., and K. Troitzsch. 2005. *Simulation for the Social Scientist*. McGraw-Hill. 2nd ed. GMU (George Mason University). 2014. MASON Home Page. <http://cs.gmu.edu/~eclab/projects/mason/> [Accessed July 29, 2014].
- Gu, Y., Cheng, Y., Chen, C. P., & Wang, X. (2021). Proximal policy optimization with policy feedback. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(7), 4600-4610.
- Gu, Y., Cheng, Y., Chen, C. P., & Wang, X. (2021). Proximal policy optimization with policy feedback. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(7), 4600-4610.
- Guan, W., Zhang, H., & Leung, V. C. (2021). Customized slicing for 6G: Enforcing artificial intelligence on resource management. *IEEE network*, 35(5), 264-271.
- Gülseren, A., & Sağbaş, A. (2019). Endüstri 4.0 perspektifinde sanayide dijital dönüşüm ve dijital olgunluk seviyesinin değerlendirilmesi. *European Journal of Engineering and Applied Sciences*, 2(2), 1-5.
- Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 1157–1182.
- Han, W., & Wang, X. (2024). Diverse and Differentiated QoS Provisioning for 6G Communications via Demand-Aware Prioritization and DEI-based Resource Allocation. *IEEE Transactions on Wireless Communications*.
- Hanappi, H. (2017). Agent-based modelling. History, essence, future. *PSL Quarterly Review*, 70(283), 449-472.
- Harzing, A. W., & Alakangas, S. (2016). Google Scholar, Scopus and the Web of Science: a longitudinal and cross-disciplinary comparison. *Scientometrics*, 106, 787-804.
- Heath, B. L., & Hill, R. R. (2010). Agent-based modeling: A historical perspective and a review of validation and verification efforts. *Handbook of research on discrete event simulation environments: technologies and applications*, 28-57.
- Hu, H., Yang, Y., Guo, Y., Gao, Z., & Rui, L. (2023, June). Improved MAPPO-based Collaborative Computing Offloading Algorithm in Broadband Mobile Internet. In *2023 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)* (pp. 1-6). IEEE.
- Hwangbo, J., Sa, I., Siegwart, R., & Hutter, M. (2017). Control of a quadrotor with reinforcement learning. *IEEE Robotics and Automation Letters*, 2(4), 2096-2103.
- Jyoti, Noliya, A., & Kumar, D. (2025). Resource Allocation in 5G NR Networks via Hybrid Lyrebird-Red Panda Optimization Model. *International Journal of Communication Systems*, 38(3), e6089.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement Learning: A Survey. *Journal of Artificial Intelligence Research*, 4, 237–285.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Kalusivalingam, A. K., Sharma, A., Patel, N., & Singh, V. (2020). Optimizing Industrial Systems Through Deep Q-Networks and Proximal Policy Optimization in Reinforcement Learning. *International Journal of AI and ML*, 1(3).
- Kamruzzaman, M., Sarkar, N. I., & Gutierrez, J. (2024). Machine Learning-Based Resource Allocation Algorithm to Mitigate Interference in D2D-Enabled Cellular Networks. *Future Internet*, 16(11), 408.

- Karuppiyan, M., Subramani, H., Kandasamy Raju, S., & Maradi Anthonymuthu Prakasam, M. (2024). Dynamic resource allocation in 5G networks using hybrid RL-CNN model for optimized latency and quality of service. *Network: Computation in Neural Systems*, 1-25.
- Khani, M., Jamali, S., Sohrabi, M. K., Sadr, M. M., & Ghaffari, A. (2024). Resource allocation in 5G cloud-RAN using deep reinforcement learning algorithms: A review. *Transactions on Emerging Telecommunications Technologies*, 35(1), e4929.
- Kholidy, H. A. (2025). Dynamic network slicing orchestration in open 5G networks using multi-criteria decision making and secure federated learning techniques. *Cluster Computing*, 28(4), 237.
- Klügl, F. (2016). *Agent-based simulation engineering*.
- Kolesov, D. E., Sinegubova, M. V., Dayanova, L. K., Dolzhikova, I. V., Vorobiev, I. I., & Orlova, N. A. (2022). Fast and accurate surrogate virus neutralization test based on antibody-mediated blocking of the interaction of ACE2 and SARS-CoV-2 spike protein RBD. *Diagnostics*, 12(2), 393.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.
- Kutscher, D. (2016, April). It's the network: Towards better security and transport performance in 5G. In *2016 IEEE conference on computer communications workshops (INFOCOM WKSHPS)* (pp. 656-661). IEEE.
- Lekshmi, S. (2023, May 9). Private 5G: Promising Industry 4.0 transformation. Calsoft Inc. Blog. from <https://www.calsoftinc.com/blogs/private-5g-promising-industry-4-0-transformation.html> (13.06.2025)
- Liu, B., Luo, J., & Su, X. (2021). The Framework of 6G Self-Evolving Networks and the Decision-Making Scheme for Massive IoT. *Applied Sciences*, 11(19), 9353.
- Lopes, G. C., Ferreira, M., da Silva Simões, A., & Colombini, E. L. (2018, November). Intelligent control of a quadrotor with proximal policy optimization reinforcement learning. In *2018 Latin American robotic symposium, 2018 Brazilian symposium on robotics (SBR) and 2018 workshop on robotics in education (WRE)* (pp. 503-508). IEEE.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Lundgren, C., Turanoglu Bekar, E., Barring, M., Stahre, J., Skoogh, A., Johansson, B., & Hedman, R. (2022). Determining the impact of 5G-technology on manufacturing performance using a modified TOPSIS method. *International Journal of Computer Integrated Manufacturing*, 35(1), 69-90.
- Lundgren, C., Turanoglu Bekar, E., Barring, M., Stahre, J., Skoogh, A., Johansson, B., & Hedman, R. (2022). Determining the impact of 5G-technology on manufacturing performance using a modified TOPSIS method. *International Journal of Computer Integrated Manufacturing*, 35(1), 69-90.
- Macal, C. M. (2010, December). To agent-based simulation from system dynamics. In *Proceedings of the 2010 winter simulation conference* (pp. 371-382). IEEE.
- Macal, C. M. (2016). Everything you need to know about agent-based modelling and simulation. *Journal of Simulation*, 10(2), 144-156.

- Macal, C. M., & North, M. J. (2009, December). Agent-based modeling and simulation. In *Proceedings of the 2009 winter simulation conference (WSC)* (pp. 86-98). IEEE.
- Macal, C. M., & North, M. J. (2010). Tutorial on agent-based modelling and simulation. *Journal of Simulation*, 4(3), 151–162. <https://doi.org/10.1057/jos.2010.3>
- Macal, C., & North, M. (2014, December). Introductory tutorial: Agent-based modeling and simulation. In *Proceedings of the winter simulation conference 2014* (pp. 6-20). IEEE.
- Mahmood, T., & ur Rehman, U. (2025). Resource allocation strategy selection for 5G network by using multi-attribute decision-making approach based on tangent trigonometric bipolar fuzzy aggregation operators. *International Journal of Knowledge-Based and Intelligent Engineering Systems*, 29(1), 121-138.
- Malandrino, F., Chiasserini, C. F., & Landi, G. (2019). Service shifting: A paradigm for service resilience in 5g. *IEEE Communications Magazine*, 57(9), 120-125.
- Mbulwa, A. I., Yew, H. T., Chekima, A., & Dargham, J. A. (2024, June). Handover Optimization Framework for Next-Generation Wireless Networks: 5G, 5G– Advanced and 6G. In *2024 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)* (pp. 409-414). IEEE.
- Meng, W., Zheng, Q., Pan, G., & Yin, Y. (2023, June). Off-policy proximal policy optimization. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 37, No. 8, pp. 9162-9170).
- Meng, W., Zheng, Q., Pan, G., & Yin, Y. (2023, June). Off-policy proximal policy optimization. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 37, No. 8, pp. 9162-9170).
- Metre, P. B., Kalnoor, G., Mahesh, G., & Gowrishankar, S. (2025). A Comparative Study of Network Slicing Techniques for effective utilization of channel for 5G and Beyond 5G Networks. *IEEE Access*.
- Moriassi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Mukaka, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. *Malawi medical journal*, 24(3), 69-71.
- Mushtaq, M. I., Chughtai, O., Naeem, M., Iqbal, M., & Yuen, C. (2024). Service Priority-Driven Resource Management in Multi-User, Multi-Service, and Multi-Device 6G Wireless Networks. *IEEE Internet of Things Journal*.
- Nguyen, D. C., Pathirana, P. N., Ding, M., & Seneviratne, A. (2020). Blockchain for 5G and beyond networks: A state of the art survey. *Journal of Network and Computer Applications*, 166, 102693.
- Nguyen, H. X., Trestian, R., To, D., & Tatipamula, M. (2021). Digital twin for 5G and beyond. *IEEE Communications Magazine*, 59(2), 10-15.
- Ning, Z., Wang, X., Rodrigues, J. J., & Xia, F. (2019). Joint computation offloading, power allocation, and channel assignment for 5G-enabled traffic management systems. *IEEE Transactions on Industrial Informatics*, 15(5), 3058-3067.
- O'Hare, G. M., & Jennings, N. R. (Eds.). (1996). *Foundations of distributed artificial intelligence*. John Wiley & Sons.
- O'Hare, G. M., Duffy, B. R., Bradley, J. F., & Martin, A. (2003). *Agent chameleons: Moving minds from robots to digital information spaces*.

- Othman, A., & Nayan, N. A. (2019). Efficient admission control and resource allocation mechanisms for public safety communications over 5G network slice. *Telecommunication Systems*, 72(4), 595-607.
- Oughton, E. J., & Frias, Z. (2018). The cost, coverage and rollout implications of 5G infrastructure in Britain. *Telecommunications Policy*, 42(8), 636-652.
- Özaktaş, F. D., & Ardiyok, Ş. (2025). Policies and legislation: A historical overview and current perspectives on digitalization in Türkiye. *The Economics and Regulation of Digitalisation*, 43-64.
- Rao, S. K., & Prasad, R. (2018). Impact of 5G technologies on industry 4.0. *Wireless personal communications*, 100, 145-159.
- Rasheed, I. (2022). Dynamic mode selection and resource allocation approach for 5G-vehicle-to-everything (V2X) communication using asynchronous federated deep reinforcement learning method. *Vehicular Communications*, 38, 100532.
- Reynolds, C. W. (1987, August). Flocks, herds and schools: A distributed behavioral model. In *Proceedings of the 14th annual conference on Computer graphics and interactive techniques* (pp. 25-34).
- Ripberger, A., Onder, Y., Plunkett, O., Reilly, C., & Mansson, J. A. (2025). Definition of feel-related impact parameters of tennis rackets and correlations with racket properties. *Sports Engineering*, 28(1), 1-12.
- Sag, A. (2025, 4 Şubat). The state of 5G developments in 2024 and 5G predictions for 2025. **Forbes**. Erişim adresi: <https://www.forbes.com/sites/moorinsights/2025/02/04/the-state-of-5g-developments-in-2024-and-5g-predictions-for-2025/> (15.06.2025).
- Schelling, T. C. (1971). Dynamic models of segregation. *Journal of Mathematical Sociology*, 1(2), 143–186.
- Schulman, J., Wolski, F., Dhariwal, P., Radford, A., & Klimov, O. (2017). Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*.
- Shakya, J., Ghribi, C., Chopin, M., & Merghem-Boulahia, L. (2023, January). Agent-based simulation for placement and pricing of 5G network slices. In *2023 IEEE 20th Consumer Communications & Networking Conference (CCNC)* (pp. 883-884). IEEE.
- Shapley, L. S. (1953). A value for n-person games.
- Shokrnezhad, M., & Taleb, T. (2022, December). Near-optimal cloud-network integrated resource allocation for latency-sensitive b5g. In *GLOBECOM 2022-2022 IEEE Global Communications Conference* (pp. 4498-4503). IEEE.
- Shokrnezhad, M., Taleb, T., & Dazzi, P. (2023). Double deep q-learning-based path selection and service placement for latency-sensitive beyond 5g applications. *IEEE Transactions on Mobile Computing*, 23(5), 5097-5110.
- Singh, S., Rosak-Szyrocka, J., Drotár, I., & Fernando, X. (2023). Oceania's 5G multi-tier fixed wireless access link's long-term resilience and feasibility analysis. *Future Internet*, 15(10), 334.
- Singh, S., Rosak-Szyrocka, J., Drotár, I., & Fernando, X. (2023). Oceania's 5G multi-tier fixed wireless access link's long-term resilience and feasibility analysis. *Future Internet*, 15(10), 334.
- Sisinni, E., Saifullah, A., Han, S., Jennehag, U., & Gidlund, M. (2018). Industrial internet of things: Challenges, opportunities, and directions. *IEEE transactions on industrial informatics*, 14(11), 4724-4734.

- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
- Taheri, M., Schreiner, H. K., Mohammadian, A., Shirkhani, H., Payeur, P., Imanian, H., & Cobo, J. H. (2023). A review of machine learning approaches to soil temperature estimation. *Sustainability*, 15(9), 7677.
- Tesfatsion, L. (2023). Agent-based computational economics: Overview and brief history. *Artificial intelligence, learning and computation in economics and finance*, 41-58.
- Thantharate, A., Paropkari, R., Walunj, V., & Beard, C. (2019, October). DeepSlice: A deep learning approach towards an efficient and reliable network slicing in 5G networks. In *2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)* (pp. 0762-0767). IEEE.
- Tsuang, B. J., Tu, C. Y., Tsai, J. L., Dracup, J. A., Arpe, K., & Meyers, T. (2009). A more accurate scheme for calculating Earth's skin temperature. *Climate dynamics*, 32, 251-272.
- Tufeanu, L. M., Vochin, M. C., Paraschiv, C. L., & Li, F. Y. (2023, October). Enabling Reinforcement Learning for Network Slice Management in Multi-Agent 5G Networks. In *2023 IEEE 9th World Forum on Internet of Things (WF-IoT)* (pp. 1-6). IEEE.
- Vaidya, S., Ambad, P., & Bhosle, S. (2018). Industry 4.0—a glimpse. *Procedia manufacturing*, 20, 233-238.
- Varga, P., Peto, J., Franko, A., Balla, D., Haja, D., Janky, F., Soos, G., Ficzer, D., Maliosz, M., & Toka, L. (2020). 5g support for industrial iot applications—challenges, solutions, and research gaps. *Sensors*, 20(3), 828.
- Vilà Muñoz, I., Pérez Romero, J., & Sallent Roig, O. (2024). A transfer reinforcement learning approach for capacity sharing in Beyond 5G networks. *Future internet*, 16(12, article 434).
- Vitturi, S., Zunino, C., & Sauter, T. (2019). Industrial communication systems and their future challenges: Next-generation Ethernet, IIoT, and 5G. *Proceedings of the IEEE*, 107(6), 944-961.
- Von Neumann, J. (1951). The general and logical theory of automata. In L. A. Jeffress (Ed.), **Cerebral mechanisms in behavior: The Hixon Symposium** (pp. 1–31). John Wiley and Sons.
- Wang, C. H., Lee, C. J., & Wu, X. (2020). A coverage-based location approach and performance evaluation for the deployment of 5G base stations. *IEEE Access*, 8, 123320-123333.
- Wang, H., Liang, Q., Hancock, J. T., & Khoshgoftaar, T. M. (2024). Feature selection strategies: a comparative analysis of SHAP-value and importance-based methods. *Journal of Big Data*, 11(1), 44.
- Wang, S., & Ferrús, R. (2019, June). On the use of prioritization and network slicing features for mission critical and commercial traffic multiplexing in 5G Radio Access Networks. In *2019 IEEE Symposium on Computers and Communications (ISCC)* (pp. 1-6). IEEE.
- Wang, Y., He, H., & Tan, X. (2020, August). Truly proximal policy optimization. In *Uncertainty in artificial intelligence* (pp. 113-122). PMLR.
- Wang, Z., Wei, Y., Yu, F. R., & Han, Z. (2020, December). Utility optimization for resource allocation in edge network slicing using DRL. In *GLOBECOM 2020-2020 IEEE Global Communications Conference* (pp. 1-6). IEEE.

- Wicklin, R. 2023. Interpret Spearman and Kendall correlation coefficients. SAS Blogs. <https://blogs.sas.com/content/iml/2023/04/05/interpret-spearman-kendall-corr.html> (29.06.2025).
- Xiao, T., Chao, K., Liu, G., Li, Y., Xu, G., Xu, L., Cheng, C., Jin, Y., & Zheng, Y. (2021, December). 5G residency enhancement method based on 5g beam intelligent optimization. In 2021 20th International Conference on Ubiquitous Computing and Communications (IUCC/CIT/DSCI/SmartCNS) (pp. 528-534). IEEE.
- Ye, F., Cheng, X., Wang, P., Chan, C. Y., & Zhang, J. (2020, October). Automated lane change strategy using proximal policy optimization-based deep reinforcement learning. In 2020 IEEE Intelligent Vehicles Symposium (IV) (pp. 1746-1752). IEEE.
- Zakharenkov, A., & Makarov, I. (2021, November). Deep reinforcement learning with dqn vs. ppo in vizdoom. In 2021 IEEE 21st international symposium on computational intelligence and informatics (CINTI) (pp. 000131-000136). IEEE.
- Zhang, C., Ueng, Y. L., Studer, C., & Burg, A. (2020). Artificial intelligence for 5G and beyond 5G: Implementations, algorithms, and optimizations. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 10(2), 149-163.
- Zhang, H., Liu, N., Chu, X., Long, K., Aghvami, A. H., & Leung, V. C. (2019). Network slicing based 5G and future mobile networks: mobility, resource management, and challenges. *IEEE Communications Magazine*, 55(8), 138-145.
- Zielinski, E., Schulz-Zander, J., Zimmermann, M., Schellenberger, C., Ramirez, A., Zeiger, F., Mormul, M., Hetzelt, F., Beierle, F., Klaus, H., Ruckstuhl, H., & Artemenko, A. (2019, March). Secure real-time communication and computing infrastructure for Industry 4.0—challenges and opportunities. In 2019 international conference on networked systems (NetSys) (pp. 1-6). IEEE

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	: Sadrettin ÇODUR
Doğum tarihi	:
Doğum Yeri	:
Uyruğu	:
Adres	:
Tel	:
E-mail	:
Eğitim	
Lise	: Erzurum Lisesi
Lisans	: Atatürk Üniversitesi Mühendislik Fakültesi, Endüstri Mühendisliği
Yüksek lisans	: Atatürk Üniversitesi Sağlık Bilimleri Enstitüsü, İş Sağlığı ve Güvenliği ABD Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği ABD
Doktora	: Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği ABD
Yabancı Dil Bilgisi	
İngilizce	: İyi
Tezden Üretilmiş Projeler ve Yayınlar	
<ol style="list-style-type: none">1. Çodur, S., Erkayman, B., Alp, S. S., Özenir, O., Pamucar, D., Yıldız, G., Gemalmaz, A., Dikel, A., Simic, V., Akın, H., Yılmaz, Y., Türk, Y., & Aktaş, S., (2024), Application of the full consistency method (FUCOM)-Cosine similarity framework in 5G infrastructure investment planning: An approach for telecommunication quality improvements, Heliyon, 10(9).2. Aktaş, S., Çodur, S., Erkayman, B., Yıldız, G., Gemalmaz, A., & Dikel, A. (2023, July), Evaluation of 5G Infrastructure Investment Options Using the AHP-TOPSIS Method, In 2023 31st Signal Processing and Communications Applications Conference (SIU) (pp. 1-4), IEEE.3. Erkayman, B. (Yürütücü), Çodur, S. (Araştırmacı), (2022) Bir Servis Sağlayıcısının 5G Alt Yatırım Planlaması İçin Simülasyona Dayalı Talep Tahmini, Atatürk Üniversitesi Bilimsel Araştırma Projeleri, Proje Kodu: FDK-2022-10716.	