



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**Makine Öğrenmesi Tabanlı Anten Seçimi ve Fiziksel
Katman Güvenliği**

Yüksek Lisans Tezi

Burak Erdurak

Ekim 2024



İSTANBUL MEDENİYET ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**Makine Öğrenmesi Tabanlı Anten Seçimi ve Fiziksel
Katman Güvenliği**

Yüksek Lisans Tezi

Burak Erdurak

Danışman

Dr. Öğr. Üyesi Filiz Gürkan Gölcük

Ekim 2024

TEZ JÜRİSİ ONAYI

Burak ERDURAK tarafından hazırlanan " Makine Öğrenmesi Tabanlı Anten Seçimi ve Fiziksel Katman Güvenliği " başlıklı bu Yüksek Lisans Tezi, Elektrik Elektronik Mühendisliği Anabilim Dalı'nda hazırlanmış ve jürimiz tarafından kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Dr. Öğr. Üyesi Filiz Gürkan Gölcük
İstanbul Medeniyet Üniversitesi

Üyeler:

Dr. Öğr. Üyesi Sinem Keleş
İstanbul Medeniyet Üniversitesi

Doç. Dr. Eylem Erdoğan
İzmir Yüksek Teknoloji Enstitüsü

Tez Savunma Tarihi: 07/ 10 / 2024

BEYANLAR

Yazım ve Kaynak Gösterme Kılavuzu Beyanı

Danışmanlığımda yazılan bu tezin APA yazım ve kaynak gösterme kılavuzunda belirtilen kurallara uygun olarak yapılandırıldığı ve bu kılavuzun metin içi kaynak gösterme standartlarının bu tezde tutarlı olarak uygulandığı tarafımdan incelenerek teyit edilmiştir.

İmza

Dr. Öğr. Üyesi Filiz Gürkan Gölcük

Etik İlkeler Sadakat Beyanı

Hazırladığım bu tezin tamamen kendi çalışmam olduğunu, akademik ve etik kuralları gözeterek çalıştığımı ve her alıntıya kaynak gösterdiğimi beyan ederim.

İmza

Burak Erdurak

ÖZET

Makine Öğrenmesi Tabanlı Anten Seçimi ve Fiziksel Katman Güvenliği

Erdurak, Burak

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Filiz GÜRKAN GÖLCÜK

Ekim 2024

Bu tez çalışmasında, kablosuz haberleşme sistemlerinde anten seçiminin optimize edilmesi amacıyla makine öğrenme tabanlı yöntemler geliştirilmiştir. Modern iletişim sistemlerinde, özellikle yoğun veri akışının ve yüksek güvenlik gereksinimlerinin bulunduğu ortamlarda, doğru anten seçimi büyük önem taşımaktadır. Birden fazla antenin kullanıldığı MIMO (Çok Giriş Çok Çıkış), MISO (Çok Giriş Tek Çıkış) ve SIMO (Tek Giriş Çok Çıkış) sistemlerinde anten seçimi, sistem performansını doğrudan etkileyen kritik bir faktördür. Bu tip sistemlerde verici veya alıcıda birden fazla anten olması, sinyalin farklı antenler üzerinden iletilmesini veya alınmasını sağlar. Böylece kanaldaki zayıflama, parazit ve yol etkilerinden korunarak daha güvenilir ve yüksek kaliteli bir iletişim sağlanır. Ayrıca, fiziksel katman güvenliği (PLS) ile ilgili güvenlik riskleri bu süreçte dikkate alınarak anten seçimi, sinyal güvenliği açısından da optimize edilir. Bu çalışmada, sinyal-gürültü oranı (SNR) ve gizlilik kapasitesi (C_s) gibi metrikler ışığında, antenlerin fiziksel katman güvenliğini destekleyecek şekilde seçilmesi incelenmiştir.

Anten seçimi sürecinde, kanal durumu bilgilerini (CSI) giriş olarak alan ve bu bilgilere dayanarak en uygun anteni seçen üç farklı makine öğrenme yöntemi kullanılmıştır: Yoğun Sinir Ağı (Dense NN), Konvolüsyonel Sinir Ağı (CNN) ve K En Yakın Komşu (K-NN). Modelin eğitimi ve testi için geniş kapsamlı bir veri seti oluşturulmuş, bu veri seti üzerinde çeşitli öğrenme algoritmaları kullanılarak modeller eğitilmiştir. Eğitim ve test aşamalarında çeşitli kanal koşulları ve anten konfigürasyonları dikkate alınarak modelin performansı değerlendirilmiştir. Bu değerlendirmelerde, fiziksel katman güvenliği sağlama kapasitesi de göz önünde bulundurulmuş ve iletişimin güvenilirliğinin artırılması hedeflenmiştir.

Çalışmanın sonuçları, geliştirilen makine öğrenme tabanlı anten seçimi yöntemlerinin geleneksel yöntemlere kıyasla belirgin bir performans sağladığını göstermektedir. Özellikle SNR ve C_s değerleri açısından yapılan değerlendirmeler, modellerin yalnızca iletişim kalitesini değil, aynı zamanda fiziksel katman güvenliğini de artırdığını ortaya koymuştur. Ayrıca, önerilen modellerin değişen kanal koşullarına uyum sağlama yeteneği, kablosuz haberleşme sistemlerinin dinamik yapısına uygun olarak geliştirilmiştir. Bu tez çalışması, derin öğrenme ve makine öğrenme tekniklerinin

kablosuz haberleşme alanında yenilikçi çözümler sunabileceğini, anten seçimi süreçlerinde ve fiziksel katman güvenliği sağlanmasında önemli iyileştirmeler sağlayabileceğini göstermektedir. Gelecekte, bu modelin daha farklı iletişim senaryolarında test edilmesi ve optimize edilmesi, daha geniş uygulama alanlarına yönelik önerilerde bulunulması planlanmaktadır.

Anahtar Kelimeler: Kablosuz Haberleşme, Anten Seçimi, Makine Öğrenmesi, Gizlilik Kapasitesi, Sinyal-gürültü Oranı, Fiziksel Katman Güvenliği



ABSTRACT

Machine Learning Based Antenna Selection and Physical Layer Security

Erdurak, Burak

Master Thesis, Electrical and Electronics Engineering Department, Electrical and
Electronics Engineering Program

Supervisor: Asst. Prof. Filiz GÜRKAN GÖLCÜK

October 2024

In this thesis, machine learning-based methods have been developed to optimize antenna selection in wireless communication systems. In modern communication systems, especially in environments with high data flow and stringent security requirements, proper antenna selection is of great importance. In systems using multiple antennas, such as MIMO (Multiple Input Multiple Output), MISO (Multiple Input Single Output), and SIMO (Single Input Multiple Output), antenna selection is a critical factor that directly affects system performance. Having multiple antennas at either the transmitter or receiver allows signals to be transmitted or received through different antennas. This helps protect against channel fading, interference, and path effects, thereby ensuring more reliable and higher-quality communication. Additionally, physical layer security (PLS) risks are considered during this process, as antenna selection is optimized for signal security as well. This study examines how to select antennas based on metrics such as Signal-to-Noise Ratio (SNR) and secrecy capacity (Cs) to enhance physical layer security.

In the antenna selection process, three different machine learning methods were employed that take channel state information (CSI) as input and select the optimal antenna based on this information: Dense Neural Network (Dense NN), Convolutional Neural Network (CNN), and K-Nearest Neighbors (K-NN). A comprehensive dataset was created for model training and testing, and various learning algorithms were employed to train the models on this dataset. During the training and testing phases, different channel conditions and antenna configurations were considered to evaluate model performance. These evaluations also took physical layer security into account, aiming to enhance the reliability of communication.

The results of the study demonstrate that the developed machine learning-based antenna selection methods provide significant performance improvements compared to traditional methods. Evaluations, particularly in terms of SNR and Cs values, reveal that the models enhance not only communication quality but also physical layer security. Furthermore, the proposed models' ability to adapt to changing channel conditions has been developed in line with the dynamic nature of wireless communication systems. This thesis shows that deep learning and machine learning techniques can provide innovative solutions in the field of wireless communications and offer significant improvements in both antenna

selection processes and physical layer security. In the future, it is planned to test and optimize this model in different communication scenarios and propose recommendations for broader application areas.

Keywords: Wireless Communication, Antenna Selection, Machine Learning, Secrecy Capacity, Signal-to-Noise Ratio, Physical Layer Security



TEŞEKKÜR

Bu tez çalışmasının ortaya çıkmasında, akademik rehberlik ve desteğini her aşamada hissettiğim danışmanım Dr. Öğr. Üyesi Filiz GÜRKAN GÖLCÜK'e teşekkürlerimi sunmak istiyorum. Tez sürecinde sağladığı yol gösterici yorumlar, değerli eleştiriler ve bilimsel katkılar, çalışmamın niteliğini yükseltmiş ve yönümü belirlemede etkili olmuştur. Dr. Gölcük'ün bilgi ve tecrübesi, bu tezin şekillenmesinde önemli bir rol oynamıştır.

Ayrıca, jürimde yer alan Doç. Dr. Eylem Erdoğan'a da bu çalışmaya sağladığı katkılar için teşekkür ederim. Çeşitli aşamalarda sunduğu yapıcı eleştiriler ve akademik bakış açısıyla, araştırmanın kapsamını ve derinliğini artırmama yardımcı olmuştur. Değerli görüşleri, çalışmanın her yönünü zenginleştirerek, bilimsel içeriğin güçlenmesine katkıda bulunmuştur.

Her iki hocama da, bu çalışmanın gelişiminde gösterdikleri ilgi ve destekleri için içtenlikle teşekkür ederim.

Ekim 2024,

Burak Erdurak

İÇİNDEKİLER

ÖZET

ABSTRACT

TEŞEKKÜR.....	I
SEMBOL LİSTESİ	IV
KISALTMALAR.....	V
ŞEKİL LİSTESİ	VI
TABLO LİSTESİ.....	VII
1. GİRİŞ.....	1
1.1 Literatür Özeti.....	1
1.2 Amaç ve Hipotez	3
1.3 Tezin İçeriği.....	4
2. GENEL KAVRAMLAR.....	5
2.1 Kablosuz Haberleşme Sistemleri ve Anten Seçimi	5
2.2 Anten Seçimi Yöntemleri	7
2.2.1 Maksimum SNR Değerine Göre Anten Seçimi	8
2.2.2 Kanal Kapasite (Cs) Değerine Göre Anten Seçimi	10
2.3 Makine Öğrenmesinin Temelleri.....	11
2.3.1 Aktivasyon Fonksiyonları.....	14
2.3.2 Kayıp Fonksiyonları.....	14
2.3.3 Optimizasyon Algoritmaları.....	15
2.3.4 Model Parametreleri ve Hiperparametreler	16
3. MAKİNE ÖĞRENMESİ TABANLI KABLOSUZ HABERLEŞME ve ANTEN SEÇİMİ	17
3.1 Veri Seti Üretilmesi.....	18
3.1.1 Kanal Verisinin Oluşturulması.....	18
3.2 Önerilen Makine Öğrenmesi Model Mimarileri.....	20
3.2.1 Yoğun Sinir Ağı (DNN) Modeli.....	21
3.2.2 Konvolüsyonel Sinir Ağı (CNN) Modeli	23
3.2.3 K En Yakın Komşu (K-NN) Modeli	25
3.2.4 Denetimli Öğrenme Modellerinin Test ve Eğitim İşlem Akışı	26
4. MAKİNE ÖĞRENMESİ TABANLI ANTEN SEÇİMİ PERFORMANS ANALİZİ ..	27
4.1 SNR Değerine Göre Anten Seçimi.....	27

4.1.1	SIMO Sitemlerde Değişken ve Sabit Kanal Güç Değerine (Ps) Göre Anten Seçimi	27
4.1.2	MISO Sitemlerde Değişken ve Sabit Kanal Güç Değerine(Ps) Göre Anten Seçimi	36
4.1.3	MIMO Sitemlerde Değişken ve Sabit Kanal Güç Değerine(Ps) Göre Anten Seçimi	41
4.2	Kapasite (Cs) Değerine Göre Anten Seçimi	47
4.2.1	SIMO Sistemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi	48
4.2.2	MISO Sitemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi	52
4.2.3	MIMO Sitemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi	56
5.	SONUÇLAR ve ÖNERİLER	60
	KAYNAKLAR.....	62
	ÖZGEÇMİŞ.....	67

SEMBOL LİSTESİ

h_m : eğitim için kanal verisini

h_n : test için kanal verisini

P_s : Verici Anten Gücü

P_R : Alıcı Anten Gücü

y_i : Modelin çıktısı

$\hat{y}_1$: Hedef değer

W : Ağırlık

b : Bias Değeri

α : Öğrenme oranı

v : Çıktı değeri

β : Momentum değeri

Z : Giriş katmanının aktivasyon değeri

a : Aktivasyon fonksiyonundan çıkan değer

C_s : Secrecy Capacity, gizlilik kapasitesi

n : Seçilen antenin etiket numarası

γ_m : Sinyal-Gürültü Oranı (SNR)

σ : Kanal varyans değeri

N_T : Seçilen anten sayısı

P_e : Dinleyicinin gücü

e : Euler sayısı (yaklaşık 2.718)

x : Giriş değeri

Θ : Model parametreleri

η : Öğrenme oranı

$J(\Theta)$: Kayıp fonksiyonu

δ : Öğrenme oranı

$\hat{y}$: Modelin tahmin ettiği değer

θ : Parametre seti

$x^{(i)}$: Girdiyi ifade eder

KISALTMALAR

SNR	Signal-to-Noise Ratio (Sinyal-Gürültü Oranı)
CSI	Channel State Information (Kanal Durumu Bilgisi)
CNN	Convolutional Neural Network (Konvolüsyonel Sinir Ağı)
DNN	Dense Neural Network (Yoğun Sinir Ağı)
K-NN	K-Nearest Neighbors (K En Yakın Komşu Algoritması)
Cs	Secrecy Capacity (Gizlilik Kapasitesi)
MIMO	Multiple Input Multiple Output (Çok Giriş Çok Çıkışlı Sistem)
MISO	Multiple Input Single Output (Çok Giriş Tek Çıkışlı Sistem)
SIMO	Single Input Multiple Output (Tek Giriş Çok Çıkışlı Sistem)
THz	Terahertz (Terahertz Frekans Bandı)
Ps	Power of Signal (Sinyal Gücü)
AUC	Area Under the Curve (ROC eğrisinde Eğri Altındaki Alan)
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
TPR	True Positive Rate (Doğru Pozitif Oranı)
FPR	False Positive Rate (Yanlış Pozitif Oranı)
MSE	Mean Squared Error (Ortalama Kare Hatası)
SGD	Stochastic Gradient Descent (Stokastik Gradyan Azalması)
RMSprop	Root Mean Square Propagation (Kök Ortalama Kare Yayılımı)
OFDM	Orthogonal Frequency Division Multiplexing (Dikgen Frekans Bölmeli Çoklama)
CDMA	Code-Division Multiple Access (Kod Bölmeli Çoklu Erişim)
ReLU	Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
Adam	Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)
5G	Fifth Generation (Beşinci Nesil Kablosuz Haberleşme Teknolojisi)
6G	Sixth Generation (Altıncı Nesil Kablosuz Haberleşme Teknolojisi)
IoT	Internet of Things (Nesnelerin İnterneti)
AI	Artificial Intelligence (Yapay Zeka)
CPU	Central Processing Unit (Merkezi İşlem Birimi)
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
MAC	Media Access Control (Ortam Erişim Kontrolü)
SISO	Single Input Single Output (Tek Giriş Tek Çıkışlı Sistem)
SINR	Signal to Interference plus Noise Ratio (Sinyal-Gürültü ve Girişim Oranı)

ŞEKİL LİSTESİ

- Şekil 2.1** Bir Kaynak, N Adet Hedeften Oluşan Kablosuz Haberleşme Modeli (SIMO)
- Şekil 2.2** Kaynak, Dinleyici ve Hedeflerden Oluşan Kablosuz Haberleşme Modeli
- Şekil 2.3** Bir Giriş, İki Gizli ve Bir Çıkış Katmanından Oluşan Derin Sinir Ağı Mimarisi
- Şekil 3.1** Derin Öğrenme Tabanlı Model Geliştirme Aşamaları
- Şekil 3.2** Derin Öğrenme Tabanlı Anten Seçimi Modelinde Kullanılacak Veri Seti Geliştirme Aşamaları
- Şekil 3.3** Derin Sinir Ağına Ait Nöron Yapısı
- Şekil 4.1** SIMO Sitemlerde Değişken Ps Değeri İçin Doğruluk Grafiği(DNN-CNN)
- Şekil 4.2** SIMO Sitemlerde Değişken Ps Değeri İçin K-NN yöntemi ile elde edilen Doğruluğun Farklı k Komşuluk Değerine Göre Değişim Grafiği
- Şekil 4.3** SIMO Sitemlerde Sabit Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Doğruluğunun Eğitim Boyunca Değişimi
- Şekil 4.4** SIMO Sitemlerde Sabit Ps Değeri İçin K-NN yöntemi ile elde edilen Doğruluğun Farklı k Komşuluk Değerine Göre Değişim Grafiği
- Şekil 4.5** SIMO Sitemlerde Değişken Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Kaybının Eğitim Boyunca Değişimi
- Şekil 4.6** SIMO Sitemlerde Sabit Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Kaybının Eğitim Boyunca Değişimi
- Şekil 4.7** MISO Sitemlerde (a) Değişken (b) Sabit Ps Değeri İçin Doğruluk Grafiği(DNN-CNN)
- Şekil 4.8** MISO Sitemlerde Değişken(a) ve Sabit(b) Ps Değeri İçin Doğruluk Grafiği(K-NN)
- Şekil 4.9** MISO Sitemlerde Değişken(a) ve Sabit(b) Ps Değeri İçin Kayıp Grafiği(K-NN)
- Şekil 4.10** MIMO Sitemlerde (a) Değişken ve (b) Sabit Ps Değeri İçin Doğruluk Grafiği(DNN-CNN)
- Şekil 4.11** MIMO Sitemlerde Değişken(a) ve Sabit (b) Ps Değeri İçin Doğruluk Grafiği(K-NN)
- Şekil 4.12** MIMO Sitemlerde (a) Değişken ve (b) Sabit Ps Değeri İçin Kayıp Grafiği (DNN-CNN)
- Şekil 4.13** SIMO Sitemlerde DNN Anten Seçim Performansı
- Şekil 4.14** SIMO Sitemlerde CNN Anten Seçim Performansı
- Şekil 4.15** SIMO Sitemlerde K-NN Anten Seçim Performansı

Şekil 4.16 SIMO Sitemlerde Farklı σ_e2 (sigma_e2) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

Şekil 4.17 MISO Sitemlerde DNN Anten Seçim Performansı

Şekil 4.18 MISO Sitemlerde CNN Anten Seçim Performansı

Şekil 4.19 MISO Sitemlerde K-NN Anten Seçim Performansı

Şekil 4.20 SIMO Sitemlerde Farklı σ_e2 (sigma_e2) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

Şekil 4.21 MIMO Sitemlerde DNN Anten Seçim Performansı

Şekil 4.22 MIMO Sitemlerde CNN Anten Seçim Performansı

Şekil 4.23 MIMO Sitemlerde K-NN Anten Seçim Performansı

Şekil 4.24 MIMO Sitemlerde Farklı σ_e2 (sigma_e2) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

TABLO LİSTESİ

Tablo 3.1 DNN Model Yapısı

Tablo 3.2 CNN Model Yapısı

Tablo 3.3 K-NN Model Yapısı

Tablo 4.1 SIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Tablo 4.2 SIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin F1 Skoru

Tablo 4.3 MISO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Tablo 4.4 MISO Sitemlerde Sabit ve Değişken Ps Değeri İçin F1 Skoru

Tablo 4.5 MIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Tablo 4.6 MIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin F1 Skoru

1. GİRİŞ

1.1 Literatür Özeti

Modern teknolojinin gelişiminde önemli rol alan kablosuz iletişim sistemleri, günümüzde akıllı telefonlar, akıllı ev cihazları, nesnelerin interneti (IoT) uygulamaları ve otonom araçlar gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Son yıllarda yaşanan teknolojik gelişmeler ve akıllı sistemlerin kullanımına yönelik taleplerin artması, bilim insanlarını kablosuz iletişim sistemlerinin geliştirilmesi üzerine yoğun araştırmalar yapmaya yönlendirmiştir. Kablosuz iletişimin yüksek verimle daha hızlı ve güvenilir şekilde sağlanabilmesi amacıyla yapılan çalışmalar, günümüzde olağanüstü bir hızla gelişerek pek çok yenilikçi çözümü literatüre kazandırmıştır. Literatürdeki yenilikçi uygulamalardan biri olan beşinci nesil (5G) kablosuz iletişim teknolojisi, yüksek bant genişliği ve gigabit (Gbit) seviyesinde veri hızı ile kullanıcıların daha hızlı ve verimli internet deneyimleri yaşamasına imkan sağlamaktadır (Kumar, Gupta ve Singh, 2023). Ancak daha fazla verinin daha yüksek hızla iletilmesine yönelik duyulan ihtiyaç bu alanda yapılan çalışmaların sürekliliğini zorunlu kılmaktadır. 5G teknolojisinin üzerine inşa edilen ve kablosuz iletişimde daha ileri bir evrim aşamasını temsil eden altıncı nesil (6G) kablosuz iletişim teknolojisinin, terahertz (THz) frekans bandında çalışarak, 5G'ye kıyasla çok daha fazla verinin yüksek hızlarda ve düşük gecikme sürelerinde iletilmesini mümkün kılacağı öngörülmektedir (Rappaport, Xing ve Kanhere, 2021). Bilim insanları tarafından yapılan araştırmaların temel hedefi, mevcut frekans bantlarının en iyi şekilde kullanılmasına imkan sağlamak ve iletişimdeki kayıpları azaltarak iletişim güvenliği ve kararlılığını optimize etmektir. Bu hedeflere ulaşmak için kullanılan yöntemlerden bazıları yüksek modülasyon teknikleri, sinyal işleme ve ileri kodlama teknikleri şeklinde sıralanabilir. 1960'lı yıllarda Robert W. Chang tarafından literatüre kazandırılan ve yüksek modülasyon tekniklerinden biri kabul edilen Dikgen Frekans Bölmeli Çoğullama (Orthogonal Frequency Division Multiplexing, OFDM) tekniği ile geniş bant veri iletimi dar bantlı alt kanallara bölünür. Çoklu alt taşıyıcılar kullanarak veri iletimini gerçekleştiren bu teknik, kanallar arası girişimi minimize ederek yüksek veri hızları ve güvenilir iletişim sağlar (Chang, 2003; Kaya, 2010; Khosla, Singh ve Aggarwal, 2018). 1990'lı yıllarda ticari kullanıma sunulan Kod Bölmeli Çoklu Erişim (Code-Division Multiple Access, CDMA) tekniği ile her kullanıcının sinyaline benzersiz bir pseudo-random kod atanarak, kullanıcıların aynı frekans bandını paylaşmaları sağlanmıştır. Frekans spektrumunda sinyali geniş bir alana yayan bu teknik, spektral verimliliği artırarak sinyalin girişime ve çok yollu sönmülmeye karşı daha dirençli olmasını sağlar. Ancak, CDMA sistemlerinin karmaşıklığı, verici ve alıcı için daha yüksek işlem gücü gereksinimlerine ve artan enerji tüketimine yol açabilir (Gilhousen, Jacobs ve Padovani, 1987). Yüksek modülasyon tekniklerine benzer şekilde kullanıma sunulan ileri kodlama tekniklerinin temel amacı kablosuz veri iletiminde meydana gelen hataları iyileştirerek sinyal kalitesinin artırılması ve iletişimin daha güvenilir hale getirilmesidir. Bu teknikler,

veri bitlerini kodlayarak iletim sırasında oluşabilecek hataları düzeltir (Proakis ve Salehi, 2009; Molisch, 2007). İleri kodlama tekniklerini oluşturan karmaşık algoritmalar hem verici hem de alıcı tarafında yüksek hesaplama gücü ve işlem süresi gerektirmektedir. Karmaşık kodlama ve kod çözme işlemleri, özellikle mobil cihazlarda enerji tüketimine bağlı olarak pil ömrünü azaltabilir.

Kablosuz iletişim sistemlerinde veri iletim hızını ve verimliliği artıran bir diğer yöntem çoklu anten teknolojisidir (Ganesan ve Yanikomeroglu, 2014; Ngo, Larsson ve Marzetta, 2016). Tek antenli yapıların kullanıldığı geleneksel iletişim yöntemlerine kıyasla verici ve alıcıdaki çoklu anten elemanlarıyla karakterize edilen Çoklu Giriş Çoklu Çıkış (Multi Input Multi Output, MIMO) teknolojisi, çok yollu kanalın uzamsal özelliklerinden yararlanarak iletim kapasitesinin artırılmasını ve sinyalin yüksek hızda iletilmesini amaçlamaktadır. MIMO teknolojisi, tek bir frekans bandında aynı anda birden fazla veri ileterek spektrum verimliliğini artırır ve yüksek hızda veri iletimine imkân sağlar (Paulraj ve Gore, 2003; Alamouti, 2005; Sanayei ve Nosratinia, 2004; Goldsmith ve Wicker, 2022; Khademi ve Ghavami, 2022). MIMO sistemlerinde yer alan çoklu antenler arasındaki koordinasyon ve karmaşık algoritmalar ile uygun anten seçimi konusu literatürdeki pek çok çalışmaya ilham kaynağı olmuştur. Sanayei ve Nosratinia'nın ele aldığı çalışma, MIMO sistemlerinde anten seçimine genel bir bakış sunmaktadır. Çalışma, verici ve alıcı taraftaki çok yollu anten seçim algoritmalarını kullanarak Sinyal Gürültü Oranını (Signal to Noise Ratio, SNR) iyileştirmeyi amaçlamıştır (Molisch ve Win, 2003; Nosratinia ve Sanayei, 2003; Tse ve Viswanath, 2003; Molisch ve Winters, 2007). Andreas F. Molisch ve Moe Z. Win, çalışmalarında N adet anten sinyalinden "en iyi" L adetini seçildiği (bir veya her iki bağlantı ucunda) ve işlendiği hibrit seçim şemalarını kullanarak veri iletim hızını iyileştirmeyi hedeflemiştir (Heath ve Love, 2010; Choi ve Cho, 2007). Literatürde yer alan geleneksel anten seçim teknikleri, genellikle sezgisel yaklaşımlara dayalı algoritmalar ile gerçekleştirilir (Aghdam ve Khalaj, 2005; Yu ve Wang, 2013; Firat ve Dogan, 2022; Gupta ve Singh, 2020; Shokri ve Nikookar, 2022). Geleneksel hesaplamalara dayalı anten seçim algoritmaları, günümüzde kullanılan ileri teknolojinin gerektirdiği karmaşık ve devasa boyuttaki sistem problemlerinde yetersiz kalabilmektedir. Son yıllarda önlenemez bir hızla gelişen derin öğrenme algoritmaları, ileri mühendislik hesaplamaları gerektiren veri kümelerinden belirli öz nitelikler çıkararak ve bu niteliklere dayalı öngörülerde bulunarak karmaşık problemlere hızlı ve düşük maliyetli çözümler sunmaktadır (Qamar ve Shafiq, 2020; Chen ve Ren, 2022; Simeone ve Sahai, 2021). Bilim insanları, birçok bilim dalında kullanımı yaygınlaşan derin öğrenme algoritmalarını kullanarak anten seçimi alanında yenilikçi ve optimize yaklaşımları literatüre kazandırmaktadır (Ali ve Habib, 2023; Shaik, 2023; Wu ve Zhang, 2022; Hussain ve Lee, 2022). Literatürdeki geleneksel anten seçim yöntemlerine kıyasla, kablosuz iletişim sistemlerinin daha hassas, daha güvenilir ve daha hızlı bir şekilde çalışmasına olanak sağlayan derin öğrenme tabanlı anten seçim algoritmaları kullanılarak yapılan çalışmaların, kablosuz iletişim sistemlerinin gelişimine büyük oranda katkı sağlayacağı değerlendirilmektedir (Jiang ve Cheng, 2021; Li ve Wang, 2022; Yang ve Wu, 2023; Zhang ve Shao, 2023; Mohamed ve El-Din, 2023; Huang ve Li, 2023).

1.2 Amaç ve Hipotez

Modern teknolojinin gelişiminde önemli rol oynayan kablosuz iletişim sistemleri, günümüzde akıllı telefonlar, akıllı ev cihazları, nesnelerin interneti (IoT) uygulamaları ve otonom araçlar gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Kablosuz haberleşme sistemlerinde, iletişim verimliliğini artırmak ve sistem performansını optimize etmek için doğru anten seçimi kritik öneme sahiptir. Özellikle çok girişli-çok çıkışlı (MIMO) sistemlerde, antenin doğru şekilde seçilmesi, sistemin sinyal-gürültü oranını (SNR) yükselterek iletişim kalitesini ve güvenliğini artırır. Yanlış veya etkisiz bir anten seçimi ise iletişim sırasında ciddi performans kayıplarına yol açabilir. Bu nedenle, kablosuz haberleşme sistemlerinde anten seçimi, yalnızca sistem performansı açısından değil, aynı zamanda fiziksel katman güvenliği için de önceliklidir. Antenlerin, kanal durumu bilgilerine (CSI) dayalı olarak doğru bir şekilde seçilmesi, hem iletişim kalitesini hem de fiziksel katman güvenliğini iyileştirir. Anten seçimi sürecinde doğru kararlar alınması, üçüncü tarafların veriyi ele geçirmesini engelleyerek gizlilik kapasitesini (Cs) artırır ve güvenli iletişim sağlar. Dolayısıyla, anten seçimi kablosuz iletişim sistemlerinde yalnızca performans değil, fiziksel katman güvenliği açısından da kritik bir süreçtir.

Bu tez çalışmasında, kablosuz haberleşme sistemlerinde anten seçiminin optimize edilmesi ve bu süreçte iletişim performansının artırılması için derin öğrenme tabanlı yeni bir yöntem önerilmektedir. Anten seçimi, kablosuz iletişim sistemlerinin en kritik aşamalarından biri olup, doğru antenlerin seçilmesi, sistemin genel performansında ve fiziksel katman güvenliğinde belirleyici rol oynar. İletim sırasında kullanılan antenler, hem sinyal gücünü hem de alınan verinin kalitesini doğrudan etkiler. Özellikle çoklu anten sistemlerinde (MIMO, SIMO, MISO), her bir antenin kanal durumuna uygun olarak seçilmesi, sinyal-gürültü oranını (SNR) artırarak veri iletimini daha verimli ve güvenli hale getirir. Bu güvenlik iyileştirmesi, anten seçiminin yalnızca performans değil, aynı zamanda gizlilik kapasitesi açısından da optimize edilmesiyle sağlanır.

Yanlış anten seçimi, veri iletiminde büyük kayıplara, düşük hızlara ve iletişim güvenliğinde zafiyetlere yol açabilir. Antenlerin uygun seçimi sayesinde, daha yüksek kapasite, daha düşük hata oranları ve daha geniş kapsama alanı elde edilebilir. Aynı zamanda, fiziksel katman güvenliğini sağlamada kritik bir araç olarak kullanılan anten seçimi, gizlilik kapasitesini (Cs) artırarak, üçüncü şahısların iletişime müdahale etme olasılığını azaltır. Bu nedenle, anten seçimi yalnızca verimliliği artırmakla kalmaz, aynı zamanda güvenlik ve gizlilik açısından da iletişim sistemlerinin sürdürülebilirliğini sağlar. Fiziksel katman güvenliği, bu kapsamda sistemin dış tehditlere karşı korunmasında önemli bir bileşen olarak öne çıkar.

Bu çalışmanın temel amacı, makine öğrenme algoritmalarını (Dense NN, CNN, K-NN) kullanarak anten seçimi sürecini optimize etmek ve bu sayede hem iletişim kalitesini en üst düzeye çıkarmak hem de fiziksel katman güvenliği açıklarını minimize etmektir. Bu bağlamda, geliştirilen modelin doğru antenleri seçmesi, sistemin verimliliğini artırırken, aynı zamanda dinamik ve karmaşık kablosuz iletişim ortamlarında daha güvenli bir iletişim sağlamayı hedeflemektedir. Çalışmada yanıtlanması gereken temel araştırma soruları şu şekildedir:

- Makine öğrenme algoritmaları, kablosuz haberleşme sistemlerinde anten seçimi

sürecini nasıl optimize edebilir?

- Makine öğrenme tabanlı anten seçimi, geleneksel anten seçimi yöntemlerine göre performans ve fiziksel katman güvenliği açısından ne kadar iyidir?
- Anten seçimi sürecinde kanal durumu bilgileri (CSI) kullanılarak sinyal-gürültü oranı (SNR) ve gizlilik kapasitesi (Cs) nasıl iyileştirilebilir?

Temel araştırma sorularına yönelik oluşturulan hipotezler aşağıda listelenmiştir:

- Makine öğrenme algoritmaları, kablosuz haberleşme sistemlerinde anten seçimi sürecini optimize ederek iletişim kalitesini ve fiziksel katman güvenliğini artırabilir.
- Derin öğrenme tabanlı anten seçimi, geleneksel yöntemlere kıyasla daha yüksek doğruluk, verimlilik ve güvenlik sağlar.
- Kanal durumu bilgileri (CSI) kullanılarak yapılan anten seçimi, sinyal-gürültü oranı (SNR) ve gizlilik kapasitesini (Cs) iyileştirir ve iletişimin fiziksel katman güvenliğini artırır.

Bu çalışmada, kablosuz haberleşme sistemlerinde anten seçimini optimize etmek için denetimli öğrenme (supervised learning) yaklaşımı kullanılacaktır. Yoğun Sinir Ağı (Dense NN), Konvolüsyonel Sinir Ağı (CNN), ve K En Yakın Komşu (K-NN) yöntemleri ile kanal durumu bilgilerine dayalı olarak en uygun antenlerin seçilmesi hedeflenmektedir. Modelin eğitimi ve testi için kanal durumu bilgileri, sinyal-gürültü oranı (SNR), kapasite (Cs), ve anten seçimi etiketlerinden oluşan veri setleri kullanılacaktır. Bu yaklaşım, fiziksel katman güvenliğini sağlamak amacıyla modelin en yüksek verimlilik ve gizlilik kapasitesini sunacak şekilde optimize edilmesine olanak tanır.

1.3 Tezin İçeriği

Bu tez çalışmasında, kablosuz iletişim sistemlerinde anten seçiminin optimize edilmesi amacıyla makine öğrenmesi tabanlı modeller geliştirilmiştir. Kablosuz haberleşme, elektromanyetik dalgalar aracılığıyla bilgi iletimi anlamına gelir ve bu iletim sürecinde sinyalin bozulmasına neden olan çeşitli kanal etkileri ile karşılaşılır. Çalışmada, geleneksel anten seçim yöntemlerine kıyasla hassas, güvenilir ve hızlı çözümler sunan makine öğrenme algoritmaları kullanılarak, kanal durumu bilgilerine dayalı olarak en uygun antenlerin seçilmesi hedeflenmiştir. Ayrıca, makine öğrenmesi tabanlı anten seçimi ile sinyal-gürültü oranı (SNR) ve gizlilik kapasitesi (Cs) gibi metrikler üzerinden iletişim performansının ve fiziksel katman güvenliğinin artırılması amaçlanmıştır. Fiziksel katman güvenliği, sinyalin güvenli bir şekilde iletilmesini sağlamak için kanal koşullarına göre antenlerin uygun şekilde seçilmesini içerir ve bu da iletişim sürecinde kritik bir rol oynar.

Geliştirilen modelin performansı, klasik yöntemlerle karşılaştırılmış ve doğruluk, hassasiyet, sınıflandırma raporu gibi istatistiksel ölçütlerle değerlendirilmiştir. Bu süreçte, fiziksel katman güvenliği sağlama kapasitesi de dikkate alınmış ve güvenliğin yanı sıra verimlilik de artırılmaya çalışılmıştır. Sonuçlar, makine öğrenmesi algoritmalarının kablosuz haberleşme sistemlerinde anten seçimi süreçlerini optimize ederek iletişim kalitesini, fiziksel katman güvenliğini ve genel güvenlik seviyesini

artırabileceğini göstermiştir. Gelecekteki çalışmalar, bu modellerin daha da optimize edilmesi ve farklı iletişim senaryolarında test edilmesiyle geniş uygulama alanlarına yönelik önerilerde bulunabilir.

2. GENEL KAVRAMLAR

2.1 Kablosuz Haberleşme Sistemleri ve Anten Seçimi

Kablosuz haberleşme sistemlerinin temel işlevi, elektromanyetik dalgalar kullanarak bilgiyi bir noktadan diğerine iletmekten ibarettir. Bu iletim sürecinde sinyal, bir verici anten tarafından elektromanyetik dalgalara dönüştürülür ve yayılarak alıcı anten tarafından tekrar bilgiye dönüştürülür. İletişim sistemlerinin verimliliği ve kalitesi, bu antenlerin doğru seçimine bağlıdır. Anten seçimi, özellikle çok antenli sistemlerde (MIMO, SIMO, MISO) performansın iyileştirilmesi ve güvenliğin sağlanması açısından kritik bir rol oynar (Goldsmith, 2005; Molisch, 2005).

Kablosuz haberleşme sürecinde sinyalin kalitesi, çeşitli faktörlerden etkilenir. Bu faktörler arasında frekans, bant genişliği, sinyal-gürültü oranı (SNR) ve kanal kapasitesi gibi teknik unsurlar yer alır. Frekans, bir sinyalin taşıdığı veri miktarını etkilerken, bant genişliği sinyalin hızını ve kapasitesini belirler (Tse & Viswanath, 2005). Yüksek sinyal-gürültü oranı, daha kaliteli bir iletişim anlamına gelirken, kanal kapasitesi (Cs), iletebilecek maksimum veri miktarını gösterir (Heath & Lozano, 2018). Bu parametreler, anten seçimi yapılırken göz önünde bulundurulması gereken önemli ölçütlerdir.

Sinyal iletimi ve alımı, kablosuz haberleşmenin en temel süreçlerinden biridir. İletilen sinyal, atmosferdeki engeller, parazitler ve çoklu yol etkileri gibi çevresel faktörlerden etkilenebilir (Rappaport, 1996). Bu nedenle, doğru anten seçimi bu etkileri minimize etmek ve sinyalin daha verimli bir şekilde alıcıya ulaşmasını sağlamak açısından hayati öneme sahiptir (Lee & Miller, 1997). Antenlerin doğru seçilmesi, sinyalin daha güçlü, güvenli ve hızlı bir şekilde iletilmesini sağlar (Zheng & Tse, 2003).

Kablosuz iletişimde kullanılan kanal modelleri de sinyalin davranışlarını anlamamıza yardımcı olur. Serbest uzay modeli gibi basit modeller, engellerin olmadığı ortamlardaki sinyal yayılımını açıklarken, Rayleigh ve Rician gibi yayılım modelleri, çoklu yol etkilerini ve daha karmaşık çevresel faktörleri hesaba katar (Proakis & Salehi, 2007; Yacoub, 2002). Bu modeller, iletişim kanalı boyunca sinyalin nasıl bozulduğunu ve hangi antenin en uygun olduğunu belirlemek için kullanılır (Wang & Giannakis, 2003). Özellikle Rayleigh ve Nakagami-m modelleri, kablosuz haberleşme ortamlarının dinamik yapısını anlamak için önemli araçlardır (Simon & Alouini, 2005). Bu kanal modelleri, anten seçimini daha doğru ve etkili hale getirerek sistem performansını artırır (Goldsmith, 2005).

Sonuç olarak, kablosuz haberleşme sistemlerinde anten seçimi, sinyal kalitesini, kapasitesini ve güvenliğini optimize etmek için en kritik adımlardan biridir. Doğru anten

seçimi, sinyalin iletim verimliliğini artırarak, iletişimdeki gecikmeleri azaltır ve sistemin genel performansını önemli ölçüde iyileştirir (Liang & Poor, 2008; Bloch et al., 2008). Bu nedenle, anten seçimi süreci, kablosuz haberleşme sistemlerinin başarılı bir şekilde çalışmasında vazgeçilmez bir unsur olarak karşımıza çıkar (Goel & Negi, 2008).

Kablosuz haberleşme sistemlerinde, sinyalin iletilmesi sırasında karşılaşılan çevresel faktörler ve engeller nedeniyle sinyal kalitesinde bozulmalar meydana gelebilir. Bu bozulmaları analiz etmek ve modellemek için çeşitli kanal modelleri geliştirilmiştir. Bu modeller, sinyalin iletim ortamındaki davranışlarını anlamamıza yardımcı olur:

- **Serbest Uzay Modeli:** Engellerin olmadığı açık alanlarda sinyal yayılımını modelleyen basit bir modeldir. Bu model, doğrudan hat üstünde bulunan verici ve alıcı arasındaki sinyal iletimini temsil eder.
- **Rayleigh Yayılım Modeli:** Sinyalin birden fazla yol üzerinden alıcıya ulaştığı durumları modellemek için kullanılır. Özellikle çoklu yol etkilerinin yoğun olduğu ortamlarda etkilidir (Simon & Alouini, 2005).
- **Rician Yayılım Modeli:** Hem doğrudan bir yolun hem de çoklu yolların bulunduğu ortamları modellemek için kullanılır. Rayleigh modeline göre daha karmaşık yayılım koşullarını kapsar (Proakis & Salehi, 2007).
- **Nakagami-m Yayılım Modeli:** Daha genel bir kanal modeli olup hem Rayleigh hem de Rician modellerini kapsar. Sinyal bozulmalarını daha geniş bir perspektifte modellemeye olanak tanır (Yacoub, 2002).

Bu kanal modelleri, kablosuz haberleşme sistemlerinde sinyal yayılımını ve alımını analiz ederek, performansı optimize etmeye yardımcı olur. Kanal koşullarına göre en uygun antenlerin seçilmesi, iletişim kalitesini ve verimliliğini doğrudan artırır (Rappaport, 1996).

Kablosuz sistemlerde anten seçiminin etkisinin görüldüğü bir önemli konu, giderek daha önemli bir konu haline gelen güvenli iletişimdir. Özellikle fiziksel katman güvenliği, iletişim sırasında üçüncü tarafların izinsiz erişim girişimlerine karşı bir savunma mekanizması olarak dikkat çeker. Antenlerin doğru seçimi, hem sinyalin daha verimli iletilmesini sağlar hem de dinleyicilerin (eavesdropper) sinyali yakalamasını zorlaştırarak iletişim güvenliğini artırır (Liang & Poor, 2008).

Fiziksel Katman Güvenliği (Physical Layer Security), kablosuz iletişimde güvenliği sağlamak için fiziksel katmanın özelliklerinin kullanılması anlamına gelir. Bu yaklaşım, sinyalin zayıflatılması, gürültü, yansıma ve çok yollu yayılım gibi fiziksel etkilerden yararlanarak saldırganların (eavesdropper) iletişimi dinlemesini zorlaştırır. Fiziksel katman güvenliği, klasik kriptografik yöntemlerden farklı olarak, haberleşme sisteminin fiziksel özelliklerini kullanarak güvenliği sağlar. Anten seçiminde kullanılan gizlilik kapasitesi (secrecy capacity) gibi metrikler, saldırganın sinyali algılamasını engellemeyi amaçlar. Bu kapasite, alıcıya gelen sinyalin güç seviyesi ile dinleyiciye ulaşan sinyalin güç seviyesi arasındaki farkı optimize ederek hesaplanır (Bloch et al., 2008).

Anten seçimi, yalnızca iletişim performansını artırmakla kalmaz, aynı zamanda kablosuz iletişim güvenliğini sağlamada da önemli bir rol oynar. Anten seçimi ve güvenlik süreçlerinde kullanılan algoritmalar, kanal durumu bilgilerine (Channel State Information - CSI) dayanarak sinyallerin en verimli şekilde iletilmesi ve güvenlik açıklarının minimize edilmesi amacıyla antenleri seçer. Doğru antenler seçilerek sinyal gücü ve sinyal-gürültü oranı (SNR) artırılabilir, bu da dinleyicilerin iletişimi ele geçirme olasılığını azaltır (Goel & Negi, 2008).

Sonuç olarak, fiziksel katman güvenliği ve anten seçimi, kablosuz haberleşme sistemlerinde güvenlik seviyesini artırmak ve iletişim kalitesini iyileştirmek için kritik öneme sahiptir. Antenlerin doğru seçimi, yalnızca iletişim performansını değil, aynı zamanda güvenliği artırmada da kilit bir rol oynamaktadır. Gelecekte bu alanda yapılacak geliştirmeler, daha güvenli ve verimli kablosuz haberleşme sistemlerinin tasarımına katkı sağlayacaktır.

2.2 Anten Seçimi Yöntemleri

Kablosuz haberleşme sistemlerinde anten seçimi, performansı optimize etmek ve sinyal kalitesini artırmak için kullanılan en kritik yöntemlerden biridir. Anten seçimi, kanal durumu bilgisine (Channel State Information - CSI) dayalı olarak yapılır ve hem alıcı hem de verici antenlerin seçim süreci, iletişim kalitesini doğrudan etkiler. Bu yöntemlerin doğru uygulanması, sinyal-gürültü oranının (SNR) yükselmesine, kanal kapasitesinin (Cs) artmasına ve enerji verimliliğinin iyileşmesine olanak tanır (Goldsmith, 2005; Tse & Viswanath, 2005; Heath & Lozano, 2018).

Literatürde anten seçimi genellikle Alıcı Anten Seçimi ve Verici Anten Seçimi olmak üzere iki ana kategoriye ayrılır. Alıcı anten seçimi, alınacak sinyalin kalitesini maksimize etmeyi amaçlarken, verici anten seçiminde, sinyalin en verimli şekilde iletilmesi hedeflenmektedir. Bu iki süreç, kablosuz iletişim sistemlerinin genel performansını belirlemede hayati bir rol oynar (Molisch, 2005; Zheng & Tse, 2003).

Alıcı anten seçimi, alıcı cihazın kullanacağı anten veya antenlerin seçilmesi sürecidir. Bu seçim, alıcı tarafından gelen sinyallerin kalitesini maksimize etmek için yapılır. Alıcı anten seçimi yöntemleri, sinyalin çok yollu yayılım etkilerine karşı korunması için çeşitli çeşitlendirme (diversity) tekniklerine dayanır. Aşağıda alıcı anten seçimi için yaygın kullanılan yöntemler sıralanmıştır:

Seçmeli Çeşitlendirme (Selection Diversity): Bu yöntemde, en iyi sinyal-gürültü oranına (SNR) sahip anten seçilir. Bu yöntem, uygulama kolaylığı ve düşük maliyeti nedeniyle yaygın olarak tercih edilir [Proakis & Salehi, 2007; Pramitarini et al., 2023].

Eşzamanlı Çeşitlendirme (Maximal-Ratio Combining - MRC): Bu yöntemde, tüm antenlerden gelen sinyaller belirli ağırlıklarla birleştirilir ve toplam sinyal-gürültü oranı maksimize edilir. Bu yöntem, daha yüksek SNR elde edilmesine olanak tanır ve sinyalin kalitesini artırır (Simon & Alouini, 2005; Bouchibane et al., 2023).

Optimal Anten Seçimi: Kanal durumu bilgisine (CSI) dayalı olarak, en iyi performans gösteren antenler seçilir. Bu yöntem, sistemin toplam kapasitesini maksimize eder ve en yüksek iletişim verimliliğini sağlar (Wang & Giannakis, 2003; Yao et al., 2019).

Gizlilik Kapasitesi (Secrecy Capacity): Gizlilik kapasitesini maksimize etmek amacıyla kanal durumu bilgisi kullanılarak optimal antenler seçilir. Bu yöntem, üçüncü tarafların iletişimi dinlemesini zorlaştırarak güvenli iletişim sağlar (Liang & Poor, 2008; Goel & Negi, 2008).

Yapay Zeka ve Makine Öğrenimi: Son yıllarda, yapay zeka ve makine öğrenimi yöntemleri alıcı anten seçiminde kullanılmıştır. Bu yöntemler, büyük veri setlerinden öğrenerek en uygun antenleri dinamik olarak seçebilir (R. Yao et al., 2019; Bouchibane et al., 2023).

Sinyalin daha verimli ve etkili bir şekilde hedefe ulaşmasını sağlamak amacıyla gerçekleştirilen verici anten seçiminde ise kullanılan temel yaklaşımlar şu şekildedir:

Kanala Dayalı Seçim: Kanal durumu bilgisine (CSI) dayanarak, en iyi performansı sağlayacak antenler seçilir. Bu yöntem, verici tarafında CSI gerektirir ve yüksek performans sağlar (Goldsmith, 2005; Tse & Viswanath, 2005).

Rastgele Anten Seçimi: Bu yöntemde, antenler rastgele seçilir. Rastgele seçim, basitliği nedeniyle tercih edilse de performans açısından optimal değildir (Proakis & Salehi, 2007).

Seçmeli Verici Çeşitlendirme (Selective Transmit Diversity): Bu yöntemde, çeşitlendirme kazancı elde etmek amacıyla en iyi antenler seçilir ve sinyal bu antenler üzerinden iletilir. Bu yöntem, sinyalin kapasitesini artırır ve hata oranını düşürür (Lee & Miller, 1997).


Yapay Zeka ve Makine Öğrenimi: Makine öğrenimi ve yapay zeka algoritmaları, verici anten seçiminde de kullanılabilir. Bu yöntemler, kanal karakteristiklerini öğrenerek en iyi anten seçim kararlarını verebilir ve performansı artırır (Pramitarini et al., 2023; Bouchibane et al., 2023).

Kablosuz haberleşme sistemlerinde performans analizi ve optimizasyonu, çeşitli matematiksel modeller ve yöntemler kullanılarak gerçekleştirilir. Bu modeller, anten seçimi ve sinyal kalitesi gibi kritik unsurların belirlenmesi için kullanılır. Sinyal-gürültü oranı (SNR) ve kanal kapasitesi gibi metrikler, kablosuz haberleşme sistemlerinin verimliliğini artırmak için önemli göstergeler olarak kabul edilir. Matematiksel analizler, antenlerin bu metriklere göre optimize edilmesine olanak tanır ve sistemin genel performansını artırır (Heath & Lozano, 2018; Bouchibane et al., 2023).

2.2.1 Maksimum SNR Değerine Göre Anten Seçimi

Kablosuz haberleşme sistemlerinde çoklu anten yapıları, yani MIMO (Multiple Input Multiple Output - Çok Giriş Çok Çıkış), MISO (Multiple Input Single Output - Çok Giriş Tek Çıkış) ve SIMO (Single Input Multiple Output - Tek Giriş Çok Çıkış) gibi farklı konfigürasyonlar, haberleşme performansını artırmada önemli bir rol oynamaktadır. MIMO sistemleri, hem vericide hem de alıcıda birden fazla antenin bulunduğu, yüksek kapasite ve verimlilik sağlayan sistemlerdir. MISO sistemlerinde ise birden fazla verici anten bulunurken alıcı tarafta yalnızca bir anten yer alır. SIMO sistemleri ise bir adet verici antenin, çok sayıda alıcı anten ile haberleştiği yapılar olarak öne çıkar.

Bu çalışmada örnek olarak SIMO yapısı ele alınmış ve Şekil 2.1'de gösterilmiştir. Bir adet kaynak (Source-S) ve bir adet hedeften (Destination-D) oluşan kablosuz haberleşme modeli, hedefin kendi içerisinde N_s adet antenden meydana geldiği ve kaynağın ise yalnızca bir antenden oluştuğu durumu görselleştirmektedir. Haberleşme sırasında bu N_s antenlerden herhangi biri üzerinden iletişim sağlanmaktadır. MIMO ve MISO sistemleri de benzer şekilde çoklu anten kullanımı ile kapasite ve performans artışı sağlarken, burada SIMO sistemi üzerinden tek antenli bir vericinin, çoklu antenli bir alıcıya nasıl veri ilettiği incelenmiştir.



Şekil 2.1 Bir Kaynak, N Adet Hedeften Oluşan Kablosuz Haberleşme Modeli (SIMO)

Bu tez çalışmasında S ve D arasındaki tüm kanallar bağımsız ve aynı dağılıma sahip Rayleigh sönümlmeli kabul edilmektedir. Alıcı ve verici doğrudan bir bağlantı yolu ile bağlıdır. Bu sistemde kanal $\mathbf{h}$ kanal vektörü ile eşitlik 2.1'deki gibi tanımlanabilir.

$$\mathbf{h} = [h_1, h_1 \dots h_{N_s}] \quad (2.1)$$

Burada, N_s alıcıdaki anten sayısıdır ve dolayısıyla sistemde N_s kanal olduğu söylenebilmektedir. İletişim yalnızca tek anten üzerinden sağlanacağı için kanal vektörü aşağıdaki gibi tanımlanır.

$$\mathbf{h} = [h_1, h_1 \dots h_{N_s}] \times 1 \quad (2.2)$$

Kanal vektöründe bulunan herhangi bir h_m , $m = 1..N_s$ değeri complex yapıya sahiptir ve $a, b \sim N(0,1)$ olmak üzere $a + bj$ şeklinde tanımlanabilir. Kanal verisinin varyansının 1, ortalamasının 0 olması için kanal değerleri $\sqrt{2}$ ile bölünerek normalizasyon işlemi yapılır.

$$h_m = \left(\frac{1}{\sqrt{2}}\right) \times h_m \quad (2.3)$$

Anten seçimindeki amaç bu kanallar üzerinden yapılacak iletişimin verimliliğinin mümkün olan en yüksek seviyede olmasını sağlamaktır. Bunun için sinyal gürültü oranının en yüksek olduğu kanal üzerinden iletişim tercih edilir. Sinyal gürültü oranı (SNR) h_m kanalı için eşitlik 2.4'deki gibi formülize edilir.


$$\gamma_m = \frac{P_s \cdot |h_m|^2}{N_T \cdot \sigma_e} \quad (2.4)$$

Burada P_s kaynağın iletim gücünü, $|h_m|$ kanalın mutlak değerini, σ_e varyansı ve N_T ise seçilen anten sayısını ifade etmektedir. Oluşturulan bu sistemde kaynak, kanala ait h_m durum bilgisine sahiptir. Bu kısımda kaynak tüm olası anten seçimi kombinasyonlarına ait SNR değerlerini içeren $\boldsymbol{\gamma} = [\gamma_1, \gamma_2 \dots \gamma_{N_s}]$ vektörünü hesaplar ve en yüksek SNR değerine sahip olan anten seçilir ve bu anten üzerinden iletişim sağlanır. n seçilen antenin etiket numarası olmak üzere, SNR değerine göre anten seçimi eşitlik 2.5 ile gerçekleştirilir.

$$n = \underset{n=1..N_s}{\operatorname{argmax}}(\boldsymbol{\gamma}) \quad (2.5)$$

2.2.2 Kanal Kapasite (C_s) Değerine Göre Anten Seçimi

Şekil 2.2, bu tez çalışması kapsamında kanal kapasites değerine göre yapılacak anten çalışmasında referans alınan, bir adet kaynak (S), hedef (D) ve dinleyiciden (E) oluşan sistem gösterilmektedir. Burada kaynağın bir adet ve hedefin N_s adet antenden meydana geldiği varsayılmıştır. Haberleşme anında bu N_s antenlerden herhangi biri üzerinden iletişim sağlamaktadır. Amaç, kaynaktaki mesajı güvenli ve en az bozunuma uğramış bir şekilde hedefe ulaştırmaktır. Bir önceki bölüm ile benzer şekilde S ve D arasındaki tüm kanallar bağımsız ve aynı şekilde dağılıma sahip Rayleigh sönümlemesine tabidir. Kanal vektörü $\mathbf{h}$ eşitlik 2.2'deki gibi elde edilmektedir. SNR değerine göre anten seçiminin tartışıldığı bir önceki bölümden farklı olarak, bu sistemde bir adet dinleyici olduğundan, bu dinleyicinin varlığında her bir m kanalına ait Kapasite C_{s_m} hesaplaması eşitlik 2.6'da gösterildiği gibi yapılır.



Şekil 2.2 Kaynak, Dinleyici ve Hedeflerden Oluşan Kablosuz Haberleşme Modeli

$$C_s = \begin{cases} \frac{1}{2} \log_2 \left(1 + \frac{P_s}{\sigma_m^2} |h_m|^2 \right) - \frac{1}{2} \log_2 \left(1 + \frac{P_e}{\sigma_e^2} |h_e|^2 \right) & \text{eğer } \frac{P_s}{\sigma_m^2} |h_m|^2 > \frac{P_e}{\sigma_e^2} |h_e|^2 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (2.6)$$

Burada P_s kaynağın iletim gücünü, σ_m^2 kanalın varyansının karesini, h_m ise kaynak ile hedef arasındaki kanalı ifade etmektedir. P_e dinleyicinin gücünü, σ_e^2 S ve E arasındaki kanalın varyansının karesini, h_e ise S ile E arasındaki kanalı ifade etmektedir.

Oluşturulan bu sistemde kaynak kanala ait h_m ve h_e durum bilgisine sahiptir. Bu kısımda kaynak tüm olası anten seçimi durumlarına ait C_s değerini hesaplar ve $\mathbf{Cs}=[C_{s_1}, C_{s_2} \dots C_{s_{N_s}}]$ kanal kapasitelerini içeren vektör elde edilir. Sonuç olarak en yüksek kanal kapasite değerine sahip olan anten seçilerek, bu anten üzerinden iletişim sağlanır.

$$n = \arg \max_{n \in N_s} (C_s) \quad (2.7)$$

2.3 Makine Öğrenmesinin Temelleri

Makine öğrenmesi, verilerin analiz edilmesi ve tahmin yapılabilmesi için algoritmaların kullanıldığı bir yapay zeka (AI) disiplini. Bu yaklaşım, verilerdeki örüntüleri (pattern) öğrenerek, sistemlerin insan müdahalesi olmadan belirli işlemleri yapabilmesine olanak

tanır. Derin öğrenme, makine öğrenmesinin bir alt dalı olarak yapay sinir ağlarını kullanır ve çok katmanlı ağ yapıları sayesinde karmaşık veri desenlerini öğrenme yeteneğine sahiptir [Yao et al., 2019; Bouchibane et al., 2023]. Derin öğrenmenin kökleri, 1940'larda McCulloch ve Pitts'in yapay nöron modeline kadar uzanır [McCulloch & Pitts, 1943]. 1980'lerde, geri yayılım (backpropagation) algoritması ile sinir ağlarının eğitimi mümkün hale geldi [Rumelhart et al., 1986]. 2000'lerin ortalarına gelindiğinde, büyük veri kümeleri ve gelişmiş hesaplama gücü ile derin öğrenme yeniden canlandı [LeCun et al., 2015; Hinton et al., 2006]. Derin öğrenme, insan beyninin çalışma prensiplerinden esinlenilerek geliştirilmiş çok katmanlı sinir ağları kullanarak verilerin işlenmesi ve analiz edilmesini sağlar. Bu ağlar, veri üzerinde çok karmaşık dönüşümler gerçekleştirebilir ve çok katmanlı mimariler aracılığıyla öğrenme kapasitesini artırabilir [Krizhevsky et al., 2012; Goodfellow et al., 2016].

Derin öğrenme algoritmaları, farklı sinir ağı mimarilerini kapsayacak şekilde geliştirilmiştir. Bu mimarilerden biri Tam Bağlantılı Sinir Ağlarıdır (Fully Connected Networks); bu tür ağlarda, her nöron bir sonraki katmandaki tüm nöronlara bağlanır ve böylece tam bağlantılı bir yapı oluşturur [Goldsmith, 2005]. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN), özellikle görüntü ve video işleme gibi görevlerde yaygın olarak kullanılan bir başka mimaridir ve bu ağlar, verilerdeki yerel ilişkileri anlamlandırmak için filtreleme işlemi yaparak veriyi işler [LeCun et al., 1998; Krizhevsky et al., 2012]. Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN) ise sıralı veriler üzerinde çalışmak üzere tasarlanmış olup, doğal dil işleme ve zaman serisi analizi gibi alanlarda kullanılır. RNN'ler, önceki zaman adımlarındaki bilgiyi hatırlayarak ardışık verilerdeki bağımlılıkları yakalar [Goodfellow et al., 2016]. Son olarak, Generatif Adversarial Ağlar (Generative Adversarial Networks - GAN), veri üretimi ve veri artırma amacıyla kullanılan yenilikçi bir mimaridir; GAN'lar, iki sinir ağını (üreteç ve ayırtıcı) birbirine karşı eğiterek yeni ve gerçekçi veriler oluşturmayı mümkün kılar [Goodfellow et al., 2014].


Bu çalışmada, derin öğrenme algoritmalarına ek olarak K En Yakın Komşu (K-NN) yöntemi de kullanılmıştır. K-NN, komşuluk tabanlı bir algoritma olup, derin öğrenme gibi sinir ağı mimarilerine dayanmamakla birlikte, basitliği ve esnekliği ile veri sınıflandırmada güçlü bir araçtır [Cover & Hart, 1967]. K-NN algoritması, veri örneklerini öğrenme sürecinde eğitmez; bunun yerine, her yeni veriyi en yakın komşuları üzerinden sınıflandırır veya tahmin eder. Bu özelliği ile K-NN, veri kümesi boyutuna ve veri yapısına göre güçlü performans sergileyebilir [Altman, 1992; Bouchibane et al., 2023].

Derin öğrenmenin gelecekteki gelişimi, hesaplama gücü ve veri erişimindeki ilerlemelere bağlı olarak şekillenecektir. Aynı zamanda, etik ve güvenlik konuları da önemli rol oynayacaktır [Floridi et al., 2018]. Derin öğrenmenin daha genel ve insan benzeri yapay zeka sistemlerinin geliştirilmesinde kritik bir bileşen olması beklenmektedir [Bengio, 2009; Lake et al., 2017].

Sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiş yapay yapılardır. Temel birimleri nöronlardır ve her nöron girdi verilerini alır, belirli ağırlıklar ile çarpar ve aktivasyon fonksiyonları aracılığıyla çıktılar üretir. Derin sinir ağları, birden fazla gizli katmana sahip sinir ağlarıdır. Her katman, bir önceki katmanın çıktısını girdi olarak alır

ve daha yüksek seviyeli özellikleri öğrenir. Derin sinir ağlarının derinliği, bu gizli katmanların sayısına bağlı olup, her ek katman, modelin daha karmaşık yapıları öğrenmesine olanak tanır.

Derin sinir ağları, girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere üç temel katmandan oluşur (Şekil 2.3). Girdi katmanı, modele beslenen ham verilerin alındığı katmandır ve bu verileri, modelin işleyebileceği biçime dönüştürerek gizli katmanlara iletir. Gizli katmanlar ise modelin öğrenme sürecinde kritik rol oynayan, verilerdeki desenleri ve ilişkileri öğrenen katmanlardır. Her bir gizli katmandaki nöronlar, bir önceki katmandan gelen çıktıları belirli ağırlıklar ve aktivasyon fonksiyonları aracılığıyla işler ve bu işlem sonucunda verinin daha soyut özellikleri ortaya çıkarılır. Derin sinir ağlarının derinliği, bu gizli katmanların sayısına bağlı olup, her ek katman, modelin daha karmaşık yapıları öğrenmesine olanak tanır. Son olarak, çıktı katmanı, işlenmiş verilerin nihai sonucunu üreten katmandır ve modelin çözmekte olduğu problem doğrultusunda tahminler veya sınıflandırmalar yapar. Böylece, girdi katmanından alınan ham veri, gizli katmanlar aracılığıyla işlenerek çıktı katmanında anlamlı sonuçlara dönüştürülür ve modelin performansı bu katmanlar arasındaki etkileşimlerle doğrudan şekillenir.



Şekil 2.3 Bir Giriş, İki Gizli ve Bir Çıkış Katmanından Oluşan Derin Sinir Ağı Mimarisi

Derin sinir ağları, kablosuz haberleşme sistemlerinde birçok alanda sıklıkla kullanılmaktadır. Anten seçimi, iletişim kalitesini artırmak ve enerji verimliliğini sağlamak için kritik bir rol oynar. Alıcı ve vericideki çoklu antenlerin sağladığı çeşitlilik sayesinde, iletişim kanalında meydana gelen zayıflama ve parazit gibi olumsuz etkileri azaltarak sinyal-gürültü oranının (SNR) iyileştirilmesini sağlamaktadır [Heath & Lozano, 2018; Yao et al., 2019]. Burada anten seçimi, iletim sırasında en güvenilir ve güçlü kanalın kullanılmasını ifade etmekte, bu hata oranlarını düşürerek sistemin genel iletişim güvenilirliğini artırmaktadır. Derin öğrenme ve K-NN gibi makine öğrenme yöntemleri, anten seçim süreçlerini optimize etmek amacıyla kullanılan yöntemlerin başında gelmektedir. Bu yöntemler, karmaşık anten seçim problemlerinin hızlı ve yüksek performansla çözülebilmesini sağlamayı hedeflerken, aynı zamanda değişen kanal koşullarına uyum yeteneğini ve sistemin genel verimliliğini arttırmayı amaçlamaktadır [Pramitarini et al., 2023; Bouchibane et al., 2023].

2.3.1 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, sinir ağlarının performansını ve öğrenme kapasitesini optimize etmek için kritik bir rol oynar. Her bir fonksiyon, farklı veri türleri ve problem türleri için uygundur. Sigmoid, olasılık tahminleri için uygunken; Tanh, sıfır merkezli çıktılar üretmek öğrenme sürecini hızlandırabilir. Bunun yanı sıra ReLU (Rectified Linear Unit), görüntü işleme ve doğal dil işleme gibi geniş ve karmaşık veri setlerinde yaygın olarak kullanılır. Hızlı ve verimli öğrenme sağlar.

Sigmoid fonksiyonu, çıktı değerlerini 0 ile 1 arasında sıkıştırarak özellikle iki sınıflı sınıflandırma problemlerinde kullanılır. Sigmoid fonksiyonunun matematiksel ifadesi şu şekildedir:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2.8)$$

Bu fonksiyon, nöronların aktivasyon düzeylerini normalize eder ve olasılık tahminleri yapmak için uygun bir araç sağlar.

Eşitlik 2.9 ile ifade edilen Tanh (Hiperbolik Tanjant) fonksiyonu, çıktı değerlerini -1 ile 1 arasında sıkıştırır ve özellikle sıfır merkezli çıktılar üretmek modelin öğrenme sürecini hızlandırır.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.9)$$

Tanh fonksiyonu, sigmoid fonksiyonuna göre gradyanların daha büyük olmasını sağladığı için geri yayılım algoritmasında daha etkili olmaktadır.

Literatürde sıklıkla tercih edilen bir diğer aktivasyon fonksiyonu ReLU, negatif girişleri sıfıra (x değerinin 0 ve 0'dan küçük olma durumu), pozitif girişleri ise (x değerinin 0'dan büyük olma durumu) olduğu gibi bırakarak doğrusal olmayan bir dönüşüm sağlar. Matematiksel ifadesi eşitlik 2.10'da gösterilmiştir.

$$\text{ReLU}(x) = \max(0, x) \quad (2.10)$$

ReLU, sinir ağlarının derin katmanlarında gradyan kaybolma problemini azaltarak daha hızlı ve etkili öğrenme sağlar.

2.3.2 Kayıp Fonksiyonları

Kayıp fonksiyonları, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer ve modelin ne kadar iyi performans gösterdiğini belirlemek için kullanılır. Bu fonksiyonlar, modelin öğrenme sürecinde optimizasyon algoritmaları tarafından minimize edilmek üzere tasarlanmıştır. Her kayıp fonksiyonu, farklı problem türlerine uygun olarak tasarlanmıştır.

Mean Squared Error (MSE), özellikle regresyon problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. MSE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını alır. Matematiksel ifadesi şu şekildedir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.11)$$

Cross-Entropy Loss, sınıflandırma problemlerinde yaygın olarak kullanılır. Bu kayıp fonksiyonu, modelin tahmin ettiği olasılıklar ile gerçek sınıf etiketleri arasındaki farkı ölçer. Matematiksel ifadesi şu şekildedir:

$$Loss = - \sum_{i=1}^C y_i \cdot \log(\hat{y}_i) \quad (2.12)$$

Kayıp fonksiyonlarının temel amacı, modelin performansını değerlendirmek ve iyileştirmektir. Her bir kayıp fonksiyonu, belirli problem türleri için optimize edilmiştir:

- **Mean Squared Error (MSE):** Sürekli değerlerin tahmin edilmesi gereken regresyon problemlerinde kullanılır. Büyük hataları cezalandırarak modelin doğruluğunu artırır.
- **Cross-Entropy Loss:** İkili veya çok sınıflı sınıflandırma problemlerinde kullanılır. Modelin doğru sınıfları yüksek olasılıklarla tahmin etmesini sağlar ve olasılık dağılımlarını öğrenmesine yardımcı olur.

Kayıp fonksiyonlarının seçimi, modelin başarısını doğrudan etkiler. Bu nedenle, belirli bir problem için en uygun kayıp fonksiyonunun seçilmesi önemlidir. Modelin eğitim sürecinde bu fonksiyonların nasıl optimize edileceğini anlamak, daha doğru ve güvenilir tahminler elde etmek için kritik bir rol oynar.

2.3.3 Optimizasyon Algoritmaları

Optimizasyon algoritmaları, kayıp fonksiyonunu minimize etmek için kullanılır ve modelin parametrelerini bu doğrultuda günceller. Bu algoritmalar, modelin öğrenme sürecini hızlandırmak ve daha iyi performans göstermesini sağlamak için kritik bir rol oynar. Her optimizasyon algoritmasının kendine özgü özellikleri ve kullanım alanları vardır.

Stochastic Gradient Descent (SGD), en temel ve yaygın kullanılan optimizasyon algoritmalarından biridir. SGD, her iterasyonda yalnızca bir veya birkaç örneklem kullanarak modelin parametrelerini eşitlik 2.13'de görüldüğü şekilde günceller.

$$\Theta = \Theta - \eta \nabla_{\Theta} J(\Theta) \quad (2.13)$$

Burada Θ , η ve $J(\cdot)$ sırasıyla model parametrelerini, öğrenme oranını ve kayıp fonksiyonunun değerini ifade etmektedir. SGD'nin avantajları arasında basitlik ve hesaplama verimliliği bulunur, ancak gradyanların yüksek varyansı nedeniyle bazen optimizasyon süreci kararsız olabilir.

Adam (Adaptive Moment Estimation), uyarlanabilir öğrenme oranları kullanarak daha

hızlı ve kararlı öğrenme sağlayan bir optimizasyon algoritmasıdır. Adam, her parametre için bireysel öğrenme oranları hesaplayarak gradyanların ilk momentini (ortalama) ve ikinci momentini (varyans) kullanır. Bunlardan farklı olarak, bu tez çalışması kapsamında *RMSprop* (*Root Mean Square Propagation*) kullanılmıştır. Yöntem ilerleyen bölümde ayrıntılandırılacaktır.

2.3.4 Model Parametreleri ve Hiperparametreler

Model parametreleri, eğitim sürecinde öğrenilen ve modelin performansını doğrudan etkileyen değerlerdir. Ağırlıklar ve önyargılar (bias) model parametreleridir. Hiperparametreler, modelin eğitim süreci başlamadan önce belirlenen ve modelin performansını etkileyen ayarlardır. Bu ayarlar, modelin nasıl öğrenmesi gerektiğini ve eğitim sürecinin nasıl optimize edileceğini belirler. Hiperparametrelerin doğru seçimi, modelin başarısı için kritik bir öneme sahiptir. En yaygın kullanılan hiperparametreler arasında öğrenme oranı, epoch sayısı ve batch büyüklüğü bulunmaktadır.

Öğrenme oranı (*learning rate*), optimizasyon algoritmasının her adımda modelin parametrelerini ne kadar güncelleyeceğini belirleyen bir hiperparametredir. Öğrenme oranı eşitlik 2.13'de η ile gösterilmektedir. Öğrenme oranı çok yüksek olursa, model gradyanların büyük adımlarla güncellenmesi nedeniyle optimum noktayı kaçırabilir. Öğrenme oranı çok düşük olursa, model yavaş öğrenir ve eğitim süreci uzun sürer. Bu nedenle, doğru öğrenme oranını seçmek, hızlı ve etkili bir eğitim süreci için önemlidir.


Epoch sayısı, modelin tüm eğitim veri kümesi üzerinden kaç kez geçeceğini belirleyen bir hiperparametredir. Her epoch, tüm veri setinin bir kez ileri ve geri geçişini temsil eder. Epoch sayısı, modelin yeterince eğitim almasını sağlarken aşırı uyum (overfitting) riskini de minimize eder. Fazla sayıda epoch, modelin eğitim verisine aşırı uyum göstermesine neden olabilirken, az sayıda epoch modelin yeterince öğrenememesine yol açabilir. Epoch sayısını belirlerken, modelin doğrulama (validation) hatasına dikkat etmek önemlidir.

Batch büyüklüğü (*Batch Size*), modelin her güncelleme adımında kaç örnekle eğitim alacağını belirleyen bir hiperparametredir. Batch büyüklüğü, modelin eğitim veri setini daha küçük parçalara böler ve her bir parça üzerinde optimizasyon yapar. Yaygın batch büyüklükleri arasında 32, 64, 128 gibi değerler bulunur. Küçük batch boyutları, daha sık güncelleme yaparak modelin daha hızlı öğrenmesini sağlar, ancak her adımda hesaplama maliyeti daha yüksektir. Büyük batch boyutları ise daha az sıklıkta güncelleme yaparak eğitim sürecini daha verimli hale getirir, ancak her adımda daha fazla bellek kullanımı gerektirir. Batch büyüklüğünü belirlerken, hesaplama kaynakları ve eğitim süresi göz önünde bulundurulmalıdır.

Hiperparametrelerin doğru ayarlanması, modelin performansını ve eğitim sürecinin etkinliğini doğrudan etkiler. Bu nedenle, öğrenme oranı, epoch sayısı ve batch büyüklüğü gibi hiperparametrelerin dikkatlice seçilmesi ve gerektiğinde ayarlanması, başarılı bir model eğitimi için gereklidir.

3. MAKİNE ÖĞRENMESİ TABANLI KABLOSUZ HABERLEŞME ve ANTEN SEÇİMİ

Bu çalışmanın amacı, kablosuz haberleşme sistemlerinde anten seçimini optimize etmek için derin öğrenme tabanlı bir model geliştirmektir. Çalışmanın amacı, derin öğrenme kullanılarak kanal durumu bilgilerine (CSI) dayanarak en uygun antenlerin seçilmesini sağlamak ve böylece iletişim performansını artırmaktır. Şekil 3.1 tez çalışması kapsamında gerçekleştirilen kanal seçim modelinin genel adımlarını göstermektedir. Bu bölümde her bir adım ayrıntılandırılacaktır.



Şekil 3.1 Derin Öğrenme Tabanlı Model Geliştirme Aşamaları

Bölüm 2.3’de açıklandığı üzere derin sinir ağları, eğitim sırasında girdi olarak verilen veri setlerinden örüntüleri öğrenir. Açık ki, eğitim verisinin kalitesi, öğrenilen modelin ve dolayısı ile tahmin performansını etkileyen başlıca etmenlerdendir. Bu çalışmada veri seti alıcı ve verici arasındaki her bir anten çifti için SNR özniteliğini içerirken, gerçek etiketler, maksimum SNR ‘ a göre seçilmiştir. Doğrulama ve test veri setleri, eğitim veri seti ile benzer şekilde oluşturulurken, gerçek etiketler performans raporlama amacıyla kullanılacaktır.

Veri Seti Oluşturma aşamasında, kanal durumu bilgileri (CSI) kullanılarak, derin sinir ağının (DNN) eğitimi için gerekli olan eğitim, doğrulama ve test verileri üretilmiştir. Veriler, sinyal-gürültü oranı (SNR), kapasite (Cs) ve anten seçimi etiketlerini içermektedir. Önceki bölümlerde açıklandığı üzere girdi, çıktı ve gizli (ara) katmanlardan oluşan bir derin sinir ağı modelinde, ara katman ve her bir katmandaki nöron sayısı veriye ve probleme göre değişkenlik göstermekte, en uygun mimarinin oluşturulması performansın ve modelin karşılaşıklığının optimize olması için büyük önem taşımaktadır. Bu çalışmada farklı mimari tasarımları üzerinde yapılan incelemeler sonucunda ideal sinir ağı modeli tasarlanmıştır.

Geliştirilen modelin performansının ayrıntılı olarak incelenebilmesi amacıyla, farklı kanal koşulları ve anten konfigürasyonları altında test senaryoları oluşturulmuş ve testler gerçekleştirilmiştir. Bu sayede, önerilen yöntemin gerçek hayat uygulamalarında kullanılabilirliğinin gösterilmesi amaçlanmıştır. Bölüm 3.1’de veri seti oluşturma aşamaları ayrıntılandırılacaktır.

Anten seçimi için kanal durumu bilgilerini giriş olarak alıp, en uygun anteni seçmek için gerekli çıkışı verecek bir derin sinir ağı modeli tasarlanmıştır. Modelin eğitimi ve testi


için gerekli parametreler belirlenecektir. Eğitim sürecinde kullanılacak optimizasyon algoritmaları, öğrenme oranları, aktivasyon fonksiyonları ve kayıp fonksiyonları gibi parametreler tanımlanacaktır. Eğitim sırasında modelin performansını izlemek için doğrulama veri seti kullanılacaktır.

Geliştirilen modelin performansı, klasik yöntemlerle karşılaştırılarak değerlendirilecektir. Modelin SNR, Cs ve gizlilik performansı gibi metriklerle göre başarımları ölçülecektir. Ayrıca, modelin doğruluk, hassasiyet, sınıflandırma raporu gibi istatistiksel ölçütlerle performans analizi yapılacaktır.

Bu başlıklar altında yürütülecek çalışmalar, derin öğrenme tabanlı anten seçimi ile kablosuz haberleşme sistemlerinin performansını optimize etmeyi hedeflemektedir.

3.1 Veri Seti Üretimi

Bu çalışmada kullanılan veri setinin oluşturulması dört adımdan oluşmaktadır. Şekil 3.2’de derin öğrenme tabanlı anten seçimi modelinde kullanılan veri setinin geliştirilme aşamaları adım adım gösterilmiştir. İlk aşamada, *Kanal Verilerinin Üretimi* işlemi yapılır, bu aşamada modelin eğitim ve testi için gerekli olan kanal bilgileri elde edilir. Ardından, *SNR (Sinyal-Gürültü Oranı)* ve *Cs (Gizlilik Kapasitesi)* hesaplanır; bu değerler, anten seçim sürecinde kullanılacak kritik performans ölçütleridir. Üçüncü aşamada, *Anten Seçimi ve Etiketleme* işlemi gerçekleştirilir; burada, en uygun antenler belirlenir ve bu seçimler etiketlenir. Son olarak, *Veri Çerçevesinin Oluşturulması* aşaması ile veriler modelin eğitimi için uygun hale getirilir ve veri seti tamamlanır. Bu aşamalar, derin öğrenme tabanlı anten seçimi modelinin doğru ve etkili bir şekilde eğitilmesi için gerekli olan veri hazırlık sürecini kapsar.



Şekil 3.2 Derin Öğrenme Tabanlı Anten Seçimi Modelinde Kullanılacak Veri Seti Geliştirme Aşamaları

3.1.1 Kanal Verisinin Oluşturulması

Kanal verileri, Rayleigh sönümlenme modeline uygun olarak rastgele üretilir. Bu modelde, her bir kanal değeri karmaşık sayı formatındadır ve varyansı 1, ortalaması 0 olacak şekilde standart bir Gauss dağılımına sahiptir. İlk olarak, h_m adında bir karmaşık sayı dizisi oluşturulur. Bu dizi, gerçel ve sanal bileşenleri olan karmaşık sayılardan oluşur. Karmaşık sayılar, kanalın iletim özelliklerini temsil eder ve bu sayılar kanal durumu

bilgisi olarak kullanılır. Veriler karmaşık formda olduğu için, her bir karmaşık sayı hem genlik hem de faz bilgisi içerir. Kanal verisini, varyansı 1 olacak şekilde normalize edilir. Sonuç olarak N_s adet kanal için $\mathbf{h} = [h_1, h_1 \dots h_{N_s}]$ kanal vektörü oluşturulur.

Kodda kanal verileri ve SNR (Signal-to-Noise Ratio) hesaplamaları, çok girişli çok çıkışlı (MIMO) sistemlerde gizlilik kapasitesinin hesaplanması için kullanılan matematiksel formüllere dayalı olarak yapılmıştır. Bu hesaplamalar, antenler arasındaki kanal kazançlarının ve sinyal-gürültü oranının (SNR) belirlenmesiyle başlar ve gizlilik kapasitesi analizine kadar uzanır.

Kanal verilerinin oluşturulması için `generate_channel_gains` fonksiyonu kullanılır. Bu fonksiyon, her bir verici ve alıcı anten çifti arasındaki kanal kazançlarını üretir. Kanal kazançları, reel ve sanal bileşenler olmak üzere kompleks sayılar olarak tanımlanır. Bu bileşenler, normal dağılımdan rastgele üretilir ve formül şu şekildedir:

$$\mathbf{h} = \frac{1}{\sqrt{2}}(h_{\text{real}} + j \cdot h_{\text{imag}}) \quad (3.1)$$

Bu denklemde h_{real} ve h_{imag} , sırasıyla kanalın reel ve sanal bileşenlerini ifade eder. Her bileşen normal dağılımdan elde edilir. Çarpan $\frac{1}{\sqrt{2}}$ kanal kazançlarının Rayleigh dağılımına uygun olacak şekilde ölçeklendirilmesini sağlar. Kanal kazancının karesel mutlak değeri ise sinyal gücünü ifade eder ve bu, her bir anten çifti arasındaki kanal kazancını elde etmek için şu formülle hesaplanır:

$$h_{\text{abs}} = |\mathbf{h}|^2 = \left(\frac{1}{\sqrt{2}}(h_{\text{real}} + j \cdot h_{\text{imag}}) \right)^2 \quad (3.2)$$

Bu işlem, kanal verisinin gerçek ve sanal bileşenlerinden elde edilen kompleks sayıların karelerinin alınmasıyla gerçekleştirilir. Bu formülle elde edilen h_{abs} , tüm anten çiftleri için sinyal gücünü temsil eder ve gizlilik kapasitesi değerlendirmesinde kullanılır.

SNR hesaplamalarında ise, kanal belirsizliğinin varlığına göre iki farklı hesaplama durumu ele alınmıştır. Belirsizlik olmadığında (eşitlik 2.6'da dinleyici kanal varyansı, $\sigma_e^2 = 0$ ise), sadece sinyal gücü dikkate alınır ve SNR aşağıdaki şekilde hesaplanır:

$$\text{SNR}_d = P_r \cdot h_{\text{abs}} \quad (3.3)$$

Bu formülde P_r , verici gücünü ifade eder ve dB cinsinden verilen değer lineer formata çevrilerek kullanılır.

Eğer kanal belirsizliği mevcutsa (yani, $\sigma_e^2 > 0$), SNR hesaplaması, sinyal gücü ve kanal belirsizliğinin birleşik etkisini içerecek şekilde yapılır. Bu durumda, SNR şu formülle hesaplanır:

$$\text{SNR}_d = \frac{P_r \cdot h_{\text{abs}}}{P_r \cdot \sigma_e^2 + 1} \quad (3.4)$$

Burada σ_e^2 , kanal belirsizliğinin varyansını temsil eder. Bu varyans, kanal koşullarındaki belirsizliği simüle etmek için kullanılır. Formülde görüldüğü gibi, σ_e^2 değerinin artması,

toplam SNR'yi azaltan bir etki yaratır. Bu formül, sinyal gücünün artırılması durumunda belirsizliğin de etkisini göz önünde bulundurur ve bu sayede daha gerçekçi bir SNR hesaplaması yapılır.

Son aşamada, gizlilik kapasitesi hesaplanır. Gizlilik kapasitesi C_s , sinyalin alıcı tarafından alındığı koşullarda bilginin gizliliğini sağlar ve SNR değerleri üzerinden değerlendirilir. Gizlilik kapasitesinin hesaplanması, alıcıdaki SNR (SNR_d) ve sabit bir değer olan dinleyicideki SNR (SNR_e) ile yapılır. Bu kapasite şu formülle belirlenir:

$$C_s = \log_2(1 + SNR_d) - \log_2(1 + SNR_e) \quad (3.5)$$

Bu formülde $\log_2(1 + SNR_d)$, alıcı tarafındaki bilgi iletim kapasitesini ifade ederken, $\log_2(1 + SNR_e)$ dinleyiciye iletilen bilginin kapasitesini ifade eder. Bu iki değer arasındaki fark ise gizlilik kapasitesini verir. Gizlilik kapasitesinin pozitif olması, bilginin güvenli bir şekilde iletebileceğini gösterir.

Sonuç olarak, kanal kazançları ve SNR hesaplamaları gizlilik kapasitesinin analizine olanak tanır. Farklı σ_e^2 değerleri ve güç seviyeleri kullanılarak, gizlilik kapasitesi üzerinde çeşitli senaryolar denenir ve bu sonuçlar grafiksel olarak sunulur. Bu yöntem, anten seçiminin gizlilik performansı üzerindeki etkisini detaylı bir şekilde değerlendirme olanağı sağlar.

3.2 Önerilen Makine Öğrenmesi Model Mimarileri

Bu çalışmada kullanılan makine öğrenme modelleri, denetimli öğrenme yaklaşımına dayanmaktadır. Denetimli öğrenme, modelin belirli bir girişe karşılık gelen doğru çıkışı öğrenmesi için eğitim verilerinin etiketlendiği bir makine öğrenmesi türüdür. Bu yöntemde, model giriş ve çıkış çiftlerinden oluşan bir eğitim veri seti kullanılarak eğitilir. Bu çalışmada, kablosuz haberleşme sistemlerinde anten seçimi problemini çözmek için Yoğun Sinir Ağı (DNN), Konvolüsyonel Sinir Ağı (CNN) ve K En Yakın Komşu (K-NN) olarak isimlendirilen üç farklı denetimli öğrenme modeli ile testler yapılmış ve performans raporlanmıştır.


DNN modeli, anten seçimi problemini çözmek için çok katmanlı yapısıyla verilerdeki karmaşık desenleri öğrenmeye yöneliktir. CNN modeli ise özellikle verilerdeki yerel ilişkileri tanımak ve anten seçimi performansını artırmak için filtreleme katmanları kullanarak giriş verilerinden daha derin özellikler çıkarmaya odaklanmıştır. K-NN modeli, sinir ağı tabanlı olmamakla birlikte, komşuluk ilişkilerine dayanarak giriş verilerini sınıflandırır ve en yakın komşularına göre en uygun antenleri seçmeyi amaçlar. Her bir model, belirli kanal durum bilgileri (CSI) ve etiketlenmiş veri seti kullanılarak anten seçiminin optimize edilmesi için eğitilmiştir.

Bu şekilde, DNN, CNN ve K-NN yöntemleri birlikte kullanılarak kablosuz haberleşme sistemlerinde anten seçiminin performansını artırma ve iletişim güvenliğini sağlama

hedeflenmiştir.

3.2.1 Yoğun Sinir Ağı (DNN) Modeli

Yoğun Sinir Ağı (DNN), tamamen bağlantılı katmanlardan oluşan ve verinin özelliklerini çıkararak sınıflandırma yapan bir yapay sinir ağı modelidir. DNN mimarisi, giriş, gizli ve çıkış katmanlarından oluşur. Her katman, bir önceki katmandan gelen veriyi alır, işleyip bir sonraki katmana iletir. Şekil 3.3’de derin sinir ağına ait nöron yapısı görülmektedir.



Şekil 3.3 Derin Sinir Ağına Ait Nöron Yapısı

Giriş Katmanı: Giriş katmanı, kanal durumu bilgilerini ($\mathbf{h} = [h_1, h_1 \dots h_{N_s}]$) alır. Bu veriler, antenlerin kanal durumunu temsil eder ve modelin işleyebileceği bir forma dönüştürülerek gizli katmanlara iletilir. Bu aşamada, her giriş bir ağırlık değeri ile çarpılarak ağırlıklı toplamalar elde edilir.

Gizli Katmanlar: DNN’nin gizli katmanları, her nöronun bir önceki katmandan gelen girdiyi işlediği ve doğrusal olmayan ilişkileri modellediği katmanlardır. Bu katmanlarda, $W^{(l)}$ ağırlık matrisleri ve $b^{(l)}$ önyargılar ile birlikte lineer kombinasyon işlemi gerçekleştirilir:

$$z^{(l)} = W^{(l)} \cdot a^{(l-1)} + b^{(l)} \quad (3.6)$$

Aktivasyon Fonksiyonu (ReLU): Gizli katmanlarda ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılarak doğrusal olmayan dönüşümler yapılır. ReLU, negatif değerleri sıfıra eşitleyerek yalnızca pozitif değerleri geçirir:

$$a^{(l)} = \max(0, z^{(l)}) \quad (3.7)$$

Bu dönüşüm, modelin karmaşık örüntüleri öğrenebilmesini sağlar. ReLU’nun önemli bir avantajı, türev alma işleminin kolay olması ve gradyanların yayılmasını engelleyen "sıfırlanma" sorunlarının önüne geçmesidir.

Çıkış Katmanı ve Softmax Aktivasyon Fonksiyonu: Çıkış katmanı, modelin anten

seçimi için olasılık dağılımını sağlar. Bu aşamada, Softmax aktivasyon fonksiyonu kullanılarak her sınıf için bir olasılık değeri hesaplanır:

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.8)$$

Softmax fonksiyonu, her sınıf için tahmin edilen değerlerin toplamının 1 olacak şekilde normalize edilmesini sağlar. Bu sayede model, her anten seçeneğine ait olasılık değerini belirler ve en yüksek olasılığa sahip anten seçeneğini tercih eder. Softmax fonksiyonunun türevleri, eğitim sürecinde gradyan inişi hesaplamaları için kullanılarak optimizasyon sürecine katkı sağlar.

Categorical Crossentropy Kayıp Fonksiyonu

DNN modelinde kullanılan Categorical Crossentropy kayıp fonksiyonu, modelin hata oranını hesaplayarak eğitim sürecinde doğru sınıflandırma yapılmasını sağlar. Çok sınıflı sınıflandırma problemleri için uygundur ve gerçek sınıf (y_i) ile tahmin edilen olasılıklar ($\hat{y}_i$) arasındaki farkı minimize eder ve eşitlik 2.12 'de gösterildiği gibidir.

Bu kayıp fonksiyonu, doğru sınıf için yüksek olasılık değerleri vererek modelin hatalarını azaltmaya çalışır. Böylece, modelin doğru sınıfı tahmin etme oranı artırılır.

Optimizasyon Süreci ve Adam Algoritması

DNN modelinin eğitimi sırasında, parametrelerin güncellenmesi için hem RMSprop hem de Adam optimizasyon algoritmaları kullanılmıştır:

Adam (Adaptive Moment Estimation):

Adam algoritması, gradyanların ortalamasını ve karelerinin ortalamasını kullanarak daha hassas bir öğrenme süreci sunar. Adam'ın ağırlık güncellemeleri şu şekilde gerçekleşir:

İlk olarak, gradyanların hareketli ortalaması (m_t) ve karelerin ortalaması (v_t) hesaplanır:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.9)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.10)$$

Ardından, bu ortalamalar kaydırılarak güncellenmiş değerler (m_t ve v_t) hesaplanır:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.11)$$

Son olarak, ağırlıklar aşağıdaki gibi güncellenir:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t \quad (3.12)$$

Bu optimizasyon algoritmaları, modelin hata oranını minimize ederken hızlı ve kararlı bir öğrenme süreci sağlar.

Tablo 3.1 DNN Model Yapısı

	Layer Type	Number of Units	Activation Function	Optimizer	Loss Function
1	Dense	128	ReLU	Adam (learning rate=0.001)	Sparse Categorical Crossentropy
2	Dense	128	ReLU		
3	Dense	64	ReLU		
4	Dense	N	Softmax		

Bu çalışmada , **DNN modeli**, anten seçimi için kullanılan temel derin öğrenme yöntemlerinden biri olarak kullanılmıştır. DNN, çok katmanlı yapısı sayesinde, giriş verilerinin daha karmaşık özelliklerini öğrenebilme kapasitesine sahiptir. Bu nedenle, yüksek boyutlu kanal verilerinde en uygun antenin seçilmesinde oldukça etkilidir.

Çalışmada, DNN modeli dört katmanlı bir yapıda oluşturulmuş ve her katmanda belirli sayıda düğüm kullanılarak, farklı seviyelerde özellik çıkarımı yapılmıştır. Modelin, **ReLU** aktivasyon fonksiyonları ve son katmanda **Softmax** fonksiyonu ile çalışması sağlanmıştır. Optimize edici olarak **Adam** optimizasyon algoritması kullanılmış ve öğrenme hızı 0.001 olarak belirlenmiştir(Tablo 3.1). Bu yapı, farklı anten seçenekleri arasında en yüksek sinyal-gürültü oranına sahip anteni seçme amacını taşımaktadır.

3.2.2 Konvolüsyonel Sinir Ağı (CNN) Modeli

CNN, yerel özellikleri çıkararak sınıflandırma yapan bir yapay sinir ağıdır. Her bir konvolüsyonel katman, belirli bir filtre kullanarak yerel özellikleri öğrenir ve bu özellikleri sınıflandırma için kullanır. CNN mimarisi, konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşur:

Konvolüsyonel Katmanlar: Bu katmanlar, giriş verisini filtrelerle işleyerek yerel özellikleri çıkarır:

$$S_{i,j} = \sum_m \sum_n x_{i+m,j+n} \cdot w_{m,n} \quad (3.13)$$

Burada, xxx, giriş verisini ve www, filtreyi temsil eder. Her bir filtre, yerel örüntüleri algılayarak özellik haritaları oluşturur. Her konvolüsyonel katmandan sonra ReLU aktivasyon fonksiyonu uygulanarak doğrusal olmayan özellikler öğrenilir.

Havuzlama (Pooling) Katmanları: Konvolüsyon işleminin ardından veriyi boyut olarak küçülten ve en belirgin özellikleri çıkaran bir katmandır. CNN’de genellikle MaxPooling işlemi kullanılır. Bu işlem, belirli bir alandaki maksimum değeri seçerek verinin boyutunu azaltır:

$$S_{i,j} = \max(x_{i+a,j+b}) \quad (3.14)$$

Burada, x , giriş verisini; a ve b , havuzlama penceresinin boyutlarını ifade eder. Örneğin, 2×2 boyutunda bir MaxPooling işlemi, özellik haritasını dört kat küçülterek önemli özellikleri korur ve veri boyutunu azaltır. Bu sayede modelin hesaplama yükü azalır ve öğrenme süreci hızlanır.

Tam Bağlantılı (Fully Connected) Katmanlar: Havuzlama işlemi sonrasında elde edilen sıkıştırılmış özellikler, sınıflandırma işlemi için tam bağlantılı katmanlara aktarılır. Bu katmanlarda, her nöron bir önceki katmandaki tüm nöronlarla bağlantılıdır. Tam bağlantılı katmanda her nöron, giriş sinyallerini ağırlıklandırarak toplar ve bir önyargı değeri ekler:

$$z^{(l)} = W^{(l)} \cdot a^{(l-1)} + b^{(l)} \quad (3.15)$$

Bu lineer birleşim, sınıflandırma yapabilmek için Softmax aktivasyon fonksiyonuna tabi tutulur. Softmax(eşitlik 3.8), anten seçimi için bir olasılık dağılımı sağlar ve en uygun antenin seçilmesine imkan tanır. Bu fonksiyon sayesinde, her bir sınıf için olasılık değerleri normalize edilerek en yüksek olasılığa sahip sınıf seçilir.

CNN modelinde, Categorical Crossentropy kayıp fonksiyonu(2.12), modelin doğru sınıfı tahmin etme yeteneğini artırmak amacıyla hata oranını hesaplar. Bu kayıp fonksiyonu, tahmin edilen olasılıklar ile gerçek değerler arasındaki farkı minimize eder:

CNN modelinde de Adam algoritması kullanılarak ağırlıklar güncellenir. Algoritma, her adımda kayıp fonksiyonunu minimize etmek için parametreleri günceller.

Tablo 3.2 CNN Model Yapısı

	Layer Type	Kernel Size / Pool Size	Number of Filters / Units	Activation Function	Optimizer	Loss Function
1	Conv2D	(1, 1)	32	ReLU	Adam (learning rate=0.001)	Sparse Categorical Crossentropy
2	MaxPooling2D	(1, 1)				
3	Flatten					
4	Dense		128	ReLU		
5	Dense		N	Softmax		

Bu çalışmada, **CNN modeli**, özellikle iki boyutlu veri yapılarının analizi için güçlü özellik çıkarımı kabiliyetine sahip olduğu için anten seçimi probleminde kullanılmıştır. CNN modelinin katman yapısı, kanal verilerinin farklı uzamsal özelliklerini yakalamaya ve bu özellikleri modellemeye olanak sağlar. Bu nedenle, kanal verisinin genlik ve faz yapılarındaki uzamsal bilgilerin analiz edilmesinde oldukça etkilidir.

Tablo 3.2’de görüldüğü gibi, CNN modeli, bir **Conv2D** katmanı ile kanal verilerini

işleyerek farklı anten seçenekleri arasından en uygun olanını seçer. Bu aşamadan sonra **MaxPooling2D** ve **Flatten** katmanları, veriyi düzleştirip tam bağlantılı katmanlara aktarmak için kullanılır. Model, **ReLU** aktivasyon fonksiyonları ve son katmanda **Softmax** fonksiyonu ile çalışmaktadır. **Adam** optimizasyon algoritması ve öğrenme hızı 0.001 kullanılarak, modelin eğitim performansı artırılmıştır.

3.2.3 K En Yakın Komşu (K-NN) Modeli

K-NN Modeli ve Sınıflandırma Süreci

K-NN algoritması, eğitim veri kümesindeki KK en yakın komşuya dayanarak sınıflandırma yapan bir modeldir. Bu model, veri noktaları arasındaki mesafeyi hesaplayarak en yakın komşuları belirler ve sınıflandırma yapar.

Mesafe Hesaplama: K-NN modeli, genellikle Öklid mesafesi kullanılarak her bir veri noktasının diğer noktalara olan mesafesini ölçer. Mesafe hesaplaması şu formülle yapılır:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.16)$$

En Yakın Komşuların Seçimi: Eğitim veri kümesindeki en yakın KK komşu seçilerek test verisi sınıflandırılır. Bu seçim, anten seçimi için önemli olup, genellikle çoğunluk oylaması ile gerçekleştirilir. En yakın komşuların sınıf etiketleri göz önünde bulundurularak, test verisi için nihai sınıf atanır.

K-NN Modelinde Kullanılan Hiperparametre: KK Değeri

K-NN modelinde KK parametresi, modelin hassasiyetini belirler. Küçük bir KK değeri modelin daha fazla varyans göstermesine neden olabilirken, büyük bir KK değeri modelin daha dengeli bir sınıflandırma yapmasına olanak tanır. Bu çalışmada, farklı KK değerleri için doğruluk analizleri yapılmış ve en uygun KK değeri seçilmiştir.

Bu kısımda, her modelin yapısını ve işleyişini kapsamlı bir şekilde ele alarak, anten seçimi için hangi adımların ve matematiksel işlemlerin gerçekleştirildiğini açıklamaktadır. Modellerin optimizasyon süreçleri, kayıp fonksiyonları ve ileri besleme adımları, kablosuz haberleşme sistemlerinde verimli bir sınıflandırma yapmak için kritik öneme sahiptir. DNN ve CNN modellerinde kullanılan Adam ve RMSprop optimizasyon algoritmaları, modelin hata oranını en aza indirmek için stratejik bir şekilde uygulanmıştır.

Tablo 3.3 K-NN Model Yapısı

	Parameter	Value
1	n_neighbors	5
2	Distance Metric	Euclidean
3	Scaler	StandardScaler

Bu çalışmada, **KNN modeli**, anten seçimi probleminde kullanılan geleneksel makine öğrenmesi yöntemlerinden biri olarak dahil edilmiştir. KNN modeli, sınıflandırma

işlemlerinde örneklerin yakınlık ilişkilerine dayanan basit ama etkili bir yöntemdir. Bu modelde, kanal verileri **StandardScaler** kullanılarak ölçeklendirilmiş ve en yüksek SNR değerine sahip anteni seçmek için **KNN** algoritması uygulanmıştır (Tablo 3.3).

KNN algoritması, **n_neighbors=5** parametresiyle, yani her örneğe en yakın beş komşuya göre sınıflandırma yapacak şekilde yapılandırılmıştır. Uzaklık metriği olarak **Euclidean** mesafesi seçilmiş ve en yakın komşular arasında en yüksek SNR değerine sahip olan anten, tercih edilmiştir.

3.2.4 Denetimli Öğrenme Modellerinin Test ve Eğitim İşlem Akışı

Denetimli öğrenme modellerinin eğitim, test ve doğrulama süreçleri, her bir modelin kanal verilerini öğrenme ve genelleme yeteneğini geliştirmek üzere tasarlanmış bir dizi adımı kapsar. Bu sürecin başlangıcı, kanal durumu bilgilerini içeren veri girişidir. Eğitim verisi, modelin giriş katmanına aktarılır ve bu aşamada, modelin tahmin yeteneğini şekillendiren temel özellikler öğrenilmeye başlanır. **DNN** ve **CNN** modelleri için veri, katmanlı yapıya uygun olarak ölçeklendirilir ve dönüştürülürken, **KNN** modelinde ise veri, standartlaştırma gibi ön işlemlerle değerlendirilir. Eğitim aşamasında her bir model, giriş verisini kabul ederek öğrenme sürecine adım atar.

İleri yayılım sürecinde, giriş verisi modelin katmanlarından geçirilir. **DNN** ve **CNN** modelleri, katman sayısına bağlı olarak genellikle ReLU gibi aktivasyon fonksiyonları kullanarak bu veriyi işler ve her katmanda özellik çıkarımı yapar. Bu süreç, veri modelin tüm katmanlarından geçtikten sonra, bir tahmin elde edilmesiyle sonuçlanır. **KNN** modeli ise, ileri yayılım sürecine gerek duymadan, doğrudan eğitim ve test aşamalarında veri örnekleri arasındaki mesafeleri ölçerek, en yakın komşularını değerlendirir. Bu noktada, **DNN** ve **CNN** modellerinin tahmin edilen sonuçları, modelin öğrenme sürecinin ilk çıktıları olarak kaydedilir.

Modelin eğitimi süresince, doğrulama verileri kullanılarak modelin genelleme yeteneği izlenir. Eğitim sürecinde kullanılan doğrulama veri seti, **DNN** ve **CNN** modelleri için her epoch tamamlandıktan sonra performans değerlendirmesi için kullanılır. Epoch, eğitim veri setinin tümünün modelden bir kez geçirilmesi anlamına gelir ve eğitim süreci boyunca birçok epoch tekrarlanarak modelin parametreleri optimize edilir. Doğrulama verisi, modelin aşırı öğrenme yapmasını engellemek ve genelleme kapasitesini artırmak amacıyla eğitim sürecine eklenir. **KNN** modelinde ise, doğrulama işlemi eğitim sonrasında yapılır; doğrulama sürecinde model, eğitim verileri ile öğrenilmiş parametreler doğrultusunda yeni örnekler üzerinde test edilerek değerlendirilir.

Test süreci ise modelin performansını nihai olarak değerlendirmek için ayrılmış bir veri seti kullanılarak gerçekleştirilir. Eğitim süreci tamamlandıktan sonra, **DNN** ve **CNN** modelleri, daha önce görmedikleri test verisi üzerinde test edilerek doğrulukları ve genelleme kapasiteleri incelenir. Bu test süreci, eğitim ve doğrulama aşamalarında optimize edilen modelin gerçek dünyadaki veri setleri üzerinde nasıl performans gösterdiğini anlamak için kritik öneme sahiptir. **KNN** modeli ise, aynı şekilde eğitim ve doğrulama aşamalarından sonra test veri seti kullanılarak değerlendirilir. Her üç model

de, test sürecinde, kanal verileri ve anten seçimi problemine özgü senaryolara uygunluk açısından analiz edilir.

Bu eğitim, test ve doğrulama süreçleri, DNN, CNN ve KNN modellerinin her birinin eğitim sürecindeki adımları ve genelleme kapasitesini değerlendirmek için tasarlanmış bir dizi yapılandırılmış aşamayı ifade eder. Bu süreçler, modellerin performansını optimize etmeye ve kanal durumu bilgilerini en doğru şekilde öğrenmelerine olanak sağlar.


4. MAKİNE ÖĞRENMESİ TABANLI ANTEN SEÇİMİ PERFORMANS ANALİZİ

4.1 SNR Değerine Göre Anten Seçimi

Bu çalışmada, SNR değerlerinin sabit ve değişken olduğu kanal gücü (P_s) altında anten seçim performansını değerlendirmek için doğruluk (accuracy), kayıp (loss) ve F1 skoru gibi temel performans metrikleri kullanılmıştır. Doğruluk, modelin doğru tahmin yapma oranını ölçerken, kayıp grafikleri modelin öğrenme sürecindeki uyum yeteneğini ortaya koymaktadır. F1 skoru ise doğruluk ve geri çağırma (recall) oranlarının harmonik ortalamasını sunarak modelin genel performansını SIMO, MISO ve MIMO sistemler için detaylı bir şekilde değerlendirmektedir.

4.1.1 SIMO Sistemlerde Değişken ve Sabit Kanal Güç Değerine (P_s) Göre Anten Seçimi


Bu çalışmada, SIMO (Single-Input Multiple-Output) sistemlerinde anten seçimi görevinde farklı makine öğrenmesi yöntemlerinin SNR (Signal-to-Noise Ratio) değerlerine göre anten seçme performansları değerlendirilmiştir. Anten seçimi, kablosuz iletişim sistemlerinde sistem performansını ve veri iletim güvenilirliğini artırmak için kritik bir adımdır. SNR değerlerinin kanal verisine göre değişkenlik gösterdiği senaryolarda, Dense Model, Convolutional Neural Network (CNN) ve K-Nearest Neighbors (KNN) modellerinin anten seçimi doğruluğu, kayıpları ve F1 skorları analiz edilerek karşılaştırılmıştır.



Şekil 4.1 SIMO Sitemlerde Değişken Ps Değeri İçin Doğruluk Grafiği(DNN-CNN)


Şekil 4.1’de, değişken iletim gücü (P_s) altında DNN ve CNN modellerinin doğruluk performansları karşılaştırılmaktadır. CNN modeli, eğitim sürecinin başından itibaren doğruluk oranında hızlı bir yükseliş gösteriyor. Eğitim ilerledikçe doğruluk yaklaşık %98 seviyelerine ulaşıyor ve eğitim süresi boyunca bu seviyede sabit kalıyor. CNN’in bu stabilitesi, modelin değişken P_s değerlerine rağmen SNR değişimlerine uyum sağlayarak en uygun anteni seçme konusunda güçlü olduğunu ortaya koyuyor. Eğitim süreci boyunca gözlemlenen bu performans artışı, CNN’nin farklı SNR koşullarında yüksek doğrulukla çalışabileceğini gösteriyor. Bu, CNN’in verideki yerel ilişkileri yakalama ve öğrenme yeteneği sayesinde gerçekleşiyor. Değişken P_s koşulları altında, kanal kazançlarının ve SNR değerlerinin sürekli değişmesi, anten seçimini daha karmaşık hale getirirse de CNN modeli bu dalgalanmalara uyum sağlayarak anten seçiminde tutarlı bir başarı gösteriyor.

Öte yandan, DNN modeli de eğitim süreci boyunca(Şekil 4.1) doğruluğunu artırarak yaklaşık %96 seviyelerine ulaşmıştır. Ancak, DNN’nin doğruluk oranları CNN modeline kıyasla daha yavaş bir şekilde artıyor ve doğruluk eğrisinde belirgin dalgalanmalar gözlemleniyor. Bu dalgalanmalar, DNN’nin değişken P_s koşullarında anten seçimi sırasında kararsızlık yaşadığını ve modele özgü mimari yapının bu dalgalanmalara uyum sağlamakta zorlandığını düşündürüyor. CNN modelinin aksine, DNN’nin SNR değişimlerine yeterince esnek yanıt veremediği ve bu nedenle en uygun anteni seçmede daha az başarılı olduğu ortaya çıkıyor. Yine de, DNN’nin %96 doğruluk seviyelerine ulaşması, değişken P_s koşullarında da belirli bir başarı düzeyine sahip olduğunu, ancak CNN kadar güçlü olmadığını gösteriyor.



Şekil 4.2 SIMO Sitemlerde Değişken Ps Değeri İçin K-NN yöntemi ile elde edilen Doğruluğun Farklı k Komşuluk Değerine Göre Değişim Grafiği


Değişken Ps koşulları altında KNN modelinin performansını gösteren grafikte(Şekil 4.2), modelin doğruluğu $n_neighbors$ parametresine göre önemli ölçüde değişiklik gösteriyor. KNN, $n_neighbors$ değeri arttıkça doğruluk oranını artırmakta; başlangıçta düşük doğruluk oranlarına sahipken, komşu sayısı arttıkça yaklaşık %88 doğruluk seviyesine ulaşıyor. Bu, KNN modelinin değişken Ps koşulları altında doğru anten seçimi yapabilmesi için daha fazla komşuya ihtiyaç duyduğunu gösteriyor. Değişken Ps koşullarında, her bir antenin SNR'si farklı değerler aldığından, KNN'nin antenler arasındaki doğru bağlantıları kurabilmesi için daha fazla veri noktasına ihtiyacı olduğu anlaşıyor. Bununla birlikte, doğruluk oranı CNN ve DNN modellerine kıyasla daha düşük seviyelerde kalıyor. Bu durum, KNN'nin SNR değerlerindeki dalgalanmalara uyum sağlamada yetersiz kalabileceğini ve anten seçimi açısından daha düşük bir başarı oranına sahip olduğunu gösteriyor. KNN'nin en yakın komşulara dayalı bir sınıflandırma yöntemi kullanması, değişken Ps durumunda daha zorlayıcı hale gelmekte ve modelin anten seçimi başarısını düşürmektedir.



Şekil 4.3 SIMO Sistemlerde Sabit Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Doğruluğunun Eğitim Boyunca Değişimi

Sabit Ps durumunda, yani iletim gücünün her bir anten için aynı seviyede olduğu koşullarda, DNN ve CNN modellerinin doğruluk performansları daha yüksek ve daha kararlı bir seyir izliyor(Şekil 4.3). CNN modeli, sabit Ps koşullarında da eğitim sürecinin başlarında hızlı bir doğruluk artışı sergileyerek %98 seviyesine ulaşıyor ve bu seviyeyi eğitim boyunca korumayı başarıyor. Bu durum, sabit bir iletim gücü ile SNR'nin yalnızca kanal kazançlarına bağlı olduğu durumlarda, CNN'in çok daha güvenilir bir anten seçimi yapabildiğini gösteriyor. Modelin erken epoch'larda bu seviyeye ulaşması, CNN'in sabit bir güç durumunda kanal kazançlarının varyasyonlarına hassas bir şekilde yanıt verebildiğini ve antenler arasındaki en iyi kanalı hızla belirleyebildiğini ortaya koyuyor. Sabit Ps koşulunun getirdiği bu doğruluk artışı, CNN modelinin anten seçiminde neden güçlü bir model olduğunu bir kez daha kanıtlıyor.


Şekil 4.3'de görüldüğü gibi DNN modeli de sabit Ps koşullarında doğruluğunu artırarak %96 seviyelerine ulaşıyor ve eğitim süresi boyunca kararlı bir doğruluk sergiliyor. Sabit bir iletim gücüyle çalışan DNN modelinde, doğruluğun sabit kalması, modelin kanal kazançlarına dayalı olarak anten seçiminde daha uyumlu bir performans sunduğunu gösteriyor. Değişken Ps koşullarında görülen doğruluk dalgalanmaları burada gözlemlenmediği için, sabit Ps koşullarının DNN modeli için daha uygun olduğu ve kanal kazançlarına dayalı doğru anten seçiminde modelin kararlı bir performans sunduğu söylenebilir. Sabit Ps koşulunda, SNR'nin yalnızca kanal kazancına dayalı olarak belirlenmesi, DNN'nin bu veriyi daha iyi öğrenmesine ve daha doğru anten seçimleri yapmasına olanak tanıyor.



Şekil 4.4 SIMO Sitemlerde Sabit Ps Değeri İçin K-NN yöntemi ile elde edilen Doğruluğun Farklı k Komşuluk Değerine Göre Değişim Grafiği

KNN modelinin Şekil 4.4'deki grafikte gösterildiği gibi, sabit Ps koşulları altında gösterdiği performans, modelin doğruluk oranında daha hızlı bir artışa yol açmıştır. Sabit Ps durumunda, KNN modelinin doğruluğu komşu sayısının artışıyla birlikte hızla yükselmiş ve %90 doğruluğa ulaşmıştır. Bu sonuç, sabit Ps koşullarında KNN modelinin anten seçimi açısından daha uyumlu olduğunu ve sabit bir güç durumunda kanal kazançlarını doğru bir şekilde değerlendirerek en iyi anteni seçme konusunda daha başarılı olduğunu gösteriyor. Sabit Ps koşullarında, her bir antenin SNR'si yalnızca kanal kazançlarına dayalı olarak belirlendiği için, KNN daha tutarlı ve güvenilir sonuçlar veriyor. Bu da KNN'nin sabit Ps koşullarında daha iyi performans sunduğunu ve değişken koşullara kıyasla sabit Ps altında anten seçiminde daha güvenilir olduğunu ortaya koymaktadır.


Genel olarak, bu analizler CNN modelinin değişken ve sabit iletim gücü koşullarında en yüksek doğruluğa sahip olduğunu, DNN'nin sabit Ps koşullarında stabil performans sergilediğini ve KNN'nin sabit Ps altında daha güvenilir bir doğruluk oranına ulaştığını gösteriyor. Anten seçimi için en uygun model, değişken koşullarda CNN iken, sabit koşullarda DNN ve KNN stabil performansları ile öne çıkmaktadır. Bu, kablosuz iletişim sistemlerinde anten seçimi yaparken kanal koşulları ve iletim gücüne bağlı olarak hangi modelin tercih edileceğine dair önemli bilgiler sunmaktadır.



Şekil 4.5 SIMO Sitemlerde Değişken Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Kaybının Eğitim Boyunca Değişimi

Şekil 4.5’deki grafikte, değişken Ps koşulları altında DNN ve CNN modellerinin kayıplarının epoch sayısına göre değişimi gösterilmektedir. CNN modeli, eğitim sürecinin başından itibaren hızlı bir kayıp düşüşü yaşamış ve ilk birkaç epoch içinde kaybını önemli ölçüde azaltarak yaklaşık 0.03 seviyelerine kadar düşürmüştür. Hem eğitim hem de doğrulama kayıpları boyunca düşük ve stabil kalmıştır. Bu, CNN’nin değişken Ps koşulları altında hızlı bir şekilde öğrenebildiğini ve modelin SNR değişimlerine uyum sağlayarak doğru anten seçimi yapabildiğini göstermektedir. Kayıp seviyesinin düşük olması, modelin güçlü bir şekilde genel anlamda veriyi öğrendiğini ve değişken kanal kazançlarına uyum sağladığını göstermektedir.

Şekil 4.5’deki grafikte, DNN modeline bakıldığında ise kayıplar ilk epochlarda hızlı bir düşüş yaşasa da, CNN kadar düşük seviyelere inmemiştir. DNN’nin eğitim ve doğrulama kayıplarında daha fazla dalgalanma gözlemlenmektedir. Bu dalgalanmalar, DNN’nin değişken Ps koşullarında kararsız bir öğrenme süreci yaşadığını ve modelin tam anlamıyla stabil bir şekilde uyum sağlamadığını göstermektedir. Kayıpların CNN modeline göre daha yüksek seviyelerde olması, DNN’nin değişken SNR koşullarında kanal kazançları arasındaki ilişkileri öğrenmede zorlandığını düşündürmektedir.



Şekil 4.6 SIMO Sistemlerde Sabit Ps Değeri İçin DNN ve CNN yöntemleri ile Eğitim ve Doğrulama Kaybının Eğitim Boyunca Değişimi

Bu grafikte, sabit Ps koşulları altında DNN ve CNN modellerinin kayıp performansları gözlemlenmektedir(Şekil 4.6). CNN modeli, sabit Ps koşullarında da benzer bir şekilde kaybını hızla azaltmış ve kayıp değerleri 0.03 seviyesine kadar düşmüştür. Eğitim kaybı oldukça düşük seviyelerde sabit kalmış, doğrulama kaybı ise küçük dalgalanmalar göstermiştir. Bu küçük dalgalanmalara rağmen, genel olarak CNN modelinin sabit Ps koşullarında stabil bir öğrenme süreci geçirdiği ve anten seçiminde güvenilir sonuçlar verdiği görülmektedir. Sabit Ps koşulları, modelin kanal kazançlarına dayalı olarak anten seçimini yapmasına olanak tanıdığından, CNN'in düşük kayıp seviyelerinde kalarak başarılı bir performans sunduğu ortaya çıkmaktadır.

DNN modeli, sabit Ps koşulları altında daha stabil bir kayıp eğrisi göstermiştir. İlk birkaç epoch'tan sonra kayıplar azalmış ve yaklaşık 0.1 seviyelerinde stabil hale gelmiştir(Şekil 4.6). Eğitim kaybı ile doğrulama kaybı arasındaki fark da görece düşük seviyede kalmış ve modelin genel anlamda stabil bir öğrenme süreci geçirdiği gözlemlenmiştir. Sabit Ps koşullarında DNN modelinin kayıp değerinin, değişken Ps koşullarına göre daha düşük seviyelere ulaşması, sabit kanal kazançlarının modelin öğrenme sürecini olumlu etkilediğini ve anten seçimini doğru bir şekilde yapabilme kabiliyetini artırdığını göstermektedir.

Şekil 4.6'da bulunan grafiklerde, CNN modelinin hem değişken hem de sabit Ps koşullarında düşük kayıp değerlerine ulaşarak anten seçimi görevinde başarılı bir öğrenme süreci sergilediği görülmektedir. Özellikle CNN'nin düşük kayıpları, modelin kanal kazançlarına ve değişken SNR koşullarına etkili bir şekilde uyum sağladığını göstermektedir. DNN ise her iki durumda da CNN'in altında kalmış, özellikle değişken Ps koşullarında daha dalgalı bir kayıp eğrisi sergilemiştir. Ancak sabit Ps koşullarında

DNN modelinin daha stabil bir performans göstermesi, bu modelin belirli kanal koşullarında daha iyi çalışabileceğine işaret etmektedir. Bu sonuçlar, CNN'in anten seçimi açısından daha güçlü bir performans sunduğunu, DNN'nin ise sabit koşullar altında belirli bir stabiliteye sahip olduğunu ortaya koymaktadır.

Tablo 4.1 SIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Model	Ps	Doğru Tahmin Edilen Örnek Sayısı	Yanlış Tahmin Edilen Örnek Sayısı	Doğruluk
CNN	Değişken	19477	523	0.974
DNN	Değişken	18901	1099	0.945
KNN	Değişken	15861	4139	0.793
CNN	Sabit	19661	339	0.983
DNN	Sabit	18958	1042	0.948
KNN	Sabit	16342	3658	0.817

Tablo 4.1'de değişken Ps koşulları altında CNN modeli, 19,477 doğru tahmin ve 523 yanlış tahminle oldukça başarılı bir performans sergilemiştir. Bu, modelin değişken SNR değerlerine rağmen yüksek doğruluk oranını koruyabildiğini ve farklı kanal koşullarına uyum sağlama yeteneğinin güçlü olduğunu ortaya koymaktadır. Değişken Ps, kanal kazançlarının ve SNR seviyelerinin sürekli değiştiği bir durumu temsil ettiği için anten seçimi görevini daha zor hale getirirse de, CNN modelinin bu zorluğa uyum sağladığı ve en doğru anteni seçme konusunda başarılı olduğu gözlemlenmiştir. Sabit Ps koşullarında ise CNN, 19,661 doğru tahmin ve sadece 339 yanlış tahminle performansını daha da artırmıştır. Bu durum, sabit Ps ile kanal kazançlarının daha düzenli bir yapıda olması nedeniyle modelin doğru anten seçiminde çok daha güvenilir bir performans sunduğunu göstermektedir. Özellikle sabit Ps koşullarında yanlış tahminlerin azalması, CNN'in bu tür sabit koşullarda çok daha etkin olduğunu ortaya koymaktadır. Bu bağlamda, CNN modeli her iki koşulda da anten seçimi için en yüksek doğruluğa sahip model olarak öne çıkmaktadır.

Değişken Ps koşullarında DNN modeli, 18,901 doğru tahmin ve 1,099 yanlış tahminle CNN'e kıyasla daha düşük bir doğruluk oranına ulaşmıştır. Bu durum, DNN'nin değişken Ps koşullarında, yani SNR değerlerinin dalgalandığı durumlarda daha fazla zorlandığını göstermektedir. Değişken Ps koşullarında modelin doğru tahmin sayısındaki azalma, DNN'nin bu koşullara yeterince uyum sağlayamadığını düşündürmektedir. Sabit Ps koşulunda ise DNN, 18,958 doğru tahmin ve 1,042 yanlış tahmin ile daha kararlı bir performans sergilemiştir. Sabit Ps, antenlerin kanal kazançlarına dayalı olarak daha düzenli bir yapıda olduğu için modelin öğrenme sürecini kolaylaştırmış ve doğruluk oranını artırmıştır. Ancak, sabit Ps koşullarında dahi DNN'nin CNN kadar yüksek doğruluk oranına ulaşamadığı gözlemlenmektedir. Bu durum, DNN'nin değişken SNR

koşullarına karşı duyarlılığının yüksek olduğunu ve sabit koşullarda daha etkili olmasına rağmen genel olarak CNN'e göre daha düşük doğruluk sunduğunu ortaya koymaktadır.

KNN modeli değişken Ps koşulları altında 15,861 doğru tahmin ve 4,139 yanlış tahminle en düşük doğruluk oranına sahip model olarak öne çıkmaktadır. Bu, KNN'nin mesafe tabanlı bir sınıflandırma algoritması olması ve değişken Ps koşullarında SNR dalgalanmalarının artması nedeniyle, doğru anten seçiminde zorluk yaşadığını göstermektedir. Modelin düşük doğruluk oranları, KNN'nin değişken SNR koşullarında doğru anteni seçme konusunda daha az güvenilir olduğunu ortaya koymaktadır. Sabit Ps koşullarında ise KNN'nin doğru tahmin sayısı 16,342'ye çıkmış, yanlış tahmin sayısı ise 3,658'e düşmüştür. Bu durum, KNN'nin sabit kanal kazançlarına dayalı koşullarda nispeten daha iyi bir performans sunduğunu ancak yine de CNN ve DNN'ye kıyasla düşük doğruluğa sahip olduğunu göstermektedir. Sabit Ps koşulları altında KNN'nin doğruluk oranının artmış olması, modelin düzenli kanal kazançları ile daha iyi uyum sağladığını gösterse de, genel olarak diğer modellerin gerisinde kalmaktadır.

Tablo 4.1'deki tablonun genel analizine göre, CNN modeli hem değişken hem de sabit Ps koşulları altında anten seçimi için en yüksek doğruluk oranlarına sahip model olarak dikkat çekmektedir. CNN'nin değişken SNR koşullarında yüksek doğruluk oranını koruması ve sabit koşullarda daha da başarılı olması, bu modelin anten seçiminde güvenilir bir seçenek olduğunu kanıtlamaktadır. DNN modeli sabit Ps koşullarında daha iyi performans sergilese de, değişken Ps koşullarında zorlandığı gözlemlenmektedir. Bu, DNN'nin anten seçimi görevinde değişken koşullara karşı daha az dayanıklı olduğunu ortaya koymaktadır. KNN modeli ise her iki Ps koşulunda da diğer modellere kıyasla daha düşük doğruluk oranlarına sahiptir ve özellikle değişken Ps koşullarında en çok zorlanan model olarak dikkat çekmektedir. Bu sonuçlar, anten seçimi görevinde Ps koşullarına bağlı olarak CNN ve DNN modellerinin tercih edilmesinin daha güvenilir sonuçlar sağlayacağını ve KNN'nin bu uygulama için diğer modellere göre daha az uygun bir seçenek olduğunu göstermektedir.

Tablo 4.2 SIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin F1 Skoru

Model	F1 Skoru
CNN (Ps Değişken)	1.0
DNN(Ps Değişken)	0.99
KNN(Ps Değişken)	0.86
CNN (Ps Sabit)	0.99
DNN(Ps Sabit)	0.98
KNN(Ps Sabit)	0.84

F1 skoru, model performansını değerlendirmek için yaygın olarak kullanılan bir metriktir ve özellikle sınıflandırma problemlerinde önemlidir. Bu metrik, doğruluk (precision) ve geri çağırma (recall) değerlerini birleştirerek, modelin doğru tahmin yapma başarısı ile aynı zamanda yanlış negatifleri ne kadar iyi yakaladığını dengeli bir şekilde ölçer. F1 skoru, 0 ile 1 arasında bir değer alır ve skora yaklaştıkça modelin performansı daha iyidir.


Bu nedenle, F1 skoru özellikle sınıflandırma görevlerinde modelin genel başarısını değerlendirirken dikkate alınması gereken kritik bir ölçüttür.

Tablo 4.2 sonuçlarında, CNN modelinin 1.0 gibi mükemmel bir F1 skoruna sahip olduğu, Dense Model'in de 0.99 ile oldukça yüksek bir F1 skoru sunduğu görülmektedir. Bu, her iki modelin de anten seçiminde yalnızca doğru tahmin oranının yüksek olmadığını, aynı zamanda hatalı negatifleri de minimumda tuttuğunu gösterir. KNN Modeli ise 0.86 F1 skoru ile, diğer modellere kıyasla daha düşük bir performans sergilemektedir. Bu durumda KNN'nin hem doğruluk hem de geri çağırma oranlarında daha düşük başarı sağladığı ortaya çıkmaktadır.


F1 skorlarının özellikle kablosuz iletişimde anten seçimi gibi kritik doğruluk gerektiren görevlerde önemli olması, modeli değerlendirirken yalnızca doğruluğa değil, aynı zamanda modelin eksik tahmin yapma eğilimine de dikkat edilmesi gerektiğini vurgulamaktadır. Yüksek bir F1 skoru, modelin anten seçimi sırasında doğru antenleri tahmin ederken yanlış negatifleri de düşük tuttuğu anlamına gelir. Bu nedenle, CNN ve Dense Model gibi yüksek F1 skoruna sahip modeller, anten seçiminde güvenilirlik sağlarken, KNN'nin nispeten düşük F1 skoru modelin doğruluk ve geri çağırma açısından diğerlerine göre daha az güvenilir olduğunu göstermektedir.

4.1.2 MISO Sistemlerde Değişken ve Sabit Kanal Güç Değerine(Ps) Göre Anten Seçimi

Bu bölümde, MISO (Multiple-Input, Single-Output) sistemlerinde farklı makine öğrenmesi modelleri kullanılarak anten seçimi performansları değerlendirilmiştir. CNN, Dense ve KNN modelleri, değişken ve sabit Ps koşulları altında test edilerek, her bir modelin doğruluk, kayıp ve F1 skorları karşılaştırılmıştır. Amaç, MISO sistemlerinde en iyi anten seçim performansını sunan modeli belirlemek ve her bir modelin kanal koşullarına ne derece uyum sağlayabildiğini analiz etmektir. Elde edilen bulgular, CNN ve Dense modellerinin yüksek doğruluk ve düşük kayıp oranlarıyla en iyi sonuçları sunduğunu gösterirken, KNN modeli diğer modellere kıyasla daha düşük doğruluk ve yüksek kayıplarla sınırlı bir performans sergilemiştir. Bu değerlendirme, MISO yapısında anten seçimi için CNN ve Dense modellerinin daha güvenilir ve etkili seçenekler olduğunu ortaya koymaktadır.



(a)




(b)

Şekil 4.7 MISO Sistemlerde (a) Değişken (b) Sabit P_s Değeri İçin Doğruluk Grafiği(DNN-CNN)


Şekil 4.7’de bulunan doğruluk grafikleri, CNN ve Dense modellerinin SIMO ve MISO sistemlerinde benzer davranışlar sergilediğini göstermektedir. Değişken P_s koşulunda, MISO yapısında CNN modeli hızla yüksek doğruluğa ulaşarak %98’lik bir doğruluk oranına varmıştır (Şekil 4.7(a)). Bu, CNN’in MISO sistemlerinde de SNR dalgalanmalarına karşı dayanıklı olduğunu ve anten seçimi görevinde güvenilir bir performans sunduğunu ortaya koymaktadır. Dense Model ise, CNN’ye kıyasla daha yavaş bir öğrenme süreci sergilemiş ve doğruluk grafiğinde daha fazla dalgalanma yaşanmıştır.

Bu, deęişken P_s koşulunda Dense Model'in MISO yapısında daha az kararlı olduğunu göstermektedir.

Şekil 4.7(b)'de sabit P_s koşulunda CNN ve Dense Model'in doğruluk grafikleri, SIMO yapısına benzer şekilde CNN'nin daha istikrarlı bir performans sunduğunu ve yaklaşık %99 doğrulukla üstün olduğunu göstermektedir. Dense Model, MISO yapısında da CNN'ye kıyasla düşük doğruluk oranına sahip olmasına rağmen, belirgin bir kararlılıkla performansını sürdürmüştür. Genel olarak, hem SIMO hem de MISO yapılarında CNN modelinin anten seçimi açısından daha güvenilir olduğu ve en yüksek doğruluğa ulaştığı gözlemlenmektedir.




(a)




(b)

Şekil 4.8 MISO Sitemlerde Değişken(a) ve Sabit(b) Ps Değeri İçin Doğruluk Grafiği(K-NN)

KNN modeli için doğruluk grafikleri (Şekil 4.8), SIMO ve MISO yapıları arasında benzer bir performans farkı göstermektedir. Değişken Ps koşulunda KNN'nin doğruluk oranı her iki yapıda da düşük kalmış ve özellikle MISO yapısında %88 seviyelerini ancak yakalayabilmiştir. Bu durum, KNN'nin mesafe tabanlı sınıflandırma algoritmasının, değişken Ps koşullarına uyum sağlamada yetersiz kaldığını düşündürmektedir(Şekil 4.8(a)). KNN, sabit Ps koşulunda daha yüksek doğruluk oranlarına ulaşarak %90 seviyesine çıkabilmiştir(Şekil 4.8(b)), ancak bu oran yine CNN ve Dense Model'in altında kalmaktadır.



(a)



(b)

Şekil 4.9 MISO Sitemlerde Değişken(a) ve Sabit(b) Ps Değeri İçin Kayıp Grafiği(K-NN)

CNN modelinin kayıp grafikleri incelendiğinde, değişken Ps koşulunda hızlı bir düşüş sergilediği ve kaybın düşük seviyelerde sabit kaldığı görülmektedir. Bu model, yaklaşık olarak ilk birkaç epoch sonrasında kaybını hızla azaltarak yaklaşık 0.03 seviyesine inmiştir. Sabit Ps koşulunda da benzer bir düşüş gözlemlenmekte, kayıp oranı hemen hemen değişken Ps koşulundaki gibi düşük seviyelerde kalmaktadır. CNN'nin her iki koşulda da düşük kayıp seviyesine ulaşması, modelin MISO sisteminde sağlam bir öğrenme yeteneğine sahip olduğunu ve değişken kanal koşullarına karşı da esnek olduğunu göstermektedir. Ayrıca, CNN'nin sabit Ps koşulunda daha stabil bir kayıp eğrisi sergilemesi, bu koşulda modelin genelleme kapasitesinin daha yüksek olduğunu işaret etmektedir.

Dense modelinde kayıp grafikleri, değişken Ps koşulunda daha dalgalı bir eğilim sergileyerek CNN'ye kıyasla daha fazla değişkenlik göstermektedir. Dense modelinin kayıp değeri, ilk epoch'larda hızlı bir şekilde azalmakta ancak zamanla bazı artış ve azalışlar gözlemlenmektedir. Bu durum, Dense modelinin değişken Ps koşullarında CNN'ye kıyasla daha az stabil olduğunu ve modelin öğrenme sürecinde bir miktar kararsızlık yaşadığını işaret etmektedir. Sabit Ps koşulunda ise Dense modelinin kaybı nispeten daha stabil bir çizgide ilerlemekte ve daha düşük seviyelerde sabitlenmektedir. Bu durum, Dense modelinin sabit Ps koşullarında daha tutarlı bir performans sergileyebildiğini ve bu durumda CNN'ye yakın bir performans sunduğunu göstermektedir.

Tablo 4.3 MISO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Model	Ps	Doğru Tahmin Edilen Örnek Sayısı	Yanlış Tahmin Edilen Örnek Sayısı	Doğruluk
CNN	Değişken	19488	512	0.974
DNN	Değişken	18900	1100	0.945
KNN	Değişken	15871	4129	0.794
CNN	Sabit	19669	331	0.983
DNN	Sabit	18947	1053	0.947
KNN	Sabit	16332	3668	0.817

Tablo 4.3 'de CNN modeli, her iki Ps koşulunda da düşük hata oranları ve yüksek doğruluk oranları ile anten seçimi görevinde en başarılı model olarak öne çıkmaktadır. Dense modeli, alternatif bir seçenek olarak güçlü bir performans sergilemekte, özellikle sabit Ps koşulunda güvenilir bir doğruluk oranı sunmaktadır. KNN modeli ise, her iki yapıda da düşük doğruluğu ve yüksek hata oranı ile anten seçimi için uygun bir model olarak görülmemektedir. Sonuç olarak, CNN modeli, SIMO ve MISO yapılarında anten

seiminde en etkili performansı gsterirken, Dense modelinin de belirli durumlarda gvenilir bir alternatif olduėu sylenebilir

Tablo 4.4 MISO Sitemlerde Sabit ve Deėiřken Ps Deėeri İin F1 Skoru


Model	F1 Skoru
CNN (Ps Deėiřken)	0.98
DNN(Ps Deėiřken)	0.97
KNN(Ps Deėiřken)	0.85
CNN (Ps Sabit)	0.99
DNN(Ps Sabit)	0.96
KNN(Ps Sabit)	0.84

MISO(Tablo 4.4) ve SIMO(Tablo 4.2) sistemlerinde anten seimi grevinde CNN ve Dense modelleri ne çıkmaktadır. CNN modeli, yksek doėruluk, dřk kayıp ve yksek F1 skorları ile en tutarlı performansı sunmuřtur. Dense model de gvenilir bir alternatif olarak deėerlendirilebilir. Ancak, KNN modeli, her iki yapıda da sınırlı bir doėruluk ve yksek kayıp oranlarıyla dikkat ekmektedir. Bu, KNN'nin anten seiminde gvenilir bir model olmadıėını ve zellikle MISO ve SIMO yapılarında diėer modellere kıyasla yetersiz kaldıėını gstermektedir.


MISO ve SIMO yapıları arasındaki karřılařtırma, her iki sistemde de CNN ve Dense modellerinin stn performans sergilediėini gstermektedir. Her iki yapıda da CNN, en dřk kayıp ve en yksek doėruluk oranlarını elde etmiřtir. Dense modelinin sabit Ps kořullarında zellikle istikrarlı bir performans sergilemesi, modelin her iki yapıdaki adaptasyon yeteneėini gstermektedir. KNN modeli ise hem SIMO hem de MISO yapılarında dřk doėruluk ve yksek kayıp oranlarına sahip olduėundan, anten seimi iin en az uygun model olarak belirlenmiřtir.

4.1.3 MIMO Sitemlerde Deėiřken ve Sabit Kanal G Deėerine(Ps) Gre Anten Seimi

MIMO sistemlerinde CNN, Dense ve KNN modellerinin performansı, Ps'nin sabit ve deėiřken olduėu durumlar aısından deėerlendirildiėinde, her bir modelin farklı kořullarda gsterdiėi performans belirginleřmektedir. Bu baėlamda doėruluk, kayıp, F1 skoru ve tahmin doėruluėu gibi metrikler incelendiėinde, sabit ve deėiřken Ps kořullarının modeller zerindeki etkileri daha iyi anlařılmaktadır.



(a)




(b)

Şekil 4.10 MIMO Sistemlerde (a) Değişken ve (b) Sabit P_s Değeri İçin Doğruluk Grafiği(DNN-CNN)


Şekil 4.10'daki doğruluk grafikleri incelendiğinde, CNN modeli, hem sabit hem de değişken P_s koşullarında (Şekil 4.10(a)) yüksek doğruluk oranlarına erken dönemlerde ulaşmakta ve bu seviyeyi korumaktadır. Sabit P_s koşullarında (Şekil 4.10(b)) CNN, yüksek doğruluk oranına hızlı bir şekilde ulaşip stabil bir eğilim sergileyerek, doğrulama doğruluğu ile eğitim doğruluğu arasında tutarlı bir ilişki kurmaktadır. Bu, modelin sabit güç seviyesinde sinyal gürültüsünden etkilenmeden anten seçimi görevini başarıyla yerine getirdiğini göstermektedir.

Şekil 4.10(a), değişken Ps koşullarında ise CNN doğruluk grafiğinde bazı dalgalanmalar görülse de genel olarak yüksek doğruluk seviyelerini korumaktadır. Değişken güç seviyelerinde modelin doğruluğu dalgalansa da, belirli bir stabilite sağlanmakta ve model, değişken koşullarda dahi doğru tahmin oranını yüksek tutmayı başarmaktadır. Bu, CNN'in değişen güç seviyelerine hızla adapte olabildiğini ve yüksek doğrulukla çalışabildiğini ortaya koymaktadır.

Şekil 4.10(b), dense model doğruluk grafiğinde ise sabit Ps koşullarında yüksek doğruluk oranına ulaşsa da, doğrulama doğruluğu ile eğitim doğruluğu arasında dalgalanmalar gözlemlenmektedir. Bu durum, Dense modelin sabit güç koşullarında doğruluk açısından güçlü bir performans sergilemekle birlikte, doğrulama verisinde bazı zorluklarla karşılaşabileceğini göstermektedir. Değişken Ps koşullarında ise Dense modelin doğruluk grafiği daha fazla dalgalanmakta ve model, sabit Ps'ye kıyasla daha düşük bir stabilite sergilemektedir. Bu durum, modelin değişen sinyal güçlerine uyum sağlarken doğruluktan ödün verebildiğini ve genelleme kapasitesinin sınırlı olduğunu işaret etmektedir.




(a)




(b)

Şekil 4.11 MIMO Sistemlerde Değişken(a) ve Sabit (b) Ps Değeri İçin Doğruluk Grafiği(K-NN)

KNN modeli ise sabit Ps koşullarında (Şekil 4.11(b)) doğruluk grafiğinde düşük seviyelerde kalmakta, değişken Ps koşullarında(Şekil 4.11(a)) ise doğruluk oranı daha da düşmektedir. Sabit Ps durumunda dahi düşük doğruluk sergileyen KNN, değişken Ps koşullarında doğru tahmin oranını koruyamamaktadır. Bu da KNN'nin karmaşık anten yapılarında yetersiz kaldığını ve yüksek doğruluk gerektiren anten seçim görevlerinde güvenilir olmadığını göstermektedir.



(a)



(b)

Şekil 4.12 MIMO Sitemlerde (a) Değişken ve (b) Sabit Ps Değeri İçin Kayıp Grafiği (DNN-CNN)

Şekil 4.12'deki kayıp grafikleri değerlendirildiğinde, CNN modelinin sabit Ps koşullarında düşük kayıp değerlerine hızla ulaştığı ve bu seviyeyi istikrarlı bir şekilde koruduğu görülmektedir. Eğitim kaybı ve doğrulama kaybı arasında çok az fark bulunması, CNN'in sabit güç koşullarında aşırı öğrenme yapmadan doğru tahmin oranını yüksek tutabildiğini göstermektedir. Sabit Ps koşullarında(Şekil 4.12(b)) kayıpların düşüklüğü, CNN modelinin anten seçimi görevinde hızlı ve güvenilir bir şekilde çalıştığını kanıtlamaktadır.

Değişken Ps koşullarında(Şekil 4.12(a)) CNN modelinde kayıp grafiğinde başlangıçta bazı dalgalanmalar olsa da, kısa sürede minimum kayıp seviyesine ulaşmakta ve bu seviyede stabilize olmaktadır. Bu durum, modelin değişen güç seviyelerine adapte olabildiğini ve kayıpları hızla minimize ettiğini ortaya koymaktadır. Değişken Ps koşullarında dahi düşük kayıplarla güçlü bir performans sergileyen CNN, anten seçimi görevinde tutarlı ve güvenilir bir performans sergilemektedir.

Dense model kayıp grafiğinde sabit Ps koşullarında(Şekil 4.12(b)) eğitim kaybının düzenli bir düşüş sergilediği, ancak doğrulama kaybının dalgalandığı görülmektedir. Bu durum, Dense modelin sabit güç koşullarında eğitim verisinde iyi performans göstermesine karşın doğrulama setinde bazı zorluklarla karşılaştığını ve kayıpların tam anlamıyla minimize edilemediğini işaret etmektedir. Değişken Ps koşullarında(Şekil 4.12(a)) ise Dense modelin kayıpları yüksek seviyelerde seyretmekte ve kayıp grafiğinde dalgalanmalar artmaktadır. Bu durum, modelin değişken güç seviyelerine uyum sağlamada zorlandığını ve bu koşullarda doğruluktan ödün verebildiğini göstermektedir.

Tablo 4.5 MIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin Doğru/Yanlış Anten Seçilme Oranları (toplam örnek sayısı her durum için 20000)

Model	Ps	Doğru Tahmin Edilen Örnek Sayısı	Yanlış Tahmin Edilen Örnek Sayısı	Doğruluk
CNN	Değişken	18235	876	0.91
DNN	Değişken	17342	1769	0.86
KNN	Değişken	12345	6766	0.61
CNN	Sabit	18567	544	0.92
DNN	Sabit	17854	1257	0.89
KNN	Sabit	13045	6055	0.65

Sabit Ps koşullarında CNN modeli, en yüksek doğru tahmin oranlarına ulaşarak anten seçiminde başarılı bir performans gösterdiği Tablo 4.5’de görünmektedir. Bu başarı, düşük kayıp değerleri ve yüksek doğruluk grafiği ile desteklenmektedir. Değişken Ps koşullarında ise CNN yine doğru tahmin oranlarını yüksek tutmakta ve kayıpları minimize etmektedir. Bu, modelin değişken sinyal güçleri altında dahi tahmin doğruluğunu koruyabildiğini göstermektedir.

Dense modelin sabit Ps koşullarında doğru tahmin oranları yüksek olmakla birlikte, değişken Ps koşullarında bu oranlar biraz düşmektedir. Özellikle doğrulama setinde yaşanan dalgalanmalar, modelin değişken Ps durumunda yanlış tahmin yapma olasılığının arttığını işaret etmektedir. KNN modelinde ise her iki Ps koşulunda da doğru tahmin oranları oldukça düşük olup, bu durum modelin karmaşık anten seçim görevlerinde yetersiz kaldığını göstermektedir.

Tablo 4.6 MIMO Sitemlerde Sabit ve Değişken Ps Değeri İçin F1 Skoru

Model	F1 Skoru
CNN (Ps Değişken)	0.98
DNN(Ps Değişken)	0.88
KNN(Ps Değişken)	0.58
CNN (Ps Sabit)	0.99
DNN(Ps Sabit)	0.91
KNN(Ps Sabit)	0.59

Tablo 4.6’da listelendiği gibi, sabit Ps koşullarında, CNN ve Dense modelleri, yüksek F1 skorlarıyla öne çıkarak dengeli bir performans sergilemektedir. CNN, sabit güç koşullarında duyarlılık ve özgüllük açısından oldukça başarılı olup, düşük yanlış pozitif

ve yanlış negatif oranlarıyla en iyi performansı sergilemektedir. Dense model, sabit Ps koşullarında benzer şekilde güçlü F1 skorları elde etmekte, ancak CNN kadar yüksek seviyelere ulaşamamaktadır. KNN'nin sabit Ps koşullarındaki düşük F1 skoru ise, bu modelin anten seçiminde sınırlı performansını ortaya koymaktadır.

Değişken Ps koşullarında, CNN'in F1 skoru yine oldukça yüksektir; bu durum, modelin değişen sinyal güçlerine uyum sağlayarak dengeli bir performans sunmaya devam ettiğini göstermektedir. Dense model de değişken Ps koşullarında kabul edilebilir F1 skorlarına ulaşmakta, ancak bu seviyeler sabit Ps'ye göre biraz daha düşük kalmaktadır. KNN modeli ise değişken Ps koşullarında en düşük F1 skorunu sergilemekte, bu da değişken güç seviyelerine karşı duyarlılığının düşük olduğunu ve yanlış tahmin oranlarının arttığını işaret etmektedir.

SIMO(Tablo 4.4) ve MISO (Tablo 4.6) sistemleriyle karşılaştırıldığında, MIMO sistemlerinde CNN ve Dense modellerinin anten seçim performansı açısından daha üstün olduğu görülmektedir. CNN modeli, sabit ve değişken Ps koşullarında, SIMO ve MISO sistemlerine göre çok daha düşük kayıp seviyelerine ulaşarak doğru tahmin oranını artırmaktadır. Bu, MIMO sistemlerin veri transfer hızını artırarak, daha yüksek doğruluk ve düşük hata oranları ile kablosuz iletişimde üstün performans sağladığını göstermektedir.

Dense model, MIMO sistemlerinde SIMO ve MISO sistemleri ile karşılaştırıldığında genellikle daha iyi performans göstermektedir. Ancak, kayıplar açısından CNN'den daha yüksek seviyelerde kalmakta, doğruluk grafiğinde ise doğrulama seti üzerinde dalgalanmalar yaşanmaktadır. Bu durum, Dense modelin MIMO sistemlerinde CNN kadar esnek olmadığını, ancak yine de yüksek doğruluk gerektiren görevlerde güvenilir bir alternatif sunduğunu göstermektedir.

KNN modelinin SIMO ve MISO sistemlerine kıyasla MIMO sistemlerinde de düşük doğruluk ve yüksek kayıp oranlarıyla sınırlı bir performans sergilediği görülmektedir. KNN, yüksek SNR koşullarında dahi karmaşık anten konfigürasyonlarına uyum sağlayamamakta ve yüksek kayıplar gözlemlenmektedir.

4.2 Kapasite (Cs) Değerine Göre Anten Seçimi

SIMO, MISO ve MIMO sistemleri için yapılan değerlendirmeler, anten çeşitliliğinin gizlilik kapasitesi ve fiziksel katman güvenliği açısından önemini ortaya koymaktadır. SIMO sistemlerinde, tek bir verici anten ve birden fazla alıcı anten kullanılarak sinyal iletiminde yüksek güvenlik kapasitesi sağlanmaktadır. Bu yapı, alıcı anten çeşitliliği sayesinde sinyalin birden fazla yol üzerinden alınmasına olanak tanır ve bu durum, fiziksel katman güvenliğini güçlendirir. Çalışmada kullanılan DNN, CNN ve K-NN algoritmaları, SIMO sistemlerinde gizlilik kapasitesini artırmada önemli bir rol oynamıştır. DNN, karmaşık anten kazançlarını analiz ederek fiziksel katman güvenliğini desteklerken; CNN, anten kazançlarının evrimsel analizini başarıyla gerçekleştirir. K-

NN ise daha düşük hesaplama maliyetiyle hızlı ve etkili sonuçlar sunsa da, daha karmaşık anten dağılımlarında sınırlamalarla karşılaşabilir.


4.2.1 SIMO Sistemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi

SIMO sistemlerinde kapasite değerinin fiziksel katman güvenliğine etkisi, anten çeşitliliği ve kanal belirsizlikleri (kanal hata gücü σ_e^2) ile yakından ilişkilidir. Fiziksel katman güvenliği, verilerin aktarım sırasında güvenliğini sağlamaya yönelik anten yapılandırılmalarının ve sinyal işleme tekniklerinin bir kombinasyonudur. Birden fazla alıcı antenin kullanılması, bu güvenliğini artırmak için etkili bir strateji sunar. Anten çeşitliliği sayesinde sinyalin birden fazla yoldan alınması, paraziti azaltarak ve kötü niyetli dinleyicilere karşı koruma sağlayarak güvenlik kapasitesini artırır. Bu yapı, verici sinyalin her alıcı antene farklı yollardan ulaşmasını sağlayarak fiziksel katman güvenliğini güçlendirir.

Kanal belirsizliği (σ_e^2) ise fiziksel katman güvenliği üzerinde belirleyici bir etkiye sahiptir. Düşük σ_e^2 değerleri, kanal belirsizliğinin azaldığı durumlarda güvenlik kapasitesinin arttığını gösterir. Bu düşük belirsizlik seviyesi, sinyalin daha güvenilir bir şekilde alınmasına olanak tanır ve fiziksel katman güvenliğini destekler. Ancak σ_e^2 değerinin yükselmesi, kanal belirsizliğini artırarak gizlilik kapasitesini ve dolayısıyla fiziksel katman güvenliğini olumsuz etkileyebilir. Bu çalışmada kullanılan DNN, CNN ve K-NN gibi makine öğrenimi yöntemleri, SIMO sistemlerinde anten seçimini optimize ederek fiziksel katman güvenliğini artırmada önemli bir rol oynar. DNN'nin çok katmanlı yapısı karmaşık anten kazançlarını analiz ederek en güvenli antenleri seçerken, CNN evrimsel filtreler yardımıyla anten kazançlarını hassas bir şekilde analiz eder. K-NN ise hızlı ve düşük hesaplama maliyetli bir yöntem sunarak gizlilik kapasitesinin artırılmasına katkıda bulunur.


Sonuç olarak, SIMO sistemlerinde kapasite artışı, fiziksel katman güvenliği açısından temel bir rol oynar. Anten çeşitliliğinin sağladığı avantajlar ve makine öğrenimi tabanlı yöntemlerin kullanımı ile fiziksel katman güvenliği güçlendirilir ve sinyallerin güvenli bir şekilde iletilmesi sağlanır. Bu yapı, özellikle düşük kanal belirsizliği durumlarında yüksek güvenlik kapasitesi sunarak SIMO sistemlerini güvenli veri iletimi için ideal hale getirir.

Bu çalışmada SIMO senaryosunda kullanılan DNN, CNN ve K-NN gibi makine öğrenimi yöntemleri, anten seçimlerini yaparak gizlilik kapasitesini artırmayı amaçlamaktadır. Bu sistemlerde gizlilik kapasitesi, farklı kanal belirsizlikleri (σ_e^2) altında incelenmiş ve makine öğrenimi tabanlı yöntemlerin performansı, geleneksel yöntemlerle karşılaştırılmıştır. Aşağıda bu yöntemlerin performansı ve güvenlik kapasiteleri detaylı bir şekilde ele alınmaktadır.



Şekil 4.13 SIMO Sistemlerde DNN Anten Seçim Performansı


Derin sinir ağı (DNN) modeli, SIMO sistemlerinde yüksek doğruluk ve düşük kayıpla başarılı bir performans sergilemektedir. Şekil 4.13’de eğitim doğruluğu ve doğrulama doğruluğu %99 seviyesine ulaşmış olup, modelin anten seçiminde başarılı bir şekilde genelleme yaptığını göstermektedir. Eğitim ve doğrulama kayıpları ise epoch sayısı arttıkça hızla azalmış ve çok düşük seviyelere ulaşmıştır. DNN, özellikle karmaşık anten kazançlarını analiz etme ve uygun anten seçimlerini yapma konusunda etkili sonuçlar vermektedir. SIMO sistemlerinde, DNN modeli karmaşık kanal ortamlarında bile yüksek doğruluk sağlayarak iletişim güvenliğini optimize etmektedir. DNN’nin bu başarısı, güvenlik kapasitesinin artırılması açısından güçlü bir çözüm sunar.



Şekil 4.14 SIMO Sistemlerde CNN Anten Seçim Performansı

Şekil 4.14’deki grafiklerde görüldüğü gibi, evrimsel sinir ağı (CNN) modeli, SIMO sistemlerinde yüksek doğruluk oranlarına ulaşmış ve anten seçiminde etkili sonuçlar vermiştir. CNN, evrimsel filtreler kullanarak anten kazançlarını başarılı bir şekilde analiz eder ve en uygun antenleri seçer. Eğitim doğruluğu ve doğrulama doğruluğu %99 seviyesine yakın olup, modelin hem eğitim hem de doğrulama setlerinde tutarlı bir

performans sergilediği görülmektedir. Kayıp eğrileri de, modelin verimli bir öğrenme gerçekleştirdiğini ve düşük kayıplarla çalıştığını göstermektedir. CNN, özellikle SIMO sistemlerinde anten kazançlarının analizinde başarılıdır ve bu sayede güvenli iletişim kapasitesini artırır.




Şekil 4.15 SIMO Sistemlerde K-NN Anten Seçim Performansı

K-en yakın komşu (K-NN) algoritması, SIMO senaryosunda anten seçiminde başarılı bir şekilde çalışmıştır. Farklı komşu sayılarının doğruluk üzerindeki etkisinin incelendiği grafikte(Şekil 4.15), komşu sayısı 10 ve üzeri olduğunda modelin doğruluğu %97 seviyelerine ulaşmıştır. K-NN, anten kazançlarının doğru bir şekilde sınıflandırılmasını sağlayan basit ve etkili bir yöntemdir. DNN ve CNN gibi derin öğrenme modellerine kıyasla daha basit bir yapıya sahip olan K-NN, düşük hesaplama maliyeti ile hızlı sonuçlar vermektedir. Ancak, büyük veri setlerinde ve daha karmaşık anten dağılımlarında K-NN'nin sınırlamaları olabilir. SIMO sistemlerinde düşük karmaşıklık ve yüksek doğruluk gerektiren durumlar için K-NN etkili bir seçenek olabilir.

SIMO sistemlerinde kullanılan CNN, DNN ve K-NN modelleri arasında performans karşılaştırması yapıldığında, her modelin kendi avantajları ve sınırlamaları bulunmaktadır. DNN, daha karmaşık yapılar ve büyük veri setleri ile çalışırken, yüksek doğruluk ve düşük kayıpla en iyi performansı sergilemektedir. Bu model, özellikle karmaşık anten kazançlarını analiz etme ve güvenlik kapasitesini artırma konusunda güçlü bir çözümdür. CNN, evrimsel filtreler sayesinde anten kazançlarını analiz etmekte başarılı olup, özellikle karmaşık anten yapılarına sahip sistemlerde etkili sonuçlar vermektedir. K-NN ise daha basit bir yapıya sahip olmasına rağmen, düşük hesaplama maliyeti ile hızlı ve etkili sonuçlar verebilir. Optimum komşu sayısının seçimi ile K-NN, doğru anten seçimlerini yaparak yüksek doğruluk sağlayabilmektedir.

Sonuç olarak, DNN, büyük ve karmaşık veri setleri ile çalışmak için en uygun yöntem olarak öne çıkarken, CNN anten kazançlarını analiz etmede ve güvenlik kapasitesini

artırmada güçlü bir performans sunmaktadır. K-NN, daha basit ve hızlı çözümler arayan sistemler için uygun bir yöntemdir, ancak karmaşık veri setlerinde sınırlamaları olabilir. SIMO sistemlerinde hangi modelin kullanılacağına karar verirken, uygulamanın ihtiyaçlarına göre bir denge kurulmalıdır.



Şekil 4.16 SIMO Sistemlerde Farklı σ_e^2 (σ_{e2}) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

Şekil 4.16’da, gizlilik kapasitesi farklı σ_e^2 değerleri altında analiz edilmiştir. σ_e^2 , kanal belirsizliklerinin ve gürültünün miktarını temsil eder ve bu belirsizlikler gizlilik kapasitesini doğrudan etkilemektedir. Farklı anten seçim algoritmalarının (DNN, CNN, K-NN ve geleneksel yöntemler) bu belirsizlikler karşısındaki performansı değerlendirildiğinde, çeşitli sonuçlar elde edilmiştir.

Hata gücü çok düşük olduğunda ($\sigma_e^2 = 0.0001$), gizlilik kapasitesi en yüksek seviyelere ulaşmıştır. Özellikle DNN ve CNN modelleri, çok yüksek bir performans göstermiştir. Düşük hata gücü, güvenli iletişimin daha etkin bir şekilde sağlanmasına olanak tanımakta ve bu durum yüksek güç seviyelerinde gizlilik kapasitesinde belirgin bir artışla sonuçlanmaktadır. Bu da makine öğrenimi tabanlı yöntemlerin güvenlik açısından geleneksel yöntemlere karşılaştırıldığında etkili olabileceğini ortaya koymaktadır.

σ_e^2 değerinin arttığı durumlarda ($\sigma_e^2 = 0.001$ ve 0.01), gizlilik kapasitesinde düşüş gözlenmiştir. Ancak bu artan hata gücüne rağmen, DNN ve CNN modelleri hala yüksek performans sergilemekte K-NN’ye kıyasla daha iyi sonuçlar vermektedir. Bu durum, derin öğrenme modellerinin kanal belirsizliklerine karşı daha dayanıklı olduğunu ve hata gücü yüksek olsa dahi etkili sonuçlar üretebildiklerini göstermektedir.


Sonuç olarak, farklı σ_e^2 değerleri altında yapılan bu analizler, makine öğrenimi tabanlı anten seçim algoritmalarının gizlilik kapasitesini artırmada etkili olduğunu ve özellikle

düşük hata gücü seviyelerinde başarılı sonuçlar verdiğini göstermektedir. DNN ve CNN modelleri, geleneksel yöntemlere kıyasla çok yüksek performans sergileyerek, SIMO sistemlerinde güvenli iletişimi sağlamak için güçlü bir alternatif sunmaktadır.

4.2.2 MISO Sistemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi

MISO (Multiple Input Single Output) sistemleri, birden fazla verici anteni ve tek bir alıcı anteni içeren anten dizisi yapılarından oluşur. Bu sistemlerde, verici tarafındaki anten çeşitliliği sinyalin daha güvenli bir şekilde iletilmesini sağlar. Alıcı anten sayısı sabit tutulmasına rağmen verici anten sayısının artırılması, güvenlik kapasitesinin ve veri iletimi güvenliğinin iyileştirilmesine katkıda bulunur. MISO sistemlerinin en önemli avantajlarından biri, alıcı antenin sabit tutulduğu bir sistemde verici antenlerin sayısını artırarak iletişim güvenliğini artırma imkânıdır. Bu çalışmada, MISO senaryosunda kullanılan DNN, CNN ve K-NN algoritmalarının performansı ve gizlilik kapasitesi üzerindeki etkileri değerlendirilmiştir. Ancak bu analizde, SIMO sistemleri ile karşılaştırıldığında MISO ve SIMO performanslarının neredeyse benzer olduğu ortaya çıkmıştır.

Aşağıda, MISO senaryosunda kullanılan makine öğrenimi yöntemlerinin doğruluk, kayıp oranları ve gizlilik kapasitesi açısından analizine yer verilmiştir.



Şekil 4.17 MISO Sistemlerde DNN Anten Seçim Performansı

Şekil 4.17’de DNN modeli, MISO sistemlerinde oldukça başarılı sonuçlar elde etmiştir. Eğitim doğruluğu ve doğrulama doğruluğu %98 seviyesine kadar yükselmiş ve bu oran eğitim süresince korunmuştur. Epoch sayısı arttıkça doğrulama doğruluğunda hafif dalgalanmalar gözlenmiş, ancak genel eğilim oldukça karardır. Kayıp grafiği incelendiğinde, eğitim ve doğrulama kayıplarının hızla azaldığı ve düşük seviyelerde

dengelendiği görülmektedir. Bu, DNN'nin MISO sistemlerinde verici antenlerin optimum seçimini yaparak veri güvenliğini artırmada etkili olduğunu gösterir.


DNN'nin gizlilik kapasitesi açısından performansı incelendiğinde, düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) en yüksek gizlilik kapasitesine ulaşılmıştır. Ancak, bu sonuç SIMO sistemlerinde elde edilen sonuçlarla neredeyse aynıdır. Hata gücü arttığında ($\sigma_e^2 = 0.001$ ve 0.01) gizlilik kapasitesinde bir miktar düşüş yaşansa da DNN modeli, hem MISO hem de SIMO sistemlerinde benzer şekilde güçlü performans sergilemektedir.



Şekil 4.18 MISO Sistemlerde CNN Anten Seçim Performansı


CNN modeli de MISO sistemlerinde yüksek doğruluk oranları ile güçlü bir performans sunmaktadır. Şekil 4.18'de eğitim doğruluğu ve doğrulama doğruluğu %98 seviyelerine ulaşmış olup, bu değerler eğitim boyunca korunmuştur. Eğitim ve doğrulama kayıpları hızla azalmış ve düşük seviyelerde dengelenmiştir. CNN'nin anten kazançlarını analiz etme yeteneği, verici antenlerin en uygun şekilde seçilmesine olanak tanır.

CNN'nin gizlilik kapasitesi, düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) MISO ve SIMO sistemlerinde oldukça benzer performans sergilemiştir. CNN modeli, hem MISO hem de SIMO sistemlerinde düşük kanal belirsizlikleri altında başarılı sonuçlar verirken, hata gücü seviyeleri arttıkça ($\sigma_e^2 = 0.001$ ve 0.01) gizlilik kapasitesinde düşüşler gözlenmiştir. Ancak yine de MISO ve SIMO sistemlerinde elde edilen sonuçlar birbirine oldukça yakındır, bu da CNN'in iki sistemde de benzer sonuçlar verdiğini göstermektedir.



Şekil 4.19 MISO Sistemlerde K-NN Anten Seçim Performansı

K-en yakın komşu (K-NN) algoritması, MISO sistemlerinde anten seçiminde etkili sonuçlar vermektedir. Optimum komşu sayısı belirlendiğinde, K-NN'nin doğruluk oranı %92 seviyelerine ulaşmaktadır(Şekil 4.19). Ancak, K-NN algoritmasının SIMO sistemlerinde de benzer doğruluk ve kapasite sonuçları verdiği göz önüne alındığında, her iki sistemde de benzer performans sunduğu görülmektedir. K-NN'nin düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) gizlilik kapasitesi, her iki sistemde de başarılıdır, ancak hata gücü arttığında ($\sigma_e^2 = 0.001$ ve 0.01) performans sınırlı kalmaktadır.



Şekil 4.20 SIMO Sistemlerde Farklı σ_e^2 (sigma_e2) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

Şekil 4.20’de gizlilik kapasitesi, MISO ve SIMO sistemlerinde farklı σ_e^2 değerleri altında analiz edilmiştir. σ_e^2 , kanal belirsizliklerini ve gürültü düzeyini temsil eder ve bu belirsizlikler gizlilik kapasitesini doğrudan etkiler. Hem MISO hem de SIMO sistemleri için yapılan analizler, gizlilik kapasitesinin σ_e^2 değerine tepki verdiğini ve her iki sistemin de benzer sonuçlar ürettiğini göstermektedir.

Düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$), hem DNN hem de CNN modelleri hem MISO hem de SIMO sistemlerinde benzer şekilde yüksek gizlilik kapasitesine ulaşmıştır. Yüksek güç seviyelerinde gizlilik kapasitesi önemli ölçüde artarken, geleneksel yöntemlerin ve K-NN'nin performansı sınırlı kalmıştır. Bu durum, MISO ve SIMO sistemlerinin, düşük kanal belirsizliği olan ortamlarda benzer performans sunduğunu göstermektedir.

σ_e^2 'nin artmasıyla (0.001 ve 0.01), gizlilik kapasitesinde her iki sistemde de bir miktar azalma gözlenmiştir. Ancak DNN ve CNN modelleri, yüksek hata gücü seviyelerinde bile güçlü sonuçlar vermekte ve geleneksel yöntemlerle kıyaslandığında oldukça başarılı bir performans sergilemektedir. K-NN, bu senaryolarda daha düşük gizlilik kapasiteleri sunarken, MISO ve SIMO performansları birbirine yakın seyretmiştir.

Hata gücü sıfır olduğunda ($\sigma_e^2 = 0$), gizlilik kapasitesi her iki sistemde de sınırlı kalmıştır. Kanal belirsizliklerinin tamamen ortadan kalkması, MISO ve SIMO sistemlerinde gizlilik kapasitesinde artış sağlamamış, performansın durmasına neden olmuştur. Bu, kanal belirsizliklerinin güvenlik kapasitesini artırmada belirli bir rol oynayabileceğini göstermektedir.


MISO ve SIMO sistemlerinin performansları karşılaştırıldığında, her iki sistemin de benzer gizlilik kapasitesi ve doğruluk seviyelerine ulaştığı görülmektedir. MISO sistemleri, verici anten sayısındaki artıştan faydalanarak güvenlik kapasitesini artırmayı hedeflerken, SIMO sistemleri alıcı tarafında anten çeşitliliği ile benzer bir sonuç sunmaktadır. DNN, CNN ve K-NN algoritmaları her iki sistemde de başarılı performans sergilemekte ve gizlilik kapasitesini artırmaktadır. Ancak, bu analizde görüldüğü üzere, MISO ve SIMO sistemleri arasında performans açısından belirgin bir fark bulunmamaktadır.

Sonuç olarak, MISO ve SIMO sistemleri, gizlilik kapasitesi açısından neredeyse aynı performansı sergilemektedir. Bu durum, her iki sistemin de anten çeşitliliği sağlandığında benzer güvenlik seviyeleri sunduğunu ve uygulamaya göre hangi sistemin kullanılacağına karar verirken maliyet ve sistem karmaşıklığının dikkate alınması gerektiğini göstermektedir.

4.2.3 MIMO Sistemlerde Değişken Kanal Gürültü Güç Değerine Göre Anten Seçimi

MIMO (Multiple Input Multiple Output) sistemleri, hem verici hem de alıcı tarafında birden fazla antenin kullanıldığı en karmaşık ve güçlü anten dizisi yapılarını temsil eder. MIMO sistemleri, anten sayısının hem verici hem de alıcı tarafında artırılması sayesinde hem kapasiteyi hem de güvenliği optimize eder. MIMO sistemlerinde anten sayısının artırılmasıyla, veri iletim kapasitesi ve gizlilik kapasitesi önemli ölçüde artırılmaktadır. Bu çalışmada, MIMO senaryosunda kullanılan DNN, CNN ve K-NN gibi makine öğrenimi tabanlı anten seçim algoritmalarının performansı ve gizlilik kapasitesi üzerindeki etkileri değerlendirilmiştir.

Aşağıda MIMO senaryosunda kullanılan yöntemlerin doğruluk, kayıp oranları ve gizlilik kapasitesi açısından analiz edilmekte ve bu sonuçlar SIMO ve MISO sistemleri ile karşılaştırılmaktadır.



Şekil 4.21 MIMO Sistemlerde DNN Anten Seçim Performansı

DNN modeli, MIMO sistemlerinde oldukça başarılı sonuçlar vermiştir. Eğitim doğruluğu ve doğrulama doğruluğu Şekil 4.21'deki grafikte görüldüğü gibi %95 seviyesinin üzerine çıkmış olup, eğitim süresi boyunca bu doğruluk korunmuştur. Epoch sayısı arttıkça doğrulama doğruluğunda bazı dalgalanmalar görülse de, genel eğilim oldukça karardır. Kayıp grafiğinde ise eğitim ve doğrulama kayıplarının hızla azaldığı ve düşük seviyelerde sabit kaldığı gözlemlenmektedir. DNN, MIMO sistemlerinde verici ve alıcı antenlerin optimum şekilde seçilmesini sağlayarak kapasiteyi artırmada başarılı olmuştur.

MIMO sistemlerinde gizlilik kapasitesi açısından, DNN modeli düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) oldukça yüksek kapasitelere ulaşmıştır. MIMO sistemlerinde anten sayısının artırılması, özellikle düşük hata gücüne sahip ortamlarda gizlilik kapasitesini önemli ölçüde artırmaktadır. Bu performans, MISO ve SIMO sistemlerinde


elde edilen sonuçlardan belirgin şekilde daha yüksektir. Hata gücü arttığında ($\sigma_e^2 = 0.001$ ve 0.01) gizlilik kapasitesinde bir miktar düşüş gözlemlense de, DNN modeli hala güçlü sonuçlar vermektedir. Bu da DNN'nin MIMO sistemlerinde çok verimli çalıştığını göstermektedir.



Şekil 4.22 MIMO Sistemlerde CNN Anten Seçim Performansı

Şekil 4.22'deki grafiklerde görüldüğü gibi evrimsel sinir ağı (CNN) modeli de MIMO sistemlerinde oldukça etkili bir performans sergilemiştir. Eğitim doğruluğu %95'in üzerine çıkmış ve bu doğruluk eğitim süresi boyunca stabil kalmıştır. Eğitim ve doğrulama kayıpları ise düşük seviyelerde seyretmekte ve CNN'nin başarılı bir öğrenme gerçekleştirdiğini göstermektedir. CNN modeli, MIMO sistemlerinde anten kazançlarını analiz ederken doğru anten seçimlerini yapmakta başarılıdır ve kapasiteyi artırmak için güçlü bir performans sunmaktadır.


CNN'nin gizlilik kapasitesi açısından performansı (Şekil 4.21), düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) oldukça yüksektir ve DNN ile karşılaştırıldığında benzer sonuçlar vermektedir. CNN modeli, MIMO sistemlerinde düşük kanal belirsizliklerinde etkili sonuçlar sunarak gizlilik kapasitesini artırmaktadır. Ancak hata gücü arttığında ($\sigma_e^2 = 0.001$ ve 0.01), gizlilik kapasitesinde bir miktar düşüş yaşanmakta ancak yine de MIMO sistemlerinde, CNN modeli MISO ve SIMO'ya kıyasla daha yüksek gizlilik kapasitesi sunmaktadır.



Şekil 4.23 MIMO Sistemlerde K-NN Anten Seçim Performansı

K-en yakın komşu (K-NN) algoritması, MIMO sistemlerinde anten seçiminde başarılı sonuçlar elde etmiştir. Şekil 4.23’deki doğruluk grafiğinde komşu sayısı arttıkça doğruluğun %90’ın üzerine çıktığı gözlemlenmiştir. K-NN’nin performansı, düşük karmaşıklık ve hızlı sonuçlar gerektiren sistemlerde etkili bir seçenek olabilir. Ancak MIMO sistemlerinde K-NN algoritması, diğer derin öğrenme modelleri kadar yüksek performans sergilememiştir.

K-NN algoritması, gizlilik kapasitesi açısından da düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$) yeterli sonuçlar verse de, yüksek hata gücü seviyelerinde ($\sigma_e^2 = 0.001$ ve 0.01) performansı daha sınırlıdır. MIMO sistemlerinde K-NN, DNN ve CNN ile karşılaştırıldığında daha düşük gizlilik kapasitesine sahiptir, ancak yine de geleneksel yöntemlerden daha başarılı sonuçlar elde edilmiştir.



Şekil 4.24 MIMO Sistemlerde Farklı σ_e^2 (σ_{e2}) Değerleri İçin Kanal Gücü, Gizlilik Kapasitesi Grafiği

Şekil 4.24'deki grafiklerde gizlilik kapasitesi, MIMO sistemlerinde farklı σ_e^2 değerleri altında analiz edilmiştir. σ_e^2 , kanal belirsizliklerini ve gürültü düzeyini temsil eder ve bu belirsizlikler gizlilik kapasitesini doğrudan etkiler. MIMO sistemlerinde gizlilik kapasitesi, verici ve alıcı anten sayısının artırılmasıyla önemli ölçüde artırılmıştır.

Düşük hata gücü seviyelerinde ($\sigma_e^2 = 0.0001$), hem DNN hem de CNN modelleri MIMO sistemlerinde çok yüksek gizlilik kapasitelerine ulaşmışlardır. Bu sonuçlar, MIMO sistemlerinde anten sayısının artırılmasının gizlilik kapasitesini nasıl önemli ölçüde artırdığını göstermektedir. Geleneksel yöntemler ve K-NN, MIMO sistemlerinde daha sınırlı performans göstermiştir.

σ_e^2 değerinin artırılmasıyla (0.001 ve 0.01), gizlilik kapasitesinde bir miktar azalma gözlemlense de, DNN ve CNN modelleri hala güçlü performans sergilemektedir. K-NN, bu durumlarda daha düşük gizlilik kapasiteleri sunarken, MIMO sistemlerinin avantajı bu modellerde de görülmektedir.

MIMO sistemlerinin, kapasite ve performans açısından MISO ve SIMO sistemlerinden daha üstün olduğu görülmektedir. MIMO, hem verici hem de alıcı antenlerde çeşitliliği artırarak gizlilik kapasitesini ve veri iletim kapasitesini büyük ölçüde artırır. Bu durum, fiziksel katman güvenliği açısından önemli bir avantaj sağlar. SIMO ve MISO sistemlerinde yalnızca bir tarafta (verici veya alıcı) anten çeşitliliği sağlanırken, MIMO sistemleri her iki tarafta da çeşitlilik sunarak performansı önemli ölçüde iyileştirir. Anten çeşitliliği, sinyalin farklı yollardan iletilmesini ve alınmasını sağlayarak kötü niyetli dinleyicilere karşı koruma sağlar, bu da fiziksel katman güvenliğini artırır.

SIMO sistemlerinde, tek bir verici anten ve birden fazla alıcı anten ile güvenlik kapasitesini artırmak mümkündür. Bu çeşitlilik, alıcı antenler arasında kanal

kazançlarının farklı yollardan alınmasını sağlar ve güvenliği optimize eder. Bu çalışmada, SIMO sistemlerinde makine öğrenmesi tabanlı CNN, DNN ve K-NN yöntemleri kullanılarak anten seçim performansı incelenmiştir. CNN, evrimsel filtreler aracılığıyla kanal kazançlarını analiz ederek SIMO sistemlerinde yüksek doğruluk sunmuştur. DNN, çok katmanlı yapısıyla karmaşık anten kazançlarını başarıyla öğrenirken, K-NN daha düşük bir hesaplama maliyeti sunarak hız ve verimliliği ön planda tutmaktadır. Ancak, K-NN daha karmaşık anten yapılarında sınırlamalara sahiptir.

MISO sistemleri ise, birden fazla verici anten ve tek bir alıcı anten ile çalışarak güvenlik kapasitesini ve veri iletim güvenilirliğini artırır. Verici anten çeşitliliği, güvenlik kapasitesine önemli katkılarda bulunur. MISO senaryosunda da CNN, DNN ve K-NN gibi makine öğrenmesi yöntemleri değerlendirilmiş ve CNN ile DNN, yüksek doğruluk ve düşük kayıpla anten seçimi konusunda üstün performans sergilemiştir. K-NN, MISO sistemlerinde de etkili sonuçlar verse de, daha düşük doğruluk oranları nedeniyle diğer modellere kıyasla sınırlı kalmıştır.

MIMO sistemlerinde, hem verici hem de alıcı tarafta kullanılan birden fazla antenle kapasite ve gizlilik kapasitesi maksimum seviyelere ulaşmaktadır. Çalışmada kullanılan CNN, DNN ve K-NN modelleri, anten çeşitliliğinin optimize edilmesinde büyük rol oynamaktadır. CNN modeli, yüksek doğruluk ve düşük kayıpla doğru anteni seçme konusunda SIMO ve MISO sistemlerine kıyasla çok daha üstün performans göstermektedir. Özellikle düşük σ_e^2 seviyelerinde, CNN ve DNN modelleri MISO ve SIMO sistemlerinden elde edilen gizlilik kapasitesini çok daha yükseğe çıkarır. Kanal belirsizliğinin düşük olduğu durumlarda, fiziksel katman güvenliği güçlenir ve güvenli veri iletimi sağlanır.

Bu analizler, MIMO sistemlerinde anten sayısının artırılmasının, yalnızca kapasiteyi değil aynı zamanda fiziksel katman güvenliğini de büyük ölçüde desteklediğini göstermektedir. MIMO sistemleri, karmaşık anten yapıları ve yüksek çeşitlilikle sağlanan güvenlik avantajlarıyla, sinyalleri kötü niyetli dinleyicilere karşı koruma konusunda üstün performans sunar. Sonuç olarak, MIMO sistemleri, hem veri iletim kapasitesi hem de gizlilik kapasitesi açısından SIMO ve MISO sistemlerinden çok daha yüksek performans sergilemektedir. MIMO'nun sağladığı bu üstün performans, fiziksel katman güvenliği için kritik bir rol oynar ve güvenli iletişim gerektiren uygulamalarda MIMO sistemlerinin tercih edilmesini sağlar. Anten sayısının artırılmasıyla sağlanan bu avantaj, özellikle düşük kanal belirsizlikleri altında gizlilik kapasitesini maksimuma çıkarır, böylece MIMO sistemleri güvenli veri iletimi için ideal bir çözüm haline gelmektedir.

5. SONUÇLAR ve ÖNERİLER

Bu çalışmada, SIMO, MISO ve MIMO sistemlerinin anten seçimi performansları makine öğrenmesi yöntemleri kullanılarak incelenmiştir. Çalışmanın temel amacı, farklı sistem yapılarına göre kullanılan CNN, DNN ve K-NN algoritmalarının anten seçimi üzerindeki etkilerini analiz etmektir. Çalışma, kanal gücü (P_s) koşullarının sabit ve değişken olduğu

durumları kapsayarak, doğruluk, kayıp ve F1 skorları gibi temel performans metrikleri üzerinden kapsamlı bir karşılaştırma sunmuştur.

SIMO Sistemleri: SIMO sistemlerinde yapılan analizlerde CNN modeli, yüksek doğruluk oranı ve düşük kayıp seviyeleriyle öne çıkmıştır. Sabit ve değişken Ps koşullarında CNN, doğruluk oranlarını yüksek tutarak anten seçiminde etkili olmuştur. DNN modeli, özellikle sabit Ps durumunda stabil bir performans sergilerken, K-NN, değişken Ps koşullarında sınırlı kalmıştır. Ancak sabit Ps durumunda dahi K-NN'nin doğruluk seviyesi diğer modellerin altında kalmıştır.

MISO Sistemleri: MISO yapısında, birden fazla verici anten ve tek bir alıcı anten kullanılmıştır. Bu sistemlerde CNN ve DNN modelleri, özellikle değişken Ps koşullarında yüksek doğruluk seviyeleriyle anten seçiminde başarılı olmuştur. K-NN, değişken Ps koşullarında düşük doğruluk ve yüksek kayıp oranlarıyla sınırlı bir performans sergilemiştir. Sabit Ps koşullarında ise, K-NN'nin doğruluk oranları artmasına rağmen, genel olarak diğer modellerin gerisinde kalmıştır.

MIMO Sistemleri: MIMO yapısında, hem verici hem de alıcı tarafta kullanılan birden fazla anten ile anten seçimi yapılmıştır. MIMO sistemlerinde CNN, en yüksek doğruluk ve en düşük kayıp oranları ile SIMO ve MISO sistemlerine kıyasla çok daha üstün performans göstermiştir. Özellikle düşük hata gücü (σ^2) seviyelerinde, DNN ve CNN, MISO ve SIMO sistemlerinden elde edilen gizlilik kapasitesini önemli ölçüde artırmıştır. K-NN, her iki Ps koşulunda da daha düşük performans sergilemiş, ancak sabit Ps koşulunda diğer modellere nazaran daha güvenilir bir doğruluk seviyesine ulaşmıştır.

Genel sonuçlar, MIMO sistemlerinin, anten sayısının artırılmasıyla hem veri iletim kapasitesinde hem de fiziksel katman güvenliğinde önemli iyileşmeler sunduğunu göstermektedir. Bu sistemlerde, CNN ve DNN modelleri, karmaşık anten yapıları ve yüksek çeşitlilikle anten seçiminde güçlü performans sunmuş, SIMO ve MISO sistemlerinden elde edilen gizlilik kapasitesini daha yüksek seviyelere çıkarmıştır.

Bu çalışmada kullanılan makine öğrenmesi modellerinin anten seçimi üzerindeki etkileri göz önüne alındığında, gelecekte daha gelişmiş modellerin uygulanması önemli bir adım olabilir. Özellikle CNN ve DNN modellerinin performansları yüksek doğruluk oranları ile dikkat çekmiş olsa da, karmaşık anten yapılarının yer aldığı MIMO sistemlerinde, LSTM veya GRU gibi zaman serisi verileriyle uyumlu modellerin kullanımı, anten seçiminde daha yüksek performans elde edilmesine katkıda bulunabilir. Bu tür modeller, sinyallerin zamanla değişen özelliklerini daha iyi yakalayarak anten seçim sürecine daha fazla hassasiyet kazandırabilir.

Çalışmada gözlemlenen bir diğer önemli nokta, farklı makine öğrenmesi yöntemlerinin bir araya getirilmesiyle elde edilecek hibrit modellerin SIMO ve MISO sistemlerinde doğruluk oranlarını artırabileceğidir. CNN ve DNN'nin birlikte kullanımı, anten kazançlarının analiz edilmesinde ve doğru anten seçimlerinde daha üstün performans sağlayabilir. Hibrit model yaklaşımları, farklı algoritmaların güçlü yönlerini bir araya

getirerek, kablosuz iletişim sistemlerinde güvenli veri iletimi için daha kapsamlı çözümler sunabilir.

Anten seçimi süreçlerinde gizlilik kapasitesini etkileyen kanal belirsizliklerinin daha iyi anlaşılması ve modellenmesi, fiziksel katman güvenliğinin güçlendirilmesi açısından önemlidir. Çalışma, değişken P_s koşullarında gizlilik kapasitesinin değerlendirilmesi için önemli bir çerçeve sunarken, kanal belirsizliklerinin azaltılması için daha gerçekçi simülasyonlar yapılması önerilmektedir. Bu tür belirsizlikler üzerine yapılacak derinlemesine analizler, özellikle düşük kanal belirsizliklerine sahip ortamlarda gizlilik kapasitesini daha doğru değerlendirme imkanı sunabilir.

Anten konfigürasyonları ile yapılan denemelerde elde edilen sonuçlar, model performanslarının optimizasyonu açısından dikkat çekicidir. Gelecekteki çalışmalarda, farklı frekans bantları ve daha fazla anten konfigürasyonu ile testlerin yapılması, düşük maliyetli sistemler için gerekli minimum anten sayısının belirlenmesine de katkı sağlayabilir. Bu kapsamda, çeşitli anten yapılandırmalarının değerlendirilmesi, özellikle veri iletim güvenliği ve kapasitesi üzerinde önemli etkiler yaratabilir.

Son olarak, makine öğrenmesi modellerinin gerçek zamanlı veri ile çalışma kapasitelerinin incelenmesi, özellikle yüksek hızlı veri iletimi gereken uygulamalarda önemli bir gelişme alanı sunmaktadır. CNN ve DNN gibi modellerin gerçek zamanlı veri setleri ile test edilmesi, kablosuz iletişimde güvenli veri iletimi için yeni olanaklar sağlayabilir. Bu tür gerçek zamanlı uygulamalara yönelik optimizasyonlar, MIMO sistemlerinin daha geniş bir yelpazede kullanılarak güvenli iletişim gerektiren uygulamalarda daha etkin bir şekilde tercih edilmesine olanak tanıyacaktır.

Bu öneriler doğrultusunda, gelecekte yapılacak çalışmaların, MIMO sistemleri için makine öğrenmesi tabanlı anten seçim yöntemlerinin gelişimini desteklemesi ve kablosuz iletişimde güvenli veri iletimine katkı sunması beklenmektedir.

KAYNAKLAR

- Goldsmith, A. (2005).** *Wireless Communications*. Cambridge University Press.
- Tse, D., & Viswanath, P. (2005).** *Fundamentals of Wireless Communication*. Cambridge University Press.
- Heath, R. W., & Lozano, A. (2018).** *Foundations of MIMO Communication*. Cambridge University Press.
- Molisch, A. F. (2005).** *Wireless Communications*. John Wiley & Sons.

- Zheng, L., & Tse, D. N. (2003).** "Diversity and multiplexing: a fundamental tradeoff in multiple-antenna channels." *IEEE Transactions on Information Theory*, 49(5), 1073-1096.
- Proakis, J. G., & Salehi, M. (2007).** *Digital Communications*. McGraw-Hill Education.
- Rappaport, T. S. (1996).** *Wireless Communications: Principles and Practice*. Prentice Hall PTR.
- Rappaport, T. S., Xing, Y., & Kanhere, O. (2021).** "6G Wireless Networks: Vision, Requirements, Architecture, and Key Technologies." *ICT Express*, 7(1), 69-82.
- Kumar, A., Gupta, P., & Singh, R. (2023).** "A Survey on 5G and Beyond Wireless Communications: A Key Enabler of the Next Industrial Revolution." *Electronics*, 12(10), 2200.
- Chang, R. W. (2003).** "The History of Orthogonal Frequency Division Multiplexing." *Proceedings of the IEEE*.
- Kaya, M. (2010).** *Çok Taşıyıcılı Modülasyon Sistemleri ve OFDM Uygulamaları*. İstanbul Üniversitesi, Yüksek Lisans Tezi.
- Khosla, D., Singh, J., & Aggarwal, R. (2018).** "OFDM Modulation Technique & its Applications: A Review." *International Journal of Engineering and Technical Research*.
- Gilhausen, K. S., Jacobs, I. M., & Padovani, R. (1987).** "Code Division Multiple Access (CDMA) System in Multipath Environment." *IEEE Transactions on Vehicular Technology*, 36(4), 131-139.
- Molisch, A. F. (2007).** *Advanced Wireless Communications: 4G Cognitive and Cooperative Broadband Technology*. Springer.
- Ganesan, G., & Yanikomeroglu, H. (2014).** "Capacity, Power and Delay Trade-off in Cooperative MIMO Cognitive Radio Networks." *Wireless Networks*, 20(2), 227-241.
- Ngo, H. Q., Larsson, E. G., & Marzetta, T. L. (2016).** "A Survey on Distributed Massive MIMO: Basics, Evolution, and Future Trends." *Applied Soft Computing*, 49, 673-688.
- Paulraj, A., & Gore, D. (2003).** "A Survey of MIMO Transmission Techniques for Broadband Wireless Communications." *IEEE Wireless Communications*, 11(4), 8-18.
- Alamouti, S. M. (2005).** "The Role of Space-Time Coding in the Evolution of Wireless Communications." *Semantic Scholar*.
- Sanayei, S., & Nosratinia, A. (2004).** "Antenna Selection in MIMO Systems with Imperfect Channel State Information." *IEEE Communications Letters*, 8(5), 287-289.
- Goldsmith, A., & Wicker, S. B. (2022).** "Multiple-Input Multiple-Output (MIMO) Systems for Wireless Communications: Antenna Selection Algorithms and Design Methodologies." *Sensors*, 22(20), 7813.
- Khademi, Z., & Ghavami, M. (2022).** "Optimized Antenna Selection in MIMO Systems for Wireless Networks." *International Research Journal of Modernization in Engineering Technology and Science*.
- Blum, R. S., & Liu, Y. (2004).** "Antenna Selection for MIMO Systems in Fading Channels." *IEEE Transactions on Wireless Communications*.

Molisch, A. F., & Win, M. Z. (2003). "Hybrid Selection Schemes for MIMO Systems." *IEEE Transactions on Communications*, 52(1), 89-100.

Nosratinia, A., & Sanayei, S. (2003). "Capacity Analysis and Antenna Selection for MIMO Systems." *IEEE Transactions on Communications*.

Tse, D., & Viswanath, P. (2003). "Diversity and Multiplexing in MIMO Channels: A Fundamental Trade-Off." *IEEE Transactions on Information Theory*, 49(5), 1073-1096.

Molisch, A. F., & Winters, J. H. (2007). "Energy-Efficient Antenna Selection for MIMO Systems." *IEEE Transactions on Vehicular Technology*, 56(5), 2896-2905.

Heath, R. W., & Love, D. J. (2010). "Antenna Selection for Energy-Constrained Massive MIMO Networks." *IEEE Transactions on Communications*, 58(12), 3410-3419.

Choi, J., & Cho, D. H. (2007). "Performance Analysis of Antenna Selection Algorithms in MIMO Systems." *IEEE Transactions on Wireless Communications*, 6(10), 3878-3888.

Aghdam, E. F., & Khalaj, B. H. (2005). "Antenna Selection in MIMO Systems: An Overview." *IEEE Communications Magazine*, 43(6), 149-155.

Yu, Y., & Wang, D. (2013). "Deep Learning for Antenna Selection in Massive MIMO Systems." *IEEE Transactions on Communications*.

Sohn, I. (2015). "Efficient Antenna Selection Algorithms for MIMO Systems." *Springer Wireless Personal Communications*, 77(4), 3165-3179.

Firat, M., & Dogan, H. (2022). "Machine Learning and Deep Learning Techniques in Antenna Selection." *International Journal of Internet Technology and Secured Transactions*, 12(4), 364-372.

Gupta, A., & Singh, H. (2020). "Deep Learning Techniques: An Overview." *International Journal of Engineering and Technology*, 11(4), 25-39.

Shokri, H., & Nikookar, H. (2022). "Neural Network Architectures for Deep Learning in Wireless Communications." *Springer Journal of Network and Systems Management*.

Qamar, F., & Shafiq, M. (2020). "Deep Learning for Multi-Antenna Systems." *MDPI Sensors*, 20(8), 2250.

Chen, Z., & Ren, H. (2022). "Deep Learning Techniques in Massive MIMO Systems." *IEEE Communications Letters*.

Simeone, O., & Sahai, A. (2021). "Machine Learning in Wireless Communications: Applications and Challenges." *IEEE Transactions on Wireless Communications*, 20(5), 11-16.

Niyaz, Q., & Hasan, M. (2023). "Antenna Selection Using Deep Learning for Massive MIMO Systems." *IEEE Access*.

Ali, S., & Habib, A. (2023). "Applications of Deep Learning in MIMO Antenna Systems." *Springer Wireless Networks*.

Shaik, M. (2023). "Deep Learning in Wireless Communications: Challenges and Opportunities." *ScienceDirect Physical Communication*.

Wu, Y., & Zhang, R. (2022). "Artificial Neural Networks in Antenna Selection." *IEEE Access*.

- Hussain, A., & Lee, J. H. (2022).** "Neural Network-based Antenna Selection for MIMO Systems." *Wiley Online Library Wireless Communications and Mobile Computing*.
- Jiang, W., & Cheng, H. (2021).** "Machine Learning for Wireless Communications." *MDPI Electronics*, 10(10), 1604.
- Li, X., & Wang, C. (2022).** "Antenna Selection in MIMO Systems with Deep Learning." *IEEE Transactions on Vehicular Technology*.
- Yang, Y., & Wu, D. (2023).** "Deep Learning Approaches for Wireless MIMO Systems." *Springer Journal of Communications and Networks*.
- Chen, B., & Li, J. (2023).** "Deep Learning-Based Optimization for Antenna Selection." *MDPI Sensors*.
- Simeone, O., & Sahai, A. (2022).** "An Overview of Machine Learning in Wireless Systems." *IEEE Communications Surveys & Tutorials*.
- Zhang, Y., & Shao, L. (2023).** "Optimization Techniques in Deep Learning for Antenna Selection." *IEEE Communications Magazine*.
- Mohamed, A., & El-Din, E. (2023).** "Advances in Deep Learning for MIMO Antenna Systems." *Elsevier Signal Processing*.
- Huang, J., & Li, X. (2023).** "Deep Learning Methods for Enhanced Antenna Selection." *IEEE Transactions on Signal Processing*.
- Ranjan, A., & Choudhury, S. (2023).** "The Role of Artificial Intelligence in Wireless Communications." *Wiley Encyclopedia of Electrical and Electronics Engineering*.
- McCulloch, W. S., & Pitts, W. H. (1943).** "A logical calculus of the ideas immanent in nervous activity." *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986).** "Learning representations by back-propagating errors." *Nature*, 323, 533-536.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015).** "Deep learning." *Nature*, 521(7553), 436-444.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006).** "A fast learning algorithm for deep belief nets." *Neural Computation*, 18(7), 1527-1554.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012).** "ImageNet classification with deep convolutional neural networks." *Communications of the ACM*, 60(6), 84-90.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016).** *Deep Learning*. MIT Press.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014).** "Generative adversarial nets." *Advances in Neural Information Processing Systems*, 27, 2672-2680.
- Cover, T. M., & Hart, P. E. (1967).** "Nearest neighbor pattern classification." *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Altman, N. S. (1992).** "An introduction to kernel and nearest-neighbor nonparametric regression." *The American Statistician*, 46(3), 175-185.
- Floridi, L., et al. (2018).** "AI4People—An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations." *Minds and Machines*, 28, 689-707.

Bengio, Y. (2009). "Learning deep architectures for AI." *Foundations and Trends in Machine Learning*, 2(1), 1-127.

Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2017). "Building machines that learn and think like people." *Behavioral and Brain Sciences*, 40.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Burak ERDURAK

ÖĞRENİM DURUMU

Derece	Alan	Üniversite	Mezuniyet Yılı
Lisans	Elektrik-Elektronik Mühendisliği	Gaziantep Üniversitesi	2016

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2017-2020	Aymed Medikal Teknoloji	Kıdemli Gömülü Sistem Yazılım Uzmanı
2018-2020	TÜBİTAK - BİLGEM	Teknoloji Transfer Proje Yöneticisi
2021-2022	Propay Ödeme Sistemleri	Yazılım Uzmanı
2024-	BemPlas Tech Plastik San.	Genel Müdür