




BMBAD
BJESR

Mühendislik Bilimleri ve Araştırmaları Dergisi
Journal of Engineering Sciences and Researches



Derin Öğrenme Tabanlı Kanal Kestirimi: 5G NR OFDM Sistemleri için Hiperparametre Analizi ve Performans Karşılaştırması

Deep Learning-Based Channel Estimation: Hyperparameter Analysis and Performance Comparison for 5G NR OFDM Systems

¹Merih LEBLEBİCİ , ²Ali ÇALHAN

¹Düzce Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Düzce, Türkiye

²Düzce Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Düzce, Türkiye

¹merihleblebici@duzce.edu.tr, ²alicalhan@duzce.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 11 October 2024

Accepted : 20 January 2025

Keywords:

Channel Estimation,
OFDM, Deep Learning,
Wireless Communication,
Parameter Analysis

ABSTRACT

Fifth generation (5G) New Radio (NR) is the global standard for a unified, flexible, and scalable wireless communication framework designed to deliver enhanced mobile broadband and ultra-reliable low-latency communication for next-generation networks. Channel estimation is critical for optimizing the performance of 5G NR orthogonal frequency division multiplexing (OFDM) systems. This study explores deep learning (DL)-based channel estimation techniques, focusing on hyperparameter analysis and performance comparison with the traditional least squares (LS) method. Through 300 simulations, DL models are analyzed under varying parameters to assess their adaptability and accuracy in dynamic wireless environments. The results demonstrate that DL models, when fine-tuned, outperform LS in terms of estimation accuracy, achieving lower errors and greater adaptability to changing channel conditions. Furthermore, the study highlights the potential of optimized DL models to reduce computational complexity, enabling their deployment in real-time applications. This work underscores the advantages of DL-based approaches in 5G NR OFDM systems.

© 2025 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 11 Ekim 2024

Kabul : 20 Ocak 2025

Anahtar Kelimeler:

Kanal Kestirimi, OFDM,
Kablosuz Haberleşme,
Derin Öğrenme, Parametre
Analizi

ÖZET

Beşinci nesil (5G) Yeni Radyo (NR), gelişmiş mobil geniş bant ve ultra güvenilir düşük gecikmeli iletişim sağlamak üzere tasarlanmış birleşik, esnek ve ölçeklenebilir kablosuz iletişim için küresel bir standarttır. Kanal kestirimi, 5G NR dik frekans bölümleri çoğullama (OFDM) sistemlerinin performansını optimize etmek için kritik bir öneme sahiptir. Bu çalışma, hiperparametre analizine ve geleneksel en küçük kareler (LS) yöntemiyle performans karşılaştırmasına odaklanarak derin öğrenme (DL) tabanlı kanal kestirim tekniklerini araştırmaktadır. 300 adet simülasyon aracılığıyla, DL modellerinin dinamik kablosuz ortamlardaki uyarlanabilirliklerinin ve doğruluklarının değerlendirilmesi için değişen parametreler altında analizi yapılır. Sonuçlar, DL modellerinin, ince ayar yapıldığında, tahmin doğruluğu açısından LS'den daha iyi performans gösterdiğini, daha düşük hatalar elde ettiğini ve değişen kanal koşullarına daha fazla uyum sağladığını göstermektedir. Ayrıca çalışma, optimize edilmiş DL modellerinin hesaplama karmaşıklığını azaltma potansiyelini vurgulayarak gerçek zamanlı uygulamalarda kullanılabileceklerine dikkat çekmekte ve 5G NR OFDM sistemlerinde DL tabanlı yaklaşımların avantajlarının altını çizmektedir.

© 2025 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Kanal kestirimi, özellikle dördüncü nesil (fourth generation, 4G), beşinci nesil (fifth generation, 5G), Wi-Fi vb. modern standartlarda sıkça yer alan çoklu giriş-çoklu çıkış (multi-input-multi output, MIMO) ve dik frekans bölmeli çoğullama (orthogonal frequency division multiplexing OFDM) gibi ileri teknolojilerin kullanıldığı kablosuz haberleşme sistemlerinin önemli bir parçasıdır. MIMO sistemlerinde doğruluğu yüksek bir kanal kestirimi, uzaysal çeşitlilikten olabildiğince yararlanmak ve hüzmeye oluşturma (beamforming) ile uzaysal çoğullama gibi tekniklerin optimize edilmesi için olmazsa olmaz bir unsurdur. Özellikle hüzmeye oluşturma ile uzaysal çoğullama, çoklu yol yayılım etkilerini yöneterek veri kapasitesini (data throughput) ve izgesel verimliliği artırmaktadır [1]. Benzer şekilde OFDM sistemlerinde de her bir alt taşıyıcı farklı sönmüleme etkisini hisseder. Bu durumda kanal kestirimi, semboller arası girişimi (inter symbol interference, ISI) en aza indirmek ve güvenli bir haberleşmenin sağlanabilmesi adına alınan sinyalin düzeltilebilmesi için gereklidir [2]. Kanal kestirimi kaliteli bir şekilde yapılmazsa bu sistemlerin performansı dramatik bir şekilde düşer ve yüksek hata oranları, düşük veri oranları ve etkisiz bir izge kullanımı ortaya çıkar [3].

En küçük kareler (least squares, LS) ve en küçük ortalama karesel hata (minimum mean square error, MMSE) gibi mevcut kanal kestirim teknikleri kablosuz haberleşme sistemlerinde sıklıkla kullanılan yöntemler olmalarına karşın bazı kısıtlamalara sahiptir. LS kanal kestiriminin işlemsel karmaşıklığı düşüktür ve kanal ya da gürültü istatistiği gibi herhangi bir ön bilgiye ihtiyaç duymaz. Bu durum onun yaygın olarak kullanılmasını sağlar ancak LS gürültüye karşı yüksek bir duyarlılığa sahiptir. Özellikle düşük sinyal-gürültü oranı (signal to noise ratio, SNR) durumlarında optimum altı bir performans sergiler [3]. Diğer taraftan MMSE, hem gürültü hem de kanal istatistiklerini dikkate alarak LS'ye göre daha az kestirim hatasıyla daha iyi bir performans sergiler. Ödünleşimin bir gereği olarak bu teknikte kanal istatistiklerine ön bilgi olarak ihtiyaç duyulduğu için yüksek bir işlemsel karmaşıklık görülmektedir. Bu durum da onu gerçek zamanlı uygulamalar ya da hızlı değişen kanalların olduğu sistemler için daha az elverişli hale getirir [4]. Modern kablosuz sistemlerde üstesinden gelinmesi gereken yüksek karmaşıklık ve gürültüye karşı duyarlılık gibi kısıtlamalar, araştırmaların makine öğrenimi ve türevleri tabanlı daha etkili ve uyarlanabilir tekniklerin geliştirilmesine yol açmıştır [1].

Derin öğrenme (deep learning, DL), birçok alanda olduğu gibi kablosuz kanalların karmaşık ve doğrusal olmayan yapılarını kolaylıkla modelleme yeteneğiyle kanal kestiriminin iyileştirilmesi için de önemli bir metot olarak ortaya çıkmıştır. LS ve MMSE gibi geleneksel kestirim teknikleri bazı doğrusal varsayımlara ve istatistiki ön bilgilere ihtiyaç duymaktadır. Bu durum ilgili tekniklerin, 5G ve ötesi haberleşme sistemlerinde karşılaşılan dinamik ve yüksek oranda doğrusal olmayan ortamlarda etkilerini kısıtlar [2]. Buna karşın evrişimli sinir ağı (convolutional neural network, CNN) ve yinelemeli sinir ağı (recurrent neural network, RNN) gibi DL modelleri kablosuz sinyaller ait büyük veri setlerinden çeşitli özellikleri kolaylıkla öğrenebilir. Bu da ilgili modellerin karmaşık kanal davranışlarını yakalamalarını ve değişen koşullara daha etkili bir şekilde uyum sağlamalarını mümkün kılar [5]. Böylece özellikle geleneksel tekniklerin zorlandığı yüksek mobilite ve girişim senaryolarında daha doğru kanal kestirimlerinin yapılabilmesinin önü açılır [6]. Ayrıca DL modelleri eğitildikten sonra kanal durumları hakkında hızlıca çıkarım yapabilir. Bu durum onların gerçek zamanlı performanslarını iyileştirir ve işlemsel karmaşıklıklarını düşürür. Böylece modern, yüksek verimli sistemler için uygun hale gelmiş olurlar.

Yapılan çalışmalardan farklı olarak bu çalışmada:

- Az çalışılan bir konu olan hiperparametre analizi üzerinde çalışılmış ve hiperparametre değişikliğinin DL tabanlı kanal kestirim performansı üzerindeki etkisi incelenmiştir.
- Yapılan 300 adet simülasyon ile DL tabanlı kanal kestirim performansı geleneksel kanal kestirim yöntemlerinden biri olan LS ile karşılaştırılmıştır.
- DL tabanlı kanal kestirim yöntemlerinin uygun tasarlandıkları zaman kablosuz haberleşme sistemlerinin dinamik durumlarına geleneksel kanal kestirim yöntemlerinden daha iyi uyum sağladıkları gösterilmiştir.
- DL modelleri ile daha az kestirim hatası elde edilebileceği gösterilmiştir.
- Geleneksel yöntemlerin işlemsel yüklerine karşın optimum hiperparametrelerle beraber işlemsel karmaşıklığı daha düşük DL tabanlı kanal kestirim yöntemlerinin tasarlanabileceği gösterilmiştir.

Çalışmanın geri kalanı şu şekilde hazırlanmıştır: Bölüm 2'de kanal kestirim yöntemleriyle ilgili literatür taraması verilerek yapılacak katkı sunulmuştur. Bölüm 3'te sistem modeli açıklanıp Bölüm 4'te kanal kestirimi için önerilen DL modelleri hakkında bilgi verilmiştir. Simülasyon kurulumu Bölüm 5'te yer alırken Bölüm 6'da simülasyon çıkarımları açıklanmıştır. Son olarak Bölüm 7'de çalışmanın sonucu ve potansiyel çalışma konuları verilmiştir.

2. İLGİLİ ÇALIŞMALAR

Kanal kestirimi için kablosuz haberleşmede kullanılan geleneksel metotların arasında LS, MMSE ve maksimum olabilirlik (maximum likelihood, ML) teknikleri yer almaktadır. LS kestirim tekniği sahip olduğu düşük işlemsel karmaşıklığı sayesinde en basit ve yaygın olarak kullanılan metotlardan biridir ancak gürültü ve kanal istatistiklerini dikkate almadığı için gürültülü ortamlarda düşük performans göstermektedir [3]. MMSE kestirim tekniği, hem kanal hem de gürültü istatistiklerini hesaba katarak LS tekniğini geliştirir ve özellikle düşük SNR senaryolarında daha doğru sonuçlar elde eder. Bunu yaparken kanala ve gürültüye ait kovaryans matrislerine ön bilgi olarak ihtiyaç duyan MMSE, karmaşıklığı ve işlemsel yükü ciddi oranda artırır [4]. ML kestirim tekniği de

gözlemlendiği veriler üzerinden olabilirlik fonksiyonunu maksimize ederek daha iyi bir performans sergiler ancak ihtiyaç duyduğu yüksek işlemsel yük nedeniyle gerçek zamanlı uygulamalar için pratik bir çözüm değildir [1]. Gürültü duyarlılığı, işlemsel yük ve istatistiksel bilgilere olan ihtiyaç gibi kısıtlamalar kanal kestirimi için makine öğrenimi gibi daha gelişmiş tekniklerin araştırılmasını gerekli hale getirmiştir.

Kanal kestirimi için derin öğrenmeyi kullanan çalışmalar geleneksel tekniklere göre doğruluğu, sağlamlığı ve verimliliği geliştirerek büyük ilerlemeler kaydetmektedir. Öne çıkan yaklaşımlardan birisi masif (massive) MIMO sistemlerindeki kanal durum bilgisini (channel state information, CSI) CNN kullanarak kestirmeye çalışmaktır. Zhang vd. CNN'nin geleneksel tekniklere göre CSI'yi daha etkili bir şekilde sıkıştırıp geri elde etmeyi öğrenerek masif MIMO'daki geri bildirim yükünün önemli ölçüde azaltılabileceğini göstermiştir. Bu durum izgesel verimliliğin artmasını sağlamaktadır [6]. Bir diğer önemli çalışma ise MMSE gibi klasik yöntemlere göre kanalın dinamiklerini daha iyi takip eden ve zamana bağlı ilişkilerini daha etkili modelleyen derin sinir ağı (deep neural network, DNN) modellerinin zamanla değişen kanallara uygulanmasıdır [7]. Bunlara ek olarak otokodlayıcılar ve üretken çekişmeli ağ (generative adversarial network, GAN) modelleri karmaşık ve çok boyutlu kanal verilerini anlamlandırmak için araştırılmıştır. Bu çalışmalardan elde edilen sonuçlar göstermiştir ki DL tabanlı kanal kestirim modelleri geleneksel tekniklere sadece doğruluk olarak üstün gelmekle kalmayıp aynı zamanda işlemsel yükü azaltma ve hızlı değişen ortamlara uyum sağlama konusunda da büyük bir potansiyele sahiptir.

Literatürdeki güncel çalışmaların çoğu 5G ve sonrası haberleşme sistemleri için yapılan araştırmalardan oluşmaktadır. [8]'de önerilen DL mimari yapısı, milimetrik dalga sistemlerinin simülasyonları aracılığıyla grafik işlem birimi (graphics processing unit, GPU) ya da kullanıcı programlamalı kapı dizisi (field programmable gate array, FPGA) gibi paralel olarak çalışabilen donanımlar için optimize edilmiştir. Simülasyon sonuçlarına göre bit hata oranı (bit error rate, BER) metriği özelinde LS ve doğrusal MMSE'ye (linear MMSE, LMMSE) göre sırasıyla 5 ve 2 katlık bir iyileşme elde edilmiştir. Ayrıca düşük SNR bölgelerinde LMMSE kestirim tekniğine göre daha büyük uzaysal çeşitlilik sağlanmış ve 4 dB'ye kadar alınan sinyal gücünde iyileşme sağlanmıştır.

Saikrishna vd. 5G aşağı yönlü bağlantısında (downlink) CNN kullanarak gürültü filtreleme ve interpolasyon için üç parçadan oluşan DL tabanlı kanal kestirimi önermiştir. Bu sayede normalleştirilmiş ortalama karesel hata (normalized mean square error, NMSE) tekniğinde LMMSE'ye göre gecikme ve Doppler yayılımına karşı dayanıklılıkla beraber 4 dB'lik bir performans kazancı elde edilmiştir [9]. 5G milimetrik dalga sistemleri düşük gecikme ve yüksek veri hızları sağlamasına rağmen yüksek işlemsel yüklere neden olmaktadır. [10]'da bunun önüne geçmek için işlemsel karmaşıklığı ve enerji tüketimini ciddi oranda düşüren DL tabanlı kanal kestirimi modeli FPGA üzerinde optimize edilmiştir. Böylece 10 kata kadar düşük gecikme ve 300 kata kadar iyileştirilmiş enerji verimliliği elde edilmiştir.

OFDM'den yararlanılan hücreli kablosuz sistemlerde pilot yardımcı kanal kestirim tekniği istikrarlı performansı sebebiyle yaygın olarak kullanılsa da DL metotları bu alanda da ilgi çekmeye başlamıştır. Mohammed vd. [11]'de DL tabanlı kanal kestirim modeli önermiştir. Bu modelin çeşitli parametrelerde LS ve MMSE kestirim tekniklerinden daha iyi performans sergilediği gösterilmiştir ancak önerilen uzun kısa-süreli bellek (long short-term memory, LSTM) tabanlı modelin karmaşıklığının çok yüksek olduğu belirtilmiştir. [12]'de ise 5G OFDM sistemi için süper çözünürlük tekniklerinin kullanıldığı bir DL tabanlı kanal kestirim modeli önerilmiştir. Önerilen modelde kullanılan teknikler işlemsel yükü ve parametre sayısını azaltıp çok kullanıcı senaryolar için gürültü azaltma işlevi görmektedir.

Kablosuz haberleşmede performansın optimize edilmesi için kanal kestirimi çok önemlidir ama geleneksel teknikler 5G ve sonrası sistemlerin sahip olduğu karmaşık yapıdan dolayı yetersiz kalmaktadır. [13]'teki çalışma sentetik olarak üretilen 5G veri setiyle eğitilen CNN yapısının kullanıldığı DL modelinden yararlanmıştır. Önerilen model geleneksel tekniklerden biri olan doğrusal interpolasyondan ciddi oranda daha yüksek bir doğruluğa sahiptir ve gelecek nesil ağ yapıları için kanal kestirimi işleminde derin öğrenmenin önemini vurgulamaktadır.

Literatürdeki çoğu çalışma teorik araştırmalara yoğunlaşmakta ve pratikte kullanılan sistemleri incelememektedir. Bu çalışmada literatürden farklı olarak haberleşme standartlarında yer alan 5G yeni radyo (new radio, NR) OFDM sistemleri için tek giriş-tek çıkış (single input-single output, SISO) senaryosunda DL tabanlı kanal kestiriminin performansı incelenmiştir. Önerilen farklı DL modellerinin performansı klasik kanal kestirimi ile karşılaştırılmıştır.

3. SİSTEM MODELİ

OFDM, uzun vadeli evrim (long term evolution, LTE), Wi-Fi ve 5G gibi standartların içinde bulunduğu modern kablosuz haberleşme sistemlerinde yaygın olarak kullanılan bir iletim tekniğidir. OFDM'nin temel prensibi geniş frekans izgesinin birbirlerine dik olacak şekilde çoklu dar bant alt taşıyıcılara bölünmesidir. Bu diklik alt taşıyıcıların frekans alanında girişime neden olmadan üst üste gelmelerine imkan sağlar ve böylece izgesel verimlilik artırılmış olur [2].

Her bir alt taşıyıcı karesel genlik modülasyonu (quadrature amplitude modulation, QAM) gibi teknikler kullanılarak bağımsız bir şekilde modüle edilebilir. Böylece aynı bant genişliğinde daha fazla verinin iletimi sağlanmış olur. OFDM, döngüsel önek (cyclic prefix, CP) kullanımıyla kablosuz ortamlardaki temel bir sorun olan ve çok yollu yayılımdan kaynaklanan ISI'nın azaltılmasında kısmen etkili olur. CP, her bir OFDM sembolünün


sonundaki belli bir kısmın ilgili sembolün başına eklenmesiyle elde edilir ve iletilen sinyalin gecikmiş halinin sonrasında iletilen sembolle karışmasını engelleyerek ISI'nın azaltılmasına yardımcı olur [3].

Frekans seçici kanallar, iletilen sinyallerin farklı frekanslardaki bileşenlerinin çok yollu yayılımdan kaynaklı sönümlemeye farklı oranlarda etkilenebilmesiyle karakterize edilebilir. Bu durum kanalın dürtü cevabının sembol süresinden daha uzun bir yayılım gösterdiğinde ortaya çıkar ve birden fazla sinyal yolunun alıcıya farklı zamanlarda ulaşmasına neden olur. Frekans seçici kanallar için çoğunlukla çok yollu Rayleigh sönümleme modeli ve kademeli gecikme hattı (tapped delay line, TDL) modeli kullanılır.

Çok yollu Rayleigh sönümleme modelinde iletilen sinyal çeşitli yansıma ve kırınımına maruz kalır. Böylelikle çoklu yayılım yolları, sinyale iyileştirici ya da bozucu şekilde etki eder. İletim ortamlarında baskın bir doğrudan görüş (line of sight, LoS) yolu yoksa alınan sinyalin zarfı sinyal gücünde ani dalgalanmaların gözlemlendiği Rayleigh dağılımı olarak modellenebilir [1]. Bu model genellikle binaların sinyalleri etrafa saçtığı kentsel ortamlardaki senaryolar için uygulanabilir.

TDL modelinde frekans seçici kanal, çeşitli gecikme ve zayıflamalarla karakterize edilen yolların ayırık dizisi şeklinde temsil edilir. Her bir kademe (tap) farklı bir yayılım yoluna karşılık gelir ve çok yollu ortamların daha detaylı bir şekilde temsil edilmesini sağlar. TDL modeli kanalın zaman dağılımı özelliklerini etkili bir şekilde yakalar ve farklı frekans bileşenlerinin nasıl etkilendiğinin analiz edilmesini kolaylaştırır [14].

Sonuç olarak OFDM, geniş bantlı bir sinyali üst üste gelen dar bant alt taşıyıcılara bölerek frekans seçici kanallardan kaynaklanan zorlukların üstesinden gelen etkili bir iletim tekniğidir. Genellikle çok yollu Rayleigh sönümleme ve TDL modeli olarak modellenen frekans seçici kanallar ise sinyallerin çoklu yayılım yollarına sahip ortamlarda nasıl davrandığının anlaşılması için önemli bir bakış açısı sunar.



Şekil 1. Kablosuz haberleşme sistem modeli.

Şekil 1’de genel bir sistem modeli verilen kablosuz haberleşmede kanal kestirimi; iletilen sinyal, kanal matrisi ve gürültüden etkilenecek olarak alınan sinyal arasındaki ilişkiye bakılıp matematiksel olarak formüle edilebilir. Kablosuz kanal, $\mathbf{H}$ kanal matrisi olacak şekilde ifade edilebilir. $\mathbf{H}$ matrisinin boyutu, N_r alıcı anten sayısını ve N_t verici anten sayısını göstermek üzere $N_r \times N_t$ şeklinde verilebilir. Kanal matrisinin her bir elemanı, h_{ij} olmak üzere j . verici antenden i . alıcı antene olan kanal kazancı şeklinde temsil edilir.

İletilen sinyal, QAM gibi herhangi bir modülasyon türüyle modüle edilmiş sembollerden oluşan $N_t \times 1$ boyutundaki $\mathbf{x}$ vektörü olarak ifade edilebilir. Alıcı tarafından alınan sinyal vektörü $\mathbf{y}$ olmak üzere;

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n} \quad (1)$$

şeklinde yazılabilir. Burada alınan sinyal vektörü $\mathbf{y}$ ’nin boyutu $N_r \times 1$ iken $\mathbf{n}$ aynı boyuttaki gürültü vektörünü gösterir. Genel olarak toplamsal beyaz Gauss gürültüsü (additive white Gaussian noise, AWGN) olarak modellenen $\mathbf{n}$ gürültü vektörünün her bir bileşeni bağımsız ve aynı şekilde dağıtılmış (independent and identically distributed, i.i.d.) Gauss gürültüsünü temsil eder. Kanal kestiriminin amacı $\mathbf{H}$ kanal matrisini $\mathbf{y}$ alınan sinyal vektörünü kullanarak tespit etmeye çalışmaktır.

Kanal matrisi için LS kestirimci, Denklem 2’deki gibi farkların kareler toplamının minimize edilmesi şeklinde verilebilir.

$$\hat{\mathbf{H}}_{LS} = \arg \min_{\mathbf{H}} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 \quad (2)$$

Burada $(\cdot)$ kestirim işlemi ile elde edilen sonucu gösterirken $\|\cdot\|$ ise L2 normu ifade eder. Bu problemin çözümü,

$$\hat{\mathbf{H}}_{LS} = \mathbf{y}\mathbf{x}^\dagger (\mathbf{x}\mathbf{x}^\dagger)^{-1} \quad (3)$$

şeklinde verilebilir. Burada $(\cdot)^\dagger$ ve $(\cdot)^{-1}$ sırasıyla eşlenik devriği ve matrisin tersini alma işlemlerini temsil eder. MMSE kestirimci, LS’den farklı olarak kanal ve gürültünün istatistik bilgilerini hesaba katarak aşağıdaki şekilde ifade edilebilir:

$$\hat{\mathbf{H}}_{MMSE} = \mathbb{E}[\mathbf{H}|\mathbf{y}] \quad (4)$$

Burada $\mathbb{E}[\cdot]$ beklenti (expectation) operatörünü temsil etmektedir ve Denklem 4, beklenti işleminin $\mathbf{H}$ üzerinden $\mathbf{y}$ koşuluyla gerçekleştirileceği anlamına gelir. Bu yaklaşım kanalın ve gürültünün istatistiksel özelliklerinin bilinmesini gerektirir ve özellikle zamanla değişen kanallar için daha karmaşık işlemlere ihtiyaç duyar [4]. Sonuç olarak kanal kestirimi problemi kanal matrisi, iletilen sinyal ve gürültü modeli kullanılarak matematiksel olarak ifade edilebilir. LS ve MMSE gibi kestirim teknikleri bu şekilde kanal matrisi $\mathbf{H}$ 'yi alınan sinyal $\mathbf{y}$ 'yi kullanarak tahmin etmek için farklı yaklaşımlar gösterir.

DL, kablosuz haberleşme sistemleri için kanal kestiriminde karşılaşılan zorluklara çözüm üretmek adına büyük bir potansiyele sahiptir. Derin öğrenmenin çözüm üretebileceği zorluklar kısaca şöyle özetlenebilir:

- *Doğrusal Olmama*: Geleneksel kanal kestirim teknikleri çoğunlukla kablosuz kanallardaki doğrusal olmayan ortamlarda zorluk yaşayan doğrusal modellere dayanır. Bu doğrusal olmama durumu çok yönlü yayılım, girişim ve kablosuz ortamın özellikleri gibi çeşitli faktörler nedeniyle ortaya çıkar. DL modelleri, özellikle sinir ağları, sahip oldukları katmanlı mimarilerden dolayı doğrusal olmayan bağlantıları ortaya çıkarmada büyük başarı gösterir. Büyük veri setleri ile eğitildikleri takdirde DL, bu doğrusal olmayan durumları modellemeyi etkili bir şekilde öğrenir ve daha doğru kanal kestirimleri gerçekleştirir [6].
- *Karmaşık Kanal Modelleri*: Pratikte karşılaşılan kanallar çoğunlukla zamanla değişen sönümlenme ve çok kullanıcı girişim gibi doğru bir matematiksel modelinin çıkarılmasının zor olduğu karmaşık davranışlar gösterir. DL teknikleri, belirgin bir kanal modeline ihtiyaç duymadan veriler üzerinden öğrenme işlemini uyarlanabilir şekilde yapabilir. Örneğin CNN modelleri kanal davranışını temsil eden özellikleri giriş verisi üzerinden öğrenirken RNN modelleri zamanla değişen kanalların zamana bağlı korelasyonlarını kolayca ortaya çıkarır [7]. Bu esneklik basit modellere bağlı geleneksel tekniklere göre çeşitli kanal durumları için daha iyi bir performansa imkan sağlar.
- *Çok Boyutlu Veriler*: Çoklu anten sistemlerindeki giriş verisinin çok boyutlu olması klasik kestirim teknikleri için büyük bir zorluk teşkil etmektedir. CNN gibi özellikle çok boyutlu verilerin işlenmesi için tasarlanmış DL mimarileri, asıl önemli olan bilgiyi kaybetmeden etkili bir şekilde boyut indirgeme yapabilir. Bu durum MIMO ve OFDM sistemlerinde daha dayanıklı kanal kestirimine olanak tanır.
- *Sınırlı Eğitim Verisi*: Pratik bir çok senaryoda DL modellerini eğitmek için etiketlenmiş verilerin elde edilmesi zorlayıcı bir süreçtir. Öğrenme aktarımı ve yarı denetimli öğrenme gibi teknikler benzer görevler için eğitilmiş mevcut modellerden yararlanarak sınırlı veriyle etkili bir kanal kestirimine imkan sağlayacak şekilde uygulanabilir [15]. Bu yaklaşımlar veri kıtlığı problemini azaltmaya yardım eder ve DL modellerinin dayanıklılığını artırır.
- *Gerçek Zamanlı İşlem*: Kablosuz haberleşme sistemleri yüksek performansın sağlanması için çoğunlukla gerçek zamanlı kanal kestirimine ihtiyaç duyar. DL modellerinin eğitim süreçleri işlemsel olarak zorlayıcı geçse de bir kere eğitilip hızlı çıkarımlar yapmaları için optimize edilebilirler. Model budama (pruning) ve nicemleme (quantization) gibi tekniklerden hesaplama yükünü azaltıp DL modellerini gerçek zamanlı uygulamalar için bir seçenek haline getirmek adına yararlanılabilir [16].

4. ÖNERİLEN DL MODELLERİ

DL modellerinden biri olan CNN, görüntü ve 2 boyutlu sinyal matrisleri gibi ızgara benzeri yapılara sahip verileri işlemek için özel olarak tasarlanmıştır. CNN modelleri, verilerdeki uzaysal hiyerarşiyi ortaya çıkarmada oldukça etkilidir. Bu durum onları desen tanımlama, görüntü sınıflandırma ve kablosuz haberleşmede kanal kestirimi gibi sinyal işleme görevleri için oldukça kullanışlı hale getirmektedir. CNN modellerinin genel mimarisi şu katmanlardan oluşur:

- *Giriş Katmanı (input layer, IL)*: Giriş katmanı görüntü ve sinyal matrisleri gibi 2 boyutlu ya da zaman serileri gibi 1 boyutlu ham veriyi alır. Kablosuz haberleşme özelinde bu, CSI ya da alınan sinyal verisi olur.
- *Evrişim Katmanları (convolutional layer, CL)*: Bu katmanlar filtreler (çekirdekler) kullanarak giriş verisine evrişim işlemleri uygular. Her filtre girdi üzerinde hareket ederek kenarlar, dokular ya da diğer desenler gibi özellikleri tespit eder. Evrişim işlemi veri içerisindeki uzaysal ilişkiyi koruyarak parametre sayısını azaltmaya yardım eder. Bu işlemin çıktısı olarak özellik haritaları elde edilir.
- *Aktivasyon Fonksiyonları*: Her evrişim işleminden sonra modele doğrusal olmama durumunu işleyebilmek için düzeltilmiş doğrusal birim (rectified linear unit, ReLU) gibi doğrusal olmayan aktivasyon fonksiyonu uygulanır ve bu sayede karmaşık desenler ve gösterimler öğrenilebilir.
- *Havuzlama Katmanları*: Genellikle maksimum havuzlama ve ortalama havuzlama tekniklerinden yararlanan havuzlama katmanları, özellik haritalarının boyutlarını azaltmak için kullanılır. Bu durum işlemsel karmaşıklığı azaltır ve önemli özellikleri koruyarak aşırı uyum (overfitting) sorununu önler.
- *Tam Bağlı Katmanlar*: Tam bağlı katmanlar evrişim ve havuzlama katmanları tarafından çıkarılan özellikleri birleştirerek tahminler üretir. Bu katmanlar klasik sinir ağlarına benzer ve bir katmandaki her bir nöronu sonraki katmandaki nöronlara bağlar.
- *Çıkış Katmanı (output layer, OL)*: Çıkış katmanı sınıflandırma, regresyon ya da kestirim görevi olabilecek son tahmin işlemini gerçekleştirir. Kanal kestirimi için çıkış, tahmin edilen kanal katsayılarını ya da kablosuz kanalın özelliklerini temsil edebilir.


Tablo 1. DL modellerine ait katman yapıları

	Model-1 (MATLAB)		Model-2		Model-3		Model-4		Model-5	
Katman Sayısı	10		12		16		18		20	
Öğrenilen Parametre Sayısı	262.2k		1M		1M		1.2M		1.1M	
Katman Yapıları	IL	(612, 14, 1)	IL	(612, 14, 1)	IL	(612, 14, 1)	IL	(612, 14, 1)	IL	(612, 14, 1)
	CL1	(9x9, 64) str [1 1] pad [4 4 4 4]	CL1	(7x7, 128) str [1 1] pad [3 3 3 3]	CL1	(7x7, 128) str [1 1] pad [3 3 3 3]	CL1	(7x7, 128) str [1 1] pad [3 3 3 3]	CL1	(11x11, 96) str [1 1] pad [5 5 5 5]
	ReLU		ReLU		BNL, ReLU		BNL, ReLU		BNL, LReLU(1e-4)	
	CL2	(5x5, 64) str [1 1] pad [2 2 2 2]	CL2	(5x5, 128) str [1 1] pad [2 2 2 2]	CL2	(5x5, 128) str [1 1] pad [2 2 2 2]	CL2	(5x5, 128) str [1 1] pad [2 2 2 2]	CL2	(5x5, 128) str [1 1] pad [2 2 2 2]
	ReLU		ReLU		BNL, ReLU		BNL, ReLU		BNL, LReLU(1e-4)	
	CL3	(5x5, 64) str [1 1] pad [2 2 2 2]	CL3	(5x5, 128) str [1 1] pad [2 2 2 2]	CL3	(5x5, 128) str [1 1] pad [2 2 2 2]	CL3	(5x5, 128) str [1 1] pad [2 2 2 2]	CL3	(5x5, 128) str [1 1] pad [2 2 2 2]
	ReLU		ReLU		BNL, ReLU		BNL, ReLU		BNL, LReLU(1e-4)	
	CL4	(5x5, 32) str [1 1] pad [2 2 2 2]	CL4	(5x5, 64) str [1 1] pad [2 2 2 2]	CL4	(5x5, 64) str [1 1] pad [2 2 2 2]	CL4	(5x5, 64) str [1 1] pad [2 2 2 2]	DRL(%30)	
	ReLU		ReLU		BNL, ReLU		CL4 (1)	(5x5, 64) str [1 1] pad [2 2 2 2]	CL4	(5x5, 64) str [1 1] pad [2 2 2 2]
	CL5	(5x5, 1) str [1 1] pad [2 2 2 2]	CL5	(5x5, 32) str [1 1] pad [2 2 2 2]	CL5	(5x5, 32) str [1 1] pad [2 2 2 2]	CL4+CL4(1)		CL4 (1)	(5x5, 64) str [1 1] pad [2 2 2 2]
	OL	(612, 14, 1)	ReLU		ReLU		BNL, ReLU		CL4+CL4(1)	
			CL6	(5x5, 1) str [1 1] pad [2 2 2 2]	CL6	(5x5, 1) str [1 1] pad [2 2 2 2]	CL5	(5x5, 32) str [1 1] pad [2 2 2 2]	BNL, LReLU(1e-4)	
			OL	(612, 14, 1)	OL	(612, 14, 1)	ReLU		DRL(%30)	
							CL6	(5x5, 1) str [1 1] pad [2 2 2 2]	CL5	(5x5, 32) str [1 1] pad [2 2 2 2]
							OL	(612, 14, 1)	LReLU(1e-4)	
									CL6	(5x5, 1) str [1 1] pad [2 2 2 2]
									OL	(612, 14, 1)

CNN modelleri kanal kestirim problemleri için oldukça etkilidir çünkü giriş verisinden kanal modeli hakkında herhangi bir ön bilgiye ihtiyaç duymadan CSI gibi karmaşık uzaysal ilişkileri kolaylıkla öğrenebilir. Bu özellik

CNN modellerini DL tabanlı haberleşme sistemleri için kullanışlı bir araç haline getirir. Bundan dolayı çalışmamızda kanal kestirimi için CNN modeli kullanılmıştır.

Bir tanesi MATLAB tarafından kullanılan model olmak üzere toplamda beş adet modele ait performans karşılaştırması yapılmıştır. Kullanılan modellere ait katman yapıları Tablo 1’de detaylı şekilde verilmiştir. Referans olarak alınan Model-1’e göre performansı iyileştirmek üzere 4 farklı model oluşturulmuştur. Model-2 için katman sayısı artırılıp bazı evrişim katmanlarında filtre sayıları, filtre boyutları ve dolgulama (padding, pad) değerleri değiştirilmiştir ancak adım aralığı (stride, str) değerlerine dokunulmamıştır. Normalizasyonun etkisini görebilmek için Model-2’den Model-3’e geçerken sadece aktivasyon işlemlerinden önce toplu normalleştirme katmanları (batch normalization layer, BNL) eklenmiştir. Model-4 ve Model-5’te atlama bağlantısı (skip connection) kullanılarak CL4(1) üzerinden bu işlem gerçekleştirilmiştir. Ayrıca Model-5’te aktivasyon fonksiyonu olarak ReLU yerine sızdırılan ReLU (leaky ReLU, LReLU) aktivasyon fonksiyonu kullanılıp bazı seyreltme katmanları (dropout layer, DRL) da eklenmiştir. Modellere ait mimariler Şekil 2’de gösterildiği gibidir.



Şekil 2. DL modellerine ait mimariler.

Kanal kestirimi yapılması amacıyla MATLAB 5G Toolbox kullanılarak SISO için fiziksel aşağı yönlü bağlantı paylaşımlı kanal (physical downlink shared channel, PDSCH) demodülasyon referans sinyali (demodulation reference signal, DM-RS) üretilmiştir [17-21]. Giriş katmanındaki verinin boyutu sırasıyla alt taşıyıcı, OFDM sembolü ve anten sayısı olmak üzere 612x14x1’dir. Karmaşık sayılardan oluşan bu veri gerçek ve sanal olmak üzere iki parçaya ayrılıp modellerin eğitilmesi sağlanır.

Yukarıda da belirtildiği gibi modellerin eğitimi için kullanılan veri seti, standartlardaki 5G NR sistemi için MATLAB kullanılarak üretilmiştir. Tablo 1’de detaylı bir şekilde verilen parametrelerle modellerin eğitimi gerçekleştirilirken eğitim ve doğrulama setlerine ait ortalama karesel hatanın karekökü (root mean square error, RMSE) ve kayıp değerleriyle süreç takip edilmiştir. Son olarak da kanal kestiriminin performansını karşılaştırmak için ortalama karesel hata (mean square error, MSE) kullanılarak gerçek kanal ile interpolasyon (MSE_I), LS pratik kestirim (MSE_P) ve derin öğrenme (MSE_N) sonucu karar verilen kanal arasındaki değerlerine bakılmıştır.

5. SİMÜLASYON KURULUMU

Tüm simülasyonlar için MATLAB 2024a kullanılmıştır. İlgili derin öğrenme modellerinin verimli bir şekilde çalışması için yararlanılan donanım ekipmanları ise Intel i7 13700KF merkezi işlem biriminden (central processing unit, CPU), 32 GB rastgele erişimli bellekten (random access memory, RAM) ve tek bir NVIDIA GeForce RTX 4070Ti GPU’dan oluşmaktadır. Modülasyon türü, SNR değeri, kanal karakteristikleri vb. parametreler Tablo 2’de detaylı bir şekilde verilmektedir. Örnek sayısı 256 ve 512 adet alınarak DL tabanlı kanal kestirimine etkisi

gözlemlenmeye çalışılmıştır. DL modellerinin aşırı uyum sorunu yaşamaması için üretilen veri seti eğitim ve doğrulama seti olarak ayrılıp eğitilen modelin performansı belli aralıklarla doğrulama seti üzerinden gözlemlenmektedir. Veri seti boyutunun küçük olmasından dolayı doğrulama setinin büyüklüğü olarak parametrelerde belirtilen yığın boyutu (batch size) seçilmiştir. Bu yığın boyutu değerine göre belirlenen doğrulama sıklığı (validation frequency) adındaki bir iterasyon sayısı ile ilgili doğrulama metrikleri çalıştırılır. Ayrıca doğrulama seti üzerinden kayıp değerine bakılmakta ve erken durdurma kriteri (validation patience) ile belirlenen dönem (epoch) boyunca iyileşme görülmediği takdirde eğitim süreci durdurulmaktadır. DL modeli sonunda elde edilen ve pratik kanal kestirimleri, gerçek kanal ile aralarındaki MSE değerleri üzerinden karşılaştırılmaktadır.

Tablo 2. Veri seti içeriğine ait parametreler

Parametre	Değer	Parametre	Değer
Verici		OFDM Alt Taşıyıcı	
Anten Sayısı	1	Sayısı	612
Alıcı		OFDM Sembol Sayısı	14
Anten Sayısı	1		
Muhtemel Kanal Profilleri	TDL-A, TDL-B, TDL-C, TDL-D, TDL-E	Δ_f	30 kHz
Kanal		PDSCH Modülasyon	
Gecikme Yayılımı	[1, 300] ns	Türü	QAM16
Maksimum		SNR	[0, 10] dB
Doppler Kayması	[5, 400] Hz		
OFDM RB Sayısı	51		

*özkaynak bloğu (resource block, RB), alt taşıyıcı aralığı (subcarrier spacing, Δ_f)

6. SİMÜLASYON ÇIKARIMLARI

Tablo 3'te detaylı bir şekilde verilen parametreler ile toplamda 300 adet simülasyon gerçekleştirilmiştir. Bu simülasyonlarda örnek sayısının, yığın boyutunun, eniyileycinin (optimizer) ve ilk öğrenme oranının (initial learning rate) etkileri incelenmiştir. Şekil 3'te elde edilen simülasyon sonuçları toplu bir şekilde verilmektedir. Bu şekildeki kırmızı, mavi ve yeşil dolgular kötüden iyiye doğru giden bir performans değerlendirmesini göstermektedir. Ayrıca erken durdurma kriteri sütunlarında yer alan yeşil metin rengindeki simülasyonlara eğitim sürecinin, gerekli iyileşme olmadığı için erken durduğu göz önünde bulundurulmalıdır.

Eğitilen model kanal kestirimi tahmini yaparken interpolasyon işleminden geçirilen sinyali kullanır. Bu sinyal, alıcıda alınan sinyal üzerinden pilot sembollerinin yerleri kullanılıp interpolasyon yapılarak elde edilir. Şekil 3'te MSE_I olarak gösterilen interpolasyonla elde edilen kanal ile gerçek kanal arasındaki MSE değerlerine bakıldığı zaman beklendiği gibi tüm modeller için en kötü performansa sahip oldukları gözlenmektedir.

Tablo 3. Simülasyon parametreleri

Parametre	Değer	Parametre	Değer
Örnek Sayısı	256, 512	İlk Öğrenme Oranı	0.0001, 0.0003
Yığın Boyutu	4, 8, 16, 32, 64	Toplam Dönem Sayısı	10
Eniyileyici	adam, sgdm, rmsprop	Erken Durdurma Kriteri (dönem)	5

Karşılaştırılan bir diğer parametre Şekil 3'te MSE_P ile gösterilen ve klasik kanal kestirim yöntemlerinden olan LS ile gerçek kanal arasındaki MSE değeridir. DL tabanlı kanal kestirimiyle gerçek kanal arasındaki MSE değeri olan MSE_N, karşılaştırılan temel değerlerden bir diğeridir. Şekil 3'ün geneline bakıldığı zaman kullanılan simülasyon parametreleri değiştikçe MSE_P ve MSE_N değerlerinin birbirlerine karşı sağladığı üstünlük de değişmektedir. Bunun nedeni olarak veri seti üretilirken Tablo 2'de belirtilen kanal gecikme yayılımı, maksimum Doppler kayması ve kanal modellerinden birinin rastgele seçiliyor olması gösterilebilir. Çünkü kanal kestirimi yapılırken kullanılan sinyal, veri seti üretilirken kullanılan parametrelerden farklı parametrelere sahip olmaktadır. Klasik kanal kestirimleri bu gibi durumlara karşı ortalama bir performans gösterirken DL tabanlı sistemlerdeki modellerin hangi veriyle eğitildiği ve bu eğitimin ne kadar geliştirilmiş olduğu performanslarını büyük ölçüde etkilemektedir.

Beş modelin hepsinde de MSE_N'nin en düşük değeri aldığı parametre seti bir tane olmak üzere örnek sayısı, yığın boyutu, eniyileyici ve ilk öğrenme oranı için sırasıyla 512, 4, adam ve 0.0003 değerlerinde gerçekleşmiştir. Bunun tam tersi olarak MSE_P'nin tüm modellerde en düşük değeri aldığı birçok parametre seti mevcuttur. Bunların arasında olan setlerin simülasyon numaraları 8, 13-15, 17-20, 24, 25, 30, 45, 47-50'dir. Bunun nedeni olarak yukarıda da belirtilen klasik kanal kestiriminin tüm koşullara karşı ortalama bir performans göstermesi için tasarlanmış olması gösterilebilir.

Örnek sayısı açısından yapılan simülasyonlar değerlendirilecek olursa her iki durumda da DL tabanlı kanal kestiriminin pratik kanal kestiriminin gerisinde kaldığı görülmektedir. DL tabanlı kanal kestirimine kendi içerisinde bakılacak olursa da örnek sayısı 256'dan 512'ye çıkarıldığında daha iyi performans sergiledikleri görülmüştür. Bu durum DL modellerinin ne kadar çok ve farklı veriyle beslenirse daha iyi sonuç verdiği gerçeğini

hassas bir şekilde tasarlandığı zaman dinamik koşullara daha etkili bir şekilde uyum sağladığını ve geleneksel yöntemlere göre daha düşük kestirim hataları sunduğunu ortaya koymuştur. Uygun hiperparametrelerle DL modellerinin işlem karmaşıklığının azaltılabileceği ve bu sayede gerçek zamanlı uygulamalarda verimli bir şekilde kullanılabileceği gösterilmiştir. Gelecek çalışmalar kapsamında BER ve MSE analizleri eksiksiz bir haberleşme sistemi çerçevesinde incelenerek bu çalışmadaki bulgular genişletebilir. DL tabanlı kanal kestiriminde MIMO gibi farklı veri çeşitliliklerini içeren daha geniş veri setlerinin kullanılması, performansın daha da iyileştirilmesi açısından önem taşımaktadır. Ayrıca, DL modellerinin mobil ve hızlı değişen kanallara daha hızlı uyum sağlayabilmesi için öğrenme aktarımı (transfer learning) gibi tekniklerin araştırılması yararlı olabilir. Son olarak, yapay zeka tabanlı kestirim tekniklerinin enerji verimliliğini artırmak ve farklı kanal koşullarında daha az hesaplama gücü ile daha iyi sonuçlar elde etmek amacıyla düşük güç tüketen donanımlara entegrasyonu gelecekte önemli bir araştırma alanı olarak karşımıza çıkmaktadır.

Yazar Katkıları

Bu çalışmanın tüm aşamaları, her iki yazarın ortak katkılarıyla gerçekleştirilmiş olup, araştırma, veri analizi, sonuçların değerlendirilmesi ve yazım süreci birlikte yürütülmüştür.

Çıkar Çatışması

Makalenin yazarları, bu çalışmanın yürütülmesi ve yayımlanması sürecinde herhangi bir çıkar çatışması bulunmadığını beyan etmektedirler.

KAYNAKÇA

- [1] D. Tse and P. Viswanath, Fundamentals of Wireless Communication, Cambridge Univ. Press, Cambridge, U.K., 2005.
- [2] Y. Li and G.L. Stüber, "Orthogonal Frequency Division Multiplexing for Wireless Communications," in Signals and Communication Technology, Springer, New York, NY, 2006.
- [3] T. Rappaport, Wireless Communications Principles and Practice, 2nd ed., Prentice Hall PTR, Upper Saddle River, NJ, 2001.
- [4] S.M. Kay, Fundamentals of Statistical Signal Processing, Volume I: Estimation Theory, 1st ed., Pearson, Boston, MA, 1993.
- [5] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning, MIT Press, Cambridge, MA, 2016.
- [6] C.K. Wen, W. T. Shih, and S. Jin, "Deep learning for massive MIMO CSI feedback," IEEE Wirel. Commun. Lett., vol. 7, no. 5, pp. 748–751, Oct. 2018.
- [7] H. Ye, G.Y. Li, and B.H. Juang, "Power of deep learning for channel estimation and signal detection in OFDM systems," IEEE Wirel. Commun. Lett., vol. 7, no. 1, pp. 114–117, Feb. 2018.
- [8] M. Belgiovine, K. Sankhe, C. Bocanegra, D. Roy, and K. R. Chowdhury, "Deep learning at the edge for channel estimation in beyond-5G massive MIMO," IEEE Wirel. Commun., vol. 28, no. 2, pp. 19–25, Apr. 2021.
- [9] P. Saikrishna, A.K.R. Chavva, M. Beniwal, and A. Goyal, "Deep learning-based channel estimation with flexible delay and Doppler networks for 5G NR," in Proc. IEEE Wirel. Commun. Netw. Conf. (WCNC), IEEE, 2021.
- [10] P.K. Chundi, X. Wang, and M. Seok, "Channel estimation using deep learning on an FPGA for 5G millimeter-wave communication systems," IEEE Trans. Circuits Syst. I, Reg. Papers, vol. 69, no. 2, pp. 908–918, Feb. 2022.
- [11] A.S.M. Mohammed, A.I.A. Taman, A.M. Hassan, and A. Zekry, "Deep learning channel estimation for OFDM 5G systems with different channel models," Wirel. Pers. Commun., vol. 128, no. 4, pp. 2891–2912, Feb. 2023.
- [12] X. Guo, X. Liu, and X. Gong, "Deep learning based channel estimation for 5G," in Proc. 6th Int. Conf. Inf. Commun. Signal Process. (ICICSP), IEEE, 2023, pp. 700–705.
- [13] Y. Singh, P. Swami, V. Bhatia, and P. Brida, "Channel estimation in 5G and beyond networks using deep learning," in Proc. 34th Int. Conf. Radioelektronika (RADIOELEKTRONIKA), IEEE, 2024.
- [14] S.S. Haykin, Adaptive Filter Theory, 5th ed., Pearson, Boston, MA, 2014.
- [15] C.T. Nguyen et al., "Transfer learning for wireless networks: A comprehensive survey," Proc. IEEE, vol. 110, no. 8, pp. 1073–1115, Aug. 2022.
- [16] Y. Cheng, D. Wang, P. Zhou, and T. Zhang, "Model compression and acceleration for deep neural networks: The principles, progress, and challenges," IEEE Signal Process. Mag., vol. 35, no. 1, pp. 126–136, Jan. 2018.
- [17] TSGR, TS 138 214 - V16.2.0 - 5G; NR; Physical layer procedures for data (3GPP TS 38.214 version 16.2.0 Release 16), 2020. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.
- [18] TSGR, TS 138 212 - V16.2.0 - 5G; NR; Multiplexing and channel coding (3GPP TS 38.212 version 16.2.0 Release 16), 2020. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.
- [19] TSGR, TS 138 211 - V16.2.0 - 5G; NR; Physical channels and modulation (3GPP TS 38.211 version 16.2.0 Release 16), 2020. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.
- [20] TSGR, TR 138 901 - V16.1.0 - 5G; Study on channel model for frequencies from 0.5 to 100 GHz (3GPP TR 38.901 version 16.1.0 Release 16), 2020. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.
- [21] TSGR, TS 138 213 - V16.2.0 - 5G; NR; Physical layer procedures for control (3GPP TS 38.213 version 16.2.0 Release 16), 2020. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.