



KABLOSUZ İLETİŞİM SİSTEMLERİ İÇİN MAKİNA ÖĞRENİMİ DESTEKLİ ALTERNATİF SEZİCİ TASARIMI

Ahmet EMİR*, Ferdi KARA, Hakan KAYA

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü,
Zonguldak, Türkiye

Anahtar Kelimeler	Öz
<i>CNN,</i> <i>QPSK,</i> <i>BSPK,</i> <i>ML,</i> <i>Derin Öğrenme.</i>	Son yıllarda derin öğrenme (deep learning-DL) teknikleri fiziksel seviye iletişim sistemlerinde yaygın olarak kullanılmaktadır. DL teknikleri, modern haberleşme sistemlerindeki işlem karmaşıklığını azaltmasından ve daha iyi başarımlar sağlaması gibi nedenlerden dolayı hali hazırda var olan haberleşme yöntemlerine alternatif seçenekler sunmaktadır. Bu çalışmada, Rayleigh sönümlenmeli kanalda ikili faz kaydırmalı anahtarlama (binary phase shift keying-BPSK) veya dördün faz kaydırmalı anahtarlama (quadrature phase shift keying-QPSK) modülasyonu kullanılması durumunda alıcıya ulaşan işaretin işaret yıldız kümesi görüntüsünden, gönderilen işaretin DL ile kestirimi hedeflenmiştir. DL tekniklerinden olan evrişimli sinir ağı (convolutional neural network -CNN) girişine alıcıya gelen işaretin ve denkleştirilmiş işaretin işaret yıldız kümesi görüntüsü uygulanmıştır. CNN sınıflandırıcı ile bulunan sistemin hata başarımları klasik en büyük olasılıklı sezici (maximum likelihood-ML) başarımları ile karşılaştırılmıştır. İşaret yıldız kümesinde farklı boyutlarda bölgeler seçilmiştir. Bu bölgelerin her biri ayrı senaryo olarak değerlendirilir. Belirli senaryolar altında bu bölgelerin CNN sınıflandırıcı ile elde edilen hata başarımları ile ML hata başarımları ile benzer çıktığı görülmüştür.

MACHINE-LEARNING AIDED ALTERNATIVE DETECTOR DESIGN FOR WIRELESS COMMUNICATIONS SYSTEMS

Keywords	Abstract
<i>CNN,</i> <i>QPSK,</i> <i>BPSK,</i> <i>ML,</i> <i>Deep Learning.</i>	In recent years, deep learning (DL) techniques are widely used for physical layer solutions in communication systems. DL techniques offer alternative options to existing communication methods since they can reduce the computational complexity and provide better performance in modern communication systems. In this study, we propose a DL-aided signal detections for BPSK (Binary Phase Shift Keying) or QPSK (Quadrature Phase Shift Keying) modulation over Rayleigh fading channel where the DL-aided detection is performed based on the constellation diagram image of the received signal. The constellation diagram image of received signal and the equalized signal are given as inputs to the convolutional neural network (CNN), which is one of the commonly used DL techniques, Regions of different sizes are selected in the constellation diagram. Each of these regions is considered as different scenarios. The error performance of the system obtained with the CNN classifier is compared with the classical maximum likelihood (ML) detector performance. Under certain scenarios, it has been revealed that the DL-aided signal detection could achieve the performance of the ML detector which shows the effectiveness of the proposed solution.

Alıntı / Cite

Emir, A., Kara, F., Kaya, H., (2021). Kablosuz İletişim Sistemleri İçin Makina Öğrenimi Destekli Alternatif Sezici Tasarımı, Mühendislik Bilimleri ve Tasarım Dergisi, 9(2), 381-388.

* İlgili yazar / Corresponding author: ahmet.emir@beun.edu.tr, +90-372-291-1526

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process	
A. Emir, 0000-0001-8038-2747	Başvuru Tarihi / Submission Date	03.02.2021
F. Kara, 0000-0001-9735-5200	Revizyon Tarihi / Revision Date	01.04.2021
H. Kaya, 0000-0003-4390-5363	Kabul Tarihi / Accepted Date	04.05.2021
	Yayın Tarihi / Published Date	20.06.2021

1. Giriş (Introduction)

Uçtan-uca iletişim sistemlerinin tasarımı ve analizi, işaret iletimi, işaret yayılımı, alıcı gürültüsü vb. diğer bileşenlerinin çoğunu tanımlayan matematiksel modellerin geliştirilmesine dayanır. Uçtan uca kablosuz iletişim sistemlerinin temelinde, bir mesaj işaretinin alıcıda mükemmel bir şekilde kestirilebilmesi için kanal bozulmalarına dirençli bir şekilde gönderilmesi ve alınması hedeflenmektedir. Bu hedefler doğrultusunda haberleşme sistemlerinin alıcı ve verici kısımları kaynak kodlama, kanal kodlama, modülasyon, demodülasyon, denkleştirme vb. alt görevlere ayrılmıştır. Derin öğrenme (deep learning- DL) yardımcı sistemlerin uçtan-uca haberleşme sistemlerinde kullanımı ilk kez (Dorner vd., 2018)'te önerilmiştir. Son zamanlarda ise literatürde değişik amaçlarla, farklı derin ağlardan yararlanılarak kullanımı yaygınlaşmıştır. Bu farklı DL ağları, evrimsimli sinir ağları (convolutional neural network-CNN), uzun kısa dönem hafıza (long short term memory- LSTM), derin öğrenme takviyeli (deep reinforcement learning-DRL), otomatik kodlayıcı (autoencoders-AE), üretken rakip ağlar (generative adversarial nets-GAN) olarak sıralanabilir. (Ye vd., 2020)'de uçtan-uca haberleşme sistemlerinin tüm modellerinin tasarımı GAN'lar ile yapılmıştır. (Peng vd., 2017)'de haberleşme sistemlerinde modülasyon sınıflandırması için CNN'den faydalanılmıştır. (Lu vd.,2019)'da ise farklı sönümlenmeli kanal (Rayleigh, Rician, vb.) modellerine göre modülasyon sınıflandırma doğruluğu incelenmiştir. (Soltani vd.,2019)'da CNN dikgen frekans bölmeli çoğullama (orthogonal frequency division multiplexing-OFDM) sistemlerinde kanal kestirimi için kullanılmıştır. Yine OFDM için kanal kestirimi ile işaret kestirimi LSTM ağlar kullanılarak gerçekleştirilmiştir (Ye vd.,2018). OFDM ile sınırlı olmamakla birlikte diğer çeşitli kablosuz iletişim sistemlerinde de işaret kestirimi için matematiksel modeller yerine DL ağları kullanmak alternatif hale gelmiştir (Jiang vd.,2020;Farsad ve Goldsmith,2018;Xu vd.,2020). (Wu vd.,2019)'da rasgele blok uzunluklu akıllıca çalışabilen, farklı çıkış hızlarını destekleyebilen ve toplanır beyaz gauss gürültüsü (additive white gaussian noise-AWGN) ile Rayleigh sönümleme kanallarında çalışabilen yeni bir CNN tabanlı AE iletişim sistemi önerilmiştir. Bu gibi çalışmaların ötesinde DL ağlar, büyük ölçekli çoklu-giriş-çoklu-çıkış haberleşme sistemleri için de bir alternatiftir (Yuan vd.,2020;Zhenyu vd.,2020;Hojatian vd.,2020;Jiajia vd.,2020). DL aynı zamanda 5. Nesil (5G) haberleşme sistemleri için dikgen olmayan çoklu erişim (non orthogonal multiple Access-NOMA) tekniklerinde sinyal kestirimi için kullanılmıştır (Emir vd., 2019;Gui vd., 2018;Lin vd., 2019). Öte yandan NOMA sistemlerinde sinyal kestiriminin dışında güç atama (Wang vd.,2020), kaynak atama (Xu vd.,2020), sistem çıkış hızı (throughput) artırma (Zhang vd.,2020) işlemlerinde DL ağlarına başvurulmuştur. Ayrıca görünür ışık modülasyonu (Xiao vd.,2019), milimetre dalga iletişimi (Alrabeiah ve Alkhateeb,2020) ve indis modülasyonu (Luong vd., 2019) vb. pek çok güncel alanda da DL kullanımı yaygınlaşmaya başlamıştır.

Bu çalışmada, alıcıda gerçekleştirilen işaret kestirimi için yeni bir yöntem olan DL-CNN ağı önerilmiştir. Bu çalışmada önerilen yöntemde, geleneksel haberleşme sistemleri alıcılarında kullanılan en büyük olabirlikli sezici (maximum likelihood-ML) gibi işaret sezim yöntemlerinin aksine, alıcıya ulaşan sinyalin işaret yıldız kümesi görüntüsünden işaret sezilmeye çalışılmaktadır. BPSK ve QPSK modülasyonlu Rayleigh sönümlenmeli kanalın var olduğu sistemde alıcıda CNN sınıflandırıcı kullanılmasıyla giriş sinyalinin demodülasyonu/kestirimi gerçekleştirilmiştir. Kanalın alıcıda bilindiği varsayılarak; CNN sembol sembol eğitilmiştir. Bu çalışmada alıcıda sinyal tespiti için görüntüler üzerinde çalışan 3 katmanlı CNN ağı kullanılmıştır. CNN ağı ile sinyal kestirimindeki hata başarımı, klasik ML ise sinyal sezimdeki hata başarımı ile benzerdir.

Çalışmanın bundan sonraki bölümleri aşağıdaki gibi sunulmuştur. Bölüm 2'de sistem modeli ve DL parametreleri açıklanmıştır. Bölüm 3'te simülasyon sonuçları verilmiştir. Bölüm 4'te ise elde edilen sonuçlar değerlendirilmiştir ve literatüre katkı sağlayacak avantajları açıklanarak gelecek çalışmalara yer verilmiştir

2. İşaret Modeli (Signal Model)

Bu çalışmada bir kullanıcı (user equipment-UE) ve bir baz istasyonundan (Base Station-BS) bir aşağı yönlü (downlink) haberleşme sistemi düşünülmüştür. BS'den gönderilen işaret:

$$y = \sqrt{P}xh + n \quad (1)$$

ile ifade edilmektedir.


Burada x UE'nin mesaj işareti (m) modülasyonlu halidir. P baz istasyonunun toplam iletim gücüdür.h, BS ile UE

arasındaki σ^2 varyanslı Rayleigh sönümlenme katsayısı olup, n alıcıda $N_0/2$ spektral yoğunluğa sahip AWGN'dir. Alıcıya gelen işarete kanal etkisinin azaltılması için, kanal denkleştirme işlemi

$$y_{eq} = \frac{y}{h} \quad (2)$$

olarak verilir.

Tek sembol üzerinden veri gönderildiğinde y ve y_{eq} birlikte gösterilerek, alıcıdaki işaret yıldız kümesi görüntüsünün bir örnek modeli Şekil 1'de verilmiştir. Dairesel çizim y 'yi, karesel çizim y_{eq} 'i ifade etmektedir. İşaret diyagramında y ve y_{eq} kendi genlikleri ile normalizasyon yapılarak belirli bir genişlik ve uzunlukta görüntü formatına dönüştürülmüştür. Böylelikle; alıcıya gelen işaret ve denkleştirilmiş işareten alıcıda hangi bitlerin gönderildiğinin tespit edilmesi hedeflenmiştir. Bu sebeple gelen işaretin ve kanal denkleştirilmiş işaretinin işaret yıldız kümesinin 8 bit gri ölçekli görüntüsü CNN ağına giriş olarak verilmektedir.



Şekil 1. y ve y_{eq} 'in İşaret Yıldız Kümesi (Signal Constellation of y and y_{eq})

BPSK ve QPSK modülasyon türleri için, işaret gürültü oranının (İGO) 10dB olduğu durumda alıcıya ulaşan sinyale göre elde edilen CNN giriş verileri için örnekler Şekil 2'de verilmiştir. CNN, modülasyon türüne göre BPSK modülasyonu için 2 sınıf (0,1), QPSK modülasyonu için 4 sınıf (0,1,2,3) üzerinden verileri eğitir. Bu sınıf değerleri, BPSK'da sırasıyla {0} ,{1}; QPSK'da {00} ,{01}, {10} ve {11} mesaj işaretlerinin birer temsilidir. Sınıf değerleri (S) uçtan-uça haberleşme sisteminde vericiden gönderilen mesaj işaretlerinin (m) ondalık karşılığını ifade ettiğini gösterir. CNN, QPSK mesaj işaretinde 2 bit veri olduğu ve 4 ayrı mesaj işareti seçeneği olduğundan ötürü 4 sınıf üzerinden, BPSK için ise mesaj işaretinde 1 bit veri olduğu ve 2 ayrı mesaj işareti seçeneği olduğundan ötürü 2 sınıf üzerinden işaret kestirimi yapmaktadır. CNN ağında BPSK ve QPSK hem iki hem de dört sınıfı eğitim seçeneği mümkün olmadığından iki ayrı sınıflandırma için iki ağ gereklidir. Bu sebeple BPSK ve QPSK için birbirleri ile benzer iki CNN ağı kurgulanmıştır.

3. Önerilen CNN Modeli (Proposed CNN Model)

Gönderilen sinyalin kestirimi için, işaret yıldız kümesi görüntüsünün özneteliklerinin çıkarılması gereklidir. Bu işlemi gerçekleştiren DL ağlarından birisi de CNN ağlarıdır. CNN ağları 1988 yılında Yann LeCun tarafından geliştirilen LeNet mimarisine dayanır (Cun vd.,1989). Çalışmamızda kullanılan CNN ise, Şekil 3'te gösterildiği üzere 3 katmanlı yapıdadır. Her bir CNN katmanı konvolüsyon filtresi, yığın normalizasyonu (Batch Normalization-BN), aktivasyon fonksiyonu ve maksimum havuzlama (max pooling) katmanlarından oluşmaktadır.

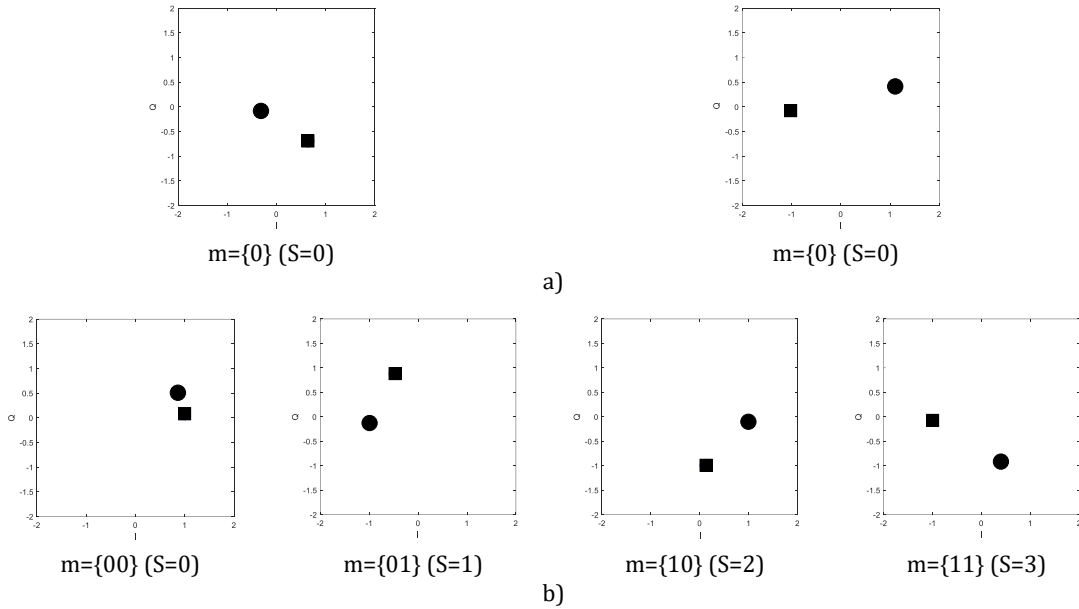
Konvolüsyon filtreleri, işaret yıldız kümesi görüntüsünde 3×3 'lük bölgeler seçilerek oluşturulan alanların öznetelik çıkarma çekirdek işlemleri (kernel) ile konvolüsyon işlemlerini yerine getirmektedir (Albawi vd., 2018). Buradaki konvolüsyon işlemi bu mikro alanlardaki görüntülerin kendi uyarısına verdiği cevaptır.

BN, aktivasyon fonksiyonu ile konvolüsyon katmanı arasında kullanılmaktadır (Sledevic,2019). BN, her bir mini grup (mini batch) için girdileri bir katmana standartlaştıran derin sinir ağlarını eğitmek için bir tekniktir. Ayrıca, öğrenme sürecini stabilize etme ve derin ağları eğitmek için gereken eğitim dönemi sayısını (epoch) önemli ölçüde

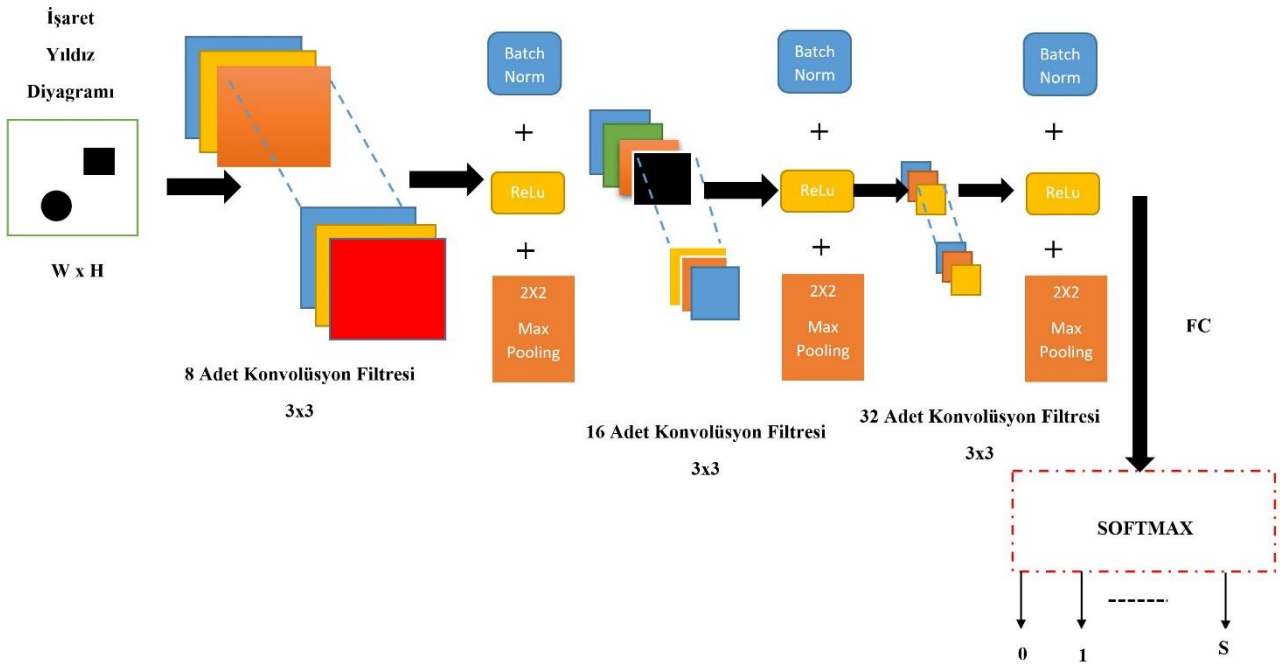
azaltma etkisine sahiptir. Bu katmanda her bir eğitim örneği için, ilk önce konvolüsyon sonucu elde edilen veriden grup ortalaması (μ) kadar çıkarılıp; sonrasında çıkan değer grup varyansına (σ_Y^2) bölünmektedir. Çıkan sonuç öğrenilir β parametresi kadar kaydırılıp ve öğrenilir γ uyarınca ölçeklenmektedir. BN işlemlerinin matematiksel ifadeleri Eşitlik (3) ve (4)'te gösterilmiştir.

$$Y' = \frac{Y - \mu}{\sqrt{\sigma_Y^2}} \quad (3)$$

$$Y'' = \gamma Y' + \beta \quad (4)$$



Şekil 2. Modülasyon türüne göre a) BPSK için 2 sınıf (0, 1) CNN giriş verileri, b) QPSK için 4 sınıf (0, 1, 2, 3) (According to Modulation Type a) 2 class (0,1) for BPSK input data b) 4 class (0,1,2,3) for QPSK input data)



Şekil 3. CNN Sistem Modeli (CNN System Model)

(3) 'te Y konvolüsyon çıkışlarını göstermektedir.

BN işlemlerinin ardından aktivasyon fonksiyonu olarak ReLu işlevi kullanılmıştır. ReLu fonksiyonu Eşitlik (5)'teki gibidir:

$$f(Y^n) = \begin{cases} 0 & , Y^n < 0 \\ Y^n & , Y^n \geq 0 \end{cases} \quad (5)$$

Eşitlik (5)'te görüldüğü üzere Y^n , BN işlemlerinin çıkışıdır.

Maksimum havuzlama, örnek tabanlı bir ayırıklaştırma sürecidir. Maksimum havuzlamanın amacı, bir girdiden (görüntü, matris, gizli katman çıkışı vs.) örnek seyrelterek örnek sayısını azaltmaktır. Böylelikle alt bölgelerdeki özellikler hakkında varsayımlar yapılabilir. Bu çalışmada 2x2 maksimum havuzlama işlevi, ReLu işlevi sonucunda bulunan sonuçtan 2x2 dikdörtgensel bölgeler olarak bu bölgelerdeki en büyük değeri yeni sonuç matrisine kaydetmektedir.

İlk CNN katmanında 8, ikinci CNN katmanında 16, üçüncü CNN katmanında 32 adet konvolüsyon filtresi bulunmaktadır. Fazla sayıda konvolüsyon filtrelerinin kullanılmasının sebebi işaret diyagram görüntüsündeki kare ve daire piksellerinin görüntüye göre küçük bir bölgede yer alması dolayısıyla öznelik çıkarma zorluğundan kaynaklanmaktadır.

CNN katmanlarından sonra tam bağlı katmanı (fully connected layer-FC) yer almaktadır. FC katmanı öznelik elde etme işlemleri sonrası elden edilen sonucu belirli bir ağırlık matrisi ile çarpıp ve son-eşik (bias) ekler.

En son katman, normalizasyonlu üstel fonksiyonu olarak da bilinen softmax katmanıdır. Softmax, bir ağın çıktısını çıktı sınıfları üzerinden bir olasılık dağılımına normalleştirir. Örneğin K bir eğitim örneğindeki mini grup boyutu olmak, z_i i. gruptaki çıktıları göstermek üzere softmax fonksiyonun çıktısı aşağıdaki gibi hesaplanır (Chen vd.,2018):

$$\varphi(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (6)$$

Softmax fonksiyon sonuçlarına göre en iyi olasılıklı sonucu veren sınıf CNN ağının bulunduğu sonuçtur. Şekil 3'teki S sınıf indisini göstermektedir. Bu sınıflar girişteki mesaj işaretlerinin ondalık karşılığıdır.

Çalışmada kullanılan eğitim öğrenme türü ise denetimli öğrenmedir. Örnek girdi-çıkı çiftlerine dayalı olarak, denetimli öğrenme, bir girdiyi bir çıktıya eşleyen bir işlevi öğrenmenin makine öğrenimi sürecidir. Denetimli öğrenmede, her örnek, bir girdi nesnesi (vektör, matris, vb.) ve istenen bir çıktı değerinden oluşan bir çifttir. Bu durum giriş ve çıkış seti örneğine göre CNN ağının eğitildiği anlamına gelmektedir.

Eğitilen ağ aşağıdaki gibi mesaj işaretini sınıflandırabilmektedir.

$$m^{est} = \text{sınıflandırıcı} \left([y; y_{eq}] \right), i = 1, 2 \quad (7)$$

Burada sınıflandırıcı gelen işaret ve gelen işaretin denkleştirilmiş halinden sınıflandırma yapan fonksiyondur. m^{est} ise CNN'nin bulunduğu S sınıflandırmasıdır.

x girişteki modülasyonlu işaret olmak üzere; x^{est} kestirilen modülasyonlu işaret arasındaki kayıp fonksiyonu yarı ortalama karesel hata (half mean squared error-hmse) ile ifade edilir:

$$E = \frac{\sum_{j=1}^N (x_j - x_j^{est})^2}{N} \quad (8)$$

4. Benzetim Sonuçları (Simulation Results)

BPSK ve QPSK modülasyonuna göre iki farklı CNN ağı, alıcıda gönderilen sembolü sınıflandıracak şekilde eğitilmiştir. Veri setinin giriş parametreleri olarak alıcıda alınan işaret ve alınan işaretin kanal denkleştirilmiş halinin işaret yıldız diyagram görüntüsü; çıkış parametresi olarak da vericide girişteki sembol alınmıştır. Eğitim örneği sayısı, 10^6 farklı denemede veri seti oluşturulduğunu göstermektedir. Veri setinin %80 eğitim %20'si

eğitilen ağı test etmek (validation) için kullanılmıştır. Mini grup boyutu ise her bir iterasyonda ağının kaç veri örneğini eğiteceğini göstermektedir. Epoch ise tüm bir veri örneğinin tamamının ilk kez eğitildiği iterasyon sayısını ifade etmektedir. 1000 iterasyonda tüm veri örneği eğitilebilmektedir. Eğitim süresi ise 20 epoch olarak seçilmiştir. Optimizasyon ise her bir iterasyondan sonra eğitim parametrelerinin güncelleme algoritmasıdır. Eğitim aşamasında eğitimler %99 doğrulukla sonuçlanmıştır.

Tablo 1. Simülasyon Parametreleri (Simulation Parameters)

Kullanılan Program	MATLAB 2018b
Kullanıcı Sayısı	2 (1 BS 1 UE)
Haberleşme Kanalı	Rayleigh + AWGN
Modülasyon	BPSK, QPSK
Kullanılan DL Modeli	CNN
Öğrenme türü	Denetimli (supervised)
Veri Seti Giriş Parametreleri	Alıcıda alınan sinyal ve Rayleigh kanalın işaret diyagram görüntüsü
Veri Seti Çıkış Parametreleri	Girişteki Sembol
Veri Seti Eğitim-Test Oranı	%80 eğitim,%20 test
Alıcıda alınan sinyal ve rayleigh kanalın işaret diyagram görüntüsü boyutları	30x30,50x50,100x100
Eğitimdeki Epoch Sayısı	20
Eğitim Örneği Sayısı	10 ⁶
İterasyon Sayısı	20000
Mini grup boyutu	1000
Eğitim Optimizasyon Algoritması	SGDM
Eğitim Doğruluğu	%99

BPSK ve QPSK modülasyonuna göre iki farklı CNN ağı, alıcıda gönderilen sembolü sınıflandıracak şekilde eğitilmiştir. Veri setinin giriş parametreleri olarak alıcıda alınan işaret ve alınan işaretin kanal denkleştirilmiş halinin işaret yıldız diyagram görüntüsü; çıkış parametresi olarak da vericide girişteki sembol alınmıştır. Eğitim örneği sayısı, 10⁶ farklı denemede veri seti oluşturulduğunu göstermektedir. Veri setinin %80 eğitim %20'si eğitilen ağı test etmek (validation) için kullanılmıştır. Mini grup boyutu ise her bir iterasyonda ağının kaç veri örneğini eğiteceğini göstermektedir. Epoch ise tüm bir veri örneğinin tamamının eğitildiği iterasyon sayısını ifade etmektedir. 1000 iterasyonda tüm veri örneği eğitilebilmektedir. Eğitim süresi ise 20 epoch olarak seçilmiştir. Optimizasyon ise her bir iterasyondan sonra eğitim parametrelerinin güncelleme algoritmasıdır. Rmsprop, Adadelta ve Adam optimizasyon algoritmaları ile de benzetimler yapılmış olup benzer hata başarımları elde edilmiştir. Bu nedenle bu çalışmaya özgü olarak SGDM tercih edilmiştir. İlerleyen çalışmalarda farklı optimizasyon türlerinin DL destekli kablosuz haberleşme problemlerine etkileri incelenecektir. Eğitim aşamasında eğitimler %99 doğrulukla sonuçlanmıştır.

Tablo 1'de verilen eğitim parametreleri uçtan uca hata olasılığını minimize edecek şekilde seçilmiştir. CNN girişi olarak kullanılan işaret diyagram görüntüsünün farklı boyutlarda sınırlandırılmasına göre üç farklı senaryo belirlenmiştir. CNN, bu üç farklı senaryoya göre eğitilmiş ve sembol kestirimi için kullanılmıştır. Senaryo I işaret yıldız diyagram görüntüsü boyutlarının 30 piksel genişlik ve 30 piksel yükseklik (30x30) seçilmesi, Senaryo II 50x50'lik boyutlar ve Senaryo III 100x100 olarak boyutların seçilmesidir.


Yukarıda belirtilen üç farklı senaryoya göre, gelen işaret ve denkleştirilmiş işaretin normalizasyon yapılmamış işaret yıldız diyagram görüntülerinden, CNN ağları ile sistemin giriş sembolleri sezilmiştir. Şekil 4'te, CNN senaryoları ile edilen bit hata oranı (bit error rate-BER) ve klasik ML sezici BER başarımları karşılaştırılmıştır.

Şekil 4.a'da, BPSK, Şekil 4.b'de QPSK için BER sonuçları görülmektedir. Şekil 4'ten görüleceği üzere, normalizasyon yapılmamış işaret yıldız diyagram görüntüsü durumunda CNN Senaryo II ve III'ün hata başarımları standart ML seziciye yaklaşımaktadır. CNN Senaryo I'nin hata başarımları grafiği ise diğerlerinden biraz daha düşüktür.


Diğer bir yöntem olarak, yukarıda açıklanan üç farklı senaryoya göre, gelen işaret ve denkleştirilmiş işaretin normalizasyon yapılmış işaret yıldız diyagram görüntülerinden, CNN ağları ile sistemin giriş sembolleri sezilmiştir. Şekil 5'te, CNN senaryoları ile elde edilen BER ve klasik ML sezici BER başarımları karşılaştırılmıştır. Şekil 5.a'da, BPSK Şekil 5.b'de QPSK sonuçları görülmektedir. Şekil 5'ten görüleceği üzere CNN Senaryo II ve III'ün

hata başarımları standart ML sezici ile hemen hemen aynı çıkmıştır. CNN Senaryo I'nin hata başarımları grafiği ise diğerlerinin az daha gerisindedir.

Şekil 4 ve Şekil 5 beraber düşünüldüğünde CNN girişindeki işaret yıldız kümesi görüntüsünde yapılan normalizasyonun gerekliliği açıkça görülmektedir. Normalizasyon yapılmadığında işaret yıldız diyagram görüntüsündeki saçılma daha fazla olacağından ötürü BER performansı olumsuz etkilenmiştir. Normalizasyon yapıldığında ise görüntü verisinin içindeki alınan işaret ve kanal denkleştirilmiş işaret verileri birbirlerine daha yakın yerleşimlerle oluşmaktadır ve saçılmanın önüne geçilerek daha iyi bir sınıflandırma/kestirim yapılabilir. İşaret yıldız diyagram görüntüsünde büyük bölgeler seçmek daha iyi görüntü çözünürlüğü sağlar. Ayrıca, işaret yıldız diyagram görüntüsünün çözünürlüğü arttıkça CNN sınıflandırma yapabilme kabiliyeti de artmaktadır.




BPSK Normalizasyonsuz CNN Sonuçları

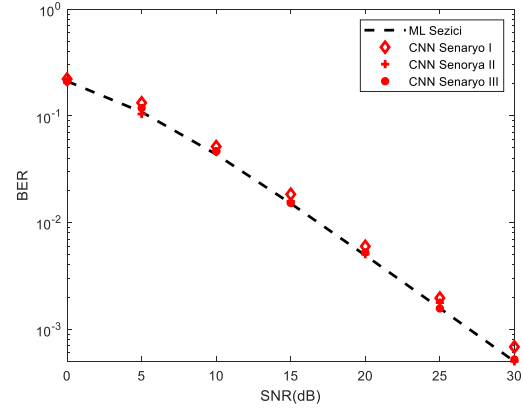


QPSK Normalizasyonsuz CNN Sonuçları

Şekil 4. Normalizasyonsuz CNN sınıflandırıcı başarımları (CNN classifier performances without normalization)



BPSK Normalizasyonlu CNN Sonuçları



QPSK Normalizasyonlu CNN Sonuçları

Şekil 5. Normalizasyonlu CNN sınıflandırıcı başarımları (CNN classifier performances with normalization)

5. Sonuç ve Tartışma (Result and Discussion)

Son yıllarda kablosuz iletişim sistemlerinde sinyal kestirimi için matematiksel modeller yerine DL kullanmak alternatif çözümler olarak düşünülmektedir. Bu çalışmada BPSK veya QPSK modülasyonun var olduğu Rayleigh sönümlenmeli kanalda alıcıda CNN kullanıldığında hata başarımlarına etkisi araştırılmıştır. ML sezici ile benzer sonuçlar elde edildiğinden, DL'nin ML sezicilere alternatif olabileceği görülmüştür. Gelen işaretin ve kanal denkleştirilmiş işaretin işaret yıldız diyagramı, görüntü formatına dönüştürülerek CNN yardımıyla alıcıda giriş sembollerinin kestirebileceği çalışmada vurgulanmıştır. Görüntü boyutlarını değiştirmenin ve işaret yıldız diyagramında normalizasyon işlemlerinin bit hata başarımlarına ne gibi etkileri olduğu tartışılmıştır. İlerleyen çalışmalarda CNN ve başka DL ağları ile 5G sistemleri için düşünülen NOMA, indis modülasyonu gibi sistemlerde işaret kestirim hata başarımları incelenecektir.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Albawi, S., Mohammed, T. A., & Al-Zawi, S., 2018. Understanding of a convolutional neural network. Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, 2018-January, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Alrabeiah, M., & Alkhateeb, A., 2020. Deep Learning for mmWave Beam and Blockage Prediction Using Sub-6 GHz Channels. IEEE Transactions on Communications, 68(9), 5504–5518. <https://doi.org/10.1109/TCOMM.2020.3003670>.
- Chen, L., Zhou, M., Su, W., Wu, M., She, J., & Hirota, K., 2018. Softmax regression based deep sparse autoencoder network for facial emotion recognition in human-robot interaction. Information Sciences, 428, 49–61. <https://doi.org/10.1016/j.ins.2017.10.044>.
- Cun, Y. Le, Guyon, I., Jackel, L. D., Henderson, D., Boser, B., Howard, R. E., Denker, J. S., Hubbard, W., & Graf, H. P., 1989. Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning. IEEE Communications Magazine, 27(11), 41–46. <https://doi.org/10.1109/35.41400>.
- Dorner, S., Cammerer, S., Hoydis, J., & Brink, S. Ten., 2018. Deep Learning Based Communication over the Air. IEEE Journal on Selected Topics in Signal Processing, 12(1), 132–143. <https://doi.org/10.1109/JSTSP.2017.2784180>.
- Emir, A., Kara, F., & Kaya, H., 2019. Deep learning-based joint symbol detection for NOMA. In 27th Signal Processing and Communications Applications Conference, SIU 2019. <https://doi.org/10.1109/SIU.2019.8806600>.
- Farsad, N., & Goldsmith, A., 2018. Neural network detection of data sequences in communication systems. IEEE Transactions on Signal Processing, 66(21), 5663–5678. <https://doi.org/10.1109/TSP.2018.2868322>.
- Gui, G., Huang, H., Song, Y., & Sari, H., 2018. Deep Learning for an Effective Nonorthogonal Multiple Access Scheme. IEEE Transactions on Vehicular Technology, 67(9), 8440–8450. <https://doi.org/10.1109/TVT.2018.2848294>.
- Hojatian, H., Nadal, J., Frigon, J. F., & Leduc-Primeau, F., 2020. Unsupervised Deep Learning for Massive MIMO Hybrid Beamforming. In arXiv: <https://arxiv.org/pdf/2007.00038.pdf>
- Jiajia Guo, Chao-Kai Wen & Shi Jin, 2020. Deep Learning-Based CSI Feedback for Beamforming in Single- and Multi-cell Massive MIMO Systems. IEEE Journal on Selected Areas in Communications. Submitted 11 Nov 2020. In arXiv: <https://arxiv.org/pdf/2011.06099.pdf>
- Jiang, R., Sun, C., Zhang, L., Tang, X., Wang, H., & Zhang, A., 2020. Deep learning aided signal detection for SPAD-Based underwater optical wireless communications. IEEE Access, 8, 20363–20374. <https://doi.org/10.1109/ACCESS.2020.2967461>.
- Lin, C., Chang, Q., & Li, X., 2019. A deep learning approach for mimo-noma downlink signal detection. Sensors (Switzerland). <https://doi.org/10.3390/s19112526>.
- Luo, B., Peng, Q., Cosman, P. C., & Milstein, L. B., 2019. Robustness of Deep Modulation Recognition under AWGN and Rician Fading. In Conference Record - Asilomar Conference on Signals, Systems and Computers (Vol. 2018-October, pp. 447–450). <https://doi.org/10.1109/ACSSC.2018.8645089>.
- Luong, T. Van, Ko, Y., Vien, N. A., Nguyen, D. H. N., & Matthaiou, M., 2019. Deep Learning-Based Detector for OFDM-IM. IEEE Wireless Communications Letters, 8(4), 1159–1162. <https://doi.org/10.1109/LWC.2019.2909893>.
- Peng, S., Jiang, H., Wang, H., Alwageed, H., & Yao, Y. D., 2017. Modulation classification using convolutional Neural Network based deep learning model. In 2017 26th Wireless and Optical Communication Conference, WOCC 2017. <https://doi.org/10.1109/WOCC.2017.7929000>.
- Sledevic, T., 2019. Adaptation of Convolution and Batch Normalization Layer for CNN Implementation on FPGA. 2019 Open Conference of Electrical, Electronic and Information Sciences, EStream 2019 - Proceedings. <https://doi.org/10.1109/eStream.2019.8732160>.
- Soltani, M., Pourahmadi, V., Mirzaei, A., & Sheikhzadeh, H., 2019. Deep Learning-Based Channel Estimation. IEEE Communications Letters, 23(4), 652–655. <https://doi.org/10.1109/LCOMM.2019.2898944>.
- Wang, X., Zhang, Y., Shen, R., Xu, Y., & Zheng, F. C., 2020. DRL-Based Energy-Efficient Resource Allocation Frameworks for Uplink NOMA Systems. IEEE Internet of Things Journal, 7(8), 7279–7294. <https://doi.org/10.1109/JIOT.2020.2982699>.
- Wu, N., Wang, X., Lin, B., & Zhang, K., 2019. A CNN-Based End-to-End Learning Framework Toward Intelligent Communication Systems. IEEE Access, 7, 110197–110204. <https://doi.org/10.1109/access.2019.2926843>.
- Xiao, L., Sheng, G., Liu, S., Dai, H., Peng, M., & Song, J., 2019. Deep Reinforcement Learning-Enabled Secure Visible Light Communication against Eavesdropping. IEEE Transactions on Communications, 67(10), 6994–7005. <https://doi.org/10.1109/TCOMM.2019.2930247>.
- Xu Y, Yang C, Hua M and Zhou W., 2020. Deep Deterministic Policy Gradient (DDPG)-Based Resource Allocation Scheme for NOMA Vehicular Communications. IEEE Access. 2020; 8: 18797-18807. doi: 10.1109/ACCESS.2020.2968595.
- Xu, W., Zhong, Z., Beery, Y., You, X., & Zhang, C., 2018. Joint neural network equalizer and decoder. In Proceedings of the International Symposium on Wireless Communication Systems (Vol. 2018-August). <https://doi.org/10.1109/ISWCS.2018.8491056>.
- Ye, H., Li, G. Y., & Juang, B. H., 2018. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems. IEEE Wireless Communications Letters, 7(1), 114–117. <https://doi.org/10.1109/LWC.2017.2757490>.
- Ye, H., Liang, L., Li, G. Y., & Juang, B. H., 2020. Deep Learning-Based End-to-End Wireless Communication Systems with Conditional GANs as Unknown Channels. IEEE Transactions on Wireless Communications, 19(5), 3133–3143. <https://doi.org/10.1109/TWC.2020.2970707>.
- Yuan, J., Ngo, H. Q., & Matthaiou, M., 2020. Machine Learning-Based Channel Prediction in Massive MIMO with Channel Aging. IEEE Transactions on Wireless Communications, 19(5), 2960–2973. <https://doi.org/10.1109/TWC.2020.2969627>.
- Zhang, J., Tao, X., Wu, H., Zhang, N., & Zhang, X., 2020. Deep Reinforcement Learning for Throughput Improvement of the Uplink Grant-Free NOMA System. IEEE Internet of Things Journal, 7(7), 6369–6379. <https://doi.org/10.1109/JIOT.2020.2972274>.
- Zhenyu Liu, Mason del Rosario & Zhi Ding, 2020. A Markovian Model-Driven Deep Learning Framework for Massive MIMO CSI Feedback. IEEE Transactions on Wireless Communications. Submitted 20 Sep 2020. In arXiv: <https://arxiv.org/pdf/2009.09468.pdf>.