



## Aşağı ve Yukarı Yönlü NOMA Haberleşme Sistemleri için CNN Yardımlı Alternatif Sezici Tasarımı

### CNN Aided Alternative Detector Design for Uplink and Downlink NOMA Communications Systems

Ahmet Emir <sup>1\*</sup>, Ferdi Kara <sup>1</sup>, Hakan Kaya <sup>1</sup>

<sup>1</sup> Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü, Zonguldak, TÜRKİYE

Sorumlu Yazar / Corresponding Author \*: [ahmet.emir@beun.edu.tr](mailto:ahmet.emir@beun.edu.tr)

Geliş Tarihi / Received: 20.05.2021

Kabul Tarihi / Accepted: 23.08.2021

[Atıf şekli/ How to cite: EMİR, A., KARA, F., KAYA, H. \(2022\). Aşağı ve Yukarı Yönlü NOMA Haberleşme Sistemleri için CNN Yardımlı Alternatif Sezici Tasarımı. DEUFMD, 24\(70\), 341-349.](#)

Araştırma Makalesi/Research Article

DOI:10.21205/deufmd.2022247030

#### Öz

Haberleşme sistemlerinde kanal sönmlemelerine karşı işareti iletmek ve alıcıda almak için fiziksel seviyede geliştirilen yöntemler işlem karmaşıklığına sebep olmaktadır. Son yıllarda işlem karmaşıklığını azaltmak için alternatif olarak Derin öğrenme (deep learning-DL) ağlarına başvurulmaktadır. Gelecek nesil haberleşme sistemleri için öncü olacağı düşünülen dikgen olmayan çoklu erişim (non-orthogonal multiple access-NOMA) kullanıcıları aynı kaynak bloğunda güç ekseninde paylaştırarak yüksek spektral verim sağlar. Fakat sinyal sezimi için kullanılan ardışık girişim engelleyici (successive interference cancellation-SIC) işlem karmaşıklığına sebep olmaktadır. Bu çalışmada aşağı yönlü (downlink) ve yukarı yönlü (uplink) NOMA haberleşme sistemlerinde alıcıya ulaşan işaretin alternatif olarak DL ile sezimi amaçlanmıştır. DL ağı olarak evrişimli sinir ağı (convolutional neural network-CNN) kullanılmıştır. CNN yardımcı sezici ve maksimum olabirlikli (maximum likelihood-ML)-SIC sezicisi hata başarımları karşılaştırılmıştır. Aşağı ve yukarı yönlü NOMA haberleşme sistemlerinde yakın ve uzak kullanıcı bitlerinin CNN ağıyla ortak kestirilebilmesi ve bazı durumlarda bit hata oranı grafiklerinin DL sezicilerde SIC-ML sezicilerden daha iyi bulunması önemli bir avantajdır. Ayrıca NOMA sistemlerinde CNN ağının sezici olarak kullanılabilmesi, sınıflandırıcıların kablosuz haberleşme sistemlerinde gücünü ortaya koymaktadır.

**Anahtar Kelimeler:** BPSK, CNN, DL, Hata Performansı, İşaret Matrisi, ML, Ortak Kestirim, SIC

#### Abstract

Methods implemented at the physical level in order to transmit and receive signals at the receiver against channel fading in communication systems cause processing complexity. In recent years, Deep learning (DL) networks have been used as an alternative to reduce processing complexity. Non-orthogonal multiple access (NOMA) which has been to be a pioneer for future generation, provides high spectral efficiency by sharing users on the power axis in the same source block. However, successive interference cancellation (SIC) used for signal detection causes processing complexity. In this study, it is proposed to detect the received signal with DL as an alternative method in downlink and non-orthogonal multiple access (NOMA) communication systems. Convolutional neural network (CNN) is used as DL network. The error performance of CNN aided detector and SIC- ML (maximum

likelihood )based detector has been compared. In downlink and uplink NOMA communication systems, it is an important advantage that the near and far user bits can be estimated jointly with the CNN network and in some cases the bit error rate curves are better in DL detectors than SIC-ML detectors. In addition, the ability using the CNN network as a detector in NOMA systems reveals the power of classifiers in wireless communication systems.

**Keywords:** BPSK, CNN, DL, Error Performance, Signal Matrix, ML, Joint Detection, SIC

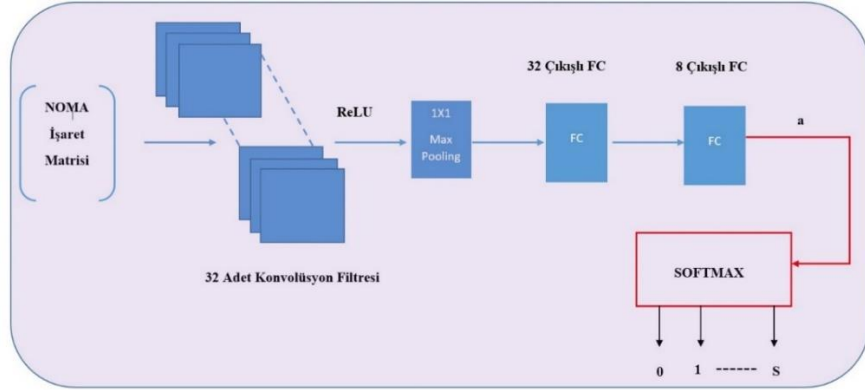
## 1. Giriş

Uçtan uça iletişim sistemlerinde kanal bozulmalarına dirençli şekilde işaretin gönderilmesi ve alınabilmesi için fiziksel seviyede yöntemler geliştirilmektedir. Kablosuz haberleşme sistemlerinde bu yöntemler, alıcı ve vericide kaynak kodlama, modülasyon, kanal kodlama, demodülasyon, kanal denkleştirme vs. olarak sıralanmaktadır. Bu yöntemleri derin öğrenme (deep learning-DL) ile gerçekleştirilmesi son yıllarda popüler hale gelmiştir. Kanal ve kaynak kodlama [1], modülasyon ve demodülasyon [2] blokları, alıcıda sinyal sezimi [3] DL ağlarla gerçekleştirilmiştir. [4]'te ise tüm uçtan uca haberleşme sistemi DL ağlarla tasarlanmıştır.

5G ve ötesi için öncü olması düşünülen tekniklerden birisi dikgen olmayan çoklu erişim (non orthogonal multiple access-NOMA) tekniğidir [5]. NOMA dikgen çoklu erişim (orthogonal multiple Access-OMA) tekniklerine göre kapasite bakımından avantajlı olup, hata başarımı açısından dezavantajlıdır [6]. Literatürde NOMA için de DL ağları kullanımı önerilmiştir. Yukarı yönlü (uplink) NOMA haberleşmesinde [7-10] ve aşağı yönlü (downlink) NOMA haberleşmesinde [11-12] geleneksel ardışık girişim engelleyici (successive interference cancellation-SIC) tabanlı seziciler yerine DL tabanlı seziciler önermişlerdir. Ayrıca NOMA'da kaynak atama [13] ve modülasyon sınıflandırma [14] uygulamaları için de DL ağına başvurmuşlardır. DL ağ uygulamaları NOMA dışında 5G ve 6G ağlarda daha güncel teknolojilerde uygulanmıştır. DL, Indis modülasyonu (index modulation) [15] ve mm dalga (mmWave) [16] sistemlerine uygulamıştır. [17]'de birden fazla kablosuz düğüm için DL destekli dağıtılmış dışbükey olmayan optimizasyon algoritması önerilmiştir. [18]'de derin pekiştirmeli öğrenme (deep reinforcement learning-DRL) temelli kaynak atama, yüksek mobilite, yukarı bağlantı ve aşağı bağlantı kablosuz heterojen ağlarda (HetNet) denemiştir.

[19]'da büyük makina tipli ağlar (massive machine type communication)'da yayılı dizi (spreading sequeunce) [20]'de kanal kestirimi doğrudan DL ağlarla gerçekleştirilmiştir. [21]'de ise ağ kodlama için DL ağlarına başvurulmuştur. [22]'de ise 2.6GHz'de çalışan kablosuz sistemler için yol kayıp modeli olarak DL kullanılmıştır. [23]'te ise uçtan uca dikgen frekans bölmeli çoğullama (orthogonal frequency division multiplexing-OFDM) sistemi DL ağlarla tasarlanarak sistemin hata performansı değerlendirilmiştir. DL aynı zamanda, 6G tabanlı nesnelerin interneti (internet of things-IoT) ağları için büyük miktarda veri toplamak için uygulanmaktadır [24]. [25]'de, kablosuz iletişim ağında gizli dinleyicilerin mevcut olduğu çok sayıda meşru kullanıcının iletişimini güvence altına almak için DRL tabanlı akıllı yüzey önerilmiştir. Gelecekte 5G'nin ötesinde 6G ağlarda akıllı kaynak yönetimi, akıllı hizmet sağlama vb. görevler için yapay zekâ yardımcı ağlar kullanılacaktır [26].

Bu çalışmada ikili faz kaydırmalı anahtarlamalı (binary phase shift keying-BPSK) modülasyonlu hem aşağı yönlü hem de yukarı yönlü NOMA haberleşme sistemlerinde literatürde sıkça kullanılan [27,28] evrişimli sinir ağı (convolutional neural network-CNN) tabanlı sınıflandırıcı kullanılarak NOMA işaretinin sezimi amaçlanmıştır. Kanal etkisinin alıcıda bilindiği varsayılmıştır. Aşağı yönlü NOMA sisteminde yakın kullanıcıya gelen işaret ve yakın kullanıcıya gelen işaretin baz istasyonu (base station-BS) ile yakın kullanıcı arasındaki Rayleigh sönümlemeli kanal vektörü ile denkleştirilmiş işareti iki boyutlu matris haline getirilmiştir. Bu iki boyutlu matristen CNN ile NOMA işareti kestirilmiştir. Yukarı yönlü NOMA sisteminde ise BS'e gelen süperpozisyon kodlu (superposition coded-SC) işaret, BS'e gelen SC işaretinin BS ile yakın kullanıcı arasındaki Rayleigh sönümlemeli kanal vektörü ile denkleştirilmiş işareti ve BS'e gelen SC işaretinin BS ile uzak kullanıcı arasındaki Rayleigh sönümlemeli kanal vektörü ile denkleştirilmiş



Şekil 1 CNN Yardımlı Sistem Modeli

işareti benzer şekilde iki boyutlu matris haline getirilmiştir. Aşağı yönlü sistemde olduğu gibi yukarı yönlü sistemde de iki boyutlu matristen CNN sınıflandırıcı ile NOMA işaret tespiti hedeflenmiştir. Dolayısıyla aşağı yönlü NOMA için CNN giriş matrisinde iki bileşke işaret, yukarı yönlü NOMA için giriş matrisinde üç bileşke işaret bulunmaktadır. DL tabanlı sezici ile bulunan hata başarımları, en büyük olasılıklı (maximum likelihood-ML) sezici ve SIC-ML sezici ile bulunan hata başarımları ile karşılaştırılmıştır. Çalışmanın bundan sonraki bölümleri şu şekilde sunulmuştur. Geleneksel aşağı yönlü-NOMA sistem modeli, geleneksel yukarı yönlü-NOMA sistem modeli ve önerilen DL tabanlı yukarı yönlü-NOMA sezme işlemi tanıtılmıştır. DL için benzetim sonuçları sunulmuştur. Son olarak sonuçlar tartışılarak çalışma sonlandırılmıştır

## 2. Sistem Modeli

### 2.1. Geleneksel Aşağı Yönlü NOMA Modeli

Bu çalışmada ilk olarak birisi yakın diğeri uzak kullanıcı olarak adlandırılan iki gezgin kullanıcı (user equipment-UE) ve bir BS'den oluşan bir aşağı yönlü NOMA sistem modeli sunulmuştur. UE<sub>1</sub> yakın kullanıcıyı, UE<sub>2</sub> uzak kullanıcıyı ifade etmektedir. BS'e uzaklık farkından dolayı UE<sub>2</sub>'nin kanal koşulları UE<sub>1</sub>'den kötüdür. BS'den kullanıcılara iletilen SC işareti:

$$\chi = \sqrt{\alpha}\chi_1 + \sqrt{(1-\alpha)}\chi_2 \quad (1)$$

ile ifade edilir.

Burada  $\alpha$  yakın kullanıcı için ayrılan gücü göstermektedir.  $\chi_1$  ve  $\chi_2$  sırasıyla UE<sub>1</sub> ve UE<sub>2</sub> için BPSK modülasyonlu temel bant karmaşık işaretlerini temsil etmektedir. Her bir kullanıcıda (UE<sub>i</sub>) alınan işaret:

$$y_i = \sqrt{P}\chi \times h_i + n_i \quad (2)$$

ile ifade edilmektedir.

Burada  $P$ , BS'in toplam gücünü  $h_i$ , UE<sub>i</sub> ile BS arasındaki  $\sigma^2$  varyanslı Rayleigh kanal sönümlenme kanal katsayılarını ifade etmektedir.  $n_i$  ise UE<sub>i</sub>'deki  $N_0/2$  güç spektral yoğunluğundaki toplam beyaz gauss gürültüsünü (additive white gaussian noise-AWGN) göstermektedir.

UE<sub>2</sub> için ayrılan güç daha fazla olduğundan UE<sub>2</sub> doğrudan ML sezici ile kendi sembollerine karar vermektedir. UE<sub>1</sub>'de ise SIC kullanılarak öncelikle UE<sub>2</sub> kestirilmektedir, sonrasında alınan toplam işareten UE<sub>2</sub> sembolleri çıkartılmaktadır. En son aşamada ML ile UE<sub>1</sub> sembolleri kestirilmektedir.

### 2.2. Geleneksel Yukarı Yönlü NOMA Modeli

Bu çalışmanın ikinci aşaması olarak bir BS, UE<sub>1</sub> ve UE<sub>2</sub>'den oluşan yine her bir kullanıcı BPSK modülasyonlu yukarı yönlü NOMA sistem modeli sunulmuştur. BS'e gelen SC işareti

$$y = \sum_{i=1}^2 (\sqrt{P_i}x_i h_i) + n \quad (3)$$

ile gösterilmektedir.

Burada  $P_i$  UE<sub>i</sub>'nin iletim gücünü göstermektedir.  $n$  ise BS'de oluşan  $N_0/2$  güç spektral yoğunluğundaki AWGN'dir.

BS'de ilk olarak ML ile yakın kullanıcı sembolleri kestirilmektedir. Sonrasında yakın kullanıcı sembolleri alınan SC işaretinden SIC ile çıkarılmaktadır. Son kez ML sezici uygulanarak uzak kullanıcı sembolleri kestirilmektedir.

### 2.3. Önerilen DL Modeli

Gönderilen işaretin sezimi için, işaret yıldız kümesi matrisinin özneliklerinin çıkarılması gerekmektedir. Bu işlemi gerçekleştiren DL ağlarından olan CNN ağları 1988 yılında Cun vd.[29] tarafından geliştirilen LeNet mimarisine dayanmaktadır.

CNN yardımcı sistem modeli Şekil 1'de gösterilmiştir. CNN modeli konvolüsyon katmanı, maksimum havuzlama (maxpooling) ve iki adet tam bağlı katman (FC-Fully Connected Layer)dan oluşmaktadır.

CNN girişine işaret matrisi uygulanmaktadır. Şekil 2'de aşağı yönlü NOMA haberleşme sistemi için CNN girişine uygulanan örnek işaret matrisini görülmektedir ( $y_{input}$ ). Bu işaret matrisinde  $y_i$  aşağı yönlü NOMA haberleşme sisteminde i. kullanıcıdan alınan işareti ve  $y_{eqdi}, y_i$ 'nin BS ile UE<sub>i</sub> arasındaki kanal katsayısı ( $h_i$ ) ile denkleştirilmiş işaretini göstermektedir ( $y_{eqdi}=y_i/h_i$ ). CNN  $y_{input}$  işaret matrisini, BPSK için 4 sınıf (C) {0,1,2,3} üzerinden eğitmektedir. Bu sınıflar NOMA mesaj işaretlerinin(m) {0,0}, {0,1}, {1,0}, {1,1} birer temsilidir. Örneğin {0,0} sırasıyla UE<sub>1</sub> ve UE<sub>2</sub> için ikili bit dizilerini göstermektedir. Eğitilen ağ, hem yakın kullanıcı hem de uzak kullanıcıda test edilebilmektedir.  $y_{input}$  eğitim aşamasında rasgele üretilen NOMA sembollerine karşılık gelen bir eğitim örneğini temsil ederken, eğitilen ağ test aşamasında ise test verisini ifade etmektedir.  $y_{input}$ , eğitim aşamasında aşağı yönlü nomada [gerçel( $y_1$ ) sanal( $y_1$ ); gerçel( $y_{eqd1}$ ) sanal( $y_{eqd1}$ )]'ye eşittir. Eğitilen ağ test edilirken de  $y_{input}$ , yakın kullanıcıda [gerçel( $y_1$ ) sanal( $y_1$ ); gerçel( $y_{eqd1}$ ) sanal( $y_{eqd1}$ )], uzak kullanıcıda [gerçel( $y_2$ ) sanal( $y_2$ ); gerçel( $y_{eqd2}$ ) sanal( $y_{eqd2}$ )] matrisleri seçilmektedir. Gerçel( ) işlevi işaretlerin gerçel, sanal( ) işlevi ise işaretlerin sanal bileşenlerini ifade etmektedir. Gerçel ve sanal bileşenlerin ayrı alınarak giriş matrisinde kullanılması CNN'nin karmaşık sayılar üzerinde işlem yapamamasından kaynaklanmaktadır.

Şekil 3' te ise yukarı yönlü NOMA haberleşme sistemi için CNN girişine uygulanan örnek işaret matrisini göstermektedir. İşaret matrisinde sırasıyla y BS'e gelen işareti,  $y_{equ1}$  y'nin BS ile UE<sub>1</sub> arasındaki kanal katsayısı ( $h_1$ ) ile denkleştirilmiş işaretini ve  $y_{equ2}$  y'nin BS ile UE<sub>2</sub> arasındaki kanal katsayısı ( $h_2$ ) ile denkleştirilmiş işaretini ifade etmektedir. Eğitim yine BPSK modülasyonu için yukarı yönlü NOMA'da 4 sınıf üzerinden yapılır.  $y_{input}$ , eğitim ve eğitilen ağ test aşamasının her ikisinde de [gerçel(y) sanal(y); gerçel( $y_{equ1}$ ) sanal( $y_{equ1}$ ); gerçel( $y_{equ2}$ ) sanal( $y_{equ2}$ )] 'ye eşittir. Aşağı yönlü NOMA'ya benzer olarak yukarı yönlü NOMA'da da  $y_{input}$  işaret matrisinden NOMA bitlerinin kestirimi hedeflenmiştir.

Gerçel( $y_i$ )	Sanal( $y_{eqdi}$ )
Gerçel( $y_i$ )	Sanal( $y_{eqdi}$ )

Şekil 2 Aşağı Yönlü NOMA sistemi için CNN giriş matrisi

Gerçel(y)	Gerçel ( $y_{equ1}$ )	Gerçel( $y_{equ2}$ )
Sanal(y)	Sanal( $y_{equ1}$ )	Sanal( $y_{equ2}$ )

Şekil 3 Yukarı Yönlü NOMA sistemi için CNN giriş matrisi

CNN ağı her bir işaret matrisinde işaret sezimi için öznelik çıkarma özelliğinden ötürü bu çalışmada tercih edilmiştir.

Konvolüsyon filtresi, öznelik çıkartmak için işaret matrisi ile konvolüsyon işlemlerini yerine getirir. Şekil 1'den görüleceği üzere 32 adet konvolüsyon filtresi kullanılmıştır.

Aktivasyon fonksiyonu olarak ReLU işlevine başvurulur. ReLU fonksiyonu, herhangi bir negatif girdi alırsa 0 döndürmektedir, ancak herhangi bir pozitif değer girdisi için bu değeri geri döndürmektedir.

Maksimum Havuzlama matrisi üzerinden örnek seyrelterek örnek sayısını azaltılmaktadır. Her bir CNN katmanında 1x1 lik bölgeler alınarak yarı yarıya örnek azaltılmıştır.

CNN katmanlarından sonra kullanılan FC çıkış katmanından önce konvolüsyon çekirdeğinden gelen değerleri rasgele belirlenmiş bir ağırlık matrisi ile çarpıp, rasgele belirlenmiş bir son eşik (bias) eklemektedir. Modelde iki adet FC vardır. İlk 32 diğeri 4 çıkışlıdır.

Çıkış fonksiyonu olarak softmax fonksiyonu kullanılmıştır. Softmax fonksiyonu en iyi olasılık veren sonucu çıkışa aktaran bir işlevdir:

$$f(a)_i = \frac{e^{a_i}}{\sum_j^c e^{a_j}} \quad (4)$$

a, ikinci FC katmanının çıkışındaki değerdir.

Kayıp fonksiyonu, kategorisel çapraz entropi (categorical cross entropy loss-CCE) fonksiyonudur. CCE, mini grup (minibatch size) olarak adlandırılan daha küçük alt küme veri setinden oluşan her iterasyonda ( $l$ ) her bir C sınıfına ait mesaj işareti  $m_i$  ile softmax çıkışını karşılaştırmaktadır:

$$CCE(l) = - \sum_i^c m_i \log(f(a)_i) \quad (5)$$

Stokastik gradyan azalma (stochastic gradient descent-SGD) algoritması, kaybın negatif gradyanı yönünde her iterasyonda küçük adımlar atarak kayıp fonksiyonunu en aza indirmek için ağırlıklarını (ağırlıklar ve son eşik) günceller:

$$\theta_{l+1} = \theta_l - \beta \nabla CCE(l) \quad (6)$$

Burada  $\theta$  ağırlık parametrelerini,  $l$  iterasyonu  $\nabla CCE$  kayıp fonksiyonunun gradyanını,  $\beta$  öğrenme oranını ifade etmektedir.

### 2.3.1 Eğitim ve Test Algoritmaları

Eğitime başlamadan önce veri seti oluşturulması gerekmektedir. Aşağı yönlü NOMA ve yukarı yönlü NOMA haberleşme sistemlerine göre iki ayrı veri seti elde edilir. **Algoritma 1** veri seti elde etme algoritmasını göstermektedir. **Algoritma 1**'e göre **CS=1** aşağı yönlü NOMA haberleşme sistemini, **CS=2** yukarı yönlü haberleşme sistemini göstermektedir. Veri seti her bir örnekte ( $s$ ) anlık Rayleigh sönümlenmeli kanal vektörü ve AWGN kullanılarak oluşturulmuştur. Bu sebeple CNN sınıflandırmada anlık veriler kullanılacağı için kanal vektörü boyutu **N=1** seçilmiştir. Ayrıca her bir veri örneğinde 0 ile 30dB arasında düzgün dağılımlı değerlerden rasgele seçilen **SNR** (signal to noise ratio-ışaret gürültü oranı) değerine başvurulmuştur. NOMA mesaj işaretleri ( $m$ ) rasgele bitlerden oluşturulur. Sonrasında her bir

örnek için oluşturulan  $y_{input}$  CNN giriş matrisleri ve bu giriş matrisine karşılık gelen  $m$  NOMA mesaj işaretleri kaydedilerek veri seti elde edilmiştir.

#### Algoritma 1: Veri Seti Elde Etme

**Veri: SNR, S, N=1,CS**

- 1: **CS=1**
- 2: **Döngü1**  $s=1:S$
- 3: 0 ile 30 dB arasında düzgün dağılımlı rasgele **SNR** üret.
- 4: Rasgele bitlerden oluşmuş NOMA mesaj işareti ( $m$ ) oluştur.
- 5:  $UE_1$  için  $h_1$  rasgele Rayleigh sönümlenme katsayısını ve  $n_1$  rasgele AWGN oluştur.
- 6: (1) 'deki gibi SC kodlu sembolü hesapla
- 7: CNN giriş matrisini ( $y_{input}$ )  $UE_1$  için Şekil 3'deki gibi hazırla.
- 8:  $y_{input}$  giriş matrisini ve  $m$  NOMA mesaj işaretini her bir  $s$  için kaydet
- 9: **Döngü1 Bitir**
- 10: **CS=2**
- 11: **Döngü2**  $s=1:S$
- 12: 0 ile 30 dB arasında düzgün dağılımlı rasgele **SNR** üret.
- 13: Rasgele bitlerden oluşmuş NOMA mesaj işareti ( $m$ ) oluştur.
- 14:  $h_1$  ve  $h_2$  rasgele Rayleigh sönümlenme katsayılarını ve rasgele  $n$  AWGN oluştur.
- 15:  $BS^e$  gelen SC işaretini (3)'e göre oluştur.
- 16: CNN giriş matrisini ( $y_{input}$ )  $BS$  için Şekil 4'teki gibi hazırla.
- 17:  $y_{input}$  giriş matrisini ve  $m$  NOMA mesaj işaretini her bir  $s$  için kaydet.
- 18: **Döngü2 Bitir**

Eğitim algoritması ve parametre optimizasyonu **Algoritma 2** 'de gösterilmiştir. Eğitim aşaması aşağı ve yukarı yönlü haberleşme sistemleri için benzerdir. Kullanılan veri setleri farklı olacağı

için iki farklı ağ elde edilecektir. DL parametreleri tanımlanır. Her bir iterasyonda kayıp fonksiyonu ( $CCE(I)$ ) önceki iterasyonlara göre maksimum yakınsamaya ulaşıp ulaşılmadığı test edilir. Eğer test geçerli ise ağ parametreleri SGD'ye göre güncellenir.

**Algoritma 2:** Eğitim Algoritması ve Parametre Optimizasyonu

Veri: $y_{input}$ , $m$ , $CS$	
1:	DL parametrelerini tanımla ( maksimum epoch, öğrenme oranı, mini grup boyutu
2:	Döngü $i=1:e$
3:	Her epoch için iterasyonları başlat.
4:	Ağı eğit ve (5)'e göre mevcut iterasyon için kayıp fonksiyonunu hesapla
5:	Eğer Koşul {Maks { $CCE(I)$ }}
6:	(6)'ya göre epochdaki iterasyon için ağ parametrelerini güncelle. Basamak 4'e dön.
7:	Koşul yanlış ise
8:	CCE işlevinde maksimuma yakınsama yok. Diğer iterasyona geç.
9:	Bitir Eğer
10:	İterasyonları bitir.
11:	Her epoch için ağ parametrelerini kaydet.
12:	Bitir Döngü
13:	Sonuç: $net, m^{dl}$

Aşağı ve yukarı yönlü haberleşme sistemleri için kaydedilen ağlar ile NOMA sinyali ( $m^{dl}$ ) aşağıdaki gibi kestirilebilmektedir:

$$m^{dl} = net(y_{input}) \quad (7)$$

### 3. Nümerik Sonuçlar

Aşağı yönlü ve yukarı yönlü NOMA haberleşme sistemlerinde simülasyon parametreleri Tablo 1 'de gösterilmiştir. Tüm programlar Intel Core i9 işlemciye ve NVIDIA Quadro P2200 GPU'ya sahip iş istasyonunda çalıştırılmıştır.

Aşağı yönlü ve yukarı yönlü NOMA haberleşme sistemlerine göre eğitilen CNN ağı ile NOMA sembolleri kestirilmiştir. Kestirilen NOMA

sembollerinden uzak ve yakın kullanıcıya karşılık gelen semboller belirlenerek, gönderilen yakın ve uzak kullanıcı sembolleri ile karşılaştırılarak bit hata oranı (bit error rate-BER) grafikleri oluşturulmuştur. BER grafiklerinin elde edildiği monte carlo simülasyonları MATLAB'da yapılmıştır.

**Tablo 1 Simülasyon Parametreleri**

NOMA Kullanıcı Sayısı	2
Kanal Modeli	Rayleigh + AWGN
Kanal Varyansları	$\sigma_1^2=2, \sigma_2^2=1$
Modülasyon	BPSK
Eğitim için kullanılan Program	Phyton Tensorflow Kütüphanesi
Veri seti ve simülasyonlar için kullanılan program	MATLAB
Eğitim Örneği Sayısı(S)	$10^6$
Kullanılan DL Modeli	CNN
Epoch Sayısı	5
Mini Grup Boyutu	32
Öğrenme Oranı	0.01
Kayıp Fonksiyonu	CCE
Optimizasyon Algoritması	SGD
Eğitim/Test Oranı	70% / 30%

Şekil 4'te farklı SNR'a göre aşağı yönlü NOMA haberleşme sistemlerinde DL seziciyle elde edilen BER grafikleri ML ve SIC-ML sezicilerle karşılaştırılmıştır. Yakın kullanıcı ve uzak kullanıcı bitlerini ortak kestirecek şekilde eğitilen DL ağı hem UE<sub>1</sub> hem de UE<sub>2</sub>'de kullanılmıştır. DL ağıyla, yakın kullanıcıda hem yakın hem uzak kullanıcı bitleri kestirilirken, uzak kullanıcıda sadece kendi bitleri kestirilir. NOMA'da yakın kullanıcı sembollerini sezerken ML seziciden önce kullanılan SIC işlem karmaşıklığına sebep olarak ek işlem yükü getirmektedir. Görüldüğü üzere DL sezicinin performansı ML ve SIC-ML sezicilerle benzer çıkmıştır. Bu durum SIC yöntemine başvurmadan UE<sub>1</sub>'de CNN ağı kullanılarak aynı

hata başarımlarının elde edilebileceğinin göstergesidir. Ayrıca yakın kullanıcıda hem uzak hem yakın kullanıcı bitlerinin ortak kestirilebilmesi uzak kullanıcıda herhangi bir ek işlem yapılmaması açısından avantajlıdır.

Şekil 5'te yukarı yönlü NOMA'da yakın kullanıcıdan ve uzak kullanıcıdan eşit SNR'da işaretler BS'e gönderilirken DL seziciyle elde edilen BER grafikleri ML ve SIC-ML sezicilerle karşılaştırılmıştır. Şekil 5'te DL seziciyle elde edilen BER grafikleri  $UE_2$  için SNR 15dB'den sonra SIC-ML sezici ve  $UE_1$  için SNR 5dB'den sonra ML sezici ile elde edilen BER grafiklerine üstün olmaya başlamıştır. Düşük SNR'larda yukarı yönlü haberleşme sisteminde gürültüden dolayı CNN ağının öznelilik çıkarması güçleşir bu sebeple performans düşük SNR'larda kötüleşirken, SNR yükseldikçe DL sezicinin performansı artmaktadır. Böylelikle yukarı yönlü NOMA haberleşmesinde de aşağı yönlü NOMA haberleşmesinde DL sezicilerde işlem yükü azaltılmış olur.

Şekil 6'da ise yukarı yönlü NOMA'da yakın kullanıcıdan BS'e gönderilen işaret SNR'ı 20dB'de sabit tutulurken, uzak kullanıcıdan gönderilen BS'e gönderilen işaretin SNR'ı 0 ile 30dB arasında değişirken DL seziciyle elde edilen BER grafikleri ML ve SIC-ML sezicilerle karşılaştırılmıştır. Şekil 5'te kullanılan eğitilmiş ağ parametreleri Şekil 6'daki sonuçları elde ederken de kullanılmıştır. Bu durum yukarı yönlü NOMA'daki ağın esnekliğini göstermektedir. Dolayısıyla yukarı yönlü NOMA için eğitilen ağ yapılan simülasyonlarda eğitimde olmayan parametreler için de iyi sonuç verdiği gözlemlenmiştir. Yakın ve uzak kullanıcı için eşit SNR seçilirken bulunan DL sezici sonuçlarındaki benzer eğilim gözlemlenmiştir. Şekil 6'da  $UE_1$  için DL seziciyle elde edilen BER grafikleri SNR 10dB'den sonra ML sezici ile elde edilenden üstün olmuştur. Benzer şekilde  $UE_2$  için DL seziciyle elde edilen BER grafikleri SNR 15dB'den sonra SIC-ML sezici ile elde edilenden üstün olmuştur.


#### 4. Tartışma ve Sonuç

DL ağları son yıllarda haberleşme sistemlerinde fiziksel katmanda artan işlem karmaşıklığını azaltan önemli argümanlardır. NOMA sistemlerinde SIC ve ML sezici işlemleri işlem karmaşıklığı yaratmaktadır. Bu çalışmada aşağı

yönlü NOMA ve yukarı yönlü NOMA haberleşme sistemlerinde alıcıda alınan işaret ve kanal katsayıları ile denkleştirilmiş işaretlerin işaret matrislerinden CNN ağı ile yakın ve uzak kullanıcı bitleri ortak kestirilmiştir. Aşağı yönlü NOMA sisteminde DL sezici ile hata başarımları ML ve SIC-ML sezicilerle benzer çıkarken, yukarı yönlü NOMA sistemlerinde DL sezici hata performansı bazı durumlarda daha iyidir. Öte yandan yukarı yönlü NOMA haberleşme sisteminde geleneksel sezicilerle elde edilen hata performans grafiğinde yüksek iletim SNR'larına gidildikçe oluşan hata katı (error floor) DL sezicilerle elde edilen hata performans grafiğinde gözlemlenmemektedir. Bu durum yukarı yönlü NOMA haberleşme sisteminde daha az iletim gücüyle DL sezicilerin geleneksel sezicilerle aynı hata performansı elde edilebileceğini göstermekte olup enerji sınırlı (energy limited) sistemler için önemli bir gelişmedir. Ayrıca SIC-ML ve ML seziciler kullanılmadan DL seziciler ile BER eğrileri elde edilmesi önemli bir avantajdır. Dolayısıyla NOMA haberleşme sisteminin işlem karmaşıklığı azaltılmış olmaktadır.

Doğru veri seti seçimi ve eğitimle DL teknikleri turbo kodlu veya polar kodlu NOMA sistemlerinde de uygulanabilmektedir. Kodlanmış NOMA sistemleri gelecek çalışmalarda uygulanması düşünülmektedir.

Diğer bir gelecek çalışması olarak kanalın alıcıda bilinmediği NOMA haberleşme sistemlerinde DL tekniklerinin etkileri araştırılacaktır.




Şekil 4 Aşağı Yönlü NOMA Sisteminde BER Eğrileri


#### Teşekkür

2021-75737790-02 kodlu bu proje, Zonguldak Bülent Ecevit Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir. Bu çalışmanın ortaya

çıkmasında verdiği destekten ötürü Bilimsel Araştırma Projeleri Birimine teşekkür ederiz.



**Şekil 5** Yukarı Yönlü NOMA Sisteminde UE<sub>1</sub> ve UE<sub>2</sub>'den eşit SNR'da işaret BS'e gönderilirken BER Eğrileri



**Şekil 6** BS'e yakın kullanıcıdan gönderilen işaret SNR'ı 20dB'de sabit tutulup, uzak kullanıcıdan 0 ile 30dB SNR aralığında işaret gönderilirken yukarı yönlü NOMA haberleşme sisteminde BER Eğrileri.

#### Kaynakça

- [1] Xuan, Z and Narayanan, K. 2020. Analog Joint Source-Channel Coding for Gaussian Sources over AWGN Channels with Deep Learning. International Conference on Signal Processing and Communication, 19-24 July, Bangalore, India.
- [2] Kim, M., Kim, N., Lee, W. and Cho, D. 2018. Deep Learning-Aided SCMA, IEEE Communications Letters, vol. 22, no. 4, pp. 720-723. doi: 10.1109/LCOMM.2018.2792019.
- [3] Ye, H., Li, G. Y. and Juang, B. 2018. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems, IEEE Wireless Communications Letters, vol. 7, no. 1, pp. 114-117. doi: 10.1109/LWC.2017.2757490
- [4] Ye, H., Liang, K., Li, G. Y. and Juang, B. 2020. Deep Learning-Based End-to-End Wireless Communication Systems With Conditional GANs as Unknown Channels, IEEE Transactions on Wireless Communications, vol. 19, no. 5, pp. 3133-3143. doi: 10.1109/TWC.2020.2970707.
- [5] Benjebbour, A., Saito, Y., Kishiyama, Y., Li, A., Harada, A. and Nakamura, T. 2013. Concept and practical considerations of non-orthogonal multiple access (NOMA) for future radio access. International Symposium on Intelligent Signal Processing and Communication Systems, 12- 15 Nov., Naha, Japan 770-774.
- [6] Benjebbour, A., Li, A., Kishiyama, Y., Jiang, H. and Nakamura, T., 2014. System-level performance of downlink NOMA combined with SU-MIMO for future LTE enhancements, IEEE Globecom Workshops (GC Wkshps), 8-12 Decemver, Austin, USA, pp. 706-710.
- [7] Emir, A., Kara, F., Kaya, H. and Yanikomeroglu, H. 2021. DeepMuD: Multi-User Detection for Uplink Grant-Free NOMA IoT Networks via Deep Learning, IEEE Wireless Communications Letters, vol. 10, no. 5, pp. 1133-1137. doi: 10.1109/LWC.2021.3060772.
- [8] Emir, A., Kara, F., Kaya, H. and Yanikomeroglu, H. 2021. Deep Learning Empowered Semi-Blind Joint Detection in Cooperative NOMA, IEEE Access, vol. 9, 61832-6185. doi: 10.1109/ACCESS.2021.3074350.
- [9] Narengerile and Thompson, J. 2019. Deep Learning for Signal Detection in Non-Orthogonal Multiple Access Wireless System. UK/ China Emerging Technologies (UCET), 21-22 August, Glasgow, UK, 1-4.
- [10] Emir, A., Kara, F., Kaya, H. and Li, X. 2021. Deep learning-based flexible joint channel estimation and signal detection of multi-user OFDM-NOMA, Physical Communication, Elsevier, vol. 48. doi: 10.1016/j.phycom.2021.101443.
- [11] Zhang, N., Cheng, K. and Kang, K. 2018. A Machine-Learning-Based Blind Detection on Interference Modulation Order in NOMA Systems, IEEE Communications Letters, vol. 22, no. 12, pp. 2463-2466. doi: 10.1109/LCOMM.2018.2874218.
- [12] Lin, C., Chang, Q. and Li, X. 2019. A Deep Learning Approach for MIMO-NOMA Downlink Signal Detection, Sensors, vol. 19, no. 11, pp 1-22. doi: 10.3390/s19112526.
- [13] Liu, M., Song, T. and Gui, G. 2019. Deep Cognitive Perspective: Resource Allocation for NOMA-Based Heterogeneous IoT With Imperfect SIC, IEEE Internet of Things Journal, vol. 6, no. 2, pp. 2885-2894. doi: 10.1109/JIOT.2018.2876152.
- [14] AbdelMoniem, M., Gasser, S. M., El-Mahallawy, M. S., Fakh, M. W. and Soliman, A. 2019. Enhanced NOMA system using adaptive coding and modulation based on LSTM neural network channel estimation, Applied Sciences (Switzerland), vol. 9, No 15, pp. 3022. doi: doi.org/10.3390/app9153022.
- [15] Luong, T. V., Ko, Y., Vien, N. A., Nguyen, D. H. N. and Matthaiou, M. 2019. Deep Learning-Based Detector for OFDM-IM, IEEE Wireless Communications Letters, vol. 8, no. 4, pp. 1159-1162. doi: 10.1109/LWC.2019.2909893.
- [16] Huang, H., Song, Y., Yang, J., Gui, G. and Adachi, F. 2019. Deep-Learning-Based Millimeter-Wave Massive MIMO for Hybrid Precoding, IEEE Transactions on Vehicular Technology, vol. 68, no. 3, pp. 3027-3032. doi: 10.1109/TVT.2019.2893928.
- [17] Lee, H., Lee, S. H. and Quek, T. Q. S. 2019. Deep Learning for Distributed Optimization: Applications to Wireless Resource Management, IEEE Journal on



- Selected Areas in Communications, vol. 37, no. 10, pp. 2251-2266. doi: 10.1109/JSAC.2019.2933890
- [18] Tang, F., Zhou Y. and Kato N. 2020. Deep Reinforcement Learning for Dynamic Uplink/Downlink Resource Allocation in High Mobility 5G HetNet, IEEE Journal on Selected Areas in Communications, vol. 38, no. 12, pp. 2773-2782. doi: 10.1109/JSAC.2020.3005495.
- [19] Kim, N, Kim, D., Shim, B. and Lee, K. B. 2021. Deep Learning-Based Spreading Sequence Design and Active User Detection for Massive Machine-Type Communications, IEEE Wireless Communications Letters, vol. 10, no. 8, pp. 1618-1622. doi: 10.1109/LWC.2021.3071453.
- [20] Yang, Y., Gao, F., Zhong, Z., Ai, B. and Alkhateeb, A. 2020. Deep Transfer Learning-Based Downlink Channel Prediction for FDD Massive MIMO Systems, IEEE Transactions on Communications, vol. 68, no 12, pp. 7485-7497. doi: 10.1109/TCOMM.2020.3019077
- [21] Park, J., Ji, D. J. and Cho, D., H. 2021. High-Order Modulation Based on Deep Neural Network for Physical-Layer Network Coding, IEEE Wireless Communications Letters, vol. 10, no. 6, pp. 1173-1177. doi: 10.1109/LWC.2021.3060750.
- [22] Thrane, J., Zibar, D. and Christiansen, H. L. 2020. Model-Aided Deep Learning Method for Path Loss Prediction in Mobile Communication Systems at 2.6 GHz, IEEE Access, vol. 8, pp. 7925-7936. doi: 10.1109/ACCESS.2020.2964103.
- [23] Felix, A., Cammerer, S., Dörner, S., Hoydis, J. and Ten Brink, S. 2018. OFDM-Autoencoder for End-to-End Learning of Communications Systems. IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC), 25-28 June, Calamata, Greece, pp. 1,5.
- [24] Li, T., Liu, W., Zeng, Z. and Xiong, N. N. 2021. DRLR: A Deep Reinforcement Learning based Recruitment Scheme for Massive Data Collections in 6G-based IoT networks, IEEE Internet of Things Journal(Early Acces). doi: 10.1109/JIOT.2021.3067904.
- [25] Yang, H., Xiong, Z., Zhao, J., Niyato, D., Xiao, L. and Wu, Q. 2021. Deep reinforcement learning-based intelligent reflecting surface for secure wireless communications, IEEE Transactions on Wireless Communications 20, 1, 375-388. doi: 10.1109/TWC.2020.3024860.
- [26] Yang, H., Alphones, A., Xiong, Z., Niyato, D., Zhao, J. and Wu, K. 2020. Artificial-Intelligence-Enabled Intelligent 6G Networks, IEEE Network, vol. 34, no. 6, pp. 272-280. doi: 10.1109/MNET.011.2000195.
- [27] Keçeli, A., Kaya, A. 2019. Video Görüntülerinde Şiddet İçeren Aktivitelerin Lstm Ağı İle Tespiti, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi , Cilt 21, Sayı 63, s.933-939. doi: 10.21205/deufmd.2019216321.
- [28] Bozyiğit, F., Taşkın, A., Akar, K., Kılınç, D. 2021. A Deep Learning-Based Hotel Image Classifier for Online Travel Agencies, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi , Cilt 23, Sayı 67, s.257-264, doi: 10.21205/deufmd.2021236722
- [29] Cun Y. L., Jackel, L. D., Boser, B., Denker, J. S., Graf, H. P., Guyon, I., Henderson, D., Howard, R. E., Hubbard, W. 1989. Handwritten digit recognition: applications of neural network chips and automatic learning, IEEE Communications Magazine, vol. 27, no. 11, pp. 41-46. doi: 10.1109/35.41400