

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPİŞTİRME
BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA) SİSTEMLERİNDE
YAPAY ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ**

**Hazırlayan
Şakir ŞİMŞİR**

**Danışman
Prof. Dr. Necmi TAŞPINAR**

Yüksek Lisans Tezi

**Haziran 2015
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPİŞTİRME
BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA) SİSTEMLERİNDE
YAPAY ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Şakir ŞİMŞİR**


**Danışman
Prof. Dr. Necmi TAŞPINAR**

**Bu çalışma; Erciyes Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından
FYL-2013-4799 kodlu proje ile desteklenmiştir.**

**Haziran 2015
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.




Şakir ŞİMŞİR

YÖNERGEYE UYGUNLUK


Dikgen Frekans Bölmeli Çoğullama-Serpiştirme Bölmeli Çoklu Erişim (OFDM-IDMA) Sistemlerinde Yapay Zeka Teknikleri ile Kanal Kestirimi adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan




Şakir ŞİMŞİR

Danışman



Prof. Dr. Necmi TAŞPINAR

Elektrik-Elektronik Mühendisliği ABD Başkanı



Prof. Dr. Necmi TAŞPINAR

Prof. Dr. Necmi TAŞPINAR danışmanlığında **Şakir ŞİMŞİR** tarafından hazırlanan “**Dikgen Frekans Bölmeli Çoğullama-Serpiştirme Bölmeli Çoklu Erişim (OFDM-IDMA) Sistemlerinde Yapay Zeka Teknikleri ile Kanal Kestirimi**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

25 /06 / 2015

JÜRİ:

Danışman : Prof. Dr. Necmi TAŞPINAR


Üye : Prof. Dr. İbrahim DEVELİ

Üye : Yrd. Doç. Dr. Ali ÖZEN

(Handwritten signatures of the jury members)

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 30/06/2015 tarih ve 2015/27-06 sayılı kararı ile onaylanmıştır.



Prof. Dr. Kâzım KEŞLİOĞLU

Enstitü Müdürü

TEŞEKKÜR

Öncelikle yüksek lisans eğitimim boyunca bilgi ve tecrübelerini benimle paylaşan, göstermiş olduğu yakın ilgi ve çalışmaya teşvik edici tutumu ile daha kolay yol almamı sağlayan danışman hocam sayın Prof. Dr. Necmi TAŞPINAR'a teşekkürlerimi sunarım.

Sadece bu tez çalışmasında değil, hayat boyu maddi ve manevi her türlü desteği sağlayıp bugünlere gelmemde büyük emekleri olan aileme çok teşekkür ederim.

Ayrıca tez çalışmamın yazım aşamasında, sevgisi ve güler yüzüyle bana güç verip desteğini benden esirgemeyen sevgili nişanlım Şerife KAVVAL'a teşekkür ederim.

Şakir ŞİMŞİR

Kayseri, Haziran 2015

DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPİŞTİRME BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA) SİSTEMLERİNDE YAPAY ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ

Şakir ŞİMŞİR

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Haziran 2015
Tez Danışmanı: Prof. Dr. Necmi TAŞPINAR**

ÖZET

Son yıllarda, hem Semboller Arası Girişim (ISI) hem de Çoklu Erişim Girişimi (MAI) problemini çözebilen Dikgen Frekans Bölmeli Çoğullama-Serpiştirme Bölmeli Çoklu Erişim (OFDM-IDMA) sistemi, kablosuz haberleşme sistemlerindeki yüksek veri iletim oranı talebini karşılamaya aday umut vadeden bir sistem olarak görülmektedir. Bu teknikte, çok yollu kanalların sebep olduğu ISI problemini gidermek için OFDM işlemleri kullanılırken, farklı kullanıcılara ait sinyaller, IDMA ilkesine dayalı olarak, kullanıcıya özgü serpiştiriciler yardımıyla ayırt edilir. Diğer taraftan OFDM-IDMA tekniğinde, çok düşük maliyetli IDMA tipi Çok Kullanıcılı Sezme (MUD) yardımıyla MAI bastırılabilir. Sonuç olarak OFDM ve IDMA sistemlerine has avantajlar, OFDM-IDMA tekniğinde birleştirilmektedir.

OFDM-IDMA sistemi birçok avantaja sahip olmasına karşın, yüksek hızlı ve geniş bantlı radyo kanallarının frekans seçimli ve zamana bağımlı olması nedeniyle, alıcıya gelen sinyallerin demodüle edilmesinden önce Kanal Durum Bilgisinin (CSI) elde edilmesi gerekmektedir. Bu işlem, kanal kestirimi olarak ifade edilir. Kanal kestirimi sayesinde, sönümlü kanalın sinyal üzerindeki etkisi ortadan kaldırılabilir. Eğer kanal kestirimi yapılmazsa, verilerin doğru bir şekilde alınması mümkün olmaz. En Küçük Kareler (LS) ve Minimum Ortalama Karesel Hata (MMSE) algoritmalarını da içeren çeşitli pilot tabanlı kanal kestirim yöntemleri vardır. LS algoritmasının basit ve kullanımının kolay olmasına karşın, sönümlü ve zamana göre değişken kanallardaki performansı oldukça kötüdür. Diğer taraftan, MMSE algoritması LS algoritması ile karşılaştırıldığında çok daha iyi bir performans sergiler, fakat çok fazla karmaşık yapıya sahip olması nedeniyle kullanışlı değildir.

Bu tezde, OFDM-IDMA sistemlerinde kanal kestirimi başarımları, Çok Katmanlı Algılayıcılar (MLP), Radyal Tabanlı Sinir Ağı (RBFNN) ve Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS) gibi yapay zeka teknikleri yardımıyla bilgisayar ortamında simülasyon çalışmaları yapılarak gerçekleştirilmiştir. Bunun sonucunda, LS ve MMSE gibi klasik kanal kestirim algoritmalarının sahip olduğu dezavantajlar ortadan kaldırılmıştır.

Anahtar Sözcükler: OFDM-IDMA, kanal kestirimi, LS, MMSE, yapay sinir ağları MLP, RBFNN, ANFIS.

**CHANNEL ESTIMATION USING ARTIFICIAL INTELLIGENCE
TECHNIQUES IN ORTHOGONAL FREQUENCY DIVISION
MULTIPLEXING-INTERLEAVE DIVISION MULTIPLE ACCESS (OFDM-
IDMA) SYSTEMS**

Şakir ŞİMŞİR

**Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, June 2015**

Thesis Supervisor: Prof. Dr. Necmi TAŞPINAR

ABSTRACT

In recent years, Orthogonal Frequency Division Multiplexing-Interleave Division Multiple Access (OFDM-IDMA) system which solves both Inter Symbol Interference (ISI) and Multiple Access Interference (MAI) problem is accepted as the promising candidate to meet the demand of high data transmission rates in wireless communication systems. In this technique, whereas ISI is resolved by OFDM, the signals belonging to different users are separated by user specific interleavers based on IDMA principle. On the other hand, in OFDM-IDMA technique, MAI can be suppressed with the aid of very low cost IDMA type Multiuser Detection (MUD). As a result, advantages belonging to OFDM and IDMA separately, are combined in OFDM-IDMA technique.

Although OFDM-IDMA system has many advantages, due to the high speed and broadband radio channels which are frequency selective and time dependent, Channel State Information (CSI) must be acquired before the demodulation of received signals. This process is called as channel estimation. Fading effect of the channel can be eliminated thanks to the channel estimation. If the channel estimation isn't carried out, it becomes impossible to take accurate data at the receiver side. There are various pilot based channel estimation techniques including Least Squares (LS) and Minimum Mean Square Error (MMSE) algorithms. The complexity of LS algorithm is simple and it is easy to implement the algorithm whereas its performance is poor for fast fading and time varying channels. On the other hand, MMSE algorithm shows better performance

compared to LS algorithm however it is not practicable because of having too complex nature.

In this thesis, channel estimation in OFDM-IDMA was performed by using artificial intelligence techniques such as Multilayered Perceptrons (MLP), Radial Basis Function Neural Network (RBFNN) and Adaptive Neuro Fuzzy Inference System (ANFIS) with the aid of computer simulations. Hence, the disadvantages belonging to classical channel estimation algorithms such as LS and MMSE were eliminated.

Keywords: OFDM-IDMA, channel estimation, LS, MMSE, artificial neural networks, MLP, RBFNN, ANFIS.

İÇİNDEKİLER

DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPIŞTİRME BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA) SİSTEMLERİNDE YAPAY ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ

BİLİMSEL ETİĞE UYGUNLUK SAYFASI	I
YÖNERGEYE UYGUNLUK SAYFASI.....	II
KABUL VE ONAY SAYFASI	III
TEŞEKKÜR.....	IV
ÖZET.....	V
ABSTRACT.....	VII
İÇİNDEKİLER	IX
KISALTMA VE SİMGELER.....	XIII
TABLolar VE ŞEKİLLER LİSTESİ.....	XIX

GİRİŞ

Tezin Literatürdeki Yeri	1
Tezin Amacı ve Önemi.....	4

1. BÖLÜM

DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPIŞTİRME BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA)

1.1. Gezgin Radyo Kanal Karakteristikleri	7
1.1.1. Zayıflama.....	7
1.1.2. Gölgeleme	8
1.1.3. Kırılma	9
1.1.4. Doppler Kayması	9
1.1.5. Gecikme Yayılmı	9

1.1.6. Çok Yollu Sönümleme	10
1.1.7. Çok Yollu Sönümleme Etkileri	11
1.1.7.1. Düz Sönümleme (Flat Fading)	11
1.1.7.2. Frekans Seçici Sönümleme (Frequency Selective Fading)	12
1.1.8. Doppler Yayılımı Sonucu Oluşan Sönümlemeler	12
1.1.8.1. Hızlı Sönümleme (Fast Fading)	12
1.1.8.2. Yavaş Sönümleme	13
1.2 İletim Çeşitlemeleri	13
1.2.1. Frekans Çeşitlemesi	13
1.2.2. Zaman Çeşitlemesi	14
1.2.3. Uzay Çeşitlemesi	15
1.3. Dikgen Frekans Bölmeli Çoğullama (OFDM)	15
1.3.1. Dikgenliğin Önemi	15
1.3.2. OFDM'nin Matematiksel Tanımı	16
1.3.3. OFDM'de Hızlı Fourier Dönüşümü (FFT)	19
1.3.4. OFDM'de Koruma Aralığı Eklenmesi	20
1.4. OFDM-IDMA Sistem Modeli	21
1.5. OFDM-IDMA Kanal Kestirimi	25
1.5.1. Pilot Ton Eklemeli Kanal Kestirim Yöntemleri	26
1.5.1.1. Blok Tipi Pilot Ton Yerleşimi	26
1.5.1.2. Tarak Tipi Pilot Ton Yerleşimi	27
1.5.2. Kanal Kestirim Algoritmaları	28
1.5.2.1. LS Algoritması	28
1.5.2.2. MMSE Algoritması	28

2. BÖLÜM

YAPAY ZEKÂ YÖNTEMLERİ

2.1. Yapay Sinir Ağları	30
2.1.1. Biyolojik Sinir Hücresi	30
2.1.2. Yapay Sinir Hücresi	31
2.1.3. Aktivasyon Fonksiyonları	32
2.1.3.1. Eşik Aktivasyon Fonksiyonu	32
2.1.3.2. Doğrusal Aktivasyon Fonksiyonu	33
2.1.3.3. Sigmoid Aktivasyon Fonksiyonu	34
2.1.4. Yapay Sinir Ağlarının Eğitilmesi	34
2.1.5. Öğrenme Algoritmaları	35
2.1.5.1. Geri Yayılım Algoritması	36
2.1.5.2. Levenberg-Marquardt Algoritması	39
2.1.6. Yapay Sinir Ağı Yapıları	41
2.1.6.1. Çok Katmanlı Algılayıcılar	41
2.1.6.2. Radyal Tabanlı Sinir Ağları	43
2.1.6.2.1. Ağırlıkların (W) Güncellenmesi	44
2.1.6.2.2. Düğümler Merkezinin (μ) Güncellenmesi	45
2.1.6.2.3 Yayılma Genişliğinin (σ) Güncellenmesi	45
2.2. Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS)	46
2.2.1. ANFIS Mimarisi	46
2.2.1.1. Karma Öğrenme Algoritması	48

3. BÖLÜM

SİMÜLASYON ÇALIŞMALARI

3.1. Giriş	50
3.2. Yapay Zeka Yöntemleri İçin OFDM-IDMA Sistem Parametreleri	50
3.3. MLP Sinir Ağları Kullanarak Kanal Kestirimi	51
3.4. RBF Sinir Ağları Kullanarak Kanal Kestirimi	56

3.5. ANFIS Kullanarak Kanal Kestirimi	61
--	-----------

4. BÖLÜM

SONUÇ VE ÖNERİLER

KAYNAKÇA	70
-----------------------	-----------

ÖZGEÇMİŞ.....	78
----------------------	-----------

KISALTMA VE SİMGELER

<u>Kısaltma</u>	<u>Anlamı</u>
OFDM	(Orthogonal Frequency Division Multiplexing) ⇒ Dikgen Frekans Bölmeli Çoğullama
IDMA	(Interleave Division Multiple Access) ⇒ Serpiştirme Bölmeli Çoklu Erişim
ISI	(Inter Symbol Interference) ⇒ Semboller Arası Girişim
MAI	(Multiple Access Interference) ⇒ Çoklu Erişim Girişimi
MUD	(Multiuser Detection) ⇒ Çok Kullanıcılı Sezme
CSI	(Channel State Information) ⇒ Kanal Durum Bilgisi
LS	(Least Squares) ⇒ En Küçük Kareler
MMSE	(Minimum Mean Square Error) ⇒ En Küçük Ortalama Karesel Hata
MLP	(Multilayered Perceptrons) ⇒ Çok Katmanlı Algılayıcılar
RBFNN	(Radial Basis Function Neural Network) ⇒ Radyal Tabanlı Sinir Ağı
ANFIS	(Artificial Neuro Fuzzy Inference System) ⇒ Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi
SISO	(Single Input Single Output) ⇒ Tek Girişli Tek Çıkışlı
MIMO	(Multiple Input Multiple Output) ⇒ Çok Girişli Çok Çıkışlı
BPA	(Backpropagation Algorithm) ⇒ Geri Yayılım Algoritması
BHO	Bit Hata Oranı
OKH	Ortalama Karesel Hata
LMS	(Least Mean Squares) ⇒ En Küçük Ortalama Kareler

FDM	(Frequency Division Multiplexing) ⇒ Frekans Bölmeli Çoğullama
IFFT	(Inverse Fast Fourier Transform) ⇒ Ters Hızlı Fourier Dönüşümü
FFT	(Fast Fourier Transform) ⇒ Hızlı Fourier Dönüşümü
DFT	(Discrete Fourier Transform) ⇒ Ayırık Fourier Dönüşümü
IDFT	(Inverse Discrete Fourier Transform) ⇒ Ters Ayırık Fourier Dönüşümü
QPSK	(Quadrature Phase Shift Keying) ⇒ Dördün Faz Kaydırmalı Anahtarlama
FEC	(Forward Error Correction) ⇒ İleri Hata Düzeltme
AWGN	(Additive White Gaussian Noise) ⇒ Toplanabilir Beyaz Gauss Gürültüsü
CP	(Cyclic Prefix) ⇒ Döngüsel Önek
CBC	(Chip by Chip) ⇒ Kırmık Kırmık
ESE	(Elementary Signal Estimator) ⇒ Temel Sinyal Kestirici
LLR	(Log-Likelihood Ratio) ⇒ Logaritmik Olasılık Oranı
DEC	(Decoder) ⇒ Kod Çözücü
APP	(A Posteriori Probability) ⇒ Sonsal Olasılık
ADALINE	(Adaptive Linear Neuron) ⇒ Uyarlanabilir Lineer Nöron
LM	Levenberg-Marquardt
FIS	(Fuzzy Inference System) ⇒ Bulanık Çıkarım Sistemi
OFDMA	(Orthogonal Frequency Division Multiple Access) ⇒ Dikgen Frekans Bölmeli Çoklu Erişim

<u>Simge</u>	<u>Anlamı</u>
P_R	Alınan sinyal gücü
P_T	İletilen sinyal gücü
f	Taşıyıcı frekansı
d	Alıcı ile verici arasındaki mesafe
G	Verici ve alıcı antenlerden gelen güç kazancı
Δf	Frekanstaki değişim
f_0	Kaynak frekansı
v	Kaynak ile alıcı arasındaki hız farkı
c	Işık hızı
B_c	Kanalın bant genişliği
B_s	İletilen sinyalin bant genişliği
T_s	Sinyal periyodu
T_c	Kanal uyum zamanı
Ψ	Alt taşıyıcı kümesi sayısı
$S_c(t)$	Taşıyıcı sinyal
$A_c(t)$	Taşıyıcı sinyalin genliği
$\phi_c(t)$	Faz açısı
$s(kT)$	Taşıyıcı sinyalin zaman domenindeki temsili
$T_{DÖ}$	Döngüsel önek süresi
d_k	k kullanıcısına ait olan veri seti
c_k	k . kullanıcının karmık dizisi

$x_k(j)$	k . kullanıcının sembol dizisi
J	Çerçeve uzunluğu
N_c	Alt taşıyıcı sayısı
W	Ayrık fourier dönüşüm matrisi
" H "	Hermit transpozu
$H_k(j)$	k . kullanıcının sönüm katsayısı
$Z(j)$	Toplanabilir beyaz Gauss gürültüsü
I	2×2 'lik birim matris
π_k	k . kullanıcının serpiştirilme işlemi
$r(j)$	Alıcıda algılanan toplam işaret
$E(\cdot)$	Ortalama değer
$Var(\cdot)$	Varyans
$Cov(\cdot)$	Kovaryans
$\zeta_k(j)$	k . kullanıcıya etki eden girişim ve gürültü toplamı
$e_{ESE}(x_k(j))$	k . kullanıcının ESE fonksiyonu için LLR değeri
$e_{DEC}(x_k(j))$	k . kullanıcının DEC fonksiyonu için LLR değeri
g	Dairesel dürtü cevabı
$(\cdot)^H$	Hermit matrisi
F	Ayrık Fourier dönüşüm (DFT) matrisi
$\hat{h}_{LS}$	Kanal frekans cevabı
n	Kanal gürültüsü
X	İletilen veri

y	Alınan veri
R_{gy}	g ve y arasındaki çapraz kovaryans matrisi
R_{yy}	y 'nin otokovaryans matrisi
σ_n^2	Gürültü varyansı
h_{MMSE}	Kanal frekans cevabı
R	Nöron giriş sayısı
$\mathbf{W}$	Ağırlık matrisi
b	Aktivasyon fonksiyonunun eşik değeri (bias)
n	Net giriş
a	Nöron çıkışı
$f(\cdot)$	Aktivasyon fonksiyonu
$\underline{e}_q$	q . giriş için hesaplanan hata değeri
α	Öğrenme oranı
$\delta^k(i)$	k . katmanda i . birimin net girişindeki değişimlere olan hassaslığı
$\nabla^2 V(\underline{x})$	Hessian matrisi
$\nabla V(\underline{x})$	Eğim (gradient)
$J(x)$	Jacobian matrisi
$\phi_j(\cdot)$	j 'inci gizli düğümde kullanılan radyal tabanlı fonksiyon
w_j	Gizli katmandan çıkış katmanına yapılmış olan bağlantılar (ağırlıklar)
y	Ağ çıkışı
n	Gizli Düğüm sayısı
σ_j	j 'nci düğümün yayılma genişliği

μ_j	j 'nci düğümün merkez genişliği
λ_w	Sinirsel ağırlıkların öğrenme oranı
λ_μ	düğüm merkezlerinin öğrenme oranı
λ_σ	Ağ yayılımına bağlı öğrenme oranı
$O_{1,i}$	1. ANFIS katmanının i . düğüm çıkışı
S_p	Pilot sembolü
E_b/N_0	Bit başına enerjinin gürültüye oranı

ŞEKİLLER LİSTESİ

Şekil 1.1	Radyo yayılım etkileri	8
Şekil 1.2	Çok yollu gecikme yayılımı	10
Şekil 1.3	Çok yollu yayılım etkisi	11
Şekil 1.4	Frekans çeşitlemesi.....	14
Şekil 1.5	Zaman Çeşitlemesi	14
Şekil 1.6	OFDM ve FDM'de bant genişliği kullanımı.....	16
Şekil 1.7	OFDM spektrum örnekleri: (a) tek taşıyıcılı spektrum (b) 5 taşıyıcılı spektrum	17
Şekil 1.8	Döngüsel önek ekleme işlemi.....	20
Şekil 1.9	K eşzamanlı kullanıcıya sahip OFDM-IDMA sistemi verici ve alıcı yapısı.....	21
Şekil 1.10	Blok tipi pilot ton yerleşimi.....	26
Şekil 1.11	Tarak tipi pilot ton yerleşimi	27
Şekil 2.1	Biyolojik sinir hücresi yapısı.....	31
Şekil 2.2	Yapay sinir hücresi	31
Şekil 2.3	Eşik aktivasyon fonksiyonu.....	33
Şekil 2.4	Doğrusal aktivasyon fonksiyonu	33
Şekil 2.5	Sigmoid aktivasyon fonksiyonu	34
Şekil 2.6	Eğitim işlemi	35
Şekil 2.7	Üç katmanlı yapay sinir ağı	36
Şekil 2.8	Çok katmanlı algılayıcı (MLP) yapısı	42
Şekil 2.9	Radyal tabanlı sinir ağı yapısı	43
Şekil 2.10	(a) İki girişli ve iki kurallı birinci dereceden Sugeno bulanık model; (b) eşdeğer ANFIS yapısı.....	47
Şekil 3.1	MLP sinir ağı kanal kestirimci yapısı.....	51
Şekil 3.2	OFDM-IDMA sisteminde MLP kanal kestirimcisinin BHO performansı.....	54
Şekil 3.3	OFDM-IDMA sisteminde MLP kanal kestirimcisinin OKH performansı	55
Şekil 3.4	Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO	

	performansları.....	56
Şekil 3.5	Radyal tabanlı sinir ağı kanal kestirimci yapısı.....	57
Şekil 3.6	OFDM-IDMA sisteminde RBFNN kanal kestirimcisinin BHO performansı.....	58
Şekil 3.7	OFDM-IDMA sisteminde RBFNN kanal kestirimcisinin OKH performansı.....	59
Şekil 3.8	Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO performansları.....	60
Şekil 3.9	ANFIS kanal kestirimci yapısı	62
Şekil 3.10	OFDM-IDMA sisteminde ANFIS kanal kestirimcisinin BHO performansı.....	63
Şekil 3.11	OFDM-IDMA sisteminde ANFIS kanal kestirimcisinin OKH performansı.....	64
Şekil 3.12	Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO performansları.....	65

GİRİŞ

Tezin Literatürdeki Yeri

Kablosuz haberleşme sistemlerinde, geniş bantlı görüntü yayını, yüksek kaliteli ses ve internet uygulamalarına talebin günden güne artması, araştırmacıları yüksek veri transfer oranında haberleşme yapabilmek için yeni teknolojiler bulmaya mecbur bırakmaktadır. Aynı zamanda, yüksek veri hızıyla birlikte güvenli iletişime de ihtiyaç duyulmaktadır. Başka bir deyişle, yeni nesil kablosuz sistemlerin daha iyi bir kaliteye ve kapsama alanına sahip olması, daha güçlü olup bant genişliğini verimli kullanması ve farklı çevrelere uygulanabilir olması beklenmektedir.

Dikgen Frekans Bölmeli Çoğullama (OFDM) ve Serpiştirme Bölmeli Çoklu Erişim (IDMA) sistemlerinin birleştirilmesiyle meydana getirilen OFDM-IDMA, yüksek veri transfer oranlarında iletişimi sağlaması ve kablosuz haberleşmede karşılaşılan birçok soruna çözüm olması beklenen iletim teknolojilerinin başında yer almaktadır. Semboller Arası Girişim (ISI) ve Çoklu Erişim Girişimi (MAI) gibi kablosuz haberleşmede karşılaşılan iki temel problemi aynı anda ortadan kaldırabilme yetisine sahip olması, OFDM-IDMA sistemini diğer kablosuz haberleşme teknolojileri arasında öne çıkarmaktadır. Bünyesinde bulunan OFDM sisteminin bir özelliği olarak, iletim kanalı, dar bantlı alt kanallara bölünerek veriler daha uzun sembol periyotlarında paralel bir şekilde gönderilir. Böylece ISI probleminin önüne geçilmiş olur. Diğer taraftan, farklı kullanıcılara ait sinyaller, bünyesinde bulunan IDMA sisteminin getirdiği bir özellik olarak, kullanıcıya has serpiştiriciler vasıtasıyla ayrıştırılırken, düşük maliyetli IDMA tipi Çok Kullanıcılı Sezme (MUD) yardımıyla da MAI ortadan kaldırılır. Böylelikle hem OFDM hem de IDMA sistemine özgü avantajlardan aynı anda yararlanır [1-15].

OFDM-IDMA sistemi, birçok avantaja sahip olmasına karşın, kablosuz haberleşmenin doğası gereği verici ve alıcı arasındaki engeller (dağlar, yüksek binalar, vs.) iletilen sinyalin yansımalarına, kırılmasına ve dağılmasına sebep olup, alıcıya aynı sinyalin çoklu yollardan gelmiş, farklı gecikme ve zayıflama değerlerindeki kopyalarının toplamı ulaşır. Bu sebeple, alınan sinyalin gücünde dalgalanmalar meydana gelir. Bu dalgalanmalar, sönümleme olarak adlandırılmaktadır. İletilen sinyalin alıcıda hatasız olarak tekrardan elde edilebilmesi için, demodülasyon işleminden önce sönümleme etkisinin ortadan kaldırılması gerekmektedir. Bu etkiyi ortadan kaldırabilmek için ise, Kanal Durum Bilgisinin (CSI) elde edilmesi gerekir. Bu işlem kanal kestirimi olarak adlandırılır [16-42].

Kör ve pilot tabanlı olmak üzere iki çeşit kanal kestirim yöntemi bulunmaktadır. Kör kanal kestirim metodunda, iletilen verilere herhangi bir ekleme yapılmaksızın, yalnızca alınan bilgi sinyalinin istatistiksel özelliklerinden yararlanılarak kanal durum bilgisi elde edilir. Bu özelliğiyle kör kanal kestirim yönteminde, pilot tonlara ihtiyaç duymadan kanal katsayılarının elde edilmesi bir avantajmış gibi görünse de, iletilen sinyalin istatistiksel özelliklerinden kanal katsayılarını tam olarak tahmin edebilmek için alıcıda çok miktarda veriye ihtiyaç duyulacağından dolayı çok fazla tercih edilen bir yöntem değildir. Bu durum, kablosuz haberleşme kanallarının zamana bağımlı olması nedeniyle büyük bir dezavantaj teşkil eder. Bu yüzden kablosuz sistemlerde, kör kanal kestirim yöntemleri genellikle pilot tabanlı kanal kestirim metodlarından daha kötü bir performansa sahiptir [16-19].

Pilot tabanlı kanal kestirim yönteminde, pilot tonları olarak adlandırılan ve alıcı tarafından da bilinen veriler, vericide bilgi sinyaline eklenir. Daha sonra, ham veriyle birlikte iletme sokularak kablosuz haberleşme kanalı boyunca sönümlemeye maruz bırakılır. Sonuç olarak pilot tonlarının bozulmaya uğramış hali ile bozulmamış hali, kanal kestirimi amacıyla geliştirilmiş olan çeşitli algoritmalarda kullanılarak kanal frekans cevabı elde edilir. Pilot tabanlı kanal kestirim yöntemi de, pilot tonlarının yerleşimi bakımından, blok tipi ve tarak tipi olmak üzere ikiye ayrılmaktadır. Blok tipi pilot yerleşiminde kanal kestirimi için kullanılan semboller, alt taşıyıcıların tamamına belirli periyotlarla düzenli olarak yerleştirilir. Eğer kanal blok boyunca değişkenlik göstermiyor ve durağan kalıyorsa, bütün alt taşıyıcılar üzerinde pilot tonları olduğu için

hatasız bir kanal kestirimi gerçekleştirilir. Diğer taraftan, birbirine komşu OFDM sembolleri arasında değişkenlik gösteren hızlı sönmümlü kanallar için tarak tipi pilot yerleşimi olarak bilinen, pilot tonlarının alt taşıyıcılara belirli aralıklarla yerleştirildiği yerleşim yöntemi kullanılmaktadır. Bu pilot yerleşim türünde, kanal frekans cevabını elde edebilmek için ara değerlendirme (interpolasyon) hesabı yapılır [20-42].

Kanal frekans cevaplarını elde edebilmek için, En Küçük Kareler (LS) ve En Küçük Ortalama Karesel Hata (MMSE) gibi klasik kanal kestirim algoritmalarından yararlanılabilir. Bu iki algoritma, karmaşıklık ve performans bakımından farklılık göstermektedir. LS algoritması, yapısı itibarıyla çok basit olup herhangi bir sisteme kolaylıkla uygulanabilir, fakat hızlı sönmümlü ve zamana göre değişken kanallarda kötü bir performans gösterir. Dolayısıyla bu algoritma, karmaşıklıktan ziyade performansa daha çok önem verilen sistemlerde tercih edilmez. Diğer taraftan, MMSE algoritması, gürültü varyansı ve kanal kovaryansı bilgilerini kullanması sebebiyle kanal katsayılarını tahmin etmede LS algoritmasına oranla çok daha iyi bir performans gösterir. Fakat kanal bilgilerine olan ihtiyaç, MMSE algoritmasını herhangi bir haberleşme teknolojisinde kullanılamayacak kadar karmaşık bir hale getirmektedir [22-33].

OFDM-IDMA sisteminde yapay zeka teknikleriyle kanal kestirimi üzerine yapılmış çalışma bulunmamasına rağmen, Tek Girişli Tek Çıkışlı (SISO) OFDM ve Çok Girişli Çok Çıkışlı (MIMO) OFDM sistemleri gibi diğer iletişim teknolojilerinde, sezgisel yöntemler kullanılarak yapılmış birçok çalışma mevcuttur [43-52].

[43,44] no'lu çalışmalarda, kanal kestirimi amacıyla tasarlanan yapay sinir ağı tabanlı kestirimciler, Geri Yayılım Algoritması (BPA) kullanılarak eğitilip OFDM veya MIMO-OFDM gibi iletişim sistemlerine uygulanmıştır. [43]'de modellenen yapay sinir ağı tabanlı kestirimci, MIMO-OFDM sistemine uygulanmıştır. Daha sonra sistem performansı bit hata oranı (BHO) kriterine göre değerlendirilmiştir. [44]'de bu kez OFDM sistemi için üç katmanlı yapay sinir ağı, kanal frekans cevaplarını doğruya en yakın şekilde elde edebilmek için tasarlanıp, BHO ve ortalama karesel hata (OKH) grafiklerinin elde edilmesi suretiyle sistem performansı değerlendirilmiştir. [45] no'lu çalışmada ise yine geri yayılım algoritmalı yapay sinir ağı, kanal kestirimi amacıyla tasarlanmıştır, ancak diğer çalışmalardan farklı olarak bu çalışmada kestirimci performansı, Rician, Rayleigh ve TU6 (Typical Urban 6) gibi üç farklı kanalda

incelenmiştir. Sistem performansı BHO kriterine göre değerlendirilmiştir. [46] ve [47] no'lu çalışmalarda ise, Levenberg-Marquardt Algoritması ile eğitilen yapay sinir ağı tabanlı kanal kestirimciler sırasıyla OFDM ve MIMO-OFDM sistemlerine uygulanmıştır. [47]'de, iki giriş iki çıkışlı Çok Katmanlı Algılayıcı (MLP), kanal kestirimci olarak modellenmiş olup LS ve En Küçük Ortalama Kareler (LMS) gibi klasik algoritmalarla, BHO ve OKH kriterlerine göre karşılaştırılmıştır. Önerilen kanal kestirimci, her iki algoritmadan da üstün performans göstermiştir. [48]'de ise, yine yapay sinir ağı tabanlı kanal kestirimci önerilmiştir, fakat diğerlerinden farklı bir eğitime metodu uygulanmıştır. Önerilen kestirimci, geri besleme sembolleriyle sürekli olarak eğitime tabi tutulmuştur. Böylelikle hızlı sönmümlü kanalların sahip olduğu bozucu etki sebebiyle meydana gelen kestirim hataları en aza indirgenmiştir. [49] no'lu çalışmada, Radial Tabanlı Yapay Sinir Ağı (RBFNN) kullanılmak suretiyle tasarlanan kanal kestirimci, MIMO-OFDM sistemi için önerilmiştir. Önerilen kestirimci, LS, LMS ve MLP kanal kestirimcileriyle OKH ve BHO kriterlerine göre karşılaştırılmış ve hepsinden daha iyi bir performans gösterdiği yapılan simülasyon çalışmalarıyla kanıtlanmıştır. [50] ve [51] no'lu çalışmalarda Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS) tabanlı kanal kestirimci, sırasıyla OFDM ve MIMO-OFDM iletişim teknolojileri için önerilmiştir. Her iki çalışmada da, önerilen kestirimcinin performansı BHO ve OKH kriterlerine göre değerlendirilmiştir. [52] no'lu çalışmada ise, iki katmanlı yapay sinir ağına dayanan yarı-kör MIMO-OFDM kanal kestirim algoritması önerilmiştir. Önerilen algoritma sadece LS ile karşılaştırılmış ve daha iyi bir performans sergilediği gözlemlenmiştir.

Tezin Amacı ve Önemi

OFDM-IDMA, kablosuz haberleşmede karşılaşılan iki temel problem olan ISI ve MAI ile başa çıkabilen ve aynı zamanda yüksek veri transfer oranında haberleşme yapmaya olanak sağlayan bir sistem olmasına karşın, diğer iletim teknolojilerinde olduğu gibi, iletilen verilerin alıcıda hatasız olarak tekrardan elde edilebilmesi için kanal kestirime ihtiyaç duyulmaktadır. Bu gibi sistemlerde girişimi ortadan kaldırmak ve denkleştirme işlemi için güvenilir kanal kestirim metotlarına ihtiyaç duyulur. Eğer kanal kestirimi yapılmazsa, verilerin doğru bir şekilde alınması mümkün olmaz.

OFDM-IDMA sisteminde, daha önce diğer iletim teknolojilerinde de sıkça kullanılmış olan, LS ve MMSE gibi klasik kanal kestirim yöntemlerinden faydalanılmıştır. Fakat, bu tür algoritmalar, performans ve karmaşıklık bakımından birbirleriyle karşılaştırıldığında farklı sonuçlar vermektedir. Örneğin, yüksek bir performansa sahip ve kanal durum bilgisini gerçeğe en yakın şekilde tahmin edebilen MMSE algoritması; kanalın istatistiksel verileri ve gürültü bilgisine ihtiyaç duyması sebebiyle oldukça karmaşık bir yapıya sahiptir ve herhangi bir sisteme uygulanması halinde çalışma hızını hatırı sayılır bir şekilde düşüreceğinden kullanışlı değildir. Diğer taraftan, LS ve LMS gibi yöntemler, MMSE algoritmasına göre oldukça basit bir yapıya sahip ve herhangi bir sisteme rahatlıkla uygulanabilir olmalarına rağmen, sönümlü ve zamana göre değişken kanallarda oldukça düşük bir performans gösterirler. Bu yüzden, yüksek performans beklenen ve kabul edilebilir hata oranının düşük olduğu sistemlerde bu algoritmalar tercih edilmez.

Bütün bu durumlar göz önüne alındığında, OFDM-IDMA için, sistem karmaşıklığını çok fazla artırmadan kanal durum bilgisini en doğru şekilde elde edip kanalın bozucu etkilerinin ortadan kaldırılmasını sağlayacak bir kanal kestirim metoduna ihtiyaç duyulmaktadır. Bu yüzden, bu tezde önerilen, MLP, RBFNN ve ANFIS gibi yapay zeka tekniklerinden yararlanılarak bulunan kanal kestirim yöntemleri ile, literatürde mevcut uygulanmış olan geleneksel kanal kestirim metodlarının sahip olduğu dezavantajların asgari düzeye indirilmesi amaçlanmaktadır.

Bu tezde amaçlanan bir diğer hedef ise, yapay zeka teknikleri yardımıyla pilot tonlarına ihtiyaç duymadan, yalnızca ham veriyi kullanarak kanal durum bilgisini elde etmektir. Böylelikle pilot tonlarının sebep olduğu yükten kurtulup bant genişliğini daha verimli kullanma fırsatı doğacaktır. Bu da, önerdiğimiz yöntemleri, diğer klasik algoritmalar arasında daha avantajlı bir konuma getirecektir.

Tezin birinci bölümünde, gezgin radyo karakteristikleri, dikgen frekans bölmeli çoğullama tekniği, dikgen frekans bölmeli çoğullama-serpiştirme bölmeli çoklu erişim sistem modeli ve son olarak LS ve MMSE gibi klasik kanal kestirim algoritmalarından bahsedilmiştir.

İkinci bölümde, bu tez çalışmasında kanal kestirimi için kullanılmış olan yapay zeka yöntemlerinden Çok Katmanlı Algılayıcılar, Radyal Tabanlı Sinir Ağları ve Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi açıklanmıştır.

Üçüncü bölümde, yapay zeka teknikleri kullanılarak yapılan kanal kestirimi ile ilgili elde edilen simülasyon sonuçları verilmiştir.

Dördüncü ve son bölümde ise, elde edilen simülasyon sonuçları yorumlanıp çeşitli değerlendirmeler yapılmıştır. Ayrıca ilerde yapılacak çalışmalar için önerilerde bulunulmuştur.

1. BÖLÜM

DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA-SERPİŞTİRME BÖLMELİ ÇOKLU ERİŞİM (OFDM-IDMA)

1.1. Gezgin Radyo Kanal Karakteristikleri


Kablosuz iletişimde, haberleşme kanalı olarak hava ortamı kullanılmaktadır. Bu yüzden sinyal yayılımı, kablolu iletişimde olduğu gibi düzgün değildir. Bunun sebebi, kablolu haberleşmedeki gibi iletilen sinyalin direk olarak alıcıya gelmeyip, yansımış, kırılmış ve dağılmış kopyalarının alıcıya ulaşmasıdır. Diğer taraftan kanal boyunca sinyalin gürültüye maruz kalması, taşıyıcı frekans kaymaları (Doppler kayması) ve gölgeleme gibi olumsuzluklar, iletilen sinyalin alıcıda hatasız olarak tekrardan elde edilebilmesini oldukça zorlaştırmaktadır. Bu yüzden, uygun iletişim sistemi mimarisini oluşturabilmek ve optimum parametreleri belirleyebilmek için haberleşme kanalı karakteristiklerini tam olarak anlamak hayati önem taşımaktadır [53-55]. Radyo kanal karakteristiklerini etkileyen faktörlerden bazıları aşağıda yer almaktadır:

1.1.1. Zayıflama

Zayıflama, sinyalin bir noktadan bir noktaya iletilmesi sırasında gücünde meydana gelen azalmadır. Alıcı ile verici arasındaki mesafe, iletim yolu üzerindeki engeller ve çoklu yol etkileri, sinyalin zayıflamasına neden olan etkenlerdir. Alıcı ile verici arasında herhangi bir engelin olmaması durumunda, alıcıya gelen sinyalin gücü, taşıyıcı frekansının karesi ve iletim mesafesinin karesiyle ters orantılı olarak değişmektedir. P_R ve P_T sırasıyla alınan ve iletilen sinyal gücünü ifade ettiğine göre, sinyalin boş alandaki yayılımı aşağıdaki bağıntıyla ifade edilebilir:

$$P_R \propto \frac{G * P_T}{f^2 * d^2} \quad (1.1)$$

Burada f taşıyıcı frekansı, d alıcı ile verici arasındaki mesafe, G ise verici ve alıcı antenlerden gelen güç kazancıdır [54]. Şekil 1.1'de zayıflamaya neden olan bazı radyo yayılım etkileri yer almaktadır.



Şekil 1.1. Radyo yayılım etkileri.

1.1.2. Gölgeleme

Gölgeleme, alıcı ile verici arasında yer alan ve aynı zamanda sinyalin zayıflamasına da sebep olan bina ve tepeler başta olmak üzere çeşitli engellerin sebep olduğu bir problemdir. Yüksek binaların bolca bulunduğu şehir merkezleri ile yüksek tepelerin bulunduğu yerleşim merkezlerinde meydana gelen gölgelemeler haberleşmede büyük sorun teşkil etmektedir. Gölgelemenin sebep olduğu sinyal üzerindeki bozulmaların önüne geçmek ve sağlıklı bir haberleşme ortamı oluşturabilmek için vericiler mümkün olduğunca yüksek yerlere kurulmalıdır [54].

1.1.3. Kırılma

Kırılma, alıcı ile verici antenler arasında bulunan binalar, araçlar, duvarlar ve ağaçlar gibi çeşitli engellere sinyalin ulaşmasıyla, bu engellerin arkasında ikincil sinyallerin meydana gelmesidir. Kırınım miktarı, sinyalin frekansına göre değişim göstermektedir. Düşük frekanslı sinyaller, yüksek frekanslı sinyallerden daha fazla kırınımına uğrarlar [55].

1.1.4. Doppler Kayması

Hareket, sinyal frekansında kaymaya sebep olmaktadır. Sinyal kaynağı ya da alıcı hareket ettirildiği zaman, alıcıya ulaşan sinyalin frekansıyla kaynaktan çıkan sinyalin frekansı aynı olmayacaktır. Sinyal kaynağı, alıcıya doğru hareket ettirilirse, alıcıdaki sinyalin frekansı, kaynak frekansından daha büyük olur. Tam tersi durumda bu kez sinyal kaynağı alıcıdan uzaklaşacak şekilde hareket ettirilirse, alıcıdaki sinyalin frekansı kaynak frekansından daha düşük olacaktır. Harekete bağlı olarak sinyal frekansında meydana gelen bu değişmeye Doppler Kayması denilmektedir. Doppler kayması, gezgin radyo sistemleri geliştirilirken dikkate alınması gereken önemli bir etkidir.

Doppler etkisinden dolayı frekansta meydana gelen değişim miktarı, kaynak ve alıcının birilerine göre hareketine ve dalganın yayılım hızına bağlıdır. Frekanstaki kayma aşağıdaki şekilde ifade edilmektedir:

$$\Delta f \approx \pm f_0 \frac{v}{c} \quad (1.2)$$


Burada Δf frekanstaki değişimi, f_0 kaynak frekansını, v kaynak ile alıcı arasındaki hız farkını, c ise ışık hızını simgelemektedir [56].

1.1.5. Gecikme Yayılımı

Vericiden alıcıya ulaşan radyo sinyali, direkt olarak gelen sinyal ile, bu sinyalin binalar, tepeler ve ağaçlar gibi çeşitli engellerden yansıtılarak veya kırılarak gelen gecikmiş kopyalarının toplamından oluşmaktadır. Orijinal sinyalin yansıyan ve kırılan kopyaları alıcıya daha geç ulaşır. Bunun sebebi, yansıyan sinyallerin direkt sinyale göre daha fazla

yol almasıdır. Bu da her bir kopyanın farklı varış zamanlarına sahip olmasına ve bunun sonucunda da alıcıya gelen enerjinin zaman domeninde yayılmasına sebep olmaktadır. Gecikme yayılımı, alıcıya ulaşan ilk çok yollu sinyal ile bu sinyalin geciken son kopyası arasındaki zaman yayılımıdır.

Sayısal haberleşme sistemlerinde, gecikme yayılımı semboller arası girişime sebep olmaktadır. Bu durum, geciken çoklu yol sinyalleri ile bu sinyalleri takip eden sembollerin birbiri üzerine binmesinden kaynaklanmaktadır. Semboller arası girişim, kablosuz haberleşme sistemlerinde karşılaşılan ve bilginin alıcıda hatasız bir şekilde alınmasına engel teşkil eden önemli bir problemdir. Şekil 1.2'de gecikme yayılımı sebebiyle meydana gelen semboller arası girişimin alınan sinyal üzerindeki bozucu etkisi görülmektedir [57].




Şekil 1.2. Çok yollu gecikme yayılımı.

1.1.6. Çok Yollu Sönümlleme

Kablosuz haberleşmede çok yollu yayılım, radyo sinyallerinin, iyonosferik yansıma ve kırılma, su yüzeyi yansıması ya da binalar ve dağlar gibi çevresel objelerin sebep

olduğu yansımalar vasıtasıyla alıcı antenine iki veya daha fazla yoldan ulaşmasıdır. Şekil 1.3'de çok yollu yayılım etkisinin nasıl meydana geldiği görülmektedir. Şekilden de görüleceği üzere alıcı antenine, gönderilen sinyalin farklı yönlerden gelen, farklı gecikme, zayıflama ve faz değerlerine sahip kopyalarının toplamı ulaşmaktadır. Alıcıya ulaşan bu dalgaların toplamı da alınan sinyalin genliğinde ve fazında değişimlere sebep olur. Meydana gelen bu durum, çok yollu sönümlenme olarak adlandırılmaktadır. Çok yollu sönümlenme, sayısal radyo haberleşmesinde hatalara sebep olan ve iletişim kalitesini düşüren önemli bir problemdir [53].



Şekil 1.3. Çok yollu yayılım etkisi.

1.1.7. Çok Yollu Sönümlenme Etkileri

Çok yollu yayılım sonucunda gönderilen sinyal, kanal boyunca düz (flat) ya da frekans seçici (frequency selective) sönümlenmeye maruz kalır.

1.1.7.1. Düz Sönümlenme (Flat Fading)

Kanalın bant genişliği, iletilen sinyalin bant genişliğinden fazla ise ($B_c > B_s$), işaret düz sönümlenmeye uğrar. Sinyalin spektral formu aynı kalırken kazancı değişir. Dar bantlı

sinyaller, kanal bant genişliğinden daha küçük bant genişliğine sahip olduğu için bu kategoride yer alır. Düz sönümlü kanallar, kazançta ve frekans spektrumunda değişime sebep olmasıyla haberleşmede çeşitli sorunlar meydana getirir. Kazançtaki bozulmalar derin sönümlemelere sebep olabilir, dolayısıyla bazı frekanslardaki güç değerlerinde önemli ölçüde artırım yapılması gerekebilir. Diğer taraftan, frekans domenindeki herhangi bir boşluk sinyalde kayıplara neden olacağı için, dar bantlı sinyallere has bir problem olarak da bilinen yıkıcı girişimler, sinyalin güç spektrumunda derin boşluklar oluşmasına sebep olabilmektedir [54].

1.1.7.2. Frekans Seçici Sönümleme (Frequency Selective Fading)

Eğer iletilen sinyalin bant genişliği, frekans bandı boyunca sabit kazançlı ve doğrusal fazlı frekans cevabına sahip olan kanalın bant genişliğinden daha büyükse, sinyal üzerinde frekans seçici sönümleme meydana gelir. Bu gibi durumlarda, çok yollu gecikme yayılımı sembol süresinden daha büyük olmaktadır. Sonuç olarak, alınan sinyal, iletilen dalga formunun zayıflatılmış ve geciktirilmiş çoklu versiyonlarını içerir. Bu yüzden, frekans seçici sönümleme, iletilen sembolün kanal içerisindeki zaman yayılımının bir sonucu olarak meydana gelmektedir. Bu da semboller arası girişime (ISI) sebep olmaktadır. Frekans seçici kanallar için, iletilen sinyal spektrumu, kanalın bant genişliğinden daha büyük bir değere sahiptir ($B_s > B_c$). Bu tür kanallar, geniş bantlı (wideband) kanallar olarak da adlandırılmaktadır [58,59].

1.1.8. Doppler Yayılımı Sonucu Oluşan Sönümlemeler

1.1.8.1. Hızlı Sönümleme (Fast Fading)

Hızlı sönümlü kanallarda, kanal dürtü cevabı sinyalin sembol periyodu boyunca hızlı bir şekilde değişir. Bunun yanında sinyal, Doppler yayılımından dolayı frekans dağılımına ve bunun sonucunda da bozulmaya uğrar. $T_s > T_c$ ve $B_s > B_D$ olduğu durumlarda hızlı sönümleme meydana gelmektedir. Burada T_s sinyal süresini, T_c kanal uyum zamanını, B_s sinyal bant genişliğini, B_D ise kanal bant genişliğini simgelemektedir. Çok düşük veri hızlarında iletişim yapıldığında, sembol periyotları çok büyük olacağından dolayı hızlı sönümleme meydana gelme olasılığı oldukça artacaktır [54].

1.1.8.2. Yavaş Sönümleme


Yavaş sönümlü kanallarda, kanal dürtü cevabındaki değişim oranı, iletilen sinyaldeki değişimden çok daha azdır. Başka bir ifadeyle, eğer sinyal bant genişliği Doppler yayılımından çok daha fazla ise, Doppler yayılımından dolayı frekansta meydana gelen kayma önemsiz hale gelecektir. Bu durumda meydana gelen sönümleme yavaş sönümleme olarak adlandırılmaktadır. Yavaş sönümleme, en azından bir sembol periyodu boyunca kanalın çoğunlukla sabit kaldığı sönümleme çeşidi olarak düşünülebilir. Özet olarak, yavaş sönümlemenin meydana gelebilmesi için, $T_s < T_c$ ve $B_s > B_D$ şartlarının sağlanması gerekmektedir [54]:

1.2 İletim Çeşitlemeleri

Çeşitleme teknikleri, sönümlü kanallardaki bozucu etkiyi ortadan kaldırmak ve sistem performansını iyileştirmek amacıyla geliştirilmiştir. Sadece tek bir sinyali tek bir kanaldan iletmek yerine, bu sinyalin birden çok kopyasının birden fazla ve birbirinden farklı kanallardan iletilmesi esasına dayanmaktadır. Böylelikle iletilen kopyaların bazıları derin sönümlemeye uğrarken, geri kalanları sağlıklı bir şekilde alıcıya ulaşabilmektedir. Sonuç olarak, bu yöntemle birlikte sinyalin bütün kopyalarının aynı anda sönümlemeye maruz kalıp bozulmaya uğrama olasılığının çok düşük olması sebebiyle, iletilen sinyal alıcıda hatasız olarak elde edilebilmektedir [60,61]. Aşağıda kablosuz radyo haberleşmesinde kullanılan bazı çeşitleme teknikleri verilmiştir:

1.2.1. Frekans Çeşitlemesi


Frekans çeşitlemesi, bilgi sinyalinin farklı frekanslardaki taşıyıcılar ile modüle edilmesiyle gerçekleştirilmektedir. Her bir taşıyıcı arasında en az bir uyum bant genişliği kadar mesafe olmalıdır, böylece sinyalin her bir kopyası birbirinden bağımsız bir şekilde sönümlemeye uğrar. Birbirinden bağımsız olan bu kopyalar, orijinal sinyali elde edebilmek için alıcıda yeniden birleştirilirler. Frekans çeşitlemesi, frekans seçici sönümlemeye karşı kullanılan bir tekniktir [60-61]. Şekil 1.4, frekans çeşitlemesine bir örnektir. Burada $s(t)$ sinyali frekans ekseninde, her bir kopyasının arasında B_c ile temsil edilen uyum bant genişliği kadar mesafe bırakılarak iletme sokulmaktadır.



Şekil 1.4. Frekans çeşitlemesi [60].

1.2.2. Zaman Çeşitlemesi

Bir diğer çeşitleme yöntemi olan zaman çeşitlemesi ile, bilgi sinyali zaman ekseninde düzenli aralıklarla tekrarlı bir şekilde iletilir. Gönderilen sinyaller arasındaki zaman farkı, kanalın uyum zamanından (T_c) büyük olmalıdır. Böylece sinyalin her bir kopyası birbirinden bağımsız bir şekilde sönmlemeye uğrar. Zaman aralığı sönmleme oranına bağlıdır ve sönmlemede meydana gelen düşüşe paralel olarak artış gösterir [58-59]. Şekil 1.5'de zaman çeşitlemesi gösterilmektedir. Burada $s(t)$ sinyali zaman ekseninde, her bir kopyasının arasında T_c ile temsil edilen uyum zamanı kadar boşluk bırakılarak iletilmektedir.



Şekil 1.5. Zaman Çeşitlemesi [60].

1.2.3. Uzay Çeşitlemesi

Bu çeşitleme tekniğinde, hem verici hem de alıcı tarafta çoklu antenler kullanılır. Böylece alıcıda iletilen sinyalin anten sayısı kadar kopyası elde edilir. Sinyalin her bir kopyasının birbirinden bağımsız bir şekilde sönmlemeye uğraması için antenler yeteri derecede birbirinden uzak aralıklarla yerleştirilmelidir. Bu yöntemde, frekans çeşitlemesi ve zaman çeşitlemesi yöntemlerinden farklı olarak iletim sonucunda ek bir işleme, ek bir bant genişliğine veya iletim zamanına gerek duyulmaz. Fakat fiziksel sınırlamalar bu yöntemin uygulama alanının daralmasına sebep olmaktadır. Uzay çeşitlemesi yöntemi, hem frekans seçici sönmleme hem de zaman seçici sönmleme problemleriyle mücadele etmek için kullanılabilir [60-61].


1.3. Dikgen Frekans Bölmeli Çoğullama (OFDM)

Dikgen Frekans Bölmeli Çoğullama, mevcut bant genişliğinin birçok alt kanala bölünüp verinin tek bir taşıyıcı yerine nispeten daha yavaş ve birbirlerine dik olan alt taşıyıcılar üzerinden paralel olarak taşındığı iletişim teknolojisidir. OFDM sisteminde, ilettime sokulacak veri, birbirine yakın olarak yerleştirilmiş alt taşıyıcılar arasında bölüştürölüp, paralel ilettime tabi tutulur. OFDM tekniğinde işaret birçok alt taşıyıcı üzerinden iletildiğı ve her bir alt taşıyıcının bant genişliğı çok dar olduğı için işaret hızı düşük olur. Dolayısıyla sembol periyodu artar. Bu da işaretin çok yollu yayılım gecikmesine karşı direncini artırır. Diğer taraftan, tek taşıyıcılı sistemlerde tek bir sönm ya da girişim bütün bir hattı zayıflatırken, OFDM gibi çok taşıyıcılı bir sistemde sönmleme olması durumunda, her bir taşıyıcı üzerinde toplam verinin sadece küçük bir kısmı bulunduğundan dolayı, alt taşıyıcıların ve dolayısıyla toplam verinin sadece küçük bir yüzdesi bu durumdan etkilenir. Bu özelliğıyle OFDM, frekans seçici sönmlemeye karşı oldukça dayanıklıdır [62-69].

1.3.1. Dikgenliğın Önemi

Normal Frekans Bölmeli Çoğullama (FDM) sisteminde, klasik filtreler ve demodölörler kullanılarak gönderilen sinyali alıcıda tekrardan elde edebilmek için taşıyıcılar arasında boşluklar bırakılır. Koruma bandı olarak adlandırılan bu boşluklar,

spektrum verimliliğini düşürmektedir. OFDM sisteminde ise, dikgen taşıyıcılar kullanılarak taşıyıcı spektrumlarının çakışmasına izin verilir. Taşıyıcılar birbirine dik olduğu için, frekans uzayında birbirleri ile çakışmalar bile alıcıda doğru olarak çözümlenebilirler. Böylelikle klasik FDM'de olduğu gibi koruma aralığı bırakmaya gerek kalmadığı için frekans spektrumu daha verimli kullanılmış olur. Şekil 1.6'da taşıyıcıların dikgen olarak yerleştirilmesi sonucu sağlanan spektrum kazancı gösterilmektedir.



Şekil 1.6. FDM ve OFDM'de bant genişliği kullanımı [62].

Matematiksel olarak, Ψ tane alt taşıyıcı kümesi olduğu ve Ψ_p 'nin de bu kümedeki p 'inci alt taşıyıcı olduğu göz önüne alındığında:

$$\int_a^b \Psi_p(t) \Psi_q^*(t) dt = \begin{cases} K & p = q \\ 0 & p \neq q \end{cases} \quad (1.3)$$

Şartı sağlanırsa, taşıyıcılar birbirine dikgendir. Bu ifadede; '*' kompleks eşlenik işlemini gösterirken, $[a,b]$ aralığı, sembol periyoduna karşılık gelmektedir [62-69].


1.3.2. OFDM'nin Matematiksel Tanımı

OFDM sisteminin matematiksel tanımı, sinyalin nasıl üretildiğinin, alıcıda yapılan işlemlerin ve kanalda meydana gelen bozucu etkilerin daha iyi anlaşılmasını

sağlamaktadır. Yukarıda da bahsedildiği üzere, OFDM sisteminde, frekans domeninde birbirine yakın olarak yerleştirilmiş çok sayıda dar bantlı taşıyıcılar iletime sokulmaktadır. Her bir taşıyıcı matematiksel olarak kompleks bir dalga şeklinde tanımlanabilir:

$$S_c(t) = A_c(t)e^{j[w_c t + \phi_c(t)]} \quad (1.4)$$

Denklem (1.4)'de $S_c(t)$ işaretinin reel kısmı, iletilen bilgi sinyaline karşılık gelmektedir. $A_c(t)$ taşıyıcı sinyalin genliğini, $\phi_c(t)$ ise faz açısını göstermektedir. Parametre değerleri, bir sembol periyodu boyunca aynı kalmaktadır.



Şekil 1.7. OFDM spektrum örnekleri: (a) tek taşıyıcılı spektrum (b) 5 taşıyıcılı spektrum [60].

OFDM, Şekil 1.7'de görüldüğü gibi çok sayıda taşıyıcıyı bünyesinde barındırmaktadır. OFDM spektrumunda birbirlerine dik olarak yerleştirilmiş bu kompleks taşıyıcılar aşağıdaki gibi tanımlanmaktadır:

$$S_s(t) = \frac{1}{N} \sum_{n=0}^{N-1} A_N(t) e^{j[w_n t + \phi_n(t)]} \quad (1.5)$$

Burada, $W_n = W_0 + n\Delta w$ 'dir.

Denklem (1.5) ile gösterilen sinyal sürekli bir sinyaldir. Eğer her bir sinyal bileşeninin dalga formları bir sembol periyodu boyunca incelenirse, taşıyıcı frekansına bağlı olarak $A_c(t)$ ve $\phi_c(t)$ değişkenleri sabit değerler alır:

$$A_n(t) \Rightarrow A_n$$

$$\phi_n(t) \Rightarrow \phi_n$$

Eğer sinyal $1/T$ örnekleme frekansı ile örneklenirse, aşağıdaki sinyal elde edilir:

$$S_s(kT) = \frac{1}{N} \sum_{n=0}^{N-1} A_n e^{j[w_0 + \Delta w]kT + \phi_n} \quad (1.6)$$

Bu noktada, sinyal N örnek boyunca analiz edildiğinde aralığı sınırlandırılmış olur. Bir sembol periyodu boyunca örnekleme yapılırsa aşağıdaki bağıntı elde edilir:

$$\tau = NT \quad (1.7)$$

$w_0 = 0$ olarak kabul edilip, Denklem (1.6) sadeleştirilirse, aşağıdaki sinyal elde edilir:

$$S_s(kT) = \frac{1}{N} \sum_{n=0}^{N-1} A_n e^{j\phi_n} e^{j(n\Delta w)kT} \quad (1.8)$$

Şimdi Denklem (1.8) , ters fourier dönüşümünün (IFFT) genel formuyla karşılaştırılabilir:

$$g(kT) = \frac{1}{N} \sum_{n=0}^{N-1} G\left(\frac{n}{NT}\right) e^{j2\pi nk/N} \quad (1.9)$$

Denklem (1.8)'deki $A_n e^{j\phi_n}$ ile örneklenmiş frekans domenindeki bir sinyal arasında çok fazla fark yoktur. $s(kT)$ ise sinyalin zaman domenindeki temsilidir. Aşağıdaki koşulun sağlanması durumunda, Denklem (1.8) ile Denklem (1.9) eşdeğer olmaktadır:

$$\Delta f = \frac{\Delta w}{2\pi} = \frac{1}{NT} = \frac{1}{\tau} \quad (1.10)$$

Yukarıdaki koşul, dikgenlik için gerekli olan koşulla aynıdır. Bu yüzden, dikgenliği korumanın bir sonucu olarak OFDM sinyali, Fourier dönüşümü prosedürleri kullanılarak tanımlanabilmektedir [62-69].

1.3.3. OFDM'de Hızlı Fourier Dönüşümü (FFT)

OFDM sisteminin verici kısmında sinyal frekans domeninde tanımlanmaktadır. Bu sinyal, örneklenmiş sayısal bir sinyaldir, öyle ki ayrık Fourier spektrumu sadece ayrık frekanslar halinde bulunur. Her bir OFDM taşıyıcısı, bu ayrık Fourier spektrumunun bir elemanına karşılık gelmektedir. Taşıyıcıların genlik ve fazları, iletilecek olan veriye bağlıdır. Veri iletimi taşıyıcılarda senkronize edilip, birlikte sembol sembol işlenebilmektedir.

N noktalı ayrık Fourier dönüşümü (DFT) aşağıdaki gibi tanımlanmaktadır:

$$X_p[k] = \sum_{n=0}^{N-1} x_p[n] e^{-j\left(\frac{2\pi}{N}\right)kn} \quad (1.11)$$

N noktalı ters ayrık Fourier dönüşümü (IDFT) ise aşağıdaki gibidir:

$$x_p[n] = \frac{1}{N} \sum_{k=0}^{N-1} X_p[k] e^{j\left(\frac{2\pi}{N}\right)kn} \quad (1.12)$$

Bu yöntemin doğal bir sonucu olarak birbirlerine dik olan taşıyıcılar elde edilebilmektedir.

Her bir elemanın kompleks sayı olduğu ($d_n = a_n + jb_n$) bir veri dizisi düşünülün: $((d_0, d_1, d_2, \dots, d_{N-1}))$ (QPSK için $a_n, b_n = \pm 1$)

$$D_m = \sum_{n=0}^{N-1} d_n e^{-j\left(\frac{2\pi nm}{N}\right)} = \sum_{n=0}^{N-1} d_n e^{-j2\pi f_n t_m} \quad k = 0, 1, 2, \dots, N-1 \quad (1.13)$$

Burada, $f_n = n/(N\Delta T)$, $t_k = k\Delta t$ 'dir ve Δt ise seri veri dizisinin (d_n) rastgele seçilmiş olan sembol süresidir. D vektörünün reel kısmı aşağıdaki gibidir:

$$Y_m = \text{Re}\{D_m\} = \sum_{n=0}^{N-1} [a_n \cos(2\pi f_n t_m) + b_n \sin(2\pi f_n t_m)] \quad (1.14)$$

$$k = 0, 1, 2, \dots, N-1$$


Eğer bu bileşenler, Δt zaman aralıklarında alçak geçiren filtreye uygulanırsa, frekans bölmeli çoğullama sinyaline oldukça yaklaşan bir sinyal elde edilir [62-69]:

$$y(t) = \sum_{n=0}^{N-1} [a_n \cos(2\pi f_n t_m) + b_n \sin(2\pi f_n t_m)] \quad 0 \leq t \leq N\Delta t \quad (1.15)$$

1.3.4. OFDM'de Koruma Aralığı Eklenmesi

Kablosuz haberleşme sistemlerinde karşılaşılan en büyük sorunlardan bir tanesi çok yollu gecikme yayılımıdır. OFDM, bu problemle etkin bir şekilde mücadele etmektedir. OFDM'de bilgi işareti, düşük hızlı ve büyük periyotlu birçok alt taşıyıcı üzerinden paralel olarak iletildiği için, işaretin gecikme yayılımına uğrama olasılığı azalmaktadır.

Semboller arası girişim (ISI), Şekil 1.8'de görüldüğü gibi her bir OFDM sembolüne koruma aralığı ekleyerek ortadan kaldırılabilir. Herhangi bir sembolde oluşan çok yollu bileşenler ile bir sonraki sembolün girişim meydana getirmemesi için, koruma aralığı beklenen gecikme yayılımından daha büyük seçilmelidir. Koruma aralığı ile birlikte OFDM sembolü periyodik olarak uzatılmış olur. Kullanılan bu metot ile birlikte, gecikme süresi koruma aralığından küçük olduğu müddetçe, OFDM sembolünün gecikmiş kopyaları FFT aralığında tam sayıda salınımlara sahip olur. Gecikme süreleri koruma aralığından küçük olan çok yollu sinyaller, semboller arası girişime sebep olmaz [62-69].




Şekil 1.8. Döngüsel önek ekleme işlemi.

1.4. OFDM-IDMA Sistem Modeli

OFDM ve IDMA sistemlerinin birleştirilmesiyle oluşturulan OFDM-IDMA, her iki sistemin de kendine özgü avantajlarını bünyesinde barındıran ve bu sayede ISI ve MAI gibi kablosuz haberleşmede iletişim kalitesinin düşmesine sebep olan çeşitli engellerle başa çıkabilen bir iletişim teknolojisidir. Özellikle IDMA sisteminin getirdiği bir avantaj olarak, yapısında bulunan ve çok kullanıcıli sistemlere uygulanabilen basit ve etkili bir algoritma olan turbo-tipi tekrarlamalı Çok Kullanıcıli Algılama (MUD) algoritması sayesinde yüksek sistem başarımı elde edilmektedir.

K eşzamanlı kullanıcıya sahip OFDM-IDMA sisteminin verici ve alıcı yapısı Şekil 1.9'da gösterilmiştir.



Şekil 1.9. K eşzamanlı kullanıcıya sahip OFDM-IDMA sistemi verici ve alıcı yapısı.

Şekil 1.9'da d_k , k kullanıcısına ait olan veri setine karşılık gelmektedir. Bu veri seti, ileri hata düzeltme (FEC) kodları ile kodlandıktan sonra c_k ile temsil edilen kırmık dizileri üretilir. Burada, FEC kodları olarak yayma (spreading) kodları veya tekrarlama (repetition) kodları kullanılabilir. Daha sonra üretilen c_k kırmık dizileri kullanıcıya özgü serpiştiriciler vasıtasıyla serpiştirme işlemine tabi tutulur. Modülasyon işleminden sonra, $x_k = [x_k(1), \dots, x_k(j), \dots, x_k(J)]^T$ sembol dizisi üretilir. Burada J çerçeve uzunluğudur. Daha sonra üretilen bu semboller, IFFT işlemi uygulanarak farklı alt taşıyıcılara bindirilir.

Dördün Faz kaydırmalı Anahtarlama (QPSK) modülasyonu yapıldığı göz önüne alınırsa:

$$x_k(j) = x_k^{Re}(j) + ix_k^{Im}(j) \quad (1.16)$$

şeklinde olur. OFDM modülasyonundan sonra iletilen sembol dizisi $v_k = W^H x_k$ şeklinde ifade edilebilir. Burada x_k , OFDM iletimi için N_c uzunluklu bloklara bölünür. N_c kullanılan alt taşıyıcı sayısına, W ayrık Fourier Dönüşüm (DFT) matrisine, üst indis " H " ise Hermit transpozuna karşılık gelmektedir.

DFT matrisi W 'nin (m,n) 'inci girişi aşağıdaki gibidir:

$$W[m, n] = \frac{1}{\sqrt{N_c}} e^{-i2\pi mn/N_c} \quad (1.17)$$

k tane kullanıcı için, $h_k = [h_k(0), h_k(1), \dots, h_k(L-1)]$ şeklinde sönüm katsayılarına sahip L yollu kanal modeli üzerinden iletim yapıldığı kabul edilirse çok yollu kanalın çıkışı aşağıdaki gibi olur:

$$y = \sum_k y_k + z = \sum_k h_k * v_k + z \quad (1.18)$$

Burada $*$ simgesi konvolüsyon işlemi, z ise toplanabilir beyaz Gauss gürültüsünü (AWGN) göstermektedir.

Alıcı tarafta, tekrarlı çok kullanıcılı algılama (MUD) işleminden önce OFDM demodülasyonu gerçekleştirilir. Döngüsel önek (CP) uzunluğunun maksimum kanal gecikme süresinden fazla olduğu varsayımıyla birlikte, OFDM demodülasyonundan sonra alınan sinyal aşağıdaki gibi ifade edilir:

$$r(j) = \sum_k H_k(j) x_k(j) + Z(j) \quad (1.19)$$

Burada $H_k(j) = \sum_{l=0}^{L-1} h_k(l) \cdot e^{-i2\pi jl/N_c}$, j alt taşıyıcısının sönüm katsayısını göstermektedir. $z(j)$ 'nin FFT'si olan $Z(j)$ ise, varyansı σ^2 'ye eşit olan kompleks beyaz Gauss gürültüsüdür. Daha sonra kırmık kırmık (CBC) algılama algoritması alınan sinyale uygulanır. OFDM-IDMA için uygulanan tekrarlı algılama işlemi aşağıdaki gibi gerçekleştirilir:

(i) **Başlangıç:** $E(x_k(j)) = 0$, $Cov(x_k(j)) = I$ olarak alınır. Burada I , 2×2 'lik birim matristir.

(ii) **Ana işlemler:** Tekrarlı işlemlerden oluşan bu kısım, iki adıma ayrılmaktadır:

Adım (a): Temel Sinyal Kestirici (ESE) Bölümü

Öncelikle k kullanıcısı için $x_k(j)$ 'yi algılama üzerine yoğunlaşılır ve (1.19)'daki ifade, aşağıdaki şekliyle tekrardan yazılır:

$$r(j) = H_k(j) x_k(j) + \zeta_k(j) \quad (1.20)$$

ve burada:

$$\zeta_k(j) = \sum_{m \neq k} H_m(j) X_m(j) + Z(j) \quad (1.21)$$

şeklinde ifade edilir. $x_k(j)$ 'yi algılamak için aşağıdaki ifade üretilir:

$$\tilde{r}_k(j) = H_k^*(j) r(j) = |H_k(j)|^2 x_k(j) + \tilde{\zeta}_k(j) \quad (1.22)$$

Burada:

$$\tilde{\zeta}_k(j) = H_k^*(j) \zeta_k(j) \quad (1.23)$$

ifadesine eşittir.

Merkezi limit teoremine göre $\tilde{\zeta}_k(j)$, Gauss değişkeni olarak düşünülebilir. Bu yaklaşım, Temel Sinyal Kestirici (ESE) tarafımdan $x_k(j)$ için Logaritmik Olasılık Oranı (LLR) üretiminde kullanılır:

$$e_{ESE}(x_k^{Re}(j)) = \frac{2|H_k(j)|^2 \left(\tilde{r}_k^{Re}(j) - E(\tilde{\zeta}_k^{Re}(j)) \right)}{Var(\tilde{\zeta}_k^{Re}(j))} \quad (1.24)$$

$e_{ESE}(x_k^{Im}(j))$ ifadesi de (1.24)'deki gibi elde edilebilir. $E(\tilde{\zeta}_k^{Re}(j))$ ve $Var(\tilde{\zeta}_k^{Re}(j))$ ifadeleri ile ilgili hesaplamalar aşağıdaki gibi gerçekleştirilir. (1.23)'den yola çıkılarak aşağıdaki ifade elde edilir:

$$\begin{cases} E(\tilde{\zeta}_k(j)) = H_k^*(j)E(\zeta_k(j)), \\ Var(\tilde{\zeta}_k(j)) = R_k^T(j)Cov(\zeta_k(j))R_k(j). \end{cases} \quad (1.25)$$

Yukarıdaki eşitlikte:

$$R_k(j) = \begin{bmatrix} H_k^{Re}(j) & -H_k^{Im}(j) \\ H_k^{Im}(j) & H_k^{Re}(j) \end{bmatrix} \quad (1.26)$$

şeklinde ifade edilir. (1.21)'deki eşitlik kullanılarak:

$$\begin{cases} E(\zeta_k(j)) = E(r(j)) - H_k(j)E(x_k(j)), \\ Cov(\zeta_k(j)) = Cov(r(j)) - R_k(j)Cov(x_k(j))R_k^T(j). \end{cases} \quad (1.27)$$

ifadesi elde edilir. Burada, alınan sinyalin ortalaması ve varyansı aşağıdaki gibi kestirilebilir:

$$\begin{cases} E(r(j)) = \sum_k H_k(j)E(x_k(j)), \\ Cov(r(j)) = \sum_k R_k(j)Cov(x_k(j))R_k^T(j) + \sigma^2 I. \end{cases} \quad (1.28)$$

Adım (b): Kod Çözücüler (DEC) Bölümü

Kod çözücüler (DEC), ESE çıkışlarını kullanarak sonsal olasılıklı (APP) kod çözme işlemini icra ederler. Modülasyon türü olarak QPSK kullanıldığı düşünülürse, hem reel $\{x_k^{Re}(j)\}$ hem de sanal $\{x_k^{Im}(j)\}$ kısımlar için DEC çıkışlarında dışsal LLR değerleri üretilir. Dışsal bilgiler kullanılarak her bir çip için ortalama ve varyans değerleri aşağıdaki gibi güncellenir:

$$\begin{cases} E(x_k(j)) = \tanh\left(\frac{e_{DEC}(x_k^{Re}(j))}{2}\right) + i \tanh\left(\frac{e_{DEC}(x_k^{Im}(j))}{2}\right) \\ Cov(x_k(j)) = \begin{bmatrix} 1 - \left(E(x_k^{Re}(j))\right)^2 & 0 \\ 0 & 1 - \left(E(x_k^{Im}(j))\right)^2 \end{bmatrix} \end{cases} \quad (1.29)$$

Burada, $x_k(j)$ 'nin gerçek ve sanal kısımları için dışsal LLR değerleri ilintisiz kabul edilmiştir ve böylece $Cov(x_k(j))$ 'nin köşegen dışında kalan girdileri sıfır değeri almıştır.

Tekrarlamalı işlemlerde, ESE ve DEC bölümlerinin $x_k(j)$ ile ilgili dışsal bilgileri değişir. OFDM-IDMA için CBC algılama aşağıdaki gibi sonuçlandırılır:

- 1) ESE çıkışlarında, DEC'ler için $\{e_{ESE}(x_k(j))\}$ değerleri üretilir.
- 2) DEC'ler, $\{(x_k(j))\}$ 'nin ortalama ve varyans değerlerinin güncellenmesinde kullanılan $\{e_{DEC}(x_k(j))\}$ değerlerini üretir [1-15].

1.5. OFDM-IDMA Kanal Kestirimi

Kablosuz haberleşmenin doğası gereği, iletilen sinyalin doğal veya insan yapımı çeşitli engellere maruz kalmasıyla sönümleme meydana gelir ve bunun sonucunda sinyal bozulmaya uğrayıp, alıcıda hatasız olarak tekrardan elde edilmesi zorlaşır. OFDM-IDMA iletişim teknolojisinin, kablosuz haberleşmede karşılaşılan birçok problemle başa çıkabilmesine karşın, diğer haberleşme sistemlerinde olduğu gibi bu sistemde de kanal durum bilgisine (CSI) ihtiyaç duyulmaktadır. Dolayısıyla, kanal durum bilgisini elde edebilmek için kanal kestirim metotlarına başvurulması gerekmektedir. Klasik kanal kestirim yöntemleri, kör ve pilot tabanlı olmak üzere ikiye ayrılmaktadır [16-42]. Bunun


yanında literatürde yapay zeka teknikleri kullanılarak geliştirilmiş çeşitli kanal kestirim metotları da yer almaktadır [43-52].

Kör kanal kestirim metodunda kanal katsayıları, pilot tonları eklemekten, sadece kanalın istatistiksel verileri kullanılarak elde edilmektedir. Pilot tabanlı kanal kestirim metoduna göre hem daha karmaşık, hem de daha düşük performansa sahip olması nedeniyle genel olarak çok fazla tercih edilen bir yöntem değildir [16-19]. Pilot tabanlı kanal kestirim yönteminde ise, pilot tonları olarak adlandırılan ve alıcı tarafında da bilinen veriler vericide ham veriye eklenir. Daha sonra kanal katsayılarını elde etmek için alıcıda bu verilerden yararlanılır [20-42].

1.5.1. Pilot Ton Eklemeli Kanal Kestirim Yöntemleri

Pilot tonlarının yerleşimine göre blok tipi ve tarak tipi yerleşim olmak üzere iki çeşit pilot ton eklemeli kanal kestirim yöntemi mevcuttur [23]. Her iki yöntemle de yapılan kanal kestirim işlemlerinde LS ve MMSE gibi klasik kanal kestirim algoritmaları kullanılabilir [22-33].

1.5.1.1. Blok Tipi Pilot Ton Yerleşimi




Şekil 1.10. Blok tipi pilot ton yerleşimi.

Blok tipi pilot yerleşimi ile yapılan kanal kestirim yönteminde, Şekil 1.10' da görüldüğü gibi pilot tonlar belirli periyotlarda OFDM sembollerinin bütün alt taşıyıcılarına yerleştirilir. Böylelikle alıcı, gönderilen pilot tonları kullanarak elde ettiği kanal durum bilgisini (CSI), bir sonraki pilot tonlar gelene kadar kullanır. Bu yöntem ile, özellikle yavaş sönmümlü kanallarda kanal katsayıları minimum hatayla kestirilebilir [23].

1.5.1.2. Tarak Tipi Pilot Ton Yerleşimi

Tarak tipi pilot yerleşimi ile yapılan kanal kestirim yönteminde, Şekil 1.11'de görüldüğü gibi pilot tonları alt taşıyıcılara belirli aralıklarla düzenli olarak yerleştirilir. Pilot tonları, her bir alt taşıyıcıya yerleştirilmeyip aralıklı olarak yerleştirildiğinden dolayı, kanalın bütün frekans bandındaki değişimini kestirebilmek için ara değerleme (interpolasyon) yöntemi uygulanır. Bu pilot yerleşim yöntemi, birbirine komşu OFDM sembolleri arasında değişkenlik gösteren hızlı sönmümlü kanallarda başarılı bir performans gösterir [23].



Şekil 1.11. Tarak tipi pilot ton yerleşimi.

1.5.2. Kanal Kestirim Algoritmaları

1.5.2.1. LS Algoritması

LS algoritması yapı olarak basit, uygulaması kolay bir algoritmadır, fakat zamana göre değişen sönümlü kanallardaki performansı oldukça düşüktür. LS kestirimcisi, " g " dairesel dürtü cevabı olmak üzere,

$$(y - XF_g)^H (y - XF_g) \quad (1.30)$$

ifadesini minimize ederek aşağıdaki ifadeyi üretir:

$$\hat{h}_{LS} = FQ_{LS}F^HX^Hy \quad (1.31)$$

Burada;

$$Q_{LS} = (F^HX^HXF)^{-1} \quad (1.32)$$

$\hat{h}_{LS}$ kanal frekans cevabını, $(.)^H$ sembolü Hermit matrisini, F sembolü ayrık Fourier dönüşüm (DFT) matrisini, X sembolü iletilen veriyi, y sembolü ise alınan veriyi ifade etmektedir. $\hat{h}_{LS}$ ifadesi son haliyle aşağıdaki gibi yazılabilir [22-33]:

$$\hat{h}_{LS} = X^{-1}y \quad (1.33)$$

1.5.2.2. MMSE Algoritması

MMSE algoritması, LS algoritmasına göre çok daha iyi bir performans göstermesine rağmen oldukça karmaşık bir yapıya sahiptir. Kanal durum bilgisini (CSI) elde edebilmek için kanalın istatistiksel verilerine ihtiyaç duyması, algoritmanın karmaşıklığını artırmaktadır. MMSE algoritmasıyla kanal kestirimi şu şekilde gerçekleşmektedir;

Eğer g kanal vektörü Gauss ise ve n kanal gürültüsü ile ilintisi yoksa, g 'nin MMSE kestirimi aşağıdaki gibi olur:

$$\hat{g}_{MMSE} = R_{gy}R_{yy}^{-1}y \quad (1.34)$$

Burada,

$$R_{gy} = E\{gy^H\} = R_{gg}F^HX^H \quad (1.35)$$

$$R_{yy} = E\{yy^H\} = XFR_{gg}F^HX^H + \sigma_n^2 I_N \quad (1.36)$$

şeklindedir. R_{gy} , g ve y arasındaki çapraz kovaryans matrisini, R_{yy} ise y 'nin otokovaryans matrisini ifade etmektedir. Ayrıca, R_{gg} ifadesi g 'nin otokovaryans matrisine karşılık gelirken σ_n^2 ise $E\{|n_k|^2\}$ gürültü varyansını temsil etmektedir. Bu iki ifadenin bilindiği kabul edilir. F matrisinin sütunları hem ortogonal hem de normalize edilmiş olduğundan dolayı, h_{MMSE} ile ifade edilen kanal frekans cevapları aşağıdaki gibi kestirilmektedir:

$$\hat{h}_{MMSE} = F\hat{g}_{MMSE} = FQ_{MMSE}F^HX^Hy \quad (1.37)$$

Yukarıdaki ifadede Q_{MMSE} aşağıdaki gibi yazılabilir [22-33]:

$$Q_{MMSE} = R_{gg}[(F^HX^HXF)^{-1}\sigma_n^2 + R_{gg}]^{-1}(F^HX^HXF)^{-1} \quad (1.38)$$

2. BÖLÜM

YAPAY ZEKÂ YÖNTEMLERİ


2.1. Yapay Sinir Ağları

İnsan beyni, oldukça kompleks bir yapıya sahip olup doğrusal olmayan ve bilgiyi paralel olarak işleyen biyolojik bir bilgi işletim sistemidir. Yapay sinir ağları fikri de, insan beyninin tanıma, öğrenme, algılama ve bilgiyi işleme yeteneklerinden ilham alınarak ortaya çıkmıştır [70-77].

2.1.1. Biyolojik Sinir Hücresi

İnsan beyni, nöron olarak adlandırılan ve birbirleriyle bağlantılı yaklaşık 10^{11} tane çok sayıda biyolojik sinir hücresinden meydana gelmektedir. Nöron başına yaklaşık olarak 10^4 tane bağlantı düşmektedir. Bu hücreler Şekil 2.1'de görüldüğü gibi dendritler, hücre gövdesi ve akson olarak adlandırılan üç temel bileşenden meydana gelmektedir. Dendritler, elektriksel sinyalleri hücre gövdesine taşıyan sinir lifleridir. Hücre gövdesi, dendritler yoluyla gelen elektriksel sinyalleri toplayıp eşikleme görevini yerine getiren hücre bileşenidir. Akson ise hücre gövdesinden gelen sinyali başka bir nörona aktaran tek bir sinir lifidir. Herhangi bir hücrenin aksonuyla, başka bir hücrenin dendriti arasındaki bağlantı noktası sinaps olarak adlandırılır. Nöronların yerleşim düzeni ve kompleks bir kimyasal işlem ile belirlenen bireysel sinaps güçleri, biyolojik sinir ağının fonksiyonunu belirlemektedir. Bazı sinirsel yapılar doğum sırasında oluşurken geri kalan kısımlar, hayat boyu gerçekleştirilen öğrenme faaliyetleri ve bunun sonucunda nöronlar arası yeni bağlantıların yapılmasıyla doğum sonrası süreçte gelişmektedir.


Yapay sinir ağı, beynin sahip olduğu kompleks yapıya yaklaşamamaktadır. Ancak, biyolojik ve yapay sinir ağı arasında iki temel benzerlik bulunmaktadır. Birincisi, her iki sinir ağı da basit ve hesaplama karmaşıklığı gerektirmeyen birbirine bağlanmış nöronlardan meydana gelmektedir. İkincisi ise, nöronlar arası bağlantı şekilleri sinir ağının fonksiyonunu belirlemektedir [70-77].



Şekil 2.1. Biyolojik sinir hücresi yapısı.

2.1.2. Yapay Sinir Hücresi

Yapay sinir hücreleri, diğer bir deyişle nöronlar birden fazla girişe sahiptirler. Şekil 2.2'de R tane girişe sahip bir nöron görülmektedir. $p_1, p_2, p_3, \dots, p_R$ girişleri, bu girişlere karşılık gelen $\mathbf{W}$ ağırlık matrisi elemanları $w_{1,1}, w_{1,2}, w_{1,3}, \dots, w_{1,R}$ ile ağırlıklandırılır.



Şekil 2.2. Yapay sinir hücresi [70].

Yukarıdaki şekilde görülmekte olan b girişi, bias ya da aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Bias değeri, net giriş n 'yi oluşturmak için ağırlıklandırılmış girişlerle toplanır:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + w_{1,3}p_3 + \dots + w_{1,R}p_R + b \quad (2.1)$$

Yukarıdaki ifade matris formunda da yazılabilmektedir:

$$n = \mathbf{W}_p + b \quad (2.2)$$

Burada $\mathbf{W}$ matrisi, tek bir nöron için sadece bir satırdan oluşmaktadır. Dolayısıyla nöron çıkışı aşağıdaki şekilde yazılabilir:

$$a = f(\mathbf{W}_p + b) \quad (2.3)$$

Yukarıdaki ifadede f transfer veya aktivasyon fonksiyonu olarak adlandırılmaktadır. Burada nöron çıkışı, seçilen aktivasyon fonksiyonuna göre değişmektedir [70-77].


2.1.3. Aktivasyon Fonksiyonları

Yapay sinir hücresine gelen giriş verileri ağırlıklandırılıp toplandıktan sonra aktivasyon fonksiyonu vasıtasıyla algoritmik bir işleme tabi tutularak çıkış verisi üretilir. Aktivasyon fonksiyonları genel olarak doğrusal değildir. Kullanılmakta olan doğrusal fonksiyonlar sınırlı sayıdadır. Çünkü bu tür fonksiyonların kullanıldığı sistemlerde çıkışta elde edilen veriler ile girişe uygulanan veriler birbirleriyle orantılı olmaktadır. Bu yüzden doğrusal fonksiyonlar çok fazla kullanışlı değildir. Çözülmesi gereken problemin türüne göre çeşitli türlerde aktivasyon fonksiyonları kullanılabilmektedir. Aşağıda en çok kullanılan aktivasyon fonksiyonlarından üç tanesi tanıtılmıştır [70-77]:

2.1.3.1. Eşik Aktivasyon Fonksiyonu

Şekil 2.3'de görülmekte olan eşik aktivasyon fonksiyonu, eğer net giriş değeri n , 0'dan küçükse nöron çıkışını 0'a sabitler. Diğer taraftan eğer n değeri, 0'dan büyük ya da 0'a

eşitse çıkış 1 değerini alır. Bu aktivasyon fonksiyonu, girişleri iki ayrı kategoride sınıflandıran sinir hücrelerini oluşturmak için kullanılabilir [70-77].




Şekil 2.3. Eşik aktivasyon fonksiyonu.

2.1.3.2. Doğrusal Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonu Şekil 2.4'de görülmektedir. Bu aktivasyon fonksiyonuna sahip nöronlar Uyarlanabilir Doğrusal Nöron (Adaptive Linear Neuron: ADALINE) ağlarında yaygın olarak kullanılmaktadır. Doğrusal aktivasyon fonksiyonunun girişi ile çıkışı birbirine eşit olmaktadır [70-77]:

$$a = n \quad (2.4)$$




Şekil 2.4. Doğrusal aktivasyon fonksiyonu.

2.1.3.3. Sigmoid Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu Şekil 2.5'de görülmektedir. Bu fonksiyon, artı sonsuz ile eksi sonsuz arasında herhangi bir değere karşılık gelebilen girişi, 0 ile 1 değeri arasına sıkıştırmaktadır. Bu işlemi, aşağıdaki ifadeye göre gerçekleştirmektedir:

$$a = \frac{1}{1 + e^{-n}} \quad (2.5)$$

Sigmoid aktivasyon fonksiyonu, geri yayılım algoritması kullanılarak eğitilen çok katmanlı algılayıcılarda yaygın olarak kullanılmaktadır [70-77].




Şekil 2.5. Sigmoid aktivasyon fonksiyonu.

2.1.4. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağları paralel bir şekilde çalışan basit bileşenlerden meydana gelmektedir. Bu bileşenler arasındaki bağlantılar sinir ağının fonksiyonunu belirlediğinden dolayı, nöronlar arasındaki bağlantılarda yapılacak ayarlamalarla birlikte yapay sinir ağına özel bir fonksiyon yüklenebilmektedir. Nöronlar arasındaki bağlantılarda, diğer bir değişle ağırlıklarda yapılan bu ayarlamalar eğitme işlemi olarak bilinmektedir.

Eğitim işlemine başlamadan önce, başlangıç ağırlıkları gelişigüzel olarak seçilir. Daha sonra, önceden belirlenmiş giriş verileri sinir ağına uygulanarak ilk çıkışlar üretilir. Elde edilen bu çıkış değerleri, arzulanan çıkış verileri ile karşılaştırılarak hata değeri hesaplanır. Çeşitli öğrenme algoritmaları kullanılarak, hesaplanan bu hataya göre sinir ağının ağırlıkları her bir döngüde yenilenir. Her bir döngü için yeniden hesaplanan hata, daha önceden belirlenen minimum hata değerinin altına düşünceye kadar döngü devam

ettirilir (Şekil 2.6). Öğretme işlemi tamamlandıktan sonra, yapay sinir ağına daha önce hiç verilmeyen girişler uygulanarak ağ test edilir. Test işlemi sonucunda da ağ doğru çıkışlar üretiyorsa eğitim işlemi başarıya ulaşmış demektir [70-77].



Şekil 2.6. Eğitim işlemi

2.1.5. Öğrenme Algoritmaları

Öğrenme algoritmalarının amacı, nöronlar arasındaki bağlantıları (ağırlıkları) değiştirerek yapay sinir ağını herhangi bir probleme uygun çözümler üretecek hale dönüştürmektir. Arzulanan sonuçları elde edebilmek için ağırlıkların değiştirilmesi işlemi öğrenme ya da adaptasyon olarak adlandırılmaktadır. Eğitici ve eğitici olmayan olmak üzere iki çeşit öğrenme türü mevcuttur.


Eğitici öğrenmede, bir öğretmene ihtiyaç duyulmaktadır. Burada öğretmen olarak kastedilen eğitim için kullanılan bir veri seti ya da yapay sinir ağı sonuçlarının performansını derecelendiren bir gözlemci olabilir. Öyle ya da böyle, eğitici öğrenmede mutlaka bir öğretmene yani desteğe ihtiyaç duyulur.

Eğitici olmayan öğrenme, gelecek için umut vadeden bir yöntemdir. Bu yöntemde, herhangi bir desteğe ihtiyaç duymaksızın kendi kendine öğrenme gerçekleştirilmesi amaçlanmaktadır. Bu yöntemle birlikte yapay sinir ağlarında nöronlar arası bağlantıları değiştirmek için herhangi bir dış etki kullanılmamaktadır. Bu öğrenme türünü kullanan

yapay sinir ağı, giriş sinyallerindeki düzen ve eğilimlere bakıp ağın işlevine göre adaptasyon geliştirirler. Doğrunun ya da yanlışın ne olduğu gösterilmeden ağı kendi kendini organize edebilmesi için hala bazı bilgilere ihtiyacı vardır. Bu bilgiler, ağ topolojisine ve öğrenme kurallarına inşa edilmektedir [70-77].

2.1.5.1. Geri Yayılım Algoritması

Öğrenme algoritması olarak geri yayılım algoritması kullanılan yapay sinir ağlarında, daha önce bahsedildiği üzere eğitici öğrenmenin bir özelliği olarak, eğitim setleri yardımıyla eğitme işlemi gerçekleştirilir. Öğrenme işlemi sırasında, yapay sinir ağının çıkışı ile arzu edilen çıkış her bir döngü için karşılaştırılarak hata değeri hesaplanır ve hata minimize edilmeye kadar döngü devam ettirilir. Hesaplanan hata değerinin minimize edilmesi ise, nöronlar arası bağlantıların (ağırlıkların) geri yayılım algoritması yardımıyla güncellenmesi ile sağlanmaktadır [70-77].



Şekil 2.7. Üç katmanlı yapay sinir ağı [70].

Şekil 2.7'de görüldüğü gibi üç katmanlı yapay sinir ağı modeli göz önünde bulundurulursa, $k + 1$ katmanındaki i birimine olan net giriş aşağıdaki gibi olmaktadır:

$$n^{k+1}(i) = \sum_{j=1}^{S_k} w^{k+1}(i,j)a^k(j) + b^{k+1}(i) \quad (2.6)$$

i biriminin çıkışı ise :

$$a^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \quad (2.7)$$

Şeklinde olur. M katmanlı yapay sinir ağı için sistem denklemlerinin matris formunda yazılışı aşağıdaki gibi olmaktadır:

$$\underline{a}^0 = \underline{p} \quad (2.8)$$

$$\underline{a}^{k+1} = \underline{f}^{k+1}(W^{k+1}\underline{a}^k + \underline{b}^{k+1}) \quad k = 0, 1, 2, \dots, M-1. \quad (2.9)$$

Yapay sinir ağının görevi, $\{(\underline{p}_1, \underline{t}_1), (\underline{p}_2, \underline{t}_2), (\underline{p}_3, \underline{t}_3), \dots, (\underline{p}_Q, \underline{t}_Q)\}$ giriş çıkış çiftleri arasındaki ilişkiyi öğrenmektir.

Ağın performans indeksi ise şu şekildedir:

$$V = \frac{1}{2} \sum_{q=1}^Q (\underline{t}_q - \underline{a}_q^M)^T (\underline{t}_q - \underline{a}_q^M) = \frac{1}{2} \sum_{q=1}^Q \underline{e}_q^T \underline{e}_q \quad (2.10)$$

Burada $\underline{a}_q^M$, q . giriş $\underline{p}_q$ olduğu durumdaki yapay sinir ağı çıkışıdır. $\underline{e}_q = \underline{t}_q - \underline{a}_q^M$ ifadesi ise q . giriş için hesaplanan hata değeridir. Standart geri yayılım algoritması için yaklaşık dik iniş kuralı kullanılmaktadır. Buna göre performans indeksi yaklaşımı aşağıdaki gibi olur:

$$\hat{V} = \frac{1}{2} \underline{e}_q^T \underline{e}_q \quad (2.11)$$

Burada, toplam karelerin toplam değeri, tek giriş tek çıkış çifti için karesel hatalarla yer değiştirilir. Böylece yaklaşık dik iniş (gradient:eğim) algoritması aşağıdaki gibi olur:

$$\Delta w^k(i, j) = -\alpha \frac{\partial \hat{V}}{\partial w^k(i, j)} \quad (2.12)$$

$$\Delta b^k(i) = -\alpha \frac{\partial \hat{V}}{\partial b^k(i)} \quad (2.13)$$

Burada α , öğrenme oranına karşılık gelmektedir. Aşağıdaki ifade ise, performans indeksinin k . katmanda i . birimin net girişindeki değişimlere olan hassaslığı olarak tanımlanmaktadır:

$$\delta^k(i) \equiv \frac{\partial \hat{V}}{\partial n^k(i)} \quad (2.14)$$

(2.6), (2.11) ve (2.14) kullanılarak aşağıdaki ifadeler elde edilir:

$$\frac{\partial \hat{V}}{\partial w^k(i,j)} = \frac{\partial \hat{V}}{\partial n^k(i)} \cdot \frac{\partial n^k(i)}{\partial w^k(i,j)} = \delta^k(i) a^{k-1}(j) \quad (2.15)$$

$$\frac{\partial \hat{V}}{\partial b^k(i)} = \frac{\partial \hat{V}}{\partial n^k(i)} \cdot \frac{\partial n^k(i)}{\partial b^k(i)} = \delta^k(i) \quad (2.16)$$

Hassaslık ifadesi, aşağıdaki yinelemeli ilişkiyi de karşılamaktadır:

$$\underline{\delta}^k = \dot{F}^k(\underline{n}^k) W^{k+1} \underline{\delta}^{k+1} \quad (2.17)$$

Burada $\dot{F}^k(\underline{n}^k)$ ifadesi aşağıdaki şekilde yazılabilir:

$$\dot{F}^k(\underline{n}^k) = \begin{bmatrix} \dot{f}^k(n^k(1)) & 0 & \cdots & 0 \\ 0 & \dot{f}^k(n^k(2)) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \dot{f}^k(n^k(S_k)) \end{bmatrix} \quad (2.18)$$

$\dot{f}^k(n)$ ise aşağıdaki şekilde ifade edilir:

$$\dot{f}^k(n) = \frac{df^k(n)}{dn} \quad (2.19)$$

Bu yinelemeli ilişki, son katmanda başlatılır:

$$\underline{\delta}^M = -\dot{F}^M(\underline{n}^M)(\underline{t}_q - \underline{a}_q) \quad (2.20)$$

Bütün öğrenme algoritması şu şekilde ilerlemektedir: İlk olarak (2.8) ve (2.9) kullanılarak giriş verileri ileri yönde yayılır. Daha sonra (2.20) ve (2.17) kullanılarak

geri yayılır ve son olarak (2.12), (2.13), (2.15) ve (2.16) kullanılarak ağırlık ve ofset değerleri güncellenir [70-77].

2.1.5.2. Levenberg-Marquardt Algoritması

Kenneth Levenberg ve Donald Marquardt tarafından geliştirilen Levenberg-Marquardt (LM) algoritması lineer olmayan fonksiyonları minimize etme problemine sayısal bir çözüm getirmektedir. Geri yayılım algoritmasına oranla çok daha hızlı ve kararlı bir yakınsama gösterir. LM algoritması yapay sinir ağları alanında, küçük ve orta ölçekli problemlerin çözümü için geliştirilen ağ yapılarının eğitilmesinde yaygın olarak kullanılmakta ve başarılı sonuçlar vermektedir.

Geri yayılım algoritması bir dik iniş algoritmasıyken, LM algoritması Newton metoduna olan bir yaklaşımdır. $\underline{x}$ parametre vektörüne göre minimize etmek istediğimiz bir $V(\underline{x})$ fonksiyonuna sahip olduğumuzu düşünelim. Buna göre Newton metodu aşağıdaki gibi olacaktır:

$$\Delta \underline{x} = -[\nabla^2 V(\underline{x})]^{-1} \nabla V(\underline{x}) \quad (2.21)$$

Burada $\nabla^2 V(\underline{x})$ Hessian matrisini, $\nabla V(\underline{x})$ ise eğimi (gradient) ifade etmektedir. Eğer $V(\underline{x})$ kareler toplamı fonksiyonu olarak kabul edilirse:

$$V(\underline{x}) = \sum_{i=1}^N e_i^2(\underline{x}) \quad (2.22)$$

şeklinde ifade edilir. Böylece Hessian matrisi ile eğim ifadesi aşağıdaki şekilde gösterilebilir:

$$\nabla V(\underline{x}) = J^T(\underline{x}) \underline{e}(\underline{x}) \quad (2.23)$$

$$\nabla^2 V(\underline{x}) = J^T(\underline{x}) J(\underline{x}) + S(\underline{x}) \quad (2.24)$$

Burada $J(\underline{x})$ Jacobian matrisi olup aşağıdaki gibi ifade edilmektedir:

$$J(\underline{x}) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad (2.25)$$

ve

$$S(\underline{x}) = \sum_{i=1}^N e_i(\underline{x}) \nabla^2 e_i(\underline{x}) \quad (2.26)$$

ifadesine eşittir. Gauss-Newton metodu için $S(\underline{x}) \approx 0$ olarak kabul edilir ve (2.21) aşağıdaki gibi güncellenir:

$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x})]^{-1} J^T(\underline{x}) \underline{e}(\underline{x}) \quad (2.27)$$

Gauss-Newton metoduna Levenberg-Marquardt modifikasyonu yapılırsa, aşağıdaki ifade elde edilir:

$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x}) + \mu I]^{-1} J^T(\underline{x}) \underline{e}(\underline{x}) \quad (2.28)$$

Bir adım $V(\underline{x})$ artımı sonucunda μ parametresi β faktörü ile çarpılır. Bir adım $V(\underline{x})$ azaltımı sonucunda ise μ parametresi β faktörüne bölünür. Algoritma, μ parametresi büyük değer aldığı anda dik iniş ($1/\mu$ adım büyüklüğüne sahip), küçük değer aldığı anda ise Gauss-Newton haline gelmektedir.

Levenberg-Marquardt Algoritmasının en önemli basamağı, Jacobian matrisinin hesaplandığı aşamadır. Yapay sinir ağı eşleştirme problemi için Jacobian matrisi içerisindeki terimler, geri yayılım algoritmasına basit modifikasyonlar yapılarak hesaplanabilir. Eşleştirme problemi için performans indeksi (2.10)'da verilmiştir. (2.10)'daki ifadenin yapı olarak (2.22)'deki ifadeyle eşdeğer olduğu kolayca görülebilir. Burada, $\underline{x} = [w^1(1,1)w^1(1,2) \dots w^1(S1,R)b^1(1) \dots b^1(S1)w^2(1,1) \dots b^M(SM)]^T$ ve $N = Q \times SM$ olmaktadır. Standart geri yayılım algoritması ile terimler aşağıdaki gibi hesaplanır:

$$\frac{\partial \hat{V}}{\partial w^k(i,j)} = \frac{\partial \sum_{m=1}^{SM} e_q^2(m)}{\partial w^k(i,j)} \quad (2.29)$$

LM algoritması için ihtiyaç duyulan Jacobian matrisi elementleri için aşağıdaki terimlerin hesaplanması gerekmektedir:

$$\frac{\partial e_q(m)}{\partial w^k(i,j)} \quad (2.30)$$

Bu terimler, son katmandaki bir modifikasyonla standart geri yayılım algoritması kullanılarak hesaplanabilir:

$$\Delta^m = -\dot{F}^M(\underline{n}^M) \quad (2.31)$$


(2.31)'deki her bir matris sütunu Jacobian matrisin bir satırını oluşturmak için ağ boyunca geri yayılması gereken hassaslık vektörüdür [70-77].

2.1.6. Yapay Sinir Ağı Yapıları

Bu tezde, kanal kestirimi için çok katmanlı algılayıcılar (MLP) ve radyal tabanlı yapay sinir ağları (RBFNN) kullanılmış olup, aşağıda bu ağların yapıları ve çalışma prensiplerinden bahsedilmiştir:

2.1.6.1. Çok Katmanlı Algılayıcılar

Çok katmanlı algılayıcılar (MLP) en çok kullanılan yapay sinir ağı çeşitlerinden bir tanesidir. Şekil 2.8'de görülmekte olan bu sinir ağı çeşidi, tipik olarak bir giriş katmanı, bir veya daha fazla sayıda gizli katman ve bir de çıkış katmanından meydana gelmektedir. Her bir katman ise nöron olarak adlandırılan işlem elemanlarından oluşmaktadır [70-77].



Şekil 2.8. Çok katmanlı algılayıcı (MLP) yapısı.


MLP sistemlerinde, herhangi bir işlem elemanı, kendisinden sonra gelen katmandaki bütün işlem elemanları ile bağlantı oluşturmaktadır. Ağda bulunan her bir işlem elemanı ise lineer olmayan aktivasyon fonksiyonu içermektedir. MLP sistemlerinin bir veya birden çok gizli katmana sahip olması ve bu katmanlarda bulunan işlem elemanlarının lineer olmayan aktivasyon fonksiyonu içermesi, bu ağ yapılarının giriş verilerinden daha anlamlı çıkarımlarda bulunmasına ve çok daha kompleks görevleri yerine getirmelerine olanak sağlamaktadır [76].

MLP sinir ağlarında sinyal akışı, Şekil 2.8'de de görüldüğü gibi katmanlar arasında soldan sağa doğru ağ boyunca ileri yönlü olarak gerçekleşmektedir. Ağın girişine uygulanan sinyal, aynı zamanda fonksiyon sinyali olarak da adlandırılır. Çünkü ağ boyunca üzerinden sinyal geçen her bir işlem elemanında ağırlıkların bağlantı şekillerinde yapılan düzenlemeyle birlikte sinyal hesabı yapılmakta ve girişten uygulanan sinyal çıkışa ulaştığında belli bir fonksiyonu yerine getirebilir hale gelmektedir [76].

2.1.6.2. Radyal Tabanlı Sinir Ağları

Radyal tabanlı sinir ağları (RBFNN), her biri tamamen birbirinden farklı rollere sahip üç katmandan meydana gelmektedir. Giriş katmanı, sinir ağını dış ortama bağlayan kaynak düğümlerinden oluşmaktadır. Radyal tabanlı sinir ağlarının sahip olduğu tek gizli katman olan ikinci katman, giriş boşluğundan gizli boşluğa lineer olmayan bir dönüşüm uygulamaktadır. Lineer bir yapıya sahip olan çıkış katmanından ise, giriş katmanına uygulanan sinyale karşılık ağı sağlamış olduğu yanıt elde edilmektedir [78-83].

Radyal tabanlı sinir ağının kullanılabilmesi için öncelikle gizli katmanda kullanılacak aktivasyon fonksiyonu, işlem elemanı sayısı, ve eğitim algoritması türü gibi ağın eğitimini ve performansını doğrudan etkileyen değişkenlerin belirlenmesi gerekmektedir. Eğitim seti olarak adlandırılan giriş ve çıkış veri çiftleri kullanılarak gerçekleştirilen eğitim işlemiyle birlikte ağ parametreleri optimize edilir. Eğitim işlemi sırasında ağın girişine uygulanan veriye karşılık üretmiş olduğu çıkışın doğruluğu ortalama karesel hata fonksiyonu vasıtasıyla değerlendirilir. Eğitim işlemi tamamlandıktan sonra radyal tabanlı sinir ağı artık uygulanabilir hale gelmiş demektir [76].



Şekil 2.9. Radyal tabanlı sinir ağı yapısı.

Şekil 2.9'da radyal tabanlı sinir ağının yapısı görülmektedir. Buna göre, RBFNN çıkışı aşağıdaki gibi olmaktadır:

$$y = \sum_{j=1}^n w_j \phi_j(x) \quad (2.32)$$

Burada $\phi_j(\cdot)$, j 'inci gizli düğümde kullanılan radyal tabanlı fonksiyona karşılık gelmektedir. w_j , gizli katmandan çıkış katmanına yapılmış olan bağlantıları (ağırlıkları), y ağın çıkışını simgelemektedir. $x = [x_1 \dots x_K]^T$ K boyutlu giriş vektörünü temsil ederken, n sembolü gizli düğüm sayısına karşılık gelmektedir. Gaussian aktivasyon fonksiyonu, gizli katmanda sıklıkla kullanılmakta olan radyal tabanlı bir fonksiyondur. Bu fonksiyon aşağıdaki şekilde ifade edilmektedir:

$$\phi_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (2.33)$$

Burada, σ_j ve μ_j , j 'nci düğümün yayılma ve merkez genişliğini temsil etmektedir.

Radyal tabanlı sinir ağlarının eğitimi sırasında, hedef ve gerçek çıkış değerleri arasındaki hatayı minimize etmek için yayılma genişliği (σ) her bir düğümün sahip olduğu ağırlık (w) ve düğümler merkezi (μ) gibi parametreler güncellenir:

$$E = y_{target} - y \quad (2.34)$$

Bu parametrelerin güncellenmesiyle ilgili bilgiler aşağıda verilmiştir [81-83]:

2.1.6.2.1. Ağırlıkların (W) Güncellenmesi

Ağırlığa (w) göre hatadaki değişim aşağıdaki gibi ifade edilmektedir:

$$\frac{dE^2}{dW} = \phi \Delta W = \lambda_w E \phi(x) \quad (2.35)$$

Burada λ_W , sinirsel ağırlıkların öğrenme oranıdır. Güncelleme işleminden sonraki ağırlık değeri aşağıdaki gibi olmaktadır:

$$w_t = \lambda_W E \phi(x) + W_{t-1} \quad (2.36)$$

Burada t ve $(t - 1)$ sırasıyla şimdiki ve bir önceki zaman adımlarını belirtmektedir [81-83].

2.1.6.2.2. Döğümler Merkezinin (μ) Güncellenmesi

Döğümler merkezine göre hatadaki değışim aşağıdaki gibi ifade edilmektedir:

$$\frac{dE^2}{d\mu} = \Delta\mu = \lambda_\mu WE \frac{(x - \mu)}{\sigma^2} \phi(x) \quad (2.37)$$

Burada λ_μ döğümler merkezinin öğrenme oranına karşılık gelmektedir. Buna göre, güncellenmiş merkez değeri aşağıdaki gibi yazılır [81-83]:

$$\mu_k = \lambda_\mu WE \frac{(x - \mu)}{\sigma^2} \phi(x) + \mu_{k-1} \quad (2.38)$$

2.1.6.2.3 Yayılma Genişliğinin (σ) Güncellenmesi

Sinir yayılımına göre hatadaki değışim aşağıdaki gibi ifade edilir:

$$\frac{dE^2}{d\sigma} = \Delta\sigma = \lambda_\sigma WE \frac{(x - \mu)^2}{\sigma^3} \phi(x) \quad (2.39)$$

Burada λ_σ , ağ yayılımına bağı öğrenme oranını belirtmektedir. Güncelleme işleminden sonraki yayılma değeri ise aşağıdaki gibi yazılır:

$$\sigma_k = \lambda_\sigma WE \frac{(x - \mu)^2}{\sigma^3} \phi(x) + \sigma_{k-1} \quad (2.40)$$

Bu parametrelerdeki güncelleme işlemi, durdurma kriterini sağılayan uygun ağ çıkışları elde edilinceye kadar sürdürölür [81-83].

2.2. Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

ANFIS, Takagi-Sugeno bulanık çıkarım sistemine dayanan ve karma öğrenme kurallarını kullanan uyarlanabilir bir ağ olup bu özelliğiyle hem lineer hem de lineer olmayan fonksiyonel problemlerde kullanılmaya oldukça elverişlidir. Ayrıca, üyelik fonksiyonu parametrelerini ve Bulanık Çıkarım Sistemi (FIS) yapısını ayarlamak için sinirsel öğrenme metotlarından yararlanan ANFIS, hem FIS hem de yapay sinir ağlarının sahip olduğu avantajları bünyesinde barındırmaktadır [84-85].

2.2.1. ANFIS Mimarisi

Kolaylık olması açısından söz konusu bulanık çıkarım sisteminin x ve y 'den oluşan iki girişle birlikte bir de z çıkışı olduğu düşünölsün. Birinci dereceden bir Sugeno bulanık modeli için, iki bulanık eğer-ise şartlamasına sahip olan ve yaygın olarak kullanılan kural seti aşağıdaki gibi tanımlanmaktadır:

$$\text{Kural 1: Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise, } f_1 = p_1x + q_1y + r_1 \quad (2.41)$$



$$\text{Kural 2: Eğer } x \text{ } A_2 \text{ ve } y \text{ } B_2 \text{ ise, } f_2 = p_2x + q_2y + r_2 \quad (2.42)$$

Şekil 2.10 (a), Sugeno modeli için neden sonuç mekanizmasını gösterirken buna karşılık gelen eşdeğer ANFIS yapısı Şekil 2.10 (b)'de gösterilmektedir. Burada, aynı katmanda yer alan düğümler benzer fonksiyonlara sahiptir [84-85].

Katman 1: Bu katmandaki her bir i düğümü uyarlanabilirdir ve aşağıdaki gibi tanımlanan bir düğüm çıkışına sahiptir:

$$\begin{cases} O_{1,i} = \mu_{A_i}(x), & i = 1,2 \text{ için} \\ O_{1,i} = \mu_{B_{i-2}}(y), & i = 3,4 \text{ için} \end{cases} \quad (2.43)$$

Burada x ve y düğüm girişlerini, A_i ve B_{i-2} ise ilgili düğümün bulanık setini temsil etmektedir. Diğer bir deyişle, bu katmanın çıkışları öncül bölümün üyelik değerleridir.



Şekil 2.10. (a) İki girişli ve iki kurallı birinci dereceden Sugeno bulanık model; (b) eşdeğer ANFIS yapısı [85].

Burada A_i ve B_i için üyelik fonksiyonu, uygun parametrelili herhangi bir üyelik fonksiyonu olabilir. Örneğin A_i , genelleştirilmiş çan fonksiyonu olarak karakterize edilebilir:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (2.44)$$

Burada $\{a_i, b_i, c_i\}$ parametre setidir. Bu katmandaki parametreler öncül parametreler olarak adlandırılmaktadır [84-85].

Katman 2: Bu katmandaki bütün düğümler sabit olup gelen sinyali çarparak çıkış üretmektedir. Bu katmanda yapılan işlem aşağıdaki gibi gerçekleşmektedir:

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1,2. \quad (2.45)$$

Her bir düğüm çıkışı, bir kuralın ateşleme gücünü temsil etmektedir. Bu katmanda düğüm fonksiyonu olarak bulanık mantık "VE" işlemi kullanılabilir [84-85].

Katman 3: Bu katman "N" ile gösterilen sabit düğümlerden oluşmaktadır. Bu katmandaki i 'inci düğüm, i 'inci kuralın ateşleme gücünün bütün kuralların ateşleme güçleri toplamına oranını hesaplamaktadır [84-85].

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2. \quad (2.46)$$

Katman 4: Bu katmandaki her bir i düğümü uyarlanabilir bir düğümdür ve aşağıdaki düğüm fonksiyonuna sahiptir:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (2.47)$$

Burada $\bar{w}_i$ 3. katmanın çıkışı, $\{p_i, q_i, r_i\}$ ise parametre setidir. Bu katmandaki parametreler, sonuç parametreleri olarak adlandırılmaktadır [84-85].

Katman 5: Bu katman, " Σ " işareti ile gösterilen sabit tek bir düğümden oluşmaktadır. Bu düğüme giren bütün sinyaller toplanarak çıkışa aktarılır [84-85]:

$$O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (2.48)$$

2.2.1.1. Karma Öğrenme Algoritması

Şekil 2.10 (b)'deki ANFIS mimarisinden yola çıkarak, öncül parametrelerin sabitleştirilmesiyle toplam çıkış, sonuç parametrelerinin doğrusal bir kombinasyonu olarak ifade edilebilir. Buna göre, Şekil 2.10 (b)'deki f çıkışı aşağıdaki gibi yazılabilir:

$$\begin{aligned}
f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\
&= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\
&= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \quad (2.49)
\end{aligned}$$

Karma öğrenme algoritmasının ileri geçişinde düğüm çıkışları 4. katmana kadar ilerler ve sonuç parametreleri en küçük kareler yöntemi yardımıyla belirlenir. Algoritmanın geri geçişinde ise hata sinyalleri geriye doğru yayılır ve öncül parametreler gradyan iniş metodu kullanılarak güncellenir. Karma öğrenme algoritması, orijinal geri yayılım algoritmasının sahip olduğu araştırma uzayının boyutunu düşürdüğünden dolayı çok daha hızlı bir yakınsama göstermektedir [84-85].

3. BÖLÜM

SİMÜLASYON ÇALIŞMALARI

3.1. Giriş

Bu bölümde OFDM-IDMA sistemi için, LS ve MMSE gibi klasik kanal kestirim algoritmalarına alternatif olarak, Çok Katmanlı Algılayıcılar, Radyal Tabanlı Sinir Ağları ve Uyarlanabilir Bulanık Çıkarım Sistemi gibi yapay zeka yöntemleri kullanılarak elde edilen kanal kestirimcilerin performansları bilgisayar ortamında yapılan simülasyon çalışmaları vasıtasıyla incelenmiş ve çeşitli karşılaştırmalar yapılmıştır.

3.2. Yapay Zeka Yöntemleri İçin OFDM-IDMA Sistem Parametreleri

Klasik kanal kestirimciler ve önerilen yapay zeka teknikleri kullanılarak tasarlanmış kanal kestirimcilerin performanslarını değerlendirmek için Şekil 1.9'da verilen OFDM-IDMA sistem modeli kullanılmış olup, sistem parametreleri ise Tablo 3.1'deki gibi belirlenmiştir.


Simülasyon çalışmalarında her biri $M = 256$ alt taşıyıcıdan oluşan $S - S_p = 16$ OFDM sembolü kullanılmıştır. Burada S_p , pilot bilgisi olarak ayrılmış olan 17 OFDM sembolünden bir tanesidir. Bununla birlikte, $(171,133)_8$ 'lik üreteç polinomuna sahip $1/2$ oranlı konvolusyon kodlayıcısını takiben her bir kullanıcı için eşdeğer olarak üretilmiş olan $1/16$ 'lık yayma kodu kullanılmıştır. Kanal türü olarak ise, $[0, 4, 8, 12]$ μs 'lik gecikme yayılımları ve $[0, -3, -6, -8]$ dB güç yollarına sahip frekans seçici çok yollu sönmülemeli kanal tipi kullanılmıştır. Simülasyonlar için belirlenen diğer parametreler ise Tablo 3.1'de verilmiştir.

Tablo 3.1. OFDM-IDMA sistem parametreleri.

Kullanılan alt taşıyıcı sayısı	256
FFT boyutu	256
Örnekleme frekansı	500KHz
Örnekleme periyodu	2 μ s
Sembol süresi (TFFT)	256.Ts=512 μ s
Döngüsel önek boyutu	FFT/4=64
Döngüsel önek süresi	TFFT/4=512/4=128 μ s
Modülasyon çeşidi	QPSK

3.3. MLP Sinir Ağları Kullanarak Kanal Kestirimi

Kanal kestirimci olarak kullanılan çok katmanlı algılayıcı modeli Şekil 3.1'de görülmektedir. Şekilde görüldüğü gibi, bir gizli katman, bir de çıkış katmanından oluşan iki katmanlı sinir ağı, kanal kestirimi için dizayn edilmiştir. Simülasyon çalışmasında, 5 nöronlu gizli katman için tanjant hiperbolik fonksiyonu kullanılırken, 2 nöronlu çıkış katmanı için lineer aktivasyon fonksiyonu kullanılmıştır. Kullanılan bu parametreler, yapılan tekrarlı simülasyonlar sonucu elde edilen en uygun değerlerdir.



Şekil 3.1. MLP sinir ağı kanal kestirimci yapısı.

OFDM-IDMA sisteminde vericiden alıcıya gönderilen sinyallerin kompleks sayılardan meydana gelmesi sebebiyle, MLP sinir ağı 2 giriş 2 çıkışlı şekilde tasarlanarak sisteme adapte edilmiştir. Yapay sinir ağlarında yalnızca gerçek sayılarla işlem yapılabildiğinden dolayı, kompleks sayılar kestirimci girişine uygulanmadan önce reel ve imajiner kısımlarına ayrılmıştır.

Sinir ağını kanal kestirimci olarak kullanabilmek için öncelikle Levenberg-Marquardt (LM) algoritması kullanılarak eğitime tabi tutulmuştur. Eğitim verisi olarak ise gerçek kanal frekans cevapları kullanılmıştır. 12000 tane gerçek kanal frekans cevabından oluşan eğitim seti kullanılarak, 100 tekrar (epoch) boyunca sinir ağı eğitilmiştir. Eğitim işlemi tamamlandıktan sonra, alınan sinyallerin reel ve imajiner kısımları ağıın giriş katmanına uygulanmış ve ağ çıkışından kestirilmiş kanal frekans cevapları elde edilmiştir. MLP sinir ağı ile kanal kestirimi işlemi, matematiksel olarak şu şekilde gerçekleştirilmektedir:

Giriş sinyalinin reel ve imajiner kısımları giriş katmanına uygulandıktan sonra, gizli katman aşağıdaki gibi hesaplanmaktadır:

$$net_j = \sum_{i=1}^{L_1} r_i w_{ij} \quad (3.1)$$

Burada w_{ij} , giriş katmanının i 'inci girişinden gizli katmanın j 'inci düğümüne olan ağırlık değeridir. L_1 ise giriş nöron sayısıdır. Eğer gizli katmanda aktivasyon fonksiyonu olarak tanjant hiperbolik fonksiyonu kullanıldıysa, aktivasyon fonksiyonu uygulandıktan sonraki gizli katman değeri aşağıdaki gibi olmaktadır:

$$o_j = f(net_j) = \frac{e^{2net_j} - 1}{e^{2net_j} + 1} \quad (3.2)$$

Çıkış katmanında çıkış düğümleri aşağıdaki gibi hesaplanmaktadır:

$$net_k = \sum_{j=1}^{L_2} o_j w_{jk} \quad (3.3)$$


$$o_k = f(net_k) = net_k \quad (3.4)$$

Burada w_{jk} , gizli katmanın j 'inci düğümünden çıkış katmanının k 'inci düğümüne olan ağırlık bağlantısıdır. L_2 ise gizli katmandaki düğüm sayısını ifade etmektedir. Sonuç olarak, MLP kanal kestirimcisinin çıkışlarından bir tanesi aşağıdaki gibi olacaktır:

$$o_k = f(net_k) = f \left\{ \sum_{j=1}^{L_2} w_{jk} f \left[\sum_{i=1}^{L_1} w_{ij} r_i \right] \right\} \quad (3.5)$$

Kestirilmiş kanal frekans cevapları $H(j)$ ise, ağ çıkışındaki veri çiftlerinin birbirleriyle toplanması sonucu elde edilmektedir.

Şekil 3.2'de OFDM-IDMA sistemi için önerilen MLP kanal kestirimci, Bit Hata Oranı (BHO) kriterine göre LS ve MMSE algoritmalarıyla 0-12 dB E_b/N_0 aralığında kıyaslanmıştır. Bu simülasyon için kullanıcı sayısı 20 olarak belirlenmiştir. Bunun haricinde her bir kanal kestirimci için Tablo 3.1'deki parametre değerleri kullanılmıştır. Şekil 3.2'de görüldüğü gibi, MLP kanal kestirimcisi, LS algoritmasından daha iyi performans göstermektedir. Özellikle yüksek E_b/N_0 değerlerinde, önerilen kestirimcisinin performansı iyileşmekte ve iki eğri arasındaki mesafe artmaktadır. Örneğin, 4 dB 'de LS algoritmasının BHO değeri yaklaşık olarak 3×10^{-1} iken MLP kestirimcisinin BHO değeri yaklaşık olarak 1×10^{-1} 'dir. Bu iki değer birbirene oranı ise $(3 \times 10^{-1}) / (1 \times 10^{-1}) = 3$ olarak bulunur. 6 dB E_b/N_0 değerinde ise, LS algoritması 6.5×10^{-2} BHO'ya sahipken MLP kestirimcisi yaklaşık olarak 1×10^{-2} BHO'ya sahip olmaktadır ve bu kez iki BHO değerinin birbirene oranı 6.5 olarak bulunmaktadır. Yani, 4 dB 'de MLP kestirimcisinin BHO'su, LS algoritmasının BHO'sundan 3 kat daha küçük olmaktadır, 6 dB'de iki kestirimci arasındaki BHO farkı 6.5 kata kadar çıkmaktadır. Yapılan bu analiz göstermektedir ki, LS ve MLP kestirimcilerine ait eğriler arasındaki mesafe, yüksek dB değerlerine çıktıkça artmaktadır. Diğer taraftan, MMSE algoritması, en iyi performansı gösteren kanal kestirimci olarak göze çarpmaktadır. Ancak bu algoritma, kanal frekans cevaplarını kestirebilmek için kanalın istatistiksel verilerine ve gürültü bilgisine ihtiyaç duyduğundan dolayı oldukça karmaşık bir yapıya sahiptir ve bu karmaşık yapısı sebebiyle de kullanıldığı sistemin hızını hatırı sayılır ölçüde yavaşlatmaktadır. Buna karşılık, önerilen MLP kanal kestirimcisi herhangi bir kanal bilgisine ihtiyaç duymamakta ve sisteme kolaylıkla uyarlanabilmektedir. Kanal




Şekil 3.2. OFDM-IDMA sisteminde MLP kanal kestirimcisinin BHO performansı.

kestirimcilerin performansını değerlendirmede kullanılan bir başka yöntem ise Ortalama Karesel Hata (OKH) yöntemidir. Bu yöntemde, belirli bir aralıkta farklı E_b/N_0 değerleri için kestirim hataları hesaplanmaktadır. Her bir E_b/N_0 değeri için OKH değeri aşağıdaki şekilde elde edilir:

$$OKH = \frac{1}{N} \sum_{q=0}^{N-1} E[(h_{est} - h_{real})^H (h_{est} - h_{real})] \quad (3.6)$$

Burada h_{real} ve h_{est} , sırasıyla gerçek kanal frekans cevabı ile kestirilmiş kanal frekans cevabına karşılık gelmektedir.


Şekil 3.3'de her bir kanal kestirimci için 0-15 dB aralığında OKH değişim grafiği görülmektedir. Şekilde görüldüğü üzere, E_b/N_0 değeri arttıkça her bir kestirimci için OKH değeri düşmekte olup LS algoritması diğer kanal kestirimcilere oranla daha fazla



Şekil 3.3. OFDM-IDMA sisteminde MLP kanal kestirimcisinin OKH performansı.

kestirim hatasına sahip olmaktadır. Örneğin 6 dB'de LS algoritması yaklaşık olarak 2×10^{-1} OKH'ya sahipken MLP kestirimcisi ve MMSE algoritması sırasıyla 1×10^{-1} ve 5×10^{-2} OKH değerlerine sahiptir. Buradan da anlaşılacağı gibi, kanal kestirimi için önerilen MLP sinir ağı, LS ve MMSE algoritmaları arasında bir performans göstermektedir.

Şekil 3.4'de LS, MLP ve MMSE gibi kanal kestirimciler altında çalıştırılan OFDM-IDMA sisteminin performansı, farklı kullanıcı sayıları için BHO kriterine göre değerlendirilmiştir. Her bir kestirimcinin BHO grafiği sırasıyla 19 ve 20 kullanıcı OFDM-IDMA sistemi için elde edilmiştir. Yapılan simülasyonlarda Tablo 3.1'deki parametreler kullanılmıştır. Şekil 3.4'de görüldüğü gibi, kullanıcı sayısındaki artışla



Şekil 3.4. Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO performansları.


birlikte her bir kestirimci için sistemin BHO'su artmaktadır. Çünkü, kullanıcı sayısındaki artış, aynı zamanda daha fazla parametrenin işlenmesi ve kestirilmesine sebep olmakta, bunun sonucunda da sistem performansı zayıflamaktadır [86-87].

3.4. RBF Sinir Ağları Kullanarak Kanal Kestirimi

Önerilen RBFNN kestirimci yapısı Şekil 3.5'de gösterilmektedir. Şekilden de görüldüğü gibi radyal tabanlı sinir ağının, iletilen sinyallerin kompleks sayılardan oluştuğu OFDM-IDMA sisteminde kanal kestirimci olarak kullanılabilmesi için 2 giriş 2 çıkışlı bir ağ yapısı tasarlanmıştır. RBFNN sisteminde yalnızca gerçel sayılarla işlem

yapılabildiğinden dolayı her bir kompleks sayı reel ve imajiner kısımlarına ayrıldıktan sonra işleme sokulmaktadır.

İlk olarak RBF sinir ağının gerçek bir kanal kestirimciye dönüştüğü eğitim işlemi gerçekleştirilir. Bu eğitim sürecinde eğitim verisi olarak gerçek kanal frekans cevapları kullanılır. Eğitim işlemini takiben, RBFNN kanal kestirimci OFDM-IDMA sistemi alıcı yapısına entegre edilir. Gelen sinyaller reel ve imajiner kısımlarına ayrıldıktan sonra ağın girişine beslenip ağ çıkışından kestirilmiş kanal frekans cevapları gerçek ve sanal kısımların toplanmasıyla elde edilir.




Şekil 3.5. Radyal tabanlı sinir ağı kanal kestirimci yapısı.

Bu simülasyon çalışmasında, önerilen kanal kestirimci OFDM-IDMA sistemine uyarlanarak LS ve MMSE gibi klasik kanal kestirim algoritmalarının yanı sıra Levenberg- Marquardt (LM) ve Geri yayılım (Backpropagation (BP)) gibi iki farklı eğitim algoritmasıyla eğitilmiş MLP sinir ağı ile BHO ve OKH kriterine göre karşılaştırılmıştır. Kanal kestirimi için tasarlanan RBFNN kestirimcisi 20 nörondan oluşan tek bir gizli katmana sahiptir ve bu katmanda Gauss aktivasyon fonksiyonu kullanılmıştır. RBFNN kestirimcisi ile mukayese edilmek için kullanılan LM algoritmali MLP sinir ağı (MLP-LM) ile BP algoritmali MLP sinir ağı (MLP-BP), 5 nörondan oluşan bir gizli katmana ve 2 nörondan oluşan bir de çıkış katmanına sahiptir. Her iki MLP sinir ağı için aktivasyon fonksiyonu olarak gizli katman ve çıkış katmanında sırasıyla Tanjant hiperbolik fonksiyonu ile lineer aktivasyon fonksiyonu


kullanılmıştır. RBFNN de dahil olmak üzere her bir yapay sinir ağı için 12000 tane gerçek kanal frekans cevabından oluşan eğitim seti kullanılırken OFDM-IDMA sistemindeki kullanıcı sayısı 20 olarak belirlenmiştir. Bunun haricinde her bir kanal kestirimci için Tablo 3.1'deki parametre değerleri kullanılmıştır.

Şekil 3.6'da kanal kestirimi için önerilen radyal tabanlı sinir ağı, LS ve MMSE gibi geleneksel pilot tabanlı kanal kestirim algoritmaları ve MLP-LM, MLP-BP gibi sezgisel tabanlı kanal kestirimcilerle BHO kriterine göre karşılaştırılmıştır. Şekilde görüldüğü gibi, önerilen RBFNN kanal kestirimcisi, LS algoritması ve diğer sezgisel yöntemlerden tüm E_b/N_0 aralığı boyunca daha iyi performans göstermektedir. Ayrıca grafikten açık bir şekilde anlaşılacağı üzere, MLP sinir ağları kullanılarak tasarlanmış ve sırasıyla LM ile BP eğitim algoritmalarının kullanıldığı MLP-LM ve MLP-BP gibi diğer sezgisel yöntemler de LS algoritmasından daha iyi BHO sonuçlarına sahiptir. Buna karşın bu iki yöntem, önerilen RBFNN kestirimcisine göre daha kötü performans göstermektedir.



Şekil 3.6. OFDM-IDMA sisteminde RBFNN kanal kestirimcisinin BHO performansı.


Diğer taraftan, Şekil 3.6'da görüldüğü üzere MMSE algoritması diğer metotlar arasında hala en iyi performansı gösteren kestirimci olarak göze çarpmaktadır. MMSE algoritmasının diğer kestirimcilere olan bu üstünlüğü, kendisine en yakın eğriye sahip olan RBFNN kestirimcisi ile BHO sonuçlarına göre kıyaslanarak anlaşılabilir. Örneğin, 4 dB E_b/N_0 değerinde, MMSE algoritmasının BHO'su yaklaşık olarak 1.75×10^{-3} olurken RBFNN kestirimcisinin BHO değeri 7×10^{-2} olmaktadır. Buna karşın MMSE algoritması, kanal katsayılarını kestirebilmek için kanal kovaryansı ve gürültü varyansı bilgilerine ihtiyaç duymaktadır. Kanal kestirimi için ihtiyaç duyulan bu ön bilgi, MMSE algoritmasını herhangi bir sistemde kanal kestirimi amacıyla kullanılamayacak derecede karmaşık hale getirmektedir. Buna karşın, kanal kestirimi sırasında kanalın istatistiksel verilerine ihtiyaç duyulmaması ve herhangi bir sisteme kolaylıkla uygulanabilir olan esnek bir ağ yapısının kullanılması, RBFNN ile kanal kestirim yöntemini MMSE algoritması önünde avantajlı konuma getirmektedir.



Şekil 3.7. OFDM-IDMA sisteminde RBFNN kanal kestirimcisinin OKH performansı.

Şekil 3.7'de, RBFNN ve diğer kanal kestirimcilerin E_b/N_0 - OKH grafiği görülmektedir. Şekilde görüldüğü üzere, MLP-BP, MLP-LM ve RBFNN'den oluşan sezgisel yöntemlerin kestirim hataları, bütün E_b/N_0 aralığında LS ve MMSE algoritmaları arasında yer almaktadır. Bu sezgisel yöntemler arasında en iyi performansı gösteren kanal kestirimci ise, MMSE algoritmasına en yakın eğriye sahip olan RBFNN kestirimcisidir. Beklendiği gibi, diğer metotlar arasında en kötü performansı gösteren kestirimci LS algoritması olurken, MMSE algoritması en iyi performansı gösteren yöntem olarak göze çarpmaktadır. Örneğin 10 dB E_b/N_0 değerinde LS, MLP-BP, MLP-LM, RBFNN ve MMSE kestirimcilerinin OKH değerleri sırasıyla yaklaşık olarak 8×10^{-2} , 5.5×10^{-2} , 4.75×10^{-2} , 4.1×10^{-2} ve 2×10^{-2} olmaktadır.

Şekil 3.8'de ise, LS, MLP-BP, MLP-LM, RBFNN ve MMSE gibi kanal kestirimciler altında çalıştırılan OFDM-IDMA sisteminin performansı, farklı kullanıcı sayıları için BHO kriterine göre değerlendirilmiştir. Her bir kestirimci için BHO grafiği sırasıyla 19




Şekil 3.8. Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO performansları.

ve 20 kullanıcılı OFDM-IDMA sistemi için elde edilmiştir. Yapılan simülasyonlarda Tablo 3.1'deki parametreler kullanılmıştır. Şekil 3.8'de yer alan kestirimcilerin BHO performansları 19 ve 20 kullanıcılı sistem için sırasıyla kesikli ve düz çizgilerle gösterilmiştir. Şekilden de görüldüğü gibi, bütün E_b/N_0 aralığı boyunca, her bir kanal kestirimci için, sistemin kullanıcı sayısı 19 iken sahip olduğu BHO değeri, 20 iken sahip olduğu BHO değerinden daha azdır. Bunun sebebi, kullanıcı sayısındaki artışın aynı zamanda daha fazla parametrenin işlenmesine ve kestirilmesine sebep olması ve bunun sonucunda da sistem performansının zayıflamasıdır. Örneğin sadece sezgisel metotların 6 dB'deki BHO performanslarına dikkat edilecek olursa, 19 kullanıcılı OFDM-IDMA sistemi için, MLP-BP, MLP-LM ve RBFNN kestirimcilerinin BHO değerlerinin sırasıyla yaklaşık olarak 4.5×10^{-3} , 3×10^{-3} ve 1.3×10^{-3} olduğu görülür. 20 kullanıcılı OFDM-IDMA sistemi için ise MLP-BP, MLP-LM ve RBFNN kestirimcilerinin BHO'larının sırasıyla 1.3×10^{-2} , 9.5×10^{-3} ve 7×10^{-3} değerlerine yükseldiği görülmektedir.

3.5. ANFIS Kullanarak Kanal Kestirimi

Bu simülasyon çalışmasında, ANFIS kullanılarak tasarlanmış olan kanal kestirimci, LS ve MMSE gibi pilot tabanlı kanal kestirim algoritmalarının yanı sıra yaygın bir kullanım alanına sahip yapay zeka tekniklerinden biri olan MLP sinir ağları tabanlı kanal kestirimci ile BHO ve OKH kriterlerine göre karşılaştırılmıştır.

Önerilen ANFIS tabanlı kanal kestirimci Şekil 3.9'da görülmektedir. ANFIS kestirimcisinin, iletilen verilerin kompleks sayılardan oluştuğu OFDM-IDMA sisteminde kanal kestirimci olarak kullanılabilmesi için Şekil 3.9'daki gibi 2 giriş 1 çıkışa sahip bir şekilde tasarlanması gerekmektedir. Bunun sebebi, diğer yapay zeka tekniklerinde olduğu gibi ANFIS'de de yalnızca gerçek sayılarla işlem yapılabilmesi ve bu yüzden her bir kompleks sinyalin reel ve imajiner kısımlarına ayrılarak kestirimci girişine beslenmesidir. Önerilen ANFIS yapısı, ilk olarak gerçek kanal frekans cevaplarından oluşan eğitim seti kullanılarak eğitim işlemine tabi tutulur. Bu eğitim aşaması, ANFIS'in OFDM-IDMA sisteminin alıcısında kanal kestirimci olarak kullanılabilir hale gelmesi içindir. Eğitim aşamasının tamamlanmasının ardından, alınan




Şekil 3.9. ANFIS kanal kestirimci yapısı.

sinyaller reel ve imajiner kısımlarına ayrılarak önerilen ANFIS tabanlı kestirimci girişine beslenir. Böylelikle, kestirilmiş kanal frekans cevapları, reel ve imajiner kısımların tekrar toplanmasıyla ANFIS çıkışından elde edilir.

Yapılan simülasyon çalışmasında, üç tane genelleştirilmiş çan fonksiyonu (gbellmf) içeren ANFIS modeli, 10000 tane gerçek kanal frekans cevabından oluşan eğitim seti ile 100 tekrar (epoch) boyunca eğitime tabi tutulmuştur. Diğer taraftan, eğitim algoritması olarak geri yayılım algoritmasının kullanıldığı MLP tabanlı kestirimci, 5 nöronlu bir gizli katmana ve 2 nöronlu bir çıkış katmanına sahiptir. Bu kestirimcide de ANFIS tabanlı kestirimcide olduğu gibi 10000 tane gerçek frekans cevabından oluşan eğitim seti kullanılmıştır.

Şekil 3.10'da, önerilen ANFIS modelinin diğer kestirimciler arasındaki etkinliğini görebilmek amacıyla her bir kestirimci için OFDM-IDMA sistem performansı BHO kriteri bakımından değerlendirilmiştir. Bu simülasyon çalışması için kullanıcı sayısı 20


olarak seçilirken, diğer parametreler Tablo 3.1'de gösterildiği gibidir. Şekil 3.10'da görüldüğü gibi, ANFIS kestirimcisi her bir E_b/N_0 değerinde hem LS algoritmasından hem de MLP tabanlı kanal kestirimciden daha iyi performans göstermektedir. Grafik üzerinde özellikle LS ve ANFIS eğrilerine dikkat edilirse, 0 dB'den 6 dB'e kadar olan kısımda iki dalga arasındaki mesafenin arttığı görülmektedir. Buradan belirtilen aralık boyunca, önerilen ANFIS kestirimcisinin performans bakımından sürekli olarak artış gösterdiği sonucuna varılabilir. 6 dB'den itibaren ise iki eğri arasındaki mesafe sabitleşmektedir. Şekil 3.10'a farklı bir perspektiften bakılacak olursa, beklendiği üzere en iyi performansa sahip MMSE algoritmasının kanal kestirimci olarak kullanıldığı OFDM-IDMA sisteminde elde edilen E_b/N_0 -BHO eğrisine en çok ANFIS tabanlı kanal kestirimci ile yaklaşılmıştır. MMSE algoritması en iyi performansı gösterse bile, aşırı karmaşık yapısı ve kanal katsayılarının kestirilmesinde kanalın istatistiksel verilerine olan ihtiyacı, algoritmanın herhangi bir sistemde kullanılmasına büyük engel teşkil etmektedir. Buna karşın önerilen ANFIS kestirimcisi, herhangi bir kanal bilgisine



Şekil 3.10. OFDM-IDMA sisteminde ANFIS kanal kestirimcisinin BHO performansı.


ihtiyaç duymaksızın kanal frekans cevaplarını kestirebilmekte ve esnek yapısı sayesinde OFDM-IDMA sistemine rahatlıkla uygulanabilmektedir.

Şekil 3.11'de, LS, MLP, ANFIS ve MMSE kestirimcilerinin E_bN_0 -OKH grafikleri görülmektedir. Aşağıdaki şekilde, performans bakımından Şekil 3.10'da elde edilen sonuçlara benzer sonuçlar elde edilmiştir. Şekil 3.11'de görüldüğü gibi, önerilen ANFIS tabanlı kestirimcinin kanal kestirim hataları 0-15 dB aralığında MLP ve MMSE arasında kalmaktadır. Diğer taraftan, LS algoritması söz konusu kestirimciler arasında en kötü performansa sahip kanal kestirimci olarak göze çarpmaktadır. Bu durum, hızlı sönmümlü ve zaman değişimli kanallarda kanal frekans cevaplarını kestirmede göstermiş olduğu zayıflıktan kaynaklanmaktadır.



Şekil 3.11. OFDM-IDMA sisteminde ANFIS kanal kestirimcisinin OKH performansı.

Şekil 3.12'de ise OFDM-IDMA sisteminin, farklı kullanıcı sayıları için sırasıyla LS, MLP, ANFIS ve MMSE kestirimcileri altındaki performansı BHO kriterine göre elde edilmiştir. Her bir kestirimcinin BHO grafiği sırasıyla 20 ve 21 kullanıcı OFDM-IDMA sistemi için elde edilmiştir. Bunun haricinde her bir kanal kestirimci için Tablo 3.1'deki sistem parametreleri kullanılmıştır. Şekil 3.12'de, bundan önceki kullanıcı sayısına göre yapılan karşılaştırmalarda olduğu gibi, her bir kestirimci için, kullanıcı sayısı arttıkça BHO artmaktadır. Bu durum, kullanıcı sayısındaki artışla daha fazla parametrenin işlenmesi ve bunun sonucunda da sistem performansının zayıflaması sonucu ortaya çıkmaktadır. Örneğin yine sadece sezgisel metotların 6 dB'deki BHO performanslarına dikkat edilecek olursa, 20 kullanıcı OFDM-IDMA sistemi için MLP ve ANFIS kestirimcilerinin BHO değerlerinin sırasıyla yaklaşık olarak 1.3×10^{-2} ve 5.5×10^{-3} olduğu görülür. 21 kullanıcı OFDM-IDMA sistemi için ise MLP ve ANFIS kanal kestirimcilerinin BHO'larının sırasıyla yaklaşık olarak 3.5×10^{-2} ve



Şekil 3.12. Kanal kestirimcilerin farklı kullanıcı sayılarındaki BHO performansları.

2.5×10^{-2} değerlerine yükseldiği görülmektedir. Buradan, kullanıcı sayısının BHO'da artışa sebep olduğu açıkça anlaşılmaktadır.

4. BÖLÜM

SONUÇ VE ÖNERİLER

Bu tezde, yüksek veri transfer oranlarında iletişim yapılmasını sağlayan OFDM-IDMA sisteminde, çok yollu kanalların sebep olduğu sönümlleme etkisinin ortadan kaldırılabilmesi için ihtiyaç duyulan kanal katsayıları, yapay zeka tekniklerinden Çok Katmanlı Algılayıcılar (MLP), Radyal Tabanlı Sinir Ağları (RBFNN) ve Uyarlanabilir Bulanık Çıkarım Sistemi (ANFIS) kullanılarak tasarlanan kanal kestirimciler vasıtasıyla elde edilmiştir. MLP sinir ağlarının eğitimi için Levenberg-Marquardt (LM) ve Geri yayılım (Backpropagation:BP) olmak üzere iki farklı eğitim algoritması kullanılmıştır. Önerilen yapay zeka teknikleri kullanılarak yapılan kanal kestirim işlemi iki aşamada gerçekleştirilmiştir. Birinci aşamada MLP, RBFNN ve ANFIS gibi yapay zeka teknikleri ile oluşturulan ağ yapıları, gerçek kanal katsayılarından oluşan eğitim setiyle eğitilmiştir. İkinci aşamada ise, eğitim işlemi sonucunda kanal yapısını tam olarak öğrenen ve her biri artık bir kanal kestirimciye dönüşen bu ağ yapıları, OFDM-IDMA sisteminin alıcı yapısına entegre edilerek kanal kestirim işlemi gerçekleştirilmiştir. Belirtilen yapay zeka teknikleri kullanılarak tasarlanan kanal kestirimcilerin performansları, en küçük kareler (LS) ve minimum ortalama karesel hata (MMSE) gibi geleneksel pilot tabanlı kanal kestirim algoritmalarının performansları ile bit hata oranı (BHO) ve ortalama karesel hata (OKH) kriterlerine göre bilgisayar ortamında yapılan simülasyon çalışmalarıyla karşılaştırılmıştır. Bunun yanında, OFDM-IDMA sisteminin, farklı kullanıcı sayıları için LS, MLP, RBFNN, ANFIS ve MMSE kestirimcileri altındaki performansı BHO kriterine göre elde edilmiştir. Simülasyon sonuçlarına göre, kullanıcı sayısındaki artışla birlikte her bir kestirimci için sistemin BHO'sunun arttığı görülmüştür. Bu durumun, kullanıcı sayısındaki artışla daha fazla

parametrenin işlenmesi ve bunun sonucunda da sistem performansının zayıflaması sonucu meydana geldiği bilinmektedir.

Yapılan simülasyon çalışmalarına göre, önerilen yapay zeka yöntemleri kullanılarak tasarlanmış kanal kestirimcilerin her biri LS algoritmasından daha iyi performans gösterirken MMSE algoritması hala en iyi performansı gösteren algoritma olarak göze çarpmaktadır. LS algoritması yapı itibarıyla oldukça basit, fazla matematiksel işlem gerektirmeyen ve herhangi bir sisteme kolaylıkla uygulanabilir bir algoritma olmasına karşın zamana göre değişken çok yollu sönümlemeli kanallarda performans olarak zayıf kalmıştır. MMSE algoritması ise, performans olarak diğer kanal kestirimcilerden daha önde olmasına rağmen, korelasyon ve matris tersinin alınması gibi karmaşık matematiksel işlemler gerektiren yapısı nedeniyle kullanıldığı sistemin karmaşıklığını artırmakta ve bunun sonucunda sistem hızı hatırı sayılır derecede yavaşlamaktadır. Bunun yanı sıra, kanal frekans cevaplarını elde edebilmek için kanalın istatistiksel verilerine ve gürültü bilgisine ihtiyaç duymaktadır. Kanal kestirimi için ihtiyaç duyulan bu ön bilgi, MMSE algoritmasının herhangi bir haberleşme sisteminde kanal kestirimci olarak uygulanabilirlik şansını önemli derecede azaltmaktadır. Buna karşın önerilen yapay zeka yöntemleri kullanılarak tasarlanan kanal kestirimciler, herhangi bir kanal bilgisine ihtiyaç duymadan kanal katsayılarını kestirebilme özelliğine sahip olup, sahip oldukları esnek yapı ve etkin öğrenme kapasiteleri, herhangi bir sisteme kolaylıkla adapte edilebilmelerini sağlamaktadır. Diğer taraftan, yapay zeka teknikleriyle kanal kestirimi yapılırken pilot tonlarına ihtiyaç duyulmamakta ve bunun sonucunda bant genişliği daha etkin bir şekilde kullanılabilir. Bu da önerilen kanal kestirimcileri, geleneksel pilot tabanlı kanal kestirim algoritmaları arasında avantajlı bir konuma getirmektedir. MLP, RBFNN ve ANFIS gibi yapay zeka yöntemleri ile yapılan kanal kestirim işlemlerinde en iyi performansı ANFIS gösterirken en kötü performansı ise, eğitim algoritması olarak geri yayılım algoritması kullanılan MLP sinir ağı göstermiştir. Ancak aralarında performans bakımından çok büyük farklar yoktur. Yapay zeka yöntemleri ile kanal kestirim işleminin sahip olduğu en büyük dezavantaj ise aşırı değişken kanal şartlarında ağı eğitilmesinde yaşanan zorluktur. Bu dezavantaj, eğitim seti büyüklüğü artırılarak ortadan kaldırılabilir. Sonuç olarak MLP, RBFNN ve ANFIS gibi yapay zeka teknikleri kullanılarak oluşturulan kanal kestirimciler ile sistem karmaşıklığı çok fazla artırılmadan kanal durum bilgisi en doğru şekilde elde edilip

kanalın bozucu etkileri ortadan kaldırılmıştır. Bunun yanında, MMSE gibi geleneksel pilot tabanlı kanal kestirim algoritmasının sahip olduğu dezavantajlar asgari düzeye indirilmiştir.

Yapay zeka yöntemleri kullanılarak tasarlanan kanal kestirimcilerde karşılaşılan en büyük sorun ise, kanal şartlarında normalin üzerinde değişim meydana gelmesi durumunda eğitim işlemini yenileme gerekliliğidir. Eğitim işleminin belirli periyotlarla tekrarlanması ya da eğitim seti uzunluğunun artırılarak eğitim işlemi yapılması durumunda bu dezavantaj ortadan kaldırılabilir.

İlerde yapılacak çalışmalarda, İşbirlikli Haberleşme ve OFDMA gibi sistemlerde yapay zeka teknikleri ile kanal kestirimi yapılarak söz konusu haberleşme sistemlerinde daha kaliteli iletişim sağlanabilir. Böylelikle her iki haberleşme sistemi için daha önceden kullanılmakta olan klasik kanal kestirim algoritmalarının sahip olduğu dezavantajlar ortadan kaldırılacaktır. Bunun sonucunda, çok yollu sönümlü kanalların sahip olduğu bozucu etki ortadan kaldırılıp, sistem performansı maksimuma çıkarılacaktır.

KAYNAKÇA

1. Ping, L., Liu, L., 2004. Analysis and design of IDMA systems based on SNR evolution and power allocation, pp. 1068-1072. *Vehicular Technology Conference (VTC2004-Fall)*, September 26-29, 2004, Los Angeles, CA, USA
2. Mahafeno, I., Langlais, C., Jego, C., 2006. OFDM-IDMA versus IDMA with ISI cancellation for quasi-static Rayleigh fading multipath channels, pp. 3-7. *4th International Symposium on Turbo Codes & Related Topics*, April 3-7, 2006, Munich, Germany.
3. Zhou, S., Li, Y., Zhao, M., Xu, X., Wang, J., Yao, Y., 2005. Novel techniques to improve downlink multiple access capacity for beyond 3G. **IEEE Communications Magazine**, **43**(1): 61-69.
4. Wang, P., Xiao, J., Ping, L., 2006. Comparison of orthogonal and nonorthogonal approaches to future wireless cellular systems. **IEEE Vehicular Technology Magazine**, **1**(3): 4-11.
5. Schoeneich, H., Hoeher, P. A., 2004. Adaptive interleave division multiple access-A potential air interference for 4G bearer services and wireless LANs, pp. 179-182. *Wireless and Optical Communications Networks (WOCN)*, June, 2004, Muscat, Oman.
6. Ren, W., He, X., Liu, X., Li, S., 2010. 2 dimension interleaver design for OFDM-IDMA system, pp. 1-4. *Wireless Communications Networking and Mobile Computing (WiCOM)* September 23-25, 2010, Chengdu, China.
7. Juliet, M. A., Jayashri, S., 2013. Design analysis of deterministic interleaver for OFDM-IDMA system, pp. 206-210. *2013 International Conference on Signal Processing Image Processing & Pattern Recognition (ICSIPR)* February 7-8, 2013, Coimbatore, Tamil Nadu, India.
8. Kol, K. V., Mishra, A., 2013. Discrete wavelet transform based OFDM-IDMA system with AWGN channel, pp. 1-4. *2013 Students Conference on Engineering and Systems (SCES)*, April 12-14, 2013, Allahabad, India.
9. Balogun, M. B., Oyerinde, O. O., Mneney S. H., 2013. Linear MMSE-based frequency synchronization algorithm for OFDM-IDMA systems, pp. 1-6. *AFRICON*; September 9-12, 2013, Pointe-Aux-Piments.

10. Dang, J., Zhang, W., Yang, L., Zhang, Z., 2013. OFDM-IDMA with user grouping. **IEEE Transactions on Communications**, **61**(5): 1947-1955.
11. Sharma, S., Sau, P. C., Shukla, A., 2014. Performance survey of IDMA with different interleavers, pp. 344-348. *2014 International Conference on Signal Processing and Integrated Networks (SPIN)*, February 20-21, 2014, Noida, India.
12. Kalyana, R., Anuradha, S., 2014. Performance analysis of modified random based interleaver for OFDM-IDMA system, pp. 896-900. *2014 International Conference on Advanced Communication Control and Computing Technologies (ICACCCT)*, May 8-10, 2014, Ramanathapuram, India.
13. Nozaki, M., Yoshizawa, S., Tanimoto, H., 2014. VLSI design of an interference canceller for QPSK OFDM-IDMA systems, pp. 715-718. *2014 IEEE Asia Pacific Conference on Circuits and Systems*, November 17-20, 2014, Ishigaki, Japan.
14. Ping, L., Liu, L., Wu, K. Y., Leung, W. K., 2006. Interleave-division multiple-access. **IEEE Transactions on Wireless Communications**, **5**(4): 938-947.
15. Ping, L., Guo, Q., Tong, J., 2007. The OFDM-IDMA approach to wireless communication system. **IEEE Wireless Communications**, **14**(3): 18-24.
16. Zhuang, X., Ding, Z., Swindlehurst, A. L., 2000. A statistical subspace method for blind channel identification in OFDM communication, pp. 141-150. *IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '00)*, June 5-9, 2000, Istanbul, Turkey.
17. Bai, W., He, C., Jiang, L., Zhu, H., 2002. Blind channel estimation in MIMO-OFDM Systems, pp. 317-321. *IEEE Global Telecommunications Conference*, November 17-21, 2002, Taipei, Taiwan.
18. Shin, C., Heath, R.W., Powers, E.J., 2007. Blind channel estimation in MIMO-OFDM systems. **IEEE Transactions on Vehicular Technology**, **56** (2): 670-685.
19. Gao, F., Nallathathan, A., 2007. Blind channel estimation for MIMO-OFDM systems via nonredundant linear precoding. **IEEE Transactions on Signal Processing**, **55** (2): 784-789.
20. Jeremic, A., Thomas, T. A., 2004. OFDM channel estimation in presence of interference. **IEEE Transactions on Signal Processing**, **52**(12): 3429-3439.

21. Bahai, A. R. S., Saltzberg, B. R., Ergen, M., 2004. Multi Carrier Digital Communications: Theory and Applications of OFDM. Springer Science, Business Media, Boston, 411 pp.
22. Liang, S., Wu, W., 2003. Channel estimation based on pilot subcarrier in spacetime block coded OFDM system, pp. 1795-1798. *IEEE International Conference on Communication Technology*, April 9-11, 2003, Beijing, China.
23. Coleri, S., Ergen, M., Puri, A., Bahai, A., 2002. Channel estimation techniques based on pilot arrangement in OFDM systems. **IEEE Transactions on Broadcasting**, **48**(3): 223-229.
24. Edfors, O., Sandell, M., Van de Beek, J. J., Wilson, S. K., Borjesson, P.O., 1998. OFDM channel estimation by singular value decomposition. **IEEE Transactions on Communications**, **46**(7): 931-939.
25. Harjula, I., Mammela, A., 2003. Channel estimation algorithm for space-time block coded OFDM systems, pp. 143-147. *IEEE Global Communications Conference(GLOBECOM '03)*, December 1-5, 2003, San Francisco, USA.
26. Morelli, M., Mengali, U., 2001. A comparison of pilot aided channel estimation methods for OFDM systems. **IEEE Transactions on Signal Processing**, **49**(12): 3065-3073.
27. Bagadi, P. K., Das, S., 2010. MIMO-OFDM channel estimation using pilot carries. **International Journal of Computer Applications**, **2**(3): 81-88.
28. Yalçın, M., Akan, A., Doğan, H., 2012. Low-complexity channel estimation for OFDM systems in high-mobility fading channels. **Turkish Journal of Electrical Engineering and Computer Sciences**, **20**(4): 583-592.
29. Zaier, A., Bouallègue, R., 2011. Channel estimation study for block-pilot insertion in OFDM systems under slowly time varying conditions. **International Journal of Computer Networks & Communications (IJCNC)**, **3**(6): 39-54.
30. Hsieh, M. H., Wei, C. H., 1998. Channel estimation for OFDM systems based on comb-type pilot arrangement in frequency selective fading channels. **IEEE Transactions on Consumer Electronics**, **44**(1): 217-225.
31. Ozdemir, M. K., Arslan, H., 2007. Channel estimation for wireless OFDM systems. **IEEE Communications Surveys & Tutorials**, **9**(2): 18-48.

32. Pathak, S., Sharma, H., 2013. Channel estimation in OFDM systems. **International Journal of Advanced Research in Computer Science and Software Engineering**, 3(3): 312-327.
33. de Beek, J. J. V., Edfors, O. S., Sandell, M., Wilson, S. K., Börjesson, O. P., 1995. On channel estimation in OFDM systems, pp. 815-819. *IEEE Vehicular Technology Conference*, July 25-28, 1995, Chicago, IL, USA.
34. Tavassoli, F., Abolhassani, B., 2005. Comb type pilot aided channel estimation for OFDM systems, pp. 1-4. 2. *International Symposium on Wireless Communication*, September 5-7, 2005, Siena, Italy.
35. Hou, X., Xu, Y., Zheng, B., Luo, H., 2005. A time-domain approach for channel estimation in MIMO-OFDM-based wireless networks. **IEICE Transactions Communications**, E88-B(1): 3-9.
36. Ogawa, Y., Nishio, K., Nishimura, T., Ohgane, T., 2005. Channel estimation and signal detection for space division multiplexing in a MIMO-OFDM system. **IEICE Transactions Communications**, E88-B (1): 10-18.
37. Seyman, M. N., 2011. Çok Girişli-Çok Çıkışlı Dikgen Frekans Bölmeli Çoğullama Sistemlerinde Yapay Zeka Teknikleri ile Kanal Kestirimi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Kayseri, 117s.
38. Abdolee, R., Rahman, T. A., Idrus, S. M., 2007. Computational complexity reduction for MIMO-OFDM channel estimation algorithms, **Elektrika**, 9 (1): 30-36.
39. Hsieh, M. H., Wei, C. H., 2005. Channel estimation for OFDM system based on comb-type pilot arrangement in frequency selective fading channels. **IEEE Transactions on Consumer Electronics**, 44(1): 217-225.
40. Oyerinde, O. O., Mneney, S. H., 2013. Recursive MMSE-based iterative channel estimation for OFDM-IDMA systems, pp. 1-5. *AFRICON 2013*, September 9-12, 2013, Pointe-Aux-Piments.
41. Oyerinde, O. O., Mneney, S. H., 2012. Combined channel estimation and adaptive prediction for MC-IDMA systems, pp. 3708-3712. *2012 IEEE International Conference on Communications (ICC)*, June 10-15, 2012, Ottawa, ON, Canada.

42. Hammarberg, P., Rusek, F., Edfors, O., 2012. Channel estimation algorithms for OFDM-IDMA complexity and performance. **IEEE Transactions on Wireless Communications** **11**(5): 1722-1732.
43. Sarma, K. K., Mitra, A., 2009. ANN based Rayleigh multipath fading channel estimation of a MIMO-OFDM system, pp. 1-5. *First Asian Himalayas International Conference on Internet (AH-ICI 2009)*; November 3-5, 2009, Kathmandu, Nepal.
44. Cheng, C. H., Cheng, Y. P., Huang, Y. H., Li, W. C., 2013. Using back propagation neural network for channel estimation and compensation in OFDM systems, pp. 340-345. *2013 Seventh International Conference on Complex, Intelligent and Software Intensive Systems (CISIS)*; July 3-5, 2013, Taichung, Taiwan.
45. Moustafa, M. M. A., El-Ramly, S. H. A., 2009. Channel estimation and equalization using backpropagation neural networks in OFDM systems, pp. 1-4. *IFIP International Conference on Wireless and Optical Communications Networks, 2009 (WOCN'09)*; April 28-30, 2009, Cairo, Egypt.
46. Sharma, K., Varshney, S., 2012. Artificial neural network channel estimation for OFDM system. **International Journal of Electronics and Computer Science Engineering**, **1**(3): 1686-1691.
47. Seyman, M. N., Taşpınar, N., 2013. Channel estimation based on neural network in space time block coded MIMO-OFDM system. **Digital Signal Processing**, **23**(1): 275-280.
48. Seyman, M. N., Taşpınar, N., 2012. Channel estimation based on neural network with feedback for MIMO OFDM mobile communication systems. **Intelligent Automation and Soft Computing**, **18**(3): 307-316.
49. Seyman, M. N., Taspınar, N., 2013. Radial basis function neural networks for channel estimation in MIMO-OFDM systems. **Arabian Journal for Science and Engineering**, **38**(8): 2173-2178.
50. Seyman, M. N., Taşpınar, N., 2008. Channel estimation based on adaptive neuro-fuzzy inference system in OFDM. **IEICE Transactions on Communications**, **E91-B**(7): 2426-2430.
51. Seyman, M. N., Taşpınar, N., 2012. MIMO-OFDM channel estimation using ANFIS. **Elektronika ir Electrotechnica**, **4**(120): 75-78.

52. Hua, C., Xiao-hui, Z., 2010. MIMO-OFDM channel estimation based on neural network, pp. 1-4. *2010 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM)*; September 23-25, 2010, Chengdu, China.
53. Fazel, K., Kaiser, S., 2003. Multi-Carrier and Spread Spectrum Systems. John Wiley & Sons Ltd., Chichester, 353 pp.
54. Bahai, A. R. S., Saltzberg, B. R., Ergen, M., 2004. Multi Carrier Digital Communications: Theory and Applications of OFDM. Springer Science, Business Media, Boston, 411 pp.
55. Stüber, G. L., 2002. Principles of Mobile Communication. Kluwer Academic Publishers, New York, 752 pp.
56. Parsons, D., 1992. The Mobile Radio Propagation Channel, John Wiley & Sons Ltd., New York, 413 pp.
57. Rappaport, T. S., 1996. Wireless Communications. Prentice Hall, Upper Saddle River, 656 pp.
58. Rappaport, T. S., 2001. Wireless Communications: Principles and Practice, 2nd Edition. Prentice Hall PTR, Upper Saddle River, 736 pp.
59. Paetzold, M., 2011. Mobile Radio Channels, 2nd Edition. John Wiley & Sons Ltd., Chichester, 616 pp.
60. Srivastava, N., 2010. Diversity schemes for wireless communication-a short review. **Journal of Theoretical and Applied Information Technology**, **15**(2): 134-143.
61. Raut, P. W., Badjate, S. L., 2013. Diversity techniques for wireless communication. **International Journal of Advanced Research in Engineering and Technology**, **4**(2): 144-160.
62. Van Nee, R., Prasad, R., 2000. OFDM for Wireless Multimedia Communications, Artech House, London, 260 pp.
63. Heiskala, J., Terry, J., 2001. OFDM Wireless LANs: A Theoretical And Practical Guide, SAMS Publishing, 336 pp.
64. Sadat, A., Mikhael, W. B., 2001. Fast Fourier transform for high speed wireless multimedia system, **IEEE Transactions on Signal Processing**, **65** (3): 938-942.

65. Chang, R.W., Gibby, R.A., 1968. Theoretical study of performance of an orthogonal multiplexing data transmission scheme, **IEEE Transactions on Communications**, **16** (4): 529-540.
66. Weinstein, S.B., Ebert, P.M., 1971. Data transmission by frequency-division multiplexing using the discrete Fourier transform. **IEEE Transactions on Communication Technology**, **19**(5): 628-634.
67. Armstrong, J., 2009. OFDM for Optical Communications. **Journal of Lightwave Technology**, **27**(3): 189-204.
68. Wu, Y., Zou, W. Y., 1995. Orthogonal frequency division multiplexing: a multi-carrier modulation scheme. **IEEE Transactions on Consumer Electronics**, **41**(3): 392-399.
69. Kaur, S., Bharti, G., 2012. Orthogonal frequency division multiplexing in wireless communication systems: a review. **International Journal of Advanced Research in Computer Engineering & Technology**, **1**(3): 125-129.
70. Hagan, M.T., Demuth, H.B., Beale, M., 1995. Neural Network Design. PWS Publishing Company, Boston, 734 pp.
71. Zurada, J.M., 1992. Introduction to Artificial Neural Networks, West Publishing Company, New York, 758 pp.
72. Sağıroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları, Ufuk Kitap Kırtasiye Yayıncılık, Kayseri, 426 s.
73. Poggio, T., Girosi, F., 1990. Networks for approximation and learning. **Proceeding of the IEEE**, **78** (12): 1481-1497.
74. Hagan, M. T., Menhaj, B., 1994. Training feed forward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, **5** (6): 989-993.
75. Rojas, R., 1996. Neural Networks: A Systematic Introduction, Springer, Berlin, 502 pp.
76. Haykin, S., 1999. Neural networks – A comprehensive Foundation (2nd ed.). Prentice Hall, Upper Saddle River, 842 pp.
77. Rumelhart, D., McClelland, J., 1986. Parallel Distributed Processing. MIT Press, Cambridge, 567 pp.

78. Bors, A. G., 2001. Introduction of the Radial Basis Function (RBF) Networks, pp. 1-7. *Online Symposium for Electronics Engineers, issue DSP Algorithms: Multimedia*, February 13, 2001.
79. Chen, S., Cowan, C. F. N., Grant, P. M., 1991. Orthogonal least squares learning algorithm for radial basis function networks, **IEEE Transactions on Neural Networks**, **2** (2): 302-309.
80. Park, J., Sandberg, I., 1991. Universal approximation using radial basis functions network. **Neural Computation** **3**(2): 246-257.
81. Karayiannis, N.B., 1999. Reformulated radial basis neural networks trained by gradient descent. **IEEE Transactions on Neural Networks**, **10**(3): 657–671.
82. Musavi, M.T., Ahmed, W., Chan, K.H., Faris, K.B., Hummels, D.M., 1992. On the training of radial basis function classifiers. **Neural Networks**, **5**(4): 595–603.
83. Buhmann, G., Martin, D., 2003. Radial Basis Functions: Theory and Implementations. Cambridge University Press, Cambridge, 258 pp.
84. Jang, J. S. R., Sun, C. T., Mijutani, E., 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine intelligence, Prentice Hall, 614 pp.
85. Jang, J. S., Sun, C. T., 1995. Neuro-Fuzzy Modeling and Control. **Proceedings of the IEEE**, **83** (3): 378-406.
86. Taşpınar, N., Şimşir, Ş., 2014. Channel estimation techniques in OFDM-IDMA systems, pp. 10-14. *2014 2nd International Symposium on Wireless Systems within the Conferences on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS-SWS)*, September 11-12, 2014, Offenburg, Germany.
87. Şimşir, Ş., Taşpınar, N., 2014. Channel estimation using neural network in Orthogonal Frequency Division Multiplexing-Interleave Division Multiple Access (OFDM-IDMA) system, pp. 1-5. *2014 International Telecommunications Symposium (ITS)*, August 17-20, 2014, Sao Paulo, Brazil.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Şakir ŞİMŞİR
 Uyuğu: Türkiye (TC)
 Doğum Tarihi ve Yeri: 28 Kasım 1988 , Kayseri
 Medeni Durumu: Bekâr
 Tel: +90 352 207 66 66 (32235)
 Fax: +90 352 437 57 84
 email: sakirsimsir@erciyes.edu.tr
 Yazışma Adresi: Erciyes Üniversitesi, Mühendislik Fakültesi 38039
 Melikgazi/KAYSERİ

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Erciyes Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği	2011
Lise	Bünyan Anadolu Lisesi, Kayseri	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2013- Halen	Erciyes Üniversitesi Mühendislik Fakültesi	Araştırma Görevlisi

YABANCI DİL

İngilizce

YAYINLAR

1. Taşpınar, N., Şimşir, Ş., 2014. Channel estimation techniques in OFDM-IDMA systems, pp. 10-14. *2014 2nd International Symposium on Wireless Systems within the Conferences on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS-SWS)*, September 11-12, 2014, Offenburg, Germany.

2. Şimşir, Ş., Taşpınar, N., 2014. Channel estimation using neural network in Orthogonal Frequency Division Multiplexing-Interleave Division Multiple Access (OFDM-IDMA) system, pp. 1-5. *2014 International Telecommunications Symposium (ITS)*, August 17-20, 2014, Sao Paulo, Brazil.