

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

**ÇOK GİRİŞLİ-ÇOK ÇIKIŞLI DİKGEN FREKANS  
BÖLMELİ ÇOĞULLAMA SİSTEMLERİNDE YAPAY  
ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ**

**Hazırlayan  
Muhammet Nuri SEYMAN**

**Danışman  
Prof. Dr. Necmi TAŞPINAR**

**Doktora Tezi**

**HAZİRAN 2011  
KAYSERİ**



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

**ÇOK GİRİŞLİ-ÇOK ÇIKIŞLI DİKGEN FREKANS  
BÖLMELİ ÇOĞULLAMA SİSTEMLERİNDE YAPAY  
ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ**

**Hazırlayan  
Muhammet Nuri SEYMAN**

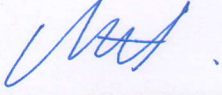
**Danışman  
Prof. Dr. Necmi TAŞPINAR**

**Doktora Tezi**

**HAZİRAN 2011  
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.



Muhammet Nuri SEYMAN

**Çok Girişli Çok Çıkışlı Dikgen Frekans Bölmeli Çoğullama Sistemlerinde Yapay Zeka Teknikleri İle Kanal Kestirimi** adlı Doktora tezi, Erciyes Üniversitesi Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

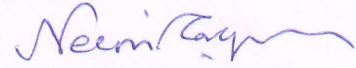
Tezi Hazırlayan

Muhammet Nuri SEYMAN



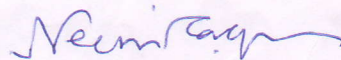
Danışman

Prof. Dr. Necmi TAŞPINAR



**Elektrik-Elektronik Mühendisliği ABD Başkanı**

Prof. Dr. Necmi TAŞPINAR

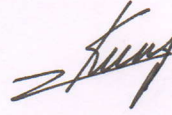


Prof. Dr. Necmi TAŞPINAR danışmanlığında **Muhammet Nuri SEYMAN** tarafından hazırlanan “**Çok Girişli-Çok Çıkışlı Dikgen Frekans Bölmeli Çoğullama Sistemlerinde Yapay Zeka Teknikleri ile Kanal Kestirimi**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalında **Doktora** tezi olarak kabul edilmiştir.

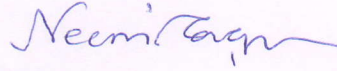
23.06.2011

**JÜRİ:**

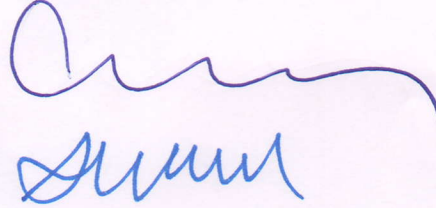
Başkan: Prof.Dr.Kerim GÜNEY



Üye : Prof.Dr. Necmi TAŞPINAR



Üye : Prof.Dr. Celal YILDIZ



Üye : Doç.Dr.Ali GANGAL



Üye : Doç.Dr.İbrahim DEVELİ

**ONAY:**

Bu tezin kabulü Enstitü Yönetim Kurulunun 05/07/2011 tarih ve 2011/23-05 sayılı kararı ile onaylanmıştır.

05/07/2011



Prof. Dr. Necmettin MARAŞLI

Enstitü Müdürü

## TEŞEKKÜR

Başta, bugünlere gelmemde büyük emekleri olan ve tüm öğrenim hayatım boyunca maddi ve manevi desteği gördüğüm anneme ve babama; yapıcı eleştirileri ile çalışmalarına olan katkılarından dolayı tez izleme komitemde yer alan Prof. Dr. Kerim GÜNEY ve Prof. Dr. Celal YILDIZ' a; bu tezin hazırlanmasında ve yaptığım çalışmalarında büyük teşvikini ve yardımlarını gördüğüm danışmanım **Prof. Dr. Necmi TAŞPINAR'a ;**

Teşekkür ederim.

**Muhammet Nuri SEYMAN**

# ÇOK GİRİŞLİ-ÇOK ÇIKIŞLI DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA SİSTEMLERİNDE YAPAY ZEKA TEKNİKLERİ İLE KANAL KESTİRİMİ

**Muhammet Nuri SEYMAN**

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü**

**Doktora Tezi, Haziran 2011**

**Tez Danışmanı: Prof. Dr. Necmi TAŞPINAR**

## ÖZET

Çok girişli ve çok çıkışlı anten sistemi ile birleştirilmiş dikgen frekans bölmeli çoğullama (MIMO-OFDM), herhangi bir ilave güç ve band genişliği tüketimine ihtiyaç duymaksızın, yüksek hızlarda veri iletimini ve servis kalitesini sağlayan çok taşıyıcılı bir modülasyon tekniğidir. Ancak MIMO-OFDM sistemlerinde evre uyumlu demodülasyon ve veri tespiti için alıcı tarafta kanal dürtü cevabı gereklidir. Kanal dürtü cevabını kestirmek için kör ve pilot ton tabanlı kanal kestirimciler kullanılır. Kör kanal kestirim tekniği herhangi bir veri eklemesi yapılmadan kanalın istatistiksel verilerini kullanarak kanalı kestirir; ancak zaman değişimli ve sönümlenmeli kanallardaki performansı düşüktür. Pilot ton tabanlı kanal kestiriminde sisteme sonradan eklenen pilot tonlar kullanılarak kestirim yapılır. Bu kestirim tekniği kör kanal kestirimi ile kıyaslandığında sönümlenmeli kanallarda daha iyi performansa sahiptir. Pilot ton tabanlı kanal kestiriminde en küçük kareler (LS), en küçük ortalama kareler (LMS) ya da en küçük ortalama karesel hata (MMSE) gibi algoritmalar kullanılır. LS ve LMS algoritmalarının uygulaması basit olmasına rağmen zaman değişimli kanallardaki performansları düşüktür. MMSE algoritması sönümlenme etkilerine karşı dayanıklıdır; ancak matris tersinin alınması, korelasyon hesaplaması ve kanal gürültüsünün istatistiksel verilerine ihtiyaç duyması nedeniyle karmaşık bir algoritmadır.

Bu tezde çok katmanlı yapay sinir ağları, radyal tabanlı sinir ağı ve uyarlanabilir bulanık sinir ağları gibi yapay zeka yöntemlerinin öğrenme kabiliyetlerinden faydalanarak MIMO-OFDM sistemlerinde kanal kestirimi yapılmış ve yukarıda bahsedilen klasik algoritmaların dezavantajları ortadan kaldırılmıştır.



Ayrıca pilot ton tabanlı kanal kestirimde kullanılan pilot tonların nasıl tasarlandığının kestirimci performansında önemli bir etkiye sahip olmasından dolayı genetik algoritma, parçacık sürü optimizasyonu, farksal gelişim algoritması ve yapay arı kolonisi algoritması gibi yapay zeka optimizasyon algoritmaları kullanarak pilot tonların yerleri ve güçleri optimize edilmiş ve bu sayede LS kanal kestirim algoritmasının performansı artırılmıştır.

**Anahtar Sözcükler:** MIMO-OFDM, kanal kestirimi, MLP yapay sinir ağı, RBF sinir ağı, ANFIS, yapay zeka optimizasyon algoritmaları.

**CHANNEL ESTIMATION IN MULTIPLE INPUT-MULTIPLE OUTPUT  
ORTHOGONAL FREQUENCY DIVISION MULTIPLEXING SYSTEMS BY  
ARTIFICIAL INTELLIGENCE TECHNIQUES**

**Muhammet Nuri SEYMAN**

**Erciyes University, Graduate School of Natural and Applied Sciences**

**Ph. D. Thesis, June 2011**

**Thesis Supervisor: Prof. Dr. Necmi TAŞPINAR**

**ABSTRACT**

Orthogonal frequency division multiplexing combined with multi input-multi output antenna system, which provides high data rate transmission and quality of service, is a multicarrier modulation technique without additional power and bandwidth consumption. However, at the receiver side channel impulse responses are necessary for coherent demodulation and data detection in MIMO-OFDM systems. In order to estimate the channels, blind and pilot based channel estimators are used. Blind channel estimation technique estimates the channels using channel statistics without any additional data; but its performance is low over time varying and fading channels. In pilot based channel estimation, channel is estimated by using data that is inserted to the system. When this technique is compared with the blind channel estimation, it has better performance in fading channels. In pilot based channel estimation, least square (LS), least mean square (LMS) or minimum mean square error (MMSE) algorithms are used. Although implementations of LS and LMS algorithms are easy, their performances are low in time varying channels. MMSE algorithm is robust against to the fading affects; however, it is a complex algorithm because it needs matrix inversion, correlation computation and statistical information of the channel noise.

In this thesis, channel estimation is achieved in MIMO-OFDM systems by utilizing the learning ability of artificial intelligence methods such as multi layered perceptron artificial neural network, radial basis function neural network and adaptive neuro-fuzzy inference system and the disadvantages of the classical algorithms that are mentioned above are eliminated. Besides, since how to design the pilot tones that are used in pilot based channel estimation has a significant effect on the estimation performance, the

placement and power of pilot tones are optimized using the artificial intelligence optimization algorithms such as genetic algorithm, particle swarm optimization, differential evolution algorithm and artificial bee colony algorithm. So that the performance of LS channel estimation algorithm is improved.

**Keywords:** MIMO-OFDM, channel estimation, MLP neural network, RBF network, ANFIS, artificial intelligence optimization algorithms.

## İÇİNDEKİLER

BİLİMSEL ETİĞE UYGUNLUK SAYFASI.....	ii
YÖNERGEYE UYGUNLUK SAYFASI.....	iii
KABUL VE ONAY SAYFASI.....	iv
ÖNSÖZ.....	v
ÖZET.....	vi
ABSTRACT.....	viii
İÇİNDEKİLER.....	x
TABLolar LİSTESİ.....	xvi
ŞEKİLLER LİSTESİ.....	xvii
<b>GİRİŞ .....</b>	<b>1</b>
Tezin Literatürdeki yeri.....	1
Tezin Amacı ve Önemi .....	4
<b>1. BÖLÜM.....</b>	<b>7</b>
<b>ÇOK GİRİŞLİ ÇOK ÇIKIŞLI DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA (MIMO-OFDM)</b>	
1.1. Gezgin Radyo Kanal Karakteristikleri.....	7
1.1.1. Zayıflama .....	7
1.1.2. Gölgeleme .....	8
1.1.3. Kırılma .....	8
1.1.4. Doppler Kayması .....	8
1.1.5. Gecikme Yayılımı .....	8
1.1.6. Çok Yollu Sönümlenme.....	9
1.1.7. Çok Yollu Sönümlenme Etkileri.....	10
1.1.7.1. Düz Sönümlenme .....	10
1.1.7.2. Frekans Seçici Sönümlenme .....	11
1.1.8. Doppler Yayılımı Sonucu Oluşan Sönümlenmeler.....	11
1.1.8.1. Hızlı Sönümlenme.....	11
1.1.8.2. Yavaş Sönümlenme.....	12

1.2. İletim Çeşitlemesi .....	12
1.2.1. Frekans Çeşitlemesi .....	13
1.2.2. Zaman Çeşitlemesi .....	13
1.2.3. Uzay Çeşitlemesi (Anten Çeşitlemesi).....	13
1.3. Dikgen Frekans Bölmeli Çoğullama (OFDM).....	13
1.3.1. OFDM Sistemlerinde Dikgenlik .....	14
1.3.2. OFDM Sinyallerinin Üretilmesi.....	15
1.3.3. OFDM’ de IFFT Kullanarak Alt Taşıyıcıların Üretilmesi.....	15
1.3.4. OFDM Sinyaline Koruma Aralığının Eklenmesi.....	17
1.4. MIMO-OFDM Sistem Modeli .....	18
1.5. MIMO-OFDM Kanal Kestirimi .....	21
1.5.1. Kör Kanal Kestirimi .....	22
1.5.2. Pilot Ton Eklemeli Kanal Kestirim Yöntemleri .....	23
1.5.2.1. Blok Tip Pilot Ton Yerleşimi.....	23
1.5.2.2. Tarak Tip Pilot Ton Yerleşimi .....	24
1.5.2.2.1. Doğrusal Ara Değerleme.....	24
1.5.2.2.2. İkinci Dereceden Ara Değerleme.....	24
1.5.2.2.3. Alçak Geçiren Ara Değerleme.....	25
1.5.2.2.4. Parçalı Kübik Ara Değerleme .....	25
1.5.2.2.5. Zaman Domeni Ara Değerleme .....	25
1.5.3. Kanal Kestirim Algoritmaları .....	26
1.5.3.1. LS Algoritması .....	26
1.5.3.2. MMSE Algoritması.....	27
1.5.3.3. LMS Algoritması .....	27
<b>2. BÖLÜM.....</b>	<b>29</b>
<b>YAPAY ZEKÂ YÖNTEMLERİ</b>	
2.1. Yapay Sinir Ağları .....	29
2.1.1. Aktivasyon Fonksiyonları .....	30
2.1.1.1. Eşik aktivasyon fonksiyonu .....	30
2.1.1.2. Doğrusal Aktivasyon Fonksiyonu.....	31
2.1.1.3. Sigmoid Aktivasyon Fonksiyonu.....	31
2.1.1.4. Tanjant Hiperbolik Aktivasyon Fonksiyonu.....	32

2.1.2. Yapay Sinir Ağlarının Eğitilmesi.....	33
2.1.3. Yapay Sinir Ağlarında Öğrenme Algoritmaları.....	33
2.1.3.1. Geri Yayınım Algoritması.....	34
2.1.3.2. Levenberg- Marquardt Algoritması .....	37
2.1.4. Yapay Sinir Ağı Yapıları .....	40
2.1.4.1. Çok Katmanlı Perceptron (MLP) Ağı.....	40
2.1.4.2. Radyal Tabanlı (RBF) Sinir Ağları.....	41
2.1.4.3. RBF Ağlarının MLP Ağlarına Göre Üstünlükleri.....	43
2.1.4.4. RBF Ağlarının MLP Ağlarına göre Dezavantajları .....	43
2.2. Uyarlanabilir Yapay Sinir Ağı Bulanık Mantık Sistemi (ANFIS).....	43
<b>3. BÖLÜM.....</b>	<b>47</b>
<b>YAPAY ZEKÂ OPTİMİZASYON ALGORİTMALARI</b>	
3.1. Genetik Algoritma (GA) .....	47
3.1.1. Genetik Operatörler.....	49
3.1.1.1. Tekrar Üreme Operatörü.....	49
3.1.1.2. Çaprazlama Operatörü .....	50
3.1.1.3. Mutasyon Operatörü.....	51
3.2. Parçacık Sürü Optimizasyonu (PSO) .....	51
3.2.1. PSO Parametre Seçimi .....	53
3.2.1.1. Parçacık sayısı.....	53
3.2.1.2. Parçacık aralığı.....	53
3.2.1.3. Maksimum Hız (Vmax) .....	54
3.2.1.4. Öğrenme Faktörleri .....	54
3.2.1.5. Durma Kriteri.....	54
3.2.1.6. Atalet Katsayısı (inertia factor).....	54
3.3. Farksal Gelişim (DE) Algoritması .....	54
3.3.1. Mutasyon.....	56
3.3.2. Yeniden Üretim.....	56
3.3.3. Seçme .....	56
3.4. Yapay Arı Koloni (ABC)Algoritması .....	57
3.5. Yapay Zeka Optimizasyon Algoritmaları İçin Uygunluk Fonksiyonu.....	60
<b>4. BÖLÜM.....</b>	<b>61</b>

## SİMULASYON ÇALIŞMALARI

4.1. Giriş.....	61
4.2. Yapay Zeka Yöntemleri İçin MIMO-OFDM Sistem Parametreleri .....	61
4.2.1. MLP Sinir Ağları Kullanarak Kanal Kestirimi .....	62
4.2.2. RBF Sinir Ağları Kullanarak Kanal Kestirimi.....	68
4.2.3. ANFIS Kullanarak Kanal Kestirimi.....	73
4.2.4. Kanal Kestiriminde Yapay Zeka Yöntemlerinin Performanslarının Kıyaslanması.....	77
4.3. Yapay Zeka Optimizasyon Algoritmaları İçin MIMO-OFDM Parametreleri .....	82
4.3.1. Genetik Algoritma Kullanarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi.....	83
4.3.2. Parçacık Sürü Optimizasyonu Kullanılarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi .....	87
4.3.3. Farksal Gelişim Algoritması Kullanılarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi .....	90
4.3.4. Yapay Arı Koloni Algoritması Kullanılarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi .....	94
4.3.5. Pilot Tonların Yerlerinin ve Güçlerinin Optimizasyonu için Yapay Zeka Optimizasyon Algoritmaları Performanslarının Kıyaslanması.....	97
<b>SONUÇ VE ÖNERİLER.....</b>	<b>100</b>
<b>KAYNAKÇA .....</b>	<b>103</b>
<b>ÖZGEÇMİŞ.....</b>	<b>115</b>

## KISALTMALAR

OFDM	(Orthogonal Frequency Division Multiplexing) → Dikgen Frekans Bölmeli Çoğullama
MIMO	(Multi Input Multi Output) → Çoklu Giriş Çoklu Çıkış
SISO	(Single Input Single Output) → Tekli Giriş Tekli Çıkış
ISI	(Inter Symbol Interference) → Semboller Arası Girişim
DVB-T	(Digital Video Broadcasting-Terrestrial) → Sayısal Karasal Video Yayıncılığı
DAB	(Digital Audio Broadcasting) → Sayısal Ses Yayıncılığı
WLAN	(Wireless Local Area Network) → Kablosuz Yerel Alan Ağları
CIR	(Channel Impulse Response) → Kanal Dürtü Cevabı
ICI	(Inter Carriers Interference) → Taşıyıcılar Arası Girişim
LS	(Least Squares) → En Küçük Kareler
LMS	(Least Mean Squares) → En Küçük Ortalama Kareler
MMSE	(Minimum Mean Square Error) → Minimum Ortalamalı Karesel Hata
MLP	(Multi Layered Perceptron) → Çok Katmanlı Perseptron
YSA	Yapay Sinir Ağı
RBFNN	(Radial Basis Function Neural Network) → Radyal Tabanlı Fonksiyon Sinir Ağı
IFFT	(Inverse Fast Fourier Transform) → Ters Hızlı Fourier Dönüşümü
CP	(Cyclic Prefix) → Periyodik Ön Ek
DFT	(Discrete Fourier Transform) → Ayrık Fourier Dönüşümü
LI	(Lineer Interpolation) → Lineer Ara Değerleme
SOI	(Second Order Interpolation) → İkinci Dereceden Ara Değerleme
LPI	(Low Pass Interpolation) → Alçak Geçiren Ara Değerleme
SCI	(Spline Cubic Interpolation) → Parçalı Kübik Ara Değerleme
TDI	(Time Domain Interpolation) → Zaman Domeni Ara Değerleme
BP	(Back Propagation) → Geri Yayılım
LM	(Levenberg-Marquardt)
ANFIS	(Adaptive Neuro Fuzzy Inference System) → Uyarlanabilir Bulanık Sinir



## Ağları

GA	(Genetic Algorithm) → Genetik Algoritma
PSO	(Particle Swarm Optimization) → Parçacık Sürü Optimizasyonu
DE	(Differential Evolution Algorithm) → Farksal Gelişim Algoritması
ABC	(Artificial Bee Colony Algorithm) → Yapay Arı Koloni Algoritması
SGO	Sinyal Gürültü Oranı
BHO	Bit Hata Oranı
OKH	Ortalama Karesel Hata
AWGN	(Additive White Gaussian Noise) → Toplamsal Beyaz Gauss Gürültüsü

**TABLULAR LİSTESİ**

No		Sayfa
Tablo 4.1	Yapay zeka yöntemlerinin değerlendirilmesi için MIMO-OFDM sistem parametreleri.	61
Tablo 4.2	Yapay zeka optimizasyon algoritmalarının değerlendirilmesi için MIMO-OFDM sistem parametreleri.	77

## ŞEKİLLER LİSTESİ

No		Sayfa
Şekil 1.1	Radyo yayılım etkileri	7
Şekil 1.2	Gecikme yayımlı sinyal	9
Şekil 1.3	Çoklu yol etkisi	10
Şekil 1.4	Dikgen alt taşıyıcı yerleşimi.	14
Şekil 1.5	Bir OFDM işaretindeki dört alt taşıyıcı örneği	16
Şekil 1.6	Periyodik ön ek ekleme işlemi	17
Şekil 1.7	MIMO-OFDM sistem modeli	18
Şekil 1.8	Pilot ton yerleşimi	23
Şekil 2.1	Temel yapay sinir ağı hücresi	30
Şekil 2.2	Eşik aktivasyon fonksiyonu	31
Şekil 2.3	Doğrusal aktivasyon fonksiyonu	31
Şekil 2.4	Logaritmik sigmoid aktivasyon fonksiyonu	32
Şekil 2.5	Tanjant hiperbolik fonksiyonu	32
Şekil 2.6	Çok katmanlı yapay sinir ağı modeli	35
Şekil 2.7	Geri yayımlı MLP yapısı	41
Şekil 2.8	Radyal tabanlı sinir ağı yapısı	42
Şekil 2.9	ANFIS yapısı	44
Şekil 3.1	Genetik algoritma akış diagramı	48
Şekil 3.2	Çaprazlama işlemi	50
Şekil 3.3	Mutasyon işlemi	51
Şekil 3.4	Parçacık sürü optimizasyonu akış diagramı	52
Şekil 3.5	Farksal gelişim algoritması işlem adımları	55
Şekil 3.6	ABC algoritması işlem adımları	58
Şekil 4.1	MLP sinir ağı kanal kestirimci yapısı	62
Şekil 4.2	2x2-MIMO-OFDM’de MLP-YSA kanal kestiriminin BHO performansı	64
Şekil 4.3	2x2-MIMO-OFDM’de MLP-YSA kanal kestiriminin OKH performansı	65
Şekil 4.4	4x4-MIMO-OFDM’de MLP-YSA kanal kestiriminin BHO performansı	65

Şekil 4.5	4x4-MIMO-OFDM’de MLP-YSA kanal kestiriminin OKH performansı	66
Şekil 4.6	8x8-MIMO-OFDM’de MLP-YSA kanal kestiriminin BHO performansı	67
Şekil 4.7	8x8-MIMO-OFDM’de MLP-YSA kanal kestiriminin OKH performansı	67
Şekil 4.8	Radyal tabanlı yapay sinir ağı kanal kestirimci modeli	68
Şekil 4.9	2x2-MIMO-OFDM’de RBF-YSA kanal kestiriminin BHO performansı	69
Şekil 4.10	2x2-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı	70
Şekil 4.11	4x4-MIMO-OFDM’de RBF-YSA kanal kestiriminin BHO performansı	71
Şekil 4.12	4x4-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı	71
Şekil 4.13	8x8-MIMO-OFDM’de RBF-YSA kanal kestiriminin BHO performansı	72
Şekil 4.14	8x8-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı	72
Şekil 4.15	ANFIS kanal kestirimci modeli	73
Şekil 4.16	2x2-MIMO-OFDM’de ANFIS kanal kestirimi BHO performansı	74
Şekil 4.17	2x2-MIMO-OFDM’de ANFIS kanal kestirimi OKH performansı	74
Şekil 4.18	4x4-MIMO-OFDM’de ANFIS kanal kestirimi BHO performansı	75
Şekil 4.19	4x4-MIMO-OFDM’de ANFIS kanal kestirimi OKH performansı	76
Şekil 4.20	8x8-MIMO-OFDM’de ANFIS kanal kestirimi BHO performansı	76
Şekil 4.21	8x8-MIMO-OFDM’de ANFIS kanal kestirimi OKH performansı	77
Şekil 4.22	2x2 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları	78
Şekil 4.23	2x2 MIMO-OFDM’de yapay zeka yöntemlerinin OKH performansları	78
Şekil 4.24	4x4 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları	79
Şekil 4.25	4x4 MIMO-OFDM’de yapay zeka yöntemlerinin OKH	80

	performansları	
Şekil 4.26	8x8 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları	80
Şekil 4.27	8x8 MIMO-OFDM’de yapay zeka yöntemlerinin OKH performansları	81
Şekil 4.28	20 dB SGO için yapay zeka yöntemlerinin anten sayılarına göre OKH performansları	82
Şekil 4.29	GA ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı	84
Şekil 4.30	GA ile Optimize edilmiş Pilot Tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı	85
Şekil 4.31	GA ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı	86
Şekil 4.32	GA ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı	86
Şekil 4.33	PSO ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı	88
Şekil 4.34	PSO ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı	89
Şekil 4.35	PSO ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı	89
Şekil 4.36	PSO ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı	90
Şekil 4.37	DE ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı	92
Şekil 4.38	DE ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı	92
Şekil 4.39	DE ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı	93
Şekil 4.40	DE ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı	93
Şekil 4.41	ABC ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı	95

Şekil 4.42	ABC ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı	95
Şekil 4.43	ABC ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı	96
Şekil 4.44	ABC ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı	96
Şekil 4.45	Yapay zeka optimizasyon algoritmalarının 5 Hz Doppler kaymalı kanaldaki BHO performansları	97
Şekil 4.46	Yapay zeka optimizasyon algoritmalarının 5 Hz Doppler kaymalı kanaldaki OKH performansları	98
Şekil 4.47	Yapay zeka optimizasyon algoritmalarının 40 Hz Doppler kaymalı kanaldaki BHO performansları	99
Şekil 4.48	Yapay zeka optimizasyon algoritmalarının 40 Hz Doppler kaymalı kanaldaki OKH performansları	99

## GİRİŞ

### Tezin Literatürdeki yeri

Son yıllarda gerek ses ve görüntü iletimi gerekse yüksek hızlı internet uygulamalarında olduğu gibi büyük band genişliği gerektiren uygulamalarda, yüksek veri hızlarında iletme ihtiyaç duyulmaktadır. Ayrıca yüksek hızlarda veri iletiminin yapılmasına olanak sağlayan kablosuz iletişimin sabit iletişim ağlarından fiziksel olarak bağımsız olması, kablolu hatların kurulumu ve bakımındaki zorluklardan dolayı yüksek hızlarda veri iletimini sağlamak için kablosuz iletişime talep giderek artmaktadır [1-5].

Geniş bantlı kablosuz iletişimde iletişimin hızlanması yeni nesil iletişim sistemlerinin ana hedefini oluşturmaktadır. Hem yüksek hızlı iletme cevap vermesi hem de iletim hattını verimli bir şekilde kullanarak hatta meydana gelebilecek girişimlere ve çoklu yol kayıplarına karşı olan verimliliğinden dolayı dikgen frekans bölmeli çoğullama (OFDM) tekniği yaygın olarak kullanılmaktadır. OFDM tekniği, yüksek bit hızlı bir veri akışını birkaç adet paralel düşük bit hızlı veri akışına bölen ve bu düşük bit hızlı veri akışlarını birkaç taşıyıcıyı modüle etmek için kullanan bir veri iletim tekniğidir [2-17]. OFDM kullanılarak toplam band genişliği dar bantlı alt kanallara bölünmekte ve çoklu yol yayılımları yüzünden meydana gelebilecek gecikme yayılımları minimize edilmektedir. Bu sayede daha az maliyetle frekans seçimli kanallarda yüksek veri hızlı iletim sağlanır [2-5]. OFDM sistemleri, kablosuz ortamlarda genellikle frekans seçimli çoklu yol tarafından oluşturulan semboller arası girişim (ISI) problemine karşı da kullanılan bir tekniktir. OFDM'de her bir alt taşıyıcı sembolü, kanal dürtü cevabından daha uzun oluşturularak düşük veri hızlarında modüle edilir. Bu yolla ISI azaltılabilir [4,5].

Gezgin iletişim sistemlerinde çok yollu sönümlenme kanallarının etkisi istenilen düzeyde iletişimin sağlanmasını zorlaştırmaktadır. Verici ile alıcı arasında kurulan kanal, bu iki birim arasındaki engellerin (yüksek binalar, dağlar, v.s.) etkisi ve gezgin birimin hareketi sonucu sürekli değişmeye uğramaktadır. Kanalin dürtü cevabının zamanla değişmesi alıcıda elde edilen işaretin aşırı sönümlenmesine neden olabilmektedir [1]. Sönümlenme etkilerine karşı koyma yöntemlerinden biri; çok antenli, bir başka deyişle çok girişli çok çıkışlı (multiple input multiple output, MIMO) sistemler kullanmaktır [18-20]. Bu sistemlerde birden fazla verici ve alıcı anten kullanılır. MIMO sistemler tek giriş ve tek çıkışlı (SISO) sistemlere göre sönümlenmeye karşı daha fazla dayanıklı olmalarından dolayı son yıllarda yüksek hızlarda veri iletimine izin veren OFDM sistemleriyle birleştirilmektedir. Bu sayede bir MIMO-OFDM sisteminde sönümlenmenin meydana getirebileceği veri kayıpları en aza indirilerek daha az kayıplı ve kazancı yüksek veri iletimleri gerçekleştirilmektedir [18-20]. Ayrıca uzay zaman kodları kullanılarak yapılan kodlama ile MIMO-OFDM sisteminin veri iletim başarımı daha da artacak ve kanalda meydana gelebilecek veri kayıpları kodlamasız sisteme göre daha da azalacaktır [21-25]. MIMO-OFDM sistemi sahip olduğu avantajlar nedeniyle günümüzde DVB-T, DAB, WLAN gibi birçok haberleşme sisteminde modülasyon tipi olarak kullanılmaktadır [26-29].

Fakat MIMO-OFDM sisteminin çok taşıyıcılı olması ve iletimin farklı kanallardan yapılması nedeniyle iletilen verilerin doğru alınması ancak alıcı tarafta kanal dürtü cevabının (CIR) doğru bir şekilde tespit edilmesine yani kestirilmesine bağlıdır [30-60]. CIR'ın alıcı tarafta tam olarak tespit edilememesi durumunda kanallar arası girişim (ICI) meydana gelecek ve iletilen verilerin doğru alınması mümkün olmayacaktır [30-45]. Genel olarak CIR'ı kestirmek için kör (blind) kanal kestirimi ve yapısı alıcı tarafından bilinen pilot ton eklemeli kestirim olmak üzere iki farklı kestirim yöntemi kullanılmaktadır [30-45]. Kör kanal kestirim yönteminde herhangi bir veri eklemeksizin kanal kestirimi yapılır. Ancak bu kestirim yönteminin performansının sönümlenme etkisinin fazla olduğu ortamlarda yetersiz kalmasından dolayı veri hızının yüksek olduğu sistemlerde tercih edilmemektedir [30-32]. Pilot ton eklemeli kanal kestiriminin performansı kör kanal kestirimine göre daha iyidir. Bu yüzden kablosuz ağlar (WLAN) ve karasal-sayısal video yayıncılığı (DVB-T) gibi veri iletiminin hızlı olmasının istendiği sistemlerde pilot ton eklemeli kanal kestirimi kullanılır [26-29]. Veri eklemeli



kanal kestirim yönteminde en küçük kareler (least squares: LS), en küçük ortalama kareler ( least mean squares: LMS) ve minimum ortalamalı karesel hata (minimum mean square error: MMSE) gibi algoritmalar kullanılmaktadır [33-45]. Bu algoritmalarından LS algoritması matematiksel olarak kolay olmasına rağmen performansı düşük bir algoritmadır [34-37]. LMS algoritmasının ise basit bir kullanımı olmasına rağmen denkleştirme olması durumunda ters katlama problemi nedeniyle bu algoritmanın öğrenme başarımı ve hızı oldukça zayıftır. LMS algoritmasında kullanılan adım büyüklüğü parametresi sabit olup küçük değerli olduğunda algoritma kararlı duruma daha yavaş ulaşırken büyük olduğunda ise kararsızlığa neden olur. Bununla birlikte sabit adım büyüklüğü zamanla değişen kanallarda zayıf başarımla sonuçlanmaktadır. Bu nedenle her adımda hata değişimi dikkate alınarak adım büyüklüğünün sürekli değiştirilmesi gerekmektedir [41]. MMSE algoritması ise en iyi performans gösteren klasik kanal kestirim algoritmalarından biri olmasına rağmen kanalın istatistiksel verilerini kullanarak kestirim yapması nedeniyle karmaşık ve uygulaması zor bir algoritmadır [34,35].

Klasik yöntemlerin yanında, literatürde yapay zeka teknikleri kullanılarak elde edilmiş çalışmalar da bulunmaktadır [70-85]. Literatürdeki mevcut çalışmalardan [78] ‘deki çalışmada MIMO OFDM sistemi için Tagaki-Sugeno-Kang tipi bulanık mantık kullanılarak kanal kestirimi yapılmıştır. [79]’da en büyük olabilirlikli ortak kanal ve veri kestirimine dayanarak kör (blind) dengeleme yöntemi geliştirilmiştir. Bu yöntemdeki ortak en büyük olabilirlik optimizasyonu iki seviyeli bir optimizasyon döngüsüne ayrılmaktadır. Bilinmeyen kanal modelini tanımlamak için üst seviyede bir mikro genetik algoritma uygulanırken iletilen veri dizisinin en büyük olasılıklı dizi kestirimini sağlamak amacıyla alt seviyede ise Viterbi algoritması kullanılmaktadır. Elde edilen sonuçlar, Genetik Algoritma temelli yöntemin ortak kanal ve veri kestirimi için mevcut olan yöntemlerden çok daha üstün bir performans sağladığını göstermektedir. Gezgin haberleşmedeki kör kanal ve sembol kestirim problemi için yapay sinir ağlarının kullanıldığı bir yaklaşım [80]’de önerilmektedir. Kullanılan yöntem, kanal ve sembollerini tanımlamak amacıyla aşırı örneklenen ve çoklu antenleri kullanan deterministik kör kestirim metotlarına dayanmaktadır. Bu deterministik yaklaşımlar da en küçük karesel hata ölçevini uygulamakta ve ardından problemi cebirsel olarak çözmektedir. Yapılan çalışmada karesel maliyet fonksiyonunun YSA

enerji fonksiyonuna eşlenmesiyle kestirim problemi YSA kullanılarak çözülmektedir [80]. [81]'de kanal kestirimi için çok katmanlı yapay sinir ağları kullanılırken [82-84]'deki çalışmalarda ise yapay sinir ağlarının bir türü olan radyal tabanlı sinir ağları kullanılarak kanal kestirimi yapılmaktadır. OFDM sistemlerinde uyarlanabilir bulanık sinir ağlarının öğrenme kabiliyeti kullanılarak yapılan kanal kestirimi de [70]'te yer almaktadır.

Ayrıca literatürde, kanal kestiriminde kullanılan pilot tonların optimum bir şekilde yerleştirilmesi ile kestirimci algoritmasının performansının artırıldığı çeşitli çalışmalar da bulunmaktadır. Bu çalışmalardan [48]'de Cramer-Rao sınırı, [46,47]'lerde ortalama karesel hata değeri minimize edilerek optimum pilot ton yerleşimleri bulunurken [53]'te ise kapasite maksimizasyonu ile optimum pilot ton tasarımı yapılmıştır. [59]'daki çalışmada parçacık sürü optimizasyonu (PSO) kullanılarak güç hatları haberleşmesinde kör kanal kestirimi yapılmıştır. [60] no.lu çalışmada OFDM sisteminde genetik algoritma (GA) ve PSO kullanarak MMSE algoritmasının optimal çözüm verdiği durum incelenmiştir.

### **Tezin Amacı ve Önemi**

Kablosuz haberleşme sistemlerinde genellikle alıcı ve verici antenin birbirini direkt olarak görmesi mümkün olmaz. Bu durumda iletilen sinyal birçok yoldan gelerek alıcıya ulaşır. Çoklu yoldan alıcıya gelen sinyalin rasgele genlik, faz ve geliş açılarına sahip kopyaları oluşur. Bundan dolayı çoklu yoldan gelen sinyallerin alıcıdaki toplamı, alınan sinyalin gücünde sönümlenme olarak adlandırılan dalgalanmalara sebep olur. Sönümlenme etkilerini azaltmanın en iyi yöntemlerinden biri; anten çeşitlemesi olarak bilinen MIMO sistemler kullanmaktır. MIMO sistemler ile birleştirilerek elde edilen MIMO-OFDM sistemleri ile kablosuz iletim ortamında meydana gelebilecek sönümlenme etkileri azaltılarak tek girişli tek çıkışlı OFDM sistemine göre yüksek hızlı ve kaliteli veri iletişimi gerçekleştirilir [18-20]. Ayrıca uzay-zaman kodları kullanılarak sistemin performansını artırılabilir [21-25].

Ancak yüksek hızlı ve geniş bantlı radyo kanallarının frekans seçimli ve zamana bağımlı olması nedeniyle MIMO-OFDM sinyallerinin evre uyumlu demodülasyonu için

önce kanal dürtü cevabı (CIR)'nı kestirmek gerekmektedir. Bu yüzden kanal kestirim işlemi MIMO-OFDM sistemleri için önem arz etmektedir [33-60].

Literatürde OFDM sistemlerinde kanal kestiriminin yapılması amacıyla klasik yöntemlerin (kör kanal kestirimi, LS, LMS ve MMSE gibi), kullanıldığı birçok çalışma mevcut olmasına rağmen bu doktora tez çalışmasının amacı; sistem performansını artırmak için MIMO OFDM sisteminde yapay zeka tekniklerinden faydalanarak kanal kestirimi yapmaktır. Bu sayede literatürde yer alan mevcut klasik teknikler ile yapılmış olan kanal kestirim işlemlerinin sahip olduğu dezavantajların en asgari düzeye indirilmesi sağlanacaktır. Yapay zeka tekniklerinin en büyük avantajlarından birisi, modellenmek istenilen sistemin matematiksel modelinin analitik olarak ifade edilmesinin gerekmemesidir. Giriş ve çıkış arasındaki ilişkiyi karakterize eden veri kümelerinin bulunması, sistemi modellemek için yeterlidir. Yapay zeka teknikleri kullanılarak elde edilen değerler, bu teknikleri kullanarak kanal kestiriminin yapılmasının iyi sonuçlar vereceğini göstermektedir. Bu tezde öncelikle yapay zeka yöntemlerinden çok katmanlı yapay sinir ağları, radyal tabanlı sinir ağları ve uyarlanabilir bulanık sinir ağlarının öğrenme özellikleri kullanılarak MIMO-OFDM sistemlerinde kanal kestirimi yapılmış ve ayrıca doğada bulunan çeşitli canlıların özelliklerinden ve davranışlarından esinlenerek ortaya çıkarılmış genetik algoritma, parçacık sürü optimizasyonu, farksal gelişim algoritması ve yapay arı koloni algoritması gibi yapay zeka optimizasyon algoritmaları kullanılarak pilot tonların yerleşim yerleri ve güçleri optimize edilmiş ve bu sayede LS kanal kestirim algoritmasının performansı artırılmıştır.

Tezin ikinci bölümünde, gezgin radyo karakteristikleri, dikgen frekans bölmeli çoğullama tekniği, çok girişli çok çıkışlı OFDM sistemleri ve bu sistemlerde kullanılan kanal kestirim yöntemlerinden bahsedilmiştir.

Üçüncü bölümde, yapay zeka yöntemlerinden olan çok katmanlı yapay sinir ağları, radyal tabanlı sinir ağları ve uyarlanabilir sinir ağları açıklanmıştır.

Dördüncü bölümde, yapay zeka optimizasyon algoritmalarından genetik algoritma, parçacık sürü optimizasyonu, farksal gelişim algoritması ve yapay arı koloni algoritması ayrıntılı bir biçimde açıklanmıştır.

Beşinci bölümde yapay zeka yöntemleri ve yapay zeka optimizasyon algoritmalar ile elde edilen simülasyon sonuçları verilmiştir.

Altıncı ve son bölümde ise elde edilen simülasyon sonuçlarına göre değerlendirmeler yapılmış ve daha sonra yapılacak çalışmalar için önerilerde bulunulmuştur.

## 1. BÖLÜM


### ÇOK GİRİŞLİ-ÇOK ÇIKIŞLI DİKGEN FREKANS BÖLMELİ ÇOĞULLAMA (MIMO-OFDM)

#### 1.1. Gezgin Radyo Kanal Karakteristikleri

Gerçek zamanlı haberleşme sistemlerinde alınan sinyal; zayıflamış, yansıtılmış veya kırılmış bileşenlerden oluşmaktadır. Ayrıca kanalda bulunan gürültü, alıcı ya da vericinin hareketinden dolayı meydana gelecek taşıyıcı frekans kaymaları (Doppler kayması) ve çok yollu sönmüleme etkisi de sistem performansını olumsuz etkileyecektir. Bu yüzden haberleşme sisteminin performansı doğrudan radyo kanal karakteristiklerine bağlıdır [1]. Radyo kanal karakteristiklerini etkileyen bazı faktörler aşağıda yer almaktadır.

##### 1.1.1. Zayıflama

Zayıflama, bir noktadan diğerine iletim esnasında çeşitli sebeplerden dolayı sinyal gücündeki düşmedir. Bu olay; yol uzunluğu, sinyal yolunda tıkanma ve çoklu yol etkileri tarafından meydana getirilebilir. Vericiden alıcıya kadarki yol içerisinde görülen sinyal hattını tıkayan herhangi bir obje, zayıflamaya neden olabilir. Şekil 1.1’de bazı radyo yayılım etkileri yer almaktadır.[1]



Şekil 1.1. Radyo yayılım etkileri.

### 1.1.2. Gölgeleme

Sinyal gölgeleme, alıcı ve verici arasında bir tıkanma olur olmaz meydana gelebilir. Genel olarak bu olay binalar, tepeler tarafından oluşturulur ve önemli bir çevresel zayıflama faktörüdür. Gölgeleme, binalardaki gölgelemeler yüzünden yüksek yapılı bölgelerde oluşur. Ama tepelerdeki gölgelemeler iletişim sistemlerindeki sinyaller için büyük problem olabilirler. Gölgeleme probleminin üstesinden gelebilmek ve tıkanma sayısını minimize etmek için verici, mümkün olduğunca yükseğe çıkartılmalıdır [1].

### 1.1.3. Kırılma

Kırılma, sinyalin binalar, araçlar, ya da buna benzer kırıcı etkiler nedeniyle çeşitli parçalara ayrılmasıdır. Kırınım miktarı, yüksek frekanslı sinyalden daha düşük frekans kırınımları kullanılan radyo frekansına bağlıdır [1].

### 1.1.4. Doppler Kayması

Bir dalga kaynağı ya da alıcıdan biri hareket ettirildiği zaman alınan sinyalin frekansı kaynak ile aynı olmayacaktır. Bir sinyal kaynağı hareket ettirildiği zaman alınan sinyal frekansı kaynağinkinden yüksek olacaktır. Eğer biri diğerine yaklaştırılırsa frekans düşecektir. Bu olaya *Doppler Kayması* denilmektedir. Bu etki gezgin radyo sistemleri geliştirilirken önemlilik arzeder.

Frekans miktarı kaynak ve alıcı arasındaki ilişkili harekete ve dalganın yayılım hızına bağlıdır. Doppler etkisi yüzünden meydana gelen frekans değişimi aşağıdaki gibi yazılabilir:

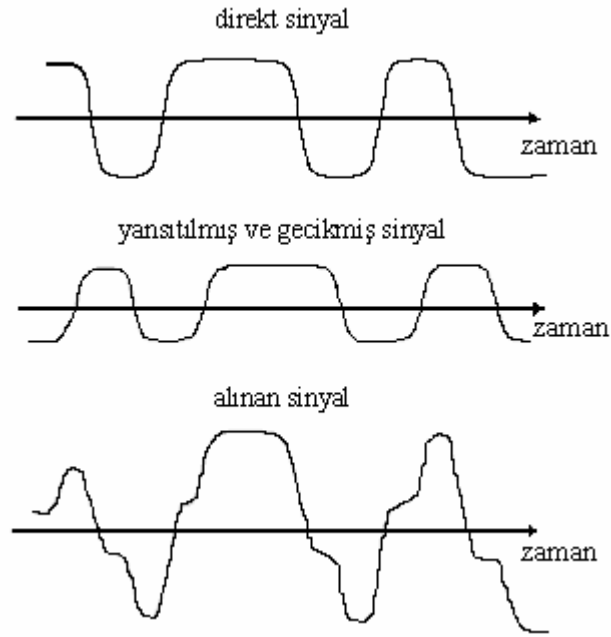
$$\Delta f = \pm f_0 \frac{V}{C_0} \quad (1.1)$$

Burada  $\Delta f$  alıcıda görülen kaynak frekansındaki değişim,  $f_0$  kaynak frekansı,  $V$  alıcı ve verici arasındaki hız farkı,  $C_0$  ise ışık hızıdır [33].

### 1.1.5. Gecikme Yayılımı

Bir vericiden alınan radyo sinyali, tipik olarak direkt sinyal artı binalar, dağlar ve diğer yapılardan yansıyan sinyallerden oluşur. Daha sonra direkt sinyal extra yol uzunluğu


yüzünden farklı ayrılma zamanlarına yükseltilir ve zaman içerisinde alınan enerji yayılır. Sayısal bir sistemde gecikme yayılımı semboller arası girişime sebep olur. Bu durum, çoklu yol sinyalleri ile bunları takip eden sembollerin üst üste binmeleri yüzündendir. Bu olay yüksek bit hızlı sistemlerde dikkate değer hatalara sebep olur. Gecikme yayımlı sinyal Şekil 1.2’de görülmektedir. Gecikme yayılımının sinyal biti zamanının %50 sinden fazla olduğu durumların dikkate alınması gereklidir. Aksi halde verilerin doğru alınması mümkün olmayacaktır [1].



Şekil 1.2. Gecikme yayımlı sinyal.

### 1.1.6. Çok Yollu Sönümlenme

Çok yollu sönümlenme, bir işaretin vericiden alıcıya Şekil 1.3’de görüldüğü gibi birçok yoldan ulaşması nedeni ile alıcıda elde edilen işaretin genliğinde ve fazında ani değişimlere neden olur. Bu yüzden çoklu yoldan gelen sinyallerin alıcıdaki toplamı alınan sinyalin gücünde dalgalanmalara sebep olur. Bu dalgalanmalar sönümlenme olarak adlandırılır. Çoklu yol sönümlenmesine ek olarak çoklu yol yayılımını iletilen sinyalin alıcıya ulaşması için gerekli olan zamanı uzatır. Zamandaki bu dağılım gecikme yayılımını olarak adlandırılır. Alıcıya farklı zamanlarda ulaşan birden çok işaretin girişimi sonucu meydana gelen sönümlenme günümüzde hücresel ve kişisel iletişim sistemlerinde sıkça karşımıza çıkan ve etkisinin azaltılması gereken önemli bir bozucu etkidir [1].



Şekil 1.3. Çoklu yol etkisi.

### 1.1.7. Çok Yollu Sönümlenme Etkileri

Çok yollu yayılım iletilen işaretin düz (flat) ya da frekans seçici (frequency selective) sönümlenmeye uğramasına neden olur.

#### 1.1.7.1. Düz Sönümlenme (Flat Fading )

Eğer gezgin radyo kanalı, iletilen sinyalin band genişliğinden daha fazla band genişliğine ve bu band genişliği boyunca sabit kazanç ve doğrusal faz yanıtına sahipse alıcıdaki işaret *düz sönümlenme*'ye uğrar. Düz sönümlenmede kanalın çok yollu yapısı iletilen işaretin spektral karakteristiğinin alıcıda aynen korunacağı anlamına gelir. Fakat, alıcıdaki işaretin gücü zamanla değişmektedir; çünkü çok sayıda yolun etkisiyle kanalın kazancında değişimler olmaktadır [33]. Düz sönümlenmeli kanallar “genlik değiştiren kanallar” olarak ta bilinir ve kanala gönderilen işaretin band genişliği kanalın band genişliğinden çok daha dar olduğundan “dar bantlı kanallar” olarak da bilinmektedirler. Düz sönümlenmeli kanallar derin sönümlenmelere neden olurlar, bunun için sönümlenme olmayan kanallara oranla daha düşük bit hata olasılığı elde etmek için gönderilecek işaretin gücü 20 yada 30 dB fazla olmalıdır [33]. Özetlenecek olursa bir işaretin düz sönümlenmeye uğraması için,

$$B_s \ll B_c \quad (1.2)$$

$$T_s \gg \sigma \quad (1.3)$$

olmalıdır. Burada  $T_s$ , işaretin simge periyodu;  $B_s$ , işaretin band genişliği;  $\sigma$ , kanalın gecikme yayılımı;  $B_c$ , kanalın uyum band genişliğidir.



### 1.1.7.2. Frekans Seçici Sönümleme (Frequency Selective Fading)

Eğer kanal iletilen sinyalin band genişliğinden daha dar bir band genişliği boyunca sabit kazanç ve doğrusal faz yanıtına sahipse bu kanal *frekans seçici sönümlemeli* kanaldır. Bu durumda kanalın dürtü yanıtı iletilen sinyalin periyodundan daha büyük çok yönlü yayılıma sahiptir. Bu şekilde alıcıdaki sinyal gönderilen sinyalin zayıflamış ve zamanda gecikmiş birçok bileşeninden oluşacaktır ki bu durumda alıcıda işaret bozulmaya uğramış olur. Frekans seçici sönümleme iletilen simgelerin kanal içinde zaman yayılımına uğramalarından kaynaklanmaktadır. Bu yüzden bu kanallar semboller arası girişime (ISI) neden olurlar [33]. Frekans seçici sönümlemede iletilen işaretin band genişliği kanalın band genişliğinden büyüktür. Yine, frekans seçici sönümleme çok yönlü gecikmelerin iletilen simgenin periyodunu geçmesi sonucu meydana gelir. Özetlersek, frekans seçici sönümleme durumu için

$$B_s > B_c \quad (1.4)$$

$$T_s < \sigma \quad (1.5)$$

olmalıdır.

### 1.1.8. Doppler Yayılımı Sonucu Oluşan Sönümlenmeler

#### 1.1.8.1. Hızlı Sönümleme (Fast Fading):

Hızlı sönümlemeli kanalda kanalın dürtü yanıtı bir simge periyodu boyunca çok hızlı değişir. Bu durum kanalın uyum zamanının ( $T_c$ ) iletilen sinyalin simge periyodundan ( $T_s$ ) daha küçük olduğu anlamına gelmektedir. Bu kanal türünde Doppler yayılımından dolayı frekans yayılımı meydana gelir ve işaret bozulmalarına neden olur [33]. Hızlı sönümleme şu durumlarda meydana gelir:

$$T_s > T_c \quad (1.6)$$

$$B_s < B_d \quad (1.7)$$

Bir kanalın hızlı ya da yavaş sönümlemeli kanal olması bu kanalın düz ya da frekans seçici sönümlemeli kanal olduğunu belirtmez. Hızlı sönümleme sadece kanalın hareket sonucu değişme oranı ile ilgilidir. Düz sönümlemeli kanalda ise kanalın dürtü yanıtının

sadece bir delta işlevi (gecikmesiz) olduğunu düşünebiliriz. Bundan dolayı, *düz, hızlı sönmülemeli kanal* delta işlevi genliğinin değişimi iletilen temelband sinyalin değişim oranından daha hızlı olduğu kanaldır. *Frekans seçici, hızlı sönmülemeli kanalda* ise her bir çok yollu elemanın zaman gecikmesinin, genliğinin ve fazının değişimi iletilen sinyalin değişim oranından hızlıdır [32].

### 1.1.8.2. Yavaş Sönümleme (Slow Fading):

Yavaş sönmülemeli kanalda kanalın dürtü yanıtı, iletilen temelband işaretin değişimine göre daha yavaş değişmektedir. Bu durumda kanalın birkaç simge periyodu boyunca sabit olduğu düşünülebilir. Frekans bölgesinde, kanalın Doppler yayılımı ( $B_d$ ) temel band sinyalin band genişliğinden ( $B_s$ ) çok küçüktür [33]. Yavaş sönmüleme şu koşullarda meydana gelir:

$$T_s \ll T_c \quad (1.8)$$

$$B_s \gg B_d \quad (1.9)$$

Gezgin birimlerin hızları ve temelband sinyalin karakteristiği iletilen sinyalin hızlı ya da yavaş sönmülemeye uğrayıp uğramayacağını belirler [33].

## 1.2. İletim Çeşitlemesi

Çok yollu sönmülemenin sistem performansı üzerinde meydana getirdiği etkiyi azaltmanın en etkili yollarından biri çeşitleme işlemidir. Çeşitleme, alıcı tarafta gönderilen işaretin istatistiksel bağımsız birden fazla kopyalarının elde edilmesi için kullanılan bir yöntemdir. Çok yollu kanallar üzerinden alıcıda elde edilen işaretler, derin sönmülemelere neden olabilmekte ve bundan dolayı alıcıda hata miktarı aşırı derecede artabilmektedir. Sinyalin birden fazla kopyasının farklı sönmülemeli kanallardan gönderilmesi ile bu bilgi sinyalinin sönmüleme sonucu ortadan kaybolması ihtimali azalacaktır. Çeşitleme, sadece sönmüleme etkisini azaltmakla kalmayıp iletim gücü gereksinimi de azaltacaktır. Bu nedenle kablosuz veri iletiminde hem performans hem de iletim gücü tasarrufu bakımından önemli bir yere sahiptir [1]. Aşağıda kablosuz kanallarda kullanılan bazı çeşitleme yöntemleri yer almaktadır:

### 1.2.1. Frekans Çeşitlemesi

Aynı sinyalin birbirinden bağımsız birden çok kopyasını elde etmek için aynı sinyalin birbirinden farklı frekanslarda ve frekanslar arası minimum band genişliğinin uyum band genişliğinden ( $B_C$ ) fazla olduğu taşıyıcılar ile iletilmesine *Frekans Çeşitlemesi* denir. Bu tekniğin dezavantajları, ek band genişliği gereksiniminin yanında daha fazla iletim gücü ve frekans çeşitlemesi için kullanılan kanal sayısı kadar alıcı gerektirmesidir.

### 1.2.2. Zaman Çeşitlemesi

Birbirinden bağımsız çeşitlenmiş sinyaller elde edebilmek için aynı sinyal bilgisi birbirinden farklı zaman dilimlerinde gönderilir. Birbirini takip eden zaman dilimleri arasındaki zaman ayrımı kanalın uyum zamanını ( $T_C$ ), geçmelidir. Uyum zamanı ( $T_C$ ), Doppler kaymasına, yani taşıyıcı frekansa ve gezgin birimin hızına bağlıdır. Bu tekniğin dezavantajlarından bazıları, gezgin birimin çok yavaş ilerlemesi durumunda istenmeyecek kadar gecikmelerin olması ve yüksek iletim gücü gerektirmesidir [1].


### 1.2.3. Uzak Çeşitlemesi (Anten Çeşitlemesi)

Uzak çeşitlemesi, hücreli radyo şebekelerinde kullanılan en yaygın teknik olmasının yanında ek frekans spektrumu gerektirmeyen bir tekniktir. Bu çeşitleme tekniğinde verici ve alıcının her ikisinde ya da sadece birinde birden çok anten kullanarak birbirinden bağımsız sönümlenmeli kanallar üzerinden iletim sağlanmaktadır. Bu çeşitleme yöntemi çok girişli çok çıkışlı (MIMO) haberleşme sistemlerinin temelini oluşturmaktadır [1].

## 1.3. Dikgen Frekans Bölmeli Çoğullama (OFDM)

Dikgen frekans bölmeli çoğullama, yüksek hızlı veri akışını belli sayıda alt taşıyıcı üzerinden eş zamanlı olarak toplam hız değişmeyecek şekilde, alt bantlardan düşük hızda göndermeyi sağlayan bir modülasyon ve çoğullama tekniğidir [2-17]. Böylece alt taşıyıcılar için sembol süresi artar ve çok yönlü gecikme yayılımı tarafından zamanda meydana gelen saçılmanın semboller arası karışımına sebep olması engellenir. Semboller

arası karışımın olmaması ise kanalın her bir alt bant için düz sönümlmeli hale gelmesini sağlamaktadır. OFDM sembolleri için koruma zamanı eklenerek semboller arası girişim problemi neredeyse tamamen yok edilir. Ayrıca OFDM de Şekil 1.4'te görüldüğü gibi taşıyıcı spektrumlarının birbiri üzerine binmesi ve alt taşıyıcıların birbirine dikgen olması nedeniyle mevcut band genişliği verimli bir şekilde kullanılacak ve spektral verimlilik sağlanacaktır. Bu sayede veri iletimi yüksek hızlarda yapılabilecektir [2-17].



Şekil 1.4. Dikgen alt taşıyıcı yerleşimi.

### 1.3.1. OFDM Sistemlerinde Dikgenlik

Bir iletim sisteminde amaç, kanaldaki band genişliğini olabildiğinde küçük olacak şekilde ayırarak taşıyıcılara minimum frekans tahsisini sağlamaktır. Her bir taşıyıcının bir sembol periyodu üzerinde tam sayı periyotlara sahip olması sayesinde sistemdeki diğer taşıyıcıların her birinin merkez frekansında bir sıfır meydana gelecek ve alt taşıyıcıların birbirine dikgen olması sağlanacaktır. Taşıyıcıların bir birine dikgen olması durumunda, taşıyıcılar arasında spektral olarak üst üste binme olmasına rağmen taşıyıcılara minimum frekans tahsisi sağlanarak spektral verimlilik elde edilecektir. Matematiksel olarak dikgenlik, şu şekilde ifade edilir [2-9]: Sistemdeki  $n$ . alt taşıyıcının  $\psi_p$  olduğu ve  $\psi$  alt taşıyıcı kümelerine sahip olduğumuzu kabul edelim.

$$\int_a^b \psi_p(t) \psi_q^*(t) dt = \begin{cases} K & p = q \\ 0 & p \neq q \end{cases} \quad (1.10)$$

olması durumunda alt taşıyıcılar birbirine dikgendir. Bu ifadede; ‘\*’ kompleks eşlenik işlemini göstermektedir [2-9].

### 1.3.2. OFDM Sinyallerinin Üretilmesi

Temel olarak OFDM sinyallerini elde etmek için öncelikle sistemde kullanılacak modülasyon işlemine bağlı olarak gerekli olan tayfın seçimi yapılır. Ters hızlı Fourier dönüşümü (IFFT) kullanılması ile frekans ekseninden zaman eksenine dönüşüm sağlanırken aynı zamanda alt taşıyıcılar da üretilecektir. Kullanılacak IFFT boyutu çoklu yolun meydana getireceği etkilere karşı sistemin direncini artıracaktır. Sonrasında ise semboller arası girişimden korunmak için üretilen OFDM sinyallerine periyodik ön ek eklenir. OFDM sinyal üretimi için yapılan işlemler aşağıda yer almaktadır.

### 1.3.3. OFDM' de IFFT Kullanarak Alt Taşıyıcıların Üretilmesi

Bir OFDM işareti, kullanılan modülasyon tipine bağlı olarak modüle edilen alt taşıyıcıların toplamından oluşmaktadır [2-7]. Eğer;  $d_i$ 'ler karmaşık QAM sembolleri,  $N_s$  alt taşıyıcı sayısı,  $T$  sembol süresi ve  $f_c$  taşıyıcı frekansı ise  $t=t_s$  anında başlayan bir OFDM işareti;

$$s(t) = \begin{cases} \operatorname{Re} \left\{ \sum_{i=-\frac{N_s}{2}}^{\frac{N_s}{2}-1} d_{i+N_s/2} \exp(j2\pi \left( \frac{i+0.5}{T} (t-t_s) \right)) \right\} & , t_s \leq t \leq t_s + T \text{ için} \\ 0 & , \text{diger} \end{cases} \quad (1.11)$$

olacaktır. Literatürde çoğunlukla Denk.(1.12)'de verilen kompleks temel bant notasyonu kullanılmaktadır. Bu gösterimde gerçel ve imajiner kısımlar, sonuç OFDM işaretini üretmek için, istenilen taşıyıcı frekansın kosinüs ya da sinüsü ise çarpılması gereken OFDM sinyalinin eş faz ve dikgen kısımlarına karşı gelmektedir.


$$s(t) = \begin{cases} \sum_{i=-\frac{N_s}{2}}^{\frac{N_s}{2}-1} d_{i+N_s/2} \exp(j2\pi \frac{i}{T} (t-t_s)) & , t_s \leq t \leq t_s + T \text{ için} \\ 0 & , \text{diger} \end{cases} \quad (1.12)$$

Şekil 1.5, bir OFDM işaretinden alınan dört alt taşıyıcıyı göstermektedir. Her bir alt taşıyıcının  $T$  aralığında tamsayı salınımlara sahip olduğuna ve bitişik alt taşıyıcılar arasındaki salınımların bir diğerinden farklı olduğuna dikkat edilmelidir. Bu özellik alt taşıyıcılar arasındaki dikgenliği açıklamaktadır.

Örneğin Denk.(1.12)'deki  $J$ 'nci alt taşıyıcı, işaretin  $J/T$  frekansı ile demodüle edilir ve ardından işaretin  $T$  saniye üzerinden integrali alınırsa sonuç, Denk(1.13)'teki gibi yazılır. Demodüle edilmiş alt taşıyıcı için bu integrasyon, QAM değeri olan istenilen  $d_{J+N/2}$  çıkışını vermektedir. Diğer bütün alt taşıyıcılar için integrasyon sıfırdır, çünkü  $(i-J)/T$  frekans farklılığı  $T$  integrasyon aralığında integrasyon sonucunun sıfır olmasını sağlayan tamsayı salınımlar üretir [1].

$$\int_{t_s}^{t_s+T} \exp\left(j2\pi \frac{i}{T}(t-t_s)\right) \sum_{i=-\frac{N_s}{2}}^{\frac{N_s}{2}-1} d_{i+N_s/2} \exp(j2\pi \frac{i}{T}(t-t_s)) dt$$

$$= \sum_{i=-\frac{N_s}{2}}^{\frac{N_s}{2}-1} d_{i+N_s/2} \exp(j2\pi \frac{i-j}{T}(t-t_s)) dt = d_{i+N_s/2} T$$
(1.13)



Şekil1.5. Bir OFDM işaretindeki dört alt taşıyıcı örneği.

Farklı OFDM alt taşıyıcılarının dikgenliğini göstermenin başka bir yolu da; Denk. (1.11)'e göre, her OFDM işareti;  $T$  saniye aralığında sıfır olmayan alt taşıyıcılar içermektedir. Böylece bir işaretin spektrumu, taşıyıcı frekansındaki Dirac darbeler grubu ile  $T$  saniye periyodunda 1, aksi taktirde sıfır olan kare darbelerin spektrumunun konvolosyonudur.  $1/T$ 'nin tamsayı çarpanı olan bütün frekanslar için, sıfırları olan kare darbenin genlik spektrumu,  $\text{sinc}(\pi fT)$ 'ye eşittir. Bu etki her bir alt taşıyıcının örtüşen sinc tayfının gösterildiği Şekil 1.4' te görülmektedir. Şekilden de görüleceği gibi her bir

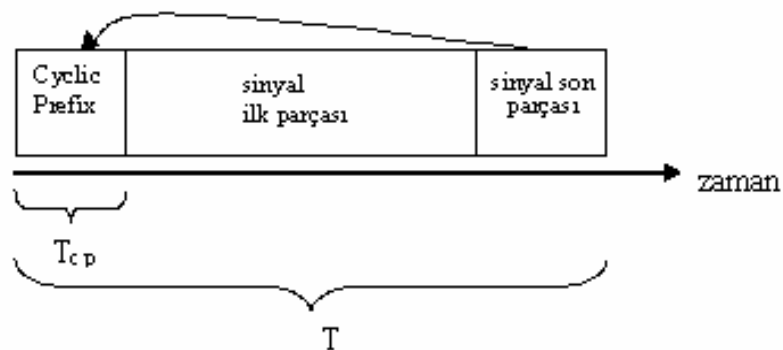
alt taşıyıcı spektrumunun maksimumunda diğer bütün alt taşıyıcıların tayfi sıfırdır. Bir OFDM alıcısı, spektrum değerlerini her bir alt taşıyıcının maksimumuna denk düşen bu noktalarda hesapladığı için, diğer alt taşıyıcılardan herhangi bir girişim olmaksızın her bir alt taşıyıcıyı serbestçe demodüle edebilir.

Denk.(1.12) ile tanımlanan karmaşık temel bant OFDM sinyali  $N_s$  adet QAM giriş sembolünün ters Fourier Dönüşümünden başka bir şey değildir. Bunun da ayrık zaman eşitliği ters ayrık Fourier Dönüşümü olup,  $t$  süresinin örnek sayısı  $n$  ile değiştiği (1.14) ifadesinde verilmektedir [2-7].

$$s(n) = \sum_{i=0}^{N_s-1} d_i \exp\left(j2\pi \frac{n_i}{N}\right) \quad (1.14)$$

#### 1.3.4. OFDM Sinyaline Koruma Aralığının Eklenmesi

Çok yollu kanallarda sönmleme etkisi, çok taşıyıcılı sistemlerde sembollerin üst üste binmesine neden olacak ve semboller arası girişim meydana getirecektir. OFDM'nin sahip olduğu en önemli özelliklerden bir tanesi de çoklu yol gecikme yayılımlarının meydana getirdiği olumsuz etkilere karşı dayanıklılığının olmasıdır. OFDM sistemlerinde, semboller arası girişime karşı dayanıklılığı sağlamak için periyodik ön ek (cyclic prefix) olarak adlandırılan koruma aralığı eklenir. Periyodik ön ek, OFDM sembolünün son parçasının bir kopyasıdır. Bu ön ek, iletilen sinyalin periyodikliğini sağlar ve taşıyıcıların dikgenliğini etkilemez. Aynı zamanda sembollerin taşıyıcıları arasında meydana gelebilecek girişimden kaçınmada rol oynar. Periyodik ön ek (CP) yerleştirme işlemi Şekil 1.6'da görülmektedir.

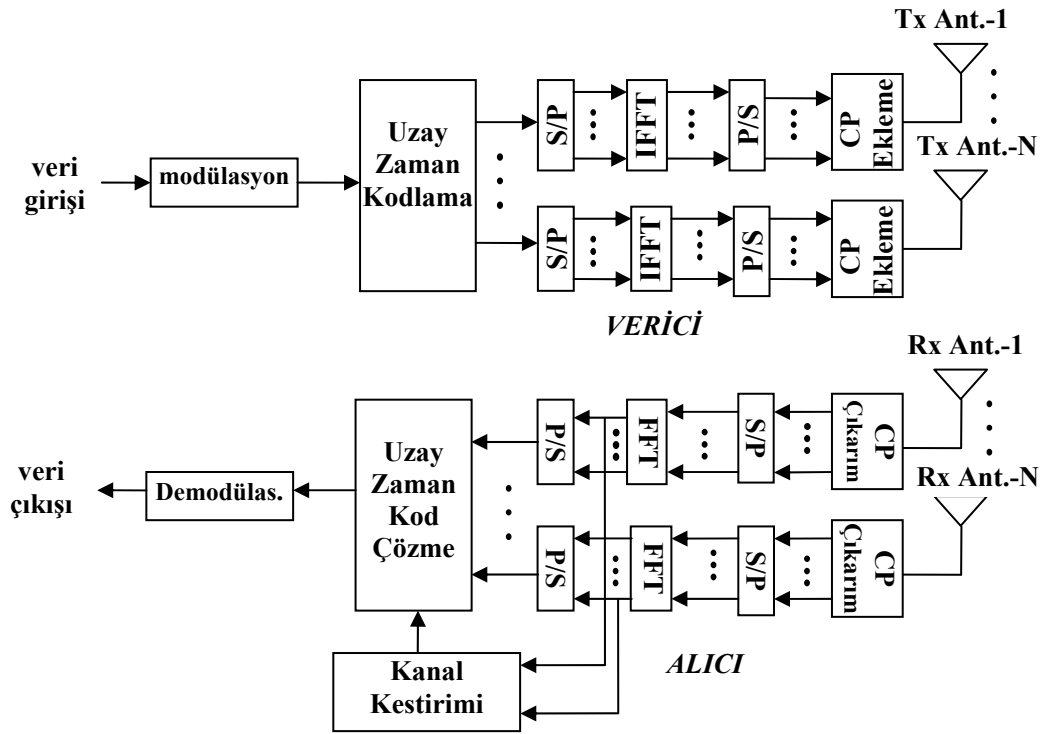


Şekil 1.6. Periyodik ön ek ekleme işlemi.

Bu işlemde OFDM sembolünün son  $v$  uzunluklu örneği sembol dizisinin başına eklenir. Alıcı tarafta ise eklenen bu koruma aralığı kaldırılır. Periyodik ön ek uzunluğu, ISI ve ICI olmayacak şekilde maksimum kanal gecikme yayılımından daha uzun yada eşit olacak biçimde seçilmelidir [2-5].

#### 1.4. MIMO-OFDM Sistem Modeli

Bir OFDM sisteminin, zamanla değişen ya da frekans seçici kanallar üzerindeki sistem kapasitesini geliştirmek ve çeşitlilik kazancını artırmak için alıcı ve verici katlarında anten dizileri ile birleştirilmesi sonucunda çok girişli çok çıkışlı dikgen frekans bölmeli çoğullama (MIMO-OFDM) sistemleri elde edilmektedir. Haberleşme sistemlerinde MIMO-OFDM kullanarak, sadece yüksek hızlarda veri iletimi sağlamakla kalmayıp aynı zamanda sistem performansının da dikkate değer bir biçimde artırılması sağlanır [18-20]. Şekil 1.7'de  $N_T$  verici,  $N_R$  alıcı,  $n$  OFDM sembolü ve  $K$  tane alt taşıyıcıdan oluşan bir MIMO-OFDM sisteminin blok diagramı görülmektedir.



Şekil 1.7. MIMO-OFDM sistem modeli.

Şekil 1.7'den görüleceği üzere sistemin girişinden gelen ikili veriler, kullanılacak modülasyon tipine bağlı olarak gruplandırıldıktan sonra modüle edilir. Daha sonra kanal



içerisinde meydana gelebilecek kanal bozulmalarının önüne geçmek için uzay zaman kodlaması yapılır ve oluşan kodlanmış semboller anten sayısına bağlı olarak ayrılır. Her bir antene bağlı olan kolda birer OFDM yapısı yer almaktadır. Her bir OFDM yapısında seri veri akışı, alt taşıyıcıların oluşturulmasını sağlayan ters hızlı Fourier dönüşümü (IFFT)'nün alınabilmesi için paralele dönüştürülür ve sonrasında ise kanal kestirimini sağlamada kullanılan pilot semboller eklenir. Bu durumda iletilecek olan sembol vektörü aşağıdaki gibidir:

$$X[n, k] = [X^1[n, k], \dots, X^{N_T}[n, k]]^T \quad k = 0, \dots, K-1 \quad (1.15)$$

İfadede  $X^{(i)}[n, k]$ ,  $i$ . anten ve  $n$ . alt taşıyıcıda iletilen semboldür.  $X[n, k]$  sembolünün IFFT si alınır ve CP eklenmesi ( $L_{CP}$ ) durumunda  $S_n[m]$  OFDM sembolü elde edilir:

$$S_n[m] = \begin{cases} \frac{1}{\sqrt{KN_T}} \sum_{k=0}^{K-1} X[n, k] e^{j2\pi mk/K} & m = -L_{CP}, \dots, K-1 \\ 0 & \text{diğer} \end{cases} \quad (1.16)$$

bu durumda her bir OFDM sembol süresi  $N = K + L_{CP}$  olacaktır. Daha sonrasında oluşan bu sembol vektörü seri hale dönüştürüldükten sonra  $i$ . antenden iletilir. İletilen bu sembol vektörü

$$S[m] = \sum_{n=-\infty}^{+\infty} S_n[m - nN] \quad (1.17)$$

dir.  $N_T$  verici ve  $N_R$  alıcı antenin kablosuz kanal dürtü cevabı aşağıdaki gibi ifade edilir:

$$h_{N_T N_R}(t, \tau) = \sum_l \xi_{N_T N_R}^{(l)}(t) c(\tau - T_{N_T N_R}^{(l)}) \quad (1.18)$$

İfadedeki  $T_{N_T N_R}^{(l)}$   $l$ . yolun gecikmesi ve  $\xi_{N_T N_R}^{(l)}$   $l$ . yolun kompleks genliğidir.  $\xi_{N_T N_R}^{(l)}$  istatistiksel olarak bağımsız Gaussian dağılımlı geniş anlamda durağan procestir.  $t$  zamanında frekans cevabı ise

$$H_{N_T N_R}(t, f) = \int_{-\infty}^{+\infty} h_{N_T N_R}(t, \tau) e^{j2\pi f\tau} d\tau = C(f) \sum_l \xi_{N_T N_R}^{(l)} e^{j2\pi f\tau_k} \quad (1.19)$$

olup  $C(f)$  aşağıdaki gibidir:

$$C(f) = \int_{-\infty}^{+\infty} c(\tau) e^{-j2\pi f\tau} d\tau \text{ dir.} \quad (1.20)$$

$j$ . alıcı antenden alınan sinyallerin öncelikle CP si kaldırıldıktan sonra FFT si aşağıdaki gibi alınır:

$$Y[n, k] = \frac{1}{\sqrt{K}} \sum_{m=0}^{K-1} y[nN + m] e^{-j2\pi km / K} \quad (1.21)$$

Bu durumda alınan sinyal vektörü aşağıdaki gibidir:

$$Y[n, k] = \sum_{j=0}^{N_T-1} X_{diag}^j [n, k] F h^{i,j} + W^j [n, k] \quad i = 1, 2, \dots, N_R \quad (1.22)$$

$$j = 1, 2, \dots, N_T$$

Eşitlik (1.22)'deki  $X[n, k]$  sembol vektörü,  $K \times 1$  boyutlu  $D[n, k]$  veri vektörü ve  $K \times 1$  boyutlu pilot sembol vektörünün toplamından oluşmaktadır.  $W^j [n, k]$  toplamsal beyaz Gauss gürültüsüdür.  $h^{i,j}$  ifadesi  $i$ . verici antenden  $j$ . alıcı antene olan  $L \times 1$  boyutlu kanal dürtü cevabıdır.  $F$  ise aşağıda eşitliği verilen  $K \times K$  boyutlu DFT matrisidir:

$$F = \begin{bmatrix} F_{0,0} & F_{0,1} & \dots & F_{0,N-1} \\ F_{1,0} & F_{1,1} & \dots & F_{1,N-1} \\ \dots & \dots & \dots & \dots \\ F_{N-1,0} & F_{N-1,1} & \dots & F_{N-1,N-1} \end{bmatrix} \quad (1.23)$$

İfadedeki  $u$ . kolon ve  $v$ . satırın elemanı olan  $F_{u,v}$ ,  $(1/\sqrt{K})e^{-j2\pi(uv/K)}$  ya eşittir. Bu durumda eşitlik (1.22) aşağıdaki gibi yeniden yazılabilir:

$$Y^j [n, k] = \sum_{i=0}^{N_T-1} D_{diag}^i [n, k] F h^{i,j} + \sum_{i=0}^{N_T-1} B_{diag}^i [n, k] F h^{i,j} + W^j [n, k] \quad (1.24)$$

Eğer (1.24) eşitliğini basitleştirilmiş şekilde yazarsak:

$$Y^j = G h^j + A h^j + W^j \quad (1.25)$$

elde edilir. Eşitlikteki  $h^j = [h^{j,1^T}, \dots, h^{j,N_T^T}]^T$   $N_T L$  boyutlu kanal dürtü cevabı,  $G = [D_{diag}^1 F, \dots, D_{diag}^{N_T} F]$  ve  $A = [B_{diag}^1 F, \dots, B_{diag}^{N_T} F]$   $K \times N_T L$  boyutlu matrislerdir.  $(.)^T$  matrisin transpozudur. MIMO-OFDM sisteminde  $N_T \times N_R$  lik her bir kanalın kanal dürtü cevabının kestirilmesi gerekmektedir. Kestirim işlemi sonraki alt bölümde anlatılacak çeşitli algoritmalar kullanarak yapıldıktan sonra uzay zaman kodlu sembollerin kodu çözülür ve demodülasyon işleminden ikili veriler elde edilir [37,38,46].

### 1.5. MIMO-OFDM Kanal Kestirimi

Frekans seçimli ve zaman değişimli iletim kanalının doğasından kaynaklanan genlik ve faz kaymaları nedeniyle OFDM sisteminde modüle edilmiş iletim bitleri iletim boyunca bozulmalara maruz kalırlar. Alıcı tarafta iletilen bu bitlerin doğru olarak alınması ve evre uyumlu demodülasyonun yapılabilmesi için kanaldaki bu değişimlerin dikkate alınması ve kanal dürtü cevabının elde edilmesi gerekir. Kanal dürtü cevabının doğru bir şekilde tespit edilmesi MIMO-OFDM sisteminin performansını doğrudan etkilemektedir. Alıcıda evre uyumlu demodülasyon için gerekli olan kanal dürtü cevapları kanal kestirim yöntemleri ile elde edilir [30-60]. Literatürde genel olarak kanal dürtü cevaplarını kestirmek için kör kanal kestirimi ve yapısı ve pozisyonu alıcı tarafta bilinen pilot ton eklemeli kanal kestirimi olmak üzere iki farklı kestirim yöntemi yer almaktadır [30-60]. Bunlardan kör kanal kestirim yönteminde sonradan herhangi bir veri eklemesi yapılmaksızın kanal kestirimi yapılır. Ancak bu yöntemin performansı kablosuz kanallardaki yüksek hızlı veri iletimi için düşük kalmaktadır. Ayrıca uygulama bakımından kanalın istatistiksel verilerine fazlasıyla ihtiyaç duyması nedeniyle pilot ton eklemeli yöntemine göre daha karmaşık bir yöntemdir [30-33]. Pilot ton eklemeli kanal kestirim yönteminde ise ya belirli periyotlarla OFDM alt taşıyıcılarına pilot tonlar yerleştirilir ya da her bir OFDM sembolüne pilot tonlar eklenerek kanal kestirimi yapılır. Bu pilot tonları kullanarak çeşitli kanal kestirim algoritmaları ile kanal dürtü cevapları elde edilir. Pilot ton eklemeli kanal kestiriminin performansı kör kanal kestirimine göre daha iyidir [33-45]. Bu yüzden kablosuz ağlar (WLAN) ve karasal-sayısal video yayıncılığı (DVB-T) gibi veri iletiminin hızlı olmasının istendiği sistemlerde pilot ton eklemeli kanal kestirimi kullanılır [26-29].

### 1.5.1. Kör Kanal Kestirimi

Kör kanal kestiriminde kullanılan alt uzay (subspace) algoritması ile kanal kestirimi şu şekilde yapılır: Alınan  $r$  veri vektörünün otokorelasyon matrisi  $R_r$  aşağıdaki gibi verilir:

$$R_r = E\{rr^H\} \quad (1.26)$$

Gürültünün iletilen verilerden bağımsız olduğu varsayılırsa  $R_r$  matrisi aşağıdaki gibi ifade edilir:

$$R_r = AR_dA^H + R_b \quad (1.27)$$

Bu ifadede  $R_d = E\{dd^H\}$  gönderilen veri vektörünün otokorelasyon matrisi,  $R_b = E\{bb^H\}$  ise gürültünün otokorelasyon matrisidir.

$R_r$  matrisinin köşegen değerleri aşağıdaki gibidir:

$$R_r = U \text{diag}(\lambda_1, \dots, \lambda_{KM}, \lambda_{KM+1}, \dots, \lambda_{(KP)N-LN}) U^H \quad (1.28)$$

İfadede  $U$  köşegen vektörleri,  $\lambda_i$  köşegen değerleridir. Bu köşegen değerler  $G = [G_1, \dots, G_g]$  ile gösterilebilir. İfadedeki  $g = k(N - M) + PN - LN$  dir.  $G$ ,  $AR_dA^H$  uzayını kapsar ve dizi uzayına dikgendir. Bu durumda

$$G_i^H A = 0 \quad i = 1, 2, \dots, g \quad (1.29)$$

dir. Bu durumda kanal kestirimi aşağıdaki ikinci dereceden fonksiyonun optimize edilmesi yapılır [30]:


$$\hat{h} = \arg \min_{\|h\|=1} \left\{ \sum_{i=1}^g G_i^H A A^H G_i \right\} \quad (1.30)$$

### 1.5.2. Pilot Ton Eklemeli Kanal Kestirim Yöntemleri

Kanal kestirimini sağlamak için pilot tonların yerleşimi için aşağıda yer alan iki temel yöntem bulunmaktadır [34]:

- Blok tip pilot ton yerleşimi.
- Tarak tip pilot ton yerleşimi.

Şekil 1.8'de bu yöntemler görülmektedir. Gerek blok tipi gerekse tarak tipi pilot ton yerleşim yöntemlerinde, en küçük kareler (LS), en küçük ortalama kareler (LMS) ya da en küçük ortalama karesel hata (MMSE) algoritmaları ile kanal kestirimi yapılır [33-45].



Şekil 1.8. Pilot ton yerleşimi.

#### 1.5.2.1. Blok Tip Pilot Ton Yerleşimi

Blok tip pilot yerleşiminde pilot tonlar tüm alt taşıyıcılara periyodik olarak yerleştirilir ve bunun sonucunda tüm alt taşıyıcılar pilot ton olarak kullanılır. Bu yerleşim türünde amaç, pilot tonları ve alınan OFDM sembollerini kullanarak belirli kanal istatistik verileri olarak veya olmaksızın kanal dürtü cevaplarını tespit etmektir. Alıcı bir sonraki pilot ton gelinceye kadar blok içerisinde alınan veriyi tespit edebilmek için kestirilmiş kanal şartlarını kullanır. Bu tip pilot ton yerleşimi sistem karmaşıklığı ve pilot ton yerleşimi bakımından avantajlı olmasına rağmen, sönümlenmenin fazla olduğu kanal şartlarında kanal kestirim performansı yetersiz kalmaktadır [35].

### 1.5.2.2. Tarak Tip Pilot Ton Yerleşimi

Tarak tipi pilot ton yerleşiminde, pilot tonlar belirli pozisyonlarda alt taşıyıcı olarak yerleştirilir. Bu sayede hızlı değişen kanallarda kanal kestirim performansı artacaktır. Ancak tüm alt taşıyıcıların yerine belirli alt taşıyıcılarda pilot semboller kullanıldığı için tüm sistemin kanal dürtü cevaplarının bulunabilmesi için ara değerleme (interpolasyon) kullanılır. Genellikle aşağıdaki ara değerleme yöntemleri kullanılmaktadır [33]:

- Doğrusal ara değerleme (LI).
- İkinci dereceden ara değerleme (SOI).
- Alçak geçiren ara değerleme (LPI).
- Parçalı kübik ara değerleme (SCI).
- Zaman domeni ara değerleme (TDI).

#### 1.5.2.2.1. Doğrusal Ara Değerleme (LI)

Doğrusal ara değerleme yönteminde,  $k$ . veri alt taşıyıcısındaki kanal kestirimi aşağıdaki gibi bulunur [33]:

$$\begin{aligned} H_e(k) &= H_e(mL + l) \quad 0 \leq l \leq L & (1.31) \\ &= (H_p(m+1) - H_p(m)) \frac{l}{L} + H_p(m) \end{aligned}$$

#### 1.5.2.2.2. İkinci Dereceden Ara Değerleme

İkinci dereceden ara değerleme kullanarak kestirilen kanal aşağıdaki gibi bulunur [33]:

$$\begin{aligned} H_e(k) &= H_e(mL + l) & (1.32) \\ &= c_1 H_p(m-1) + c_0 H_p(m) + c_{-1} H_p(m+1) \end{aligned}$$

burada

$$c_1 = \frac{\alpha(\alpha-1)}{2} \quad (1.33)$$

$$c_0 = -(\alpha-1)(\alpha+1), \alpha = \frac{l}{N} \quad (1.34)$$

$$c_{-1} = \frac{\alpha(\alpha+1)}{2} \quad (1.35)$$

### 1.5.2.2.3. Alçak Geçiren Ara Değerleme

Alçak geçiren ara değerlemede orijinal veri dizisinin içerisine sıfırlar eklenir. Daha sonra alçak geçiren sonlu dürtü yanıtı (FIR) uygulanarak orijinal verinin değişmeden geçişi sağlanır ve sonrasında da ara değerleme noktaları ile olması gereken ideal ara değerler arasındaki ortalama karesel hata minimize edilir [33].

### 1.5.2.2.4. Parçalı Kübik Ara Değerleme

Parçalı kübik ara değerleme tekniğinde verilmiş olan veri noktalarından geçen düz ve sürekli polinomial eğri üretilir [33].

### 1.5.2.2.5. Zaman Domeni Ara Değerleme

Zaman domenî ara değerlemede kestirilen  $(H_p(k), k = 0, 1, \dots, N_p - 1)$  öncelikle IDFT kullanarak zaman domenine çevrilir [33]:

$$G(n) = \sum_{k=0}^{N_p-1} H_p(k) e^{j \frac{2\pi kn}{N_p}} \quad n = 0, 1, \dots, N_p - 1 \quad (1.36)$$

Daha sonra temel sinyal işleme teknikleri kullanılarak  $N_p$  nokta  $N$  noktaya dönüştürülerek aşağıdaki ifade ile ara değerleme yapılır:

$$M = \frac{N_p}{2} + 1 \quad (1.37)$$

$$G_N = \begin{cases} G_p & 0 \leq n < M - 2 \\ 0 & \frac{N_p}{2} \leq n - M \\ G_p(n - N + 2M - 1) & -M \leq n - N < -1 \end{cases} \quad (1.38)$$

Tüm frekanslardaki kanal kestirimi aşağıdaki gibi bulunur:

$$H(k) = \sum_{n=0}^{N-1} G_N(n) e^{-j \frac{2\pi nk}{N}}, \quad 0 \leq k \leq N - 1 \quad (1.39)$$

### 1.5.3. Kanal Kestirim Algoritmaları

Kanal dürtü cevaplarını kestirmek için aşağıda verilen algoritmalar kullanılmaktadır.

#### 1.5.3.1. LS Algoritması

LS kanal kestirim algoritması, uygulama bakımından kolay bir algoritmadır. Ancak zaman değişimli sönümlenmeli kanallardaki performansı düşüktür. LS algoritması

$$\min\{(Y^j - A)^H (Y^j - A)\} \quad (1.40)$$

ifadesini minimize ederek

$$h_j = (A^H A)^{-1} A^H Y^j = h_j + (A^H A)^{-1} A^H W^j \quad (1.41)$$

ifadesi ile kanal dürtü cevabı  $h_j$ 'yi kestirir [34,35]. Bu ifadedeki  $(.)^H$  Hermitian matrisidir. Pilot tonların optimal olarak tasarlanması için LS algoritmasının ortalama karesel hata (MSE) 'sı aşağıdaki gibi yazılabilir:

$$\begin{aligned} MSE &= \frac{1}{LN_T} \mathcal{E} \left\{ \left\| \hat{h}^j - h^j \right\|^2 \right\} \\ &= \frac{1}{LN_T} \text{tr} \left\{ A^t \mathcal{E} \left\{ W^j W^{jH} \right\} A^{tH} \right\} \end{aligned} \quad (1.42)$$

İfadedeki  $(.)^t$  matrisin tersi,  $\text{tr}(\cdot)$  iz matrisi ve  $\mathcal{E}(\cdot)$  beklenti matrisidir. Sıfır ortalamalı beyaz Gauss gürültüsü için  $\mathcal{E} \left\{ W^q W^{qH} \right\} = \sigma^2 I_M$  yazılabilir. Burada  $I_M$   $M \times M$  boyutlu matris ve  $\sigma$  ise gürültünün varyansdır. Bu durumda MSE aşağıdaki gibi tanımlanır:

$$MSE = \frac{\sigma^2}{LN_T} \text{tr} \left\{ (A^H A)^{-1} \right\} \quad (1.43)$$

Eğer  $A^H A = P I_{LN_T}$  ise minimum MSE elde edilir ve bu durumda minimum MSE aşağıdaki gibi yazılabilir:



$$MSE = \frac{\sigma^2}{P} \quad (1.44)$$

İfadedeki  $P$  pilot tonun sabit gücüdür [46].

### 1.5.3.2. MMSE Algoritması

MMSE algoritması sönümlmeli kanallarda gösterdiği performans bakımından en iyi kanal kestirim algoritmalarından bir tanesidir. Ancak kanalın istatistiksel verilerine ihtiyaç duyması ve uygulanmasının zor olması nedeniyle karmaşık bir algoritmadır. MMSE algoritması ile kanal kestirimi şu şekilde yapılır:

$$h_j = FR_{hY}R_{YY}^{-1}Y \quad (1.45)$$

Bu ifadede

$$R_{hY} = E\{hY\} = R_{hh}F^H B^H \quad (1.46)$$

$$R_{YY} = E\{YY\} = BFR_{hh}F^H B^H + \sigma_G^2 I_N \quad (1.47)$$

dir. (1.47) ifadesi  $h$  ve  $Y$  arasındaki kovaryans matrisi ve (1.46) ifadesi ise  $Y$  nin otokovaryans matrisidir. (1.46) ve (1.47) ifadelerindeki  $R_{hh}$   $h$ 'nin otokovaryans matrisi ve  $\sigma_G^2 = E\{G(k)^2\}$  ise gürültünün varyansıdır [34-35].

### 1.5.3.3. LMS Algoritması

LMS algoritması kabul edilebilir kanal kestirimi sonuçları vermektedir. Ancak kullanılan adım büyüklüğü parametresi sabit olup küçük değerli olması durumunda algoritma kararlı duruma yavaş ulaşmakta, büyük olması durumunda ise kararsızlığa neden olmaktadır. LMS algoritması kullanılarak iki antenli sistemde kanal dürtü cevabı şu şekilde bulunur:

$$h_{1,j}(n+1) = h_{1,j}(n) + \eta[Y_j(n+1) - h_{2,j}(n)B_2(n+1) - h_{1,j}(n)B_1(n+1)]B_1^*(n+1) \quad (1.48)$$

$$h_{2,j}(n+1) = h_{2,j}(n) + \eta[Y_j(n+1) - h_{1,j}(n)B_1(n+1) - h_{2,j}(n)B_2(n+1)]B_2(n+1) \quad (1.49)$$

İfadelerdeki  $\eta$  LMS adım büyüklüğü parametresidir [36].


## 2. BÖLÜM

### YAPAY ZEKÂ YÖNTEMLERİ

#### 2.1. Yapay Sinir Ağları

Yapay sinir ağları insan beyninin işleyişini taklit ederek yeni sistem oluşturmaya çalışan yaklaşımlardır. Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece yapay sinir ağları denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır [61-65].

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli Şekil 3.1'de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar. Net girişi, girişler ve bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur. Şekilde görülen  $b$  bir sabit olup bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır.



Şekil 2.1. Temel yapay sinir ağı hücresi.

Nöron çıkışı,  $o = f(WX + b)$  şeklinde hesaplanır. Burada  $W$  ağırlıklar matrisi,  $X$  ise girişler matrisidir. Buna göre,  $n$  giriş sayısı olmak üzere, ağın çıkışı aşağıdaki gibi hesaplanır:

$$\text{net} = \sum_{i=1}^n w_i x_i + b \quad \text{ve} \quad o = f(\text{net}) \quad (2.1)$$

$$o = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2.2)$$

Yukarıdaki formülde görülen  $f$  aktivasyon fonksiyonudur. Genelde doğrusal olmayan aktivasyon fonksiyonunun çeşitli tipleri vardır [61-65].


### 2.1.1. Aktivasyon Fonksiyonları

Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. Aşağıda, hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları tanıtılmıştır.

#### 2.1.1.1. Eşik aktivasyon fonksiyonu

Şekil 2.2’de eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun  $-1$  ile  $+1$  arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net


giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini verir [61-65].



Şekil 2.2. Eşik aktivasyon fonksiyonu.

### 2.1.1.2. Doğrusal Aktivasyon Fonksiyonu


Şekil 2.3'te doğrusal aktivasyon fonksiyonu görülmektedir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir [61-65].



Şekil 2.3. Doğrusal aktivasyon fonksiyonu.

### 2.1.1.3. Sigmoid Aktivasyon Fonksiyonu

Şekil 2.4'te logaritmik sigmoid transfer fonksiyonu görülmektedir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir böylece daha sonraki bölümlerde görülecek olan geri yayımlı ağlarda kullanmak mümkün olabilmektedir.



Şekil 2.4 Logaritmik sigmoid aktivasyon fonksiyonu.

Fonksiyonun matematiksel ifadesi aşağıdaki gibidir:


$$f(x) = \frac{1}{1 + e^{-(\beta x)}} \quad (2.3)$$

İfadedeki  $\beta$ , eğim sabiti olup genelde 1 olarak seçilmektedir.

#### 2.1.1.4. Tanjant Hiperbolik Aktivasyon Fonksiyonu

Şekil 2.5'te tanjant hiperbolik fonksiyonun grafiği görülmektedir. Tanjant hiperbolik aktivasyon fonksiyonu lineer olmayan ve türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$



Şekil 2.5. Tanjant hiperbolik fonksiyonu.

Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir [61-65]. Yukarıda verilen fonksiyonlar en genel aktivasyon

fonksiyonlarıdır.

### 2.1.2. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağlarının öğrenme sürecinde, dış ortamdan girişler alınır ve yapay sinir ağında aktivasyon fonksiyonundan geçirilerek bir çıkış üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Yapay sinir ağının ağırlıkları her bir çevrimde yenilenecek amaca ulaşmaya çalışılır. Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer yapay sinir ağı, verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir. Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilir, sinir ağı çıkışıyla gerçek çıkışı yaklaşımı incelenir. Eğer yeni verilen örneklere de doğru yaklaşıyorsa sinir ağı işi öğrenmiş demektir. Sinir ağına verilen örnek sayısı optimum değerden fazla ise sinir ağı işi öğrenmemiş ezberlemiştir. Genelde eldeki örneklerin yüzde sekseni ağa verilir ve ağ eğitilir, daha sonra geri kalan yüzde yirmilik kısım verilir ve ağın davranışı incelenir ve ağ böylece test edilir [61-65].

### 2.1.3. Yapay Sinir Ağlarında Öğrenme Algoritmaları

1990'lı yıllardan bugüne gelinceye kadar birçok öğrenme algoritması geliştirilmiştir. Öğrenme algoritmaları temelde eğitici öğrenme, eğitici olmayan öğrenme ve takviyeli öğrenme algoritmaları olmak üzere üç grupta toplanmaktadır.

Eğitici (supervised) öğrenmede, her bir örnekleme zamanında giriş uygulandığında sistemin arzu edilen  $y$  cevabı eğitici tarafından sağlanır. Arzu edilen  $y$  çıkışı ile sinir ağının  $o$  çıkışı arasındaki fark hata ölçüsüdür ve ağ parametrelerini güncellemekte kullanılır. Ağırlıkların güncellenmesi süresince eğitici ödüllendirme-cezalendirme şemasını ağa uygulayarak hatayı azaltır. Bu öğrenme modelinde giriş ve çıkış örnekleri kümesi eğitim kümesi olarak adlandırılır.

Eğitici olmayan öğrenmede, eğitici öğrenmedeki gibi arzu edilen  $y$  çıkışları bilinmemektedir. Bu yüzden kesin bir hata bilgisini ağın davranışını değiştirmekte kullanmak mümkün

değildir. Cevabın doğruluğu veya yanlışlığı hakkında bilgi sahibi olunmadığı için öğrenme, girişlerin verdiği cevaplar gözlenerek başarıya ulaşılır. Aslında eğiticiyiz öğrenme demek doğru değildir, çünkü eğiticiyiz öğrenme gerçekte mümkün değildir. Eğitici her öğrenme adımında dahil olmamasına rağmen, amaçları ayarlamaktadır [61-65].

Takviyeli öğrenmede, ağıın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir.

Çok sayıda öğrenme algoritması bulunduğu için dolayı, bu kısımda sadece en popüler öğrenme algoritması olan Geri Yayılım Algoritması ve Levenberg-Marquardt öğrenme algoritması anlatılacaktır.


### 2.1.3.1. Geri Yayılım Algoritması

Geri yayılım algoritması, sinir ağıının eğitici sınıfına giren genel bir algoritmadır. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata yani  $e(k)$ , arzu edilen çıkış (gerçek çıkış:  $y(k)$ ) ile sinir ağıının çıkışı ( $o(k)$ ) arasındaki farktır. Yani:

$$e(k) = y(k) - o(k) \quad (2.5)$$

dır. Şekil 2.6'da birçok sinir hücresinin bir birine bağlandığı ileri yönlü çok katmanlı bir yapay sinir ağı görülmektedir. Giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir. Probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur [61-65].





Şekil 2.6. Çok katmanlı yapay sinir ağı modeli.

Şekildeki çok katmanlı ağı düşünersek;

$k+1$ . katmanda  $i$ . birime net giriş;

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

Birim  $i$ 'nin çıkışı şöyle olacaktır;

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

$M$  katmanlı bir ağ matris biçiminde ifade edilirse;

$$\underline{o}^0 = \underline{x} \quad (2.8)$$

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

elde edilir. Ağın temel görevi giriş-çıkış çiftleri arasındaki ilişkiyi öğrenmektir:

$$\{(\underline{x}_1, \underline{y}_1), (\underline{x}_2, \underline{y}_2), \dots, (\underline{x}_Q, \underline{y}_Q)\} \quad (2.10)$$

Ağın performansı şöyledir:

$$E = \frac{1}{2} \sum_{q=1}^Q (y_q - o_q^M)^T (y_q - o_q^M) = \frac{1}{2} \sum_{q=1}^Q e_q^T e_q \quad (2.11)$$

Buradaki  $o_q^M$ ,  $q$ . giriş ( $x_q$ ) olduğunda ağın çıkışıdır,  $e_q = y_q - o_q^M$  ise  $q$ . girişin hatasıdır. Standart geri yayılım algoritması yaklaşık adım düşümü algoritmasını kullanır. Performans indeksiyle şöyle yaklaşılır:

$$E = \frac{1}{2} e_q^T e_q \quad (2.12)$$

Bu ifadeye toplam karelerin toplamı tek giriş-çıkış çifti için karesel hatayla yer değiştirilir. Yaklaşık adım (eğim) düşümü algoritması bundan sonra şöyle olur:

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

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

Burada  $\alpha$  öğrenme oranı olup şöyle tanımlanır:

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

Performans indeksinin duyarlılığı  $k$ . katmanda  $i$ . birimin net girişinde değiştirilir. Şimdi (2.1), (2.6) ve (2.9) kullanılarak,

$$\frac{\partial E}{\partial w^k(i, j)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i, j)} = \delta^k(i) o^{k-1}(j) \quad (2.15)$$

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

elde edilir. Hassaslık yeterliği aşağıdaki yinelemeli ilişkiyle de gösterilebilir:

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

burada;

$$\dot{F}^k(\underline{n}^k) = \begin{bmatrix} \dot{f}^k(n^k(1)) & 0 & \dots & 0 \\ 0 & \dot{f}^k(n^k(2)) & \dots & 0 \\ \cdot & \cdot & \dots & \cdot \\ 0 & 0 & \dots & \dot{f}^k(n^k(\delta^k)) \end{bmatrix} \quad (2.18)$$

ve

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

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

dir. Tüm öğrenme algoritmalarında şu adımlar izlenir: İlk önce (2.8)-(2.9) kullanılarak giriş ileri yönde yayılır, sonra (2.20) ve (2.17) kullanılarak geri yayılır ve son olarak ağırlıklar ve denge (2.12), (2.13), (2.15) ve (2.16) kullanılarak güncellenir [61-65].

### 3.1.3.2. Levenberg- Marquardt Algoritması

Geri yayılım algoritması (GYA) çok kullanılmasına rağmen bazı dezavantajları bulunmaktadır. GYA sonuca çok yavaş olarak yaklaşmaktadır. Ayrıca lokal minimuma yakalanma riski de vardır. Geri yayılım adım düşme algoritmasıyken, Levenberg - Marquardt (LM) algoritması Newton metoduna bir yaklaşımdır. LM algoritması, Newton metodunun hızıyla adım düşme metodunun sağlamlılığının bileşkesidir [63].

LM öğrenme algoritması minimumu araştırma metodlarının ikincisidir. Her bir iterasyon adımında hata yüzeyine parabolik yaklaşımla yaklaşılır ve parabolün minimumu o adım için çözümü oluşturur.  $E(x)$  fonksiyonuna sahip olduğumuzu ve bunu  $\underline{x}$  parametresine göre minimize etmek istediğimizi düşünelim. Newton metodunda

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

olup, burada  $\nabla^2 E(\underline{x})$  ifadesi Hessian matrisidir ve  $\nabla E(\underline{x})$  ise eğimdir.  $E(\underline{x})$ 'in karelerin toplamı fonksiyonu olup

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

ifadesiyle verilir. Bu ifadeden

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

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

elde edilir. Burada  $J(\underline{x})$  Jacobian matrisi olup

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

şeklindedir ve

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

dir. Gauss-Newton metodu için  $S(\underline{x}) \approx 0$  kabul edilir ve (2.21) güncellenerek şu hale gelir:

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

Levenberg-Marquardt modifikasyonu Gauss-Newton metodu şöyle olur:

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

$\mu$  parametresi, bir adımda  $E(\underline{x})$  artımı sonucunda bir  $\beta$  faktörüyle çarpılır. Bir adım  $E(\underline{x})$  azaltışında  $\mu$  parametresi  $\beta$ ya bölünür.  $\mu$  büyükse algoritma adım düşümü ( $1/\mu$  adımı ile) olur. Küçük  $\mu$  parametresi için algoritma Gauss-Newton olur [63].

Bu algoritmadaki anahtar adım Jacobian matrisinin hesaplanmasıdır. Yapay sinir ağı tasarım probleminde Jacobian matristeki terimler geri yayılım algoritmasının basitçe değiştirilmesiyle hesaplanabilir. Tasarım problemi için performans indeksi (2.11)'de verilmiştir. Bu, (2.22)'deki eşitlikte kolayca görülebilir. Burada  $\underline{x} = [w^1(1,1)w^1(1,2)...w^1(S1,R)b^1(S1)w^2(1,1)...b^M(SM)]^T$  ve  $N=Qx$   $SM$  'dir. Standart geri yayılım algoritması terimleri şöyle hesaplanır:

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

Levenberg-Marquardt algoritması için Jacobian matrisin elemanları şöyle hesaplanabilir:

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

Bu terimler standart geri yayılım algoritması kullanılarak son katmanda bir değişiklik ile hesaplanabilir:

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

(2.31)'deki matrisin her bir kolonu bir vektördür, Jacobianın bir satırını üretmek için ağ geri yayınımalıdır.

Sonuç olarak Levenberg-Marquardt algoritması çok hızlı olarak çözüme ulaşmasına rağmen çok fazla bellek gerektirmektedir. Geri yayılım algoritması ise sonuca yavaş ulaşmakta ve daha az bellek gerektirmektedir [63].


#### **2.1.4. Yapay Sinir Ağı Yapıları**

Bu tezde kullanılan yapay sinir ağı yapıları çok katmanlı perseptron ve radyal tabanlı yapay sinir ağları olup aşağıda anlatılmıştır:

##### **2.1.4.1. Çok Katmanlı Perceptron (MLP) Ağı**

Çok katmanlı perseptron sinir ağı (MLP) modeli, Şekil 2.7’de gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Birçok öğrenme algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir MLP modeli, bir giriş, bir veya daha fazla ara (gizli) katman ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı yine uygulanan probleme dayanılarak belirlenir [61-65].

MLP ağlarında danışmanlı öğrenme uygulanmakta olup, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir. Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitme algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşüncüye kadar ağın ağırlıkları değiştirilir. İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Herhangi bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur [61-65].




Şekil 2.7. Geri yayımlı MLP yapısı [65].

#### 2.1.4.2. Radyal Tabanlı Sinir Ağları

Radyal tabanlı sinir ağı, çok değişkenli modelleme ve yakınsamalarda kullanılan bir yapay sinir ağı yapısıdır. Ara katmandaki işlemci elemanlar girişlerin ağırlıklandırılmış şeklini kullanmamakta ve ara katmandaki işlemci elemanların çıkışları YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir. Radyal tabanlı sinir ağı yapısı en genel anlamıyla radyal olarak simetrik olan ara katman işlemci elemanları içeren bir yapıdadır [65-67].

Radyal olarak simetrik olan ara katman işlemci elemanı için üç bileşen vardır. İlki giriş uzayındaki merkez vektördür. Bu vektör giriş ve ara katmanlar arasındaki ağırlık vektörü olarak saklanır. İkincisi ise bir giriş vektörünün merkezden ne kadar uzakta olduğunu belirlemek için uzaklık ölçütüdür. Tipik olarak bu ölçüt standart öklit uzaklığı olarak alınır. Sonucusu ise tek değişkenli olan ve uzaklık fonksiyonu çıkışını belirleyen bir aktivasyon fonksiyonu yapısıdır. Diğer ifade ile ara katman işlemci eleman çıkışı sadece merkezle giriş vektörü arasındaki uzaklığın bir fonksiyonudur ve

çok deęişkenli enterpolasyon yaklaşımında kullanılan YSA yapısındadır. İlk katmandaki işlemci elemanların çıkışları YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenir. Radyal tabanlı sinir ağlarının son katmanı lineerdir ve ilk katmanın çıkışlarından ağırlıklandırılmış toplam çıkış üretir. Genellikle uygulamalarda Şekil 2.8’de mimarisi yer alan yapı kullanılmaktadır.



Şekil 2.8. Radyal tabanlı sinir ağı yapısı.

Bu yapıdaki ara katman işlemci elemanları, lineer yapıdaki bir çıkış katmanına bütünüyle bağlantılıdır. Radyal tabanlı bir ağıın giriş çıkışı arasındaki ilişki aşağıdaki gibidir:

$$f_i(x) = \sum_{j=1}^n w_{ij} h_j(x) \quad (2.32)$$

$$h_j(x) = \phi(x - x_j) \quad (2.33)$$

burada  $\phi(x - x_j)$ ,  $x_j$  vektöründe merkezi olan  $j$ . düğümün aktivasyon fonksiyonudur.  $x = [x_1 \dots x_k]^T$ ,  $K$  boyutlu gerçek giriş vektörü ve  $w_{ij}$  ise gizli katman ve lineer çıkış arasındaki ağırlıklardır. Aktivasyon fonksiyonu olarak aşağıdaki Gauss fonksiyonu seçilebilir:

$$h_j(x) = \exp\left(-\frac{\sum_{k=0}^K (x_k - w_{jk})^2}{2\sigma^2}\right) \quad (2.34)$$

İfadede  $\sigma$  Gauss genişliğidir.



Radyal tabanlı sinir ağıları, çok katmanlı sinir ağlarından daha hızlı öğrenirler. Fakat artan girişle çok yüksek boyutlu radyal sinir ağı yapılarına ihtiyaç duyulur. Bu yapılar genellikle sistem modelleme, tahmin ve sınıflandırma gibi problemlerin çözümleri için kullanılırlar [65-67].

#### **2.1.4.3. RBF Ağlarının MLP Ağlarına Göre Üstünlükleri**

- MLP yapılarından daha hızlı öğrenirler.
- Karar sınırlarının belirlenmesinde ve sınıflandırmada MLP yapılarından daha doğru sonuçlar verebilmeleri.
- Ara katmanı MLP ara katmanından daha doğal bir yorumlama yeteneğine sahip olmaları.
- RBFNN ara katman elemanlarıyla giriş uzayının bir yoğunluk fonksiyonuyla temsil edilebilmesi sağlar.
- Yeni bir giriş vektörünün eğitim vektörü olarak aynı dağılımın parçası olma olasılığını ortaya çıkarabilmesi [65].


#### **2.1.4.4. RBF Ağlarının MLP Ağlarına göre Dezavantajları**

- Eğitimin ilk aşamasında merkez vektörünün belirlenmesi için kontrolsüz öğrenme yönteminin kullanılması durumunda önemli diskriminant bilgilerinin kaybolabilmesi.
- Regrasyon problemlerinin çözümünde sınırlandırılmamış aktivasyon fonksiyonlarına ihtiyaç duymaları.
- RBFNN yapılarının MLP gibi farklı formda olmamaları [65].

## **2.2. Uyarlanabilir Yapay Sinir Ağı Bulanık Mantık Sistemi (ANFIS)**

ANFIS üyelik fonksiyonu, parametrelerinin bir geri yayılım algoritması veya karma öğrenme algoritması kullanarak verilen bir giriş/çıkış veri seti vasıtasıyla belirlendiği bir bulanık mantık sistemi oluşturur. ANFIS'in ağ yapısı yapay sinir ağına benzer. Girişi, giriş üyelik fonksiyonları ve ilgili parametrelere bağlı olarak işlenir ve sonra çıkış üyelik fonksiyonları ve ilgili parametrelere bağlı olarak çıkış oluşturulur. Bir sistemin davranışını daha küçük boyutta gösterebilmek için verilen büyük bir veri

setinden verinin doğal gruplamasını belirlemek için kümeleme işlemi kullanılır. Küme bilgisi minimum sayıda kurallar kullanarak veri davranışlarını en iyi modelleyen Sugeno tipi bulanık mantık sistemini oluşturmak için kullanılır. Şekil 2.9'da ANFIS'in birinci derece Sugeno bulanık mantık sistemi olarak modellenmesi görülmektedir. Şekil 2.9'da, her bir daire bir sabit düğümü gösterirken, her bir kare bir uyarlanabilir düğümü göstermektedir [68-69].



Şekil 2.9. ANFIS yapısı.

Bu model için, eğer-ise şartlamasıyla yaygın kullanılan bir kural şöyle tanımlanabilir:

$$\text{Kural 1: Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise, } z_1 = p_1x + q_1y + r_1 \quad (2.35)$$

$$\text{Kural 2: Eğer } x \text{ } A_2 \text{ ve } y \text{ } B_2 \text{ ise, } z_2 = p_2x + q_2y + r_2 \quad (2.36)$$

Burada  $A_i$  ve  $B_i$  başlangıçtaki bulanık mantık setleri,  $p_i$ ,  $q_i$  ve  $r_i$  eğitim işlemi esnasında belirlenen sonuç parametreleridir. Şekil 2.9'da görüldüğü gibi, ANFIS beş katman içerir:

**Katman 1:** İlk katmandaki her bir  $i$  düğümü katman 1'deki  $i$ . düğümün çıkışını gösteren bir  $Q_{1,i}$  düğüm fonksiyonuna sahiptir ve bu fonksiyon şöyle verilir:

$$Q_{1,i} = \begin{cases} \mu_{A_i}(x), & i = 1,2 \text{ için} \\ \mu_{B_{i-2}}(y), & i = 3,4 \text{ için} \end{cases} \quad (2.37)$$

burada  $x$  (veya  $y$ )  $I$  düğümüne giriş,  $A_i$  (veya  $B_{i-2}$ ) düğümle ilgili dilsel terim ve  $\mu_{A_i}$  (veya  $\mu_{B_{i-2}}$ )  $A_i$  (veya  $B_{i-2}$ ) için üyelik fonksiyonudur. Diğer bir deyişle, her bir düğüm fonksiyonu,  $A_i$  (veya  $B_{i-2}$ ) belirleyicilerini sağlayan verilen  $x$  (veya  $y$ ) girişine olan dereceyi belirler.

**Katman 2:** Her bir düğüm çıkışı bir kuralın ateşleme gücünü gösterir ve bulanık mantık VE işlemini gerçekleştirir.  $i$  düğümünün çıkışı  $i$ . kural için bütün gelen sinyallerin çarpımıdır ve şöyle verilir:

$$Q_{2,i} = \omega_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2 \quad \text{için} \quad (2.38)$$

**Katman 3:** Bu katmandaki  $i$ . düğüm  $i$ . kuralın ateşleme gücünün bütün kuralların ateşleme güçlerinin toplamına olan oranı hesaplar. Bu katmandaki  $i$  düğümünün çıkışı normalize ateşleme gücüdür ve şöyle verilir:

$$Q_{3,i} = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2}, \quad i = 1,2 \quad (2.39)$$

**Katman 4:** Bu katmanda, her bir düğüm verilen şu düğüm fonksiyonuna sahiptir:

$$Q_{4,i} = \bar{\omega}_i z_i = \bar{\omega}_i (p_i x + q_i y + r_i), \quad (2.40)$$

Burada  $\bar{\omega}_i$  katman 3'den gelen bir normalize ateşleme gücüdür ve  $\{p_i, q_i, r_i\}$   $i$  düğümünün sonuç parametre setleridir.

**Katman 5:** Bu katmandaki tek düğüm bütün gelen sinyallerin toplamı olarak bütün çıkışı hesaplar ve çıkış fonksiyonu şöyle verilir:

$$Q_5 = \sum_i \bar{\omega}_i z_i = \frac{\sum_i \omega_i z_i}{\sum_i \omega_i} \quad (2.41)$$

Yapılan simülasyon çalışmalarında, en küçük kareler metodu ve gradyan iniş yöntemini birleştiren bir karma öğrenme algoritması kullanmıştır. Referans parametrelerin değerleri sabit olduğunda ve karma öğrenme kuralında, her bir eğitim adımı bir ileri

geçiş ve bir geri geçiş içerir. İleri geçişte, katman 4'ün düğüm çıkışları hesaplanır, düğüm çıkışları arzu edilen değerlerle kıyaslanır ve daha sonra sonuç parametreleri en küçük kareler metoduyla ayarlanır. Geri geçişte hata sinyalleri geri yayılır ve üyelik fonksiyonlarının parametreleri gradyan iniş yöntemiyle güncellenir [68-69].

## 3. BÖLÜM


### YAPAY ZEKÂ OPTİMİZASYON ALGORİTMALARI

#### 3.1. Genetik Algoritma (GA)

Genetik algoritma (GA), doğadaki canlıların geçirdiği evrim sürecini örnek alarak matematiksel modeli kurulamayan veya çözüm alanı çok geniş olan problemlerin çözümünde kullanılan tekniktir. Genetik algoritmanın evrimden faydalanma ilkesi, anne ve babadan meydana gelen bir çocuğun hem annesinin hem de babasının bazı özelliklerini taşıyabildiği gibi ebeveynlerinden daha üstün özellikleri de taşıyabilmesi varsayımına dayanmaktadır. John Holland (1975), evrimden ve evrimin canlılardaki bu sürecinden etkilenerek, canlılardaki bu genetik süreci bilgisayar ortamına aktarmak istemiş ve tek bir mekanik yapının öğrenme yeteneğini geliştirmek yerine, böyle yapılardan oluşan topluluğun çiftleşme, çoğalma ve değişim gibi genetik süreçlerden geçerek başarılı yeni bireyler oluşturabildiğini göstermiştir. Genetik algoritmada her bir çözüm, birey veya kromozom adı verilen dizinler ile gösterilir. Biyolojiyi andırır şekilde bir kromozom genel olarak O ve I' lerden oluşan dizinler halinde gösterilir. Biyolojik kromozom üzerinde belirli genlerin belirli karakteristik özellikleri taşıması gibi genetik algoritmadaki kromozomların belirli kısımlarının problemin belirli özellikleriyle çözümünü içerdiği kabul edilir [86-89].

Genetik algoritmada öncelikle rasgele veya bilinen "olurlu" çözümleri içeren ve uygunluk değerleri hesaplanmış başlangıç popülasyonu oluşturulur. Seçilecek popülasyondaki kromozom sayısının çok küçük olması işlem kolaylığı sağlamakla beraber, alternatif çözüm çeşitliliğini azaltacağından tercih edilmez. Kromozomların fazla olması ise işlem hacmini artırarak iterasyonların uzamasına neden olacağından uygun değerlerin seçilmesi algoritmanın performansı açısından önemlidir. Başlangıç çözümler, daha sonra probleme bağlı olarak belirlenen temel genetik operatörler yardımıyla evrimden geçirilerek yeni çözümler oluşturulur. Yeni bireyleri oluşturma

işleminde kullanılacak kromozomların seçiminde öncelik genellikle uygunluk değeri yüksek olanlara verilir. Bir veya birden fazla rasgele çaprazlama noktası seçilip, bu noktalara göre çaprazlama operatörü uygulanarak bilgi değişimi sağlanır ve yeni kromozomlar oluşturulur. Çaprazlama operatöründen sonra veya çaprazlama sırasında mutasyon operatörü uygulanır. Mutasyon operatörü tek bir kromozom üzerinde işlem yapar. Kromozomun herhangi bir elemanı rasgele seçilir ve onun yerine o elemanın alabileceği başka bir değer ile değiştirilir. Bu operatörler uygulandıktan sonra mevcut popülasyon bireylerinden bazıları yeni bireylere yer açmak amacı ile popülasyondan çıkartılır. Optimal çözüme yaklaşmak amacı ile bu evrimden geçirme operasyonu daha uygun çözüm bulunamayınca kadar devam eder.



Şekil 3.1. Genetik algoritma akış diagramı.

Yapılan bu işlemlerin basamakları Şekil 3.1'de gösterilmektedir. Oluşturulan popülasyon uygunluk değeri, uygunluk fonksiyonuna göre değerlendirilip uygunluk değerleri hesaplanır. Aradığımız sonucu veren kromozom olup olmadığı kontrol edilir. Kabul edilebilir sonuca ulaşamamışsa uygunluk değeri göz önünde bulundurularak yeni kromozomlar oluşturmak üzere bazı kromozomlar eşlenir. Eşleştirilen bireyler bilgi alışverişinde bulunmak üzere daha önceden belirlenen çaprazlama stratejisi ve çaprazlama oranına göre çaprazlamaya tabi tutulur. Çaprazlama esnasında veya sonrasında bazı bireyler yine önceden belirlenen mutasyon oranı ve stratejisi çerçevesinde mutasyona uğrattılır. Bir önceki popülasyondan direkt aktarılan kromozomlar ve çaprazlama sonucu üretilen yeni kromozomlara yer açmak üzere eski kromozomlardan en düşük uygunluk değerli olanlar veya rasgele seçilenler silinir. Daha sonra oluşan yeni popülasyon uygunluk fonksiyonuna göre değerlendirilir. Belirlenen hedefe ulaşmaya kadar bu evrim devam ettirilir [86-89].

### **3.1.1. Genetik Operatörler**

Genetik operatörler genetik algoritma yaklaşımının problemler üzerine uygulanmasını sağlayan temel işlemcilerdir. Problemden çözüme ulaşmayı sağlayan bu operatörlerdir. Genetik algoritmaların en temel operatörleri kromozomlar arasında bilgi alışverişini sağlayan "çaprazlama" ve küçük değişimi sağlayan "mutasyon"dur [89].

#### **3.1.1.1. Tekrar Üreme Operatörü**

Tekrar üreme operatörü tabii seçme olarak adlandırılan kalitesi yüksek bireylerin hayatta kalmaları ve sayılarının artması, kalitesi düşük bireylerin ise sayılarının azalması prensibine göre çalışan operatördür. Bu seçme işlemi, tabiatta çevre tarafından, yapay sistemlerde ise amaç fonksiyonu ve diğer kalite değerlendirme işlemleri tarafından kontrol edilir. Bireysel yapılar bir jenerasyondan diğer kuşağa geçerken kalite değerlerine göre daha fazla kopya edilme şansları vardır. Bundan dolayı daha kaliteli çözümlerin popülasyonda baskın olmaları, kalitesiz olanların ise yavaş yavaş kaybolmaları yani ölmeleri sağlanır. Bu operatörün uygulanması için kullanılan en basit metot rulet tekerleği tekniğidir [89].

Bu teknikte her bir çözüme, kalite değerinin popülasyonundan ortalama kalite değerine

göre tekerlek üzerinde bir değer verilir. Daha sonra tekerlek tekrar üremeye tabi tutulacak bireylerin seçimi için yeterli sayıda döndürülür. Her dönüşte top, hangi bireye ait boşluğa girerse o dönüş için o birey başarılı olmuş demektir. Başarılı adaylar eşleştirme havuzu olarak adlandırılan bir havuzda toplanarak diğer genetik operatörlerin uygulanması için hazırlanırlar [89].

### 3.1.1.2. Çaprazlama Operatörü

Çaprazlama operatörü ile iki kromozomu bir araya getirip karşılıklı bilgi değişimi yaparak yeni kromozomların oluşması sağlanır. Çaprazlanarak bilgi alış verişinde bulunacak kromozomların seçiminden önce, başlangıçta kromozomların çaprazlamaya tutulma olasılığını belirten sabit bir çaprazlama oranı tanımlanır. Bu çaprazlama oranı kromozomların çaprazlamaya tabi tutulma olasılığını verir. Çaprazlama işleminde, eşleştirme havuzunda bulunan yapıların birer çifti rasgele seçilerek bu iki yapıdan yeni iki yapı meydana getirilir. Eski yapılar veya çaprazlama operatörünün uygulanmasından sonra ortaya çıkan çocuklar mevcut jenerasyonda tutulur veya birbirileri ile yani eski ile yeni yapılar yer değiştirilirler. İkinci durumda kötü yapılar atılır ve popülasyon büyüklüğü sabit olarak korunur. Farklı şekillerde çaprazlama işlemi yapılabilmektedir.

#### Tek Noktalı Çaprazlama

Kromozom 1	1 0 1 1 0 <u>1 1 0 0</u>	Yeni kromozom 1	<u>1 0 1 1</u> 0 1 1 0
Kromozom 2	1 1 0 0 0 <u>1 1 0</u>	Yeni kromozom 2	1 1 0 0 0 <u>1 1 0</u>

#### Çift Noktalı Çaprazlama

Kromozom 1	1 0 1 1 <u>0 1</u> 0 0	Yeni kromozom 1	1 0 1 0 0 1 0 0
Kromozom 2	1 1 0 0 0 1 1 0	Yeni kromozom 2	1 1 0 <u>1 0</u> 1 1 0

Şekil 3.2. Çaprazlama işlemi.

En klasik tek noktalı çaprazlama birinci ve ikinci kromozom üzerinde ortak belirlenen rasgele nokta temel alınarak birinci kromozomun bu noktadan önceki kısmı ile ikinci kromozomun bu noktadan sonraki kısmı birleştirilerek yeni bir kromozom elde edilir.



İkinci kromozom için de kromozomların diğer kısımları birleştirilir. Çift noktalı çaprazlama ise kromozomlar üzerinde rasgele belirlenen iki nokta esas alınarak kromozomların bu noktalar arasında kalan kısımlarının karşılıklı değiştirildiği çaprazlamadır. Tek noktalı ve çift noktalı çaprazlamaya ait birer örnek Şekil 3.2’de verilmektedir [89].

### 3.1.1.3. Mutasyon Operatörü

Mutasyon operatörü ile kromozomların genleri veya genleri oluşturan küçük birimleri üzerinde değişiklik yapılması sağlanır. Yeni popülasyonda bulunan çözümlere ait her bir bit tek tek kontrol edilerek mutasyon oranına göre 1 ise 0’a, 0 ise 1’e çevrilir; yani bitlerin değerleri tersine döndürülür. Gösterim olarak buna uymayan bir yapıda da yine rastgele seçilecek iki genin yerleri veya sırası değiştirilmek suretiyle mutasyon gerçekleştirilir. Genetik algoritmalarda mutasyonun sağladığı avantaj, problemin çözüm alanını araştırmada yön değişikliklerini sağlayarak araştırmanın kısır döngüye girmesini önlemektir [89].


	Değişime uğrayan bitler									
<b>Eski Dizi</b>	1	1	<u>1</u>	1	0	0	1	1	<u>0</u>	1
<b>Yeni Dizi</b>	1	1	<u>0</u>	0	0	0	1	1	<u>1</u>	1

Şekil 3.3. Mutasyon İşlemi

## 3.2. Parçacık Sürü Optimizasyonu (PSO)

Parçacık sürü optimizasyonu (PSO) 1995 yılında Dr. Eberhart ve Dr. Kennedy tarafından geliştirilen, kuş ve balık sürülerinin davranışları gözlemlenerek oluşturulmuş popülasyon tabanlı stokastik bir optimizasyon tekniğidir. Bu teknikte kuşların yerlerini bilmedikleri yiyecekleri aramaları, optimize edilecek bir problem için çözüm yolu bulmaya karşı gelmektedir. Parçacık sürü optimizasyonunda; parçacık olarak adlandırılan tekil çözüm, arama uzayındaki bir kuştur. Parçacıkların yiyeceğe ne kadar uzakta olduğu uygunluk değeri ile ölçülür ve bu parçacıkların hızları ve konumları bu uygunluk değerine göre değiştirilir. Bu değişim, parçacıkların komşularının en iyi

koordinatlarının ve kendi koordinatlarının bileşiminden oluşacaktır. PSO rastgele bir çözümle başlatılır ve her bir tekrarlama (iterasyon) ile parçacıkların konumları en iyi iki değer arasında güncellenir. Bu iki değerden ilki parçacığın o zamana kadarki elde ettiği en iyi çözümü sağlayan koordinat olup *pbest* olarak isimlendirilir. Diğer en iyi değer ise o zamana kadar elde edilen tüm parçacıkların en iyi çözümü olan koordinat değeridir ve *gbest* olarak adlandırılır [90-92]. PSO algoritmasının işlem basamaklarını gösteren diagram Şekil 3.4'te yer almaktadır.



Şekil 3.4. Parçacık sürü optimizasyonu akış diagramı.

$D$  boyutlu arama uzayından oluşan  $n$  adet parçacığın olduğu bir problemi göz önüne aldığımızda populasyon parçacık matrisi aşağıdaki gibi olacaktır:

$$x = \begin{bmatrix} x_1^1 & x_1^2 & \dots & \dots & x_1^D \\ x_2^1 & x_2^2 & \dots & \dots & x_2^D \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_n^1 & x_n^2 & \dots & \dots & x_n^D \end{bmatrix}_{n \times D} \quad (3.1)$$

Matriste  $i$ . parçacığın pozisyon vektörü  $x_i = (x_i^1, x_i^2, \dots, x_i^D)$  dir. Önceki en iyi uygunluk değerini veren  $i$ . parçacığın pozisyonu  $pbest_i^d = (p_i^1, p_i^2, \dots, p_i^D)$  ile ifade edilir.  $gbest^d = (p^1, p^2, \dots, p^D)$  ise her bir tekrarda tüm parçacıkların en iyi konum değeridir ve tektir. Her bir boyuttaki  $i$ . parçacığın değişim hızı ise  $v_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$  dir. En iyi iki değer bulunmasından sonra parçacıkların hızları ve konumları aşağıdaki verilen ifadeler ile güncellenir:

$$v_i^d(t+1) = wv_i^d(t) + c_1r_1^1(t)(pbest_i^d(t) - x_i^d(t)) + c_2r_2^2(t)(gbest^d(t) - x_i^d(t)) \quad (3.2)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (3.3)$$

ifadelerde yer alan  $c_1$  ve  $c_2$  her bir parçacığı  $pbest$  ve  $gbest$  değerlerine çeken öğrenme faktörleridir.  $c_1$  parçacığın kendi tecrübelerine göre hareket etmesini sağlarken  $c_2$  ise sürüdeki diğer parçacıkların tecrübelerine göre hareket etmesini sağlar.  $r_1^1$  ve  $r_2^2$ ,  $[0, 1]$  arasında düzgün dağılımlı rastgele sayılardır.  $w$  ise atalet ağırlığı olup önceki hız ile mevcut hız vektörlerinin kontrol edilmesini sağlar [90-92].

### 3.2.1. PSO Parametre Seçimi

#### 3.2.1.1. Parçacık sayısı

PSO da parçacık sayısı genel olarak 20 ile 40 arasında seçilir. Çözülecek problemin zorluk durumuna göre bu parametre değeri 100 veya 200 gibi değerler de alınabilir [92].

#### 3.2.1.2. Parçacık aralığı

Optimize edilecek problemin değerine bağlı olarak farklı boyutlarda ve farklı aralıklarda

tanımlama yapılır [92].

### 3.2.1.3. Maksimum Hız (Vmax)

Her bir tekrar sonucunda bir parçacığın maksimum değişim hızıdır. Genellikle probleme bağlı olarak değişmesine rağmen (-10,10) aralığındaki bir problem için Vmax değeri 20 olarak alınır [92].

### 3.2.1.4. Öğrenme Faktörleri

$c_1$  ve  $c_2$  genelde 2 olarak seçilir ve  $c_1$  ve  $c_2$  birbirine eşittir [92].

### 3.2.1.5. Durma Kriteri

Maksimum tekrar sayısı ya da istenen bir hata değeri durma kriteri olarak seçilebilir [92].

### 3.2.1.6. Atalet Katsayısı (inertia factor)

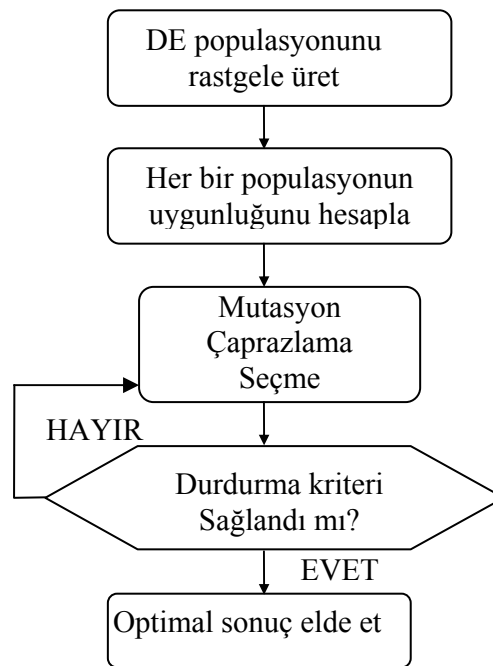
Bu katsayısı parçacıkların hızının kontrol edilmesini sağlar. Düşük  $w$  değerinin seçilmesi parçacıkların hedefe doğru çekilmeden önce bu bölgeden uzak yerlerde dolaşmasını sağlar ancak hedefe ulaşma süresi de artacaktır. Yüksek değerler seçilmesi durumunda ise hedefe ulaşma hızlanırken hedef bölgesinden uzaklaşmalar meydana gelecektir. Bu nedenle uygun değerlerin bulunması optimum değere ulaşmayı sağlarken tekrar sayısını da azaltacaktır. Aşağıdaki ifade kullanılarak en uygun  $w$  değeri bulunur [90-92]:

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{\text{tekrar}_{\max}} \times \text{tekrar} \quad (3.4)$$

## 3.3. Farksal Gelişim (DE) Algoritması

Farksal gelişim (DE) algoritması, Storn ve Kenneth 1999 yılında önerilmiş global optimizasyon problemlerinin çözümünde kullanılan popülasyon tabanlı bir algoritmadır. Farksal gelişim algoritması, popülasyondaki bireyler arasındaki fark bilgilerini

kullanarak yeni aday çözümlerin bulunmasını sağlar. Genetik algoritma gibi gelişim tabanlı algoritmaların aksine farksal gelişim algoritması rasgele olarak seçilmiş amaç vektör çiftlerinin farklarına dayalı bir mutasyon işlemi kullanır. Amaç vektör farklarının dağılımı amaç vektörlerinin kendi dağılımları tarafından belirlenir. Farksal gelişim algoritmasında kullanılan basit mutasyon işlemi algoritmanın performansını geliştirmekte ve onu daha gürbüz yapmaktadır. Bu özelliğinin yanı sıra hızlı, basit, kolayca kullanılabilir, doğal olarak paralel, matris çarpımları ve sıralama işlemleri olmadığı için hesaplama maliyeti açısından avantajlı, daha önceden tanımlanmış herhangi bir olasılık dağılımlı mutasyon kullanmadığı ve fazla parametreye ihtiyaç duymadan hızlı yakınsama özelliklerinden dolayı etkili bir optimizasyon algoritmasıdır [93,94]. Algoritmanın işlem adımları Şekil 3.5'te gösterilmektedir.



Şekil 3.5. Farksal gelişim algoritması işlem adımları.

Farksal gelişim algoritmasında NP tane D boyutlu amaç değişken vektörlerinin  $x_{jiG}$  rasgele dağılımlı başlangıç popülasyonu üretilir. j indisi j'nin her bir değeri için yeni bir rasgele sayı üretildiğini gösterir. i indisi ise rasgele değerlerin her bir vektör için üretildiğini göstermektedir. Oluşturulan başlangıç popülasyonu, mutasyon, yeniden üretim ve seçme işlemleri ile geliştirilir [93,94]

### 3.3.1. Mutasyon

Mutasyon işleminde, varolan amaç vektörler çiftinin ağırlıklaştırılmış farkının, amaç vektörüne ilave işlemi yapılır. Algoritmanın basit mutasyon işlemi genellikle aritmetik çaprazlama işlemi ile karıştırılır. Aritmetik çaprazlama, iki vektörün genel doğrusal kombinasyonu iken mutasyon üç vektörün doğrusal kombinasyonunun özel bir halidir. Her iki durumda da amaç vektörlerinin doğrusal kombinasyonu olan yeni vektörler üretmektir.

Her bir  $x_i (i = 1, 2, \dots, m)$  amaç vektörü için G jenerasyonundaki mutasyon vektörü aşağıdaki gibi tanımlanır:

$$V_{i,G+1} = x_{r_1,G} + \eta(x_{r_2,G} - x_{r_3,G}) \quad (3.5)$$

ifadede yer alan  $i, r_1, r_2, r_3 \in \{1, 2, \dots, m\}$  birbirinden farklı aynı zamanda rasgele seçilmiş popülasyon indisleridir.  $\eta$  ise  $x_{r_1}$  ve  $x_{r_2}$  arasındaki farklılığı belirleyen ölçüt faktörüdür [93-94].

### 3.3.2. Yeniden Üretim

Yeniden üretim, var olan amaç vektör parametrelerinden faydalanarak yeni vektörleri oluşturmak suretiyle araştırmanın başarılı olmasını sağlar. Yeniden üretim işlemi aşağıdaki gibi yapılır:

$$U_{i,G+1} = \begin{cases} V_{i,G+1} & \text{if } rand_j(0,1) \leq C_r \vee j = k \\ x_{i,G} & \text{aksi.halde} \end{cases} \quad (3.6)$$

ifadede yer alan  $C_r$  yeniden üretim yada çaprazlama sabiti iken,  $rand_j(0,1)$  ise  $j$ th nesil için rasgele olarak üretilmiş sayılardır [93,94].

### 3.3.3. Seçme

Seçme, yeni üretilen vektörlerin hangi şartlar altında popülasyona girebileceğini

tanımlayan bir kriterdir. Örneğin turnuva seçme işleminde rasgele seçilmiş vektör çiftleri arasında bir dizi yarışma gerçekleştirerek yeni nesil üyesi seçilir. Yarışan vektörler ebeveyn çocuk popülasyonundan seçilir ve en fazla kazanan vektörlerin gelişmesine müsaade edilir. Bu işlemde yeni üretilen vektör ebeveynine göre daha gelişmiş veya en azından aynı gelişme seviyesinde değilse ebeveyn vektör en az bir nesil daha popülasyonda kalmaya devam etmekte ve başka vektörlerle yer değiştirmemektedir. Seçim işlemi,  $U_{i,G+1}$  bireyinin  $(G + 1)$  neslin üyesi olacağına ya da olmayacağına karar verir [93,94]:


$$x_{i,G+1} = \begin{cases} U_{i,G+1}, & \text{eger } f(U_{i,G+1}) < f(x_{i,G}) \\ x_{i,G}, & \text{aksi.halde} \end{cases} \quad (3.7)$$

### 3.4. Yapay Arı Koloni (ABC) Algoritması

Yapay arı koloni (ABC) algoritması, bal arısı kolonilerinin nektar kaynaklarına giderek dans etmeleri ile zengin nektar kaynakları için diğer arılara haber vermelerinden esinlenerek 2005 yılında Prof. Dr. Derviş Karaboğa tarafından geliştirilmiş bir optimizasyon algoritmasıdır. Yapay arı kolonisi algoritmasında bir kolonide, işçi arılar, gözcü arılar ve kaşif arılar olmak üzere üç farklı arı grubu bulunmaktadır. Koloni, yarısı işçi, yarısı gözcü arı olmak üzere meydana getirilir. Her bir nektar kaynağı için sadece bir işçi arı bulunmaktadır. Yani işçi arıların sayısı nektar kaynağına eşittir [98-103]. Algoritma Şekil 3.6'da verilen adımlardan oluşmaktadır.

Her bir çevrim üç adımdan oluşmaktadır; işçi ve gözcü arıların kaynaklara gönderilmesi, gidilen kaynakların nektar miktarının hesaplanması, kaşif arıların belirlenerek yeni bir kaynağa rasgele konumlanması. Algoritmada yer alan yiyecek kaynakları optimize edilmeye çalışılan problemin olası çözümlerine karşılık gelmektedir. Bir kaynağa ait nektar miktarı, o kaynakla ifade edilen çözümün kalite değerini ifade etmektedir. Gözcü arılar rulet tekerleği prensibine göre gidecekleri kaynakları belirlemektedirler. Her kolonide rasgele araştırma yapan kaşif arılar bulunmaktadır. Bu arılar yiyecek ararken herhangi bir ön bilgi kullanmamakta tamamen rasgele araştırma yapmaktadırlar. Dolayısıyla arama maliyetleri düşüktür ve zengin nektar kaynağına sahip keşfedilmemiş kaynakları bulmaları da olasıdır. Yapay arı

kolonisi algoritmasında işçi arıların biri seçilerek kaşif arı haline gelmektedir. Bu seçme işlemi limit parametresine göre yapılmaktadır. Bir kaynağı ifade eden çözüm belli sayıdaki deneme ile gerçekleştirilmemişse bu kaynak terk edilir ve bu kaynağa gidip gelen işçi arı kâşif arı haline gelir. Kaynağın terk edilmesi için belirlenmiş deneme sayısı limit parametresi ile belirlenmektedir [98-103].



Şekil 3.6. ABC algoritması işlem adımları.

Arama işleminde keşif ve keşfedilenden faydalanma aynı anda gerçekleşmelidir. Yapay arı kolonisi algoritmasında gözcü ve işçi arılar keşfedilen kaynaklardan faydalanma işleminde, kaşif arılar ise keşif sürecinde rol alırlar. Gerçek arılarda taşıma hızı koloninin bir kaynağı bulması ve kovana getirmesi ile belirlenirken yapay arılar durumunda bulunan çözümün kalite değeri yani uygunluğu ile belirlenir.



Diğer sosyal yiyecek arayıcıları gibi arılar  $E/T$  değerini yani birim zamanda yuvaya getirilen yiyecek miktarını belirten enerji fonksiyonunu maksimize etmek için çalışırlar. Bir maksimizasyon probleminde amaç fonksiyonunun  $F(\theta_i)$ ,  $\theta_i \in R^p$  maksimize edilmesi işlemi gerçekleşir.  $\theta_i$ ,  $i$ . kaynağın pozisyonu olmak üzere  $F(\theta_i)$  bu nektar miktarına karşılık gelir ve  $E(\theta_i)$  ile orantılıdır.  $c$  çevrim sayısı,  $S$  kovan etrafındaki nektar kaynağı sayısıdır ve  $P(c) = \{\theta_i(c) | i = 1, 2, \dots, S\}$  tüm kaynakların pozisyon bilgilerini içeren nektar kaynağı popülasyonudur. Gözcü arıların bir kaynağı seçmeleri  $F(\theta)$  değerine bağlıdır. Kaynağın nektar miktarı ne kadar fazla olursa bu kaynağın bir gözcü arı tarafından seçilme olasılığı o kadar fazla olmaktadır. Yani  $\theta_i$  pozisyonundaki bir kaynağın seçilme olasılığı:

$$P_i = \frac{F(\theta_i)}{\sum_{k=1}^S F(\theta_k)} \quad (3.8)$$

ile belirlenir. Gözcü arı, işçi arıların dansını izledikten ve seçilme olasılığındaki olasılık değeri  $\theta_i$  konumundaki kaynağı seçtikten sonra bu kaynağın komşuluğundaki bir kaynağı belirler ve kaynağın nektarını almaya başlar. Yani  $\theta_i$  civarındaki kaynaklar arasında bir kıyaslama yapar. Seçilen komşuya ait pozisyon bilgisi aşağıdaki gibi hesaplanır:

$$\theta_i(c+1) = \theta_i(c) \pm \phi_i(c) \quad (3.9)$$

$\phi_i(c)$ ,  $\theta_i$  civarında daha fazla nektara sahip bir kaynak bulabilmek için kullanılan rasgele üretilen adım büyüklüğüdür.  $\phi_i(c)$ ,  $k$ ,  $i$ 'den farklı olarak rasgele üretilen popülasyondaki bir çözüme ait indis olmak üzere  $\theta_i(c)$  ve  $\theta_k(c)$  çözümlerinin bazı bölümlerinin farkının alınması ile hesaplanır.  $\theta_i(c+1)$ 'e ait nektar miktarı  $F(\theta_i(c+1))$ ,  $\theta_i(c)$  konumundaki kaynağa ait nektar miktarından daha fazla ise kovana giderek bu bilgisini diğerleri ile paylaşır ve yeni pozisyon olarak  $\theta_i(c+1)$ 'i aklında tutar, aksi durumda  $\theta_i(c)$ 'yi hafızasında saklamaya devam eder.  $\theta_i$  konumundaki nektar kaynağı "limit" parametresi sayısınca gelişmemiş ise  $\theta_i$  deki kaynak terk edilir ve o kaynağın

arısı kaşif arı haline gelerek rasgele araştırma yapar ve yeni bulduğu kaynak  $\theta_i$ 'ye atanır [98-103].

### 3.5. Yapay Zeka Optimizasyon Algoritmaları İçin Uygunluk Fonksiyonu

Denk. (1.44)'ü bu tez çalışmasındaki yapay zeka optimizasyon algoritmalarında uygunluk fonksiyonu olarak kullanabileceğimize rağmen Denk. (1.44)'te yer alan matrisin tersinin alınması gereksinimi, yapılması gereken hesap karmaşıklığını artıracaktır. Bu durumda  $A$  matrisinin full rank olması ve  $AA^H$  'nın köşegen elemanlarının pozitif ve reel değerli olması nedeniyle Gerschgorin çember teoremi yardımıyla hesap karmaşıklığını azaltabiliriz [104-107]. Yapay zeka optimizasyon algoritmaları için kullanılacak MSE'nin üst değeri bu teorem ile şu şekilde bulunabilir:

$$\text{tr}\{(AA^H)^{-1}\} = \sum_{i=1}^L \frac{1}{\lambda_i} \leq \begin{cases} \frac{L}{P - R_{\max}} & , P > R_{\max} \\ + \infty & , P \leq R_{\max} \end{cases} \quad (3.10)$$

ifadedeki  $\lambda_i$  ( $i = 1, \dots, L$ ) öz değerler,  $b_{ij} = P$  ( $i = 1, \dots, L$ ),  $(AA^H)$  matrisinin köşegen elemanları ve  $R_{\max} = \max(R_i)$  ise Gerschgorin diskinin yarıçapıdır ve aşağıdaki gibi ifade edilir [104-107]:

$$R_i = \sum_{j=1, j \neq i}^L |b_{ij}| \quad (3.11)$$

Denk. (3.8)'deki analize göre uygunluk fonksiyonu olarak aşağıdaki eşitlik kullanılabilir:

$$\text{uygunluk fonksiyonu} = \frac{R_{\max}}{P} \quad (3.12)$$

## 4. BÖLÜM

### SİMÜLASYON ÇALIŞMALARI

#### 4.1. Giriş

Bu bölümde, MIMO-OFDM sistemlerinde kullanılan kanal kestirim algoritmalarının ve bu algoritmalara alternatif olarak bu tez çalışmasının da özünü oluşturan yapay zeka yöntemlerinden çok katmanlı sinir ağları, radyal tabanlı sinir ağları ve uyarlanabilir bulanık sinir ağlarının öğrenme özellikleri kullanılarak elde edilen kanal kestirimcilerin performansları, bilgisayar simülasyonları yardımıyla incelenmiştir. Ayrıca pilot ton tabanlı kanal kestiriminde kullanılan, pilot tonların yerleşim yerleri ve güçleri genetik algoritma, parçacık sürü optimizasyonu, farksal gelişim algoritması ve yapay arı kolonisi algoritması gibi yapay zeka optimizasyon algoritmaları kullanılarak optimize edilmiş ve bu sayede kanal kestirim algoritmasının farklı Doppler kaymasına sahip kanallardaki performansı artırılmıştır.

#### 4.2. Yapay Zeka Yöntemleri İçin MIMO-OFDM Sistem Parametreleri

Tablo 4.1. Yapay zeka yöntemlerinin değerlendirilmesi için MIMO-OFDM sistem parametreleri.


Parametre	Değer
Taşıyıcı frekansı ( $f_c$ )	5 GHz
Örnekleme frekansı ( $f_s$ )	3 MHz
FFT boyutu	64
Alt taşıyıcı sayısı	64
Periyodik ön ek boyutu	16
Sembol süresi	$64 T_s = 21.33 \mu s$
Periyodik ön ek süresi	$T_{FFT}/4 = 5.33 \mu s$
Modülasyon tipi	QPSK
Kanal tipi	COST 207 TU

Klasik ve yapay zeka yöntemli kanal kestirimcilerin performanslarını değerlendirmek için Şekil 1.7’de verilen MIMO-OFDM sistem modeli ve Tablo 4.1’de verilen sistem parametreleri kullanılmıştır.

Farklı anten sayılarının kanal kestirim performansı üzerindeki etkisini görmek için 2x2, 4x4 ve 8x8 lik alıcı ve verici anten sayısına sahip MIMO-OFDM sistemi oluşturulmuştur. Kanal yapısı olarak literatürde kanal kestirim algoritmalarının performans değerlendirmesinde sıklıkla kullanılan, (0, 200, 600, 1600, 2400, 5000) ns gecikme yayılımlarına ve (-3, 0, -2, -6, -8, -10) dB güç yollarına sahip çok yollu sönümlenmeli kanal tipi olan COST 207 TU kanalı [103] kullanılmıştır.

#### 4.2.1. MLP Sinir Ağları Kullanarak Kanal Kestirimi

OFDM sinyallerinin karmaşık değerli olması, YSA'nın da reel değerli girişlere ve çıkışlara göre işlem yapması nedeniyle OFDM sinyallerinin YSA ya giriş olarak uygulanabilmesi için yapısı Şekil 4.1’de görülen 2 girişli ve 2 çıkışlı çok katmanlı model kanal kestiriminde kullanılmıştır.



Şekil 4.1. MLP sinir ağı kanal kestirimci yapısı.

Kanal kestirimi için MLP yapay sinir ağlarında kullanılan parametreler aşağıda verilmektedir. Verilen bu parametreler yapılan simülasyonlar sonucu elde edilen en uygun değerlerdir.

- Öğrenme algoritması: Levenberg- Marquarth
- Ara katman nöron sayısı: 5
- Ara katman aktivasyon fonksiyonu: tanjant hiperbolik
- Çıkış katmanı aktivasyon fonksiyonu: lineer

- Tekrar (epoch) sayısı: 500

MLP sinir ağıny eğitmek için doğru kanal dürtü cevaplarından oluşan 1200 değişik eğitim seti kullanılmıştır. Eğitim işleminden sonra reel ve imajiner parçalarına ayrılmış OFDM sinyalleri bu YSA yapısına giriş olarak uygulanarak ağıny çıkışının kestirilmiş kanal dürtü cevaplarını vermesi sağlanmıştır.


Şekil 4.2’de 2x2 alıcı ve verici anten yapısına sahip MIMO-OFDM sistemi için kanal kestirim algoritmalarının 0-30 dB sinyal/gürültü aralığında bit hata oranı (BHO) kıyaslaması yer almaktadır. Kıyaslanan algoritmalar içerisinde en kötü sonucu kör kanal kestirim işlemi vermiştir. Elde edilen bu sonuca göre, bu kestirimin çok yollu sönümlenme etkilerine karşı fazla dayanıklı olmadığı görülmektedir. Ayrıca LS ve LMS algoritmaları uygulama bakımından kolay algoritmalar olmalarına rağmen performansları hem YSA’dan hem de MMSE algoritmasından daha kötüdür. Şekil 4.2’den görüleceği gibi gerek düşük sinyal/gürültü oranı (SGO) değerinde gerekse yüksek SGO değerlerinde YSA lı kanal kestirimcinin performansı kör kanal kestirimi, LS ve LMS algoritmalarından daha iyidir. Hatta artan SGO değerlerinde YSA nın performansı daha da artmaktadır. Örneğin 10 dB SGO’da YSA ve LS algoritması arasındaki BHO değeri  $10^{-1}$  den daha azken 30 dB SGO değerindeki BHO farkı  $10^{-1}$ ’den daha fazla olmuştur. MMSE algoritması diğer algoritmalara göre en iyi performansı vermiş olmasına rağmen, kanal kestiriminde korelasyon hesaplamasına, matris tersinin alınmasına ve alıcı tarafta kanal gürültüsünün istatistiksel verilerine ihtiyaç duyması nedeniyle uygulaması zor bir algoritmadır.

Şekil 4.3’te ise kanal kestirimi için kullanılan algoritmaların performanslarını değerlendirmek için bir başka değerlendirme kriteri olarak ortalama karesel hata (OKH) değişim grafiği görülmektedir. Her bir SGO değerinde algoritmaların OKH değerlerini elde etmek için aşağıdaki ifadeden faydalanılmıştır:


$$OKH = 1/N \sum_{q=0}^{N-1} E[(H_{est} - H_{real})^H (H_{est} - H_{real})] \quad (4.1)$$

Burada  $H_{est}$  kestirilmiş kanal dürtü cevabı,  $H_{real}$  ise gerçek kanal dürtü cevabıdır.

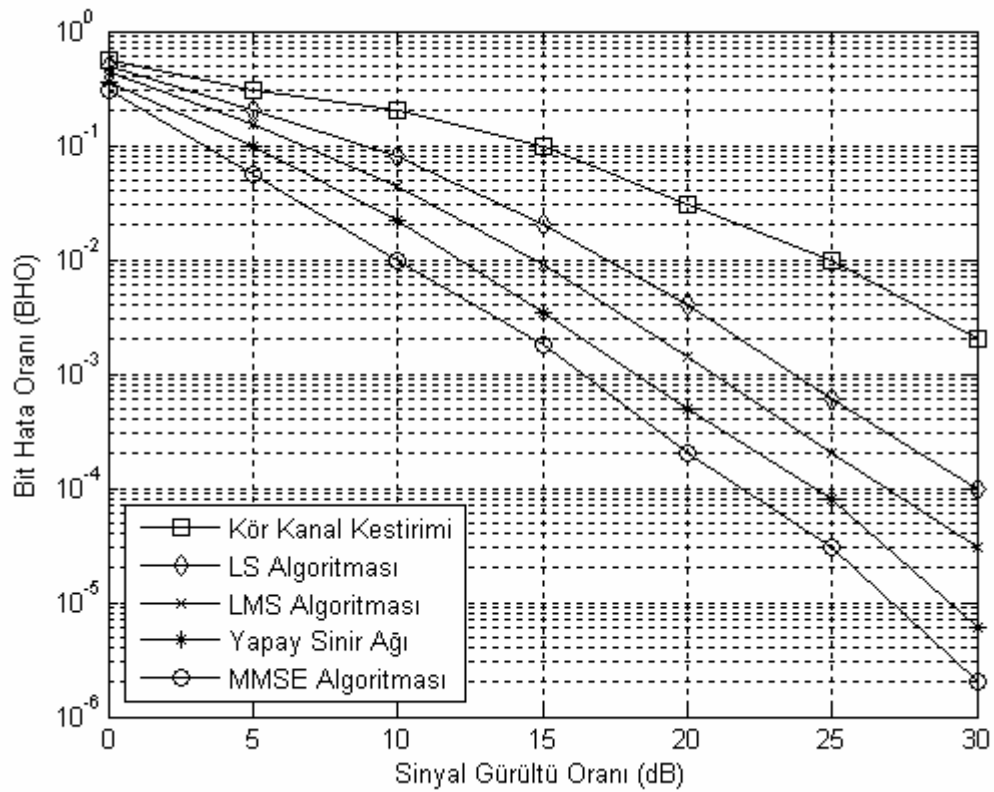
Şekil 4.3'e göre; tüm kestirim algoritmalarının artan SGO değerlerine karşı OKH değerleri azaltılmaktadır. YSA'nın kanal kestirim hatası, LS, LMS ve kör kanal kestirimine göre daha azdır. Örneğin  $10^{-1}$  OKH değerinde YSA ile kör kanal kestirimi arasında 7 dB lik SGO farkı bulunmaktadır.



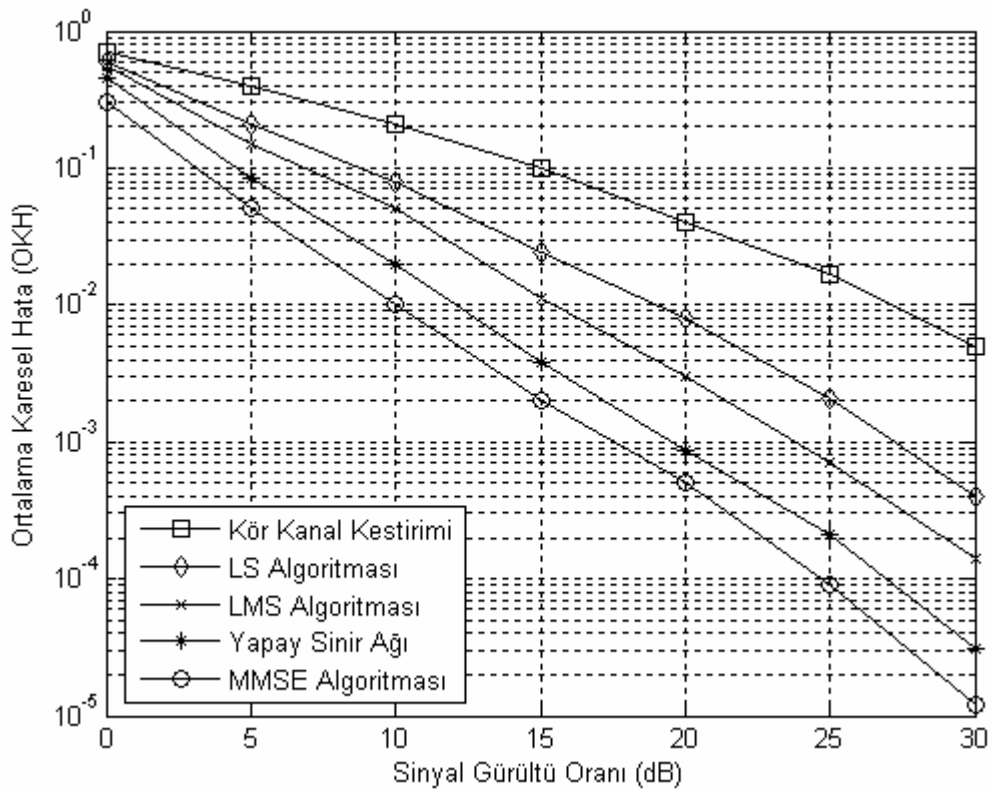
Şekil 4.2. 2x2-MIMO-OFDM'de MLP-YSA kanal kestiriminin BHO performansı.



Şekil 4.3. 2x2-MIMO-OFDM'de MLP-YSA kanal kestiriminin OKH performansı.




Şekil 4.4. 4x4-MIMO-OFDM'de MLP-YSA kanal kestiriminin BHO performansı.




Şekil 4.5. 4x4-MIMO-OFDM’de MLP-YSA kanal kestiriminin OKH performansı.

Şekil 4.4 ve Şekil 4.5’te 4x4 alıcı ve verici anten sayılarına sahip MIMO-OFDM sistemi için BHO ve OKH değişimleri görülmektedir. Şekil 4.4 ve Şekil 4.5’e göre, YSA ile elde edilen kestirim performansı; LS, LMS ve kör kanal kestirimcinin performansına göre oldukça iyidir. Şekil 4.4’ü dikkate aldığımızda 20 dB SNR değerinde, YSA ile LMS algoritması arasındaki BHO değeri  $5 \times 10^{-2}$ , LS algoritması ile  $10^{-1}$  ve kör kanal kestirimi ile de  $10^{-2}$  dir.





Şekil 4.6. 8x8-MIMO-OFDM'de MLP-YSA kanal kestiriminin BHO performansı.




Şekil 4.7. 8x8-MIMO-OFDM'de MLP-YSA kanal kestiriminin OKH performansı.

Şekil 4.6 ve Şekil 4.7’de ise, 8x8 lik anten sayılarına sahip sistemdeki kanal kestirim algoritmalarının performanslarının değerlendirilmesi yer almaktadır. Sistemde bulunan anten sayısının artmasıyla MIMO-OFDM sisteminin çoklu sönümlenmeli kanallara karşı gösterdiği dayanıklılık ta artmaktadır. Bu sayede, sistemin kanal kestirim hataları sistemde bulunan anten sayısının daha az olduğu durumlara göre daha da azalmıştır. Öyle ki Şekil 4.3 ve Şekil 4.7’yi incelediğimizde 2x2 lik antenli sistemden YSA kullanılarak elde edilen OKH değeri ile 8x8 lik antenli sistemden YSA kullanılarak elde edilen OKH arasındaki fark yaklaşık olarak  $10^{-2}$  den daha fazladır. Elde edilen bu sonuca göre, sistemde kullanılan alıcı ve verici anten sayısının artırılması kanal kestirimcinin de performansını artırmaktadır. Ancak anten sayısının artması sistemin karmaşıklığını artırmakta ve oluşturulan YSA lı kanal kestirimcinin de daha karmaşık bir yapıda olmasına neden olmuştur.

#### 4.2.2. RBF Sinir Ağları Kullanarak Kanal Kestirimi


Kanal kestiriminde kullanılan radyal tabanlı sinir ağı yapısı Şekil 4.8’de görülmektedir. Şekilden de görüleceği üzere OFDM sinyallerini RBF ağına kullanılabilir hale getirmek için karmaşık yapıdaki sinyaller reel ve imajiner kısımlarına ayrılarak ağına girişine uygulanır. 1200 tane gerçek kanal dürtü cevaplarından oluşan eğitim seti kullanılarak ağına eğitiminden sonra eğitilmiş ağ kanal kestirimci olarak kullanılmıştır. Elde edilen simülasyon sonuçlarından en uygun değer olarak radyal tabanlı sinir ağının gizli katmanında 25 nöron ve Gauss aktivasyon fonksiyonu tercih edilmiştir.




Şekil 4.8. Radyal tabanlı yapay sinir ağı kanal kestirimci modeli.

Şekil 4.9 ve Şekil 4.10’da 2x2 anten sayısına sahip MIMO-OFDM sistemindeki kanal kestirimcilerin bit hata oranı (BHO) ve ortalama karesel hata ile ilgili simülasyon

sonuçları görülmektedir. Elde edilen bu sonuçlara göre; kanal kestirimi için önerilen radyal tabanlı sinir ağı, kör kanal kestirimi, LS algoritması ve LMS algoritmalarına kıyasla daha iyi sonuçlar vermiştir. Ayrıca radyal tabanlı sinir ağları, bir önceki bölümde incelenen çok katmanlı sinir ağlarından da daha iyi performans göstermiştir. Bu algoritmanın performansı MMSE algoritmasının performansına biraz daha yaklaşmıştır. Örneğin MMSE algoritması ile radyal tabanlı SA arasındaki sinyal gürültü farkı  $10^{-2}$  BHO değerinde yaklaşık olarak 1.5 dB dir. Ancak Şekil 4.3'teki grafiğe göre YSA ile MMSE arasındaki bu değer yaklaşık olarak 2 dB civarında olduğu görülmektedir.




Şekil 4.9. 2x2-MIMO-OFDM'de RBF-YSA kanal kestiriminin BHO performansı.




Şekil 4.10. 2x2-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı.


Önerilen radyal tabanlı sinir ağı kanal kestirimcisinin 4x4 ve 8x8 lik anten yapısına sahip MIMO-OFDM sistemindeki performansını göstermek için Şekil 4.11, Şekil 4.12, Şekil 4.13 ve Şekil 4.14’teki simülasyon sonuçları elde edilmiştir. Bu sonuçlardan görülmektedir ki radyal tabanlı sinir ağı kanal kestirimcisi, anten sayılarının artırıldığı sistemde de iyi bir performans göstermiştir. Şekil 4.11 incelendiğinde 30 dB SNR değerinde RBF sinir ağı ile kör kanal kestirimi arasındaki BHO farkı  $10^{-2}$  den daha fazladır. Bu sonuç bize kör kanal kestiriminin çok yollu sönümlenmeli kanallar için uygun bir kanal kestirim yöntemi olmadığını, RBF sinir ağının ise bu tip kanallar için uygun bir kanal kestirim algoritması olduğunu göstermektedir. Ayrıca anten sayısının fazla olduğu Şekil 4.13’ teki durumda da bu algoritmanın performansı daha da artmaktadır. Şekil 4.12 ve Şekil 4.13 dikkate alındığında anten sayısının artması RBF sinir ağının  $10^{-1}$  lik OKH kazancının olmasını sağlamıştır.




Şekil 4.11. 4x4-MIMO-OFDM’de RBF-YSA kanal kestiriminin BHO performansı.



Şekil 4.12. 4x4-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı.



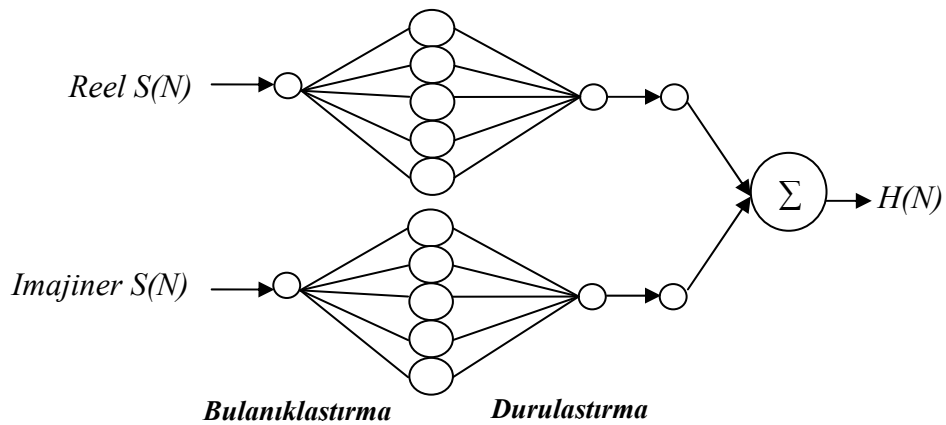
Şekil 4.13. 8x8-MIMO-OFDM’de RBF-YSA kanal kestiriminin BHO performansı.



Şekil 4.14. 8x8-MIMO-OFDM’de RBF-YSA kanal kestiriminin OKH performansı.


### 4.2.3. ANFIS Kullanarak Kanal Kestirimi

Kanal kestirimi için Şekil 4.15'te yer alan uyarlanabilir sinir ağı yapısı kullanılmıştır. Yukarıdaki bölümlerde de bahsedildiği gibi reel ve imajiner kısımlarına ayrılmış olan OFDM sinyalleri ağı giriş olarak uygulanır. 1200 eğitim seti kullanılarak 100 tekrarla eğitilmiş ağ çıkışı ise kestirilmiş kanal dürtü cevaplarını vermektedir.




Şekil 4.15. ANFIS kanal kestirimci modeli.

Şekil 4.16 ve Şekil 4.17'de 2x2 alıcı ve verici antene sahip MIMO-OFDM sisteminde kullanılan kanal kestirim algoritmalarının BHO ve OKH değerleri kıyaslanmaktadır. Şekil 4.16'dan da görüleceği gibi ANFIS tabanlı kanal kestirim algoritması MMSE dışındaki diğer kestirimcilerden daha iyi BHO değerlerine sahiptir ve bunun yanında MMSE algoritmasının BHO performansına da oldukça yakındır. Ayrıca ANFIS kanal kestirimcisi, yukarıdaki bölümlerde önerilen YSA ve RBF sinir ağından daha iyi sonuçlara sahiptir. Her ne kadar MMSE algoritması iyi sonuçlar vermiş olsa da literatürde bahsedildiği ve bölüm 1 deki yer alan eşitliklerden de görüleceği üzere kestirim işleminin kanalın istatistiksel verilerine ihtiyaç duyması ve pratik uygulamalarda bu istatistiksel verilerin elde edilmesinin güç olması nedeniyle uygulamada kullanılması zor bir algoritmadır.




Şekil 4.16. 2x2-MIMO-OFDM’de ANFIS kanal kestiriminin BHO performansı.




Şekil 4.17. 2x2-MIMO-OFDM’de ANFIS kanal kestiriminin OKH performansı.




Şekil 4.18, Şekil 4.19, Şekil 4.20 ve Şekil 4.21’de ise 4x4 ve 8x8 lik anten için kanal kestirim algoritmalarının performans değerlendirmesi görülmektedir. Şekillerden de görüleceği gibi anten sayısının artırılması ile kanal kestirim algoritmalarının performansının artmasının yanında sistemin de performansı artmaktadır. MIMO-OFDM sistemlerinde anten sayısının artırılmasıyla kanaldaki sönmüleme etkilerinin üstesinden gelmek mümkün olacaktır. Ancak bu durumda hem kestirim algoritmalarının hem de buna bağlı olarak sistemin de karmaşıklığının artacağı da unutulmamalıdır.




Şekil 4.18. 4x4-MIMO-OFDM’de ANFIS kanal kestiriminin BHO performansı.



Şekil 4.19. 4x4-MIMO-OFDM'de ANFIS kanal kestiriminin OKH performansı.




Şekil 4.20. 8x8-MIMO-OFDM'de ANFIS kanal kestiriminin BHO performansı.




Şekil 4.21. 8x8-MIMO-OFDM’de ANFIS kanal kestiriminin OKH performansı.

#### 4.2.4. Kanal Kestiriminde Yapay Zeka Yöntemleri Performanslarının Kıyaslanması

Şekil 4.22 ve Şekil 4.23’te 2x2 MIMO-OFDM sistemi için kanal kestiriminde kullanılan yapay zeka yöntemlerinin BHO ve OKH performansları görülmektedir. Şekil 4.22 incelendiğinde, YSA kanal kestirimcisinin en kötü sonuçlara sahip olduğu ancak aralarındaki performans farkının fazla olmadığı görülmektedir. En iyi sonucu ise ANFIS kanal kestirimcisi elde etmiştir. ANFIS,  $10^{-3}$  BHO değerinde RBFNN’den yaklaşık olarak 0.5 dB SGO daha iyiyken, YSA ile arasındaki fark ise yaklaşık olarak 1 dB SGO’dur. Ayrıca artan SGO’larında ise ANFIS’in BHO performansı daha da artmaktadır. Ancak YSA ile RBFNN arasındaki BHO farkı tüm SGO’larında değişmemektedir. Şekil 4.23’te ise ANFIS’in OKH değerleri YSA ve RBFNN’ten daha iyidir.  $10^{-2}$  OKH değerinde ANFIS, yaklaşık olarak YSA’dan 2 dB RBFNN’ten ise 1 dB SGO kazancına sahiptir.




Şekil 4.22. 2x2 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları.




Şekil 4.23. 2x2 MIMO-OFDM’de yapay zeka yöntemlerinin OKH performansları.


Şekil 4.24 ve Şekil 4.25’ te 4x4 MIMO-OFDM sistemi ve Şekil 4.26 ve Şekil 4.27’de ise 8x8 MIMO-OFDM sistemi için kanal kestiriminde kullanılan yapay zeka yöntemlerinin BHO ve OKH performans değerleri yer almaktadır. Şekil 4.24’ten görüleceği gibi her bir yöntemin performansı arasında çok fazla fark bulunmamaktadır. Ancak YSA’nın performans değerleri RBFNN ve ANFIS’ten daha kötüdür. En iyi kestirim performansına ise ANFIS sahiptir. YSA ile RBFNN arasındaki BHO ve OKH farkları oldukça yakındır.  $10^{-4}$  BHO değerinde iki kestirimci arasındaki SGO farkı 1 dB’in oldukça altındadır. Bu sonuçtan her iki yönteminde 4x4 anten sistemi için hemen hemen aynı performansı gösterdiğini söyleyebiliriz. ANFIS,  $10^{-4}$  BHO değerinde ise YSA’dan 2 dB SGO daha iyidir. Şekil 4.26 incelendiğinde, artan SGO değerlerine karşılık ANFIS’in BHO performansı YSA ve RBFNN’ten daha iyi olduğu görülmektedir. YSA ve RBFNN’ün performans değerleri ise oldukça yakındır. Bu nedenle kanal kestirimi için YSA ya da RBFNN ten herhangi birinin kullanılması durumunda kestirimci performansında fazla fark görülmeyecektir.




Şekil 4.24. 4x4 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları.



Şekil 4.25. 4x4 MIMO-OFDM’de yapay zeka yöntemlerinin OKH performansları.




Şekil 4.26. 8x8 MIMO-OFDM’de yapay zeka yöntemlerinin BHO performansları.



Şekil 4.27. 8x8 MIMO-OFDM’de yapay zeka yöntemlerinin OKH performansları.

Şekil 4.28’de ise anten sayılarının kestirimci performansı üzerindeki etkisini göstermek için 1x1, 2x2, 4x4 ve 8x8 antenler için 20 dB SGO’nına elde edilen OKH değişim grafiği görülmektedir. Şekilden de görüleceği gibi anten sayılarının artması durumunda kestirimcilerin de performansları artmaktadır. Örneğin 2x2 anten sayısına sahip bir sistem ile 4x4 anten sayısına sahip sistemin OKH değer farkı yaklaşık olarak  $10^{-1}$  dir. Gene aynı şekilde 4x4 anten sayısına sahip sistem ile 8x8 anten sayısına sahip sistemin OKH değer farkı  $10^{-1}$  dir. Elde edilen bu sonuçlardan anten sayılarının artırılması ile sistemin performansının da artacağı söylenebilir. Çünkü anten sayılarının artırılması çoklu yolda meydana gelebilecek sönümlenme etkilerini azaltmaktadır.



Şekil 4.28. 20 dB SGO için yapay zeka yöntemlerinin anten sayılarına göre OKH performansları.

### 4.3. Yapay Zeka Optimizasyon Algoritmaları İçin MIMO-OFDM Parametreleri

Optimize edilmiş pilot tonların LS kanal kestirim algoritması performansı üzerindeki etkisini değerlendirmek için simülasyonlarda kullanılan MIMO-OFDM sistem parametreleri Tablo 4.2’de yer almaktadır.

Tablo 4.2. Yapay zeka optimizasyon algoritmalarının değerlendirilmesi için MIMO-OFDM sistem parametreleri.

Parametre	Değer
Taşıyıcı frekansı ( $f_c$ )	5 GHz
FFT boyutu	128
Alt taşıyıcı sayısı	128
Periyodik ön ek boyutu	32
OFDM sembol süresi	1.13 ms
Pilot ton sayısı	16
Normalize edilmiş pilot ton gücü	1 dBm
Modulasyon tipi	QPSK
Alıcı-verici anten sayısı	2



Kanal türü olarak, literatürde pilot tonların optimizasyonu sonucu performans değerlendirmesi için sıklıkla kullanılan çok yollu ve her bir yolun birbirinden bağımsız, benzer yayımlı  $r_{hh}(\tau) = \sigma_h^2 J_0(2\pi f_d \tau)$  eşitlikli Jakes modeline [103] göre oluşturulmuş 8 yollu kanal yapısı kullanılmıştır. Ayrıca önerilen yöntemlerin Doppler kaymasına karşı olan dayanıklılığını göstermek için  $f_d=5$  Hz ve  $f_d=40$  Hz lik Doppler kaymalarında simülasyonlar gerçekleştirilmiştir. Simülasyonlarda aşağıdaki pilot yerleşimlerinin değerlendirilmesi yapılmıştır.

- Eşit güçlü rasgele yerleştirilmiş pilot tonlar
- Eşit güçlü eşit aralıklı yerleştirilmiş dikgen pilot tonlar
- Eşit güçlü ve yerleşimi optimize edilmiş pilot tonlar
- Gücü ve yerleşimi optimize edilmiş pilot tonlar


#### **4.3.1. Genetik Algoritma Kullanarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi**

Pilot tonların yerlerinin ve güçlerinin optimizasyonu için önerilen genetik algorithmada aşağıda verilen kontrol parametreleri kullanılmıştır. Kullanılan bu parametreler çeşitli denemeler sonucu elde edilmiştir ve bu denemeler sonucunda en uygun değerli olanları simülasyonlarda kullanılmıştır.

- Popülasyon büyüklüğü: 20
- Çaprazlama oranı: 0.8
- Mutasyon oranı: 0.2

Pilot tonların optimum yerlerinin belirlenmesi için algoritma ilk olarak 0-127 arasında rasgele popülasyon üretilerek başlatılır. Üretilen popülasyon, pilot tonların konumlarına karşılık gelecektir. 0-127 arasında popülasyonun üretilmesinin nedeni ise OFDM sisteminde 128 tane alt taşıyıcının bulunması ve pilot tonların tarak tipi yerleşimde 128 farklı konumda yerleştirilebilmesindedir. Popülasyondaki her bir bireyin uygunluk değeri Denk. (3.12)'de yer alan uygunluk fonksiyonu kullanılarak test edilir. Daha sonrasında pilotların en iyi yerlerini belirlemek için ayrıntıları bölüm 3 te yer alan çaprazlama ve mutasyon işlemleri yapılır. Yapılan bu işlemler durdurma kriteri

sağlanıncaya kadar tekrar edilir ve uygunluk değeri en yüksek olan kromozomlar seçilerek pilot tonların yerleri belirlenir. Simulasyonlarda durdurma kriteri olarak maksimum 3000 tekrar kullanılmıştır. Ayrıca pilot gücünün 0-1 dBm güç değerlerine sahip olmasından dolayı, pilot tonların gücünün optimizasyonu için başlangıçta 0-1 aralığında rasgele popülasyon üretimi yapılır ve yukarıda bahsedilen işlemler ile popülasyonun güncellenmesi ve sonucunda en uygun değer pilot gücü olarak belirlenmesi sağlanır.




Şekil 4.29. GA ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı.


Şekil 4.29 ve Şekil 4.30'da kanalda 5 Hz'lik Doppler kayması olması durumunda elde edilen 0-30 dB SGO aralığındaki BHO ve OKH grafikleri görülmektedir. Şekil 4.29 incelendiğinde, optimum pilot yerleşimi, rasgele ve dikgen yerleşime göre daha az BHO değerlerine sahiptir. 30 dB SGO değerinde optimum yerleşim ile rasgele yerleşim arasındaki BHO farkı  $10^{-1}$  den daha fazladır. Ve  $10^{-3}$  BHO değerinde ise optimum yerleşim, dikgen yerleşimden 2.5 dB fazla SGO'ya sahiptir. Ayrıca hem pilot ton konumunun hem de gücünün optimizasyonu ile dikgen yerleşime göre  $10^{-3}$  BHO değerinde 4 dB'e yakın SGO kazancı sağlanmaktadır. Şekil 4.30'a dikkat edildiğinde

ise gerek konum gerekse güç optimizasyonu ile daha az kanal kestirim hataları ortaya çıkmaktadır.

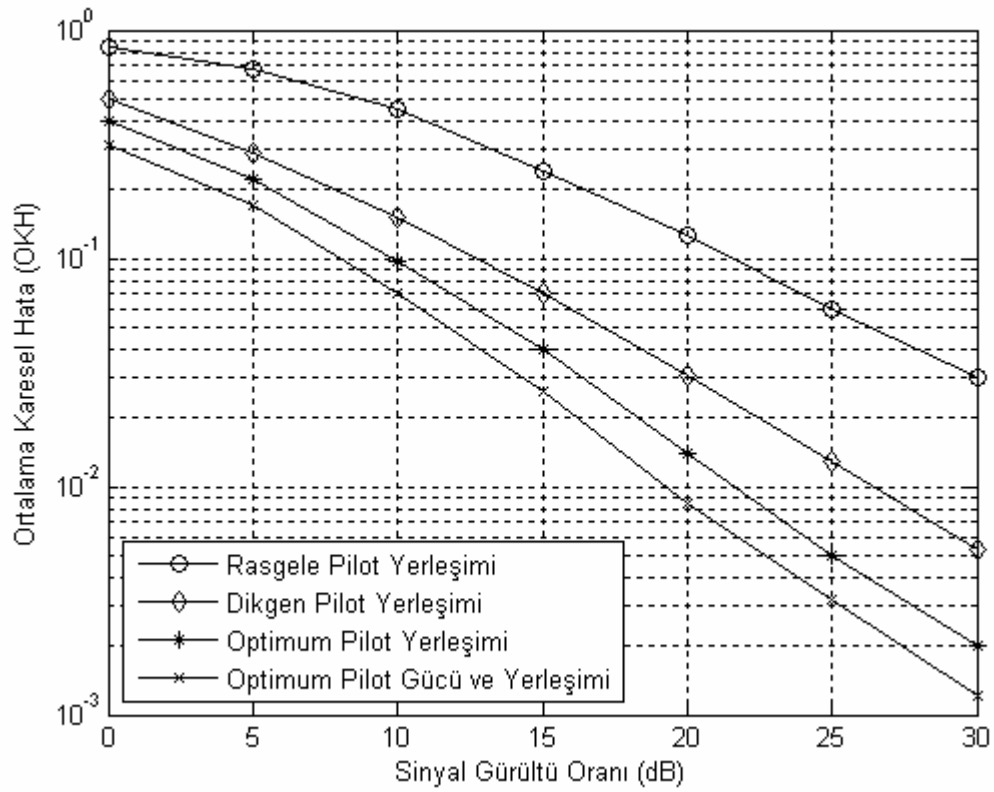
Artan Doppler kaymalarının sistem üzerindeki etkisini görmek için kanalda 40 Hz'lik Doppler kayması olması durumunda elde edilen grafikler Şekil 4.31 ve Şekil 4.32'de yer almaktadır. Şekillerden de görüleceği gibi pilot ton optimizasyonu, Doppler kaymalarının kanal kestirimci üzerinde olan etkisine karşı dayanıklılık sağlamıştır. Örneğin Şekil 4.32 incelendiğinde  $10^{-2}$  OKH değerinde yerleşim optimizasyonu dikgen yerleşimden 5 dB SGO daha iyiyken bu değer hem güç hem de yerleşim optimizasyonunda 8 dB dir.



Şekil 4.30. GA ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı.



Şekil 4.31. GA ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.32. GA ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı.

### 4.3.2. Parçacık Sürü Optimizasyonu Kullanarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi


Pilot tonların optimizasyonunda kullanılan sistem için en uygun parçacık sürü optimizasyonu parametreleri aşağıda yer almaktadır:

- Parçacık sayısı: 20
- Maksimum değişim hızı: 20
- Öğrenme faktörleri: 2
- Atalet (inertia) katsayısı: 0.9 (başlangıç), 0.4 (sonlanma).


PSO kullanılarak pilot tonların optimizasyonunda, öncelikle pilot tonların yerlerine karşılık gelen parçacıklar 0 ile 127 arasında rasgele olarak üretilir. Parçacıkların pozisyonlarının olası tüm kombinasyonları Denk. (3.12)'de yer alan uygunluk fonksiyonuna göre test edilir. Eğer parçacığın mevcut pozisyonunun uygunluk değeri, önceki en iyi pozisyonundan daha iyi ise parçacığın hızı ve konumu bölüm 4'te yer alan (4.2) ve (4.3) eşitlikleri kullanılarak güncellenir. Bu işlemler durdurma kriteri olarak seçilen 3000 tekrar yapıldıktan sonra tekrarlanır ve bu tekrarların sonucunda elde edilen en iyi global parçacıklar pilot tonların yerleşim yeri olarak seçilir. Pilot tonların gücünün optimizasyonu için pilot tonların gücünü temsil eden parçacıklar 0 ve 1 arasında rasgele olarak üretilir ve yukarıda bahsedilen işlemler yapılarak pilot tonların gücünün optimizasyonu sağlanır [105].

Şekil 4.33 ve Şekil 4.34'te, 5 Hz lik Doppler kayması olan kanaldaki pilot tonların 0-30 dB SGO'ndaki bit hata oranı (BHO) ve ortalama karesel hata (OKH) değerleri görülmektedir. Şekil 4.33'ten görüleceği gibi pilot tonların rasgele olarak yerleştirilmesi durumundaki kanal kestirimcinin performansı diğer pilot ton yerleşim yöntemlerine göre düşük kalmıştır. Örneğin rasgele yerleşim ve dikgen pilot yerleşimi arasındaki OKH farkı 30 dB SNR değerinde yaklaşık olarak  $10^{-1}$  dir. Rasgele yerleşim yerine dikgen yerleşimde olduğu gibi pilot tonların düzenli olarak yerleştirilmesi kestirimci performansının artmasını sağlayacaktır. Şekil 4.34'ten görüleceği üzere,  $10^{-2}$  BHO değerinde dikgen pilot yerleşimi rasgele yerleşime göre 10 dB daha az SGO'ya ihtiyaç duymaktadır. PSO kullanılarak pilot ton yerleşimlerinin optimize edilmesi durumunda


ise sistemin performansı artırılmıştır. 30 dB SNR değerinde optimum yerleşimli pilot tonlar, dikgen pilot yerleşimine kıyasla yaklaşık olarak  $10^{-1}$ lik BHO kazancına sahipken bu kazanç rasgele yerleşimlere göre yaklaşık olarak  $10^{-2}$  dir. Ayrıca hem pilot tonların yerleşimi hem de gücü optimize edilerek performansın daha da artırılması sağlanmıştır. Artan Doppler kaymasının sistemdeki etkisini görmek için 40 Hz lik Doppler kayması kullanılarak elde edilen simülasyon sonuçları Şekil 4.35 ve Şekil 4.36'da yer almaktadır. Bu şekillere göre Doppler kaymasının artması durumunda sistemdeki kanal kestirim hataları artmaktadır. Ancak optimum pilot tonlar kullanılması, Doppler kaymasından dolayı meydana gelen hatalara karşı bağışıklılığı artırmıştır.




Şekil 4.33. PSO ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.34. PSO ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı.



Şekil 4.35. PSO ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.36. PSO ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı.

### 4.3.3. Farksal Gelişim Algoritması Kullanarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi

Pilot tonların yerlerinin ve güçlerinin optimizasyonu için önerilen farksal gelişim algoritmasında aşağıda verilen parametreler kullanılmıştır. Verilen bu parametreler çeşitli denemeler sonucu elde edilen en optimum değerlerdir:

- Popülasyon büyüklüğü: 20
- Ölçekleme faktörü: 0.8
- Çaprazlama oranı: 0.8


Algoritma, ilk olarak pilot tonların yerlerine karşı gelen popülasyonun 0 ile 127 arasında rasgele olarak üretilen ilk değerleri ile optimizasyon işlemine başlar. Pilot tonların yerlerinin olası tüm kombinasyonları Denk. (3.12)'de yer alan uygunluk fonksiyonu kullanılarak test edilir. En iyi yerleşim yerlerinin belirlenmesi için ayrıntıları bölüm 3 te verilen mutasyon, çaprazlama ve seçim işlemleri ile güncelleme yapılır. Bu




güncelleme işlemleri simülasyon çalışmasında 2000 tekrar olarak seçilen durdurma kriteri sağlanıncaya kadar tekrar edilir. Tekrarların sonucunda en iyi yerleşim yerleri seçilerek pilot ton yerleşim optimizasyonu sonlandırılır. Pilot tonların yer optimizasyonundan sonra, pilot tonların güç optimizasyonu için başlangıç popülasyonu 0-1 arasında rasgele üretilir ve yukarıda bahsedilen mutasyon, çaprazlama ve seçim işlemleri ile olması gereken güç değerlerinin bulunması sağlanır [104].

Şekil 4.37 ve Şekil 4.38’de iletim kanalında 5 Hz lik Doppler kayması olması durumunda farksal gelişim algoritması ile optimizasyon yapılması sonucu kanal kestirimcinin performans değerlendirilmesi için bit hata oranı ve ortalama karesel hata değerleri görülmektedir. Şekillerden de görüleceği üzere, LS algoritmasının performansı optimal yerleşimli pilot tonlar kullanılarak artırılmıştır. Şekil 4.37’yi incelediğimizde artan SGO’larında bit hataların azaldığı görülmektedir. Örneğin 10 dB SGO’nda dikgen yerleşimli pilot tonlar ile optimal yerleşimli tonlar arasındaki BHO farkı  $10^{-1}$ ’den daha azdır. 30 dB SGO’da ise bu fark  $10^{-1}$ ’den daha fazla olmuştur. Pilot tonların yerleşim yerlerinin optimizasyonunun yapılmasının yanında güç optimizasyonu sayesinde performans daha da artırılmıştır. Hem gücün hem de yerleşimin optimizasyonu ile, sadece yerleşimin optimize edildiği durum arasında  $10^{-1}$  OKH değerinde 1 dB’den daha fazla SGO farkı bulunmaktadır.


Şekil 4.39 ve Şekil 4.40’ta ise 40 Hz lik Doppler kayması için pilot tonların performans değerlendirmeleri yer almaktadır. Bu şekillere göre, Doppler kaymasının artması sistemin genel performansını düşürmüştür. Örneğin Şekil 4.37 ve Şekil 4.39’taki grafikler kıyaslandığında  $10^{-3}$  BHO değerinde dikgen yerleşimli pilot tonlarda Doppler kaymasının artması 5 dB’lik SGO düşümüne neden olmuştur. Ancak bu SGO düşümü, optimum yerleşimli pilot tonlarda yaklaşık olarak 4 dB’dir. Bu sonuç optimizasyonun, Doppler kaymasına karşı sistemin daha da dayanıklılığını artırdığını göstermektedir.




Şekil 4.37. DE ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.38. DE ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı.



Şekil 4.39. DE ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.40. DE ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı.

#### 4.3.4. Yapay Arı Koloni Algoritması Kullanarak Pilot Tonların Yerlerinin ve Güçlerinin Optimize Edilmesi


Pilot tonların optimizasyonunda kullanılan yapay arı kolonisi algoritması için aşağıdaki kontrol parametreleri kullanılmıştır:

- Koloni büyüklüğü: 20
- Limit parametresi: 10
- Maksimum çevrim sayısı: 1000

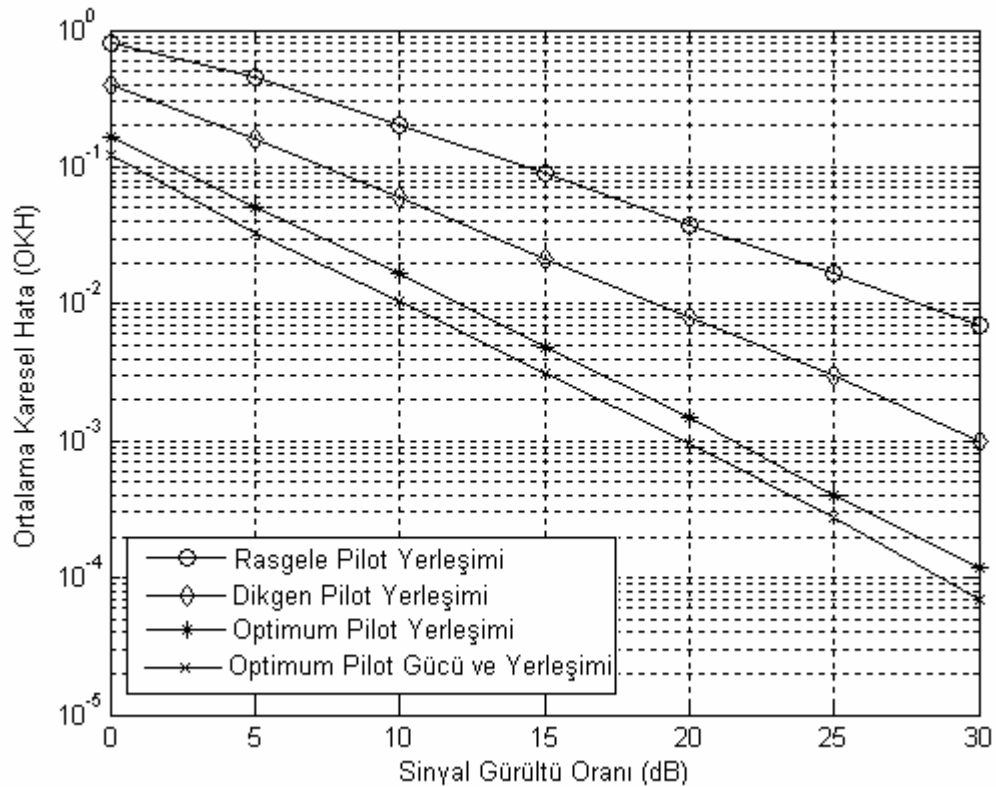
ABC algoritması kullanılarak yapılan optimizasyon işleminde, algoritmada yer alan yiyecek kaynaklarının pozisyonları pilot tonların yerlerine ya da güçlerine karşı gelmektedir. Pilot tonların optimum yerlerinin bulunması için yiyecek kaynaklarının pozisyonları 0 ile 127 arasında rasgele olarak üretilir. Daha sonrasında ayrıntıları bölüm 4'te yer alan işlemler yapılarak yiyecek kaynaklarının en iyi pozisyonlarının belirlenmesi sağlanır. Yapılan bu işlemler maksimum çevrim sayısı gerçekleşene kadar tekrarlanır ve en iyi yiyecek kaynaklarının pozisyonları pilot tonların optimal yerleşim yeri olarak kullanılır.

Önerilen ABC algoritmasının 5 Hz'lik Doppler kaymasındaki performansını değerlendirmek için Şekil 4.41 ve Şekil 4.42'de yer alan grafikler elde edilmiştir. İlgili şekillere göre; pilot tonların yerlerinin ve güçlerinin optimize edilmesi ile rasgele ve dikgen yerleşime göre dikkate değer bir performans artışı sağlanmıştır. Şekil 4.41'de optimum pilot yerleşimi,  $10^{-2}$  BHO değerinde dikgen yerleşime kıyasla 6 dB'lik SGO avantajı sağlamıştır. Aynı BHO değerinde ise rasgele yerleşime göre bu avantaj yaklaşık olarak 11 dB civarındadır. Ayrıca pilot tonların konumlarının ve güçlerinin optimize edilmesi ile dikgen yerleşime göre 30 dB SGO değerinde  $10^{-1}$ 'den daha fazla OKH farkı elde edilmiştir.

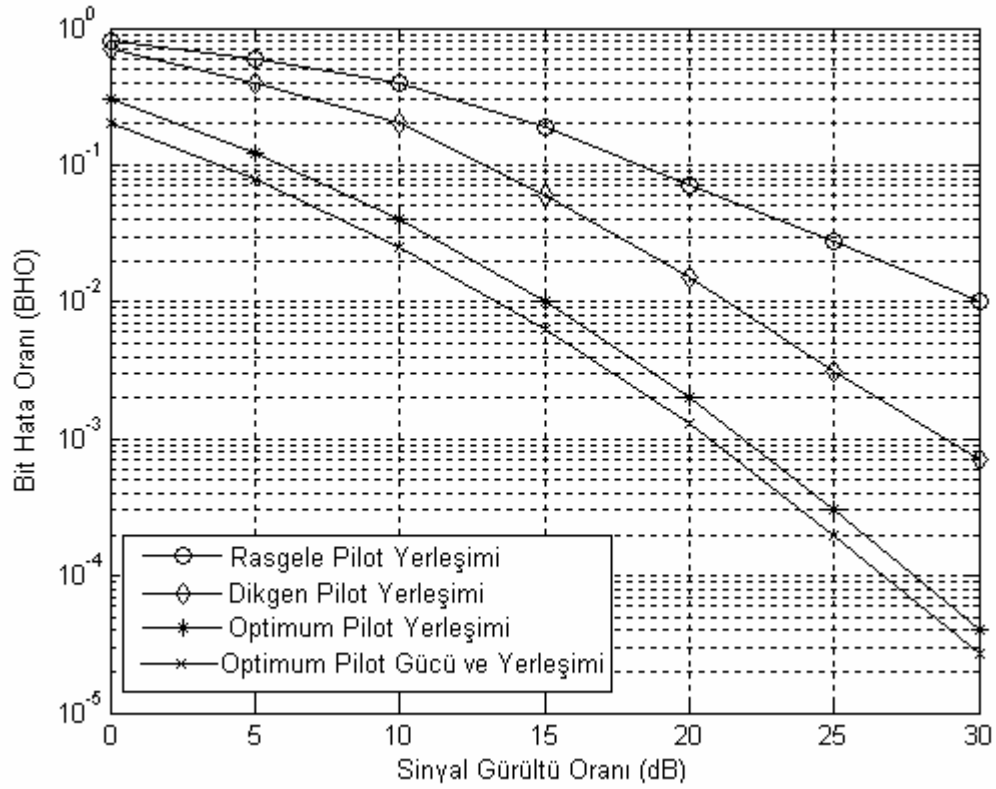
Şekil 4.43 ve Şekil 4.44'te 40 Hz lik Doppler kaymasındaki performans değerlendirmesi görülmektedir. Şekillerden de görüleceği gibi ABC algoritması ile yapılan pilot ton optimizasyonu ile kanalda meydana gelebilecek Doppler kaymalarına karşı gürbüzlük sağlanmıştır. Örneğin Şekil 4.43'te  $10^{-1}$  BHO değerinde rasgele yerleşim ve optimum yerleşim arasında 13 dB SNR farkı bulunmaktadır.




Şekil 4.41. ABC ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki BHO performansı.



Şekil 4.42. ABC ile optimize edilmiş pilot tonların 5 Hz Doppler kaymalı kanaldaki OKH performansı.




Şekil 4.43. ABC ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki BHO performansı.




Şekil 4.44. ABC ile optimize edilmiş pilot tonların 40 Hz Doppler kaymalı kanaldaki OKH performansı.

### 4.3.5. Pilot Tonların Yerlerinin ve Güçlerinin Optimizasyonu için Yapay Zeka Optimizasyon Algoritmalarının Performanslarının Kıyaslanması

Şekil 4.45 ve Şekil 4.46'da pilot tonların yerlerinin ve güçlerinin optimizasyonu için kullanılan yapay zeka optimizasyon algoritmalarının 5 Hz'lik Doppler kaymalı ortamdaki BHO ve OKH değişim grafikleri yer almaktadır. Şekil 4.45'ten görüleceği gibi ABC algoritması en iyi BHO değerine sahipken en kötü BHO değerine ise GA sahiptir. 20 dB SGO'da iki algoritma arasındaki BHO değeri  $10^{-1}$  dir.  $10^{-4}$  BHO'da ABC ile DE arasında 2.5 dB SGO farkı varken bu fark ABC ile PSO arasında ise 3.5 dB' den daha fazladır. Şekil 4.46 incelendiğinde, GA'nın OKH değeri diğer algoritmalarından daha kötü olduğu görülmektedir.  $10^{-2}$  OKH değerinde bile GA ile kendisine en yakın performans gösteren algoritma olan PSO arasında 1.5 dB'den fazla SGO farkı bulunmaktadır. Aynı OKH değerinde ise GA ile DE arasında 3 dB SGO farkı bulunmaktadır.




Şekil 4.45. Yapay zeka optimizasyon algoritmalarının 5 Hz Doppler kaymalı kanaldaki BHO performansları.




Şekil 4.46. Yapay zeka optimizasyon algoritmalarının 5 Hz Doppler kaymalı kanaldaki OKH performansları.

Şekil 4.47 ve Şekil 4.48'de pilot tonların yerlerinin ve güçlerinin optimizasyonu için kullanılan yapay zeka optimizasyon algoritmalarının 40 Hz'lik Doppler kaymalı ortamdaki BHO ve OKH değişim grafikleri yer almaktadır. Doppler kaymasının artması sistemin genel olarak performansının düşmesine neden olmuştur. Şekil 4.47'yi dikkate aldığımızda, Doppler kayma etkisine karşı en iyi dayanıklılığı ABC algoritmasının gösterdiği görülmektedir. 15 dB SGO'da, ABC algoritması ile GA arasındaki BHO farkı  $10^{-1}$  dir.  $10^{-3}$  BHO değerinde ABC ile DE arasındaki SGO farkı 1.5 dB, ABC ile PSO arasındaki SGO farkı 2.5 dB ve ABC ile GA arasındaki SGO farkı ise yaklaşık olarak 4 dB dir. Şekil 4.48'den görüleceği gibi ABC algoritmasının OKH değeri diğer algoritmalarından daha iyidir. Örneğin  $10^{-2}$  OKH değerinde ABC ile DE arasında 1 dB den fazla SGO değeri varken en kötü performans gösteren GA arasında ise 5 dB ye yakın SGO farkı bulunmaktadır.





Şekil 4.47. Yapay zeka optimizasyon algoritmalarının 40 Hz Doppler kaymalı kanaldaki BHO performansları.



Şekil 4.48. Yapay zeka optimizasyon algoritmalarının 40 Hz Doppler kaymalı kanaldaki OKH performansları.

## 5. BÖLÜM

### SONUÇ VE ÖNERİLER

Bu tezde ilk olarak yüksek hızlarda veri iletimini sağlayan MIMO-OFDM sistemlerinde kanal kestirimi için yapay zeka tekniklerinden yapay sinir ağları (YSA), radyal tabanlı sinir ağları (RBFNN) ve uyarlanabilir bulanık sinir ağları (ANFIS) önerilmiştir. Önerilen bu kestirim işlemlerinde belirtilen yapay zeka yöntemlerinin sahip olduğu öğrenme kabiliyetleri kullanılarak kanal yapısını öğrenmeleri sağlanmış ve eğitilmiş ağ yapısı kanal kestirimci olarak kullanılmıştır. Yapay zeka yöntemleri kullanılarak elde edilen kanal kestirimcilerin performansları, klasik kanal kestirim tekniklerinden kör kanal kestirimi, en küçük kareler (LS), en küçük ortalama karesel hata (LMS) ve minimum ortalamalı karesel hata (MMSE) algoritmalarının performansları ile bit hata oranı (BHO) ve ortalama karesel hata (OKH) kriterlerine göre bilgisayar ortamında simüle edilerek kıyaslanmıştır. Anten sayılarının MIMO-OFDM kanal kestirimi üzerindeki etkisini incelemek için 2x2, 4x4 ve 8x8 anten sayıları kullanılmıştır.

Elde edilen simülasyon sonuçlarına göre; önerilen her bir yapay zeka yöntemi kör kanal kestirimi, LMS ve LS algoritmasından daha iyi; MMSE algoritmasına ise yakın performans göstermiştir. Kör kanal kestiriminin çok yollu sönümlenmeli ortamda kötü sonuçlar vermesinin yanında kullanımının zor olması ve kanalın istatistiksel verilerine ihtiyaç duymasından dolayı kullanışlı bir kanal kestirimci olmadığı görülmüştür. LS algoritması ise kullanımı kolay ve fazla matematiksel işlem gerektirmeyen bir algoritmadır; ancak bu algoritmanın performansının çok yollu sönümlenmeli kanal şartlarında iyi olmadığı görülmüştür ve farklı anten sayılarına bağlı sistemlerde de yapay zeka yöntemi kullanılarak elde edilen kestirimcilerden çok daha düşük performans göstermiştir. LMS algoritması ise LS algoritmasından daha iyi performans göstermiştir ve bu algoritma da LS algoritması gibi kullanımı basit bir algoritmadır ancak bu algoritmada yer alan adım büyüklüğü parametresi sabit değerlidir ve bu

değerin uygun bir şekilde ayarlanması gerekmektedir. Bu parametrenin küçük değerli olması durumunda algoritmanın kararlı duruma ulaşması zaman almakta, aksine büyük değerli olması durumunda ise kararsızlık meydana gelmektedir. Sabit adım büyüklüğü kullanımının sönümlemeli kanaldaki zayıf başarımı ve hataya bağlı olarak adım büyüklüğünün değiştirilmesi gerekliliğinden dolayı bu algoritmanın sönümlemeli ortamlar için kullanışlı bir kanal kestirim algoritması olmadığı söylenebilir. Klasik algoritmalar içerisinde en iyi sonuçları MMSE algoritması vermiş olmasına rağmen bu algoritma yapısal olarak karmaşık ve zor bir algoritmadır. Çünkü bu algoritma, kanalın istatistiksel verilerini kullanarak kanal kestirimi yapmaktadır. Gerçek zamanlı iletim durumlarında ise kanalın istatistiksel verilerini elde etmek mümkün olmamaktadır. Bu nedenle bu algoritmanın pratik uygulamalar için kullanılabilir bir algoritma olmadığı görülmektedir. Ayrıca MMSE algoritmasında matris tersinin alınması ve korelasyon gibi matematiksel olarak zor işlemlerin yapılması gerekmektedir. Bu gibi matematiksel işlemlerin yapılması ise algoritmanın karmaşıklığını artırmakta ve bunun sonucunda ise alıcının sistem yükü artarak sistem yavaş çalışmaktadır. Ancak yapay zeka yöntemleri kullanarak yapılan kanal kestirim işleminde istatistiksel verilere ihtiyaç duyulmamaktadır. Ve yapay zeka yöntemleri ile yapılan kanal kestirimcilerin farklı anten sayılarına sahip sistemlerdeki performansları, MMSE algoritmasına yakındır. Yapay zeka yöntemlerinin içerisinde en iyi sonuçları uyarlanabilir bulanık sinir ağları vermişken en kötü sonucu ise çok katmanlı sinir ağları vermiştir. Fakat aralarındaki performans farkı fazla değildir. Yapay zeka yöntemleri kullanarak elde edilen kanal kestirimcilerin en büyük dezavantajı ise kanal şartlarının aşırı değişmesi durumunda eğitim işleminin yenilenme gerekliliğidir. Eğer belirli aralıklarla eğitim işlemi tekrar edilecek ya da çok daha büyük eğitim seti kullanılarak eğitim işlemi gerçekleştirilecek olursa bu dezavantaj da ortadan kaldırılabilir. Ancak genel olarak yapay zeka yöntemleri kullanılarak kanal kestirim işlemi yapılması ile kör kanal kestirimi, LS ve LMS algoritmalarından daha iyi performans elde edilmişken, MMSE algoritmasının sahip olduğu dezavantajlar da ortadan kaldırılmıştır.

Anten sayılarının artması durumunda ise sistemin genel olarak performansı her bir kanal kestirimci için artmaktadır. Çünkü anten sayısının artması sistemin sönümleme etkilerini azaltmış ve dolayısıyla kanal kestirim hataları daha azalmıştır. Ancak anten sayısının artması sonucu kestirilecek kanal sayısının artması nedeniyle kestirimcilere

düşen görev de artmıştır. Bu nedenle hem klasik hem de yapay zeka yöntemli kestirimcilerin yapısı biraz daha karmaşık hale gelmiştir. Elde edilen sonuçlardan yapay zeka yöntemi ile oluşturulan kanal kestirimciler klasik yöntemlere alternatif olarak kullanılabilir performansı iyi kestirimciler olarak karşımıza çıkmıştır.

Bu tez çalışmasında, ikinci olarak yapay zeka optimizasyon algoritmalarından; genetik algoritma (GA), parçacık sürü optimizasyonu (PSO), farksal gelişim (DE) algoritması ve yapay arı kolonisi (ABC) algoritması kullanılarak pilot ton tabanlı kanal kestiriminde kullanılan pilot tonların güçleri ve konumları optimize edilmiş ve LS kanal kestirim algoritmasının çok kanallı sönümlenmeli kanallardaki performansı artırılmıştır.

Pilot ton tabanlı kanal kestiriminde kullanılan pilot tonların nasıl tasarlandığı, kullanılan kestirim algoritmasının performansını doğrudan etkileyecektir. Bu nedenle pilot ton tasarımı için klasik birçok metot önerilmiştir ve önerilen bu metotlar içerisinde en iyilerinden biri dikgen yerleşimdir [46]. Ancak doğadaki çeşitli canlıların özellikleri ve davranışlarından ortaya çıkarılmış yapay zeka optimizasyon algoritmalarının farklı problemlerin optimum noktalarının bulunmasında iyi sonuçlar vermesinden yola çıkarak pilot tonların yerleşim yerleri ve güçlerinin optimum noktalarının bulunabileceği görülmüş bu parametreler optimize edilerek elde kanal kestirim sonuçları ve rasgele yerleşim ve dikgen yerleşimli sonuçlar ile bilgisayar ortamında mukayese edilmiştir. Yapılan simülasyonlarda yapay zeka algoritmaları kullanarak pilot tonların yerlerinin optimizasyonu ile gerek rasgele yerleşime göre gerekse dikgen yerleşime göre daha iyi bit hata oranı (BHO) ve ortalama karesel hata (OKH) sonuçları elde edilmiştir. Elde edilen sonuçlardan pilot tonların optimizasyonunun kanal kestirimcinin performansı üzerinde önemli bir etkiye sahip olduğu görülmüştür. Çünkü pilot tonların optimum yerleşimi, çok yollu sönümlenmeli kanalın bozucu etkilerini azaltmış ve LS kestirim algoritmasının kestirim hatalarını daha da azaltmıştır. Pilot tonların yerlerinin optimizasyonunun yanında, pilot tonların güçlerinin de optimizasyonu ile LS kanal kestirimcinin performansı daha da artırılmıştır. Ayrıca artan Doppler kaymalarının pilot ton tasarımına olan etkisini incelemek için farklı Doppler kaymasına sahip kanallardaki iletim durumları da incelenmiştir. Doppler kaymasının artması sistemin performansını azaltmış olsa da pilot tonların optimize edilmesi ile Doppler etkileri rasgele ve dikgen yerleşimli pilot tonlara göre daha az indirilmiştir.

Pilot tonların yerlerinin ve güçlerinin optimizasyonunda kullanılan yapay zeka algoritmaları içerisinde en iyi performansı yapay arı koloni algoritması gösterirken en düşük performansı ise genetik algoritma göstermiştir. Ayrıca ABC algoritması için gerekli tekrar sayısı da diğer algoritmalarından daha azdır. Elde edilen simülasyon sonuçlarına göre; yapay zeka yöntemleri ile pilot tonların optimize edilmesi LS kestirim algoritmasının performansını artırmıştır. Bu yüzden bu yöntemler kullanılarak kestirimci performansının en üst düzeye çıkarılması sağlanacaktır.

Sonraki yapılacak çalışmalarda, yapay zeka yöntemleri ile MC-CDMA ve dalgacık paket modülasyonu gibi haberleşme sistemlerinde kanal kestirimi yapılarak mevcut klasik yöntemlerin dezavantajları ortadan kaldırılabilir. Bu sayede hem sistem yükü azaltılacak hem de çoklu yol etkileri en aza indirilerek yüksek performans elde edilecektir. Ayrıca dalgacık paket modülasyonu yada MC-CDMA gibi sistemlerde pilot ton tabanlı kanal kestiriminde yer alan pilot tonların konumları bu tez çalışmasında önerdiğimiz gibi yapay zeka optimizasyon algoritmaları kullanılarak optimize edilerek kullanılacak kanal kestirim algoritmasının performansının daha iyi olması ve kanalın bozucu etkilerine karşı dayanıklı olması sağlanabilir.

## KAYNAKÇA

1. Stüber, G. L., 2002. Principles of Mobile Communication. Kluwer Academic Publishers, 752 pp.
2. Weinstein S. B., Ebert P.M., 1971. Data transmission by frequency division multiplexing using the discrete Fourier transform, **IEEE Transactions on Communication Technology**, **19** (3): 628-634.
3. Cimini L. J., Jr., 1985. Analysis and simulation of digital mobile channel using orthogonal frequency division multiplexing, **IEEE Transactions on Communications**, **33** (7): 665-675.
4. Van Nee R., Prasad R., 2000. OFDM for wireless multimedia communications, Artech House, London, 260 pp.
5. Heiskala, J., Terry, J., 2001. OFDM Wireless LANs: A Theoretical And Practical Guide, SAMS Publishing, 336 pp.
6. Seyman M. N., 2005. Dikgen Frekans Bölüşümlü Çoğullama (OFDM) Sistemlerinde Senkronizasyon Teknikleri, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 91 s.
7. Sadat A., Mikhael W. B., 2001. Fast Fourier transform for high speed wireless multimedia system, **IEEE Transactions on Signal Processing**, **65** (3): 938-942.
8. Banelli P., Cacopardi, S., 2000. Theoretical analysis and performance of OFDM signals in nonlinear AWGN channels, **IEEE Transactions on Communications**, **48** (3): 430-441.
9. Gee, P., Zaghoul, H., Wideband Orthogonal Frequency Division Multiplexing (W-OFDM), Wi-LAN's W-OFDM Patents, US patent 5 282 222, June 20, 2000.
10. Sumasu, A., Okada M., Komaki S., Yamamoto H., 2000. Orthogonal polarization and frequency division multiplexing (OPFDM): a new

multicarrier modulation scheme robust to random FM noise, **Electronics and Communications in Japan**, **83** (9): 57-66.

11. Lu, J., Tjhung T. T., Adachi F., Huang C. L., 2000. BER performance of OFDM-MDPSK system in frequency-selective rician fading with system in frequency-selective -rician fading with diversity reception, **IEEE Transactions on Vehicular Technology**, **49** (4): 1216-1225
12. Wan, L., Dubey, V. K., 2001. BER performance of OFDM system over frequency nonselective fast Ricean fading channels, **IEEE Communications Letters**, **5** (1): 19-21.
13. Banelli P., Cacopardi, S., 2000. Theoretical analysis and performance of OFDM signals in nonlinear AWGN channels, **IEEE Transactions on Communications**, **48** (3): 430-441.
14. Dardari, D., Tralli, V., 1999. High-speed indoor wireless communications of 60 GHz with coded OFDM, **IEEE Transactions on Communications**, **47** (11): 1709-1721.
15. 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.
16. Keller T., Hanzo L., 2000. Adaptive modulation techniques for duplex OFDM transmission, **IEEE Transactions Vehicular Technology**, **49** (5): 1893-1905.
17. Catreux S., Erceg V., Gesbert D., Heath R., 2002. Adaptive modulation and MIMO coding for broadband wireless data networks, **IEEE Communication Magazine**, **40** (6): 108-115.
18. Arogyaswami, J. P., Dhananjay, A. G., Rohit, U. N., Helmut, B., 2004. An overview of MIMO communications-a key to gigabit wireless, **Proceedings of the IEEE**, **92** (2): 198-218.

19. Gordon, L.S, John, R. B., Steve, W. M., Ye, L., Marry, A. I., 2004. Broadband MIMO-OFDM wireless communications, **Proceedings of the IEEE**, **92** (2): 271-294.
20. Sampath H., Talwar S., 2002. A fourth-generation MIMO-OFDM broadband wireless systems: design, performance and trial results. **IEEE Communication Magazine**, **40** (9): 143-149.
21. Alamouti S. M., 1998. A Simple transmit diversity scheme for wireless communications. **IEEE Journals on. Selected Areas Communications**, **16** (10): 1451-1458.
22. Tarokh, V., Seshadri, N., Calderbank A.R., 1998. Space-time codes for high data rate wireless communication: performance criterion and code construction, **IEEE Transactions Information Theory**, **44** (2): 744-765.
23. Bölcskei, H., David, G., Arogyaswami, J. P., 2001. On the capacity of OFDM-based spatial multiplexing systems, **IEEE Transactions on Communications**, **50** (2): 225-234.
24. S. Liang, W. Wu., 2003. Channel estimation based on pilot subcarrier in space-time block coded OFDM system, pp. 1795-1798. *IEEE International Conference on Communication Technology, April 9-11, 2003 ,Beijing, China.*
25. Liang S., Wu W., 2003. Channel estimation based on pilot subcarrier in space-time block coded OFDM system, pp. 1795-1798, *IEEE International Conference on Communication Technology, April 9-11, 2003, Beijing, China. .*
26. European Telecommunications Standards Institute (ETSI), Radio Broadcasting Systems; Digital Audio Broadcasting (DAB) to Mobile, Portable and Fixed Receivers, European Telecommunication Standard ETS 300 401, 1st edition, reference DE/JTC-DAB, February 1995. Available from the ETSI Secreteriat, F-06921 Sophia Antipolis Cedex, France.
27. European Telecommunications Standards Institute (ETSI), Digital Video Broadcasting (DVB); Framing Structure, Channel Coding and Modulation for Digital Terrestrial Television, European Telecommunications Standard,



- ETSI 300 744 1st edition, reference DE/JTC-DVB-8, March 1997. Available from the ETSI Secretariat, F-06921 Sophia Antipolis Cedex, France.
28. European Telecommunications Standards Institute (ETSI), Broadband Radio Access Networks (BRAN); Inventory of Broadband Radio Technologies and Techniques, Technical Report, reference DTR/BRAN-030001, February 1998. Available from the ETSI Secretariat, F-06921 Sophia Antipolis Cedex, France.
  29. European Telecommunications Standards Institute (ETSI), OFDMA Evaluation Report-The Multiple Access Scheme Proposal for the UMTS Terrestrial Radio AirInterface (UTRA), Technical Document Tdoc 896/97, ETSI SMG meeting no. 24, Madrid, December 1997. Available from the ETSI Secretariat, F-06921 Sophia Antipolis Cedex, France.
  30. 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.*
  31. 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.
  32. 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.
  33. 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.
  34. 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.
  35. 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.

36. Harjula I., Mammela A., 2003. Channel estimation algorithm for space-time block coded OFDM systems, pp.143-147, *IEEE Global Communications Conference, December 1-5, 2003, San Francisco, USA.*
37. Liang Y., H. Luo, J. Huang. 2005. Adaptive RLS channel estimation in MIMO-OFDM systems, pp. 79-82, *IEEE International Symposium on Communication and Information Technology, October 14-19, 2005, Beijing, China.*
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. 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.
40. Tavassoli F., B. Abolhassani, 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.*
41. Özen, A., B. Soysal, İ. Kaya, 2004. OFDM sistemlerinde kanal kestirimi ve izlemesi için yapay sinir ağı destekli bir LMS algoritması geliştirme, pp. 212-215, *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 28-30, 2004, Aydın, Türkiye.*
42. Çevik, M., H. A. Çırpan, E. Panayırıcı, 2002. OFDM sistemlerinde kanal kestirimi için koşulsuz en büyük olabilirlik yaklaşımı, pp. 1279-1282, *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Haziran 12-14, 2002, Pamukkale, Türkiye.*
43. Panayırıcı, E., H. A. Çırpan, O. Oğuz, 2002. Çok yollu sönmlemenin varlığında, uzay-zaman blok kodlanmış OFDM sistemler için kanal kestirimi, pp. 1289-1294, *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Haziran 12-14, 2002, Pamukkale, Türkiye.*

44. 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**: 3-9.
45. Ogava, 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.
46. Barhumi I., Leus G., Moonen M., 2003. Optimal training design for MIMO OFDM systems in mobile wireless channels, **IEEE Transactions on Signal Processing**, **51** (6): 1615-1624.
47. Minn H., Al-Dhair N., Li T., 2006. Optimal training signals for MIMO-OFDM channel estimation in presence of frequency offset and phase noise, **IEEE Transactions on Communications**, **54** (10): 1745-1759.
48. Dong M., Tong L., 2002. Optimal design and placement of pilot symbols for channel estimation, **IEEE Transactions on Signal Processing**, **50** (12): 3055-3068.
49. Lin C., Quin L., Zhang W., Xu Y., Li H., 2010. Optimal training design and placement for MIMO-OFDM frequency division multiplexing channel estimation, **Journal of Shanghai Jiatong University** **15** (1): 58-63.
50. Panah A. Y., Vaughan R. G., Heath R., 2009. Optimization pilot locations using feedback in OFDM systems, **IEEE Transactions on Vehicular Technology**, **58** (6): 2803-2814.
51. Minn H., Kim D. I., Bhargava V., 2002. A reduced complexity channel estimation for OFDM systems with transmit diversity in mobile wireless channels, **IEEE Transactions on Communications**, **50** (5): 799-807.
52. Hu D., Yang L., Shi Y., He L., 2006. Optimal pilot sequence design for channel estimation in MIMO OFDM systems, **IEEE Communication Letters**, **10** (1): 1-3.

53. Onho, S., Giannakis, G.B., 2004. Capacity maximizing MMSE-optimal pilots for wireless OFDM over frequency-selective block Rayleigh fading channel, **IEEE Transactions on Information Theory**, **50** (9): 2138-2145.
54. Cai, X., Giannakis, G.B., 2004. Error probability minimizing pilots for OFDM with M-PSK modulation over Rayleigh-fading channels, **IEEE Transactions on Vehicular Technology**, **53** (1): 146-155.
55. Samardzija, D., Mandayam, N., 2003. Pilot- assisted estimation of MIMO fading channel response and achievable data rates, **IEEE Transactions on Signal Processing**, **51** (11): 2882-2890.
56. Hassibi, B., Hochwald, B.M., 2003. How much training is needed in multiple antenna wireless links, **IEEE Transactions on Information Theory**, **49** (4): 951-963.
57. Ma, X., L. Yang, G. B. Giannakis, 2002. Optimal training for MIMO frequency-selective fading channels, pp. 1107-1111, *The 36th Asilomar Conference on Signals, Systems, and Computers, November 3-6, 2002, Pacific Grove, USA*.
58. Manton J. H., 2001. Optimal training sequences and pilot tones for OFDM systems, **IEEE Communication Letters**, **5** (4): 151-153.
59. Laguna-Sanchez G.A., Barron-Fernandez R., 2009. Blind channel estimation for powerline communications by a PSO-inspired algorithm”, pp. 1-6, *IEEE Latin Conference on Communication (LATINCOM 09), September 10-11, Medellin, Colombia*.
60. D’Orazio L., Sacchi C., Doneli M., 2010. Adaptive channel estimation for STBC-OFDM systems based on nature-inspired optimization strategies, pp. 188-198, *3rd International Workshop of Multiple Access Communication (MACOM 2010), September 13-14, Barcelona, Spain*.
61. Hagan, M.T., Demuth, H.B., Beale, M., Neural Network Design, PWS Publishing Company, Boston, 1995, 734 pp.
62. Zurada J.M., 1992. Introduction to Artificial Neural Networks, West Publishing Company, 758 pp.

63. Hagan M. T., Menhaj B., 1994. Training feed forward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, **5** (6): 989-993.
64. Poggio T. Girosi F., 1990. Networks for approximation and learning, **Proceeding of the IEEE**, **78** (12): 1481-1497.
65. Sağiroğlu Ş., Beşdok E., Erler M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları, *Ufuk Kitap Kırtasiye Yayıncılık, Kayseri*, 426 s.
66. 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, pp. 1-7.
67. 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.
68. 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.
69. Jang, J. S., Sun, C. T., 1995. Neuro-Fuzzy Modeling and Control, **Proceedings of the IEEE**, **83** (3): 378-406.
70. Seyman M. N., Taspınar N., 2008. Channel estimation based on adaptive neuro-fuzzy inference system in OFDM, **IEICE Transactions on Communications**, **E91-B(7)**: 2426-2430.
71. Seyman M. N., Taşpınar N., 2008. Channel estimation for OFDM systems using radial basis function networks, *Proceedings of the 6th International Conference on Electrical Engineering (ICEENG-2008)*, 27-29 May, 2008, Cairo, Egypt.
72. Taspınar N, Seyman M. N., 2010. Back propagation neural network approach for channel estimation in OFDM system, pp. 265-268, *IEEE International*

*Conference on Wireless Communication, Networking, and Information Security (WCNIS 2010), 25-27 June, 2010, Beijing, China.*

73. Seyman M. N., Taşpınar N., 2009. Çok katmanlı yapay sinir ağları kullanarak OFDM sistemlerinde kanal dengeleme, pp. 630-633, 5. *Uluslararası İleri Teknolojiler Sempozyumu (IATS-09), 13-15 Mayıs 2009, Karabük, Türkiye.*
74. Zhou X., Wang X., 2003. Channel estimation for OFDM systems using adaptive radial basis function Networks, **IEEE Transactions on Vehicular Technology**, **51** (1): 48-59.
75. Sun J., Yuan D.F., 2006. Neural network channel estimation based on least mean error algorithm in the OFDM systems, **Lecture Notes in Computer Science**, **3972**: 706-711.
76. Chen E., Tao R., Zhao X., 2006. Channel equalization for OFDM system based on the BP neural network, *8th International Conference on Signal Processing, November 16-20, 2006, Guilin, China.*
77. Charalabopoulos G., P. Stavroulakis, A. H. Aghvami, 2003. A frequency domain neural network equalizer for OFDM, pp. 571-575, *IEEE Global Communication Conference, December 1-5, 2003, San Francisco, USA.*
78. Zhang J., He Z., Wang X., Huang Y., 2007, TSK fuzzy approach to channel estimation for MIMO-OFDM systems, **IEEE Signal Processing Letters**, **14** (6): 381-384.
79. Chen, S., Wu, Y., 1998. Maximum likelihood joint channel and data estimation using genetic algorithms, **IEEE Transactions on Signal Processing**, **46** (5): 1469-1473.
80. Hernandez, R.M., Jain, V.K., 1998. Blind Channel and Symbol Estimation For Wireless Communications Via An Affinity Neural Network, pp. 386-395, *Signal Processing. Systems. (SIPS), October 8-10, 1998, Cambridge, U.K..*
81. Zhang L., Zhang X., 2007. MIMO channel estimation and equalization using tree layer neural network with feed back, **Journal of Tsinghua Science and Technology**, **12** (6): 658-662.

82. Zhou X., Wang X.. 2003. Channel estimation for OFDM systems using adaptive radial basis function networks, **IEEE Transactions on Vehicular Technology**, **51** (1): 48-59.
83. Cui T., Tellambura C., 2004. Channel estimation for OFDM systems based on adaptive radial basis function network, pp. 608-611, *IEEE 60 th Vehicular Technology Conference, September 26-29,2004, Los Angeles, USA.*
84. Moffa G., 2006. OFDM channel equalization based on radial basis function Networks, **Lecture Notes in Computer Science**, **4132**: 201-210.
85. Wen J. H., C. Y. Chang, G. R. Lee, C. Y. Huang, 2006. OFDM channel prediction using fuzzy update LMS algorithm in time-variant mobile channel, pp. 1-5, *IEEE 64th Vehicular Technology Conference, September 25-28, 2006, Montreal, Canada.*
86. Holland J. H., 1975. *Adaptation in Natural and Artificial Systems*, University of Michigan Press, Ann Arbor, MI., 183 pp.
87. Goldberg D. E., 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison- Wesley, Reading MA. pp.412.
88. Goldberg D. E., Korb B. Deb K., 1989. Messy genetic algorithms: motivation, analysis and first results, **Complex Systems**, **3**: 493-530.
89. Karaboğa D., 2004. *Yapay Zeka Optimizasyon Algoritmaları*, Nobel Yayınevi, Ankara, 199s.
90. Kennedy J., Eberhart R. C., 1995. Particle swarm optimization, pp. 1942-1948, *IEEE International Conference on Neural Networks, November 27, December 1, 1995, Piscataway, NJ.*
91. Shi Y., Eberhart R. C., 1998. A modified particle swarm optimizer, pp. 69-73, *IEEE International Conference on Evolutionary Computation, May 9, 1998, Piscataway, NJ.*
92. Shi Y., Eberhart R. C., 1998. Parameter selection in particle swarm optimization, pp. 291-300, *7 th Annual Conference on Evolutionary Programming, March 25-27, 1998, Berlin Germany.*

93. Storn R., 1997. Differential evolution: a simple and efficient heuristic strategy for global optimization over continuous spaces, **Journal of Global Optimization**, **11**: 341-359.
94. Storn, R., 1996. On the usage of differential evolution for function optimization, pp: 519-523, Biennial Conference of the North American Fuzzy Information Processing Society, *June. 19-22, 1996, Berkeley, CA.*
95. Karaboğa N., 2005. Digital IIR filter design in using differential evolution algorithm, **EURASIP Journal on Applied Signal Processing**, **8**: 269-1276.
96. Rahnamayan S., Tizhoosh H. R., Salama M. M. A., 2008. Opposition based differential evolution, **IEEE Transactions on Evolutionary Computation**, **12** (1): 64-79.
97. Wu Z., H. Huang, X. Zhang., B. Yang, H. Dong, 2008. Adaptive equalization using differential evolution, pp. 1962-1967, *IEEE World Congress on Computational Intelligence, June 1-6, 2008, Hong Kong.*
98. Karaboga D., 2005. An idea based on honey bee swarm for numerical optimization, Technical report-TR06,Erciyes University, Engineering Faculty, Computer Engineering Department.
99. Karaboga D., Akay B., 2009. A survey: algorithms simulating bee swarm intelligence, **Artificial Intelligence Review**, **31** (1): 68-85.
100. Karaboga D.,Basturk B. 2007. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, **Journal of Global Optimization**, **39** (3): 459-471.
101. Karaboga D., Basturk B., 2008. On the performance of artificial bee colony (ABC) algorithm, **Applied Soft Computing**, **8** (1): 687-697.
102. Karaboga D., Akay B., 2009. A comparative study of artificial bee colony algorithm, **Applied Mathematics and Computation**, 214: 108-132.
103. Karaboga D., Basturk Akay B., 2007. Artificial bee colony algorithm on training artificial neural networks, pp. 1-4, *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Haziran 11-13, 2007, Eskişehir, Türkiye.*



104. Seyman M. N., Taşpınar N., 2011. Optimization of pilot tones using differential evolution algorithm in MIMO-OFDM systems, Accepted for publication in **Turkish Journal of Electrical Engineering & Computer Science**, 2011.
105. Seyman M. N., Taşpınar N., 2011. Particle swarm optimization for pilot tones design in MIMO-OFDM systems, **EURASIP Journal on Advances in Signal Processing**, 2011.
106. Gerschgorin, S., 1931. Über die Abgrenzung der Eigenwerte einer Matrix. *Izv. Akad. Nauk. USSR Otd. Fiz.-Mat. Nauk*, 7: 749–754.
107. Golub G.H., Loan C.F.V., *Matrix Computations*, Baltimore, Hopkins University Press, 1996, 320 pp.
108. Stuber G. L., 2001. *Principle of Mobile Communications*, 2nd ed. Kluwer, Norwell, MA, 688 pp.

# ÖZGEÇMİŞ

## KİŞİSEL BİLGİLER

Adı, Soyadı: Muhammet Nuri SEYMAN

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 22 Kasım 1979, Dinar

Medeni Durumu: Bekâr

Tel: +90 318 357 42 42 (3011)

Fax: +90 318 357 29 23

e-mail: [mnseyman@kku.edu.tr](mailto:mnseyman@kku.edu.tr)

Yazışma adresi: Kırıkkale Üniversitesi Kırıkkale Meslek Yüksekokulu 71450

Yahşihan/KIRIKKALE

## EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lise	Sandıklı Yab. Dil Ağırlıklı Lisesi Afyonkarahisar	1998
Lisans	Erciyes Üniversitesi M.F. Elektronik Mühendisliği	2003
Yüksek Lisans	Erciyes Üniversitesi Fen Bilimleri Enstitüsü	2005

## İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2005-Halen	Kırıkkale Üniversitesi K.M.Y. O	Öğretim Görevlisi

## YABANCI DİL

İngilizce

## YAYINLAR

- Seyman M. N., Taşpınar N., “Channel Estimation Based on Adaptive Neuro-Fuzzy Inference System in OFDM”, IEICE Transactions on Communication, vol: E91-B, no: 07, pp. 2426-2430 (2008).
- Seyman M. N., Taşpınar N., “Optimization of Pilot Tones Using Differential Evolution Algorithm in MIMO-OFDM Systems”, Accepted for publication in Turkish Journal of Electrical Engineering & Computer Science , (2011).
- Seyman M. N., Taşpınar N., “Particle Swarm Optimization for Pilot Tones Design in MIMO-OFDM Systems”, EURASIP Journal on Advances in Signal Processing, (2011).

4. Seyman M. N., Taşpınar N., “Channel Estimation for OFDM Systems Using Radial Basis Function Networks”, Proceedings of the 6th International Conference on Electrical Engineering (ICEENG-2008), Cairo, Egypt, 27-29 May, 2008.
5. Taşpınar N, Seyman M. N., “Back Propagation Neural Network Approach for Channel Estimation in OFDM System”, Proceedings of the IEEE International Conference on Wireless Communication, Networking, and Information Security (WCNIS 2010), pp.265-268, Beijing, China, 25-27 June, 2010.
6. Seyman M. N., Taşpınar N., “Çok Katmanlı Yapay Sinir Ağları Kullanarak OFDM Sistemlerinde Kanal Dengeleme”, 5. Uluslararası İleri Teknolojiler Sempozyumu (IATS-09), pp.630-633, Karabük, 13-15 Mayıs 2009.
7. Seyman M. N., Taşpınar N., “MIMO-OFDM Sistemlerinde Eğitim Sembolleri Kullanarak Kanal Kestirimi” III. İletişim Teknolojileri Ulusal Sempozyumu (ITUSEM 2007), pp. 119-122, Adana, 18-19 Ekim 2007.
9. Seyman M. N., Tuna E., Taşpınar N., “OFDM Sistemlerinde Pilot Ton Eklemeli Kanal Kestirim Yöntemlerinin Rayleigh Sönümlü Kanal İçin Performanslarının İncelenmesi”, III. İletişim Teknojileri Ulusal Sempozyumu (ITUSEM 2007), pp. 123-126, Adana, 18-19 Ekim 2007.
10. Tuna E., Seyman M. N., Özyazgan G., Taşpınar N., “OFDM Sistemlerinde Pilot Ton Eklemeli Kanal Kestirim Yöntemleri”, 12. Elektrik, Elektronik, Bilgisayar, Biyomedikal Mühendisliği Ulusal Kongresi ve Fuarı, pp. 501-504, Eskişehir, 14-18 Kasım 2007.
11. Seyman M.N., Taşpınar N., “MIMO-OFDM Sistemlerinde Kanal Kestirim Algoritmalarının Performanslarının Çoklu Sönümlmeli Kanal İçin İncelenmesi”, 1. Mühendislik ve Teknoloji Sempozyumu, pp.142-147, Ankara, 24-25 Nisan 2008.
- 12 Seyman M. N., Taşpınar N., “Dikgen Frekans Bölüşümlü Çoğullama (OFDM) Sistemlerinde kullanılan Senkronizasyon Teknikleri”, II. İletişim Teknolojileri Ulusal Sempozyumu (ITUSEM 2005), pp. 103-107, Adana, 17-19 Kasım 2005.
13. Seyman M. N., Taşpınar N., “Dikgen Frekans Bölmeli Çoğullama Sistemlerinde Çevrimsel Ön Takı Tabanlı Senkronizasyon Tekniğinin AWGN ve Rayleigh Sönümlü

- Kanallardaki Performansının İncelenmesi”, 3. URSI Bilimsel Kongresi (URSI 2006), pp. 499-501, Ankara, 06-08 Eylül 2006.
14. Seyman M. N., Özdemir G., Taşpınar N., “Uçak İçi OFDM Tabanlı Kablosuz İnternet Erişimi”, Kayseri VII. Havacılık Sempozyumu, pp. 282-285, Kayseri, 15-16 Mayıs 2008.
15. Seyman M. N., Taşpınar N., “Dikgen Frekans Bölmeli Çoğullama Sistemlerinin Uçak Haberleşmesinde Kullanılması”, II. Ulusal Havacılık ve Uzay Sempozyumu, İTÜ, İstanbul, 15-17 Ekim 2008.
16. Yaman H., Seyman M. N., Taşpınar N., Uzun İ., “GSM Tabanlı Taşıt Kontrol Uygulaması”, 5. Uluslararası İleri Teknolojiler Sempozyumu (IATS-09), pp.2052-2055, Karabük, 13-15 Mayıs 2009.
17. Işık Y., Taşpınar N., Seyman M. N., “Kod Bölmeli Çoklu Erişim Sistemlerinde Güç Seviyesinin Yapay Sinir Ağları İle Kontrol Edilmesi Üzerine Değerlendirmeler” Kırıkkale Üniversitesi International Journal of Engineering Research and Development, 2(1), pp. 2-6, (2010).
18. Seyman M. N., Taşpınar N., “Dikgen Frekans Bölmeli Çoğullama Sistemlerinde Pilot Ton Tabanlı Senkronizasyon Tekniği” Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22 (1-2), pp. 75-82, (2006).
19. Yaman H., Seyman M. N., Taşpınar N., “Mikrodenetleyici Tabanlı Çok Kanallı RF Sinyalleri ile Taşıt Kontrolü”, 1. Mühendislik ve Teknoloji Sempozyumu, pp. 136-141, Ankara, 24-25 Nisan 2008.