



T.C.

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞI YÖNTEMİ KULLANARAK MİKROŞERİT YAMA
ANTENLERİN REZONANS FREKANSI VE YARI GÜÇLÜ İŞİMA
GENİŞLİĞİNİN İNCELENMESİ**

HAMDULLAH ÖZTÜRK

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

HATAY

OCAK-2018

T.C.
İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SINIR AĞI YÖNTEMİ KULLANARAK MİKROŞERİT YAMA
ANTENLERİN REZONANS FREKANSI VE YARI GÜÇLÜ İŞİMA
GENİŞLİĞİNİN İNCELENMESİ**

HAMDULLAH ÖZTÜRK

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

HATAY
OCAK-2018

T.C.
İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Tezin Adı: Yapay sinir ağı yöntemi kullanarak mikroşerit yama antenlerin rezonans frekansı ve yarı güçlü ışımaya genişliğinin incelenmesi

Öğrencinin, Adı Soyadı: Hamdullah Öztürk

Tez Savunma Tarihi: 19.01.2018

Kod No: 79

Doç. Dr. Mustafa Demirci
Enstitü Müdürü

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylıyorum.

Doç. Dr. Emin Ünal
Enstitü ABD Başkanı

Bu tez tarafımızca okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans tezi olarak kabul edilmiştir.

Yrd. Doç. Dr. Oğuzhan Akgöl
İkinci Tez Danışmanı

Doç. Dr. Yakup Hameş
Tez Danışmanı

Bu tez tarafımızca okunmuş, kapsam ve niteliği açısından bir Yüksek Lisans tezi olarak oy birliği/oy çokluğu ile kabul edilmiştir.

Jüri Üyeleri (Ünvanı, ADI ve SOYADI):

İmzası

Doç. Dr. Yakup Hameş

.....

Doç. Dr. Muharrem Karaaslan

.....

Doç. Dr. Serdar Yıldırım

.....

Yrd. Doç. Dr. Oğuzhan Akgöl

.....

Yrd. Doç. Dr. Yakup Kutlu

.....

Not : Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

19.01.2018

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını ve tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu beyan ederim.

İmza

.....

ÖZET

YAPAY SİNİR AĞI YÖNTEMİ KULLANARAK MİKROŞERİT YAMA ANTENLERİN REZONANS FREKANSI VE YARI GÜÇLÜ IŞIMA GENİŞLİĞİNİN İNCELENMESİ

Mikroşerit antenler, kolay üretilebilme, düşük maliyet ve küçük boyutlarda tasarlanabilme gibi birçok avantaja sahiptir. Bundan dolayı, kablosuz iletişimlerde, uydu ve radar sistemleri gibi birçok uygulamada tercih edilmektedir. Mikroşerit antenler kare, dikdörtgen ve dairesel gibi birçok farklı şekilde tasarlanabilmektedir.

Bu çalışmada yapay sinir ağı (YSA) yöntemi kullanarak, mikroşerit yama antenlerin rezonans frekansı ve yarı güçlü ışımaya genişliğinin incelenmesi amaçlanmıştır. Çalışmada H şekilli mikroşerit yama anten tasarımı, simülasyonu, YSA modellemesi ve üretimi yapılmıştır.

Deterministik bir analiz yöntemi olan YSA, farklı birçok problemlere uygulanabilmesi ve başarılı sonuçlar vermesinden dolayı tercih edilmiştir. Ayrıca, mikroşerit antenlerin tasarımı sırasında geçen zaman kaybını önlemesi, daha düşük maliyet ile işlemi gerçekleştirebilmesi, daha kısa süre içerisinde sonuç vererek üretime geçilebilmesi ve matematiksel işlemlere gerek duyulmaması gibi özelliklerinden dolayı yapay sinir ağı yöntemi bu çalışmada kullanılmıştır. Model geliştirilmesinde kullanılmak üzere 390 farklı parametreye sahip anten tasarımı yapılmış ve analizi gerçekleştirilmiştir. YSA modeli Levenberg Marquart ve Bayesian Regularization eğitim algoritmaları, tek ve çok katmanlı model tipleri ve farklı nöron sayıları kullanılarak gerçekleştirilmiştir. Sonuçlar değerlendirilmiş, en uygun parametreye sahip model, anten tasarımı için tercih edilerek üretilmiştir. Sonuç olarak simülasyon sonuçları, model sonuçları ve üretilmiş antenin ölçüm sonuçları karşılaştırılmıştır.

2018, 67 sayfa

Anahtar Kelimeler: Mikroşerit anten, rezonans frekansı, yayılım genişliği açısı, yapay sinir ağları, ortalama hata oranları

ABSTRACT

INVESTIGATION OF THE RESONANCE FREQUENCY AND HALF- POWER BEAMWIDTH OF MICROSTRIP PATCH ANTENNAS BY USING ARTIFICIAL NEURAL NETWORK METHOD

Microstrip antennas have many advantages such as easy fabrication, low cost and small size design. So, they are preferred in many applications like wireless communications, satellite and radar systems. Microstrip antennas can be designed in many different shapes; square, rectangular and circular.

In this study, it is aimed to investigate the resonance frequency and the half-power beamwidth of microstrip patch antennas using artificial neural network (ANN) method. In the study, H-shaped microstrip patch antenna design, simulation, ANN modeling and production were performed.

ANN, which is a deterministic analysis method, was preferred because it can be applied to many different problems and gives successful results. It prevents loss of time during designing of microstrip antennas, processing can be done at lower cost, production can be done in a shorter time and mathematical operations is not required. In our study, an antenna design with 390 different parameters had been performed and analyzed for use in model development. ANN model was performed by using Levenberg Marquart and Bayesian Regularization training algorithms, single and multi-layer model types and different neuron numbers. The results were evaluated, the model with the most suitable parameters was preferred for antenna design and it was produced. As a result, simulation results, model results and measurement results of the produced antenna were compared.

2018, 67 pages

Key Words: Microstrip antenna, resonant frequency, angular width, artificial neural network, mean error rates

TEŞEKKÜR

Kendisini tanımış olmaktan ve birlikte çalışmaktan büyük onur duyduğum, engin bilgi ve tecrübeleri ile yoluma ışık tutan değerli danışman hocam Sayın Doç. Dr. Yakup HAMEŞ'e en içten duygularıyla teşekkür ederim.

Akademik bilgi ve tecrübeleriyle, yüksek lisans eğitimim boyunca katkılarını esirgemeyen ikinci tez danışman hocam Sayın Yrd. Doç. Dr. Oğuzhan AKGÖL'e teşekkür ederim.

Tez çalışmamın hayata geçirilmesinde engin bilgi ve deneyimleriyle desteğini ve sabrını esirgemeyen değerli hocam Yrd. Doç. Dr. Yakup KUTLU'ya teşekkür ederim.

Birlikte aynı ortamı paylaşmaktan mutluluk duyduğum, desteğini esirgemeyen Elektrik Elektronik Mühendisliği araştırma görevlilerine ve Bilgisayar Mühendisliği araştırma görevlilerinden Hüseyin Atasoy'a teşekkür ederim.

Eğitim sürecim ve hayatımın her döneminde destek, sevgi ve sabrını esirgemeyen aileme teşekkür ederim.

İÇİNDEKİLER

ÖZET	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
İÇİNDEKİLER	IV
ŞEKİLLER DİZİNİ	VI
ÇİZELGELER	IX
SİMGELER VE KISALTMALAR DİZİNİ	X
1.GİRİŞ	1
1.1. Antenlerde Bazı Temel Önemli Parametreler	4
1.2. Yapay Sinir Ağları	5
2. ÖNCEKİ ÇALIŞMALAR	8
3. MATERYAL VE YÖNTEM.....	12
3.1. Kullanılan Simülasyon Yazılımları.....	12
3.2. Yapay Sinir Ağı (YSA) Modeli	12
3.2.1. Eğitim algoritmaları	12
3.2.2. YSA performans ölçüm parametreleri	13
3.3. Üretim Metodları.....	14
3.4. Ölçüm Metodları	14
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	16
4.1. Anten Tasarımı ve Simülasyon Sonuçları.....	16
4.2. Yapay Sinir Ağı Uygulaması	21
4.3. Yapay Sinir Ağı Modelleri.....	22
4.3.1. Rezonans frekansı için tek katmanlı yapay sinir ağı modelleri.....	22
4.3.2. Rezonans frekansı için çok katmanlı yapay sinir ağı modelleri.....	29
4.3.3. Yayılım genişliği açısı için tek katmanlı yapay sinir ağı modeli.....	37

4.3.4. Yayılm genişliđi açısı için çok katmanlı yapay sinir ađı modelleri.....	44
4.4. Model Belirleme.....	51
4.5. Anten Üretimi.....	52
5. SONUÇ.....	60
KAYNAKLAR.....	61
ÖZGEÇMİŞ.....	67



ŞEKİLLER DİZİNİ

Şekil 1.1. Mikroşerit yama antenin şekli (Shankar ve ark., 2015).....	2
Şekil 1.2. Mikroşerit yama anten	3
Şekil 1.3. Tipik ysa modeli (Eldhose ve Jisha, 2016)	6
Şekil 3.1. Network analyzer	15
Şekil 4.1. Mikroşerit antenin simülasyon görüntüsü (Anten 1)	16
Şekil 4.2. a) Mikroşerit antenin boyutları, b) Mikroşerit antenin yüksekliği.....	17
Şekil 4.3. Mikroşerit antenin S11 parametresinin simülasyon sonuçları (Anten 1).....	18
Şekil 4.4. Mikroşerit antenin ışınma örüntüsü	18
Şekil 4.5. Mikroşerit antenin polar ışınma örüntüsü	19
Şekil 4.6. Mikroşerit yama antenin simülasyon görüntüsü ve boyutları (Anten 2)	19
Şekil 4.7. Mikroşerit antenin S11 parametresinin simülasyon sonuçları (Anten 2).....	20
Şekil 4.8. Mikroşerit antenin ışınma örüntüsü (Anten 2).....	20
Şekil 4.9. Rezonans frekansı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği	23
Şekil 4.10. Rezonans frekansı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği	23
Şekil 4.11. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	24
Şekil 4.12. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	25
Şekil 4.13. Rezonans frekansı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	26
Şekil 4.14. Rezonans frekansı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	27
Şekil 4.15. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	28
Şekil 4.16. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	29
Şekil 4.17. Rezonans frekansı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği	30
Şekil 4.18. Rezonans frekansı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği	31
Şekil 4.19. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	32
Şekil 4.20. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	33
Şekil 4.21. Rezonans frekansı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	34

Şekil 4.22. Rezonans frekansı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	34
Şekil 4.23. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	35
Şekil 4.24. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	36
Şekil 4.25. Yayılım genişliği açısı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	37
Şekil 4.26. Yayılım genişliği açısı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	38
Şekil 4.27. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	39
Şekil 4.28. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	40
Şekil 4.29. Yayılım genişliği açısı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	41
Şekil 4.30. Yayılım genişliği açısı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	41
Şekil 4.31. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	42
Şekil 4.32. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	43
Şekil 4.33. Yayılım genişliği açısı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	44
Şekil 4.34. Yayılım genişliği açısı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	45
Şekil 4.35. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	46
Şekil 4.36. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	47
Şekil 4.37. Yayılım genişliği açısı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	48
Şekil 4.38. Yayılım genişliği açısı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği.....	49
Şekil 4.39. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	50
Şekil 4.40. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	51
Şekil 4.41. Matlab ortamında sinir ağı eğitimi.....	52

Şekil 4.42. Matlab ortamında sinir ağı eğitimi.....	52
Şekil 4.43. Anten üretim işlemleri	53
Şekil 4.44. Üretilen Anten 1 a) Ön yüz, b) Arka Yüz.....	53
Şekil 4.45. a) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 1) (yakın görüntüsü), b) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 1) (uzak görüntüsü).....	54
Şekil 4.46. Antenin simülasyon ve deneysel sonucu	55
Şekil 4.47. Antenin polar görüntüsü a) Simülasyon sonucu, b) Ölçüm sonucu.....	56
Şekil 4.48. Üretilen anten 2 a) Ön yüz, b) Arka yüz.....	57
Şekil 4.49. a) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 2) (yakın görüntüsü), b) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 2) (uzak görüntüsü).....	58
Şekil 4.50. Antenin simülasyon ve deney sonucu.....	59



ÇİZELGELER

Çizelge 1.1. Mikroşerit yamanın özellikleri (Shankar ve ark., 2015).....	2
Çizelge 4.1. Antenin parametreleri (Anten 1).....	18
Çizelge 4.2. Antenin parametreleri (Anten 2).....	20
Çizelge 4.3. Her iki antenin elektromanyetik simülasyon yazılım sonuçları.....	21
Çizelge 4.4. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	24
Çizelge 4.5. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	25
Çizelge 4.6. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	27
Çizelge 4.7. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	28
Çizelge 4.8. En kötü ortalama karesel hata oranına sahip veri baz alınarak elde edilen ortalama hata oranları.....	31
Çizelge 4.9. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	32
Çizelge 4.10. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	35
Çizelge 4.11. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	36
Çizelge 4.12. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	38
Çizelge 4.13. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	39
Çizelge 4.14. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	42
Çizelge 4.15. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	43
Çizelge 4.16. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	45
Çizelge 4.17. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	47
Çizelge 4.18. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	49
Çizelge 4.19. En iyi ortalama hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları.....	50
Çizelge 4.20. Rezonans frekansı için elde edilen en düşük ortalama hata oranları.....	51
Çizelge 4.21. Yayılım genişliği açısı için elde edilen en düşük ortalama hata oranları.....	52
Çizelge 4.22. Antenin parametreleri (Anten 1).....	54
Çizelge 4.23. Anten sonuçları (Anten 1).....	55
Çizelge 4.24. Antenin sonuçları.....	57
Çizelge 4.25. Antenin parametreleri (Anten 2).....	57
Çizelge 4.26. Anten sonuçları (Anten 2).....	59

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

c: Işığın serbest boşluk hızı

D: Yönlülük

f: Rezonans frekansı

h: Dielektrik taban kalınlığı

L: Uzunluk

N: Gözlem sayısı

n: Örnek boyutu

W: Genişlik

Prad: Toplam Işınım Gücü

ti: Hedeflenen çıkışlar

U: Işıma yoğunluğu

U₀: İzotropik Kaynağın Işıma Yoğunluğu

y_i: Gözlenen değer

a_i: YSA' dan gözlenen çıkışlar

ÿ_i: Tahmin edilen değer

Δl: Işınım boşluğunun eşdeğer uzunluğu

ε_r: Alt tabakanın etkin dielektrik sabiti

KISALTMALAR

BR: Bayesian Regularization

BW: Bant Genişliği

CST: Computer Simulation Technology

ÇKA: Çok Katmanlı Algılayıcı

EM: Elektromanyetik

GN: Gauss- Newton

LM: Levenberg Marquart

MA: Mikroşerit Anten

MYA: Mikroşerit Yama Anten

OKH: Ortalama Karesel Hata

OMH: Ortalama Mutlak Hata

OMYH: Ortalama Mutlak Yüzde Hata

RBF: Radyal Bazlı Fonksiyon
TKA: Tek Katmanlı Algılayıcı
YSA: Yapay Sinir Ađı



1.GİRİŞ

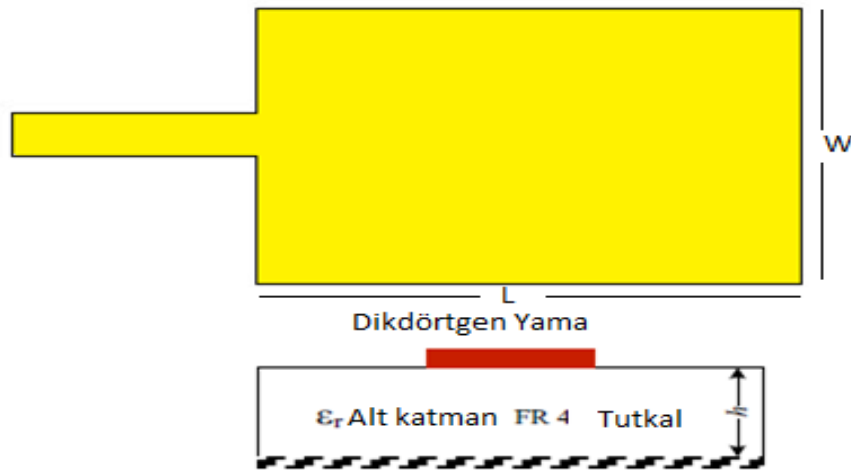
Yayın kaynağından antene veya antenden alıcısına elektromanyetik (EM) enerjiyi nakletmek için kullanılan antenler, radyo dalgalarını yaymak veya almak için kullanılan metalik bir cihaz olarak tanımlanmaktadır (Bhavanam ve Kalyan, 2016).

Mikroşerit antenler (MA), hakkında ilk fikir 1953'te Deschamps tarafından ileri sürülmüştür (Agarwal ve ark., 2012). Bu tür antenler 1970'li yıllarında başında tanınmaya başlanmış ve anten tasarımında büyük bir dönüm haline gelerek önemi ortaya çıkmıştır (Alam ve ark., 2017). Son yıllarda kablosuz iletişim uygulamalarında MA'lar anten mühendislerinin ve bilim adamlarının yoğun ilgisini görmüştür (Das ve ark., 2015). Bu antenler birçok avantajından dolayı son zamanlarda yaygın bir şekilde tercih edilmektedir.

MA'lar hafif (Guney ve Sarikaya, 2007; Suryakanth ve Mulgi, 2013; Das ve ark., 2015), üretimi kolay, düşük maliyetli (Guney ve Sarikaya, 2007; Suryakanth ve Mulgi, 2013; Cai ve ark., 2015; Das ve ark., 2015), dizilere entegre olma, kavisli yüzeylere uyumluluk, mikrodalga entegreli devre veya monolitik mikrodalga entegre devre bileşenleri ile birleşme kolaylığı gibi birçok özelliğe sahiptir. Bu özelliklerinden dolayı son zamanlarda MA uygulamaları ile ilgili araştırmalar dikkate değer bir şekilde artış göstermiştir (Guney ve Sarikaya, 2007). Aynı zamanda bu antenler yüksek verimli, tasarımı basit (Bekasiewicz ve Koziel, 2016) ve düşük hacimlidir (Suryakanth ve Mulgi, 2013). Diğer bir yandan MA'ların düşük güç taşıma kapasitesi (Kordalivand ve Rahman, 2013), düşük kazanç ve düşük bant genişliği gibi farklı dezavantajları bulunmaktadır (Kordalivand ve Rahman, 2013; Suryakanth ve Mulgi, 2013). Bu antenlerin düşük kazançlı olmasının başlıca nedeni küçük aralık ve dielektriklerindeki yüzey dalgası uyarımından kaynaklanmaktadır (Honarbaskhsh, 2017). Bununla birlikte MA'ların düşük verimli ve bant genişliğinin düşük olmasına dielektrik kayıplar, besleme kaybı gibi etmenler sebep olmaktadır (Wang ve ark., 2011). MA'lar yaklaşık olarak 1-5% dar bant genişliği (BW) oluşturur ki bu da yaygın uygulamalar için bir engel oluşturmuştur (Kordalivand ve Rahman, 2013). Bu yüzden bant genişliğini arttırma basılı anten alanlarında önemli bir faaliyet kolu haline gelmiştir (Das ve ark., 2015). Anten uygulamalarında band genişliğini karşılamak için band genişliği arttırma gibi işlemler gerekebilir (Jain ve ark., 2012). Bu yüzden antenlerin band genişliğini arttırmak için istiflenmiş yama, kalın ve düşük geçirgenlikli yüzeyler kullanma, kayıplı malzeme,

kenara bağlanmış parazit yama (Nasimuddin ve Chen, 2008), düşük dielektrik alt katman kullanımı, yarıklı yama anten, çeşitli empedans eşleştirilmesi, besleme teknikleri, alt katman kalınlığı gibi farklı şekillerde iyi bilinen çok sayıda yöntem kullanılmaktadır (Kushwaha ve ark., 2012). Aynı zamanda L prob besleme, E şekil yama, U delikli yama, kapasitif besleme ve iletken yolu ile bant genişliği arttırılabilir. Fakat bu değişikliklerin çoğu sadece anten yüksekliği veya ses seviyesini değil aynı zamanda antenin birçok özelliğinin bozulmasına neden olmaktadır (Li ve Luk, 2015).

Dielektrik alt katman, zemin düzlemi ve yayılan yama bileşeni gibi özelliklere sahip olan mikroşerit yama antenler (MYA) basit bir yama anten olarak tanımlanmaktadır ve bu antenler baskılı devre kartına doğrudan basıldığından çok popülerdir (Sharma ve Sharma). Şekil 1.1.' de bu antenin basit bir şekilde yapısı gösterilmiştir.




Şekil 1.1. Mikroşerit yama antenin şekli (Shankar ve ark., 2015)

MYA'ların frekans, alt katman yüksekliği, yamanın boyutu ve dielektrik sabiti gibi temel bazı özellikleri vardır. Aşağıdaki Çizelge 1.1' de bu parametreler listelenmiştir (Shankar ve ark., 2015).

Çizelge 1.1. Mikroşerit yamanın özellikleri (Shankar ve ark., 2015)

Parametre	Aralık
Frekans	> 0.5 GHz
Altkatman Yüksekliği	0.003 λ_0 - 0.05 λ_0
Yamanın Boyutu	$\lambda_0/3$ - $\lambda_0/2$
Dielektrik sabiti	2.2 - 12

Dielektrik alt katman, zemin düzlemi ve yayılan yama şeklinde her MA' nın üç benzer özelliği bulunmaktadır (Saini ve ark., 2016). Farklı şekillerde oluşturulabilen yamanın malzemesi genellikle bakır veya altından oluşur (Jain ve ark., 2012). Dikdörtgen ve dairesel yamalar basit ve düzenli yapıya sahip oldukları için MA'larda geleneksel şekiller kabul edilmektedir (Wang ve ark., 2017). Literatürde bu antenlerin kare, dairesel, üçgen, dikdörtgen gibi farklı şekillerde tasarlandığı gözlemlendi. Aynı zamanda literatürde E, H, U vb. şekillerde tasarlanan birçok farklı anten çeşidi bulunmaktadır. Aşağıdaki Şekil 1.2.' de mikroşerit yama antenlere örnek gösterilebilecek bir geometrik şekil verilmiştir.



Şekil 1.2. Mikroşerit yama anten

MYA'lar navigasyon, telemetri, radarlar, biyomedikal sistemler, mobil uydu iletişim, doğrudan yayın sistemi (Neyestanak, 2008), uçak, uzaktan algılama ve gezgin antenler gibi farklı birçok uygulamada tercih edildiği gibi aynı zamanda mükemmel bir radyatördür (Singh, 2015). Düşük profile sahip olan bu antenler boyut, ağırlık, maliyet, performans, kolay kurulum ve aerodinamik profil gibi sıkı kısıtlamaların olduğu uçak, uydu ve füze uygulamalarda tercih edilmektedir (Gujral ve ark., 2012).

MA'larda giriş empedansı, geometrik boyutlara bağlı olmak ile birlikte, antenin besleme çeşidi, konumu ve malzemenin fiziksel özelliğine de bağlıdır (Singh ve Bhargav, 2014). Bu tür antenlerde giriş empedansı çoğu zaman 50 ohm seçilmektedir fakat antenlerin boyut ve alt katmanının büyütülmesiyle bu oran bazen 100 ohm olabilmektedir (Sharma ve Gupta, 2007).

MA'ların tasarımında frekans, kalınlık ve alt katman malzemesi gibi gerekli olan temel üç parametre vardır. Bu antenler 100 Mhz üzerindeki frekans değerlerinde

popülerdir (Sran ve Sivia, 2016). MA'ların rezonans frekansı ve radyasyon yamasının boyutu aşağıdaki belirtilen formüller ile bulunabilir (Kushwaha ve ark., 2012).

$$f = \frac{c}{2L\sqrt{\epsilon_r}} \quad (1.1)$$

$$W = \frac{2}{f_r} \left(\frac{\epsilon_r + 1}{2} \right)^{1/2} \quad (1.2)$$

$$L = \frac{c}{2L\sqrt{\epsilon_r}} - 2\Delta l \quad (1.3)$$

f: Rezonans frekansı

c: Işığın serbest boşluk hızı

L: Gerçek uzunluk

ϵ_r : Alt tabakanın etkin dielektrik sabiti

Δl : Işınım boşluğunun eşdeğer uzunluğu

Bu antenlerin tasarımı ve üretimi sırasında boyutların ölçülerine dikkat edilmesi gerekmektedir. Boyutta yapılan küçük bir değişiklikte bile S11 (geri dönüş kaybı), ışıma örüntüsü, kazanç, bant genişliği, verim gibi anten için gerekli temel bazı parametrelerin değişmesine yol açmaktadır.

1.1. Antenlerde Bazı Temel Önemli Parametreler

S11 (Geri dönüş kaybı) parametresi

Antende porttan gönderilen sinyalin ne kadarının geri yansıdığını belirten parametredir. Genel olarak S11 parametresi için -10 dB kabul edilebilir bir durumdur fakat sanayi uygulamalarında bu değer genellikle -15 dB olarak dikkate alınmaktadır.

Işıma örüntüsü

Uzak alan bölgesi olarak belirlenen ve aynı zamanda yönlü fonksiyonlara bağlı fonksiyoların gösterimi olarak tanımlanan ışıma örüntüsü, bir antenin ışıma özelliğinin uzay koordinatlara bağlı fonksiyonunun matematiksel veya grafiksel olarak gösterimidir. Işıma özelliği güç akış yoğunluğu, ışıma yoğunluğu, alan gücü, yönlülük ve faz veya kutuplaşmayı içermektedir (Balanis, 2005).

Yönlülük

Antenlerde yönlülük bir enerjiyi belirli bir yönde toplamayı ifade etmektedir (Kaushal ve Shanmuganatham, 2016). Aynı zamanda antenlerin yönlülüğü belirli bir yöndeki ışımaya yoğunluğun her yerde oluşan ışımaya yoğunluğuna oranı olarak tanımlanmaktadır. Formülize edilmiş hali aşağıda verilmiştir (Balanis, 2005).

$$D = \frac{U}{U_0} = \frac{4 \pi U}{P_{rad}} \quad (1.4)$$

D: Yönlülük

U: Işıma yoğunluğu

U₀: İzotropik kaynağın ışımaya yoğunluğu

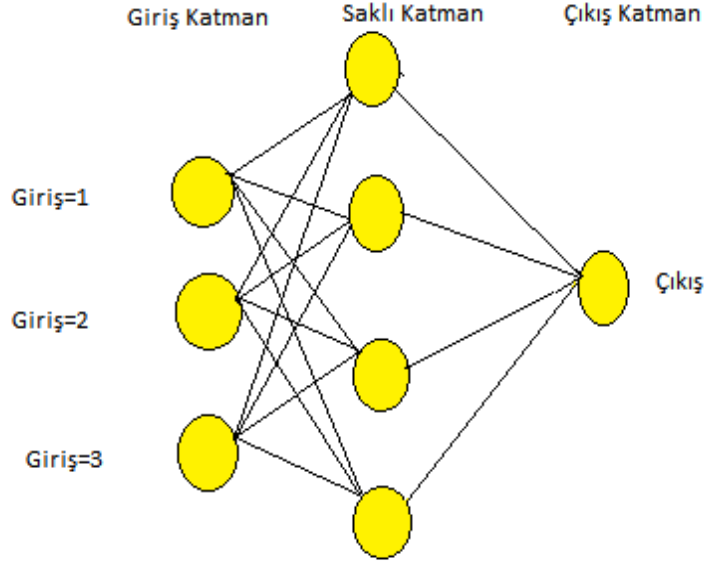
Prad: Toplam ışınım gücü

MA'ları analiz etmek için iki farklı yol vardır. Bunlardan birincisi analitik yöntem ikincisi ise sayısal yöntemdir. Bu iki yöntemin birbirinden farklı özellikleri bulunmaktadır. Analitik yöntem, sayısal yöntemden daha kolay fakat belli bazı şekiller ile sınırlandırılmıştır. Ancak sayısal yöntem, çok karışık ve daha çok zaman almasına rağmen herhangi bir şekile uygunabilir. Araştırmacılar herhangi bir karmaşık devre veya şekil için, aynı zamanda daha kısa sürede sonuçlar elde etmek amacıyla sinir modellerini kullanmışlardır (Kala ve ark., 2012).

1.2. Yapay Sinir Ağları

Yapay sinir ağı (YSA) kavramı ilk olarak 1943'te McCulloch tarafından ileri sürülmüş, ağırlık ve aktivasyon fonksiyonu kavramlarına sahip bir hücre modeli ve yapay nöron olarak ifade edilmiştir (Kim ve ark., 2017). YSA'lar genellikle sinir ağları olarak ifade edilmiştir (Parmar, 2015). Sinir kelimesi biyolojik nörondan ortaya çıkmış, yapay kelimesi de gerçek bir şeyin taklit edilmesi anlamına gelmektedir ve yapıya benzer bir grafiği belirtmektedir (Bose ve Gupta, 2012). YSA tasarımı ve uygulaması ağı oluşturulması, ağ yapılandırma, ağırlık ve önyargıların başlatılması, ağ eğitimi, ağ onaylama, ağ kullanma olmak üzere 7 adım içermektedir. YSA'ların yüksek hız, doğruluk ve erişilebilirlik gibi özellikleri vardır (Galphade, 2017).

YSA normal bir insan gibidir öğrenmeyi örnekler ile öğrenir (Elantamilan ve ark., 2016). Aşağıdaki Şekil 1. 3.' te tipik bir YSA modeli gösterilmiştir.



Şekil 1.3. Tipik ysa modeli (Eldhose ve Jisha, 2016)

YSA'lar biyolojik sinir ağları kadar hızlı olmasa da (Malmathanraj ve Selvi, 2014), biyolojik sinir ağlarının işlevinden esinlenen hesaplamalı bir model olarak tanımlanır ve ara bağlantı üzerinden bilginin işlendiği bir grup yapay nöron ile oluşturulur (Akdaglı ve ark., 2013). Nöronlar belirli problemleri çözmek için çok sayıda birbirine bağlı elementlerden oluşmaktadır (Pandit ve Bose, 2011). Basit doğrusal olmayan bir aktarım fonksiyonuyla değiştirilen tüm girdilerin toplamının bir fonksiyonu olan nöronlar, ağırlıklarla bağlantılı ve düğümler gibi davranmaktadırlar (Gupta ve Singhal, 2016).

Geçmiş yıllarda hızlı, doğru ve esneklik gibi özelliklere sahip olan YSA yöntemi anten ve EM problemlerini çözmek için yaygın bir şekilde kullanılmıştır (Maurya ve ark., 2013). YSA modelinin amacı anten tasarımındaki karmaşık ve zaman alan matematiksel işlemleri ortadan kaldırmaktır. YSA, MA'ların birçok optimizasyonunu kapsayan çeşitli anten uygulamaları için başarılı bir şekilde kullanılmıştır. Genel anlamda YSA modeli işlemi data oluşturma, eğitim ve sonuçları test etme gibi 3 adımdan oluşur (Bhagat ve ark., 2012). YSA'lar dikdörtgen, eşkenar üçgen, dairesel olmak üzere farklı şekillerdeki yama antenlere uygulanmıştır (Gupta ve ark., 2013). YSA yöntemi dikdörtgen MA'ların giriş empedansı, yönlülük, besleme konumu, dikdörtgen ve üçgen MA'ların rezonans

frekansı ve radyasyon verimliliği gibi parametreleri hesaplamak için kullanılmıştır (Singh ve ark., 2011).

Son on yılda YSA modeli hızlı ve doğru modelleme, simülasyon ve optimizasyon gibi nedenlerden dolayı kablosuz haberleşme alanında dikkate değer bir şekilde önem kazanmıştır (Kayabasi ve Akdagli, 2016). YSA hızlı öğrenme yeteneği, kararlı genellemeler, paralel işleme ve hata dayanıklılığı gibi iyi bilinen bir çok pozitif özelliğinden dolayı çok popüler hale gelmiştir (Jafari-Marandi ve ark., 2017). Sinir ağı modeli ölçülen ve simüle edilen anten verilerini eğitim süreci boyunca öğrenerek geliştirebilir. Eğitimin amacı YSA'nın gerçek sonucu ile hedeflenen sonuç arasındaki hata oranını küçültmektir (Guney ve Sarikaya, 2007). Ağ giriş, çıkış ve saklı olmak üzere üç katmandan oluşmaktadır ve her katman ağırlık olarak tanımlanan bağlantı kuvvetleri tarafından birbirine bağlıdır (Khatib ve ark., 2012). Bilgiler giriş katmanından alınmaktadır. Gizli katman bir veya birkaç katmandan oluşmaktadır. Bu katmanda giriş bilgileri analiz edilmektedir. Çıkış katmanı ise analiz sonucu elde edilen verileri alır ve çıktı sağlar. Eğitim ve test YSA'nın iki temel bileşeni olarak kabul edilmektedir. Eğitim işlemi yapılırken ağ öğrenme algoritması ve giriş data setini kullanmaktadır. YSA'nın öğrenme algoritması sinaptik ağırlık değerlerini güncelleyerek giriş-çıkış arasındaki ilişkiyi göstermektedir (Das ve ark., 2018).

2. ÖNCEKİ ÇALIŞMALAR

Güney ve ark. (2000), elektriksel olarak ince ve kalın dikdörtgen mikroşerit antenlerin (MA) rezonans direncini yapay sinir ağları (YSA) yöntemini kullanarak hesaplamışlardır. YSA uygulaması için farklı eğitim algoritmalarını kullanarak performansları karşılaştırmışlardır. Sonuçlar karşılaştırıldığında ise YSA ile elde edilen sonuçların literatürde mevcut olan erişilebilir sonuçlar ile uyumluluk içinde olduğu gözlemlenmiştir.

Gopalakrishnan ve Gunasekaran (2005), eşkenar üçgen MA'ların tasarımında YSA hesaplamasını tercih etmişlerdir. Sinir ağlarından geri yayılım çok katmanlı algılayıcıyı (ÇKA) seçmişlerdir. YSA yöntemini kullanarak elde ettikleri sonuçları deney sonuçlarının en iyi olan sonuçlarıyla karşılaştırmışlardır.

Neog ve ark. (2005), geniş bant MA'nın tasarımını yapmışlar ve parametre hesaplamada YSA yöntemini kullanmışlardır. Antenin radyasyon modellerinin hesaplanması için bir tünel tabanlı YSA geliştirmişlerdir. Çalışmada moment metodu ve genetik algoritma metodu kullanılmış, sonuçların IE3D yazılım sonuçlarıyla uyumluluk içinde olduğunu gözlemlenmiştir.

Güney ve Sarıkaya (2007), farklı şekillerdeki MA'ların rezonans frekansını hesaplamak için hibrit yöntem olarak tanımlanan YSA ve bulanık çıkarsama sistemini kapsayan metodları kullanmışlardır. YSA uygulaması için Bayes Regularization eğitim algoritmasını tercih etmişlerdir. Dairesel, dikdörtgen ve üçgen MA'lar için kullanılan Hibrit yönteminin sonuçlarının literatürde erişilebilen deneysel sonuçlar ile uyumlu olduğunu gözlemlenmiştir.

Thakare ve ark. (2008), YSA'yı kullanarak MA'nın rezonansının bant genişliğini hesaplamışlardır. Makalede aynı zamanda MA'ların tasarım problemini çözmek için yeni bir yaklaşımı araştırmayı amaçlamışlardır. IE3D yazılım sonuçlarını ile YSA sonuçlarını karşılaştırmışlar ve sonuçların uyumluluk içinde olduğunu gözlemlenmiştir.

Mishra ve ark. (2009), dikdörtgen ve kare MA'ların analiz ve sentezi için YSA yöntemini kullanmışlardır. İleri besleme geri yayılım eğitim algoritmasını uygulamışlardır. Nöral modelden elde ettikleri sonuçların literatürdeki erişilebilir deneysel sonuçlarla uyumluluk içinde olduğunu gözlemlenmiştir. Analiz modelin sentez modele göre daha doğru sonuçlar verdiğini ifade etmişlerdir.

Kumar ve ark. (2010), çalışmalarında 2 mm alt katman kalınlığına sahip olan çok yarıklı MA'yı gerçekleştirmişlerdir. Rezonans frekansı, ışınma örüntüsü, kazanç ve geri dönüş kaybı parametrelerini belirlemek için IE3D yazılımını ve aynı zamanda YSA uygulamasını kullanmışlardır. İki yöntemden elde edilen sonuçların birbirine uyumlu olduğunu gözlemlemişlerdir.

Malik ve ark. (2011), YSA yöntemini kullanarak eşkenar üçgen mikroşerit anten tasarımını çalışmışlardır. Geri yayılım ÇKA eğitim ağını tercih etmişler. YSA'dan elde ettikleri sonuçların deneysel sonuçlarla uyumluluk içinde olduğunu gözlemlemişlerdir.

Pandit ve Bose (2011), belirli bir frekans bandında çalışmayı gerektiren dairesel monopol antenin tasarım parametrelerinden biri olan besleme aralığını tahmin etmek için sinir ağını kullanmışlardır. IE3D yazılımı ile YSA uygulaması sonuçlarının birbiriyle uyum içinde olduğunu ifade etmişlerdir.

Kala ve ark. (2012), ÇKA sinir ağı modelini kullanarak dikdörtgen MA'ların tasarımını gerçekleştirmişlerdir. Mevcut olan modelin (Rezonans frekansı) çıkışı test edildiğinde teorik sonuçlarla uyumluluk içinde olduğunu gözlemlemişlerdir.

Bhagat ve ark. (2012), çalışmalarında YSA'ları kullanarak farklı şekillerde MYA'ların analiz ve sentezini gerçekleştirmişlerdir. YSA uygulaması giriş parametreleri için antenin boyutlarını, çıkış parametresi için ise rezonans frekansı ve geri dönüş kaybını incelemişlerdir.

Akdagli ve ark. (2013), E-şekilli kompakt MA'ların rezonans frekansını hesaplamak için YSA yöntemini kullanmışlardır. YSA modelinin test ve eğitim sonuçlarının simülasyondan elde edilen rezonans frekansı sonuçları ile uyumluluk içinde olduğunu gözlemlemişlerdir. Aynı zamanda amaçlanan yaklaşımın ispatlanması için üretimini gerçekleştirmişlerdir.

Gupta ve ark. (2013), YSA yöntemini kullanarak eşkenar üçgen MA'nın rezonans frekansını hesaplamışlardır. Yapar sinir ağı uygulaması için moment yöntemine dayanan bir simülasyon yazılımını kullanmışlardır. Amaçlanan YSA modelinin sonuçları ile simülasyondan elde edilen sonuçların birbiriyle uyumluluk içinde olduğunu gözlemlemişlerdir.

Roy ve Chakraborty (2013), C- oluklu MYA'nın özelliklerini analiz etmek için YSA yapısını kullanarak, ileri besleme geri yayılım ÇKA ve radyal bazlı fonksiyon (RBF) sinir modelini geliştirmişlerdir. RBF sinir modelinin sonuçlarının ileri besleme

geri yayılım ÇKA sonuçlarından daha iyi ve eğitimin daha hızlı olduğunu ifade etmişlerdir. Elde edilen sonuçların deneysel sonuçlara yakın olduğunu gözlemlemişlerdir.

Lumba ve Singh (2014), koaksiyel besleme dikdörtgen MYA'nın bant genişliğini tahmin etmek için YSA'yı tercih etmişlerdir. YSA ve IE3D simülasyon sonuçlarını karşılaştırmışlar ve sonuçların uyumluluk içinde olduğunu gözlemlemişlerdir.

Kumar ve Rai (2014), çalışmalarında YSA'yı kullanarak MA'ların rezonans frekansını incelemişlerdir. Makalede sinir ağını doğrusal olmayan sistemleri açıklamak için kullanmışlardır. Deneysel sonuçlardan yola çıkarak sinir ağının daha hızlı yakınsallık oranı ve en düşük hataya sahip olduğunu ifade etmişlerdir. Bunun sonucu olarak sinir ağının MA'ların farklı parametrelerini hesaplamak için aynı zamanda tasarım aşamasında oluşan problemlerin çözümü için bir etkinlik olduğunu ifade etmişlerdir.

Singh (2015), çalışmasında YSA yöntemi kullanarak dikdörtgen mikroşerit yama antenlerin tasarımını incelemiştir. YSA yönteminin farklı eğitim algoritmaları kullanarak MYA'nın rezonans frekansını elde etmeyi amaçlamıştır. Elde edilen sonuçların literatürde erişilebilen diğer deneysel sonuçlarla uyumlu olduğunu ifade etmiştir.

Varma ve Ghosh (2016), çalışmalarında elektromanyetik (EM) olarak eşleşmiş mikroşerit antenlerin tasarımı için YSA algoritmalarından geri yayılım ve RBF algoritmalarını kullanmışlardır. Tasarım farklı frekanslarda gerçekleşmiş olup iki algoritmanın sonuçlarını karşılaştırmışlardır. Elde edilen sonuçlardan RBF algoritmasının sonuçlarının geri yayılım sonuçlarından daha iyi olduğunu gözlemlemişlerdir. Aynı zamanda RBF sonuçlarının ölçüm ve Computer Simulation Technology (CST) yazılım sonuçlarıyla uyumlu olduğunu gözlemlemişlerdir.

Chhari ve Thakare (2016), E-şekil MA'nın performans parametrelerinin analizi için farklı YSA yöntemi kullanmışlardır. Kullanılan yazılım programı ile YSA uygulamasının sonuçlarının birbiriyle uyum içerisinde olduğunu gözlemlemişlerdir.

Bu tez çalışmasında MA parametrelerinden rezonans frekansı ve yayılım genişliği açısı YSA yöntemi kullanılarak incelenmiştir. Çalışmada farklı eğitim algoritmaları, farklı YSA yapıları ve farklı nöron sayıları kullanarak en uygun YSA modeli bulma işlemi gerçekleştirilmiştir. YSA yöntemi antenin tasarım işlemlerini kolaylaştırmak ve daha kısa sürede işlemleri gerçekleştirmek için kullanılmıştır. Literatürde yayılım genişliği açısı ile ilgili çalışmaların yetersiz olması bu konu ile ilgili çalışma yapmaya yönlendirmiştir.

Yapılan bu alıřmada simülasyon, model ve üretim sonuçları karşılaştırılmış ve tüm sonuçların birbirleriyle uyumluluk içinde olduđu gözlemlenmiştir.

3. MATERYAL VE YÖNTEM

3.1. Kullanılan Simülasyon Yazılımları

Antenin tasarımı ve analizini yapmak için elektromanyetik (EM) simülasyon yazılım programı tercih edilmiştir. Bu yazılım programı rezonans frekansı, ışıma örüntüsü, bant genişliği, kazanç gibi anten parametrelerin hesabında kullanılabilir. Anten tasarımı için frekans aralığı 1-8 Ghz aralığında seçilmiştir. Anten parametrelerin tümü manuel olarak girilmiştir. Aynı zamanda çalışmada yapay sinir ağı (YSA) uygulaması için MATLAB yazılım programı ve antenin üretim işlemi sırasında ise LPFK Circuit Pro 1.5 yazılım programları kullanılmıştır. Anten üretimi, simülasyon sonuçları ve MATLAB yazılım programı sinir ağı araç kutusu kullanılarak elde edilen sonuçlar dikkate alınarak gerçekleştirilmiştir.

3.2. Yapay Sinir Ağı (YSA) Modeli

YSA modeli için Levenberg Marquart (LM) ve Bayesian eğitim algoritmaları kullanılmıştır. Aynı zamanda tek katmanlı ve çok katmanlı YSA yapıları kullanılmıştır.

Tek katmanlı algılayıcı (TKA) ve çok katmanlı algılayıcı (ÇKA) ileri beslemeli sinir ağları türleri olarak ifade edilmiştir. Tek katmanlı ileri besleme sinir ağı bir giriş ve bir çıkış katmanına sahiptir (Turkson ve ark., 2016). Çoğu durumlarda problemleri çözmek için tek katmanlı YSA yöntemi tercih edilmiştir. Fakat karmaşık problemlerin bir kısmı bu yöntemle çözülememiştir. YSA bu tür problemlerin üstesinden gelebilmek için farklı mimariler ve farklı giriş-çıkış haritalamayı takip eden çeşitli tiplere dönüştürülmüştür (Das ve ark., 2018).

İlk algılayıcı 1958 yılında Rosenblatt tarafından tasarlanmıştır ve Rosenblatt ÇKA'sının atası olarak düşünülmektedir. ÇKA'da öğrenme aksiyon ağırlıklı hesaplama performansı elde edilinceye kadar ağıdaki ağırlıkları ayarlayarak gerçekleşir. Belirli bir girdinin eğitim işlemi tamamlandıktan sonra belirli bir hedef çıktı oluşmasına neden olur (Ferentinou ve Fakir, 2017). En çok kullanılan ileri besleme ağı tipi olan bu algılayıcı bir giriş katmanı, bir çıkış katmanı ve bir veya birden fazla saklı katmandan oluşmaktadır. ÇKA'nın hem basit hemde karmaşık fonksiyonel ilişkileri modelleme yeteneği vardır (Ofure ve ark., 2017).

3.2.1. Eğitim algoritmaları

Levenberg Marquart (LM) eğitim algoritmasının matematiksel bir tanımı Hagan ve Menhaj tarafından ileri sürülmüştür. LM algoritması Gauss-Newton (GN) ve Gradient

Descent algoritması arasında ve aynı zamanda bu tekniklerin her birinin sınırlandırılmış durumlarında ara bir optimizasyon algoritması olarak hizmet etmek amacıyla tasarlanmıştır (Kermani ve ark., 2005).

LM eğitim algoritması matematikte sönümlü en küçük kareler metodu olarak bilinmekte (Sahay ve ark., 2016) ve çoğunlukla doğrusal olmayan en küçük kare problemlerini çözmek için tercih edilmektedir. Bu küçük problemler daha çok en küçük kare eğrisini uydurmada oluşmaktadır (Singh ve ark., 2015).

LM daha fazla bellek ve daha fazla zaman gereksinimi olmadığından dolayı algoritmaları yöneten ilk seçenek olarak tavsiye edilmektedir. Aynı zamanda bu eğitim algoritması örnek veriler büyük olduğunda kullanım özelliğini azaltır (Keong ve ark., 2016).

Bayesian Regularization (BR) eğitim algoritması LM optimizasyonuna göre ağırlık ve önyargı değerlerini güncelleyen ağ eğitim algoritması olarak tanımlanmıştır. Kare hataları ve ağırlıklardan oluşan kombinasyonu en aza indirerek genel bir ağ üretimi için doğru olan kombinasyonu belirler (Nadimi ve ark., 2009). Bu eğitim algoritması sinir ağının aşırı uyum olgusundan kaçınmak için yaygın bir şekilde kullanılmıştır (Wei ve ark., 2009).

BR eğitim algoritmasının ağ mimarisi optimizasyonu, doğrulama çabası, geçerlilik kümesinin seçimi ve sağlamlığı kontrol etmek gibi özellikleri bulunmaktadır (Arora ve Saha, 2016). Bayesian tarafından düzenlenen sinir ağlarının çapraz doğrulama ihtiyacı olmamakla birlikte aynı zamanda geri yayılım nöral ağından daha sağlamdır (Bhandarkar ve Naik, 2016). BR eğitim algoritması çok fazla sayıda giriş parametresinin olduğu bir tahminde en iyi çıktıları elde etmek için kullanılmıştır (Kaur ve Salaria, 2013).

3.2.2. YSA performans ölçüm parametreleri

YSA modelini belirlemek için ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve ortalama mutlak yüzde hata (OMYH) performans ölçüm parametreleri hesaplanmıştır.

OKH, eğitim örnekleri için eğitim setinde tanıtılan hedefler ile YSA'dan gözlenen çıkış değerleri arasındaki farkı ifade etmektedir. Aşağıda formülize edilmiş hali verilmiştir (Dalipi ve Yayılğan, 2015).

$$OKH = \frac{1}{n} \sum_{i=1}^n (t_i - a_i)^2 \quad (3.1)$$

n: Örnek boyutu

t_i : Hedeflenen çıkışlar

a_i : YSA'dan gözlenen çıkışlar

OMH model belirlemede yaygın bir şekilde kullanılan diğer bir performans ölçüm hatası olarak ifade edilmektedir.

Modellerin uzun süreli performansları hakkında bilgi sunan OMH, gözlenen değerlere karşılık gelen tahmini değerlerin ortalama sapmasını gösteren hata olarak tanımlanmaktadır. Formülize edilmiş hali aşağıda gösterilmiştir (Vastrad, 2013).

$$OMH = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3.2)$$

\hat{y}_i : Tahmin edilen değer

y_i : Gözlenen değer

OMYH, boyutunun yüzde olarak hesaplanması olarak ifade edilmiştir. Formülize edilmiş hali aşağıda gösterilmiştir (Stepchenko ve ark., 2017).

$$OMYH = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| 100 \quad (3.3)$$

\hat{y}_i : Tahmin edilen değer

y_i : Gözlenen değer

N: Gözlem sayısı

3.3. Üretim Metodları

Antenlerin üretim işlemi gerçekleştirmek için LPFK Circuit Pro 1.5 yazılım programı ve LPFK (Laser & electronics)-protoMat E33 cihazı kullanıldı. Anten üretiminde bakır malzemesi kullanılmıştır. Dielektrik katman ise FR-4 malzemesinden oluşmaktadır. Aynı zamanda ölçüm işlemi gerçekleştirmek amacıyla bir tane port kullanılmıştır.

3.4. Ölçüm Metodları

Ölçüm işlemleri için Agilent marka 2- portlu PNA-L Network Analyzer cihazı kullanıldı. Bu çalışma için sadece geri dönüşüm kaybı olarak da bilinen S_{11} parametresi ölçülmesi gerektiğinden tek port kullanıldı ve ölçüm işlemi rezonans frekansı için bu şekilde gerçekleştirildi. Bu cihaz 10 Mhz - 43.5 Ghz aralığında ölçüm yapabilmektedir. Kalibrasyon işlemi için frekans aralığı tasarlanan antenlerin çalışma frekanslarını da kapsayan 1-8 Ghz olarak seçildi. Şekil 3.1.' de kullanılan Network Analyzer cihazı gösterilmiştir. Ölçümler öncesi port'a bağlı olan kablonun ucundan "açık", "kapalı" ve

“yük” aparatları kullanılarak analizörün kalibrasyonu gerçekleştirildi. Kalibrasyonun doğruluğu daha sonra tekrar yük (Load) bağlanarak test edildi ve sonrasında antenin rezonans frekansı ölçümlerine geçildi.




Şekil 3.1. Network analyzer

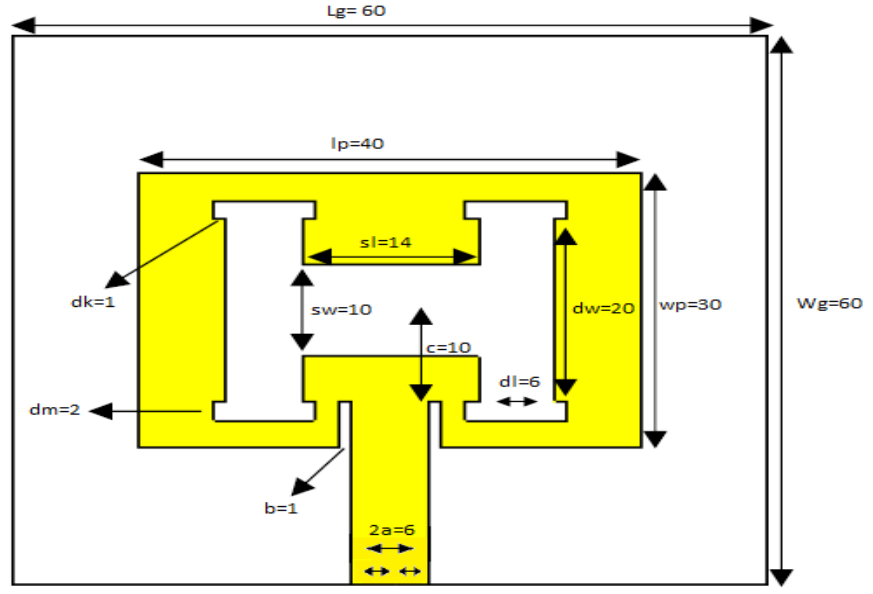
4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Anten Tasarımı ve Simülasyon Sonuçları


Anten tasarımı için elektromanyetik (EM) simülasyon yazılımı tercih edilmiştir. Antenler alt katman, toprak ve yamadan oluşmaktadır. Antenlerin S11 parametresi (geri dönüş kaybı), ışınım örüntüsü, kazanç, bant genişliği gibi temel bazı önemli parametreleri bulunmaktadır. Antenin boyutları üzerinde yapılan en ufak değişiklikte bile bu parametrelerin değiştiği gözlenmiştir. Bunun için anten üretimi ve tasarımı sırasında ölçülere çok dikkat edilmesi gerekmektedir. Bu çalışmada anten parametrelerinden S11 (geri dönüş kaybı) parametresi ve yarı güçlü ışınım genişliği üzerinde durulmuştur. Anten tasarım modelini belirlemek için literatür taraması yapılmıştır. EM yazılım programı kullanarak toplam 390 tane antenin tasarımı yapılmıştır. Tasarlanan antenlerin geometrik şeklinde herhangi bir değişiklik yapılmamıştır. Sadece antenlerin boyutlarında değişiklikler yapılmıştır. Bu değişikliklerin tümü manuel olarak gerçekleştirilmiştir. YSA uygulaması yapıldıktan sonra elde edilen sonuçlar simülasyon sonuçlarıyla karşılaştırılmış ve elde edilen en iyi sonuçlar seçilerek anten üretimi gerçekleştirilmiştir. Bu değerlendirmeler doğrultusunda üretimi uygun görülen iki antenin simülasyon görünümü ve tüm sonuçları adım adım verilmiştir. Şekil 4.1.' de tasarımı gerçekleştirilen ilk mikroşerit antenin (MA) simülasyon görüntüsü verilmiştir.



Şekil 4.1. Mikroşerit antenin simülasyon görüntüsü (Anten 1)



a)




b)

Şekil 4.2. a) Mikroşerit antenin boyutları, b) Mikroşerit antenin yüksekliği

Şekil 4.2.' de mikroşerit yama antenin (MYA) boyutları ve yüksekliği gösterilmiştir. Birinci antenin parametreleri Çizelge 4.1' de verilmiştir.


Çizelge 4.1. Antenin parametreleri (Anten 1)

Parametreler	Wg	Lg	h	t	wp	lp	a	b	c	sl	sw	dw	dl	dk	dm
Değerler	60	60	1.6	0.035	30	40	3	1	10	14	10	20	6	1	2




Şekil 4.3. Mikroşerit antenin S11 parametresinin simülasyon sonuçları (Anten 1)

Şekil 4.1.' de simülasyon görüntüsü verilen antenin S11 parametresi sonucu Şekil 4.3.' te gösterilmiştir. Şekilde görüldüğü gibi rezonans frekansı 3.261 Ghz olarak ölçüldü. S11 parametresinin (geri dönüş kaybı) yaklaşık değerinin -34 dB olduğu gözlenmiştir. Fakat anten performansı ile ilgili değerlendirme yapılırken sadece S11 parametresi değil aynı zamanda antenin ışınma örüntüsünde dikkate alınmıştır. Antenin tek yönde yayılım yapması antenin iyi performans sergilediğini göstermiştir. Şekil 4.4.' te antenin ışınma örüntüsü verilmiştir.




Şekil 4.4. Mikroşerit antenin ışınma örüntüsü



Frequency = 3.261
 Main lobe magnitude = 7.78 dBi
 Main lobe direction = 2.0 deg.
 Angular width (3 dB) = 82.4 deg.
 Side lobe level = -17.6 dB

Şekil 4.5. Mikroşerit antenin polar ışıma örüntüsü


Şekil 4.5.' te antenin polar ışıma örüntüsü verilmiştir. Yayımlı genişliği açısı 82.4 derece olduğu gözlenmiştir. Şekil 4.6.' da YSA sonucu ile simülasyon sonuçlarının uyumluluk içinde olduğu ikinci antenin simülasyon görüntüsü gösterilmiştir. Birinci antenden farkı sadece boyutlarında yapılan değişikliklerdir. Bu değişikliklerin anten parametreleri üzerindeki etkisi incelenmiştir. Çizelge 4.2' de ikinci antenin tüm parametreleri verilmiştir.



Şekil 4.6. Mikroşerit yama antenin simülasyon görüntüsü ve boyutları (Anten 2)


Çizelge 4.2. Antenin parametreleri (Anten 2)

Parametreler	Wg	Lg	h	t	wp	lp	a	b	c	sl	sw	dw	dl	dk	dm
Değerler	60	60	1.6	0.035	30	40	3	1	10	18	10	20	3	1.5	3



Şekil 4.7. Mikroşerit antenin S11 parametresinin simülasyon sonuçları (Anten 2)

Şekil 4.7.' de ikinci antenin simülasyon sonucu gösterilmiştir. İkinci anten için rezonans frekansı 3.177 Ghz olarak ölçülmüştür. Genel olarak S11 parametresinin -10 db'nin altında olması gerekmektedir. İkinci antenin S11 parametresinin (geri dönüş kaybı) yaklaşık değerinin 10.21 dB olduğu gözlenmiştir. Şekil 4.6.' da tasarlanan ikinci antenin ışımaya örüntüsü Şekil 4.8.' de gösterilmiştir. Şekilde görüldüğü antenin tek yöne yayılım yaptığı gözlenmiştir.



Şekil 4.8. Mikroşerit antenin ışımaya örüntüsü (Anten 2)

Aşağıda Çizelge 4.3' te EM yazılım programı kullanılarak her iki antenin analizi sonucu elde edilen rezonans frekans değerleri gösterilmektedir.

Çizelge 4.3. Her iki antenin elektromanyetik simülasyon yazılım sonuçları

Antenler	Rezonans Frekansı
Anten 1	3.261
Anten 2	3.177

4.2. Yapay Sinir Ağı Uygulaması

Elektromanyetik (EM) yazılım programı kullanarak antenlerin simülasyonları yapıldı ve elde edilen sonuçlar saklandı. Bu veriler YSA uygulaması için kullanıldı. Yapay sinir ağı uygulamasının ilk aşamasında rezonans frekansı incelendi. İkinci aşamasında ise üretimi gerçekleştirilen antenlerden birtanesinin verileri baz alınarak yayılım genişliği açısı incelendi. YSA, 10 giriş ve 2 ayrı çıkıştan oluşmaktadır. Giriş parametreleri antenin boyutlarında yapılan değişikliklerden oluşmaktadır. Toplam 390 tane antenin giriş parametrelerinin her biri manuel olarak girildi ve veriler kaydedildi. YSA uygulaması için MATLAB programı kullanılmıştır. Tüm veriler eğitim ve test verisi olarak iki parçaya bölünmüştür. Böylece eğitim aşamasında kullanılmayan veriler test aşamasında kullanılmıştır. Bu işlem 10 defa tekrarlanmış ve ortalama başarımların değerleri alınarak modelin başarımların değerleri belirlenmiştir. En başarılı model saklanarak anten parametrelerinin tahmininde kullanılacak model oluşturulmuştur.

Makine öğrenmesinde bir model oluşturulurken en uygun parametre kavramı yoktur. Bu kavram probleme ve verilere göre belirlenen bir unsurdur. Bundan dolayı uygun parametrelerin bulunması için YSA modelinin deneysel sonuçları değerlendirilerek sağlanır. Bu çalışmada model geliştirmek için nöron sayısı, eğitim algoritması ve gizli katman sayısı olmak üzere YSA'nın üç farklı parametresi analiz edilmiştir.

Nöron sayısı değişiminin modelin eğitime etkisini incelemek için farklı sayılarda nöronlar kullanılarak eğitimler yapılmış ve sonuçlar değerlendirilmiştir. Model geliştirilirken çalışılan nöron sayıları 10, 15, 20, 25, 30 ve 35 olarak belirlenmiştir.

YSA'lar deterministik bir model olduğundan farklı yöntemler ile optimize edilebilmektedir. Bu çalışmada da farklı eğitim algoritmasının eğitime etkisi incelenmiştir. LM ve BR eğitim algoritmaları kullanılmış ve sonuçlar incelenmiştir.

Aynı zamanda YSA'ların bir diğer parametresi olan gizli katman sayısı incelenmiştir. Tek katmanlı ve çift katmanlı YSA yönteminin başarıya etkisi incelenmiştir. Ayrıca YSA'lar eğitilirken eğitim ve test veri kümeleri dağılımının etkilerine de bakılmıştır. Eğitimde kullanılan veri sayısı farklı oranlarda kullanılarak etkileri incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır.


Sonuç olarak geliştirilen model için farklı eğitim-test veri kümesi oranları, farklı eğitim algoritmaları, farklı nöron sayıları, tek katmanlı ve çok katmanlı YSA modelleri uygulanarak sonuçlar incelenmiştir.

4.3. Yapay Sinir Ağı Modelleri


4.3.1. Rezonans frekansı için tek katmanlı yapay sinir ağı modelleri

Levenberg marquart eğitim algoritması

Tek katmanlı Levenberg Marquart (LM) eğitim algoritması uygulanmıştır. Eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır. Nöron sayıları 10, 15, 20, 25, 30 ve 35 olarak belirlenmiştir. Sistem, farklı eğitim-test ve nöron sayılarının her biri için 10 defa eğitilmiştir. Eğitim işlemi gerçekleştirilirken ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve ortalama mutlak yüzde hata (OMYH) oranları hesaplanmış ve veriler saklanmıştır. En yüksek OKH'nin 3.1101 ve en düşük OKH oranının 0.0027 olduğu gözlemlenmiştir. Hata oranlarını değerlendirirken sıfıra uzak olanı en kötü değer, yakın olanı da en iyi değer olarak ifade edilmiştir. Elde edilen ortalama hata oranları göz önünde bulundurularak en kötü OKH ve en iyi OKH oranına sahip değerlerin regülasyon grafikleri aşağıda gösterilmiştir. Şekil 4.9.' da en yüksek OKH'ya sahip verinin regülasyon grafiği ve Şekil 4.10.' da en iyi değere yani en düşük OKH' ya sahip verinin regülasyon grafiği gösterilmiştir.



Şekil 4.9. Rezonans frekansı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği



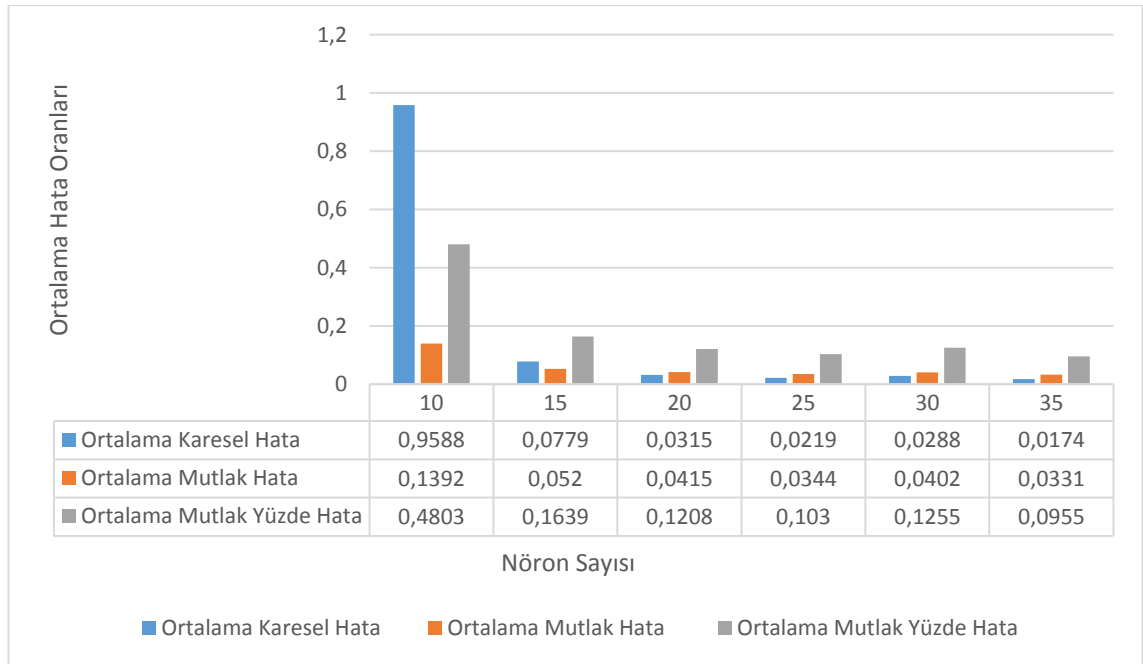
Şekil 4.10. Rezonans frekansı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği

Verinin yaklaşık %75'i eğitim için, %25'i ise test için ayrılmıştır. Nöron sayısı 10 alınarak en kötü OKH değeri bulunmuştur. Eğitim ve test sayısı sabit tutuldu sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiş ve 10 verinin ortalama hata oranları hesaplanmıştır. Elde edilen sonuçlar Çizelge 4.4' te gösterilmiştir.

Çizelge 4.4. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.9588	0.1392	0.4803
15	0.0779	0.0520	0.1639
20	0.0315	0.0415	0.1208
25	0.0219	0.0344	0.1030
30	0.0288	0.0402	0.1255
35	0.0174	0.0331	0.0955

Toplam verinin %75'i eğitim için, %25'i ise test için kullanılmıştır. Nöron sayısı ve eğitim-test veri değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.11.' de yapılan değişikliklerin, elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.11. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

En düşük OKH oranına sahip değer için ise verinin yaklaşık %80'i eğitim, %20'si ise test için kullanıldığında ve nöron sayısının da 10 olduğu durumda elde edilmiştir. Eğitim ve test sayısı sabit tutulmuş olup sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiştir ve 10 verinin ortalama hata oranları hesaplanmıştır. OKH, OMH ve OMYH verileri Çizelge 4.5' te verilmiştir.

Çizelge 4.5. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.1802	0.0514	0.1426
15	0.0144	0.0261	0.0630
20	0.0341	0.0401	0.0891
25	0.0542	0.0442	0.0950
30	0.0338	0.0410	0.0864
35	0.0254	0.0366	0.0865


Toplam verinin %80'i eğitim için, %20'si ise test için kullanılmıştır. Nöron sayısı ve eğitim-test veri değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.12.' de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.12. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Bayesian regularization eğitim algoritması

Tek katmanlı Bayesian Regularization (BR) eğitim algoritması uygulanarak rezonans frekansı için modelin hata oranları hesaplanmıştır. Eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve 20% oranlarında test kümesi oluşturularak kullanılmıştır. Nöron sayıları 10, 15, 20, 25, 30, 35 olarak belirlenerek sistem farklı eğitim, test ve nöron sayılarının her biri için 10 defa eğitilmiştir. Eğitim işlemi sırasında OKH, OMH ve OMYH oranları saklanmıştır. En yüksek OKH' nin 0.4835 ve en düşük OKH oranının 0.0025 olduğu tespit edilmiştir. Eğitim algoritmasının en kötü sonucu, verinin yaklaşık %70'i eğitim, %30'u ise test için kullanıldığında ve nöron sayısının 10 olduğu durumda elde edilmiştir. En iyi OKH oranı ise verinin yaklaşık %80'i eğitim için, %20'si ise test için kullanıldığında ve nöron sayısının 30 olduğu durumda elde edilmiştir. Elde edilen ortalama hata oranları göz önünde bulundurularak en yüksek (en kötü) OKH ve en düşük (en iyi) OKH oranına sahip değerlerin regülasyon grafikleri aşağıda verilmiştir. Şekil 4.13.' te en kötü değere sahip regülasyon grafiği ve Şekil 4.14.' te en iyi değere sahip regülasyon grafiği gösterilmiştir.



Şekil 4.13. Rezonans frekansı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağır regülasyon grafiği



Şekil 4.14. Rezonans frekansı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği


En kötü OKH oranına sahip değerlerin eğitim-test sayısı sabit tutulmuş ve sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmıştır. Elde edilen veriler Çizelge 4.6’ da gösterilmiştir.

Çizelge 4.6. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.0717	0.0437	0.1330
15	0.0228	0.0365	0.1165
20	0.0229	0.0360	0.1111
25	0.0209	0.0359	0.1125
30	0.0187	0.0344	0.1106
35	0.0244	0.0389	0.1202

Toplam verinin %70’i eğitim için, %30’u ise test için kullanılmıştır. Nöron sayısı 10, 15, 20, 25, 30 ve 35 şeklinde belirlenerek nöron sayısı değişiminin başarı üzerindeki

etkisi incelenmiştir. Şekil 4.15.' te yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.15. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Verinin yaklaşık %80'i eğitim için, %20'si ise test ayrılmıştır. Nöron sayısı da 30 alınarak en iyi OKH değeri bulunmuştur. Eğitim ve test sayısı sabit tutularak sadece nöron sayısı değiştirilmiş ve her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmış ve sonuçlar Çizelge 4.7' de gösterilmiştir.

Çizelge 4.7. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.0479	0.0438	0.0118
15	0.0351	0.0431	0.0120
20	0.0337	0.0394	0.0108
25	0.0483	0.0472	0.0131
30	0.0377	0.0385	0.0108
35	0.0728	0.0561	0.0156

Toplam verinin %80'i eğitim için, %20'si ise test için kullanılmıştır. Nöron sayısı 10, 15, 20, 25, 30 ve 35 şeklinde değiştirilerek nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.16.' da yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.16. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

4.3.2. Rezonans frekansı için çok katmanlı yapay sinir ağı modelleri


Levenberg marquart eğitim algoritması

Çok katmanlı Levenberg Marquart (LM) eğitim algoritması kullanılarak rezonans frekansı için modelin hata oranları hesaplanmıştır. Eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve 20% oranlarında test kümesi oluşturularak kullanılmıştır. Aynı zamanda nöron sayısı 10, 15, 20, 25, 30, 35 şeklinde belirlenerek ağ yapısı çok katmanlı olarak değiştirilmiş ve tüm değişimin eğitime etkisi incelenmiştir. OKH oranlarından en yüksek ve en düşük olanı belirlenmiştir. En yüksek OKH'nin 0.1438 ve en düşük OKH oranının 0.0011 olduğu gözlemlenmiştir. Elde edilen sonuçlar incelendiğinde en kötü sonuç, verinin yaklaşık %75'i eğitim, %25'i test için ayrıldığı ve nöron sayısının ise [10 15] olduğu durumda elde edilmiştir ve regülasyon grafiği Şekil 4.17.' de gösterilmiştir. En iyi sonuç ise %70'

i eğitim, %30'u test ve nöron sayısının ise [30 10] olduğu durumda gözlemlenmiş ve regülasyon grafiği Şekil 4.18.' de gösterilmiştir.



Şekil 4.17. Rezonans frekansı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği



Şekil 4.18. Rezonans frekansı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği


Verinin yaklaşık %75'i eğitim, %25'i test için ve nöron sayısının da [10 15] olduğu durumda en kötü OKH bulunmuştur. Her ağ için sistem 10 defa eğitilmiştir. 10 eğitimin ortalama hata oranları hesaplanmış ve elde edilen sonuçlar Çizelge 4.8' de gösterilmiştir.

Çizelge 4.8. En kötü ortalama karesel hata oranına sahip veri baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[10 10]	0.0382	0.0493	4.7310
[10 15]	0.0432	0.0479	3.5882
[10 20]	0.0407	0.0476	4.9016
[10 25]	0.0206	0.0392	3.7324
[10 30]	0.0284	0.0439	3.9782
[10 35]	0.0309	0.0481	3.4003

Toplam verinin %75'i eğitim için, %25'i ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi

incelenmiştir. Şekil 4.19.' da yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.19. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

En iyi sonuç ise verinin yaklaşık %70'i eğitim, %30'u test için ve nöron sayısının ise [30 10] olduğu durumda gözlemlenmiştir. Her ağ 10 defa eğitilmiş ve 10 eğitimin ortalama hata oranları hesaplanmıştır. Elde edilen sonuçlar Çizelge 4.9' da gösterilmiştir. Çizelge 4.9. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[30 10]	0.0081	0.0177	0.0587
[30 15]	0.0073	0.0216	0.0668
[30 20]	0.0121	0.0252	0.0819
[30 25]	0.0087	0.0214	0.0738
[30 30]	0.0082	0.0230	0.0763
[30 35]	0.0076	0.0227	0.0731


Toplam verinin yaklaşık %70'i eğitim için, %30'u ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.20.' de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.20. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Bayesian regularization eğitim algoritması

Çok katmanlı BR eğitim algoritması kullanılarak rezonans frekansı için modelin hata oranları hesaplandı. Eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve 20% oranları test kümesi oluşturularak kullanılmıştır. Nöron sayıları 10, 15, 20, 25, 30 ve 35 olarak belirlenmiştir. Çok katmanlı sinir ağı yapısı kullanılarak değişimin eğitime etkisi de incelenmiştir. Ortalama hata oranlarından OKH, OMH ve OMYH değerleri bulunmuş ve hata oranlarından OKH'nin en yüksek olanı ve en düşük olanı dikkate alınarak en kötü ve en iyi sonuçlar seçilmiştir. En yüksek olanı en kötü sonuç ve en düşük olanı ise en iyi sonuç olarak ifade edilmiştir. En kötü OKH 0.2131 ve en iyi OKH'nin 0.0011 olduğu gözlemlenmiştir. En kötü sonucun regülasyon grafiği Şekil 4.21.' de en iyi sonucun ise regülasyon grafiği Şekil 4.22.' de gösterilmiştir.



Şekil 4.21. Rezonans frekansı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği



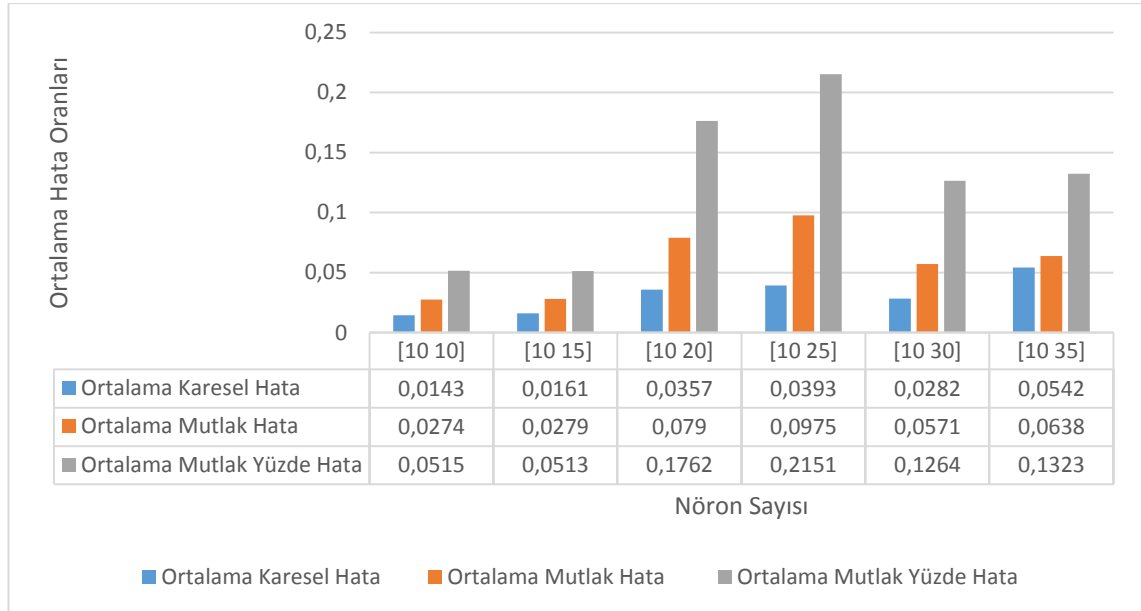
Şekil 4.22. Rezonans frekansı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği

Verinin yaklaşık %75'i eğitim için, %25'i ise test için ayrılmıştır. Nöron sayısının [10 35] olduğu durumda en kötü OKH değeri bulunmuştur. Eğitim ve test sayısı sabit tutuldu sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiş ve 10 verinin ortalama hata oranları hesaplanmıştır. Elde edilen sonuçlar Çizelge 4.10' da gösterilmiştir.

Çizelge 4.10. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[10 10]	0.0143	0.0274	0.0515
[10 15]	0.0161	0.0279	0.0513
[10 20]	0.0357	0.0790	0.1762
[10 25]	0.0393	0.0975	0.2151
[10 30]	0.0282	0.0571	0.1264
[10 35]	0.0542	0.0638	0.1323

Toplam verinin %75'i eğitim için, % 25'i ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.23.' te yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.



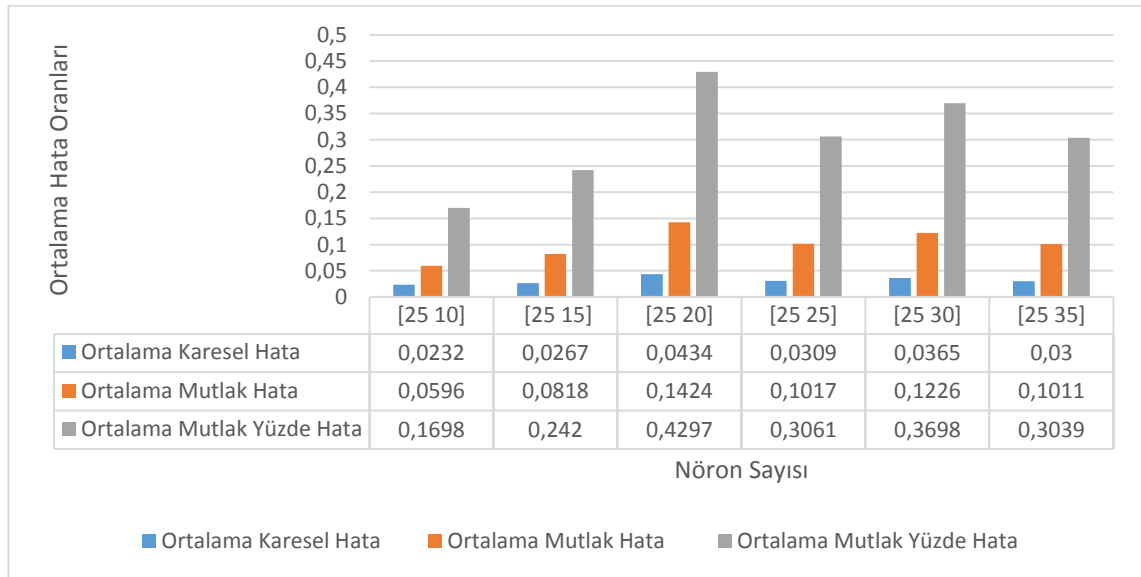
Şekil 4.23. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

En iyi sonuç ise verinin yaklaşık %80'i eğitim, %20'si test için ve nöron sayısının [25 25] olduğu durumda gözlemlenmiştir. Eğitim ve test sayısı sabit tutulmuş ve sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiştir. 10 verinin ortalama hata oranları hesaplanmış ve elde edilen sonuçlar Çizelge 4.11' de gösterilmiştir.

Çizelge 4.11. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[25 10]	0.0232	0.0596	0.1698
[25 15]	0.0267	0.0818	0.2420
[25 20]	0.0434	0.1424	0.4297
[25 25]	0.0309	0.1017	0.3061
[25 30]	0.0365	0.1226	0.3698
[25 35]	0.0300	0.1011	0.3039

Toplam verinin %80'i eğitim için, %20'i ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. En iyi ortalama hata oranlarının nöron sayısının [25 10] olduğu gözlemlenmiştir. Şekil 4.24.' te yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.24. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları


4.3.3. Yayılm genişliği açısı için tek katmanlı yapay sinir ağı modeli

Levenberg marquart eğitim algoritması

Eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelendi. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır. Aynı zamanda bu değişimin eğitime etkisi de incelenmiştir. Sistem farklı eğitim-test data sayılarının ve nöron sayılarının her biri için 10 defa eğitilmiştir. Eğitim işleminde ortalama karesel hata (OKH), ortalama mutlak hata (OMH) ve ortalama mutlak yüzde hata (OMYH) oranları hesaplanarak veriler saklanmıştır. En yüksek OKH'nin 1.8717 ve en düşük OKH oranının 0.0039 olduğu gözlemlenmiştir. En kötü OKH ve en iyi OKH oranına sahip ağıın regülasyon grafikleri aşağıda gösterilmiştir. Şekil 4.25.' te en kötü OKH'ye sahip verinin regülasyon grafiği ve Şekil 4.26.' da ise en iyi değere sahip verinin regülasyon grafiği gösterilmiştir.



Şekil 4.25. Yayılm genişliği açısı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağıın regülasyon grafiği



Şekil 4.26. Yayılm genişliği açısı için tek katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği


Verinin yaklaşık %70'i eğitim için, %30'u ise test için ayrılmıştır. Nöron sayısının 10 olduğu durumda en kötü OKH değeri elde edilmiştir. Eğitim ve test sayısı sabit tutuldu sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmış ve sonuçlar Çizelge 4.12' de gösterilmiştir.

Çizelge 4.12. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.5562	0.1225	0.2675
15	0.4152	0.1141	0.2505
20	0.2934	0.1073	0.2409
25	0.2002	0.1011	0.2235
30	0.2484	0.1130	0.2445
35	0.2647	0.1137	0.2363

Toplam verinin %70'i eğitim için, %30'u ise test için kullanılmıştır. Tek katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi

incelenmiştir. En kötü ortalama hata oranlarının nöron sayısının 10 olduğu gözlenmiştir. Şekil 4.27.' de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.



Şekil 4.27. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları


En iyi OKH değeri ise, verinin yaklaşık %75'i eğitim, % 25'i test ve nöron sayısının 10 olduğu durumda gözlemlenmiştir. Eğitim ve test sayısı sabit tutularak olup sadece nöron sayısı değiştirilmiş ve her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmış ve sonuçlar Çizelge 4.13' te verilmiştir.

Çizelge 4.13. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.1242	0.0569	0.0878
15	0.2828	0.0867	0.1371
20	0.4421	0.1382	0.2174
25	0.2702	0.1251	0.2158
30	0.4583	0.1361	0.2293
35	0.3092	0.1550	0.2636

Toplam verinin %75'i eğitim için, % 25'i ise test için kullanılmıştır. Tek katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi

incelenmiştir. En iyi ortalama hata oranlarında nöron sayısının 10 olduğu gözlenmiştir. Şekil 4.28.' de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.28. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları


Bayesian regularization eğitim algoritması

Tek katmanlı BR eğitim algoritmasının başarıya etkisi ve aynı zamanda eğitim-test setinde oranların ve nöron sayılarının değişiminin sonuçlara etkisi incelenmiştir. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır. Nöron sayıları 10, 15, 20, 25, 30 ve 35 olarak belirlenmiştir. Sistem, farklı eğitim, test ve nöron sayılarının her biri için 10 defa eğitilmiştir. Eğitim işlemi sırasında OKH, OMH ve OMYH oranları hesaplanmıştır. En yüksek OKH'nin 0.0025 ve en düşük OKH oranının 0.0010 olduğu gözlenmiştir. Verinin yaklaşık %70'i eğitim için, %30'u ise test için ayrılmıştır. Nöron sayısının 10 olduğu durumda en kötü OKH değeri elde edilmiştir. En iyi OKH oranı ise, verinin yaklaşık %80'i eğitim için, %20'si ise test için ayrıldığında ve nöron sayısının ise 10 olduğu durumda elde edilmiştir. Elde edilen ortalama hata oranları göz önünde bulundurularak en yüksek (en kötü) OKH ve en düşük (en iyi) OKH oranına sahip değerlerin regülasyon grafikleri aşağıda gösterilmiştir.

Şekil 4.29.' da en kötü değere sahip regülasyon grafiği ve Şekil 4.30.' da ise en iyi değerimize sahip regülasyon grafiği gösterilmiştir.



Şekil 4.29. Yayılm genişliği açısı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği




Şekil 4.30. Yayılm genişliği açısı için tek katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği

En kötü OKH oranının eğitim verileri dikkate alınarak elde edilen 10 sonucun ortalama hata oranları hesaplanmıştır. Sonuçlar Çizelge 4.14’ te gösterilmiştir.

Çizelge 4.14. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.0028	0.0226	0.0395
15	0.0026	0.0222	0.0389
20	0.0026	0.0220	0.0387
25	0.0026	0.0217	0.0384
30	0.0027	0.0222	0.0390
35	0.0026	0.0220	0.0386

Toplam verinin %70’i eğitim için, %30’u ise test için kullanılmıştır. Tek katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. En kötü ortalama hata oranlarının nöron sayısının 10 olduğu gözlemlenmiştir. Şekil 4.31.’ de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.31. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Aynı zamanda en iyi OKH oranının eğitim verileri dikkate alınarak elde edilen 10 sonucun ortalama hata oranları hesaplanmış ve sonuçlar Çizelge 4.15’ te gösterilmiştir.

Çizelge 4.15. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.0011	0.0164	0.0281
15	0.0011	0.0168	0.0291
20	0.0011	0.0168	0.0290
25	0.0011	0.0164	0.0283
30	0.0012	0.0167	0.0288
35	0.0012	0.0165	0.0284

Toplam verinin %80’i eğitim için, %20’si ise test için kullanılmıştır. Tek katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. En iyi ortalama hata oranlarında nöron sayısının 10 olduğu gözlemlenmiştir. Şekil 4.32.’ de yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.32. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları


4.3.4. Yayılm genişliği açısı için çok katmanlı yapay sinir ağı modelleri

Levenberg marquart eğitim algoritması

Çok katmanlı Levenberg Marquart (LM) eğitim algoritması, yayılım genişliği açısında kullanılmak üzere model belirlenmesi amacıyla uygulanmıştır. Verilerin yaklaşık %70, %75 ve %80'i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır. Bununla birlikte nöron sayısı değişiminin eğitime etkisi de incelenmiştir. Nöron sayısı 10, 15, 20, 25, 30, 35 olarak belirlendi ve çok katmanlı YSA yapısı kullanılarak sonuçlar incelenmiştir. OKH'nin en yüksek değeri 0.8825, en düşük değeri ise 0.0035 olarak hesaplanmıştır. Aşağıdaki Şekil 4.33.' te OKH'nin en yüksek çıktığı ağın regülasyon grafiği, Şekil 4.34.' te ise düşük değere sahip ağın OKH'nin regülasyon grafiği verilmiştir.



Şekil 4.33. Yayılm genişliği açısı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği




Şekil 4.34. Yayılm genişliği açısı için çok katmanlı Levenberg Marquart eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği

Verinin yaklaşık %80'i eğitim için, %20'si ise test için ayrılmıştır. Nöron sayısının ise [10 20] olduğu durumda en kötü OKH değeri elde edilmiştir. Eğitim ve test sayısı sabit tutuldu sadece nöron sayısı değiştirilerek her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmış ve elde edilen sonuçlar Çizelge 4.16' da verilmiştir.

Çizelge 4.16. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[10 10]	0.1414	0.0993	0.2135
[10 15]	0.0943	0.0982	0.1890
[10 20]	0.1938	0.1482	0.2925
[10 25]	0.0649	0.1028	0.1987
[10 30]	0.0443	0.1031	0.1919
[10 35]	0.1010	0.1323	0.2393

Toplam verinin %80'i eğitim için, %20'si ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.35.' te yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.35. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

En iyi OKH değeri ise, verinin yaklaşık %75'i eğitim, % 25'i test ve nöron sayısının [10 10] olduğu durumda elde edilmiştir. Çok katmanlı YSA yapısı kullanılmış, nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Eğitim ve test sayısı sabit tutularak olup sadece nöron sayısı değiştirilmiş ve her ağ 10 defa eğitilmiştir. Elde edilen 10 verinin ortalama hata oranları hesaplanmış ve sonuçlar Çizelge 4.17' de gösterilmiştir.

Çizelge 4.17. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[10 10]	0.0696	0.0599	0.1244
[10 15]	0.0596	0.0661	0.1337
[10 20]	0.0624	0.0710	0.1361
[10 25]	0.0198	0.0708	0.1362
[10 30]	0.0233	0.0673	0.1373
[10 35]	0.0153	0.0665	0.1313

Toplam verinin %75'i eğitim için, %25'i ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.36.' da yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.36. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları


Bayesian regülarization eğitim algoritması

Çok katmanlı Bayesian Regülarization eğitim algoritması, yayılım genişliği açısı için kullanılacak modeli belirlemek için kullanılmıştır. Verilerin yaklaşık %70, %75 ve

%80' i eğitim seti olarak kullanılırken sırasıyla yine %30, %25 ve %20 oranlarında test kümesi oluşturularak kullanılmıştır. Nöron sayısı 10, 15, 20, 25, 30, 35 şeklinde belirlenmiştir. Çok katmanlı YSA yapısı kullanılarak tüm değişikliklerin sonuca etkisi incelenmiştir. Ortalama hata oranlarından OKH, OMH ve OMYH değerleri bulunmuştur. Hata oranlarından OKH'nin en yüksek olanı ve en düşük olanı dikkate alınarak en kötü ve en iyi sonuçlar seçilmiştir. En yüksek olanı en kötü sonucu ve en düşük olanı ise en iyi sonuç değerinden oluşmuştur. En kötü sonucun regülasyon grafiği Şekil 4.37.' de en iyi sonucun regülasyon grafiği ise Şekil 4.38.' de gösterilmiştir.



Şekil 4.37. Yayılm genişliği açısı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en kötü ortalama karesel hata değerine sahip ağın regülasyon grafiği



Şekil 4.38. Yayılm genişliği açısı için çok katmanlı Bayesian Regularization eğitim algoritması uygulanarak elde edilen en iyi ortalama karesel hata değerine sahip ağın regülasyon grafiği


Verinin yaklaşık %80'i eğitim için, %20'si ise test için ayrılmıştır. Nöron sayısının [30 10] olduğu durumda en kötü OKH değeri elde edilmiştir. OKH'si 0.0494 bulunmuştur. Bu veriler ve nöron grubu dikkate alınarak her ağ için sistem 10 defa eğitilmiştir. 10 eğitimin ortalama hata oranları hesaplanmış ve elde edilen sonuçlar Çizelge 4.18' de gösterilmiştir.

Çizelge 4.18. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[30 10]	0.0161	0.0704	0.1276
[30 15]	0.0058	0.0467	0.0815
[30 20]	0.0100	0.0628	0.1114
[30 25]	0.0102	0.0683	0.1206
[30 30]	0.0060	0.0437	0.0785
[30 35]	0.0041	0.0372	0.0653

Toplam verinin %80'i eğitim için, %20'si ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi

incelenmiştir. Şekil 4.39.' da yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.




Şekil 4.39. En kötü ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

En düşük OKH oranı 0.0004 bulunmuştur. En iyi OKH değeri ise, verinin yaklaşık %80'i eğitim, % 20'si test ve nöron sayısının [15 35] olduğu durumda elde edilmiştir. Çok katmanlı YSA yapısı kullanılmış nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Bu veriler ve nöron grubu dikkate alınarak her ağ 10 defa eğitilmiştir. 10 eğitimin ortalama hata oranları hesaplanmış ve elde edilen sonuçlar Çizelge 4.19' da gösterilmiştir.

Çizelge 4.19. En iyi ortalama hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[15 10]	0.0126	0.0849	0.1482
[15 15]	0.0101	0.0683	0.1200
[15 20]	0.0041	0.0372	0.0651
[15 25]	0.0040	0.0362	0.0632
[15 30]	0.0040	0.0365	0.0639
[15 35]	0.0061	0.0395	0.0703

Toplam verinin %80'i eğitim için, %20'si ise test için kullanılmıştır. Çok katmanlı YSA yapısı kullanılmış aynı zamanda nöron sayısı değişiminin başarı üzerindeki etkisi incelenmiştir. Şekil 4.40.' ta yapılan değişikliklerin elde edilen ortalama hata oranları üzerindeki etkisi gösterilmiştir.



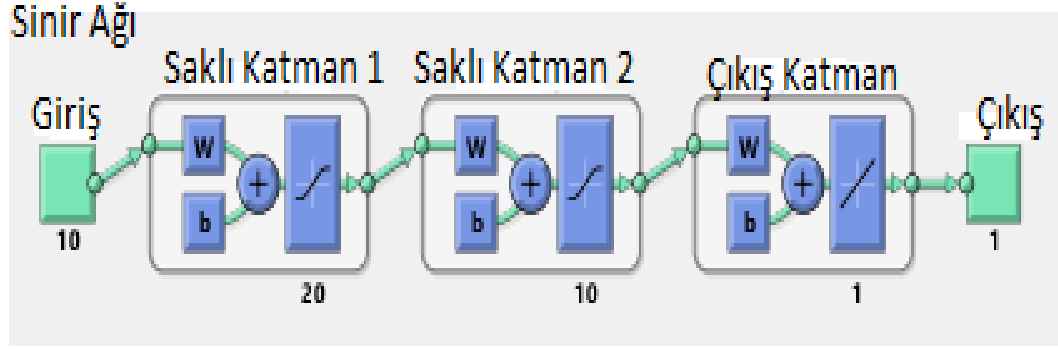
Şekil 4.40. En iyi ortalama karesel hata oranına sahip veri seti baz alınarak elde edilen ortalama hata oranları

4.4. Model Belirleme

Yukarıda gerçekleştirilen yapay sinir ağı (YSA) yöntemi işlemlerinin tümü çalışmada kullanılacak modeli belirlemek için uygulanmıştır. Farklı eğitim algoritmaları ve yapıları denenerek sonuçlar karşılaştırılmıştır. Eğitim sonucu elde edilen ortalama hata oranlarından en düşük olan en az iki değer dikkate alınarak model seçimi gerçekleştirilmiştir. Elde edilen verilerin tümü değerlendirildiğinde rezonans frekansı için en uygun modelin sonuçlarının çok katmanlı Levenberg Eğitim (LM) algoritması kullanarak elde edilen sonuçlar olduğu gözlemlenmiştir. Verinin yaklaşık %70'i eğitim, %30'u test için ayrılmıştır. Nöron sayısının ise [20 10] olduğu görülmüştür ve ortalama hata oranları Çizelge 4.20' de verilmiştir.

Çizelge 4.20. Rezonans frekansı için elde edilen en düşük ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
[20 10]	0.0036	0.0131	0.0377




Şekil 4.41. Matlab ortamında sinir ağı eğitimi

Şekil 4.41.' de MATLAB ortamında sinir ağı eğitimi ve rezonans frekansı için en uygun modelin gösterimi mevcuttur. Rezonans frekansı modelini belirlemek için uygulanan işlemler aynı şekilde yayılım genişliği açısı için de uygulanmıştır. Elde edilen verilerin tümü değerlendirildiğinde yayılım genişliği açısı için, verinin yaklaşık %80'i eğitim, %20'si test için ayrılmıştır. Nöron sayısının ise 10 olduğu görülmüştür. Aynı zamanda en uygun modelin tek katmanlı BR eğitim algoritması olduğu gözlemlenmiş ve ortalama hata oranları Çizelge 4.21' de gösterilmiştir.

Çizelge 4.21. Yayılım genişliği açısı için elde edilen en düşük ortalama hata oranları

Nöron Sayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata	Ortalama Mutlak Yüzde Hata
10	0.0011	0.0164	0.0281



Şekil 4.42. Matlab ortamında sinir ağı eğitimi

Elde edilen verilerin tümü incelenmiş ve yayılım genişliği açısı için en uygun model Şekil 4.42.' de gösterilmiştir. YSA uygulaması sonucu yayılım açısı genişliği 83.34 derece ölçülmüştür. EM simülasyon yazılımı kullanılarak elde edilen sonucun YSA uygulaması sonucu ile uyumluluk içinde olduğu gözlemlenmiştir.

4.5. Anten Üretimi


Anten üretimi işlemini gerçekleştirmek için oluşturulan veri kümesi kullanılmıştır. Toplam 390 tane verinin yaklaşık %98'i eğitim için, yüzde%2'i ise test

için ayrılmıştır. Her ağın 10 defa eğitilmesi sonucu elde edilen ortalama hata oranları saklanmıştır. Test edilen bu antenlerin simülasyon sonucu ve YSA uygulaması sonucu elde edilen çıkış parametrelerinin birbiriyle uyumlu olduğu gözlemlenmiştir. Bu çıkış parametrelerinden en iyi olan iki tanesi seçilerek anten üretim işlemi gerçekleştirilmiştir. YSA uygulaması kullanarak birinci anten için elde edilen rezonans frekansı 3.2604 iken ikinci anten için 3.1769 olduğu gözlemlenmiştir. Antenin baskısı için LPFK (Laser & electronics)-protoMat E33 cihazı kullanılmış ve Şekil 4.43.' te hem anten üretim işlemleri hem de kullanılan cihaz gösterilmiştir.



Şekil 4.43. Anten üretim işlemleri

Şekil 4.44.' te üretilen antenlerin ilki gösterilmiştir. Şekilde görüldüğü gibi anten alt katman, dielektrik tabaka ve yama olmak üzere üç farklı katmandan oluşmaktadır. Alt katman ve yamanın malzemesi bakır, dielektrik katman için FR-4 malzemesi kullanılmıştır. Aynı zamanda antenin ölçüm işlemlerini gerçekleştirmek için port kullanılmıştır. Anten ölçüm işlemini gerçekleştirmek için lehim makinesi kullanılarak port ve yama bağlantısı yapılmıştır.



a)




b)

Şekil 4.44. Üretilen Anten 1 a) Ön yüz, b) Arka Yüz


Üretimi gerçekleştirilen antenin tüm parametreleri Çizelge 4.22' de verilmiştir.

Çizelge 4.22. Antenin parametreleri (Anten 1)

Parametreler	Wg	Lg	h	t	wp	lp	a	b	c	sl	sw	dw	dl	dk	dm
Değerler	60	60	1.6	0.035	30	40	3	1	10	14	10	20	6	1	2



a)




b)

Şekil 4.45. a) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 1) (yakın görüntüsü), b) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 1) (uzak görüntüsü)

Laboratuvar ortamında gerçekleştirilen anten ölçümlerinde kalibrasyon için frekans aralığı 1- 8 Ghz arası seçilmiştir. Şekil 4.45.' te deneysel ölçüm sonucu rezonans frekansı 3.345 ve S11(geri dönüş kaybı) parametresinin -17.98 dB olduğu gözlemlenmiştir. Çizelge 4.23' te tasarlanan, YSA yöntemi uygulanan ve üretimi yapılan ilk antenin elde edilen tüm sonuçları gösterilmiştir.

Çizelge 4.23. Anten sonuçları (Anten 1)

Uygulama	Simülasyon	YSA	Deneysel Ölçüm
Rezonans	3.261	3.2604	3.345




Şekil 4.46. Antenin simülasyon ve deneysel sonucu

Şekil 4.46.' da EM simülasyon programı kullanarak elde edilen rezonans frekansı ve S11 parametresi değeri ile gerçekleştirilen ölçüm işlemi sonucu elde edilen rezonans frekansı ve S11 parametresi sonuçları karşılaştırılmıştır.

Şekil 4.47.' de bu çalışmada incelenen bir diğer çıkış parametresi olan yayılım genişliği açısı sonuçları karşılaştırılmıştır. Bu parametrenin veri kümesi için birinci antenin rezonans frekansı baz alınmıştır. Antenlerin geometrik şeklinde herhangi bir değişiklik yapılmamıştır. Simülasyon sonucu yayılım genişliği açısı 82.4 derece olduğu gözlemlenmiştir. YSA uygulaması sonucu yayılım açısı genişliğinin 83.34 derece olduğu gözlemlenmiştir. Daha sonra bu antenin ölçüm işlemi gerçekleştirilmiştir. Ölçüm aşamasında toplam 400 tane veri kullanılmıştır. Bu data 0.9 derecelik farklarla oluşturulmuştur. Ölçüm işlemi gerçekleştirilen bu antenin yayılım genişliği açısı ise 79.2 derece olarak ölçülmüştür. Şekil 4.47.b.' de gösterildiği gibi 3 dB'in karşılık geldiği derecenin 79.2 derece olduğu gözlemlenmiştir. Ölçüm sonuçları ile simülasyon

sonuçlarının karşılaştırılmasından ışına açılarının birbirine çok yakın olduğu görülmüştür. Aradaki ufak farklılık mükemmel olmayan bağlantı aparatları, yapılan lehimden dolayı oluşan kayıplar ve test kablolarındaki kayıplardan kaynaklandığı düşünülmektedir. Görsel farklılığın ise polar gösterimlerde kullanılan skala farklılığından kaynaklandığı söylenebilir. İstenmeyen arka lobların laboratuvar ölçümlerinde daha düşük (yaklaşık -15dB) değerlerinde çıkması ise yönlülüğün ölçümde normalize edilmesinden kaynaklandığı görülmektedir. Simülasyondaki yönlülük değeri eklendiği zaman neredeyse aynı değerler elde edilmektedir.




Şekil 4.47. Antenin polar görüntüsü a) Simülasyon sonucu, b) Ölçüm sonucu

Aşağıdaki Çizelge 4.24' te simülasyon, modelleme ve ölçüm sonucu elde edilen yayılım açısı genişliği gösterilmiştir.

Çizelge 4.24. Antenin sonuçları

Uygulamalar	Simülasyon	YSA	Ölçüm
Ölçülen değerler	82.4	83.34	79.2

Şekil 4.48.' de üretilen ikinci anten gösterilmiştir. Birinci anten ile farkı, boyutlarında yapılan değişiklikler olmuştur. Anten 3 katmandan oluşmuştur ve anten 1 için kullanılan malzemenin aynısı anten 2 içinde kullanılmıştır. Şekilde görüldüğü gibi alt katmanın bakır kullanılması nedeniyle yayılımın geriye doğru yapılmasını engellemek ve tüm yayılımın ön tarafa doğru olmasını sağlamaktır.



a)



b)


Şekil 4.48. Üretilen anten 2 a) Ön yüz, b) Arka yüz

Antenin parametre değerleri aşağıdaki Çizelge 4.25' te verilmiştir.


Çizelge 4.25. Antenin parametreleri (Anten 2)

Parametreler	Wg	Lg	h	t	wp	lp	a	b	c	sl	sw	dw	dl	dk	dm
Değerler	60	60	1.6	0.035	30	40	3	1	10	18	10	20	3	1.5	3

Şekil 4.49.' da ikinci antenin ölçüm işlemi gösterilmiştir. Ölçüm işlemini gerçekleştirmek için frekans aralığı 1-8 Ghz arası seçilmiştir.




a)



b)

Şekil 4.49. a) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 2) (yakın görüntüsü), b) Tasarlanan mikroşerit antenin S11 parametresinin deneysel olarak ölçülmesi (Anten 2) (uzak görüntüsü)

Şekil 4.50.' de EM simülasyon programı kullanılarak elde edilen rezonans frekans ve S11 (geri dönüş kaybı) parametresi ile gerçekleştirilen ölçüm işlemi sonucu elde edilen rezonans frekansı değeri ve S11 parametresine ait sonuçlar gösterilmiştir.



Şekil 4.50. Antenin simülasyon ve deney sonucu

Aşağıdaki Çizelge 4.26' da tasarlanan, YSA yöntemi uygulanan ve üretimi yapılan ikinci antenin elde edilen tüm sonuçları gösterilmiştir.

Çizelge 4.26. Anten sonuçları (Anten 2)

Uygulama	Simülasyon	YSA	DeneySEL Ölçüm
Rezonans	3.177	3.1769	3.275

İkinci anten için rezonans frekansı 3.275 ve S11 parametresi -15.56 dB olarak ölçülmüştür. Çizelge 4.23' te ve Çizelge 4.26' da elde edilen deneysel sonuçlar Agilent marka 2-portlu PNA-L Network Analyzer cihazı kullanılarak elde edilmiştir. Bu cihaz 10Mhz-43.5Ghz aralığında ölçüm yapabilmektedir. Rezonans frekansını ölçüm aşamasında kalibrasyon frekans aralığı 1-8 Ghz arası seçilmiştir.

5. SONUÇ

Bu çalışmada, yapay sinir ağı (YSA) yöntemi kullanarak mikroşerit yama antenlerin (MYA) rezonans frekansı ve yarı gücü ışınımının incelenmesi amaçlanmıştır. Anten tasarımındaki matematiksel ifadelerden kaçınmak ve işlemleri daha kısa sürede, daha az maliyet ile gerçekleştirebilmek gibi avantajlarından dolayı YSA yöntemi tercih edilmiştir. Farklı yazılım ve farklı eğitim algoritmaları kullanılarak işlemler gerçekleştirilmiştir. MYA' nın tasarımı için elektromanyetik (EM) yazılım programı kullanılmıştır. YSA yöntemi anten parametrelerinden olan rezonans frekansı ve yayılım genişliğini tahmin etmek amacıyla kullanılmıştır. Örneğin; EM simülasyon yazılım programı kullanarak elde edilen rezonans frekans değerleri sırasıyla 3.261Ghz ve 3.177 Ghz olarak ölçülmüşken bu değerler YSA uygulaması kullanılarak 3.2604Ghz ve 3.1769Ghz olarak tahmin edilmiştir. Aynı zamanda birinci antenin değerleri baz alınarak antenin yayılım genişliği açısı incelenmiştir. Yayılım genişliği açısı simülasyonda 82.4 derece ölçülmüşken YSA yöntemi bunu 79.2 olarak tahmin etmiştir. YSA uygulaması MATLAB programında gerçekleştirilmiştir. Levenberg Marquart (LM) ve Bayesian Regularization (BR) YSA eğitim algoritmaları kullanılmıştır. LM eğitim algoritması BR eğitim algoritması ile kıyaslandığında LM eğitim algoritmasının daha hızlı olduğu gözlemlenmiştir. Aynı zamanda tek ve çok katmanlı YSA yapıları uygulanmıştır. Eğitim algoritmaları ve YSA yapıları uygulanarak elde edilen tüm sonuçlar karşılaştırılmış ve en iyi sonuçlar dikkate alınarak anten üretimi gerçekleştirilmiştir. YSA yöntemi kullanarak elde edilen sonuçların deney sonuçları ve EM yazılım programı kullanılarak elde edilen sonuçlar ile uyumluluk içinde olduğu gözlemlenmiştir. YSA yöntemi, antenlerin kazancını arttırma, istenmeyen loblarını azaltma ve ışınım yönünü ayarlama gibi antenin diğer önemli parametreleri için ve aynı zamanda farklı anten uygulamalarının kullanımında istenilen sonuçlar elde etmek amacıyla ileriki çalışmalar için önerilebilmektedir.

KAYNAKLAR

- Agarwal, E.N., Dhukarya, D.C., Garg, S., 2012. Pattern analysis of rectangular microstrip antenna for 3g frequency. **International Journal of Innovations in Engineering and Technology**, 1(4): 72-76.
- Akdagli, A., Toktas, A., Kayabasi, A., Develi, I., 2013. An application of artificial neural network to compute the resonant frequency of e-shaped compact microstrip antennas. **Journal of Electrical Engineering**, 64(5): 317-322.
- Alam, M.J., Faruque, M.R.I., Hasan, M.M., Islam, M.T., 2017. Split quadrilateral miniaturised multiband microstrip patch antenna design for modern communication system. **IET Microw. Antennas Propag**, 11(9): 1317-1323.
- Arora, I. and Saha A., 2016. Comparison of back propagation training algorithms for Software defect prediction. **In Contemporary Computing and Informatics(IC3I), 2016 2nd International Conference on**, 51-58.
- Balanis, C. A. 2005. **Antenna theory analysis and design, Third edition**, p.27 – 44. New Jersey.
- Bekasiewicz, A. and Koziel, S., 2016. Cost-efficient design optimization of compact patch antennas with improved bandwidth. **IEEE Antennas and Wireless Propagation Letters**, 15: 270-273.
- Bhagat, P.P., Pujara, D. and Adhyaru, D., 2012. Analysis and synthesis of microstrip patch antenna using artificial neural networks. **In Antennas and Propagation (APCAP), 2012 IEEE Asia-Pacific Conference on**, 120-121.
- Bhandarkar, V.V. and Naik A.J., 2016. Artificial neural network based implementation of space vector modulation for three phase VSI. **In Electrical Energy Systems (ICEES), 2016 3rd International Conference on**, 145-150.
- Bhavanam, S.N. and Kalyan, R.S., 2016. Design of a novel coaxial feed triple frequency patch antenna with slots and shorting pin. **International Conference on Computational Modeling and Security (CMS 2016)**, 85: 345-351.
- Bose, T. and Gupta, N., 2012. Design of an aperture-coupled microstrip antenna using a hybrid neural network. **IET Microw Antennas& Propagation**, 6(4): 470-474.
- Cai, T., Wang, G.M., Zhang, X.F., Wang, Y.W., Zong, B.F. and Xu H.X., 2015. Compact microstrip antenna with enhanced bandwidth by loading magneto-electro dielectric planar waveguided metamaterials. **IEEE Transactions on Antennas and Propagation**, 63(5): 2306-2311.
- Chhari, U. and Thakare, V.V., 2016. Analysis of performance parameters of double e-shaped microstrip antenna using artificial neural network. **International Research Journal of Engineering And Technology**, 3(9): 1450-1454.
- Dalipi, F. and Yayilgan, S.Y., 2015. The impact of environmental factors to skiing injuries: bayesian regularization neural network model for predicting skiing injuries. **In Computing, Communication and Networking Technologies (ICCCNT), 2015 6th International Conference on**, 1-6.
- Das, S., Chowdhury, P., Biswas A., Sarkar, P.P. and Chowdhury, S. K., 2015. Analysis of a miniaturized multiresonant wideband slotted microstrip antenna with modified ground plane. **IEEE Antennas And Wireless Propagation Letters**, 14: 60-63.
- Das, U.K., Tey, K.S., Seyedmahmoudiana, M., Mekhilef, S., Idna Idris, M.Y., Deventer, M.V., Horan, B., Stojcevski A., 2018. Forecasting of photovoltaic power generation and model optimization. **Renewable and Sustainable Energy Reviews**, 81: 912-928.

- Elantamilan, D., Saishanmuga Raja, V., Rajagopalan, S.P., 2016. Combining artificial neural network with image data partitioning for personal iris recognition system. **International Journal of Applied Engineering Research**, 11(4): 2396-2401.
- Eldhose, E.K. and Jisha G., 2016. Active cluster node aggregation scheme in wireless sensor network using neural network. **International Conference on Emerging Trends in Engineering, Science and Technology (ICETEST - 2015)**, 24: 1603 – 1608.
- Ferentinou, M. and Fakir, M., 2017. An ann approach for the prediction of uniaxial compressive strength, of some sedimentary and igneous rocks in eastern Kwazulu-Natal. **Symposium of the International Society for Rock Mechanics**, 191: 1117 – 1125.
- Galphade, R., 2017. Electrical characterization of a photovoltaic module through artificial neural network: A review. **International Journal of Electrical Components and Energy Conversion**, 3(1): 14-20.
- Gopalakrishnan, R. and Gunasekaran, N., 2005. Design of equilateral triangular microstrip antenna using artificial neural networks. **Small Antennas and Novel Metamaterials, 2005. IWAT 2005. IEEE International Workshop on**, 246-249.
- Gujral, M., Li, J.L.W., Yuan, T. and Qiu, C.W., 2012. Bandwidth improvement of microstrip antenna array using dummy ebg pattern on feedline. **Progress in Electromagnetics Research**, 127: 79-92.
- Gupta, P., Gupta, R., Sharma R., Yadav, B., 2013. Calculation of resonating frequency of an equilateral triangular microstrip antenna using artificial neural network. **Advanced Computational Techniques in Electromagnetics 2013**, 1-8.
- Gupta, R. and Singhal, S., 2016. Prediction of global solar radiation in India using artificial neural network. **Journal of Sustainable Development of Energy, Water and Environment Systems**, 4(2): 94-106.
- Güney, K., Erler, M., Sagioglu, S., 2000. Artificial neural networks for the resonant resistance calculation of electrically thin and thick rectangular microstrip antennas. **Electromagnetics**, 20(5): 387–400.
- Güney, K. ve Sarikaya, N., 2007. A hybrid method based on combining artificial neural network and fuzzy inference system for simultaneous computation of resonant frequencies of rectangular, circular, and triangular microstrip antennas. **IEEE Transactions on Antennas and Propagation**, 55(3): 659-668.
- Güney, K. ve Sarikaya, N., 2007. Resonant frequency calculation for circular microstrip antennas with a dielectric cover using adaptive network-based fuzzy inference system optimized by various algorithms. **Progress in Electromagnetics Research**, 72: 279–306.
- Honarbaksh, B., 2017. High-gain low-cost microstrip antennas and arrays based on FR4 epoxy. **International Journal of Electronics and Communications (AEÜ)**, 75: 1-7.
- Jafari-Marandi, R., Khanzadeh, M., Smith B.K., Bian, L., 2017. Self-organizing and error driven (soed) artificial neural network for smarter classifications. **Journal of Computational Design and Engineering**, 4: 282– 304.
- Jain, S., Tomar, P.S., Tomar, G.S., 2012. Design & analysis of proximity fed circular disk patch antenna. **International Journal of Emerging Technology and Advanced Engineering**, 2(10): 126-131.

- Kala, P., Saxena, R., Kumar, M., Kumar, A., Pant, R., Ganpati, S., 2012. Design of rectangular patch antenna using mlp artificial neural network. **Journal of Global Research in Computer Science**, 3(5): 11-14.
- Kaur, H. & Salaria, D.S., 2013. Bayesian regularization based neural network tool for software effort estimation. **Global Journal of Computer Science and Technology Neural & Artificial Intelligence**, 13(2): 44-50.
- Kaushal, D. and Shanmuganatham T. ,2016. Danger microstrip patch antenna for fixed satellite applications. **In Emerging Technological Trends (ICETT), International Conference**, 1-6.
- Kayabasi, A. ve Akdagli, A., 2016. A simple and efficient approach to compute the operating frequency of annular ring patch antennas by using ann with bayesian regularization learning algorithm. **International Journal of Intelligent Systems and Applications in Engineering**, 4(special issue): 239-243.
- Keong, K.C., Mustafa, M., Mohammad, A.J., Sulaiman, M.H., Abdullah, N.R.H., Samad, R., Pebrianti D., 2016 . Levenberg-marquardt flood prediction for sungai isap residence. **In Systems, Process and Control (ICSPC), 2016 IEEE Conference**, 160-165.
- Kermani, B.G., Schiffman, S.S., Nagle, H.T., 2005. Performance of the Levenberg-Marquardt neural network training method in electronic nose applications. **Sensors and Actuators B: Chemical**, 110(1): 13-22.
- Khatib, T., Mohamed, A., Mahmoud, M., Sopian, K., 2012. Estimating global solar energy using multilayer perception artificial neural network. **International Journal Of Energy**, 6(1): 25-33.
- Kim, S.H., Vu, T.M., Pyeon, C.H., 2017. A preliminary study on applicability of artificial neural network for optimized reflector designs. **5th International Symposium on Innovative Nuclear Energy Systems, INES-5**, 131: 77-85, Ookayama Campus, JAPAN.
- Kordalivand, A.M. and Rahman, T.A., 2013. Broadband modified rectangular micro strip patch antenna using stepped cut at four corners method. **Progress in Electromagnetics Research**, 137: 599-619.
- Kumar K.A., Ashwath, R., Kumar D.S., Malmathanraj, R., 2010. Optimization of multislotted rectangular microstrip patch antenna using ann and bacterial foraging optimization. **In Electromagnetic Compatibility (APEMC), 2010 Asia-Pacific Symposium**, 449-452.
- Kumar, A. and Rai, A., 2014. Resonant frequency of microstrip antenna using artificial neural network. **International Conference of Advance Research and Innovation (ICARI-2014)**, 330-334.
- Kushwaha, R.S., Srivastava, D.K., Saini, J.P., 2012. A multi-slotted wide microstrip patch antenna for dual frequency. **International Journal of Computer Science and Information Technologies**, 3(2): 3523-3525.
- Li, M. and Luk K.M., 2015. A low-profile, low-backlobe and wideband complementary antenna for wireless application. **IEEE Transactions on Antennas and Propagation**, 63(1): 7-14.
- Lotfi-Neyestanak, A.A., 2008. Ultra wideband rose leaf microstrip patch antenna. **Progress In Electromagnetics Research**, 86: 155–168.
- Lumba, S. and Singh, V.K., 2014. A novel approach for analysis of bandwidth of microstrip patch antenna using neural network. **International Journal of**

- Advanced Research in Computer Science and Software Engineering**, 4(2): 637-642.
- Malik, P.K., Vishnoi, V., Pundir, S., 2011. Hardware design of equilateral triangular microstrip antenna using artificial neural network. **International Journal of Computing Science and Communication Technologies**, 3(2): 642-645.
- Malmathanraj, R. and Selvi, S.T., 2014. Artificial neural network application in parameter optimization of rectangular microstrip patch antenna. **Ubiquitous Computing and Communication Journal**, 3(2): 94-108.
- Maurya, R.K., Vijay., Mishra, S., Chaudhary, N., Kumar, D., 2013. Model for calculation of patch radius of circular microstrip antennas using artificial neural network(ANN). **In Machine Intelligence and Research Advancement (ICMIRA), 2013 International Conference on**, 167-173.
- Mishra, A., Nandgaonkar, A.B., Bhagile, V.D., Mehrotra, S.C., Patil, P.M., 2009. Design of square and rectangular microstrip antenna with the use of ffbp algorithm of artificial neural network. **In Applied Electromagnetics Conference (AEMC), 2009 IEEE**, 1-4.
- Nadimi, V., Azadeh, A., Saberi, M., Fattahi, S., Danesh, B., Tajvidi, A., 2009. An artificial neural network algorithm and time series for improved forecasting of oil estimation: A case study of south korea and united kingdom(2001-2008). **In Digital Ecosystems and Technologies, 2009. DEST'09. 3rd IEEE International Conference on**, 739-744.
- Nasimuddin, N. and Chen, Z. N., 2008. Wideband microstrip antennas with sandwich substrate. **IET Microw. Antennas Propag**, 2(6): 538–546.
- Neog, D.K., Pattnaik, S.S., Panda, D.C., Devi, S., Khuntia B. and Dutta, M., 2005. Design of a wideband microstrip antenna and the use of artificial neural networks in parameter calculation. **IEEE Antennas and Propagation Magazine**, 47(3): 60-65.
- Ofure, E.J., David, O.O., Oludare, A.M., Musa, A.A., 2017. Artificial neural network model for the determination of gsm rxlevel from atmospheric parameters. **Engineering Science and Technology, an International Journal**, 20: 795–804.
- Pandit, M. and Bose, T., 2011. Application of neural network model for designing circular monopole antenna. **International Symposium on Devices MEMS, Intelligent Systems & Communication (ISDMISC) 2011**, 18-21.
- Parmar, H., 2015. Artificial neural network based modelling of photovoltaic system. **International Journal of Latest Trends in Engineering and Technology (IJLTET)**, 5(1): 50-59.
- Roy P.S. and Chakraborty, S., 2013. Design of c- slotted microstrip antenna using artificial neural network model. **International Journal of Research in Engineering and Technology**, 2(12): 120-124.
- Saini, S.S., Bhatia, H., Goel A., Sidhu E., 2016. High return loss microstrip patch antenna design for radio applications. **In Automatic Control and Dynamic Optimization Techniques (ICACDOT), International Conference on**, 1106-1109.
- Sahay, K.B., Sahu S., Singh P., 2016. Short-term load forecasting of toronto canada by using different ann algorithms. **In Power Systems (ICPS), 2016 IEEE 6th International Conference on**, 1-6.
- Shankar, S., Sarkar B.D., Chaurasiya, H., Thakur, S., 2015. Microstrip antenna's impedance analysis using different ann training algorithms: comparative study.

- In Computational Intelligence and Communication Networks (CICN), 2015 International Conference, 30-33.**
- Sharma, N. and Sharma, V., "baskida". A design of microstrip patch antenna using hybrid fractal slot for wideband applications. **Ain Shams Engineering Journal**, 1-7.
- Sharma, V. and Gupta, G.K., 2007. Using artificial neural network to model microstrip inset fed rectangular patch antenna. **Microwave and Millimeter Wave Technology, 2007. ICMMT '07. International Conference on**, 1-2.
- Singh B.K., 2015. Design of rectangular microstrip patch antenna based on artificial neural network algorithm. **In Signal Processing and Integrated Networks (SPIN), 2015 2nd International Conference**, 6-9.
- Singh, J., Singh, A.P. and Kamal T.S., 2011. Design of circular microstrip antenna using artificial neural networks. **In Proceedings of the World Congress on Engineering**, 2(1): 9-12.
- Singh, R., Sahay K.B., Srivastava, S.A., 2015. Short-term wind speed forecasting of oak park weather station by using different ann algorithms. **In Innovative Smart Grid Technologies-Asia (ISGTASIA), 2015 IEEE**, 1-6.
- Singh, S.V. and Bhargav A., 2014. Design and analysis of proximity coupled circularly polarised micro strip antenna with uneven parallel slots. **IOSR Journal of Electronics and Communication Engineering**, 9(6): 54-63.
- Sran, S.S. and Sivia, J.S., 2016. Quad staircase shaped microstrip patch antenna for s, c and x band applications. **International Conference on Computational Modeling and Security (CMS 2016)**, 85: 443 – 450.
- Stepchenko, A., Chizhov, J., Aleksejeva, L., Tolujev, J., 2017. Nonlinear, non-stationary and seasonal time series forecasting using different methods coupled with data preprocessing. **Procedia Computer Science**, 104: 578 – 585.
- Suryakanth, B. and Mulgi, S.N., 2013. Design and development of aperture coupled rectangular microstrip antenna for dual band operation. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, 2(8): 3607-3613.
- Thakare, V.V., Singhal, P., Das, K., 2008. Calculation of microstrip antenna bandwidth using artificial neural network. **In RF and Microwave Conference, 2008. RFM 2008. IEEE International**, 404-406, Kuala, Lumpur, MALAYSIA.
- Turkson, R.F., Yan, F., Ali, M.K.A., Hu, J., 2016. Artificial neural network applications in the calibration of spark-ignition engines: An overview. **Engineering Science and Technology, an International Journal**, 19: 1346-1359.
- M.Vastrad, D.C., 2013. Performance analysis of neural network models for oxazolines and oxazoles derivatives descriptor dataset. **International Journal of Information Sciences and Techniques (IJIST)**, 3(6): 1-15.
- Varma, R. and Ghosh, J., 2016. Design of electromagnetically-coupled microstrip antennas using artificial neural networks. **2016 2nd International Conference on Contemporary Computing and Informatics (IC3I)**, 185-189.
- Wang, J., Liu, Q. and Zhu, L., 2017. Bandwidth enhancement of a differential-fed equilateral triangular patch antenna via loading of shorting posts. **IEEE Transactions on Antennas And Propagation**, 65(1): 36-43.
- Wang, X., Zhang, M. and Wang, S.J., 2011. Practicability analysis and application of pbg structures on cylindrical conformal microstrip antenna and array. **Progress In Electromagnetics Research**, 115: 495-507.

Wei, L., Fang, Z., Luan, S., 2009. Travel time prediction method for urban expressway link based on artificial neural network. **In Natural Computation, 2009. ICNC'09. Fifth International Conference on**, 1: 358-362.



ÖZGEÇMİŞ

1988 yılında Mardin ilinde doğdu. İlkokul, ortaokul ve lise öğrenimini Mardin’de tamamladı. 2010 yılında Mustafa Kemal Üniversitesi İskenderun Meslek Yüksek Okulu Elektrik bölümünden, 2015 yılında Atılım Üniversitesi Elektrik Elektronik Mühendisliği bölümlerinden mezun oldu. 2016 yılında İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü bünyesinde Elektrik Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans eğitimine başladı.

