

YILDIZ TEKNİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MİKROELEKTRO MEKANİK ANAHTARLARIN HFSS VE YAPAY SİNİR AĞLARI İLE MODELLENMESİ

Elektronik ve Haberleşme Müh. Yavuz ELMAS

Elektronik ve Haberleşme Müh. Anabilim Dalı Haberleşme
Programında Hazırlanan

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Y. Doç. Dr. Hamid TORPİ

İSTANBUL, 2007

İÇİNDEKİLER	Sayfa
SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ.....	xiv
ÖNSÖZ.....	xv
ÖZET.....	xvi
ABSTRACT.....	xvii
 GİRİŞ.....	 1
 1 ANAHTARLAMA TEKNOLOJİLERİ.....	 2
1.1 Temel Anahtarlama Teorisi.....	2
1.2 Mikroelektronik RF Anahtarlama Teknolojileri.....	4
1.2.1 P-I-N Diyotlar.....	4
1.2.2 FET Diyotlar.....	5
1.2.3 RF-MEMS Anahtarlar.....	6
 2 RF MEMS ANAHTARLARIN İNCELENMESİ	 9
2.1 Temel MEMS Anahtar Yapısı.....	9
2.2 RF MEMS Anahtarların Üretimi.....	12
2.3 RF MEMS Anahtar Tasarımında Dikkat Edilmesi Gereken Hususlar.....	17
2.4 MEMS Anahtarların Güvenilirliği.....	22
 3 RF MEMS KAPASİTİF ANAHTARLARIN HFSS İLE MODELLENMESİ.....	 24
3.1 RF-MEMS Kapasitif Paralel Anahtarın HFSS İle Modellenmesi.....	25
3.2 RF-MEMS Kapasitif Seri Anahtarın HFSS İle Modellenmesi.....	38

4	YAPAY SİNİR AĞLARININ İNCELENMESİ.....	50
4.1	Yapay Sinir Ağlarına Genel Bakış.....	50
4.1.1	Yapay Sinir Ağı Nedir?.....	50
4.1.2	Yapay Sinir Ağlarının Tarihi.....	51
4.1.3	Yapay Sinir Ağlarının Kullanılma Nedenleri.....	52
4.1.4	Yapay Sinir Ağı İle Geleneksel Bilgisayar Tekniklerinin Karşılaştırılması..	53
4.1.5	Biyolojik Sinir Ağları.....	54
4.1.6	Biyolojik Sinir Ağlarından Yapay Sinir Ağlarına Geçiş.....	55
4.2	Yapay Sinir Ağlarının Elektronik Uygulanması.....	57
4.3	Yapay Sinir Ağındaki Temel Yapılar.....	58
4.3.1	Ağırlık Faktörü.....	58
4.3.2	Toplama Fonksiyonu.....	59
4.3.3	Transfer Fonksiyonu.....	60
4.3.4	Çıkış Aralığını Değiştirme ve Sınırlandırma	62
4.3.5	Çıkış Fonksiyonu (Competition).....	62
4.3.6	Hata Fonksiyonu ve Geri Yayılım Değeri.....	62
4.3.7	Öğrenme Fonksiyonu.....	63
4.4	Yapay Sinir Ağlarının Eğitilmesi.....	63
4.4.1	Denetimli Eğitim.....	63
4.4.2	Denetimsiz Eğitim.....	64
4.4.3	Öğrenme Oranı.....	65
4.4.4	Öğrenme Kuralları.....	65
4.4.4.1	Perceptron Öğrenme Kuralı.....	66
4.4.4.2	Delta Öğrenme Kuralı.....	68
4.4.4.3	Geri Yayılımla Öğrenme Kuralı.....	70
4.5	Eğitim Algoritmaları.....	73
4.5.1	Temel Gradyant Düşürme (traingd).....	74
4.5.2	Momentum Kullanarak Gradyant Düşürme (traingdm).....	75
4.5.3	Değişken Öğrenme Oranı ile Gradyant Düşürme (traingda).....	75
4.5.4	Momentumlu ve Değişken Öğrenme Oranlı Eğitim (traingdx).....	75

4.5.5 Ağırlık ve Taraf Öğrenme Kurallarıyla Batch Eğitimi(trainb).....	76
4.5.6 Öğrenme Fonksiyonla Dönüşümlü Geliştirme(trainc).....	76
4.5.7 Öğrenme Fonksiyonla Rasgele Kurallı Incremental Öğrenme (trainr).....	76
4.5.8 Esnek Geri Yayılım (trainrp).....	76
4.5.9 Konjuge Gradyant Algoritmaları.....	77
4.5.9.1 Fletcher-Reeves Güncellemesi (traincgf).....	77
4.5.9.2 Polak-Ribiere Güncellemesi (traincgp).....	78
4.5.9.3 Powell-Beale Tekrar Başlamaları(traincgb).....	78
4.5.9.4 Ölçeklenmiş Konjuge Gradyant (traincsg).....	78
4.5.10 Quasi-Newton Algoritmaları.....	79
4.5.10.1 BFGS Algoritması (trainbfg).....	79
4.5.10.2 Tek Adım Algoritması (trainoss).....	79
4.5.11 Levenberg-Marquardt (trainlm).....	80
4.5.12 Bayesian Düzenleme Algoritması (trainbr).....	80
 5 MİKRO ELEKTRO MEKANİK ANAHTARLARIN YAPAY SİNİR AĞLARI İLE MODELLENMESİ.....	 82
5.1 Yapay Sinir Ağları İçin S parametrelerinin Elde edilmesi ve Uygulanması.....	82
5.2 Gerçekleştirilen Eğitimleri Karşılaştırılması.....	84
5.2.1 Eğitimlerin Hata Performansları.....	84
5.2.2 YSA Eğitim ve Test Çıktıları ile HFSS çıktıların Karşılaştırılması	86
 6 SONUÇLAR.....	 103
KAYNAKLAR.....	104
EKLER.....	106
Ek 1 Seri Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı...	107
Ek 2 Seri Anahtar için Trainbr eğitim algoritması ile yapılan eğitimin ardından çıkan hata değerleri.....	110
Ek 3 Paralel Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı	113

Ek 4 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan eğitimin ardından çıkan hata değerleri.....	116
Ek 5 Seri Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı.....	119
Ek 6 Seri Anahtar için Trainbr eğitim algoritması ile yapılan testin ardından çıkan hata değerleri.....	122
Ek 7 Paralel Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı....	125
Ek 8 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan testin ardından çıkan hata değerleri.....	128
Ek 9 MEMS - YSA Matlab Kodu.....	131
Ek 10 MEMS-YSA Grafik Ara yüzü Matlab Kodu.....	145
ÖZGEÇMİŞ	148

SİMGE LİSTESİ

Ghz	Gigahertz
$I_{\max}$	Maksimum Akım
P_{on}	Anahtarın açık konumu için çekilen güç
P_{off}	Anahtarın kapalı durumu için çekilen güç
V_L	Yük empedansı üzerine düşen gerilim
V	Volt
V_0	Referans gerilimi
V_{th}	Eşik gerilimi
$V_{\max}$	Maksimum Gerilim
V_{ds}	Drain-Source gerilimi
V_{gs}	Gate-source gerilimi
V_{gd}	Gate-Drain Gerilimi
Z_d	İdeal olmayan anahtar elemanı
Z_0	Karakteristik empedans
Z_L	Yük empedansı
GaAs	Galyum arsenür
C	kapasite
G	Merkez iletken ile toprak hat arası mesafe
g	MEMS anahtarda gövde ile üst metal tabaka arası mesafe
L	Üst metal tabaka uzunluğu
t	Üst metal tabakanın kalınlığı
t_{diel}	Dielektrik malzemenin kalınlığı
W	Metal köprünün genişliği
SİN	Silikon Nitrit
ϵ_r	Dielektrik Sabiti
Au	Altın
Al	Aliminyum
Kg	Kilogram
A	Elektrot Alanı
E	Elektrik alan
μm	Mikrometre
m	Kütle

F	Kuvvet
Q	Kalite Faktörü
SiO ₂	Silisyum Dioksit
CO ₂	Karbon Dioksit
dB	Desibel
w	Frekans
Ω	Ohm
L	endüktans
nJ	Nano joule

KISALTMA LİSTESİ

RF MEMS	Radio Frequency Microelectromechanical Systems
SAR	Syntetic Aperture Radar
GMTI/AMTI	Ground Moving Target / Airbone Moving Target
SPST	Single-Pole Single-Throw
IL	Insertion Loss
FET	Field Effect Transistor
I-Bölgesi	Instrinsic Layer
CPW	Coplanar Wave Guide
SEM	Scanning Electron Microscope
HFSS	High Frequency Structure Simulator
IC	Integrated Circuits
YSA	Yapay Sinir Ağları
MLP	Multi Layer Perceptron
MSE	Mean Square Error

ŞEKİL LİSTESİ

Şekil 1.1 İdeal tekli anahtar devreleri.....	2
Şekil 1.2 Z_d empedansıyla sonlandırılmış ideal olmayan anahtar kullanılarak kurulmuş SPST (single-pole single throw) anahtarlama devre modeli.....	2
Şekil 1.3 PIN Diyot İçin Akım-Gerilim İlişkisi.....	4
Şekil 1.4 ON ve OFF durumlarında P-I-N diyotun eşdeğer devresi.....	4
Şekil 1.5 Tipik bir GaAs FET için I-V eğrisi.....	5
Şekil 1.6 GaAs FET Kesiti a) $V_{gs}=V_{gd}=0$ için Tam iletken kanal b) $V_{gs}=V_{gd}\leq V_{po}$ tamamen yok olmuş kanal	6
Şekil 1.7 Düşük ve yüksek empedans durumlarında FET'in eşdeğer devresi	6
Şekil 1.8 MEMS anahtarın açık(up) ve kapalı(down) durumları için kesitleri.....	7
Şekil 1.9 Şekil 1.9'daki iki durum için RF MEMS anahtarın eşdeğer devresi.....	7
Şekil 1.10 MEMS paralel kapasitif anahtar ve düzlemsel dalga kılavuzu uygulaması....	8
Şekil 2.1 Tipik bir MEMS paralel kapasitif anahtar şeması.....	10
Şekil 2.2 RF MEMS anahtarların üretim süreci.....	14
Şekil 2.3 RF MEMS anahtarın hava ile kurutulması sırasında meydana gelen yapışma durumu	16
Şekil 2.4 MEMS örneklerini Kritik Nokta kurutma prosedürü uygulanmış ve Uygulanmamış halinin SEM görüntüleri. (Solda): Hava kurutmalı örnekte yapışma meydana gelir. (sağda): Kritik Nokta kurutma işleminde sonar serbest kalan yapının 90 derecelik açıyla gösterimi.....	17
Şekil 2.5 Bazı önemli MEMS tasarımlarının SEM görüntüleri	18
Şekil 2.6 RF MEMS anahtarın ileri ve geri DC bias salınımının C-V ölçümü.....	19
Şekil 2.7 (a)(solda): Alüminyum tortulanmasından önceki MEMS Anahtar resmi. b)(sağda): Nikel tortulanmasından önceki MEMS Anahtar resmi.....	20
Şekil 2.8 Fotorezistin düzgün olmayan profilinin metal depozisyonundan önceki ve sonraki halini göstermektedir.....	21
Şekil 2.9 (solda) : Yüksek sıcaklıkta reflow işlemi uygulanmayan örneğin SEM resmi (sağda) : Yüksek sıcaklıkta tekrar akış ile düzeltilen örneğin anlık görüntüsü..	21

Şekil 2.10 Anahtarların SEM resimleri : (a)(solda) : Yapı(zar) serbest bırakılmış, (b)(sağda) : Sürekli bir yapışma meydana gelmiştir.....	22
Şekil 3.1 (a) Seri anahtar ve basit eşdeğer devresi. (b) Paralel anahtar ve basit eşdeğer devresi	24
Şekil 3.2 RF-MEMS kapasitif paralel anahtarın blok diyagramı	25
Şekil 3.3 HFSS de Modellenmiş RF-MEMS kapasitif anahtar	26
Şekil 3.4 RF-MEMS Kapasitif Paralel Anahtarın Kapalı Durumu	26
Şekil 3.5 RF-MEMS Kapasitif Paralel Anahtarın Açık Durumu.....	27
Şekil 3.6 Mica malzeme ile tasarlanan paralel anahtarın kapalı durumu	29
Şekil 3.7 Mica malzeme ile tasarlanan paralel anahtarın kapalı durumu	29
Şekil 3.8 Silicon Nitrit malzeme ile tasarlanan paralel anahtarın kapalı durumu.....	30
Şekil 3.9 Silicon Nitrit malzeme ile tasarlanan paralel anahtarın açık durumu.....	30
Şekil 3.10 Bakır oksit malzeme ile tasarlanan paralel anahtarın kapalı durumu	31
Şekil 3.11 Bakır oksit malzeme ile tasarlanan paralel anahtarın açık durumu	31
Şekil 3.12 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 – 0.5 μm arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı).....	32
Şekil 3.13 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 – 0.5 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar açık).....	33
Şekil 3.14 Silicon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 – 0.5 μm arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı).....	33
Şekil 3.15 Silicon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar açık).....	34
Şekil 3.16 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1- 0.5 μm arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı).....	34
Şekil 3.17 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar açık).....	35
Şekil 3.18 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin geri dönüş kaybına etkisi (anahtar kapalı).....	35

Şekil 3.19 Mica malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu m^2$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)....	36
Şekil 3.20 Silicon Nitrit malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu m^2$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı).....	37
Şekil 3.21 Bakır Oksit malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu m^2$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı).....	37
Şekil 3.22 RF-MEMS Kapasitif seri anahtarın yapısı.....	38
Şekil 3.23 RF-MEMS kapasitif seri anahtarın blok diyagramı.....	39
Şekil 3.24 HFSS’de Modellenmiş RF-MEMS Kapasitif Seri Anahtar.....	39
Şekil 3.25 RF-MEMS Kapasitif Seri Anahtarın açık durumu	40
Şekil 3.26 RF-MEMS Kapasitif Seri Anahtarın kapalı durumu	40
Şekil 3.27 Mica ile tasarlanan anahtarın kapalı durumu.....	41
Şekil 3.28 Mica ile tasarlanan anahtarın açık durumu.....	42
Şekil 3.29 Silicon Nitrit ile tasarlanan anahtarın kapalı durumu	42
Şekil 3.30 Silicon Nitrit ile tasarlanan anahtarın açık durumu.....	43
Şekil 3.31 Bakır Oksit ile tasarlanan anahtarın kapalı durumu.....	43
Şekil 3.32 Bakır Oksit ile tasarlanan anahtarın açık durumu.....	44
Şekil 3.33 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu m - 0.5 \mu m$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	45
Şekil 3.34 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu m - 0.5 \mu m$ arasındaki değişiminin izolasyona etkisi (anahtar açık).....	45
Şekil 3.35 Silicon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu m - 0.5 \mu m$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	46
Şekil 3.36 Silicon nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu m - 0.5 \mu m$ arasındaki değişiminin izolasyona etkisi (anahtar açık).....	46
Şekil 3.37 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu m - 0.5 \mu m$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	47

Şekil 3.38 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin izolasyona etkisi (anahtar açık).....	47
Şekil 3.39 Mica malzeme ile tasarlanan anahtarın temas alanının 50 μm – 150 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	48
Şekil 3.40 Silicon Nitrit malzeme ile tasarlanan anahtarın temas alanının 50 μm – 150 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	49
Şekil 3.41 Bakır Oksit malzeme ile tasarlanan anahtarın temas alanının 50 μm – 150 μm arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı).....	49
Şekil 4.1 Biyolojik sinir hücresinin yapısı.....	55
Şekil 4.2 Temel yapay sinir hücresi.....	56
Şekil 4.3 İşlem elemanı.....	57
Şekil 4.4 Logsig transfer fonksiyonunun grafiği.....	58
Şekil 4.5 Hardlim transfer fonksiyonu.....	60
Şekil 4.6 Rampa transfer fonksiyonu.....	61
Şekil 4.7 Tansig transfer fonksiyonu.....	61
Şekil 4.8 İki katmanlı ağ yapısı.....	71
Şekil 5.1 Ağın giriş ve çıkış blok diyagramı.....	82
Şekil 5.2 Tek Saklı Katmanlı Yapay Sinir Ağı Modeli.....	83
Şekil 5.3 İki Saklı Katmanlı Yapay Sinir Ağı Modeli.....	84
Şekil 5.4 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	87
Şekil 5.5 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	88
Şekil 5.6 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	89
Şekil 5.7 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	90
Şekil 5.8 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	91
Şekil 5.9 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	92

Şekil 5.10 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	93
Şekil 5.11 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	94
Şekil 5.12 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	95
Şekil 5.13 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	96
Şekil 5.14 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	97
Şekil 5.15 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	98
Şekil 5.16 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	99
Şekil 5.17 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	100
Şekil 5.18 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması.....	101
Şekil 5.19 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması.....	102

TABLO LİSTESİ

Tablo 1.1 Farklı devre konfigürasyonlarında güç taşıma kapasitesi

Tablo 5.1 a Seri RF-MEMS Anahtarın Tek Saklı Katmanlı 25 Nöronlu Ağ Yapısı için
(MSE) Hata Performansları

Tablo 5.1 b Paralel RF-MEMS Anahtarın Tek Saklı Katmanlı 25 Nöronlu Ağ Yapısı
için (MSE) Hata Performansları

Tablo 5.2 a Paralel RF-MEMS Anahtarın İki Saklı Katmanlı 10 Nöronlu Ağ Yapısı için
(MSE) Hata Performansları

Tablo 5.2 b Seri RF-MEMS Anahtarın İki Saklı Katmanlı 10 Nöronlu Ağ Yapısı için
(MSE)Hata Performansları

ÖNSÖZ

Başta bu çalışmayı bize öneren ve her aşamasında bizden değerli katkılarını esirgemeyen değerli hocamız Yrd. Doç. Dr. Hamid Torpi'ye ve çalışmamda bana destek olan Yasin Damgacı ve A. Önder Biliroğlu arkadaşlarımıza çok teşekkür ederim. Ayrıca öğrenim hayatım boyunca sürekli bana destek olan aileme ve her aşamada bana destek olan sevgili nişanlıma sonsuz teşekkür ederim. Umuyorum ki bu çalışma bizden sonraki arkadaşlar içinde faydalı olur.

ÖZET

Bu tez yeni gelişmekte olan bir teknolojinin yani RF MEMS teknolojisinin bazı uygulamalarına değinmiştir. Yapılan çalışma mekanik, elektronik ve malzeme birimlerinin bir sentezini sunmaktadır.

Tezin birinci bölümünde RF MEMS'lerin kullanım nedenleri belirtilip, RF MEMS anahtarlara ve mikroelektronik RF anahtarlama teknolojilerine kısaca giriş yapılmıştır. İkinci bölümde RF MEMS anahtarlar ayrıntılı olarak incelenmiş ve ayrıntılı işleme teknikleri ve üretim aşamaları sunulmuştur. Üçüncü bölümde HFSS programında oluşturduğumuz RF MEMS seri ve paralel anahtarların mikrodalga karakteristikleri ve S parametreleri elde edilmiştir. Bunu takip eden bölümde ise yapay sinir ağları ile ilgili genel bilgilere yer verilmiştir. Son bölümde HFSS programı ile elde ettiğimiz verileri çeşitli ağ modellerine ve eğitim algoritmalarına göre yapay sinir ağlarında uyguladık ve çıkan sonuçları, çıkması beklenen sonuçlara göre karşılaştırıp grafikler sunulmuştur.

Anahtar Kelimeler: RF MEMS, anahtar, yapay sinir ağları.

ABSTRACT

This thesis is about some kinds of RF MEMS, which is a newly developing technology. The thesis contains mixture of mechanical, electronical and materials fields.

In the first section, a short entrance is made to RF MEMS switches and microelectronic RF switch technologies after telling the reasons of using RF MEMS. In the second part, RF MEMS switches are investigated in detail and detailed working techniques and production steps are presented. In the third part, microwave characteristics and S parameters of the RF MEMS parallel and serial switches that we produced in HFSS program are calculated. The coming section includes some necessary information about artificial neural networks technology. In the last section, we applied the variables that are produced through the HFSS program in artificial neural networks according to different network models and training algorithms and used graphics to compare the concluded results with the expected results.

Keywords: RF MEMS, switch, artificial neural networks

GİRİŞ

Daha esnek, hafif ve düşük güç tüketimine sahip kablosuz sistemlere olan talep; üretim maliyetini azaltabilecek, boyutları ve ağırlığı düşürebilecek ve aynı zamanda performansı arttırabilecek teknolojiye olan ihtiyacı ortaya çıkarmıştır. Geniş işlemsel bant genişliklerine imkan sağlaması, bağlantı kaybını ihmal edilebilir düzeylere indirmesi, off-chip pasif bileşenleri ortadan kaldırması ve halihazırda kullanılan entegre devre, mikromekanik entegre devre üretim süreçleriyle uyumlu planar üretim süreçleri ile hemen hemen ideal anahtarlar ve rezonatörler üretebilmeyi mümkün kılması sayesinde büyük bir çoğunluluk, ihtiyaç duyulan bu teknolojinin RF MEMS anahtarlar olduğu düşüncesindedir.

Uygulamaya geçildiğinde RF MEMS teknolojisi standBy durumunda sıfır güç tüketimi, nano-joule seviyesinde anahtarlama enerjisi ve 5 V un altında aktivasyon gerilimi, yüksek kalitede indüktörler uygulamaları, geniş bant faz kaydırıcı, onlu megahertzlerden birkaç gigahertz frekanslara kadar yüksek performanslı filtreleme uygulamalarına olanak sağlamaktadır.

RF MEMS teknolojisinin büyük katkıda bulunduğu diğer bir uygulama da tekrar yapılandırılabilen antenlerdir. RF MEMS anahtarların ortaya çıkmasıyla çok bantlı faz dizili antenler son zamanlarda dikkat çekmeye başladı. Bir MEMS-anahtarlı tekrar yapılandırılabilir çok bantlı anten(reconfigurable multi-band antenna), L-Bant (1-2 GHz) ve X-Bantta sentetik aperture radar(SAR) (8-12,5 GHz) iletişimi gibi farklı frekans bantlarında farklı uygulamalara hizmet vermek için birkaç mikro saniye içinde dinamik olarak yapılandırılabilir. Hava kuvvetleri yerdeki ve havadaki net görüşe sahip olmayan nesneler gibi hareket eden hedeflerin yerini tayin etmek için GMTI/AMTI (ground moving target/ airborne moving target) cihazlarını bu frekanslarda kullanır.

Günümüzde bilindiği üzere içerisinde milyonlarca işlem elemanı (transistor) bulunduran ve insan beyninin sinir yapısına göre çok daha hızlı çalışan mikroçipleri üretebiliyoruz. Bu mikroçiplerin içerebildikleri işlemci kapasitesi ve işlem hızları her geçen yıl neredeyse belirli denebilecek bir kural çerçevesinde artmaktadır. Yalnız bilim adamları şunu fark etmişlerdir ki bir mikroçipin işlemci sayısını arttırmak veya mikroçipin işlem hızını arttırmak kullandığımız mikroçipleri daha zeki yapmamaktadır. Sadece kendilerine verilen komutları daha hızlı sonuca ulaştırmalarını sağlamaktadır. Bilim adamları daha akıllı diye tanımlayabileceğimiz aygıtları nasıl meydana getirebilecekleri sorusuna cevap araya gelmişlerdir. Bunun sonucunda da insan beyninin sinir ağı yapısını taklit etmeye yönelik oluşturulan yapay sinir ağı kavramı ortaya çıkmıştır. Klasik programlama yöntemiyle oluşturulan yazılımlar maalesef tecrübeye veya


başka bir deyişle elde bulunan bilgilerin genelleştirilmesine dayalı problemlerde doğru sonuçlar vermemektedir. Bugün günümüzde yapay sinir ağı yaklaşımı belirli bir olgunluğa ulaştırılmış ve teori sayfalarından çıkıp günlük hayatımızda da yer alan bir teknik halini almıştır. Bizde tezimizde RF MEMS anahtarların yapay sinir ağları ile modelleyerek değişik boyutlara sahip RF MEMS anahtarların karakteristiklerini incelemeye çalıştık.

1. ANAHTARLAMA TEKNOLOJİLERİ

Bu bölümde mikro elektronik anahtarlama teknolojileri ile ilgili genel bilgiler aktarılmıştır.


1.1 Temel Anahtarlama Teorisi

RF devrelerde ikimuhtemel anahtarlama şekli vardır. Bunlar şekil (1.2) de gösterilen seri ve paralel bağlantı tipleridir.



Şekil 1.1 İdeal tekli anahtar devreleri

İdeal anahtar mükemmel açık devreyle mükemmel kısa devre arasında değişim gösterir. Bazı elektronik elemanlar akım-gerilim karakteristikleri bakımından ideal anahtarlara yakındır. Bu gibi elemanların anahtar olarak kullanılması hızlı anahtarlama, elektronik kontrolü ve monolitik entegrasyonu kolaylaştırır.



Şekil 1.2 Z_d empedansı ile sonlandırılmış ideal olmayan anahtar kullanılarak kurulmuş SPST (single-pole single throw) anahtarlama devre modeli

İdeal olmayan anahtarlama elemanları şekil 1.3 deki gibi Z_d empedansı ile modellenebilir. Empedans, düşük empedans ile yüksek empedans durumu arasında değiştirilebilir.

Anahtarlama devreleri için diğer bir önemli parametre de hem ON hem de OFF durumu için anahtarın ekleme kaybıdır (Insertion Loss). Bu kayıp şu şekilde hesaplanabilir:

$$IL = -20 \log \left| \frac{V_L}{V_0} \right| = \begin{cases} 20 \log |1 + Z_d / 2Z_0| , & \text{seri anahtar} \\ 20 \log |1 + Z_0 / 2Z_d| , & \text{paralel anahtar} \end{cases} \quad (1.1)$$

Anahtarlar için diğer önemli parametreler ise anahtarlama hızı, güç taşıma kapasitesi, lineerliği ve güç dağıtma kontrolüdür. Anahtarlama hızı, kontrol hattındaki giriş gerilimi değiştiğinde anahtarın çıkışa verdiği yanıt için gereken süredir. Bu süre, sürücünün propagasyon gecikmesini ve hatta geçiş süresini de içerir yani anahtarın açık olduğu süre için RF gerilim zarfının %10 dan %90'a, anahtarın kapalı durum için %90 dan %10'a ulaşması için gereken süre olarak tanımlanabilir. Güç taşıma kapasitesi ise anahtarı tamamlayan mikroelettronik elamanlar ile sınırlandırılmıştır. Yüksek empedans durumunda, her bir eleman terminallerinden geçirebileceği maksimum güçlendirilebilir gerilim (V_{max}) ile sınırlandırılacaktır. Düşük empedans durumunda ise her bir eleman maksimum güçlendirilebilir akımı ile sınırlandırılacaktır. Güç taşıma kapasitesinin farklı permütasyonları Tablo 1.1 de gösterilmiştir. Her bir durumda maksimum güç, eleman tarafından üreteçten çekilen maksimum ani gücü(yansıyan veya iletilen) gösterir.

Devre Konfigurasyonu		
Eleman Durumu	Seri	Paralel
düşük empedans $Z_d \ll Z_0$	$P_{on} \approx \frac{1}{2} I_{max}^2 Z_0$	$P_{off} \approx \frac{1}{8} I_{max}^2 Z_0$
yüksek empedans $Z_0 \ll Z_d$	$P_{off} \approx \frac{V_{max}^2}{8Z_0}$	$P_{off} \approx \frac{V_{max}^2}{8Z_0}$


Tablo 1.1 Farklı devre konfigürasyonlarında güç taşıma kapasitesi

1.2 Mikroelektronik RF Anahtarlama Teknolojileri

Genellikle PIN diyot, FET anahtarlar ve RF-MEMS anahtarlar RF ve mikrodalga uygulamalarında en çok kullanılan elamanlardır. Bu kısımda bu anahtarların teknolojisi hakkında kısa bir özet verilecektir.


1.2.1 P-I-N Diyotlar

PIN diyotun akım-gerilim karakteristiği şekil 1.3 de gösterilmiştir.



Şekil 1.3 PIN Diyot İçin Akım-Gerilim İlişkisi

Elaman üzerine düşen gerilim eşik gerilimini (V_{th}) üzerine çıktığında elaman düşük rezistif empedans (R_{on}) gibi davranır. Bu durumda güç taşıma kapasitesi elaman tarafından çekilen maksimum akımı ile belirlenir. (Tablo(1.1)). Düşük frekanslarda tepeden tepeye akım $2I_{bias}$ ile sınırlandırılmıştır. Bunun ötesinde dalga şeklinde, yapılan düzeltmelerden kaynaklanan büyük bozulmalar meydana gelir. Ama yüksek frekanslarda ani akım, I – bölgesindeki (Intrinsic layer) büyük miktardaki yükten dolayı çok yüksek değerlere çıkarılabilir. Bu akım I_{max} 'ın düşük frekans limitini geçmesine izin verir. Ayrıca, I_{max} tipik olarak RF frekanslarda termal limitlerle sınırlansılır.




Şekil1.4 ON ve OFF durumlarında P-I-N diyotun eşdeğer devresi

P-I-N diyotlar P+-I-N+ yapıya sahip diyotlardır. P+ ve N+ bölgelerinin katkı oranları oldukça yüksek ve I bölgesi ise büyük dirençlidir. Alçak frekanslarda diyot bir P-N doğrultucu gibi çalışır. Frekans yükseldikçe I bölgesi de etkinliğini gösterir. Yüksek frekanslarda I bölgesinin ileri yöndeki direnci küçük, ters yöndeki direnci ise büyüktür. Diyotun direnci, uygulama yerine göre, iki limit arasında sürekli olarak veya kademeli olarak değiştirilebilmektedir. P-I-N diyotlar değişken dirençli elaman olarak, mikrodalga devrelerinde, faz kaydırıcı, modülatör, anahtar, limitör gibi çeşitli amaçlar için kullanılmaktadır. Diyotun karakteristiği şekil 1.3 de özetlenmiştir.

1.2.2 FET Diyotlar


FET gibi üç uçlu elamanlar çoğunlukla monolitik mikrodalga tümleşik devrelerinde(MMIC) anahtar olarak kullanılırlar. Üç uçlu elamanların kullanıldığı birçok devre gibi, FET anahtarlama devreleri de konsept olarak iki uçlu elamanlara göre daha karmaşıktır. Tipik bir GaAs FET için akım-gerilim eğrisi Şekil 1.5 de gösterilmiştir.



Şekil 1.5 Tipik bir GaAs FET için I-V eğrisi

FET, anahtar olarak kullanıldığında, çoğunlukla sıfır savak-kaynak geriliminde DC olarak bias edilir, $V_{ds} = 0$ seçilir ve geçit de sıfıra bias edilir veya bir yüksek empedans kaynağından pinch-off uygulanır. Düşük empedans anahtarlama durumu, geçit referans geriliminin sıfır olduğu durumda elde edilir, $V_{gs} = V_{gd} = 0$ V. (bkz. Şekil (1.6 a)). Bu durumda şekilden de görüldüğü gibi savaktan kaynağa direk bir iletim yolu vardır. Bu


bölgedeki toplam direnç R_{on} ile ifade edilebilir. $R_{on} = R_c + 2r_g$. Burada R_c kanal direnci ve r_g ise savak-kaynak arası ohmik kontak olarak adlandırılabilir.



Şekil 1.6 GaAs FET Kesiti a) $V_{gs} = V_{gd} = 0$ için Tam iletken kanal

b) $V_{gs} = V_{gd} \leq V_{po}$ tamamen yok olmuş kanal

Şekil 1.6 b de gösterildiği gibi geçit için referans gerilimi pinch-off olarak seçildiğinde yüksek empedans durumu elde edilir. Bu durumdaki tükenme bölgesi C_g kapasiteleri ile gösterilir. Artık kanal iletkenliği kaybolmuş, savaktan kaynağa akış yolları kapanmıştır. Bu durumda elektrot kapasitesi önemli hale gelecektir ve artık modelde gösterilmek zorundadır. Buradaki modelde bunlar r_{ds} ve C_{ds} ile gösterilmiştir. Bu parametreler aynı zamanda düşük empedans durumunda da işleme katılır ancak iletken kanalla karşılaştırıldığında admitansa pek bir katkısı yoktur. Elamanın iki durumdaki basitleştirilmiş eşdeğer devresi şekil 1.8 de gösterilmiştir.




Şekil 1.7 Düşük ve yüksek empedans durumlarında FET'in eşdeğer devresi

1.2.2 RF-MEMS Anahtarlar


Radyo frekans mikroeletromekanik sistem (RF MEMS) hâlihazırdaki mikrodalga uygulamalarında düşük maliyet ve yüksek performans açısından çok iddialı olmasından dolayı son zamanlarda önem kazanan bir teknolojidir. RF MEMS anahtarlar RF transmisyon hatlarında açık devre-kapalı devre şeklinde hareket etme olanağı sağlayan

mekanik elemanlardır. Mekanik hareket için gereken kuvvet elektrostatik, magnetostatik, piazoelektrik veya termal tasarımlarla sağlanabilir. Günümüzde sadece 0.1-100 GHz frekans aralığındaki elektrostatik tip anahtarlar kullanılmaktadır. Bu anahtarlar yüksek güvenilirliğe(100 milyondan 10 milyara kadar çevrim) sahiptir.



Şekil 1.8 MEMS anahtarın açık(up) ve kapalı(down) durumları için kesitleri. Bu durumda anahtar yüksek empedans ve düşük empedans arasında değişir.


Elektrostatik tip MEMS anahtarın fiziksel yapısı şekil 1.8 de gösterilmektedir. Burada t kalınlığında ince metal bir tabaka, iletken elektrotlardan g uzaklığında konumlandırılmıştır. İki iletken arasına bir DC gerilim uygulandığında, yükler metal zar üzerinde yüklenir. Böylece iki elektrotu kendine doğru çeker. Eşik gerilimin üzerindeki bir gerilim, materyalde mekanik direnci aşacak bir çekim kuvveti oluşturur ve metal tabaka şekil 1.8'in sağ kısmında görüldüğü gibi kapalı duruma geçer.



Şekil 1.9 Şekil 1.8'deki iki durum için RF MEMS anahtarın eşdeğer devresi.

Bu teknolojiyle tam iletken on/off anahtarlar yapılması mümkün görünse de kapalı durumda metal-metal bağlantısının istenilen sonucu vermesinde zorluklar ortaya çıkmıştır. Bu yüzden yaygın olan MEMS anahtarlama teknolojisinde şekil 1.8 de görüldüğü gibi merkezdeki bir iletkenin üzerinde ince bir dielektrik tabakası kullanılır,

böylece eleman aslında iki kapasite arasında anahtarlama yapar. Tipik olarak $h=100 \text{ \AA}$ kalınlığında bir silikon nitrit (SiN) film kullanılır. Bu film için $\epsilon_r=7.5$ tur. Anahtar için eşdeğer devre şekil 1.10 da verilmiştir. İki durumdaki kapasiteler paralel levha formülü ile kolayca hesaplanabilir. Bunun için sadece elektrotun ve dielektriğin geometrik bilgisi yeterlidir.



Şekil 1.10 MEMS paralel kapasitif anahtar ve düzlemsel dalga kılavuzu uygulaması.

MEMS anahtarın koplanar bir dalga kılavuzu olarak uygulaması şekil 1.10 da gösterilmiştir. Burada metal tabaka toprak elektrotları arasında bir köprü durumundadır ki bu da zaten her düzlemsel dalga kılavuzunun bir parçasıdır ve bu yüzden alışılmışın dışında bir işlem gerektirmez. Bu anahtar, hat kapasiteleriyle karşılaştırıldığında kapalı durumda oluşan kapasitelerinin daha küçük olması sebebiyle tasarlanmıştır. Eşik değerin üzerinde bir bias, merkezi iletken ile toprak arasına uygulandığında anahtar kapanır ve hat üzerinde bir paralel kapasite etkisi oluşturur. Eşdeğer devrede de görülen kapasite RF frekanslarda etkili bir kısa devre oluşturması için tasarlanmıştır. RF MEMS anahtarlar esasen p-i-n diyotlara veya FET anahtarlara göre daha yüksek performans gösterir. Elektrostatik aktivasyon için 20-80 V aralığında bir gerilim gereklidir fakat akım çekmez ve bunun sonucunda çok düşük enerji harcaması (10-100 nJ, her bir anahtarlama çevrimi için) sağlanır. RF MEMS anahtarlar, hava boşluklarıyla üretilirler. Bu yüzden çok düşük off-state kapasitelerine (2-4 fF) sahiptir dolayısıyla 0.1- 40 GHz frekans aralığında mükemmel izolasyon sağlar. Ayrıca MEMS anahtarlarda yarıiletken anahtarlarda karşılaşılan non-lineer akım-gerilim ilişkisi gibi bir sorun yoktur. Sonuç olarak RF MEMS anahtarlar MMIC (monolitik mikroelektrik tümleşik devre) işlemleriyle, silikon, GaAs, cam ve alüminyum içeren herhangi bir gövde üzerinde üretilebilir.

FET veya p-i-n diyotlarla karşılaştırıldığında RF MEMS elemanlar ile mümkün hale gelen yüksek performans, mikrodalga ve milimetrik dalga uygulamalarını içeren ticari telekomünikasyonda ve askeri alandaki sistem tasarımında önemli şeyler ifade eder. MEMS anahtarların temel uygulama alanları;


- *Savunma Uygulamaları için Radar Sistemleri (5-94 GHz)* : Uydu tabanlı radarlar için faz kaydırıcılar, misil sistemleri, uzak mesafe radarları
- *Otomotiv Radarları*: 24, 60 ve 77 GHz.
- *Uydu Haberleşme Sistemleri(12-35 GHz)*: Anten uygulamaları için anahtarlama devreleri vs.
- *Kablosuz Haberleşme Sistemleri(0.8-6 GHz)*:
- *Enstrumantasyon Sistemleri(0.01-50 GHz)* : Bu sistemler yüksek performans anahtarlar, programlanabilir zayıflatıcılar, SPNT devreleri(Single Pole n Throw Terminated) ve faz kaydırıcıları içerir.

2. RF MEMS ANAHTARLARIN İNCELENMESİ

Bu kısma RF MEMS anahtarların temel elektromekanik karakteristikleri incelenerek başlanmaktadır. Detaylı işleme teknikleri ve bazı ilgili fonksiyonlar sunulmaktadır. RF MEMS anahtarların tasarımında, geliştirilen verimlilik ve güvenilirlik hakkında detaylarla devam edilmektedir.

2.1 Temel MEMS Anahtar Yapısı

RF MEMS Anahtarları geliştirildiği halde, bugün hala yüzlerce yıl önce geliştirilen temel mekanik yasalar takip edilmektedir, ölçümler ve anahtarlar üzerine etki eden kuvvetler bizim makro-dünyada tecrübe ettiğimizden önemli ölçüde farklıdır. Yüzey kuvvetleri ve viskoz nemli hava, sürtünme ve yerçekimi kuvvetleri üzerinde baskın bir etkiye sahiptir. RF MEMS anahtarları genellikle sinyal iletim yolunun bir tarafından öbür tarafına gerilen zar kullanılarak üretilir ve mekanik yaylara eşdeğer yay sabiti $k[N/m]$ ile modellenir. Yay sabiti zarın geometrik boyutuna ve (5-40 N/m arasında olan birçok RF MEMS anahtar tasarımında kullanılan materyalin (Au, Al, Nitrit vs.)) Young'ın zorlanım çarpanına bağlıdır. Temelde RF MEMS anahtarları çok düşük bir kütleye sahiptir, ve genellikle 10^{-10} - 10^{-11} kg arasındadır, bu nedenle çekim kuvvetleri önemsizdir, yani anahtarlar yerçekimi kuvveti ile ivmelenmez.



Şekil 2.1: Tipik bir MEMS paralel kapasitif anahtar şeması.

Aktivasyon mekanizması üst ve alt elektrotlar arasındaki elektrostatik kuvvet kullanılarak gerçekleştirilir ve şu şekilde hesaplanır:

$$F = \frac{QE}{2} = \frac{CVE}{2} = \frac{CV^2}{2(g + \frac{t_d}{\epsilon_r})} = \frac{\epsilon AV^2}{2(g + \frac{t_d}{\epsilon_r})^2} \quad (2.1)$$

V = Gerilim.

g = Boşluk mesafesi.

C= Elektrotlar arasındaki kapasite.

A= Elektrotun alanı.

En alt elektrot, kalınlığı (t_d) 100-200 nm olan dielektrik tabakasıyla çevrilidir. Üst ve alt plakalar arasında kısa devreyi sağlayan; değeri 3-8 arasında olan dielektrik sabiti (ϵ_r) vardır. Alt ve üst plakalar arasındaki hava boşluğu genellikle 1.5- 4 μm kadardır. Anahtarın elektrotunun alanı 100x100 μm^2 dir. Uygulanan gerilim 40V dur ve 2.5 μm lik boşluk vardır. Anahtarı aktif hale getirmek için gereken güç sadece 11 μNewton dur. Çok düşük kuvvetlerle elektrostatik aktivasyon sağlanmaktadır. Ve bu MEMS anahtarların çalışması için yeterlidir. Bunun sebebi, eğer anahtar alt elektrota doğru çekilirse aradaki boşluk azalır ve iki elektrot arasındaki aşağı çekme kuvveti artar. Diğer taraftan; anahtarın yay sabitine bağlı olarak bir yukarı çekme kuvveti vardır.

$$F = \frac{\epsilon A V^2}{2(g + \frac{t_d}{\epsilon_r})^2} = k(g - g_0) \quad (2.2)$$

g_0 = Köprünün başlangıç yüksekliği

İki kuvvet eşit olduğu zaman denge sağlanır ve g' ye bağlı olarak bu kübik eşitliğin çözümü kararlı durumda yaklaşık olarak $g_0/3$ tür. Ve anahtar tamamen aşağı konumda kalır. Bu kapalı durumu sağlayan gerilim aşağı çekme gerilimi olarak adlandırılır. Bu gerilim aşağıdaki eşitlikle hesaplanır.

$$V_p \equiv \sqrt{\frac{8kg_0^3}{27\epsilon A}} \quad (2.3)$$

$k= 10\text{N/m}$

$A= 100 \times 100 \text{ } \mu\text{m}^2$

$g_0= 2.5 \text{ } \mu\text{m}$

$V_p(\text{aşağı çekme gerilimi})= 23 \text{ V}$

Uygulanan gerilim tipik olarak 1.2-1.4 V_p civarındadır. Bu gerilim, anahtarın hızlı çalışmasını sağlamakta kullanılır. Bir kere anahtar aşağı çekildiğinde ve $g= 0 \text{ } \mu\text{m}$ olduğunda, elektrostatik kuvvet 8-15 Volta düşer ve anahtar aşağı konumda kalmaya devam eder. Bu, dielektrikteki elektrik alanı azaltmak ve dielektriğin bozulma ihtimali veya dielektriğe yük enjeksiyonunu önlemek için yapılır. Bias gerilimi kaldırıldığı zaman, birçok RF MEMS anahtar için 30-60 μNewton olan yukarı çekme kuvveti uygulandığında köprünün yer değiştirmesi g_0 olur. Yukarı çekme kuvveti çok düşüktür ve çevresel değişikliklere bağlıdır. Bundan dolayı RF MEMS anahtarlar yüzeye duyarlıdır ve temiz bir ortam içinde paketlenmelidir. RF MEMS anahtarlar Newton'un mekaniğini ve d'Alembert'in hareket denklemini takip eder.

Dinamik cevap:

$$mg'' + bg' + k(g_0 - g) = F_e \quad (2.4)$$

m = Kütle.

b = köprünün sönüm katsayısı.

F_e = (3.1) ile verilen elektriksel kuvvet.

Bu sistemin rezonans frekansı :

$$\omega_0 = \sqrt{\frac{k}{m}} \quad (2.5)$$

RF MEMS Anahtarların yay sabiti 5- 30 N/m olduğunda rezonans frekansı 30-100 KHz olarak görülür. Sönüm katsayısı (Q) kalite faktörü olarak ta yazılabilir; bu da $Q = k/w_0b$ dir. Anahtar kapanırken köprünün altındaki hava boşalır ve bunun sonucunda sönüm meydana gelir. Qw_0 deki ilk kutup anahtarın zaman domenindeki cevabını sınırlandırır. RF MEMS anahtarları vakumlu bölgeye koyarsak sönüm faktörü azalır. Anahtarlama zamanını doğru olarak gösteren basit eşitlik aşağıda verilmiştir.

$$t = 3.67 \frac{V_p}{V_s \omega_0} \quad (2.6)$$


V_s = Uygulanan gerilim.


Bir Anahtar için $w_0 = 50$ KHz ve $V_s = 1.3 V_p$ 'dir. Anahtarlama zamanı ise $9 \mu s$ ' dir. Çoğu MEMS anahtarın açılma-kapanma zamanı 2-50 μs arasındadır. (2.6) eşitliğinden de anlaşılacağı gibi, 0.3 μs lik anahtarlama zamanı elde etmek oldukça zordur. Yüksek rezonans frekansına ancak yüksek yay sabiti(ve çok küçük kütle), yüksek bir aşağı çekme gerilimi (ve bu nedenle V_s gerçekten çok yüksek olmalıdır) ile sağlanabilir. Anahtarlama zamanının yüksek güvenilirlikli uygulamalarda öngörülen çalışma sınırı 1 μs civarındadır.

2.2 RF MEMS Anahtarların Üretimi

RF MEMS Anahtarlar yüksek öz dirençli silikon ve galyum arsenik gibi diğer alt tabaka materyaller ile de uyumlu olmasına rağmen, çoğunlukla fiyatı etkilediğinden, 500 μm kalınlıklı cam alt tabaka ($\epsilon_r = 5.7$) üzerine üretilirler. Devam eden kısımda alt tabaka

materyalinin seçiminden bahsedeceğiz. Şekil (2.2) RF MEMS anahtarın süreçlerini detaylı olarak göstermektedir. CPW çizgileri 100/5000 Å Ti/Au ‘nun tabakasının buharlaştırıldığı lift-off işlemi ile meydana getirilir. 5000 Å ‘luk SiN plazma yükseltmeli kimyasal buhar tortusu (PECVD: plazma-enhanced chemical vapor deposition) en üste kaplanır. Daha sonra MEMS hava köprüsünün yüksekliğini belirleyen, daha sonraki aşamalarda kaldırılacak olan fotorezist (ışığa maruz kalınca çözünen likit polimer) tabaka tortulanıp işlenir. Merkezdeki iletkenin üzerindeki köprünün yüksekliği 1.5-4 µm arasında seçilir. 220 °C ‘deki sıcak yüzeyde fotorezist tabakayı pürüzsüz hale getirmek için 20 dk boyunca akıtma işlemi yapılır. 100/1000 Å ‘lük Ti/Au tabakası, altının buharlaşma hızından 6 Å/saniye daha az olan buharlaşma hızıyla buharlaştırılır ve MEMS köprüsünün geometrisi oluşturulur. Oluşan örnek, anahtarın dayanıklılığını artırmak için genellikle, buharlaşma esnasında düşük devir hızında eğik bir plaka üzerine konur ve daha sonra fotorezist tabaka kaldırılır. Bu işlemden sonra MEMS köprülerini serbest bırakmak için kritik nokta kurutma sistemi kullanılır. İşlemin verimliliği ve anahtarların güvenilirliği büyük değişiklikler gösterebilir ve bu bahsedilen verim ve güvenilirlik metal zarın kalınlığı, köprünün yüksekliği ve metalin mukavemeti gibi kritik parametrelere bağlıdır.







Şekil 2.2 RF MEMS anahtarların üretim süreci.

MEMS Anahtarların fabrikasyonunda alt tabaka olarak silikonun seçilmesinin bazı dezavantajları vardır. Ölçümler yüksek DC kapasitesini düşük kırılma gerilimini ve yüksek akım sızıntısını göstermektedir. Metal yolları oluşturan altının tortulanması, gerçekte, metal silikon bağlantısında yük yayılımı olan bir bölge oluşturur. Bu bölge de MEMS Anahtarın kapasitesiyle kıyaslanabilir bir DC parazitik kapasite meydana getirir ve DC ölçüm yapmak çok zordur. Ek olarak DC ölçüm yapılırken silisyumun üzerindeki MEMS anahtarın biasının ~ 60 Volttan daha yüksek olduğunu gözlemleriz. Bu da genellikle alt tabakanın bozulması ve neticede anahtarın kullanılamaz duruma gelmesi ile sonuçlanır. Hatta gerçekleşen bozulmanın öncesinde alt tabakadaki yüksek akım kaçağını ölçmek mümkündür. Bu problemin üstesinden gelebilmek için, silikonun üstüne SiN tabakası ve SiO₂ tabakası yerleştirilerek test edilir. Bozulma geriliminin artmış olmasına rağmen, parazitik kapasite tamamıyla kaybolmaz. Safir, yüksek özdirençli silikon ve cam alt tabakaya göre çok iyi karakteristik gösterir. Yüksek kırılma gerilimi, parazitik kapasitesi ve akım sızıntısı yoktur. Cam alt tabaka, safir ve yüksek özdirençli silikon ile kıyaslandığında


çok düşük maliyet ve bol miktarda bulunmasından dolayı tercih edilir. Bu yüzden RF MEMS anahtarların fabrikasyonunda kullanmak için idealdir. Yapıdaki fotorezist tabakayı kaldırmak için iki metot vardır: Kuru etching(asitle yıkama) ve yaş etching teknikleri. Tabakayı kaldırmak için kullanılan kuru etching tekniğini uygulayabilmek için MEMS anahtarlar köprü zarındaki birbirine yakın deliklerle imal edilir. Bu metotta etching işleminin tamamlanmasını izlemek zordur. Fotorezistin aşınan kısmının artıkları kritik aşağı çekme gerilimine ve aşağı-konum kapasitesine sebep olur. Bu yüzden kuru etching tekniğinin yerine UCSB deki RF MEMS üretiminde fotorezistin aşınan tabakasından kurtulmak için sıvı çözücü kullanılır. Fakat su veya çözücünün, havayla kurutulması ile yonga plakasının yüzeyindeki zar aşağı iner yani “meniscus(bir tarafı içbükey diğer tarafı dışbükey duran sıvı sütunu) ” formuna gelir. Bu durum Şekil (2.3) ‘te görülmektedir. Temas kuvveti zarın tekrar eski haline gelmesine engel olur. Bu problemin üstesinden gelebilmek için “Kritik Nokta” kurutma sistemi, UCSB(University of California Santa Barbara) nano üretim araştırma laboratuvarında kurulmuştur.



a) Fotorezist tabakasının kaldırılmasından önceki durum



b) Zarın altında meydana gelen menisküs formu





c) Zarın yonga plakasına yapışması durumu

Şekil 2.3: RF MEMS anahtarın hava ile kurutulması sırasında meydana gelen yapışma durumu

Sistem örnekleri, yapışmanın meydana gelmemesi için CO₂ 'in fiziksel özelliklerini baz alarak yıkar. Basınçlı bir odada CO₂ sıvısı kritik noktaya ulaşana kadar belirli bir sıcaklığa ve basınca getirilir. Bu gibi termodinamik durumlarda gaz halindeki CO₂ nin yoğunluğu sıvı CO₂'ninki ile aynıdır ve her iki hali bir arada bulunur. Bu durumda serbest bırakılan CO₂ mekanik yapıda yapışmaya neden olmaz. Örnek, kritik nokta kurutucu sistemli odaya koyulmadan önce aseton veya metanol gibi bileşikler çözücü olarak kaldırmak için kullanılır. Şekil (2.4) MEMS örneklerinin iki adet SEM görüntüsü kritik nokta kurutma prosedürünün uygulanmış ve uygulanmamış hallerini göstermektedir. Resimlerden hava ile kurutulmuş olan örnekte yapışmanın meydana geldiğini görebiliriz. Kritik noktali kurutma


prosedürünün uygulandığı örnek, askıda kalan yapının serbest bırakılmasını gösterir ve dikkat edilmelidir ki ortamdaki nem de yapışma oluşmasına neden olur. Özellikle örnek nem oranı yüksek bir ortamda uzun süre bekletilirse yapışma meydana gelir. Bu sebepten dolayı MEMS örneklerini saklamak için nitrojen odaları tercih edilir.



Şekil 2.4 MEMS örneklerini Kritik Nokta kurutma prosedürü uygulanmış ve uygulanmamış halinin SEM görüntüleri. (Solda): Hava kurutmalı örnekte yapışma meydana gelir. (sağda): Kritik Nokta kurutma işleminden sonra serbest kalan yapının 90 derecelik açıyla gösterimi.

2.3 RF MEMS Anahtar Tasarımında Dikkat Edilmesi Gereken Hususlar


Anahtarın gerçekleşmesinde birçok tasarım düşünülmüş ve uygulanmıştır. Buradaki amaç en iyi performansı elde etmek için anahtarların; güvenilirlik, aşağı çekme gerilimi, kapasitif oran (Con/Coff) 'nın incelenmesidir. Çeşitli tasarımların gerçekleşmiş örnekleri Şekil (2.5) 'te gösterilmiştir. Bazı MEMS anahtarlar, köprü zarında birbirine yakın delikli olarak imal edilmiştir. Bu tabakanın kaldırılması için kuru etching tekniğinin kullanılması ve köprünün altındaki nemin azaltılarak anahtarın hızlı çalışması için yapılır.



Şekil 2.5: Bazı önemli MEMS tasarımlarının SEM görüntüleri

Bu RF MEMS anahtarların DC karakteristikleri C-V metre ile ölçülmüştür. Ölçüm sonuçları MEMS geometrilerine göre farklılık gösterir. Aşağı-durum kapasitesinin 2-7 pF civarında ve yukarı-durum kapasitesinin ise 20-100 fF civarında olduğu gözlemlenmiştir. Aşağı çekme gerilimi ise 15 ile 50 Volt aralığındadır. MEMS yapılarının dar destek kollu ve geniş zar temas alanına sahip olanları, geniş destek kollu ve küçük temas alanına sahip olanlarına göre çok daha az aşağı çekme gerilimi gerektirirler. Fakat bu durum, diğer bir sorunu ortaya çıkarır. Düşük aşağı çekme gerilimi gerektiren MEMS yapıları çok fazla süreç kontrolü gerektirir ve ölçüm sırasında genellikle bozulurlar. Devre uygulamaları sırasında RF MEMS anahtarlardan faydalanırken, yukarı/aşağı durum kapasitelerinin tam kontrolü gerekmektedir ve bu yüzden fringing alan kapasitelerinin modellenmesi ve hesaplanmasının zor olduğu yerlerde; basit MEMS yapıları kompleks olanlarına tercih edilebilir. Bu durum anahtarın performans kaybına uğramadan dikdörtgen zar yapısıyla basitçe cihazı modellemek için sonraki birçok tasarımı ilgilendirmektedir. DC C-V ölçümünde, genellikle MEMS anahtarı aktive etmek için yüksek aşağı çekme gerilimi gerektiği halde, Şekil (2.6) 'da gösterildiği gibi sonradan üst zarın aşağı durumda


kalabilmesi için çok daha az bir bias gerilimi gerekir. Böyledir çünkü aşağı-durum halinde üst ve alt elektrotlar arasındaki boşluk azalır ve görece küçük DC Bias, yüksek elektrik alan oluşturur ve böylece en üst metalin kendine has yay kuvveti, yüksek elektrostatik kuvvet ile dengelenir.



Şekil 2.6: RF MEMS anahtarın ileri ve geri DC bias salınımının C-V ölçümü


Diğer önemli parametre ise anahtarları aktive etmek için gereken gerilimdir. Birçok araştırmada RF MEMS anahtar düşük aktivasyon gerilimi ile çalışması için tasarlanmaya çalışılmaktadır. RF MEMS anahtarın aktivasyon gerilimi ve güvenilirliği en üst zarın mukavemetine ve kalitesine bağlıdır. Mukavemetin minimum olması, aşağı çekme geriliminin de minimum olması demektir. Düşük mukavemetli metal köprünün bulunması için en iyi teknikler araştırılmaktadır, farklı metaller (Altın, Nikel, Alüminyum, Titanyum vs.) ve çeşitli metal tortulanma durumları test edilmiştir. Sonuçlar, çok yavaş bir Altın veya Alüminyum e-beam(elektron ışıması) tortulanmasının güvenilirlik ve aşağı çekme gerilimi açısından (Şekil (2.7 a)'da görüldüğü gibi) en iyi sonuçları verdiğini göstermektedir. Buradaki tasarımda anahtarların tipik aşağı çekme gerilimi, e-beam tortulanma oranına, zarın kalınlığına, direnç profiline ve dikey mukavemet eğimine bağlı olarak 20-30 Volttur. Halen, Raytheon MEMS anahtarın aşağı çekme geriliminde 1.5 Voltluk bir sapma ile standart uygulamaları gerçekleştirmektedir. Şekil (2.7b)'de görüldüğü gibi Nikel oldukça yüksek mukavemet gösterir, bu mukavemet en üst tabaka serbest bırakıldığı zaman anahtarı aşağı çeker. Titanyum bazlı metal köprüler, ölçüm sırasında çalışmasına rağmen Alüminyum ve Altının kesin alternatifi olarak görülememektedir. Titanyumun e-beam ile

tortulanması durağan değildir ve metalde kayda değer bir mukavemet meydana getirir ve çok çabuk oksitlenir. Bu durum da anahtarların mekanik ve elektriksel özelliklerini etkiler.




Şekil 2.7: (a)(solda): Alüminyum tortulanmasından önceki MEMS Anahtar resmi.
b)(sağda): Nikel tortulanmasından önceki MEMS Anahtar resmi. Burada köprünün zorlanması açıkça görülebilir. (Zarın kenarları ciddi ölçüde kıvrılmıştır)

Diğer bir önemli konu ise güvenilir teknik bir gelişme olan en üst tabakanın planarizasyonudur. Birçok mikrodalga uygulamasında, sinyal iletim kaybını azaltmak için koplanar dalga kılavuzları genellikle 1 μm kalınlığında tasarlanır. Örnekte metal köprünün yüksekliği ve profili, kaldırılan fotorezistin yüksekliğine ve profiline göre ayarlanır. Şekil (2.8)'de gösterildiği gibi, kalın transmisyon hattı metal köprünün düzensiz yüzey profiliyle sonuçlanır. Bu durum eğer zar yeterince düzgün değilse meydana gelir, ve zar aşağıya doğru çekildiğinde merkez iletkenle iyi temas sağlanamaz. Bu durumda beklenenden farklı olarak düşük kapasite değeri ile ortaya çıkar. Ek olarak, zarın düzlemsel olmayan profili gerilme kuvvetini azaltır ve böylece metal köprüdeki yay sabiti (k), düşük anahtarlama hızı ve anahtarların güvenilirliğinde azalma görülür. Böylece, fotorezistin profilindeki salınımları azaltmak için etkili bir işlem belirlemek çok önemlidir. Kaldırılacak fotorezist kısmın yüzeyini düzleştirmek için çok yüksek sıcaklıklarda (~ 280 derece) fotorezistin akışkanlığını önlemek için çok fazla çaba sarf edilmektedir. Şekil (2.9) üretilen iki örneğin yüksek sıcaklık reflow işlemi uygulanan ve uygulanmayan iki SEM resimlerini gösterir. Soldaki resimde yüksek sıcaklıktaki reflow işlemi uygulanmayan metal köprünün profilinin düzlemsel olmadığını görebiliriz. Profildeki bu durum sağdaki görüntüde gösterildiği gibi, 280°C 'deki sıcak plaka üzerinde 3 dk bekletilerek yüksek sıcaklıkta reflow işlemiyle giderilebilir.




Şekil 2.8: Fotorezistin düzgün olmayan profilinin metal depozisyonundan önceki ve sonraki halini göstermektedir.



Şekil 2.9: (solda) : Yüksek sıcaklıkta reflow işlemi uygulanmayan örneğin SEM resmi (Zarın düzlemsel olmayan profili belirgindir). En alttaki iletken ile olan temas yetersizdir. (sağda) : Yüksek sıcaklıkta tekrar akış ile düzeltilen örneğin anlık görüntüsü. Profildeki birçok düzensizlik kaybolmuş, en alttaki iletken ile olan temas artmıştır.

10 GHz in altındaki uygulamalar için üretilen RF MEMS anahtarlarında bazı güçlüklerle karşılaşılmaktadır. Bu amaçla, en üst zar olağan ($300\mu\text{m} \times 30\mu\text{m} - 80\mu\text{m}$) yerine $300\mu\text{m} \times 200\mu\text{m}$ 'ye genişletilmiştir. Fakat en üst zarın büyüyen alanı, yapışma oluşmasına neden olur ve kritik serbest bırakma olabilmesi için çok büyük değişiklikler gerekmektedir. Bu işlemin verimliliği oldukça azdır. Sadece birkaç MEMS cihazı yapışma olmadan başarıyla gerçekleştirilmiştir (Şekil (2.9a)'da görülmektedir). Ek olarak, DC ölçüm yapılamadan cihazlar başarıyla serbest bırakılmıştır. Anahtarı yukarı konumdan aşağı konuma getirebilmek için DC biasa başvurulmuştur. Fakat DC bias geriliminin kaldırılmasından sonra zar tekrar yukarı konuma gelememiştir (Şekil (2.10b)'de görülmektedir). Bundan

dolayı daha büyük tasarımların problemlere yol açacağı düşünülmektedir. Yapılar çok daha geniş olarak tasarlanabilir ancak, bu durumda silikon nitratın dielektrik tabakasındaki şarj etkileri çok büyür ve de dielektrik tabaka ve metal köprü arasında yapışma meydana gelir. Metal köprünün esnekliği aşağı konuma getirilen en üst elektrotu tekrar yukarı konuma getirebilmek için yeterli değildir. Güvenilir anahtarlama işlemi için, RF MEMS anahtar kesin ölçülerdeki üst metal köprünün boyuna ve genişliğine sahip olmalıdır. Burada dikkat edilmesi gereken en önemli nokta, metal köprünün uzunluğu $350\ \mu\text{m}$ 'yi aşmamalıdır ve genişliği $100\text{-}120\ \mu\text{m}$ arasında olmalıdır. $10\text{-}30\ \text{GHz}$ 'deki uygulamalarda genellikle köprünün uzunluğu $250\ \mu\text{m}$ ve genişliği $80\ \mu\text{m}$ olarak seçilir.



Şekil 2.10: Anahtarların SEM resimleri : (a)(solda) : Yapı(zar) serbest bırakılmış, (b)(sağda) : Sürekli bir yapışma meydana gelmiştir.

2.4 MEMS Anahtarların Güvenilirliği


Kapasitif anahtarların güvenilirliğinde en önemli etken , geniş alanda temas durumunda ortaya çıkan (yaklaşık $100\ \mu\text{m} \times 100\ \mu\text{m}$) metal ve dielektrik tabaka arasındaki yapışma durumudur(stiction). Yapışma kuvveti, silikon nitrit dielektrik tabakasındaki yük etkilerinden kaynaklanır. Enjekte edilen yükün polaritesine bağlı olarak, anahtar aşağı konumdayken yapışmaya veya aşağı çekme geriliminde yükselmeye sebep olur; bu yüzden anahtar daha fazla kullanılamaz. Dielektrik tabakadaki elektrik alan $3\text{-}5\ \text{MV/cm}$ kadar yüksek olabilir, bu da metalden dielektriğe FP-şarj enjeksiyon mekanizması ile sonuçlanır. Şarj enjeksiyonu gerilimle eksponansiyel olarak değişir ve aşağı çekme gerilimindeki 6 voltluk azalma MEMS anahtarın ömrünü 10 kata kadar artırır. $25\text{-}30$ Voltluk aşağı çekme gerilimi en uygun olanıdır. Silikon dioksitin, silikon nitritten çok daha az trap yoğunluğuna sahip olduğu bilinmektedir ve RF MEMS kapasitif anahtarlarda kullanıldığı zaman daha az yüklenme ile sonuçlanır. Bundan dolayı oksitlenen metalin düşük dielektrik sabitine bağlı

olarak ařađı durum kapasitesinde (veya kapasite oranında) azalma g r l r. řarj enjeksiyon sorunu      rse, g venilirlik; su buharı(nemlilik) ve MEMS anahtarın altında ve etrafındaki organik atıklara bađlı olarak oluřan yapıřmayla sınırlanır.

3 RF MEMS KAPASİTİF ANAHTARLARIN HFSS İLE MODELLENMESİ

İlerleyen iki bölümde RF-MEMS anahtarlar hem seri hem paralel konfigürasyonlarda incelenecektir. Şekil 3.1, seri ve paralel anahtar yapıları ile bu anahtarların basitleştirilmiş eşdeğer devrelerini göstermektedir. Bu eşdeğer devreler, anahtarların özelliklerini tam olarak karakterize etmese de önemli parametreleri içermektedir.

Anahtarlar ayrıca anahtarın S parametrelerini elde etmek amacıyla sonlu elamanlar metoduna dayalı tam dalga analizi kullanılarak karakterize edilmiştir. Anahtarın tam dalga elektromanyetik simülasyonu (Ansoft High Frequency Structure Simulator) HFSS programı ile yapılmıştır. Paralel anahtarlar için S-parametreleri 0-50 Ghz'e, seri anahtarlar için 0-10 Ghz'e kadar olan aralıkta elde edilmiştir. Bu çalışmalar yapılırken, alt tabakanın bağıl dielektrik sabiti 5.7 olup, kayıpsız olduğu varsayılmıştır. Alt tabakanın kalınlığı 500 um ve CPW (coplanar wave guide – eşdüzlemsel dalga klavuzu) iletkenleri ve RF-MEMS anahtarlar mükemmel iletken kullanılarak tasarlanmıştır. HFSS sonucunda elde edilen S-parametrelerinin, ilerleyen bölümde yapay sinir ağlarında uygulanmasına karar verilmiştir.




Şekil 3.1 (a) Seri anahtar ve basit eşdeğer devresi. (b) Paralel anahtar ve basit eşdeğer devresi


3.1 RF-MEMS Kapasitif Paralel Anahtarın HFSS İle Modellenmesi

Bu bölümde mikrodalga baskılı devre üzerine oluşturulan RF-MEMS kapasitif paralel anahtar incelenecektir. RF-MEMS anahtarın blok diyagramı Şekil 3.2 de gösterilmiştir. Koplanar dalga klavuzu toprak yapısıyla birlikte kullanılmıştır. Alt taban malzemesi olarak cam (corning glass – $\epsilon_r = 5.75$) seçilmiştir. Alt tabakanın kalınlığı 500 μm , RF sinyal genişliği 200 μm 'dır. Alt elektrodla temas alanını belirleyen metalik zarın kalınlığı 0.5 μm , genişliği ise 50 – 100 – 150 μm için ayrı ayrı incelenmiştir.


Aynı kesişim alanına sahip anahtarların dielektrik katmanı için mica($\epsilon_r = 5.7$), silikon nitrit ($\epsilon_r = 7$) ve bakır oksit ($\epsilon_r = 18.1$) olmak üzere 3 ayrı malzeme kullanılarak inceleme yapılmıştır. Bakır oksitin kullanımının çeşitli avantajları olduğu ortaya çıkmıştır. Bakır oksitin yüksek dielektrik sabiti ($\epsilon_r = 18.1$), yüksek aşağı durum kapasitesi sağlamış ve rezonans frekansını daha aşağı frekans bandına çekmiştir. Anahtarlama performansı açısından yüksek kapasite oranı sağlanmalıdır ve bunu sağlamak içinde aşağı durum kapasitesinin mümkün olduğunca yüksek olmalıdır. Aynı zar ve dielektrik tabaka kapama alanında bakır oksit, diğer iki malzemeye oranla daha yüksek kapasite oranına sahiptir. Simulasyonlar sonucunda bakır oksit RF-MEMS anahtarın diğer iki malzemeye göre daha düşük frekansta daha iyi izolasyon değerine sahip olduğu gözükmemektedir.




Şekil -3.2 RF-MEMS kapasitif paralel anahtarın blok diyagramı



Şekil3.3 HFSS de Modellenmiş RF-MEMS kapasitif anahtar



Şekil 3.4 RF-MEMS Kapasitif Paralel Anahtarın Kapalı Durumu



Şekil 3.5 RF-MEMS Kapasitif Paralel Anahtarın Açık Durumu

Anahtarlama performansını artırmak için kapalı durum kapasitesi mümkün olduğunca yüksek olmalıdır. Bu kapasite oranını belirlemek için üç yol incelenmiştir. İlk olarak, aynı kalınlıkta dielektrik malzemeye ve aynı tabaka kaplama alanına sahip anahtarların dielektrik malzeme cinsleri (dielektrik katsayısı) değiştirilmiştir, ikinci olarak bu dielektrik malzemelerin kalınlığı değiştirilmiştir ve son olarak tabaka kaplama alanı (temas alanı) değiştirilerek incelemeler yapılmıştır. Aşağı durum kapasitesi aşağıdaki gibi hesaplanabilir.(Jung,2005)

$$C_{\text{kapalı}} = \epsilon_0 \epsilon_r A / t_{\text{diel}} \quad (3.1)$$

t_{diel} = Dielektirk tabakanın kalınlığı

A = Metalik zar ile alt elektrot arasındaki temas alanı

ϵ_r = Bağıl dielektrik sabiti


Aynı kalınlıkta ($0.1 \mu\text{m}$) dielektrik malzemeye ve aynı tabaka kaplama alanına ($150 * 200 \mu\text{m}^2$) sahip mica ($\epsilon_r = 5.7$), silikon nitrit ($\epsilon_r = 7$) ve bakır oksit ($\epsilon_r = 18.1$) anahtarların kapalı ve açık durumdaki simülasyonları (S-parametreleri) şekil 3.6, 3.7, 3.8, 3.9, 3.10 ve şekil 3.11 de gözükmetedir.

Şekil 3.6 ve 3.7 dielektrik malzemesi mica kullanılarak tasarlanan anahtarın S-parametrlerini göstermektedir. Grafiklerden de görüldüğü üzere anahtar kapalı durumdayken en iyi izolasyonu 14 – 16 GHz arasında sağlamıştır. İzolasyon frekansı yaklaşık olarak 14.2 GHz civarındadır. Anahtar açık durumdayken eklenme kaybı çok düşük seviyededir. Yani gelen işaretin hemen hemen tamamını geçirmiştir.


Şekil 3.8 ve 3.9 dielektrik malzemesi silikon nitrit kullanılarak tasarlanan anahtarın S-parametrlerini göstermektedir. Grafiklerden de görüldüğü üzere anahtar kapalı durumdayken en iyi izolasyonu 12 – 14 GHz arasında sağlamıştır. İzolasyon frekansı yaklaşık olarak 13 GHz civarındadır. Anahtar açık durumdayken eklenme kaybı mica ile yaklaşık aynı seviyededir.

Şekil 3.10 ve 3.11 dielektrik malzemesi bakır oksit kullanılarak tasarlanan anahtarın S-parametrlerini göstermektedir. Grafiklerden de görüldüğü üzere anahtar kapalı durumdayken en iyi izolasyonu 8 – 10 GHz arasında sağlamıştır. İzolasyon frekansı yaklaşık olarak 8 GHz civarındadır. Anahtar açık durumdayken eklenme kaybı diğer iki malzemeye göre daha düşük seviyededir.


Bu karşılaştırmalar sonucunda bakır oksitin kapasitesi eşitlik 3.1'den de tahmin edileceği üzere bağıl dielektrik katsayısının yüksek olmasından dolayı diğer iki malzemeye göre daha yüksek olduğu belirlenmiştir. S_{12} parametreleri göz önüne alındığında rezonans frekansı bakır oksitin yaklaşık olarak 5 GHz daha düşük olduğu saptanmıştır. Bunun da nedeni bakır oksitin kapasitesinin daha yüksek olmasıdır. Bilindiği gibi kapasitenin artması rezonans frekansını düşürmektedir. Anahtarlama performansını artırmak için yüksek bağıl dielektrik katsayısına sahip malzeme kullanılması gerektiği anlaşılmıştır. Her üç malzemede S_{12} parametresi 5 GHz den sonra 20 dB'nin altına düşmüştür. Bu da anahtarların iyi izolasyon sağladığını göstermektedir.




Şekil 3.6 Mica malzeme ile tasarlanan paralel anahtarın kapalı durumu




Şekil 3.7 Mica malzeme ile tasarlanan paralel anahtarın açık durumu




Şekil 3.8 Silikon Nitrit malzeme ile tasarlanan paralel anahtarın kapalı durumu



Şekil 3.9 Silikon Nitrit malzeme ile tasarlanan paralel anahtarın açık durumu




Şekil 3.10 Bakır oksit malzeme ile tasarlanan paralel anahtarın kapalı durumu




Şekil 3.11 Bakır oksit malzeme ile tasarlanan paralel anahtarın açık durumu


Anahtarlama performansını değiştirecek parametrelerden biride dielektrik mazlemenin kalınlığıdır. Aynı kesişme alanında bakır oksit, silikon nitrit ve mica dielektrik malzeme kalınlıkları $0.1\ \mu\text{m}$ – $0.5\ \mu\text{m}$ arasında değiştirilerek incelenmiştir. Anahtarların kapalı ve açık durumdaki S parametreleri şekil 3.12, 3.13, 3.14, 3.15, 3.16 ve şekil 3.17 de verilmiştir. Şekillerden de görüleceği üzere bakır oksitle tasarlanan anahtarın izolasyon frekansı 8-20 Ghz arasında, silikon nitrit için izolasyon frekansı 12-30 Ghz arasında ve mica malzeme için izolasyon frekansının 14-32 Ghz arasında değiştiği gözlenmiştir. Anahtarların açık durumdaki eklenme kayıpları her üç malzeme içinde dielektrik kalınlıklarına göre 1.7 dB ile 2.1 dB arsında değiştiği gözlenmiştir. Anahtarlama performansı, dielektrik kalınlığı açısından göz önüne alındığında simülasyonlar sonucunda da görüldüğü üzere daha ince kalınlıktaki dielektrik mazlemenin daha düşük frekansta iyi izolasyon sağladığı ve daha az seviyede ekleme kaybına sebep olduğu belirlenmiştir. Buna ek olarak şekil 3.18 de mica malzeme kullanılarak tasarlanan anahtarın kapalı durumda değişken kalınlıktaki S_{11} parametreleride gösterilmiştir. Simülasyon sonucuna bakıldığında daha ince kalınlıktaki dielektrik mazlemenin geri dönüş kaybının daha az olduğu saptanmıştır.




Şekil 3.12 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1\ \mu\text{m}$ – $0.5\ \mu\text{m}$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)




Şekil 3.13 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1\ \mu\text{m}$ – $0.5\ \mu\text{m}$ arasındaki değişiminin eklenme kaybına etkisi (anahtar açık)




Şekil 3.14 Silikon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1\ \mu\text{m}$ – $0.5\ \mu\text{m}$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)




Şekil 3.15 Silikon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin ekleme kaybına etkisi (anahtar açık)



Şekil 3.16 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı 0.1 μm – 0.5 μm arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)




Şekil 3.17 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin ekleme kaybına etkisi (anahtar açık)




Şekil 3.18 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin geri dönüş kaybına etkisi (anahtar kapalı)

Anahtarlama performansını etkileyen son parametre olarak da temas alanı (kesişim alanı) belirlenmiştir. Aynı kalınlıktaki dielektrik malzemeye ($0.1 \mu\text{m}$) sahip anahtarların temas alanı $50*200 \mu\text{m}^2 - 150*200 \mu\text{m}^2$ arasında değiştirilerek anahtarların kapalı durumdaki izolasyon frekansına etkileri (S_{12} parametreleri) incelenerek şekil 3.19, 3.20 ve 3.21 de grafik olarak sunulmuştur.


Bu şekillerden görüldüğü üzere bakır oksitle tasarlanan anahtarın izolasyon frekansı 8-11 Ghz arasında, silikon nitrit ile tasarlanan anahtarın 12-18 Ghz arasında ve mica ile tasarlanan anahtarın 14-20 Ghz arasında değiştiği belirlenmiştir. Anahtar performansını artırmak (kapasiteyi artırmak) için temas alanının artırılması gerektiği her 3 mazleme içinde simülasyonlar sonucunda belirlenmiştir.



Şekil 3.19 Mica malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu\text{m}^2$ arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)



Şekil 3.20 Silikon Nitrit malzeme ile tasarlanan anahtarın temas alanının 50*200 – 150*200 μm^2 arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)




Şekil 3.21 Bakır Oksit malzeme ile tasarlanan anahtarın temas alanının 50*200 – 150*200 μm^2 arasındaki değişiminin izolasyon frekansına etkisi (anahtar kapalı)

3.2 RF-MEMS Kapasitif Seri Anahtarın HFSS İle Modellenmesi


Bu bölümde mikrodalga baskılı devre üzerine oluşturulan RF-MEMS kapasitif seri anahtar inceleneyecektir. RF-MEMS anahtarın yapısı şekil 3.22’de, blok diyagramı şekil 3.23 de gösterilmiştir. Anahtarın izolasyonu (anahtar açık) ve araya ekleme kaybı (anahtar kapalı) durumları HFSS simülasyonları ile incelenmiştir.

Bir önceki bölümde olduğu gibi anahtarların dielektrik kamanı için mica, silikon nitrit ve bakır oksit kullanılarak inceleme yapılmıştır. Alt taban malzemesi cam ve kalınlığı 500 μm ’dir. RF sinyal genişliği 200 μm ’dir. Alt elektrodla temas alanını belirleyen metalik zar kalınlığı 0.5 μm , genişliği ise 50*200 – 150*200 μm^2 arasında değiştirilerek inceleme yapılmıştır.




Şekil 3.22 – RF-MEMS Kapasitif seri anahtarın yapısı


Anahtarlama performansını etkileyen faktörler bir önceki bölümde belirtilmişti. Seri anahtarlar içinde aynı parametreler geçerlidir. Bir önceki bölümdeki araştırmalara benzer şekilde seri anahtar içinde aynı çalışmalar yapılmış ve simülasyon sonuçları grafik olarak sunulmuştur.




Şekil 3.23 – RF-MEMS kapasitif seri anahtarın blok diyagramı



Şekil 3.24 – HFSS’de Modellenmiş RF-MEMS Kapasitif Seri Anahtar



Şekil 3.25 RF-MEMS Kapasitif Seri Anahtarın Açık Durumu




Şekil 3.26 RF-MEMS Kapasitif Seri Anahtarın Kapalı Durumu

Şekil 3.27, 3.28, 3.29, 3.30, 3.31 ve 3.32 de $0.5 \mu\text{m}$ kalınlıklı temas alanı $150 \times 200 \mu\text{m}^2$ olan bakır oksit, silikon nitrit ve mica malzeme kullanılarak tasarlanan seri anahtarın 0-10 Ghz arasında ki S-parametreleri gösterilmiştir.


Mica malzeme ile tasarlanan seri anahtarın kapalı durumdaki araya ekleme kaybı (S_{12} parametresi) 15 dB den başlayıp 2 Ghz in üstünde tam olarak çalışmaya başlamıştır ve anahtarın çalışma frekansı 5 Ghz civarındadır, çalışma frekansında ki izolasyonu incelendiğinde ise 15 dB civarındadır.

Silikon nitrit malzeme ile tasarlanan seri anahtarın kapalı durumdaki araya ekleme kaybı (S_{12} parametresi) 12 dB den başlayıp 1.8 Ghz in üstünde tam olarak çalışmaya başlamıştır ve anahtarın çalışma frekansı 4.5 Ghz civarındadır, çalışma frekansında ki izolasyonu incelendiğinde ise 16 dB civarındadır.


Bakır oksit malzeme ile tasarlanan seri anahtarın kapalı durumdaki araya ekleme kaybı (S_{12} parametresi) 5 dB'den başlayıp 1 Ghz in üstünde tam olarak çalışmaya başlamıştır ve anahtarın çalışma frekansı 2.8 Ghz civarındadır, çalışma frekansında ki izolasyonu incelendiğinde ise 18 dB civarındadır.




Şekil 3.27 Mica ile tasarlanan anahtarın kapalı durumu




Şekil 3.28 Mica ile tasarlanan anahtarın açık durumu




Şekil 3.29 – Silikon Nitrit ile tasarlanan anahtarın kapalı durumu



Şekil 3.30 Silikon Nitrit ile tasarlanan anahtarın açık durumu




Şekil 3.31 Bakır Oksit ile tasarlanan anahtarın kapalı durumu




Şekil 3.32 Bakır Oksit ile tasarlanan anahtarın açık durumu


Anahtarlama performansını, araya ekleme kaybını ve izolasyonu incelemek için anahtarın dielektrik malzeme kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasında değiştirilip simülasyon sonuçları $150 \times 200 \mu\text{m}^2$ temas alanına sahip mica için şekil 3.33 ve 3.34, silikon nitrit için şekil 3.35 ve 3.36, bakır oksit için şekil 3.37 ve 3.38 de gösterilmiştir. Grafikler göz önüne alındığında her üç malzeme içinde dielektrik kalınlığı incelendiği zaman daha az ekleme kaybına, daha iyi izolasyona ve daha düşük izolasyon frekansına sahip olduğu anlaşılmıştır. Mica malzeme için ekleme kaybı 3 dB ile 14 dB arasında değişmekte, silikon nitrit malzeme için ekleme kaybı 2.4 dB ile 12.5 dB arasında değişmekte ve bakır oksit malzeme için ise ekleme kaybı 0.25 dB ile 6 dB arasında değişmekte olduğu belirlenmiştir.




Şekil 3.33 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin ekleme kaybına etkisi (anahtar kapalı)




Şekil 3.34 Mica malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin izolasyona etkisi (anahtar açık)




Şekil 3.35 Silikon Nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m}$ – $0.5 \mu\text{m}$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı)



Şekil 3.36 Silikon nitrit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m}$ – $0.5 \mu\text{m}$ arasındaki değişiminin izolasyona etkisi (anahtar açık)




Şekil 3.37 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı)




Şekil 3.38 Bakır Oksit malzeme ile tasarlanan anahtarın dielektrik kalınlığı $0.1 \mu\text{m} - 0.5 \mu\text{m}$ arasındaki değişiminin izolasyona etkisi (anahtar açık)


Anahtarlama performansını deęiřtiren son parametrede bir önceki bölümde de belirtildięi gibi temas alanı (kesiřme alanı) ‘dır. Temas alanı $50*200 - 150*200 \mu\text{m}^2$ arasında deęiřtirilerek inceleme yapılmıř ve sonuçlar $0.5 \mu\text{m}$ kalınlıklı mica malzeme için Şekil 3.39, silikon nitrit için Şekil 3.40, bakır oksit için şekil 3.41 grafik olarak sunulmuřtur. Mica malzeme için 14 dB ile 23 dB arasında deęiřmekte, silikon nitrit malzeme için 12 dB ile 21 dB arasında deęiřmekte ve bakır oksit malzeme için 5 dB ile 14 dB arasında deęiřtięi gözlenmiřtir.



Şekil 3.39 Mica malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu\text{m}^2$ arasındaki deęiřiminin ekleme kaybına etkisi (anahtar kapalı)



Şekil 3.40 Silikon Nitrit malzeme ile tasarlanan anahtarın temas alanının $50*200 - 150*200 \mu\text{m}^2$ arasındaki değişiminin eklenme kaybına etkisi (anahtarkapalı)



Şekil 3.41 Bakır Oksit malzeme ile tasarlanan anahtarın temas alanının $50*200 \mu\text{m}^2 - 150*200 \mu\text{m}^2$ arasındaki değişiminin eklenme kaybına etkisi (anahtar kapalı)

4. YAPAY SİNİR AĞLARININ İNCELENMESİ

Bu bölümde yapay sinir ağlarının tarihi gelişimi, neden kullandığı, yapay sinir ağlarındaki temel yapılar, eğitim algoritmaları ve transfer fonksiyonları hakkında ayrıntılı bilgi verilmiştir.

4.1 Yapay Sinir Ağlarına Genel Bakış

Bu bölümde yapay sinir ağları hakkında genel bilgi verilmiştir.

4.1.1 Yapay Sinir Ağı Nedir?

Yapay sinir ağları insan beyni gibi biyolojik sinir sistemlerinin çalışma prensibini örnek alan bir bilgi işleme tekniğidir. Burada kullanılan temel eleman biyolojik bilgi işlem mekanizmalarının temel elemanı olan nöron ve kullanılan çalışma prensipleri de bu nöronun çalışma prensipleridir. Yapay sinir ağları da biyolojik nöronlar gibi tecrübeye dayalı olarak öğrenmektedir. Yapay sinir ağları bir eğitim sürecinden geçirildikten sonra patern tanınması veya veri tasnifi gibi işlemlerde kullanılabilirler. Biyolojik nöronlarda öğrenme, nöronlar arasındaki sinaptik bağlantıların ağırlıklarının değişimleri ile gerçekleştirilmektedir. Aynı durum yapay sinir ağları için de geçerlidir.

Yapay sinir ağı kavramı yeni oluşturulmuş bir bilgi işleme tekniği gibi gözükse de bu alandaki çalışmalar bilgisayarların hayatımıza girmesinden öncesine dayanmaktadır. Bu alandaki çalışmalar süreç içerisinde birçok kez gözden düşmüş fakat yeni bulunan tekniklerle yeniden canlanmayı ve birçok araştırmacının dikkatini çekmeyi başarmıştır. Çalışmaların gözden düşmesindeki en büyük etken bu konuda yazı yazan insanların bu teknikle üretilmiş sistemlerin hemen hemen her şeyin üstesinden gelebileceği gibi bir kanıyı okurlarına aktarmalarından kaynaklanmaktadır. Potansiyel kullanıcılar bu teknikleri uygulamaya çalışmış ve daha sonra tatmin edici bir sonuca ulaşamayınca da bu teknikle ilgili tüm heveslerini kaybetme noktasına gelmişlerdir. Bu da bu konuda yapılacak araştırmalara ayrılan kaynakların kısılmasına ve hatta kaynakların başka araştırma konularına ayrılmasına sebep olmuştur. Ama günümüzde yapay sinir ağları birçok alanda kullanılabileceklerini kanıtlamış bir teknik olarak kabul edilmekte ve de bu alanda ciddi araştırmalar yapılmaktadır.

4.1.2 Yapay Sinir Ağlarının Tarihi

İnsan beyni üzerinde yapılan çalışmalar binlerce yıllık bir tarihe sahiptir. Modern elektroniğin ortaya çıkmasıyla birlikte insan beyninin çalışmasını bir parça da olsa simüle edebilecek olanaklara sahip olduk. Matematikçi Warren McCulloch'un ve de nörofizyolojist Walter Pitts'in 1943 yılında sinir hücrelerinin nasıl çalıştıkları hakkında hazırladıkları çalışma yapay sinir ağlarının araştırılması konusunda bir başlangıç olarak düşünülebilir. Basit bir yapay sinir ağını elektriksel devreler kullanarak modellemişlerdir.

1943 yılında yapılan bu çalışmanın altındaki düşüncüyü Donald Hebb 1949 yılında yazdığı 'Davranışın Organizasyonu' adlı kitabında desteklemiştir. Bu kitapta sinirsel yolların kullanıldıkça daha da güçlendiğini göstermiştir. Bilgisayarlar 1950'lerde bebeklik dönemini yaşarken insan düşüncesinin mekanizmalarının en temel ve en basit yönlerini modelleme imkanı elde edilmiştir. IBM araştırma laboratuvarlarından Nathaniel Rochester bir yapay sinir ağını simüle etmeyi denemiştir. İlk deneme başarısız olmuş fakat sonraki denemelerde başarı elde edilmiştir. Bu denemeler yapılırken bugün kullandığımız geleneksel programlama teknikleri yavaş yavaş ortaya çıkmaya başlamıştır. Bu yüzden yapay sinir ağları üzerindeki ilgi azalmış ve bu konuda yapılan araştırmalar arka planda kalmıştır. Yine de düşünen makineleri savunanlar kendi düşüncelerini ifade etmeye devam etmişlerdir. 1956 yılında yapay zeka üzerine yapılan Dartmouth Yaz Araştırma Projesi yapay zekaya ve de yapay sinir ağlarına olan ilgide bir patlamanın yaşanmasına sebep olmuştur. Bu sürecin sonucunda araştırmaların yapay zeka ve de yapay sinir ağlarının çalışması olarak iki bölümde incelenmesine karar verilmiştir.

Dartmouth projesini izleyen yıllarda John Von Neumann telgraf röleleri ve vakum tüplerini kullanarak basit sinir hücresi özelliklerinin taklit edilmesini önermiştir. Aynı zamanda Frank Rosenblatt adındaki nörobiyolog Perceptron üzerinde çalışmaya başlamıştır. Rosenblatt bir sineğin gözlerinin gösterdiği işlev karşısında şaşırmıştır. Bir sineğe hangi yöne uçuşmasını gösteren işlemlerin çoğu gözünün içerisinde meydana gelmektedir. Bu çalışmanın sonunda Perceptron ağ türü ortaya çıkmıştır. Bu ağ elimizde bulunan en eski yapay sinir ağı yapısıdır. Perceptron tipi ağlar giriş değerlerini tasnif etmek veya onları gruplara ayırmak için kullanılabilirler. Ne yazık ki Perceptron türü ağların yapabilecekleri şeylerin bir sınırı vardı.

1959 yılında Bernard Widrow ve Marcian Hoff adlı bilim adamları ADALINE ve MADALINE (çoklu adaline) ağ tiplerini geliştirmişlerdir. Bunlar adaptif lineer eleman olarak adlandırılırlar. MADALINE teori sayfalarından çıkıp günlük hayatımızda kullanılan ilk yapay sinir ağı çeşidi olmuştur. Telefon hatlarındaki ekoyu ortadan kaldıran adaptif filtreler bu tür ağ yapısı kullanılarak oluşturulmaktadır. Bu ağ türü ticari olarak hala kullanım alanı bulmaktadır.

Yapay sinir ağı konusunda yapılan bu öncel çalışmaların gösterdiği başarıya rağmen bu konu hakkında yazı yazan insanların yapay sinir ağlarının potansiyeli hakkında abartılı tahminler yapmaları ve bu tahminlerin o zamanın elektronik teknolojisi ile karşılanamayacak düzeyde olması bu alana olan ilgide büyük bir düşüşe neden olmuştur. Ayrıca düşünen makinelerin insanlığın sahip olduğu etik ve moral değerlerde yapabileceği erozyonlar hakkında yapılan çalışmalar da bu alana olan ilgide bir düşüşe neden olmuştur. Bu alanda yapılacak çalışmalar hakkında sahip olunan korkular ve de abartılı tahminlerin gerçekleştirilememesi sonucu oluşan hayal kırıklığı bu alana ayrılan kaynakların kesilmesine neden olmuştur.

1982 yılına gelindiğinde birçok ilginç olay alana olan ilgide bir artışa neden olmuştur. John Hopfield Bilimler Akademisine sunduğu çalışmasında sadece beynin nasıl modelleneceğini değil aynı zamanda bu modelleme tekniği kullanılarak oluşturulabilecek faydalı cihazları da sıralamıştır. Yine hemen hemen aynı zamanlarda Kyoto’da düzenlenen bir konferansta Japonya’nın beşinci jenerasyon programlama teknikleri geliştireceğini açıklaması üzerine bu alanda geri kalmaktan korkan Amerika Birleşik Devletleri alana yeniden kaynak ayrılmasına karar vermiştir.

Bugün yapay sinir ağı hakkındaki tartışmalar dünyanın her yerinde yapılmaktadır. Doğada çok verimli bir şekilde çalıştığını gördüğümüz bu teknik parlak bir geleceğe sahiptir. Ama alanın gelişmesindeki en önemli faktör bu tekniklerin hayata geçirilebilecekleri donanım yapılarının oluşturulmasıdır. Şirketler üç tip sinirsel yonga seti üzerinde çalışmaktadır. Bunlar dijital, analog ve optik yonga setleridir. Optik yonga setlerinin geleceği çok parlak gözükmemektedir fakat ticari olarak kullanılabilmesi için daha yıllar gerekmektedir.

4.1.3 Yapay Sinir Ağlarının Kullanılma Nedenleri

Yapay sinir ağları komplike veya hatalı verilerden anlam çıkarabilme, verilerin içerisindeki paternleri fark edebilme ve de insan gözüyle veya herhangi bir bilgisayar tekniği ile fark edilemeyecek kompleks trendleri tanımlayabilecek özelliklere

sahiptirler. Eğitilmiş bir yapay sinir ağı analiz etmesi istenen bilgi türü için bir uzman sistem olarak düşünülebilir. Aşağıda yapay sinir ağlarını kullanma nedenlerimiz sıralanmıştır.

a) Adapte olarak öğrenme : Eğitim sırasında kullanılan veriye göre nasıl işlem yapacağını öğrenebilir.

b) Kendi kendini organize etme : Bir yapay sinir ağı eğitim sırasında kullanılan veriye göre kendi kendini organize edebilmektedir.

c) Bilgilerin kaba bir şekilde tanımlanması sonucunda elde edilen hata toleransı : Ağa ait bazı parçaların zarar görmesi sonucunda performansta çok büyük düşüklükler yaşanabilir. Ama yine de ağ, bilgileri genelleştirilmiş olarak saklamasından dolayı bazı önemli özelliklerini koruma kapasitesine sahip olacaktır.

4.1.4 Yapay Sinir Ağı İle Geleneksel Bilgisayar Tekniklerinin Karşılaştırılması

Yapay sinir ağları problem çözmede günümüzün bilgisayarlarına göre farklı bir yöntem uygulamaktadır. Günümüz bilgisayarları algoritmik yaklaşımı uygularlar. Yani bilgisayar kendisine verilen komutları sırasıyla uygulayarak problemlere çözüm bulur. Ama bilgisayar daha önceden kendisine algoritmik olarak ne yapacağı söylenmemiş bir durumla karşılaştığında problemi çözememektedir. Bu da günümüz bilgisayarlarının problem çözme kapasitesini bizim tanımladığımız ve çözümünü bildiğimiz problemlerle sınırlandırmaktadır. Ama bilgisayarlar bizim tam olarak çözemediğimiz problemlere de yanıt getirebilseler bizim için daha da kullanışlı bir aygıt haline geleceklerdir.

Yapay sinir ağları bilgileri insan beyninin bilgileri işleme tekniğine benzer bir şekilde işlemektedir. Yapay sinir ağı birbirine bağlı çalışan birçok veri işleme ünitesinden oluşmaktadır. Yapay sinir ağları örneklerle bakarak öğrenme işlemini gerçekleştirirler. Spesifik bir işi gerçekleştirmek için programlanamazlar. Hangi problemi çözmede kullanılacağı doğru bir şekilde saptanmalıdır yoksa ağ yanlış bir şekilde çalışabilir. Yapay sinir ağlarının dezavantajı problemi nasıl çözeceğini ağın kendisinin belirlemesidir. Bu yüzden ağın nasıl çalışacağı bazen tahmin edilemeyebilir.

Yapay sinir ağları ve günümüz bilgisayarlarını birbirleri ile yarışan mekanizmalar olarak görmektense onları birbirlerinin daha iyi çalışmasını sağlayan veya başka bir deyişle birbirlerini tamamlayan teknikler olarak görmemiz daha iyi olacaktır. Bazı problemler mesela aritmetik işlemler günümüz bilgisayar tekniği ile çözülmek için daha uygundur. Bazı problemler ise yapay sinir ağı yaklaşımı ile daha kolay bir şekilde

sonuca ulaştırılabilir. Ve tabi ki öyle problemlerle karşılaşabiliriz ki bu problemler iki tekniğin beraber kullanılmasını gerektirebilir.


Yapay sinir ağları mucizeler yaratmamaktadır. Önemli olan bu tekniği akıllı bir şekilde kullanarak günümüz bilgisayar teknikleriyle çözemediğimiz problemlere çözüm bulabilmektir. Aşağıda yapay sinir ağları ile günümüz bilgisayarlarının genel olarak bir karşılaştırılması verilmiştir.

Yapay Sinir Ağları	Günümüz Bilgisayarları
-Paralel işlem yapar	-Seri işlem yapar
-Adapte olabilir	-Sadece tanımlanmış problemlerle çalışır
-Eksik veya bozulmuş verilerle çalışabilir	-Verilerin doğru olması gerekir
-Yavaş çalışır	-Hızlı çalışır
-Bir bozukluk olduğunda bozulan birimin yapılan işe katkısı azalır	-Herhangi bir birim bozulduğunda sistem hatalı veya eksik çalışır

4.1.5 Biyolojik Sinir Ağları

İnsan beyninin bilgileri nasıl işlediği hakkında hala birçok şeyi tam olarak öğrenmiş değiliz. Bu konu hakkında birçok teori bulunmaktadır. İnsan beyninde nöronlar diğer nöronlardan sinyalleri dentrit dediğimiz yapılar aracılığı ile almaktadır. Bir nöron diğerine elektrik sinyallerini akson dediğimiz uzun ince yapı aracılığı ile aktarır. Bu yapılar nörondan çıktıktan sonra binlerce dala ayrılmaktadırlar. Bu dalların sonunda ise gelen elektriksel sinyali tetikleyici veya engelleyici bir yapıya büründüren sinaps dediğimiz yapılar bulunmaktadır. Bir nöron kendi engelleyici girişine göre daha büyük bir tetikleyici sinyal aldığı anda aksonuna bir elektrik sinyali gönderir. Öğrenme işlemi sinaps yapılarının etkilerinde değişiklik yaparak sağlanır. Böylece bir nöronun diğer bir nöron üzerindeki etkisi değiştirilmiş olur. Tipik olarak nöronlar lojik kapılara göre çok daha yavaşlardır. Silikon bir çipin içerisinde olaylar nano saniyeler (10^{-9}) mertebesinde, nöronlar arasında ise mili saniyeler (10^{-3}) mertebesinde gerçekleşmektedir. Bu rakamlardaki oransızlığa rağmen beyin çok fazla sayıda nöronu ve bu nöronlar arasında ortalama 10^4 adet bağlantısıyla kat ve kat daha verimli çalışmaktadır. İnsan beyninde 10^{10} sinir hücresi olduğu ve 60 trilyon bağlantı veya

sinaps yapısı olduğu tahmin edilmektedir. Şekil 4.1’de biyolojik sinir hücresinin yapısı verilmiştir.




Şekil 4.1 – Biyolojik sinir hücresinin yapısı

İnsanlarda Şekil 4.1’de gösterilen tipik sinir hücresinin farklı birçok yapısı bulunmaktadır. Ama bütün sinir hücreleri 4 temel yapı taşından oluşmaktadır. Bunlar dentrit, soma, akson ve sinapsdır.

4.1.6 Biyolojik Sinir Ağlarından Yapay Sinir Ağlarına Geçiş

Son yıllarda yapılan araştırmalar göstermiştir ki biyolojik sinir hücreleri bir önceki bölümde gösterilen biyolojik sinir hücresi yapısına göre yapısal olarak daha karmaşıktır. Bugün kullandığımız yapay sinir ağlarına göre ise oldukça fazla karmaşık bir yapıya sahiptirler. Biyoloji biliminin insan beyni hakkındaki bilgileri arttıkça ve teknoloji de geliştikçe ağ tasarımcıları sistemlerini iyileştirme olanağı elde edeceklerdir. Ama şu an için bakarsak yapay sinir ağı geliştiricilerinin amacı insan beyninin mükemmel bir taklidini yapmaktan çok günümüzün programlama teknikleri ile çözilemeyen problem türlerine bir çözüm bulabilmektir. Bunu başarabilmek için yapay sinir hücreleri biyolojik sinir ağlarının 4 temel yapı taşını içerisinde bulundurmaktadır. Şekil 4.2’de yapay sinir hücresinin yapısı verilmiştir.



Şekil 4.2 Temel yapay sinir hücresi

Şekil 4.2’de giriş değerleri $x(n)$ şeklinde ifade edilmiştir. Bu giriş değerlerinin her biri bir bağlantı ağırlık değeri ile çarpılmaktadır. Bu ağırlıklar $w(n)$ şeklinde ifade edilirler. En basit durumda çarpımlar toplanır ve bir transfer fonksiyonundan geçirilerek bir çıkış değeri elde edilir. Bu süreç farklı toplama şekilleri ve farklı transfer fonksiyonları ile uygulanabilir.

Bazı uygulamalardan çıkış değeri olarak ikili sonuç vermesi istenebilir. Bu uygulamalara örnek olarak el yazısının tanınması ve sesin kime ait olduğunun tanınması gibi örnekler verilebilir. Bu uygulamalar analog giriş değerlerini alıp bunları çıkışında ayrık değerler şeklinde ifade etmek zorundadır. Bu ayrık değerler ASCII karakterleri veya en çok bilinen 50000 Türkçe kelime olabilir. Bu tür ağlar çıkış değerlerindeki bu sınırlamadan dolayı toplama fonksiyonu yerine AND veya OR işlemlerini kullanabilirler. Burada önemli olan bizim istediğimiz aralıkta ve şekilde değerleri elde edecek toplama ve transfer fonksiyonlarını kullanmaktır.


Bazı uygulamalarda ise ağların çıkışlarında sürekli veya başka bir deyişle sonsuz sayıda çıkış değeri verebilecek bir kapasitede olmaları gerekmektedir. Bu tür uygulamalara örnek robot hareketlerinin arkasındaki zekâ olarak düşünülebilir. Bu ağlar giriş değerlerini alırlar ve bir aygıtın hareket etmesini sağlayan çıkış değerlerini üretirler. Bu hareketlerin değerleri hareketin yöneldiği noktanın hassaslığına göre sonsuz sayıda değer alabilmektedir. Bu tür ağlar sensörlerden gelen ayrık değerleri (mesela saniyede 30 defa) sürekli değerler olarak çıkışlarına vermek zorundadır. Bunu da girişleri

topladıktan sonra bir hiperbolik transfer fonksiyonu uygulayarak sağlayabilirler. Böylece çıkış değerleri sürekli değerler alır ve pratik dünyada kullanılabilecek bir hale gelirler.

Bazı uygulamalarda ise ağın giriş değerlerini gruplara ayırmasını isteyebiliriz. Bu tür durumlarda çıkış değerleri 1 veya 0 şeklindedir. Bunu yapabilmek için ağ toplama işlemini gerçekleştirdikten sonra bu değeri bir eşik değeri ile karşılaştırarak çıkış değerini oluşturur.

4.2 Yapay Sinir Ağlarının Elektronik Uygulanması

Şu anda elimizde bulunan yazılımlarda yapay sinir ağı hücresi işlem elemanı olarak isimlendirilmekte ve bir önceki bölümde tanımladığımız basit yapay sinir ağı hücresine göre çok daha fazla yeteneklere sahip durumdadır. Şekil 4.3 de işlem elemanının yapısı verilmiştir.




Şekil 4.3 – İşlem elemanı

Şekil 4.3’de giriş değerleri işlem elemanına sol üst köşeden giriliyor. Buradaki uygulanacak ilk adım bu giriş değerlerinin kendilerine ait ağırlık değerleri ($w(n)$) ile çarpımlarıdır. Bu çarpımlar daha sonra toplama işlemine gönderilir. Toplama işlemi genel olarak sadece çarpımların toplamı olmasına rağmen bazen çarpımların ortalama değeri, çarpımların en büyük veya küçük olanı, çarpımlara AND veya OR işlemi

uygulamak gibi şekiller alabilir. Şu anda piyasada bulunan yapay sinir ağı simülasyon yazılımlarının çoğunda kullanıcıya kendi toplama fonksiyonunu tanımlama şansı verilmektedir. Toplama fonksiyonuna bir aktivasyon fonksiyonu da eklenerek çıkış değerlerinin zamana bağlı olması sağlanabilir.

Her iki durumda da toplama işlemi sonucu elde edilen sayı transfer fonksiyonuna aktarılır. Transfer fonksiyonu aldığı bu değeri bir işlemden geçirir ve de çıkış değerini elde eder. Genel olarak kullanılan transfer fonksiyonları sigmoid, sine ve hiperbolik tanjant fonksiyonlarıdır. Transfer fonksiyonunun bir görevi de çıkış değerlerinin hangi aralıkta olacağını belirlemektir. Şekil 4.4’ de logsig transfer fonksiyonunun grafiği verilmiştir.



Şekil 4.4 – Logsig transfer fonksiyonunun grafiği

Bütün yapay sinir ağları işlem elemanını temel yapı taşı gibi kullanarak oluşturulmaktadır. Bu işi bir uzmanlık haline getiren şey ise bu yapıların değişik biçimlerde ve geometrilere birleştirilerek hedeflenen uygulama için uygun hale getirilmesidir.

4.3 Yapay Sinir Ağındaki Temel Yapılar

Bu bölümde yapay sinir ağlarında kullanılan 7 temel mekanizmayı inceleyeceğiz.

4.3.1 Ağırlık Faktörü

Bir yapay sinir hücresi genel olarak aynı anda birçok giriş değeri alır. Her giriş değerinin kendine ait bir ağırlık değeri vardır ve bu ağırlık değeri de o girişin toplama fonksiyonu üzerindeki etki derecesini belirler. Bu ağırlık değerleri biyolojik sinir hücrelerindeki sinaptik etkileri elde etmek için kullanılmaktadır. İki hücre tipinde de

bazı girişler diğerlerine göre ağırlık değerleri değiştirilerek daha etkin yapılmaktadır. Bunun sonucunda da o giriş değerleri sinir hücresinin hangi çıkış değerini vereceği konusunda daha etkin olmaktadır.

Ağırlık değerleri adaptif elemanlardır. Yani değerleri eğitim sürecinde değişime uğratılabilir. Ağırlık değerlerinin nasıl değiştirileceği eğitim setlerine, kullanılan eğitim algoritmasına ve ağ topolojisine göre değişiklik göstermektedir.

4.3.2 Toplama Fonksiyonu

Bir işlem elemanının çalışmasındaki ilk adım ağırlık değerleri ile çarpılarak elde edilen değerleri toplamaktır. Matematiksel olarak girişler ve o girişlere denk gelen ağırlık değerleri aşağıdaki şekilde ifade edilebilir.

$$I_1, I_2 \text{ K K } I_n \quad w_1, w_2 \text{ K K } w_n$$

Toplam giriş sinyali bu değerlerin oluşturdukları vektörlerin birbirleri ile skaler çarpımı olarak düşünülebilir. Sonuç çok elemanlı bir vektör yerine bir sayıdır.

$$S = (w_1 x_1 + w_2 x_2 + \text{K K K} + w_n x_n) = w \cdot x \quad (4.1)$$

Geometrik olarak iki vektörün skaler çarpımı iki vektörün birbirlerine benzerlikleri olarak düşünülebilir. Eğer vektörler aynı yönde iseler skaler çarpımları maksimum çıkacak, ters yönlerde dönük iselerse skaler çarpım minimum değerini alacaktır.

Toplama fonksiyonu basit bir skaler çarpımdan farklı bir fonksiyon olabilir. Transfer fonksiyonuna iletilmeden önce giriş değerleri ve de ağırlık değerleri farklı şekillerde işleme konulabilirler. Bunlar en büyük değeri alma, en küçük değeri alma vb...’dir. Bunlardan hangisinin seçileceğini kullanıcı uygulamasına göre karar verir.

Bazı toplama fonksiyonları elde ettikleri değeri transfer fonksiyonuna aktarmadan önce bir işlemden daha geçirirler. Bu işleme bazen aktivasyon işlemi adı verilir. Bu işlem toplama işleminin çıkışının zamana göre değişmesini sağlar. Aktivasyon fonksiyonları hala araştırılmaktadır. Genel olarak yapay sinir ağlarında aktivasyon fonksiyonu kullanılmaz.


4.3.3 Transfer Fonksiyonu

Toplama işlemi sonucu elde edilen değer transfer fonksiyonun giriş değeri olur. Transfer fonksiyonu birçok şekilde uygulanabilir. Mesela elde edilen toplam değer bir

eşik değeri ile karşılaştırılarak ağdan bir değer üretmesi istenebilir. Eğer toplam değeri eşik değerinden büyükse işlem elemanı bir çıkış değeri üretir. Toplam değeri eşik değerinde küçük ise işlem elemanı bir çıkış vermez veya engelleyici bir çıkış verir. İki tür çıkış da bizim için önemlidir.

Eşik fonksiyonları ve transfer fonksiyonları genel olarak nonlinear fonksiyonlar olarak seçilirler. Lineer fonksiyonlar sadece toplam değerini bir değerle çarparak dışarıya verdikleri için genelde transfer fonksiyonu olarak kullanılmazlar.

Transfer fonksiyonu toplama değerinin pozitif mi veya negatif mi olduğuna karar verecek kadar basit bir fonksiyon da olabilir. Ağ çıkışına 0 veya 1, -1 veya 1 gibi sayısal değerleri verebilir. Bu tür transfer fonksiyonlarına hard limiter adını veriyoruz. Şekil 4.5’de MATLAB’DE kullanılan hard limiter fonksiyonunun grafiği verilmiştir.




Şekil 4.5 – Hardlim transfer fonksiyonu

Hardlim fonksiyonunu -1 ve 1 değerleri ile de ifade edebiliriz. Bu değerlerin alınması özellikle Perceptron öğrenme algoritmasında ağırlık değerlerinin daha hızlı bir şekilde istenen sonuca yaklaşmasını sağlamaktadır.

Başka bir transfer fonksiyonumuzda rampa transfer fonksiyonudur. Bu transfer fonksiyonu giriş değerlerini belirli bir aralıkta aynen dışarıya verirken o aralık dışarısına çıkıldığında eşik fonksiyonu gibi davranmaktadır. Yani belirlenen aralıkta lineer bir fonksiyon gibi davranmakta, aralığın dışında ise nonlinear olarak çalışmaktadır.

Kullanılabilecek bir başka transfer fonksiyonu da sigmoid veya s şekilli fonksiyonlardır. Bu fonksiyonlar giriş uzayı negatif sonsuza ve pozitif sonsuza giderken çıkış değerlerinin minimum ve maksimum değerine doğru asimptotik şekilde yaklaşmaktadır. Bu tür eğrilere çıkış değerleri 0 ile 1 arasında olduğunda sigmoid, çıkış değerleri -1 ve 1 arasında olduğunda ise hiperbolik tanjant ismi verilmektedir. Matematiksel olarak bu


fonksiyonların bize sağladığı fayda fonksiyonun hem kendisinin hem de türevinin sürekli değerler almasıdır. Şekil 4.6 ve Şekil 4.7’de sırasıyla rampa fonksiyonu ve de hiperbolik tanjant fonksiyonları gösterilmiştir.



Rampa Fonksiyonu

$$\begin{aligned} x < 0 & \quad y = 0 \\ 0 \leq x \leq 1 & \quad y = x \\ x > 1 & \quad y = 1 \end{aligned}$$

Şekil 4.6 – Rampa transfer fonksiyonu



Tansig Fonksiyonu

$$\begin{aligned} x \geq 0 & \quad y = 1 - 1/(1+x) \\ x < 0 & \quad y = -1 + 1/(1-x) \end{aligned}$$

Şekil 4.7 – Tansig transfer fonksiyonu

Transfer fonksiyonuna aktarılmadan önce toplama sonucu elde edilen değere homojen bir şekilde dağıtılmış gürültü eklenebilir. Gürültünün şekli ve miktarı kullanılan öğrenme tekniğine göre farklılıklar gösterebilir. Eklenen bu gürültüye sıcaklık adı verilir. Sıcaklık denmesinin nedeni insanların düşünme kapasitelerinin ortamın sıcak veya soğuk olmasına göre değişmesinden kaynaklanmaktadır. Elektronik olarak bu etki işarete gürültü eklenerek sağlanır ve sonuç olarak beynin çalışmasına daha yakın bir transfer fonksiyonu elde edilir. Doğada gerçekleşen düşünme süreçlerini daha ayrıntılı

bir şekilde taklit edebilmek için araştırmacılar gauss gürültü kaynağı kullanmaktadır. Sıcaklık kavramının yapay sinir ağlarında kullanılması henüz araştırma aşamasındadır. Bu tür bir yaklaşımın ağ öğrenme süreçlerine müthiş bir hız kazandıracacağı tahmin edilmektedir.

4.3.4 Çıkış Aralığını Değiştirme ve Sınırlandırma

Transfer fonksiyonundan elde edilen çıkış değeri tekrar bir işlemde geçirilerek çıkış değerinin aralığı değiştirilebilir veya çıkış değerleri belirli bir aralıkta sınırlandırılabilir. Bu tür uygulamalar genel olarak biyolojik sinir ağı modellerinin topolojilerini test etmek için kullanılırlar.

4.3.5 Çıkış Fonksiyonu (Competition)

Her bir işlem elemanı bir adet çıkış değeri verme ve de bu değeri binlerce başka işlem elemanına gönderme kapasitesine sahiptir. Normal olarak çıkış değeri transfer fonksiyonundan elde edilen değere eşittir. Ama bazı ağ topolojileri transfer sonucu ortaya çıkan değer değiştirilmesine olanak sağlamaktadır. Değişme işlemi komşu işlem elemanlarının birbirleri ile yarışmaları sonucunda oluşmaktadır. Yarışma bir veya iki seviyede gerçekleştirilir. Önce yarışma hangi işlem elemanının aktif olacağına yani bir çıkış değeri oluşturacağına karar verir. Daha sonra giriş değerleri hangi işlem elemanının öğrenme sürecinde yer alacağına karar verir.

4.3.6 Hata Fonksiyonu ve Geri Yayılım Değeri

Çoğu ağ yapısında hata değeri o anda çıkan sonuç ile istenen değer arasındaki fark olarak hesaplanır. Bu ham hata değeri bir hata fonksiyonu kullanılarak o tip ağ için işlenebilir bir hale getirilir. Bazı ağlar hata değerini aynen kullanırken bazıları hatanın karesini veya küpünü kullanmaktadır. Bu hata fonksiyonu daha sonra öğrenme fonksiyonunun bir parçası haline getirilir. Biz bu hata değerine o anki hata adını veriyoruz.

O anki hata değeri daha geride bulunan katmanlara doğru yaydırılır. Geriye doğru yaydırılan hata değeri hatanın kendisi veya genellikle kullanıldığı şekliyle hatanın türevi olabilir. Bu kullandığımız ağın tipine göre değişmektedir. Normalde bu hata değeri öğrenme fonksiyonu ile belirli bir değer aralığına çekildikten sonra ağırlık değerlerinin değiştirilmesinde kullanılır.

4.3.7 Öğrenme Fonksiyonu

Öğrenme fonksiyonunun görevi işlem elemanları arasındaki ağırlık değerlerinin belirli bir algoritmaya uygun olarak değiştirilmesini sağlamaktır. Bu süreci sağlayan fonksiyona adaptasyon fonksiyonu veya öğrenme modu adı da verilir. Öğrenme denetimli ve denetimsiz olmak üzere iki şekilde gerçekleştirilir. Denetimli öğrenmede ağırlık önceden belirlenmiş bir eğitim setine uygun olarak çıkış vermesi sağlanmaya çalışılır. Denetimsiz öğrenmede ise ağırlık sadece giriş değerleri uygulanır ve ağırdan bu giriş değerlerine göre kendini organize etmesi beklenir.

4.4 Yapay Sinir Ağlarının Eğitilmesi

Bu bölümde eğitim ve öğrenin türleri anlatılacaktır

4.4.1 Denetimli Eğitim

Yapay sinir ağlarının çoğu denetimli öğrenme kullanılarak eğitilir. Bu tür eğitimde ağırlık o anki çıkış değeri istenen çıkış değeri ile karşılaştırılır. Genel olarak başlangıçta rasgele seçilen ağırlık değerleri bir sonraki döngüde doğru sonuca daha yakın bir sonuç verecek şekilde değiştirilir. Öğrenme algoritması eğitim setinin bütün giriş-çıkış çiftleri için hata değerini en aza indirmeye çalışır. Bu işlem hata değeri kabul edilebilir bir düzeye gelene kadar devam ettirilir.

Yapay sinir ağının kullanılabilir bir hale gelmesi için ilk önce eğitilmesi gerekmektedir. Eğitim ağı istediğimiz giriş ve çıkış değerleri verilerek sağlanır. Bu değerlere genel olarak eğitim seti adı verilir. Sisteme giriş yapılan her bir değer için bir çıkış değeri de sisteme verilir. Çoğu uygulamada gerçek değerler kullanılır. Düşük işleme gücüne sahip prototip sistemlerde eğitim süresi günler alabilir. Eğitim kullanıcı tarafından belirlenen bir kritere ulaşıldığında bitmiş kabul edilir. Bu kriter genel olarak kabul edilebilir bir hata seviyesidir. Genel olarak eğitim süreci sona erdikten sonra elde edilen ağırlık değerlerinde bir değişiklik yapılmaz. Ama bazı ağlarda eğitimin daha düşük oranlarda devam etmesi sağlanır. Böylece ağırlık değişen koşullara adapte olması amaçlanır.

Eğitim seti giriş ve çıkış değerleri arasındaki fonksiyonun karmaşıklığına göre veri içermelidir. Eğer fonksiyon karmaşık veya parçalı diye tanımlayabileceğimiz bir karaktere sahipse eğitim verisi sayısının fonksiyonun bütün davranış biçimlerini ağırlık gösterecek şekilde seçilmesi gerekir. Ama fonksiyon basit bir fonksiyon ise az sayıda eğitim verisi ile de aynı başarıyı elde etmek mümkündür. Eğer ağırlık her örnekte bir

eğitirsek ağ o kadar ayrıntılı eğitilir ki bir sonraki örnekte bir önceki örnekte öğrenilen ilişkinin unutulması gibi bir durumla karşılaşabiliriz. Bu da istenen bir durum değildir.

Eğitim verilerinin ağa nasıl tanıtıldıkları da önemli bir konudur. Yapay sinir ağları sadece nümerik bilgilerle uğraşabilirler. Bu yüzden pratikteki uygulamanın bir şekilde sayısal olarak ifade edilmesi gerekmektedir. Ayrıca genel olarak ağın eğitilmesinde kullanılan veriler belirli bir değer aralığına çekilirler veya normalize edilirler. Bu sayede eğitim işleminin daha hızlı gerçekleştirilmesi sağlanır.

Ağımız eğitim seti ile eğitildikten ve bizim belirlediğimiz bir kritere ulaştıktan sonra bir de eğitim seti içerisinde olmayan verilerle denenerek ağın giriş-çıkış değerleri arasındaki ilişkiyi hangi derecede genelleştirmiş olduğu kontrol edilmelidir. Bu adım gerçekten çok önemlidir. Çünkü bu adımla ağın aynı zamanda eğitim setini ezberleyip ezberlemediğini de kontrol etmiş oluruz.

4.4.2 Denetimsiz Eğitim

Denetimsiz eğitim aslında bu işin özünü oluşturmaktadır. Yani eğer biz insan beynini aynen yaratma gibi ütöpik bir düşünce ile yola çıktıysak oluşturduğumuz mekanizmaların biz yol göstermeden de doğruları bulabilmesi gerekmektedir. Bu alan geleceği parlak bir alan olarak görülmektedir. Şu anda bu öğrenme metodu sadece kendini organize eden haritalar ile sınırlıdır. Ama yine de bu tür algoritmalar yarar sağlayabileceklerini kanıtlamışlardır. Aerodinamik akış hesaplamalarında diğer birçok hesaplama algoritmasına göre daha verimli oldukları kanıtlanmıştır. Bu tür ağlar çok kullanılan bir ağ türü değildir.

Bu tür öğrenmeye kendi kendine öğrenme adı da verilir. Bu tür ağlar ağırlık değerlerini değiştirirken herhangi bir şekilde dış etkiye maruz kalmazlar. Bunun yerine performanslarını kendi içlerinde analiz ederler. Bu tür ağlar giriş değerlerindeki benzerliklere veya trendlere bakarlar ve de bunlara göre ağırlık değerlerinde değişiklik yaparlar. Ağa bir yönlendirme yapılmamasına rağmen ağın kendini nasıl organize edeceği bilgisine sahip olması gerekmektedir. Bu bilgi ağ oluşturulurken ağın içerisine ağın topolojisi veya öğrenme kuralı şeklinde yerleştirilir.

Denetimsiz eğitim işlem elemanı gruplarının beraber çalışması ile sağlanır. Eğer herhangi bir giriş bir işlem elemanını aktive ettiyse o işlem elemanının ait olduğu grubun da etkisi arttırılmalıdır. Aynı şekilde bir giriş değeri bir işlem elemanını etkisiz hale getiriyorsa o işlem elemanının ait olduğu grup da etkisiz hale getirilmelidir.

İşlem elemanları arasında rekabet de bir öğrenme prensibi ortaya çıkarabilir. Rekabet temelinde oluşturulan grupların çıkışları belirli bazı girişlere göre arttırılabilir. Normal olarak bu teknik kullanıldığında sadece kazanan grubun ağırlık değerleri değişime uğrayacaktır.

Bugün denetimsiz eğitim hala araştırma konusudur. Bu araştırma konusu genel olarak hükümetleri ilgilendirmektedir. Askeri alanda özellikle yararlı olacakları tahmin edilmektedir. Bir savaş sırasında genel olarak bir ağı eğitecek bilgileri önceden elde etmemiz mümkün olmaz.

4.4.3 Öğrenme Oranı

Yapay sinir ağlarının öğrenme oranları birçok kontrol edilebilir faktöre bağlıdır. Seçilecek değer avantajlar ve dezavantajlar arasında bir optimum nokta bulunarak seçilir. Daha düşük bir öğrenme oranı ağı bizim istediğimiz performansa daha yavaş ulaşmasını sağlar. Ama yüksek bir öğrenme oranı kullandığımızda da ağı bazı önemli noktaları kaçırma şansı büyür. Araştırmacılar optimum büyüklüklere ulaşmak için bu konuda hala çalışmalar yapmaktadır.

Genel olarak zaman faktörünün dışında da birçok faktör bu seçimde etkili olur. Ağı kompleksliği, büyüklüğü, mimarisi, kullanılan öğrenme kuralı veya kuralları gibi faktörler de seçim yaparken dikkate alınması gereken faktörlerdir. Bu parametrelerden herhangi birini değiştirmek eğitim süresinin gereksiz bir şekilde uzamasına neden olabilir.

Çoğu öğrenim algoritmasının kendisiyle kullanılabilecek bir eğitim oranı değer aralığı bulunmaktadır. Genel olarak bu değer pozitif ve 0 ile 1 arasında bir değerdir. Eğer öğrenme oranı 1'den büyük ise öğrenme işlemi dengesiz bir hale gelebilir ve ağı osilasyon yapabilir. Küçük değerler ağı sonuca çabuk bir şekilde varmasını engeller fakat sonuçta elde edilen değer istediğimiz sonuca en yakın değer olacaktır.

4.4.4 Öğrenme Kuralları

Günümüzde uygulamada birçok öğrenme kuralı bulunmaktadır. Bu kuralların çoğu en eski ve en çok bilinen kural olan Hebb kuralının varyasyonlarından oluşmaktadır. Yeni öğrenme kuralları ile ilgili araştırmalar devam etmekte ve her geçen gün yeni kurallar geliştirilmektedir. Bazı araştırmacılar tamamen biyolojik sinir hücresinin çalışma prensiplerini taklit etmeye yönelirken bazıları da doğanın öğrenme işlemini nasıl başardığına ait fikirlerini adapte etmekle uğraşmaktadır. İki yol için de söylenebilecek

şey sinir hücrelerinin veri işlemesi hakkında hala çok az şey bildiğimizdir. Tabi ki doğadaki öğrenme bizim oluşturduğumuz öğrenme kurallarına göre çok daha karmaşık bir yapıya sahiptir.

4.4.4.1 Perceptron Öğrenme Kuralı

Perceptron ilk olarak 1962 yılında Rosenblatt tarafından incelenmiştir. Perceptron hücresinin çıkış aşağıdaki gibi tanımlanmaktadır.

$$o_i = f(Act_i) = f\left(\sum_j w_{ij} x_j\right)$$

$Act_i \rightarrow$ i numaralı çıkış nöronun aktivasyon fonksiyonu
 $x_j \rightarrow$ j numaralı giriş nöronunun çıkış değeri
 $w_{ij} \rightarrow$ j numaralı giriş nöronu ile i numaralı çıkış nöronu arasındaki ağırlık değeri

Burada kullanılan transfer fonksiyonu genel olarak bir eşik fonksiyonu veya yarı-lineer bir fonksiyondur. Yukarıdaki çıkış değerini bir sonraki sayfadaki gibi de tanımlayabiliriz.

$$o_i = f(Act_i) = f(w_i \cdot x)$$

$$x = [x_0, x_1, x_2, \dots, x_N]^T \quad w_i = [w_{i0}, w_{i1}, \dots, w_{iN}]^T$$

Perceptron türü ağlarda genel olarak bir eşik değeri kullanılır. Bu eşik değeri nöronun tasnif edebilme yeteneğini sınırsız hale getirmektedir. Bu eşik değerini de denklemlerimize eklersek aşağıdaki denklemleri elde ederiz.

$$o_i = f(Act_i) = f\left(\sum_{j=0}^N w_{ij} x_j\right) = f\left(\sum_{j=1}^N w_{ij} x_j + \theta_i\right) \quad (4.2)$$

Basit bir perceptron transfer fonksiyonu olarak eşik fonksiyonunu veya başka bir deyişle Heavside fonksiyonunu kullanır. Nöron toplama fonksiyonundan gelen değer 0'dan büyük ise 1, 0'dan küçük ise -1 değerini verir. Bu aşağıdaki gibi ifade edilebilir.

$$\begin{aligned}
\sum_{j=1}^N w_j x_j + \theta > 0 & \quad o_i = 1 \\
\sum_{j=1}^N w_j x_j + \theta < 0 & \quad o_i = -1
\end{aligned} \tag{4.3}$$

Rosenblatt perceptron öğrenme kuralı üzerinde yaptığı çalışmalarda eğitim setinin lineer olarak ayrılabilmesi koşulu ile perceptron öğrenme kuralının sonlu sayıda ağırlık değişiminden sonra doğru sonuca varabileceğini kanıtlamıştır. Perceptron öğrenme kuralı 5 temel adımdan oluşur.

- 1) Ağırlık içerisindeki bütün ağırlık değerleri -1 ile 1 arasında rasgele değerler olarak seçilirler.
- 2) Eğitim setinden bir veri çifti seçilir.
- 3) Giriş ağırlık içerisinde işleme konularak çıkış değeri (o_i) elde edilir.
- 4) Eğer çıkış değeri (o^p), istenen değeri (t^p) değerine eşitse 2. adıma dönülür.
- 5) Eğer elde edilen çıkış ile istenen çıkış aynı değil ise aşağıdaki formül ile yeni ağırlık değeri hesaplanır. 2. adıma geri dönülür.

$$\Delta w_i = \eta x_i^p (t^p - o^p) \quad \eta \rightarrow \text{Öğrenme oranı} \tag{4.4}$$

Bu kuralla yapılan şey ağırlık uzayı vektörünü giriş vektörüne yaklaştırmaktır. Böylece aynı giriş seti tekrar girildiğinde doğru sonuç verme olasılığı arttırılmaktadır. Bu kuralın en önemli özelliği sonlu bir zaman içerisinde doğru sonuca ulaşacağını kanıtlanmış olmasıdır.

Perceptron öğrenme kuralı doğru sonuca ulaşacağı kanıtlanmış olsa da sadece lineer olarak ayrılabilir problemlerde doğru sonuç verebilirler. Mesela bir XOR kapısının yaptığı işlemi taklit edemezler. XOR kapısının çıkışları lineer olarak ayrılabilir değildir. Perceptron öğrenme kuralını kullanarak XOR kapısını öğrenmesini istediğinizde teorik olarak bu işlem sonsuza kadar sürecektir. Perceptron öğrenme kuralı yararlı bir kural da olsa maalesef pratik anlamda birçok sınırlamaya sahiptir.

4.4.4.2 Delta Öğrenme Kuralı

Diğer bir ağ türü Adaline (Adaptif Lineer Eleman)' dır. Adaline çıkış değerini aşağıdaki formülle hesaplar.

$$o = \sum_j w_j x_j + \theta \quad (4.5)$$

Bu ağ ile perceptron türü ağ arasındaki fark bu ağda eşik transfer fonksiyonunun bulunmamasıdır. Bu ağ türüne olan ilginin arkasındaki en büyük neden direnç ve anahtar elemanları kullanarak basit bir şekilde uygulanabilme olanaklarının olmasıdır. Bu ağ tipinde hatanın karesini öğrenim fonksiyonunda kullanılır. Bütün eğitim setinin üzerinden geçildikten sonra elde edilen hata karesi fonksiyonun ortalama değeri alınır.

$$E = \sum_P E^P = \frac{1}{N} \sum_{p=1}^N (t^p - o^p)^2 \quad (4.6)$$

Adaline ağıımızın mümkün olduğunca doğruya yakın sonuç verebilmesi için elde ettiğimiz hatanın karesi fonksiyonunun minimize edilmesi gerekmektedir. Hatayı en aza indirebilmek için hata fonksiyonun ağırlık değerlerine göre gradyant değerini bulabiliriz. Gradyant değerinin ters yönünde ağırlık değerlerini değiştirerek hatayı en aza indirmeye

çalışırız. Gradyant değeri pozitif ise ağırlık değerlerini negatif yönde, gradyant değeri negatif ise ağırlık değerlerini pozitif yönde değiştiririz. Ağırlıklarda yapılan değişimi aşağıdaki gibi ifade ediyoruz.

$$\Delta p w_j = -\gamma \frac{\partial E^P}{\partial w_j} \quad (4.7)$$

Bu durumda yapılan işleme minimum ortalama hata değerini (LMS) arama, delta kuralı veya Widrow-Hoff kuralı adı verilir. Aşağıda ağırlık değiştirme fonksiyonun elde edilmesi verilmiştir.

$$\frac{\partial E^p}{\partial w_j} = \frac{\partial E^p}{\partial o^p} \frac{\partial o^p}{\partial w_j}$$

$$\frac{\partial o^p}{\partial w_j} = x_j^p \longrightarrow \text{Adaline ağıının lineer çalışmasından dolayı bu ifade yazılabilir}$$

$$\frac{\partial E^p}{\partial o^p} = -(t^p - o^p) \longrightarrow \Delta p w_j = \gamma (t^p - o^p) x_j^p \quad (4.8)$$

Elde edilen ağılık değiştirme kuralından da görüldüğü gibi bu kural ile perceptron öğrenme kuralı birbirine çok benzemektedir. Ama delta öğrenme kuralı çok daha geniş bir uygulama alanına sahiptir. Bunun nedeni ise delta öğrenme kuralının hem lineer hem de nonlinear transfer fonksiyonları ile beraber çalışabilmesinden kaynaklanmaktadır. Bu öğrenme kuralı hemen hemen bütün denetimli eğitim metotlarının temelini oluşturmaktadır. Yalnız burada belirtmemiz gereken önemli bir nokta perceptron öğrenme kuralında olduğu gibi bu kural da kesin yaklaşım garantisi yoktur. Yani ağ hiçbir zaman istenen hata değerine ulaşamayabilir. Nonlinear transfer fonksiyonuna sahip hücreler için ağırlık değişim değerini veren denklemlerin elde edilmesi aşağıda verilmiştir.

$$\frac{\partial E}{\partial w_j} = \frac{\partial E}{\partial o} \frac{\partial o}{\partial act} \frac{\partial act}{\partial w_j}$$

$$\frac{\partial E}{\partial w_j} = -\sum_p \left(t^p - f \left(\sum_j w_j x_j^p \right) \right) \cdot f' \left(\sum_j w_j x_j^p \right) \cdot x_j^p$$

$$\Delta w_j = -\gamma \frac{\partial E}{\partial w_j} \longrightarrow \text{Ağılık değerlerindeki değişimin hesaplanması} \quad (4.9)$$

Elde edilen formül ile bir önceki bölümde elde edilen formül arasındaki yegâne fark f fonksiyonunun türev değerinin de ağırlık değiştirme işleminde etkili olmasıdır. Bu

terimin etkisi türev değerinin büyük olduğu noktalarda ağırlık değerlerindeki değişimin büyük, türevin küçük olduğu noktalarda ise ağırlık değişimlerinin küçük olmasıdır. Kullandığımız transfer fonksiyonlarının türevlerinin büyük olduğu noktalar genellikle fonksiyonunun giriş uzayının orta bölümlerinde yer alır.

Yukarıdaki formül toplu eğitim için yani bütün eğitim verisi ağı girildikten sonra ağırlıklarda değişim yapma yöntemi için kullanılan formüldür. Eğer ağırlıkları her eğitim çiftinden sonra değiştirmek istiyorsak hatanın ağırlıklara göre değişimi fonksiyonun başındaki toplam sembolünü kaldırıyoruz. Böylece öğrenme kuralı tekli eğitim için de uygun hale geliyor.


Bu eğitim kuralı ile beraber kullanılan transfer fonksiyonlarının sürekli bir türev değerine sahip olmaları gerekmektedir. Tipik olarak kullanılan transfer fonksiyonları sigmoid ve de hiperbolik tanjant fonksiyonlarıdır. Bu fonksiyonların en önemli özellikleri türevlerinin sürekli değer alması ve de o noktadaki türev değerinin fonksiyonun o noktada aldığı değer cinsinden ifade edilebilmesidir.

Transfer Fonksiyonu	Transfer Fonksiyonunun Türevi
$f(x) = \tanh(bx)$	$f'(a) = b(1 - f(a)f(a))$
$f(x) = \frac{1}{1 + \exp(-bx)}$	$f'(a) = bf(a)(1 - f(a))$

4.4.4.3 Geri Yayımla Öğrenme Kuralı

Görüldüğü gibi Perceptron ve Adaline ağırları uygun yerlerde kullanıldığında gerçekten faydalı olabilen öğrenme kurallarıdır. Fakat aynı zamanda bu yaklaşımlarla çözülemeyecek birçok problem de bulunmaktadır. Bunlara genelde lineer olarak ayrılması mümkün olmayan problemler olarak adlandırıyoruz. Bu problemler tek katmanlı yapay nöron yapıları ile çözülememelerine rağmen çok katmanlı nöron yapıları ile rahatlıkla çözülebilirler. 1960' larda bu kurallar ilk defa geliştirildiklerinde de çok katmanlı ağ yapılarının bu problemlere çözüm bulabileceği tahmin ediliyordu. Fakat o zaman bilinmeyen şey çok katmanlı ağların nasıl bir öğrenme kuralı çerçevesinde eğitileceğiydi. Çok katmanlı ağlar için eğitim algoritmaları birbirlerinden bağımsız olarak birçok kişi tarafından geliştirilmiştir. Ama bu ağlar için öğrenme kuralı PDP

grubu tarafından hatanın geri yayılımı adı ile popülerize edilmiştir.Şekil 2.6’de çok katmanlı bir ağ yapısı gösterilmiştir.



Şekil 4.8 – İki katmanlı ağ yapısı

Şekil 4.8’de gösterilen ağ tipi çok tabakalı bir perceptron (MLP) ağıdır. Ağ içerisinde aktivasyon önce giriş katmanından gizli katmana aktarılmakta daha sonra da bu katmandan çıkış katmanına aktarılmaktadır. Görüldüğü gibi burada tek bir ağırlık matrisi yerine iki adet ağırlık matrisinin değerlerinin değiştirilmesi gerekmektedir. Bunlar giriş katmanı ile saklı katman arasındaki ağırlık değerleri ve de saklı katmanla çıkış katmanı arasındaki ağırlık değerleridir. Saklı katmanla çıkış katmanı arasındaki ağırlık değerlerinin değişimini hesaplamayı delta öğrenme kuralını kullanarak hesaplayabiliriz. Burada asıl problem daha geride kalan ağırlık değerleri matrislerinin nasıl değişime uğratılacağı sorusudur. Bunun için bu ağırlıkların her birinin çıkış üzerindeki etkisini bilmemiz ve gerekli ağırlık değerleri üzerinde değişiklik yapmamız gerekmektedir. Geri yayılım metodunun en önemli görevi bu oranları belirlemektir. Ağımız içerisinde birden fazla katman kullanabiliriz. Ama katman sayısı arttırıldığında eğitim süresi de doğru orantılı olarak artış gösterecektir. Şu ana kadar yapılan çalışmalar ve araştırmalarda elde edilen bulgular nonlineer aktivasyon fonksiyonuna sahip gizli bir katman kullanıldığında herhangi bir sürekli fonksiyonu elde etmenin mümkün olabileceğini göstermektedir.

Şimdi de geri yayılım metodunun çalışma şeklini adım adım görelim.

- 1) Ağırlık değerlerine rasgele değerler atanır.
- 2) Bir giriş çifti seçilir ve giriş katmanına uygulanır.
- 3) Giriş değeri çıkış katmanına ulaşana kadar ağ boyunca ilerletilir.
- 4) Çıkış katmanı için δs değeri aşağıdaki formül kullanılarak hesaplanır.

$$\delta_i^p = (t_i^p - o_i^p) f'(Act_i^p)$$

5) Gizli katman için δ s değeri aşağıdaki formül kullanılarak hesaplanır.

$$\delta_i^p = \sum_{j=1}^N \delta_j^p w_{ji} \cdot f'(Act_i^p)$$

6) Bütün ağırlık değerlerini aşağıdaki formülü kullanarak değiştir.

$$\Delta p w_{ij} = \gamma \delta_i^p \cdot o_j^p$$

7) 2.adımdan 6. adımlar kadar olan adımları bütün eğitim verileri için tekrarlanır.

Geri yayılım metodu ancak toplu eğitim şeklinde kullanıldığı zaman teorik olarak doğru sonuca yaklaşım garantisi vermektedir. Yani hata fonksiyonu her bir eğitim verisi için hesaplanmakta ve bu hata değerleri toplanıp ağırlık değişiminde kullanılacak hat fonksiyonu elde edilmektedir. Ama genel olarak bu metot artımlı eğitim şeklinde kullanılmaktadır. Bu şekilde tekniğin daha hızlı bir yaklaşım gösterdiği ampirik yöntemlerle gösterilmiştir. Fakat bu durumda da kendini tekrarlayan döngülere girme olasılığı vardır. Bu yüzden artımlı eğitim kullanıldığında eğitim verilerinin ağırlık tamamen rasgele bir şekilde tanıtıldığından emin olmalıyız. Artımlı eğitimin toptan eğitime göre avantajı hafıza olarak daha az yere ihtiyaç duymasıdır.

Eğitim sürecinde dikkat edilecek başka bir noktada ağırlıklara ilk değerlerin nasıl atanacağı konusudur. Hata fonksiyonunu içerisinde birçok havuz bulunan bir düzleme benzetebiliriz. Bu havuzlardan sadece biri en düşük hatayı verecektir veya başka bir deyişle bu havuzlardan sadece bir tanesi aradığımız sonuçtur. Toptan eğitim kullandığımızda eğer ağırlık ilk ağırlık değerleri yeterince büyük ise ağırlık bu havuzlardan yanlış olanına yönelmesi mümkündür. Bu noktalar lokal minimum olarak adlandırılırlar. Bu durumlardan kaçınmak için ağırlık değerlerinin küçük bir değer aralığı içerisinde homojen bir şekilde dağıtılmış olması gerekmektedir.

Şu ana kadar anlatmış olduğumuz geri yayılım metodu maalesef istediğimiz sonuca yeterince hızlı varamamaktadır. Hızı arttırmak için öğrenme oranını arttırdığımızda ise ağırlık değerlerinde çok büyük zikzaklar meydana gelme olasılığı doğmaktadır. Ağırlık daha hızlı bir şekilde istenen sonuca ulaşmasını sağlamak için momentum denilen bir teknik kullanılır. Momentum mekanizmasının arkasındaki düşünce eğer o andaki ağırlık

değişim yönü bir önceki ağırlık değişim yönü ile aynı ise ağırlık değişimini büyük, bir önceki ağırlık değişimi ile farklı yönde ise ağırlık değişimini küçük yapmaktır. Momentum mekanizmasının sonuca daha hızlı yaklaşmayı sağlaması yanında bir de eğitim durumunu lokal minimum değerinden kurtarabilmek gibi bir avantajı da vardır.

Yapay sinir ağının eğitim verilerinde doğru sonuç vermesini istememizin yanında daha da önemlisi ağın daha önceden görmediği test verilerine de doğru yanıtları vermesi gerekmektedir. Test verilerinin doğruluğu ağın genelleştirme işlemini hangi derecede gerçekleştirebildiğinin bir göstergesidir. Test verilerindeki doğruluk ile eğitim verilerinde elde edilen doğruluk arasında bir nevi değiş tokuş mekanizması bulunmaktadır. Eğer eğitim verilerinin doğruluğu çok fazla artarsa ağ eğitim verilerini ezberlemiş olabilir ve bu da ağın uygulamada kötü performans göstereceği anlamına gelmektedir. Bu durumu ortadan kaldırmak için ya ağıdaki fazlalık olan nöronları kaldırırız ki bu nöronlar ağın gereğinden fazla serbest davranmasını sağlamaktadır ya da ağırlık değerlerinin zaman içerisinde 0'a doğru yönelmelerini sağlarız. Ağırlık değerlerinin 0'a doğru yönelmesini her ağırlık değişiminden sonra bir sonraki sayfadaki formülü kullanarak sağlayabiliriz.

$$w_{ij}^{yeni} = (1 - \epsilon)w_{ij}^{eski}$$

4.5 Eğitim Algoritmaları

Bu çalışmada örnek yaparken gradyant düşürme temelli teknikleri kullandığım için diğer öğrenme algoritmalarına değinmeyeceğim. Eğitim sırasında sadece toplu eğitim algoritmalarını kullandım Temel gradyant düşürme eğitim algoritmasından başlayarak kullanılan bütün eğitim algoritmalarını açıklayacağım. Aşağıda sırasıyla kullanılan eğitim algoritmaları verilmiştir.

- 1) Temel gradyant düşürme (' **traingd** ')
- 2) Momentumlu gradyant düşürme (' **traingdm** ')
- 3) Değişken öğrenme oranı ile gradyant düşürme (' **traingda** ')
- 4) Momentumlu ve değişken öğrenme oranlı gradyant düşürme (' **traingdx** ')
- 5)Ağırlık ve Taraf Öğrenme Kurallarıyla Batch Eğitimi(' **trainb** ')
- 6)Öğrenme Fonksiyonla Dönüşümlü Geliştirme(' **trainc** ')
- 7)Öğrenme Fonksiyonla Rasgele Kurallı Incremental Öğrenme (' **trainr** ')
- 8) Esnek geri yayılım (' **trainrp** ')
- 9) Konjuge gradyant algoritmaları
 - a) Fletcher-Reeves güncellemesi (' **traincgf** ')

- b) Polak-Ribiere güncellemesi (‘ **traincgp** ’)
- c) Powell-Beale tekrar başlamaları (‘ **traincgb** ’)
- d) Ölçeklenmiş konjuge gradyant (‘ **trainscg** ’)
- 10) Quasi-Newton Teknikleri
 - a) BFGS algoritması (‘ **trainbfg** ’)
 - b) Tek adım algoritması (‘ **trainoss** ’)
- 11) Levenberg-Marquardt algoritması (‘ **trainlm** ’)
- 12) Bayesian Düzenleme Algoritması (‘ **trainbr** ’)

4.5.1 Temel Gradyant Düşürme (traingd)

Bu algoritma temel gradyant düşürme eğitim algoritmasıdır. Ağırlık değerlerindeki değişme gradyantin (-) değeri ve de öğrenme oranının çarpılmasıyla bulunur. Bu eğitim algoritması ile ilgili 7 ayarlanabilir parametre vardır. Bunlar aşağıda işlevleri ile birlikte verilmiştir.

- a) **epochs**: Eğitim algoritmasının eğitim işlemini sonlandırmadan önce eğitim seti üzerinden kaç kere geçeceğini belirtir
 - b) **show**: Eğitim gerçek zamanlı bir grafik ile gösterilmektedir. Bu grafikte kaç epok sonra elde edilen verilerin gösterileceğini show parametresi ile kontrol ediyoruz.
 - c) **goal**: Bu parametre ile hedef hata değerini belirleyebiliriz. İşlem bu hedefe ulaştığında eğitim durur.
 - d) **time**: Bu parametre ile eğitim işleminin kaç saniye boyunca sürdürüleceğini belirtiriz.
 - e) **min_grad**: Eğitimin belirtilen bir gradyant değerinde durdurulması sağlanır.
 - f) **lr**: Öğrenme oranını ifade eder.
- Şimdi bir örnekle bu parametrelerin sisteme girilişini gösterelim.

```
net.trainParam.epochs = 5000 ;
net.trainParam.goal = 0 ;
net.trainParam.lr = 0.1 ;
```

Örnekte eğitim 5000 epok boyunca sürecek, öğrenme oranı olarak 0.1 kullanılacak ve de hedef hata olarak 0 verildiği için eğitimin 5000 epok boyunca devam etmesi sağlanacak.

4.5.2 Momentum Kullanarak Gradyant Düşürme (traingdm)

Bu eğitim algoritmasında temel gradyant düşürme algoritmasına göre iki farklı parametre bulunmaktadır. Bunlar mc ve de max_perf_inc parametreleridir.

a) **mc**: Bu değer bir önceki ağırlık değerinin bir sonraki ağırlık değişiminde ne kadar etkili olacağını belirler.

$$w_{yeni} = (mc.w_{n-1}) + [(1 - mc).w_n] \quad (4.10)$$

b) **max_perf_inc**: O andaki eğitim performansı bir önceki performans değerini bu parametre ile belirlenen oranının üstünde geçmişse o döngü için mc 0 olarak alınır.

4.5.3 Değişken Öğrenme Oranı ile Gradyant Düşürme (traingda)

Standart gradyant düşürme algoritmalarında öğrenme oranı eğitim boyunca sabit tutulur. Algoritmanın performansı öğrenme oranının doğru seçilmesiyle ilintilidir. Öğrenme oranı çok büyük seçilirse sistem osilasyon yapabilir ve dengesiz bir hale gelebilir. Öğrenme oranı çok küçük seçilirse algoritmanın istenen sonuca ulaşması uzun süre alabilir. Aslında optimum öğrenme oranını eğitimden önce belirlemek pratik bir yaklaşım değildir. Çünkü optimum öğrenme oranı eğitim süreci içerisinde değişiklik göstermektedir. Standart gradyant düşürme tekniğinin performansı öğrenme oranı değişken yapılarak arttırılabilir.

Momentum ilkesinin çalışması gibi burada bir karşılaştırma yapılır. Eğer yeni hata değeri eski hata değerini max_perf_inc (tipik olarak 1.04) değeri ile belirlenen oranının üzerinde geçerse yeni ağırlık değerleri kullanım dışı bırakılır. Buna ek olarak öğrenme oranı lr_dec (tipik olarak 0.7) parametresi ile belirlenen oranda azaltılır. Eğer yeni hata değeri eski hata değerinden düşük ise öğrenme oranı lr_inc (tipik olarak 1.05) parametresi ile belirlenen oranda arttırılır. Bu prosedür öğrenme oranının büyük hata değerlerine yol açmadan arttırılmasını sağlar. Ağ dengeli bir eğitim sürecinden geçer.

4.5.4 Momentumlu ve Değişken Öğrenme Oranlı Eğitim (traingdx)

Bu eğitim algoritmasının bir önceki algoritmadan tek farkı bir momentum katsayısının tanımlanabilmesidir. Bu algoritmayı değişken öğrenme oranlı eğitim algoritması ile momentum kullanarak gradyant düşürme algoritmasının birleştirilmesi olarak düşünebiliriz.

4.5.5 Ağırlık ve Taraf Öğrenme Kurallarıyla Batch Eğitimi(trainb)

Trainb, ağırlık ve taraf öğrenme kuralları olan bir şebekeyi batch güncellemeleriyle eğitir. Ağırlık ve taraflar girdi bilgisi boyunca tam bir geçişin sonunda güncellenir. Algoritma her bir ağırlık ve taraf, her bir epoch'tan sonra öğrenme fonksiyonuna göre güncellenir.

4.5.6 Öğrenme Fonksiyonla Dönüşümlü Geliştirme(trainc)

Ağırlık ve taraf kurallı bir şebekeyi bir girdinin her bir sunumundan sonra incremental güncellemelerle geliştirilir. Her bir epoch için her vektör şebekeye ağırlık ve taraf değerlerinin her bir sunumundan sonra güncellenmiş şekliyle sırayla sunulur.

4.5.7 Öğrenme Fonksiyonla Rasgele Kurallı Incremental Öğrenme (trainr)

Ağırlık ve taraf kurallı bir şebekeyi bir girdinin her bir sunumundan sonra incremental güncellemelerle geliştirilir. Her bir epoch için, bütün eğitici vektörler her bir sunumdan sonra şebeke, taraf ve ağırlık verileri güncellenmiş şekilde bütün vektörler her defasında değişik rasgele bir şekilde sunulur.

4.5.8 Esnek Geri Yayılım (trainrp)

Çok katmanlı ağ yapıları tipik olarak saklı katmanlarında sigmoid transfer fonksiyonlarını kullanırlar. Bu fonksiyonlara aynı zamanda sıkıştırma fonksiyonları adı da verilir. Çünkü girişlerinde sürekli aldıkları değerleri önceden belirlenmiş bir değer aralığında çıkışlarına verirler. Sigmoid fonksiyonlarının diğer bir özelliği de giriş değerleri çok büyük olduğu zaman eğrilerin eğimleri 0'a yaklaşır. Bu durum gradyant ile eğitim algoritmalarında sorun yaratmaktadır. Çünkü ağırlık değerleri optimum durumlarından çok uzak dahi olsalar fonksiyonun türev değeri çok küçük olacağından ağırlıklarda çok küçük değişimler gerçekleşecektir. Esnek geri yayılım eğitim algoritmasının amacı kullanılan sigmoid fonksiyonlarının bu dezavantajını ortadan kaldırmaktır. Bu etkiyi ortadan kaldırmak için ağırlık değiştirme denkleminde ufak bir değişiklik yapılır. Ağırlık değeri değiştirmede türev fonksiyonunun sadece işareti etkili olur. Türev değerinin büyüklüğünün ağırlık değerinin değişmesinde herhangi bir etkisi olmaz. Ağırlık değişiminin hangi büyüklükte olacağı delta0 parametresi ile belirlenir.

Eğer üst üste iki ağırlık değiştirmede türev değeri aynı işarete sahip olduysa ağırlık değiştirme oranı delt_inc parametresi ile belirlenen oranda arttırılır. Eğer üst üste iki ağırlık değişiminde türev değeri farklı işarete sahip olursa ağırlık değiştirme oranı delta_dec parametresi ile belirlenen oranda azaltılır. Deltamax parametresi ağırlık değişimi oranının alabileceği maksimum değeri belirlemede kullanılır.

4.5.9 Konjuge Gradyant Algoritmaları

Temel geri yayılım algoritmaları ağırlık değerlerini gradyantın negatif yönünde hareket ettirerek optimum sonucu bulmaya çalışırlar. Bu performans fonksiyonunun en hızlı şekilde düştüğü yöndür. Yapılan araştırmalar göstermiştir ki performans fonksiyonu gradyant yönünün negatif yönünde en düşük değeri almasına rağmen bu tür bir yaklaşımın hızlı bir şekilde optimum ağırlık değerlerine ulaşmadığı görülmüştür. Konjuge gradyant algoritmalarında konjuge yönlerde de bir arama yapılır. Bu sayede temel gradyant düşürme tekniğine göre optimum değerlere daha hızlı bir yaklaşım sağlanır.

Şu ana kadar incelediğimiz eğitim algoritmalarının çoğunda ağırlık değişiminin ne kadar olacağı bir öğrenme oranı ile belirlenmiştir. Çoğu konjuge eğitim algoritmasında adım büyüklüğü her bir karşılaştırmada değişime uğratılır. Konjuge gradyant yönünde yapılan bir arama o yönde performans fonksiyonunu minimize edebilecek adım büyüklüğünün elde edilmesini sağlar. Burada inceleyeceğimiz konjuge gradyant algoritmalarının hepsi varsayılan bir arama fonksiyonuna sahiptir. Bu arama fonksiyonları istenirse kullanıcı tarafından değiştirilebilir.

4.5.9.1 Fletcher-Reeves Güncellemesi (traincgf)

Bütün konjuge gradyant algoritmaları ilk ağırlık değişiminde gradyantın negatif değerini arayarak eğitime başlarlar.

$$p_0 = -g_0$$

Daha sonra belirlenen yönde gidilecek optimum mesafe için bir arama yapılır.

$$x_{k+1} = x_k + \alpha_k p_k$$

Daha sonra bir sonraki arama yönü bir önceki arama yönüne konjuge olacak şekilde belirlenir. Yeni arama yönünü belirlemek için kullanılan genel prosedür yeni negatif gradyant yönünün bir önceki arama yönü ile bir araya getirilmesi işleminden oluşur

$$p_k = -g_k + \beta_k p_{k-1}$$

Değişik konjuge gradyant algoritmaları arasındaki fark yukarıdaki beta değerinin farklı şekillerde hesaplanmasından kaynaklanmaktadır. Fletcher-Reeves güncelleme yöntemi için beta değeri aşağıdaki gibi hesaplanır.

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (4.11)$$

4.5.9.2 Polak-Ribiere Güncellemesi (traincgp)

Bu konjuge gradyant eğitim algoritması için beta değeri aşağıdaki gibi hesaplanır.

$$\beta_k = \frac{\Delta \mathbf{g}_{k-1}^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (4.12)$$

4.5.9.3 Powell-Beale Tekrar Başlamaları(traincgb)

Bütün konjuge gradyant algoritmalarında arama yönü periyodik olarak gradyantın negatif yönüne tekrar gelecektir. Bu olay eğitim setinin üzerinden ağdaki ağırlık ve bias değerleri sayısı kadar geçildiğinde meydana gelir. Bu işlemi farklı şekillerde hayata geçirerek eğitim işleminin verimini arttırmak mümkündür. Bunun için önerilen yöntemlerden biri Powell-Beale güncellemesidir. Bu teknikte bir önceki eğitimde kullanılan gradyant ile o andaki gradyantın aralarındaki ortogonalite test edilir. Eğer iki vektör arasındaki ortogonalite çok küçülmüşse ağ başlangıçtaki gradyantın negatifi yönüne geri döner. Bu aşağıda verilmiş olan eşitsizlikle test edilir.

$$\left| \mathbf{g}_{k-1}^T \mathbf{g}_k \right| \geq 0.2 \left\| \mathbf{g}_k \right\|^2 \quad (4.13)$$

4.5.9.4 Ölçeklenmiş Konjuge Gradyant (traincsg)

Şu ana kadar incelediğimiz bütün konjuge gradyant algoritmaları her safhada bir arama yapılmasına ihtiyaç duymaktadır. Bu arama süreci hesaplama bakımından çok fazla zaman almaktadır çünkü her arama sürecinde çizgi boyunca eğitim seti değerlerinin defalarca hesaplanması gerekmektedir. Moller tarafından geliştirilen ölçeklenmiş konjuge gradyant algoritması bu fazla hesaplamaların yükünü azaltmak için geliştirilmiştir.

4.5.10 Quasi-Newton Algoritmaları

Bu bölümde Quasi-Newton algoritmalarına değinilecektir.

4.5.10.1 BFGS Algoritması (trainbfg)

Newton metodu konjuge gradyant metotlarına alternatif olabilecek bir algoritma tekniğidir. Aşağıda Newton metodunun temel adım yapısı verilmiştir.

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (4.14)$$

Burada A_k kullanıldığı an için performans indeksinin Hessian matrisi (ikinci türevi)' dir. Ama ileri beslemeli ağlar için Hessian matrisini hesaplamak çok pahalı ve de zaman alan bir iştir. Elimizde Newton' un tekniğine dayanan fakat ikinci türevi hesaplamak zorunda olmayan teknikler bulunmaktadır. Bu tekniklere Quasi-Newton adı verilmektedir. Ağırlık değiştirme büyüklüğü yaklaşık Hessian matrisi hesaplanarak bulunur. Bu algoritma konjuge gradyant algoritmalarına göre daha fazla hafızaya ve hesaplamaya ihtiyaç duymaktadır. Ama genel olarak konjuge gradyant algoritmalarına göre daha hızlı optimum değere yaklaşabilmektedir. Yaklaşık Hessian matrisinin hafızaya alınması gerekmektedir ve bu matrisin boyutları $n^2 \times n^2$ dir. Burada n ağ içerisindeki ağırlık ve bias adetlerinin toplamıdır. Çok büyük ağlar için konjuge yöntemlerin kullanmak daha faydalı olacaktır. Ama ağ küçük boyutlarda ise bu algoritma kullanılabilir.

4.5.10.2 Tek Adım Algoritması (trainoss)

BFGS eğitim algoritması fazla hesaplama ve de fazla hafızaya ihtiyaç duyduğundan dolayı konjuge gradyant algoritmaları ile Quasi-newton algoritmaları arasında köprü görevi görecek bir eğitim algoritmasına ihtiyaç vardır. Tek adım algoritması bu açığı kapatmak için geliştirilmiştir. Bu algoritma Hessian matrisinin tamamını saklamaz. Ayrıca her bir ağırlık değişimi durumunda bir önceki Hessian matrisini birim matrisi olarak kabul eder. Bunun avantajı yeni arama yönünü matrisin tersini almaya gerek kalmadan hesaplayabilmesidir. Tek adım algoritması BFGS algoritmasına göre daha az, konjuge gradyant algoritmalarına göre ise biraz daha fazla hafızaya ihtiyaç duymaktadır.

4.5.11 Levenberg-Marquardt (trainlm)

Quasi-Newton teknikleri gibi, Levenberg-Marquardt tekniği de performans indeksinin ikinci türevine Hessian matrisini hesaplamadan ulaşmaya çalışır. Performans fonksiyonu karelerin toplamı şeklinde olduğunda ki çoğu zaman böyledir Hessian matrisi ve gradyant değeri aşağıdaki şekillerdeki gibi yaklaşık olarak hesaplanabilir.

$$H = J^T J \quad g = J^T e$$

J burada Jakoben matrisini temsil etmektedir. Jakoben matrisi içerisinde hata fonksiyonunun birinci türevini ihtiva eder ise ağ hata değerleridir. Jakoben matrisi Hessian matrisine göre çok daha kolay bir biçimde hesaplanabilir. Levenberg-Marquardt algoritması aşağıdaki yaklaşımı kullanarak hessian matrisine yakın bir değer elde etmeye çalışır.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4.15)$$

μ değeri sıfıra eşit olduğunda yukarıdaki denklem yaklaşık Hessian matrisini kullanan Newton metodunu ifade etmektedir. μ büyüdüğünde denklem küçük bir öğrenme oranı ile kullanılan gradyant düşürme algoritmasına benzeyecektir. μ her başarılı adımdan sonra değer olarak düşürülür ancak performans fonksiyonunda artış olma ihtimali belirdiğinde değeri arttırılır. Böylece performans fonksiyonunun sürekli olarak azalması sağlanır. Levenberg-Marquardt optimum sonuca en hızlı şekilde ulaşan algoritmadır.

4.5.12 Bayesian Düzenleme Algoritması (trainbr)

Levenberg-Marquardt optimizasyonuna göre ağırlık ve taraf değerlerini güncelleyen bir şebeke geliştirme fonksiyonudur. Hata ve ağırlıkların karelerinden oluşan kombinasyonu en aza indirir ve sonra iyi genelleme yapan bir şebeke üretmek için doğru kombinasyonu belirler. Bu işleme Bayesian regularizasyonu denir.


Trainbr, ağırlığı, net girdisi ve transfer fonksiyonları kopya fonksiyonlar olduğu sürece her hangi bir şebekeyi geliştirebilir. Bu Bayesian regularizasyonu, Levenberg-Marquardt algoritması içinde olur. Ağırlık ve taraf değişkenleri (x)'e oranla jakabiyen performansı hesaplamak için geri yayılım kullanır. He bir değişken Levenberg-Marquardt'a göre ayarlanır.

5 MİKRO ELEKTROMEKANİK ANAHTARLARIN YAPAY SİNİR AĞLARI İLE MODELLENMESİ

Bu bölümde değişik boyutlara sahip seri ve paralel RF-MEMS anahtarların HFSS ile analizi sonucunda elde edilen S-parametrelerinin yapay sinir ağlarını nasıl uygulandığı anlatılacaktır. Ayrıca elde edilen verilerle yapay sinir ağı kullanılarak elde edilen test ve eğitim verileri karşılaştırılacaktır.

5.1 Yapay Sinir Ağları İçin S parametrelerinin Elde edilmesi ve Uygulanması

Bu kısımda değişken boyutlara sahip seri ve paralel RF-MEMS anahtarların HFSS ile analizi sonucunda elde ettiğimiz S-parametreleri yapay sinir ağlarına uygulanmıştır. Şekil 5.1 de kullanılan ağın giriş ve çıkışları blok olarak gösterilmiştir.



Şekil 5.1 Ağın giriş ve çıkış blok diyagramı


Şekilden de görüldüğü üzere 5 girişli, 4 çıkışlı bir ağ oluşturulmuştur. Eğitim ve test için kullanılan veriler (S-parametreleri) aşağıda belirtilen kriterlere ve boyutlara göre belirlenmiştir.

- a-) ϵ_r (Bağıl dielektrik katsayısı) eğitim verisi için 5, 10 ve 15 olarak kullanılmış, test datası için ise 7.5, 12.5 ve 15 olarak ele alınmıştır.
- b-) t (dielektrik kalınlığı μm) eğitim datası için 0.1, 0.3 ve 0.5 olarak kullanılmış, test datası için ise 0.2 ve 0.4 alınarak inceleme yapılmıştır.
- c-) W (temas alanı – köprü genişliği) eğitim datası için 50, 100 ve 150 μm^2 , test datası için ise 75 ve 125 μm^2 ele alınarak inceleme yapılmıştır.
- d-) Frekans her bir boyut için 0–30 Ghz arasında 1Ghz aralıklarla incelenmiştir.

e-) Anahtarın açık konumda olduğunu belirlemek amacıyla 0.1, kapalı durumda olduğunu belirtmek amacıyla 0.9 giriş verileri kullanılarak S-parametreleri elde edilmiştir.


Bu değişimler sonucunda seri ve paralel anahtarlar için ayrı ayrı olmak üzere yapay sinir ağlarına uygulayacağımız eğitim verisi için $1620 * 5$ giriş matrisi, $1620 * 4$ çıkış matrisi elde edilmiştir. Test için kullanılmak üzere ise $960 * 5$ lik bir giriş matrisi ve $960 * 4$ 'lük bir çıkış matrisi elde edilmiştir.

Elde edilen $1620 * 5$ 'lik eğitim verisi ve $960 * 5$ 'lik test verisi tek saklı katmanlı, 25 nöronluk bir ağ yapısına saklı katmanına logsig, çıkış katmanına ise tansig transfer fonksiyonu uygulanmak üzere, 16 ayrı eğitim algoritması için uygulanarak hata oranları tespit edilmiş ve ilerleyen bölümde tablo olarak sunulmuştur.



Şekil5.2 Tek Saklı Katmanlı Yapay Sinir Ağı Modeli

Ayrıca tek saklı katman kullanılarak yapılan çözümler göz önüne alınarak trainbr, traimlm ve trainrp eğitim algoritmaları için iki saklı katmanlı 10'ar nörona sahip gizli katmanlarına logsig transfer fonksiyonu, çıkış katmanına tansig transfer fonksiyonu uygulanan bir ağ tasarlanmıştır. Bu ağ sonucunda çıkan MSE hata değerleride ilerleyen bölümde kıyaslanarak tabloda gösterilmiştir.



Şekil 5.3 İki Saklı Katmanlı Yapay Sinir Ağı Modeli

5.2 Gerçekleştirilen Eğitimleri Karşılaştırılması

Eğitim algoritması olarak hem seri hem de paralel anahtar için MLP (Multi Layer Perceptron) ağ modeline ait 16 farklı eğitim algoritması kullanılmıştır. Bu algoritmaların elde ettikleri performans değerleri verilmiştir. Eğitimler sonucunda görülmüştür ki seri RF-MEMS anahtar için Trainbr, Trainlm ve Trainrp eğitim algoritmaları diğer algoritmalarla göre çok daha düşük hata oranlarına sahip olduğu belirlenmiştir. Paralel RF-MEMS anahtarlar içinde aynı eğitim algoritmaları diğer algoritmalarla göre daha iyi sonuç vermişlerdir. Tek saklı katman uygulanmasıyla, iki saklı katman uygulanması arasında pek fazla bir fark gözükmediği belirlenmiştir.

5.2.1 Eğitimlerin Hata Performansları

Bu bölümde yapılan eğitim ve testlerle elde edilen MSE (Mean Square Error) hata değerleri verilmiştir. Tablo 5.1 a, b ve Tablo 5.2 a, b’de seri ve paralel anahtarlar için kullanılan tek saklı katmanlı ve iki saklı katmanlı ağ ile elde edilen ağ performans değerleri sunulmuştur.

Tablo 5.1a Seri RF-MEMS Anahtarın Tek Saklı Katmanlı 25 Nöronlu Ağ Yapısı için Hata Performansları

Eğitim Algoritmaları	Eğitim Hata Performansı (MSE)	Test Hata Performansı (MSE)
Trainb	0.0781	0.0790
Trainbfg	0.0021	0.0022
Trainbr	0.000079972	0.00046098
Trainc	0.1552	0.1551
Traincgb	0.0099	0.0082
Traincgf	0.0112	0.0111
Traincgp	0.0078	0.0069
Traingd	0.0123	0.0120
Traingdm	0.0291	0.0253
Traingda	0.0312	0.0296
Traingdx	0.0279	0.0252
Trainlm	0.000099919	0.00023391
Trainoss	0.0423	0.0424
Trainr	0.0450	0.0467
Trainrp	0.000019134	0.00015042
Trainscg	0.0027	0.0023

Tablo 5.1 b Paralel RF-MEMS Anahtarın Tek Saklı Katmanlı 25 Nöronlu Ağ Yapısı için Hata Performansları

Eğitim Algoritmaları	Eğitim Hata Performansı (MSE)	Test Hata Performansı (MSE)
Trainb	0.0158	0.0179
Trainbfg	0.000865	0.0056
Trainbr	0.000121	0.0053
Trainc	0.2412	0.2477
Traincgb	0.0040	0.0076
Traincgf	0.0132	0.0185
Traincgp	0.0031	0.0074
Traingd	0.0241	0.0245
Traingdm	0.0406	0.0392
Traingda	0.0436	0.0443
Traingdx	0.0264	0.0253
Trainlm	0.00009846	0.0057
Trainoss	0.0249	0.0261
Trainr	0.0709	0.0586
Trainrp	0.000237	0.0052
Trainscg	0.0083	0.0154

Tablo 5.2 a Paralel RF-MEMS Anahtarın İki Saklı Katmanlı 10 Nöronlu Ağ Yapısı için (MSE) Hata Hata Performansları

Eğitim Algoritmaları	Eğitim Hata Performansı (MSE)	Test Hata Performansı (MSE)
Trainbr	0.00015391	0.0054
Trainlm	0.00009913	0.0051
Trainrp	0.00035161	0.0055



Tablo 5.2 b Seri RF-MEMS Anahtarın İki Saklı Katmanlı 10 Nöronlu Ağ Yapısı için (MSE) Hata Hata Performansları

Eğitim Algoritmaları	Eğitim Hata Performansı (MSE)	Test Hata Performansı (MSE)
Trainbr	0.000062787	0.00026307
Trainlm	0.000098702	0.00020654
Trainrp	0.000281	0.0003082



5.2.3 YSA Eğitim ve Test Çıktıları ile HFSS çıktıların Karşılaştırılması

Bu bölümde HFSS ile elde ettiğimiz S-parametreleri ile yapay sinir ağları ile elde edilen eğitim ve test çıktıları aynı grafik üzerinde çizdirilerek karşılaştırma yapılmıştır.


YSA ile MATLAB GRAFİK ara yüzü olarak yazdığım kod ile daha önce elde ettiğimiz eğitim ve test matrisinden rasgele boyutlar alınarak 0-30 Ghz arasında S-parametreleri çizdirilmiştir. Çizdirilen grafikler tek katman, 25 nörona sahip ağ yapısı kullanılarak elde edilmiştir. Seri MEMS anahtarın kapalı ve açık durumlardaki S-parametreleri trainbr eğitim algoritması kullanılarak çizdirilmiş, paralel MEMS anahtar için ise Trainlm eğitim algoritması kullanılarak grafikler çizdirilmiştir. Eğitim sonuçları kıyaslanırken $\epsilon_r = 5$ bağlı dielektrik katsayılı, $0.1 \mu\text{m}$ kalınlı dielektrik malzeme kullanılmıştır ve temas alanı $100 \times 200 \mu\text{m}^2$ olarak belirlenmiştir. Test sonuçlarını kıyaslanırken ise $\epsilon_r = 15$ bağlı dielektrik katsayılı, $0.4 \mu\text{m}$ kalınlı dielektrik malzeme kullanılmıştır ve temas alanı $75 \times 200 \mu\text{m}^2$ olarak belirlenmiştir. Ekte belirtilen Matlab ara yüz kodu ile istenilen boyutlardaki veriler parametre olarak girilerek grafikler çizdirilebilmektedir.





Şekil 5.4 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması




Şekil 5.5 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması




Şekil 5.6 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması





Şekil 5.7 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması





Şekil 5.8 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S₁₁ parametrelerinin karşılaştırılması




Şekil 5.9 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması




Şekil 5.10 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması




Şekil 5.11 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) eğitim seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması





Şekil 5.12 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması




Şekil 5.13 Seri Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması




Şekil 5.14 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S₁₁ parametrelerinin karşılaştırılması




Şekil 5.15 Seri Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainbr) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması




Şekil 5.16 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması



Şekil 5.17 Paralel Anahtarın açık konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması



Şekil 5.18 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{11} parametrelerinin karşılaştırılması



Şekil 5.19 Paralel Anahtarın kapalı konumdaki HFSS ve Ağ ile elde edilen (Trainlm) test seti çıkış değerleri S_{12} parametrelerinin karşılaştırılması

6. SONUÇLAR

Mikrodalga devrelerinin kontrolünde RF MEMS anahtarların karakteristikleri üretim aşamaları, farklı konfigürasyonları ve uygulamaları incelendi. Diğer anahtarlama teknolojileriyle karşılaştırmalı olarak avantajları ele alındı. Elde edilen sonuçlara göre RF MEMS anahtarların diğer anahtarlama teknolojilerine göre daha yüksek performans, daha hızlı anahtarlama imkânı, daha düşük güç tüketimi sağladığı gözlemlendi. RF MEMS anahtarların üretim verimliliğini arttırmak, eklenme kaybını azaltmak ve çeşitli uygulama gereksinimlerinde izolasyon performansını geliştirmek için geniş bir inceleme yapıldı. MEMS anahtarların ve uygulamalardaki devrelerin HFSS programındaki simülasyonlarıyla S-parametreleri elde edildi ve daha önce yapılmış araştırmalardaki ölçüm değerleriyle karşılaştırıldı. Bu elde edilen sonuçlar anahtarın güç kaybı, izolasyon değeri gibi parametreleri hakkında bilgi vermiştir. Başarılı bir şekilde üretilmiş RF MEMS anahtarlar; düşük maliyetli üretim, yüksek performanslı SPDT anahtarları, analog ve dijital faz kaydırıcıları, ayarlanabilir filtrelerin elde edilmesi amacı ile kullanılabilir. Fakat bu teknolojinin ticari amaçla kullanılabilmesi için geliştirilmesi ve incelenmesi gereken birçok sorun vardır.

Yapay sinir ağları sadece içerisinde ne olduğunu bildiğimiz sistemler için değil aynı zamanda içerisinde ne olduğunu bilmediğimiz sistemler için de kullanılabilirler. Yani bu tezde olduğu gibi kutu içindeki sistemin parametrik formüllerini bilmemiz gerekmemektedir. Giriş ve çıkış değerlerine sahip olduğumuz herhangi bir sistemin de içerisine bakmadan davranışlarını yapay sinir ağı kullanarak taklit etmemiz mümkündür. Tabi eğer sistemin içerisinde ne olduğunu bilmiyorsak sistem için oluşturulacak ideal yapay sinir ağı modelinin oluşturulması, içerisinde ne olduğunu bildiğimiz sistemlere göre daha uzun olacaktır. Çünkü değişik modellerin denenmesi gerekmektedir. Ama yine de ağı içerisindeki katman ve nöron sayıları değiştirilerek ideal yapı bulunabilir. Çalışmamızda da yukarıda belirttiğimiz hususları destekleyecek şekilde sonuçlar elde ettik ve sonuçları tablo ve grafik olarak sunduk. Grafikler ve tablolar incelendiğinde mikro elektromekanik anahtarların analizi sonucu elde edilen S-parametrelerinin yapay sinir ağlarında değişik boyutlar için elde edilebileceği kanıtlanmıştır.

KAYNAKLAR

- [1] Varadan V., Viney K.J., Jose K.A., (2005), "RF-MEMS and Their Applications", John Wiley&Sons
- [2] Chang Won Jung, (2005), "Multi-Functional Reconfigurable Antenna Using RF-MEMS Switches For Communication Systems" Ph.D.. dissertation, University of California.Irvine.
- [3] C. H. Chang, J. Y. Quian, B. A. Cetiner, F. De Flaviis, M. Bachman, and G.P. Li, ,(2003) "Low Cost RF MEMS Switches Fabricated on Microwave Laminate Printed Circuit Boards," Electronic Device Letters.
- [4] F. De Flaviis , (2003), "Microwave laminated substrate compatible RF MEMS technology for communication systems". Presented at IEEE MTT-17 (LAC), Los Angeles, CA.
- [5] Bedri A. Cetiner, Alfred Grau, H. Jafarkhani, Franco De Flaviis, (2003) , "Multidisciplinary adaptive wireless communication system: Reconfigurable MEMS integrated antennas & Coding/Decoding Structures". IEEE Topical conference on wireless communication technology, Honolulu Hawaii.
- [6] Polymide planarization for RF-MEMS switch on PCB. Presented at URSI International conference 2004, Boulder Colorado.
- [7] RF-MEMS capacitive series switches of CPW & MSL configuration for reconfigurable antenna application. Presented at IEEE Antenna and propagation symposium, Washington DC, 2005.
- [8] Y. Liu, T.R. Taylor, J. Speck, R.A. York, "High-Isolation BST-MEMS switches," presented at 2002 IEEE MTT-S International Microwave Symposium, June 2002, Seattle, WA., pp. 227-230.
- [9] Y. Liu, (2002)" MEMS and BST Technologies for Microwave Applications" A dissertation submitted in partial satisfaction of the requirements for the degree of Doctor of Philosophy in Electrical and Computer Engineering".
- [10] Santos, H. J. De L. , (2002), RF MEMS Circuit Design for Wireless Communications, Artech House Press, Boston, London.
- [11] Maluf, N., (2000), An Introduction to Microelectromechanical Engineering, Artech House Press, Boston, London.
- [12] Kaplan, H., Dölen, M., (2003), Mikro-Elektro-Mekanik-Sistemler(MEMS): Üretim Teknikleri, 11. ULUSAL MAKİNA TEORİSİ SEMPOZYUMU, Gazi Üniversitesi, Mühendislik-Mimarlık Fakültesi

- [13] Emre Erdil, Özlem Aydın Civi, (2004), “RF MEMS teknolojisi ile rezonans frekansı ayarlanabilir mekroşerit yama anten”, National URSI Symposium Turkey,pp.351-353.
- [14] LEHR, M., (1990), "30 Years of Adaptive Neural Networks : Perceptron, Madaline and Backpropagation" , Proceedings of the IEEE , Cilt 78, No 9, pp 1415-1442
- [15] FYFE, C., (1996) , Artificial Neural Networks , Academic Press , Paisley
- [16] "Engineering Using MATLAB 7.0" , MathWorks Inc.
- [17] Lippmann, Richard P.,(1987),"An Introduction to Computing with Neural Nets",IEEE ASSP Magazine
- [18] Minai,A.A.,Williams,R.D.,(1990),"Acceleration of Back Propagation through Learning Rate and Momentum Adaptation,International Joint Conference on Neural Networks,Cilt 1
- [19] Reece,P.,(1987),"Perceptrona and Neural Nets , AI Expert, Cilt 2
- [20] Jacobs,R.A.,(1988),"Increased Rates of ConvergenceThrough Learning Rate Adaptation", Neural Networks ,Cilt 1
- [21] Neff,H.B.,(1991),"Introductory to Electromagnetics", John Wiley and Sons Inc.,Cilt2

EKLER

Ek 1 Seri Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı

Ek 2 Seri Anahtar için Trainbr eğitim algoritması ile yapılan eğitimin ardından çıkan hata değerleri

Ek 3 Paralel Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı

Ek 4 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan eğitimin ardından çıkan hata değerleri

Ek 5 Seri Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı

Ek 6 Seri Anahtar için Trainbr eğitim algoritması ile yapılan testin ardından çıkan hata değerleri

Ek 7 Paralel Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı

Ek 8 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan testin ardından çıkan hata değerleri

Ek 9 MEMS - YSA Matlab Kodu

Ek 10 MEMS-YSA Grafik Ara yüzü Matlab Kodu

EK 1 Seri Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	5	0.1	100	0.996307	-0.06841	0.004138	0.051722
0.1	2	5	0.1	100	0.985251	-0.136073	0.016512	0.102431
0.1	3	5	0.1	100	0.966903	-0.202231	0.03699	0.151108
0.1	4	5	0.1	100	0.94139	-0.26611	0.065347	0.196723
0.1	5	5	0.1	100	0.908911	-0.326915	0.101246	0.238236
0.1	6	5	0.1	100	0.869749	-0.383833	0.144219	0.274607
0.1	7	5	0.1	100	0.824296	-0.436038	0.19365	0.304807
0.1	8	5	0.1	100	0.773065	-0.482709	0.248756	0.327845
0.1	9	5	0.1	100	0.716715	-0.523057	0.308575	0.342803
0.1	10	5	0.1	100	0.656051	-0.556353	0.371957	0.348879
0.1	11	5	0.1	100	0.592035	-0.581972	0.437581	0.345436
0.1	12	5	0.1	100	0.525765	-0.599434	0.503974	0.332055
0.1	13	5	0.1	100	0.458452	-0.608448	0.569555	0.308578
0.1	14	5	0.1	100	0.391382	-0.608943	0.632696	0.275145
0.1	15	5	0.1	100	0.325855	-0.601097	0.691793	0.232214
0.1	16	5	0.1	100	0.263131	-0.585341	0.745344	0.180556
0.1	17	5	0.1	100	0.204362	-0.562346	0.792028	0.121223
0.1	18	5	0.1	100	0.150535	-0.532993	0.830769	0.055503
0.1	19	5	0.1	100	0.102425	-0.498326	0.860785	-0.015157
0.1	20	5	0.1	100	0.060567	-0.459487	0.881614	-0.089224
0.1	21	5	0.1	100	0.025247	-0.417658	0.89311	-0.165165
0.1	22	5	0.1	100	-0.003491	-0.373998	0.895422	-0.241521
0.1	23	5	0.1	100	-0.02582	-0.329589	0.888954	-0.316964
0.1	24	5	0.1	100	-0.042091	-0.285396	0.874305	-0.390344
0.1	25	5	0.1	100	-0.052792	-0.242244	0.85222	-0.460709
0.1	26	5	0.1	100	-0.058506	-0.200797	0.823526	-0.527317
0.1	27	5	0.1	100	-0.059866	-0.161569	0.789086	-0.589623
0.1	28	5	0.1	100	-0.057525	-0.12492	0.749755	-0.647266
0.1	29	5	0.1	100	-0.052123	-0.09108	0.70635	-0.700041
0.1	30	5	0.1	100	-0.04427	-0.060164	0.659625	-0.747874
0.9	1	5	0.1	100	0.019831	-0.147774	0.981498	0.120127
0.9	2	5	0.1	100	0.000294	-0.043228	0.998987	-0.012503
0.9	3	5	0.1	100	-0.000075	0.006784	0.99589	-0.090318
0.9	4	5	0.1	100	0.003697	0.042162	0.987285	-0.15322
0.9	5	5	0.1	100	0.009646	0.071235	0.975168	-0.209477
0.9	6	5	0.1	100	0.017228	0.096742	0.960117	-0.261762
0.9	7	5	0.1	100	0.026197	0.119807	0.942421	-0.311132
0.9	8	5	0.1	100	0.036389	0.14095	0.922285	-0.358048
0.9	9	5	0.1	100	0.047671	0.160431	0.899895	-0.402714
0.9	10	5	0.1	100	0.059915	0.178384	0.875427	-0.445215
0.9	11	5	0.1	100	0.073	0.194883	0.849057	-0.485586
0.9	12	5	0.1	100	0.086803	0.209973	0.82096	-0.523833
0.9	13	5	0.1	100	0.101205	0.223684	0.791308	-0.559959
0.9	14	5	0.1	100	0.116088	0.236043	0.760271	-0.593966

0.9	15	5	0.1	100	0.131339	0.247075	0.728011	-0.625862
0.9	16	5	0.1	100	0.146848	0.25681	0.694685	-0.655665
0.9	17	5	0.1	100	0.162511	0.265283	0.660441	-0.683398
0.9	18	5	0.1	100	0.178231	0.272533	0.625416	-0.709094
0.9	19	5	0.1	100	0.193914	0.278604	0.589738	-0.732794
0.9	20	5	0.1	100	0.209478	0.283543	0.553524	-0.754542
0.9	21	5	0.1	100	0.224844	0.287403	0.51688	-0.77439
0.9	22	5	0.1	100	0.239942	0.290238	0.4799	-0.792393
0.9	23	5	0.1	100	0.254709	0.292106	0.442667	-0.808606
0.9	24	5	0.1	100	0.269088	0.293068	0.405256	-0.823086
0.9	25	5	0.1	100	0.283031	0.293182	0.367728	-0.835891
0.9	26	5	0.1	100	0.296493	0.292512	0.330139	-0.847075
0.9	27	5	0.1	100	0.309438	0.291117	0.292533	-0.856693
0.9	28	5	0.1	100	0.321834	0.289061	0.254948	-0.864794
0.9	29	5	0.1	100	0.333655	0.286403	0.217415	-0.871423
0.9	30	5	0.1	100	0.344879	0.283204	0.179958	-0.876623
0.1	1	10	0.3	50	0.996392	-0.067628	0.004067	0.051116
0.1	2	10	0.3	50	0.98559	-0.134534	0.016226	0.101245
0.1	3	10	0.3	50	0.96766	-0.199989	0.036353	0.149392
0.1	4	10	0.3	50	0.942722	-0.263244	0.06423	0.194554
0.1	5	10	0.3	50	0.910965	-0.323534	0.099532	0.235717
0.1	6	10	0.3	50	0.872655	-0.380071	0.141811	0.271863
0.1	7	10	0.3	50	0.828162	-0.432055	0.190474	0.301987
0.1	8	10	0.3	50	0.777974	-0.478691	0.244765	0.325116
0.1	9	10	0.3	50	0.722716	-0.519208	0.303758	0.340348
0.1	10	10	0.3	50	0.663155	-0.552892	0.366343	0.346886
0.1	11	10	0.3	50	0.600207	-0.579124	0.43124	0.344091
0.1	12	10	0.3	50	0.534925	-0.597422	0.49702	0.331532
0.1	13	10	0.3	50	0.468473	-0.607478	0.562145	0.309024
0.1	14	10	0.3	50	0.402093	-0.609197	0.625022	0.276674
0.1	15	10	0.3	50	0.337047	-0.602719	0.684072	0.234893
0.1	16	10	0.3	50	0.274568	-0.588428	0.737808	0.184401
0.1	17	10	0.3	50	0.215792	-0.566946	0.784908	0.126196
0.1	18	10	0.3	50	0.161704	-0.539099	0.824281	0.061512
0.1	19	10	0.3	50	0.11309	-0.505879	0.855119	-0.008249
0.1	20	10	0.3	50	0.070508	-0.468384	0.876919	-0.081592
0.1	21	10	0.3	50	0.034276	-0.427759	0.889492	-0.157009
0.1	22	10	0.3	50	0.004475	-0.385135	0.892938	-0.23305
0.1	23	10	0.3	50	-0.019028	-0.341581	0.887613	-0.308389
0.1	24	10	0.3	50	-0.036543	-0.298055	0.874075	-0.381863
0.1	25	10	0.3	50	-0.048523	-0.255385	0.853033	-0.452503
0.1	26	10	0.3	50	-0.055519	-0.214248	0.825285	-0.519539
0.1	27	10	0.3	50	-0.05814	-0.175169	0.791674	-0.582399
0.1	28	10	0.3	50	-0.057017	-0.138529	0.753042	-0.640693
0.1	29	10	0.3	50	-0.052778	-0.104576	0.710199	-0.694187
0.1	30	10	0.3	50	-0.046022	-0.073444	0.6639	-0.742782
0.9	1	10	0.3	50	0.183119	-0.394727	0.821302	0.368945

0.9	2	10	0.3	50	0.035512	-0.201887	0.967705	0.14672
0.9	3	10	0.3	50	0.005414	-0.103214	0.994455	0.019425
0.9	4	10	0.3	50	-0.001632	-0.040498	0.996622	-0.071428
0.9	5	10	0.3	50	-0.000632	0.005907	0.989336	-0.145532
0.9	6	10	0.3	50	0.0044	0.043405	0.976672	-0.21026
0.9	7	10	0.3	50	0.011987	0.075293	0.960157	-0.268862
0.9	8	10	0.3	50	0.021441	0.103227	0.940529	-0.32294
0.9	9	10	0.3	50	0.032372	0.128113	0.918232	-0.373349
0.9	10	10	0.3	50	0.044514	0.15048	0.893585	-0.420572
0.9	11	10	0.3	50	0.057664	0.170656	0.866847	-0.464894
0.9	12	10	0.3	50	0.07165	0.188855	0.838249	-0.506497
0.9	13	10	0.3	50	0.086316	0.205227	0.807997	-0.545502
0.9	14	10	0.3	50	0.101522	0.219885	0.776288	-0.581998
0.9	15	10	0.3	50	0.117137	0.23292	0.743303	-0.616058
0.9	16	10	0.3	50	0.133038	0.244411	0.709215	-0.647748
0.9	17	10	0.3	50	0.149111	0.254431	0.674183	-0.677133
0.9	18	10	0.3	50	0.165249	0.263049	0.638353	-0.704275
0.9	19	10	0.3	50	0.181355	0.270335	0.601862	-0.729241
0.9	20	10	0.3	50	0.197339	0.276358	0.564831	-0.752097
0.9	21	10	0.3	50	0.213119	0.281187	0.527372	-0.772912
0.9	22	10	0.3	50	0.228622	0.284893	0.489583	-0.791755
0.9	23	10	0.3	50	0.243783	0.287546	0.451549	-0.808697
0.9	24	10	0.3	50	0.258544	0.289217	0.413347	-0.823804
0.9	25	10	0.3	50	0.272854	0.289976	0.375041	-0.837143
0.9	26	10	0.3	50	0.286668	0.289895	0.336686	-0.848778
0.9	27	10	0.3	50	0.29995	0.289042	0.298328	-0.858769
0.9	28	10	0.3	50	0.312669	0.287486	0.260006	-0.867172
0.9	29	10	0.3	50	0.324797	0.285295	0.221749	-0.874037
0.9	30	10	0.3	50	0.336316	0.282534	0.183583	-0.87941

EK 2 Seri Anahtar için Trainbr eğitim algoritması ile yapılan eğitimin ardından çıkan hata değerleri

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	5	0.1	100	-7.64E-03	0.011782	0.012931	-0.011357
0.1	2	5	0.1	100	-7.35E-03	0.009493	0.009708	-0.003504
0.1	3	5	0.1	100	-5.84E-03	0.006531	0.007159	0.002562
0.1	4	5	0.1	100	-3.96E-03	0.00322	0.005766	0.006707
0.1	5	5	0.1	100	-2.03E-03	0.000625	0.004414	0.006964
0.1	6	5	0.1	100	-3.89E-04	-0.001097	0.002651	0.003993
0.1	7	5	0.1	100	2.84E-04	-0.002292	0.00088	0.000273
0.1	8	5	0.1	100	-7.05E-04	-0.002891	-0.00033	-0.002645
0.1	9	5	0.1	100	-3.43E-03	-0.002653	-0.00103	-0.004233
0.1	10	5	0.1	100	-7.01E-03	-0.001577	-0.00175	-0.004479
0.1	11	5	0.1	100	-1.00E-02	4.2E-05	-0.00249	-0.003696
0.1	12	5	0.1	100	-1.12E-02	0.001744	-0.00254	-0.002395
0.1	13	5	0.1	100	-1.03E-02	0.003058	-0.00118	-0.001208
0.1	14	5	0.1	100	-7.65E-03	0.003663	0.001424	-0.000805
0.1	15	5	0.1	100	-4.48E-03	0.003467	0.004217	-0.001714
0.1	16	5	0.1	100	-1.86E-03	0.002621	0.005816	-0.004116
0.1	17	5	0.1	100	-6.02E-04	0.001406	0.005262	-0.007663
0.1	18	5	0.1	100	-8.75E-04	0.000173	0.002561	-0.011464
0.1	19	5	0.1	100	-2.30E-03	-0.000814	-0.0014	-0.014304
0.1	20	5	0.1	100	-4.10E-03	-0.001473	-0.00531	-0.015176
0.1	21	5	0.1	100	-5.47E-03	-0.001852	-0.00797	-0.013745
0.1	22	5	0.1	100	-5.78E-03	-0.002092	-0.00869	-0.010599
0.1	23	5	0.1	100	-4.80E-03	-0.002321	-0.00747	-0.006976
0.1	24	5	0.1	100	-2.69E-03	-0.002594	-0.00491	-0.004216
0.1	25	5	0.1	100	9.50E-05	-0.002906	-0.00201	-0.003081
0.1	26	5	0.1	100	2.97E-03	-0.003233	0.000154	-0.003443
0.1	27	5	0.1	100	5.33E-03	-0.003581	0.000804	-0.004327
0.1	28	5	0.1	100	6.66E-03	-0.004	-0.00025	-0.004344
0.1	29	5	0.1	100	6.60E-03	-0.004638	-0.00244	-0.002349
0.1	30	5	0.1	100	4.94E-03	-0.005621	-0.0045	0.002294
0.9	1	5	0.1	100	1.92E-02	-0.025646	-0.02702	0.019303
0.9	2	5	0.1	100	5.94E-03	-0.008564	-0.01337	0.0038468
0.9	3	5	0.1	100	-2.88E-04	0.005547	-0.0081	-0.009435
0.9	4	5	0.1	100	3.72E-04	0.004286	-0.00385	-0.00688
0.9	5	5	0.1	100	3.67E-03	-0.000321	-9.8E-05	0.000287
0.9	6	5	0.1	100	4.94E-03	-0.004225	0.003093	0.006772
0.9	7	5	0.1	100	3.88E-03	-0.005917	0.005719	0.009262
0.9	8	5	0.1	100	2.01E-03	-0.0058	0.007685	0.008498
0.9	9	5	0.1	100	6.40E-04	-0.004781	0.008635	0.006484
0.9	10	5	0.1	100	1.80E-04	-0.003444	0.008323	0.004365
0.9	11	5	0.1	100	4.02E-04	-0.002073	0.006873	0.002596
0.9	12	5	0.1	100	8.65E-04	-0.000833	0.00476	0.001253
0.9	13	5	0.1	100	1.21E-03	0.000216	0.002592	0.000329

0.9	14	5	0.1	100	1.24E-03	0.001047	0.000909	-0.000264
0.9	15	5	0.1	100	9.31E-04	0.001675	-1.1E-05	-0.000588
0.9	16	5	0.1	100	3.42E-04	0.0021	-0.00011	-0.000705
0.9	17	5	0.1	100	-4.11E-04	0.002357	0.000469	-0.000662
0.9	18	5	0.1	100	-1.23E-03	0.002467	0.001454	-0.000486
0.9	19	5	0.1	100	-1.98E-03	0.002456	0.002552	-0.000206
0.9	20	5	0.1	100	-2.63E-03	0.002347	0.003496	0.000152
0.9	21	5	0.1	100	-3.11E-03	0.002167	0.00408	0.00059
0.9	22	5	0.1	100	-3.43E-03	0.001952	0.00421	0.001063
0.9	23	5	0.1	100	-3.58E-03	0.001704	0.003883	0.001536
0.9	24	5	0.1	100	-3.60E-03	0.001482	0.003214	0.001966
0.9	25	5	0.1	100	-3.52E-03	0.001288	0.002392	0.002301
0.9	26	5	0.1	100	-3.38E-03	0.001168	0.001671	0.002465
0.9	27	5	0.1	100	-3.23E-03	0.001143	0.001327	0.002393
0.9	28	5	0.1	100	-3.08E-03	0.001229	0.001652	0.002004
0.9	29	5	0.1	100	-2.98E-03	0.001457	0.002945	0.001233
0.9	30	5	0.1	100	-2.91E-03	0.001846	0.005452	-7E-06
0.1	1	10	0.3	50	-5.12E-03	0.00176	-0.00055	-0.009593
0.1	2	10	0.3	50	-3.86E-03	-0.000126	-0.00327	-0.000465
0.1	3	10	0.3	50	-1.21E-03	0.000299	-0.00751	0.003038
0.1	4	10	0.3	50	2.00E-03	0.001634	-0.00862	0.003386
0.1	5	10	0.3	50	5.38E-03	0.002564	-0.00705	0.002803
0.1	6	10	0.3	50	8.49E-03	0.003231	-0.00408	0.000497
0.1	7	10	0.3	50	1.05E-02	0.003805	-0.00093	-0.003357
0.1	8	10	0.3	50	1.06E-02	0.004001	0.000885	-0.006696
0.1	9	10	0.3	50	8.53E-03	0.003868	0.000192	-0.008228
0.1	10	10	0.3	50	5.04E-03	0.003682	-0.00286	-0.007816
0.1	11	10	0.3	50	1.39E-03	0.003594	-0.00672	-0.005901
0.1	12	10	0.3	50	-1.23E-03	0.003502	-0.00952	-0.003212
0.1	13	10	0.3	50	-2.15E-03	0.003208	-0.01014	-0.000554
0.1	14	10	0.3	50	-1.48E-03	0.002477	-0.00856	0.001286
0.1	15	10	0.3	50	4.30E-05	0.001239	-0.00575	0.001617
0.1	16	10	0.3	50	1.43E-03	-0.000382	-0.00305	2.9E-05
0.1	17	10	0.3	50	1.83E-03	-0.002084	-0.00161	-0.003366
0.1	18	10	0.3	50	8.36E-04	-0.003511	-0.00186	-0.007807
0.1	19	10	0.3	50	-1.39E-03	-0.004371	-0.00333	-0.012045
0.1	20	10	0.3	50	-4.17E-03	-0.004546	-0.005	-0.014728
0.1	21	10	0.3	50	-6.66E-03	-0.004141	-0.00574	-0.014961
0.1	22	10	0.3	50	-8.08E-03	-0.003405	-0.00479	-0.01273
0.1	23	10	0.3	50	-7.99E-03	-0.002659	-0.00198	-0.008861
0.1	24	10	0.3	50	-6.38E-03	-0.002145	0.002185	-0.004657
0.1	25	10	0.3	50	-3.61E-03	-0.001985	0.006757	-0.001247
0.1	26	10	0.3	50	-2.58E-04	-0.002222	0.010565	0.000919
0.1	27	10	0.3	50	2.98E-03	-0.002831	0.012636	0.002229
0.1	28	10	0.3	50	5.47E-03	-0.003791	0.012538	0.003663
0.1	29	10	0.3	50	6.71E-03	-0.005114	0.010641	0.006287
0.1	30	10	0.3	50	6.38E-03	-0.006797	0.00809	0.010862

0.9	1	10	0.3	50	2.42E-03	0.005477	-0.00967	-0.006485
0.9	2	10	0.3	50	2.72E-02	-0.036373	-0.00381	0.03553
0.9	3	10	0.3	50	2.30E-02	-0.014916	-0.00972	0.012394
0.9	4	10	0.3	50	1.48E-02	-0.008268	-0.01165	0.003681
0.9	5	10	0.3	50	1.09E-02	-0.007787	-0.00947	0.002102
0.9	6	10	0.3	50	7.95E-03	-0.007577	-0.00519	0.00268
0.9	7	10	0.3	50	3.94E-03	-0.006841	-7.7E-05	0.003952
0.9	8	10	0.3	50	-4.20E-05	-0.00495	0.004851	0.00342
0.9	9	10	0.3	50	-2.79E-03	-0.002323	0.008748	0.001209
0.9	10	10	0.3	50	-4.03E-03	0.00012	0.011125	-0.001168
0.9	11	10	0.3	50	-4.12E-03	0.001874	0.011943	-0.002976
0.9	12	10	0.3	50	-3.55E-03	0.002835	0.011531	-0.004083
0.9	13	10	0.3	50	-2.78E-03	0.003073	0.010393	-0.004578
0.9	14	10	0.3	50	-2.05E-03	0.002725	0.008982	-0.004622
0.9	15	10	0.3	50	-1.52E-03	0.00195	0.007617	-0.004372
0.9	16	10	0.3	50	-1.19E-03	0.000939	0.006415	-0.003962
0.9	17	10	0.3	50	-1.03E-03	-0.000181	0.005387	-0.003477
0.9	18	10	0.3	50	-1.02E-03	-0.001269	0.004407	-0.002985
0.9	19	10	0.3	50	-1.07E-03	-0.002225	0.003338	-0.002509
0.9	20	10	0.3	50	-1.20E-03	-0.002968	0.002069	-0.002073
0.9	21	10	0.3	50	-1.36E-03	-0.003447	0.000558	-0.001678
0.9	22	10	0.3	50	-1.56E-03	-0.003593	-0.00116	-0.001355
0.9	23	10	0.3	50	-1.84E-03	-0.003396	-0.00295	-0.001103
0.9	24	10	0.3	50	-2.22E-03	-0.002817	-0.00461	-0.000976
0.9	25	10	0.3	50	-2.72E-03	-0.001866	-0.00586	-0.000997
0.9	26	10	0.3	50	-3.39E-03	-0.000535	-0.00641	-0.001242
0.9	27	10	0.3	50	-4.22E-03	0.001118	-0.00597	-0.001741
0.9	28	10	0.3	50	-5.22E-03	0.003044	-0.00431	-0.002568
0.9	29	10	0.3	50	-6.37E-03	0.005155	-0.00125	-0.003773
0.9	30	10	0.3	50	-7.63E-03	0.007316	0.003277	-0.0054

EK 3 Paralel Anahtar için yapay sinir ağlarına uygulanan eğitim verilerinin bir kısmı

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	5	0.1	100	0.000039	0.000568	0.999407	-0.034417
0.1	2	5	0.1	100	0.000154	0.001102	0.99763	-0.068802
0.1	3	5	0.1	100	0.000338	0.001568	0.994667	-0.103123
0.1	4	5	0.1	100	0.000582	0.001933	0.990521	-0.137349
0.1	5	5	0.1	100	0.00087	0.002165	0.98519	-0.171449
0.1	6	5	0.1	100	0.001183	0.002233	0.978677	-0.205389
0.1	7	5	0.1	100	0.0015	0.002108	0.970982	-0.23914
0.1	8	5	0.1	100	0.001792	0.001763	0.962105	-0.272668
0.1	9	5	0.1	100	0.00203	0.001174	0.952047	-0.305943
0.1	10	5	0.1	100	0.00218	0.000319	0.940808	-0.338932
0.1	11	5	0.1	100	0.002204	-0.000821	0.928389	-0.371603
0.1	12	5	0.1	100	0.00206	-0.00226	0.914787	-0.403924
0.1	13	5	0.1	100	0.001705	-0.004011	0.900004	-0.435861
0.1	14	5	0.1	100	0.001091	-0.006081	0.884035	-0.46738
0.1	15	5	0.1	100	0.000169	-0.008471	0.86688	-0.498445
0.1	16	5	0.1	100	-0.001113	-0.011181	0.848534	-0.529021
0.1	17	5	0.1	100	-0.00281	-0.014202	0.828995	-0.559069
0.1	18	5	0.1	100	-0.004979	-0.017521	0.808257	-0.588548
0.1	19	5	0.1	100	-0.007677	-0.02112	0.786315	-0.617416
0.1	20	5	0.1	100	-0.010962	-0.024972	0.763165	-0.645628
0.1	21	5	0.1	100	-0.014894	-0.029045	0.7388	-0.673134
0.1	22	5	0.1	100	-0.019532	-0.0333	0.713215	-0.699881
0.1	23	5	0.1	100	-0.024934	-0.037689	0.686405	-0.725814
0.1	24	5	0.1	100	-0.031158	-0.042156	0.658367	-0.75087
0.1	25	5	0.1	100	-0.038258	-0.046637	0.629097	-0.774982
0.1	26	5	0.1	100	-0.046287	-0.051061	0.598598	-0.79808
0.1	27	5	0.1	100	-0.055292	-0.055344	0.566871	-0.820084
0.1	28	5	0.1	100	-0.065314	-0.059397	0.533925	-0.84091
0.1	29	5	0.1	100	-0.076391	-0.063119	0.499773	-0.860469
0.1	30	5	0.1	100	-0.088549	-0.066402	0.464435	-0.878664
0.9	1	5	0.1	100	-0.694885	-0.443033	0.304389	-0.477707
0.9	2	5	0.1	100	-0.915464	-0.241836	0.081978	-0.311005
0.9	3	5	0.1	100	-0.969811	-0.111779	0.024643	-0.215337
0.9	4	5	0.1	100	-0.986907	-0.021987	0.003387	-0.159763
0.9	5	5	0.1	100	-0.991142	0.048118	-0.00617	-0.123643
0.9	6	5	0.1	100	-0.989311	0.107377	-0.0108	-0.09808
0.9	7	5	0.1	100	-0.983884	0.159965	-0.01297	-0.078841
0.9	8	5	0.1	100	-0.975944	0.208061	-0.01372	-0.063694
0.9	9	5	0.1	100	-0.966035	0.252888	-0.01358	-0.051365
0.9	10	5	0.1	100	-0.954473	0.295176	-0.01282	-0.041075
0.9	11	5	0.1	100	-0.941456	0.335378	-0.01162	-0.032325
0.9	12	5	0.1	100	-0.927128	0.373786	-0.01008	-0.02478
0.9	13	5	0.1	100	-0.9116	0.41059	-0.00827	-0.018209

0.9	14	5	0.1	100	-0.894964	0.445919	-0.00625	-0.012445
0.9	15	5	0.1	100	-0.877304	0.479861	-0.00406	-0.007366
0.9	16	5	0.1	100	-0.858695	0.512477	-0.00174	-0.00288
0.9	17	5	0.1	100	-0.839209	0.54381	0.000707	0.001084
0.9	18	5	0.1	100	-0.818916	0.57389	0.003238	0.004582
0.9	19	5	0.1	100	-0.797881	0.602743	0.005837	0.007659
0.9	20	5	0.1	100	-0.776171	0.630388	0.008485	0.010353
0.9	21	5	0.1	100	-0.753847	0.656841	0.011166	0.012696
0.9	22	5	0.1	100	-0.730973	0.682117	0.013865	0.014715
0.9	23	5	0.1	100	-0.707607	0.706231	0.016567	0.016435
0.9	24	5	0.1	100	-0.683809	0.729199	0.01926	0.017876
0.9	25	5	0.1	100	-0.659633	0.751037	0.021933	0.019058
0.9	26	5	0.1	100	-0.635136	0.771761	0.024575	0.019999
0.9	27	5	0.1	100	-0.610368	0.79139	0.027177	0.020715
0.9	28	5	0.1	100	-0.585381	0.809943	0.02973	0.021223
0.9	29	5	0.1	100	-0.560221	0.82744	0.032227	0.021536
0.9	30	5	0.1	100	-0.534935	0.843904	0.034662	0.021669
0.1	1	10	0.3	50	0.000049	0.001135	0.99943	-0.033752
0.1	2	10	0.3	50	0.000194	0.002237	0.997719	-0.067474
0.1	3	10	0.3	50	0.000429	0.003276	0.994867	-0.101133
0.1	4	10	0.3	50	0.000745	0.004219	0.990877	-0.134699
0.1	5	10	0.3	50	0.001128	0.005036	0.985749	-0.168142
0.1	6	10	0.3	50	0.001562	0.005698	0.979485	-0.20143
0.1	7	10	0.3	50	0.002026	0.006177	0.972087	-0.234532
0.1	8	10	0.3	50	0.002495	0.006448	0.963555	-0.26742
0.1	9	10	0.3	50	0.002942	0.006486	0.953893	-0.300061
0.1	10	10	0.3	50	0.003336	0.006272	0.943103	-0.332426
0.1	11	10	0.3	50	0.003644	0.005785	0.931184	-0.364485
0.1	12	10	0.3	50	0.003827	0.005012	0.91814	-0.396206
0.1	13	10	0.3	50	0.003846	0.003939	0.903971	-0.427559
0.1	14	10	0.3	50	0.003659	0.002558	0.888677	-0.458513
0.1	15	10	0.3	50	0.00322	0.000865	0.872258	-0.489035
0.1	16	10	0.3	50	0.002483	-0.00114	0.854713	-0.519094
0.1	17	10	0.3	50	0.001397	-0.003453	0.836041	-0.548654
0.1	18	10	0.3	50	-0.000087	-0.006065	0.81624	-0.577681
0.1	19	10	0.3	50	-0.002023	-0.008962	0.795307	-0.606137
0.1	20	10	0.3	50	-0.004464	-0.012123	0.773239	-0.633983
0.1	21	10	0.3	50	-0.007463	-0.015523	0.750032	-0.661177
0.1	22	10	0.3	50	-0.011075	-0.01913	0.725682	-0.687675
0.1	23	10	0.3	50	-0.015355	-0.022905	0.700185	-0.713429
0.1	24	10	0.3	50	-0.020353	-0.026803	0.673538	-0.738386
0.1	25	10	0.3	50	-0.026124	-0.030771	0.645739	-0.762491
0.1	26	10	0.3	50	-0.032715	-0.034749	0.616785	-0.785683
0.1	27	10	0.3	50	-0.040174	-0.03867	0.586679	-0.807898
0.1	28	10	0.3	50	-0.048543	-0.042457	0.555423	-0.829064
0.1	29	10	0.3	50	-0.057859	-0.046027	0.523024	-0.849105
0.1	30	10	0.3	50	-0.068154	-0.049289	0.489496	-0.86794

0.9	1	10	0.3	50	-0.21643	-0.395017	0.782844	-0.429273
0.9	2	10	0.3	50	-0.53981	-0.464366	0.457511	-0.532594
0.9	3	10	0.3	50	-0.744747	-0.383678	0.24956	-0.485662
0.9	4	10	0.3	50	-0.856411	-0.278252	0.133812	-0.413808
0.9	5	10	0.3	50	-0.917156	-0.180077	0.067894	-0.348988
0.9	6	10	0.3	50	-0.95032	-0.093529	0.028468	-0.295529
0.9	7	10	0.3	50	-0.967579	-0.017191	0.003871	-0.251959
0.9	8	10	0.3	50	-0.974956	0.051026	-0.0119	-0.216139
0.9	9	10	0.3	50	-0.975742	0.112863	-0.02212	-0.186279
0.9	10	10	0.3	50	-0.971841	0.169618	-0.02867	-0.161031
0.9	11	10	0.3	50	-0.96442	0.222235	-0.03267	-0.139409
0.9	12	10	0.3	50	-0.954232	0.271398	-0.03485	-0.120687
0.9	13	10	0.3	50	-0.941789	0.317604	-0.03568	-0.104328
0.9	14	10	0.3	50	-0.927453	0.361221	-0.0355	-0.089927
0.9	15	10	0.3	50	-0.911496	0.402525	-0.03453	-0.077176
0.9	16	10	0.3	50	-0.894126	0.441723	-0.03295	-0.065836
0.9	17	10	0.3	50	-0.875515	0.478977	-0.03088	-0.055719
0.9	18	10	0.3	50	-0.855805	0.514412	-0.02842	-0.046673
0.9	19	10	0.3	50	-0.835116	0.54813	-0.02566	-0.038576
0.9	20	10	0.3	50	-0.813558	0.580211	-0.02264	-0.031329
0.9	21	10	0.3	50	-0.791226	0.610726	-0.01944	-0.024845
0.9	22	10	0.3	50	-0.768209	0.639731	-0.0161	-0.019054
0.9	23	10	0.3	50	-0.744588	0.667279	-0.01264	-0.013895
0.9	24	10	0.3	50	-0.720439	0.693416	-0.00911	-0.009314
0.9	25	10	0.3	50	-0.695834	0.718182	-0.00553	-0.005263
0.9	26	10	0.3	50	-0.670837	0.741619	-0.00193	-0.001702
0.9	27	10	0.3	50	-0.645512	0.763763	0.001679	0.001409
0.9	28	10	0.3	50	-0.619917	0.784651	0.005265	0.004102
0.9	29	10	0.3	50	-0.594108	0.804318	0.008818	0.00641
0.9	30	10	0.3	50	-0.568136	0.8228	0.012323	0.008361

**EK 4 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan eğitimin
ardından çıkan hata değerleri**

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	5	0.1	100	0.004759	0.0056799	7.3E-05	0.004416
0.1	2	5	0.1	100	0.002356	0.0048024	0.00134	0.007625
0.1	3	5	0.1	100	-0.004071	0.0026512	0.001753	0.004045
0.1	4	5	0.1	100	-0.004538	0.0015024	-0.00113	0.001069
0.1	5	5	0.1	100	-0.001877	0.0017348	-0.00329	0.001769
0.1	6	5	0.1	100	-0.000838	0.0023496	-0.00269	0.003129
0.1	7	5	0.1	100	-0.000906	0.003038	-0.00083	0.00381
0.1	8	5	0.1	100	-0.001236	0.0037238	0.001235	0.003668
0.1	9	5	0.1	100	-0.001403	0.0043502	0.003043	0.002893
0.1	10	5	0.1	100	-0.001216	0.0048656	0.004322	0.001712
0.1	11	5	0.1	100	-0.000624	0.0052361	0.004911	0.000333
0.1	12	5	0.1	100	0.000321	0.0054511	0.004803	-0.001086
0.1	13	5	0.1	100	0.001494	0.005523	0.004106	-0.002449
0.1	14	5	0.1	100	0.00276	0.0054718	0.003035	-0.00367
0.1	15	5	0.1	100	0.004005	0.0053155	0.00187	-0.004735
0.1	16	5	0.1	100	0.005146	0.0050751	0.000896	-0.005619
0.1	17	5	0.1	100	0.006118	0.0047695	0.000305	-0.006321
0.1	18	5	0.1	100	0.006866	0.004424	0.000253	-0.006862
0.1	19	5	0.1	100	0.007338	0.00407	0.000785	-0.007244
0.1	20	5	0.1	100	0.007492	0.003736	0.001875	-0.007502
0.1	21	5	0.1	100	0.00731	0.003452	0.00343	-0.007646
0.1	22	5	0.1	100	0.006804	0.003239	0.005295	-0.007679
0.1	23	5	0.1	100	0.006017	0.003107	0.007265	-0.007586
0.1	24	5	0.1	100	0.005033	0.003054	0.009103	-0.00737
0.1	25	5	0.1	100	0.003963	0.003068	0.010563	-0.007008
0.1	26	5	0.1	100	0.002948	0.003128	0.011382	-0.00646
0.1	27	5	0.1	100	0.002148	0.003203	0.011289	-0.005716
0.1	28	5	0.1	100	0.001738	0.003264	0.010065	-0.00476
0.1	29	5	0.1	100	0.001908	0.003277	0.007497	-0.003611
0.1	30	5	0.1	100	0.002855	0.003211	0.003435	-0.002296
0.9	1	5	0.1	100	0.025095	0.039113	0.015731	0.041647
0.9	2	5	0.1	100	0.030704	-0.028154	0.010886	-0.028145
0.9	3	5	0.1	100	0.029471	-0.029861	-0.00978	-0.032013
0.9	4	5	0.1	100	0.025917	-0.008801	-0.01416	-0.011167
0.9	5	5	0.1	100	0.021302	0.007678	-0.01438	0.007213
0.9	6	5	0.1	100	0.015981	0.012853	-0.01448	0.015358
0.9	7	5	0.1	100	0.010004	0.009405	-0.01483	0.014732
0.9	8	5	0.1	100	0.003694	0.002209	-0.01481	0.009568
0.9	9	5	0.1	100	-0.001685	-0.003708	-0.01348	0.004887
0.9	10	5	0.1	100	-0.003317	-0.004386	-0.00981	0.005236
0.9	11	5	0.1	100	-0.001294	-0.002478	-0.00539	0.007784
0.9	12	5	0.1	100	-0.001012	-0.002806	-0.00267	0.006821
0.9	13	5	0.1	100	-0.00311	-0.00425	-0.00122	0.003893

0.9	14	5	0.1	100	-0.005756	-0.005329	-0.00029	0.001219
0.9	15	5	0.1	100	-0.007966	-0.005841	0.00039	-0.0005574
0.9	16	5	0.1	100	-0.009465	-0.006047	0.000862	-0.0014539
0.9	17	5	0.1	100	-0.010221	-0.0062	0.001146	-0.0016568
0.9	18	5	0.1	100	-0.010324	-0.00644	0.001271	-0.0013711
0.9	19	5	0.1	100	-0.009919	-0.006803	0.001278	-0.0007788
0.9	20	5	0.1	100	-0.009159	-0.007198	0.001217	-3E-05
0.9	21	5	0.1	100	-0.008193	-0.007481	0.001145	0.00076
0.9	22	5	0.1	100	-0.007117	-0.007497	0.001119	0.001506
0.9	23	5	0.1	100	-0.005983	-0.007131	0.001193	0.002144
0.9	24	5	0.1	100	-0.004841	-0.006369	0.00141	0.002636
0.9	25	5	0.1	100	-0.003707	-0.005287	0.001794	0.002952
0.9	26	5	0.1	100	-0.002654	-0.004121	0.002353	0.003074
0.9	27	5	0.1	100	-0.001802	-0.00315	0.003069	0.002991
0.9	28	5	0.1	100	-0.001409	-0.002743	0.003905	0.00269
0.9	29	5	0.1	100	-0.001809	-0.00318	0.004806	0.002164
0.9	30	5	0.1	100	-0.003375	-0.004674	0.005712	0.001403
0.1	1	10	0.3	50	-0.011976	0.005937	1E-04	0.00016
0.1	2	10	0.3	50	-0.007519	0.0051928	0.001581	0.005899
0.1	3	10	0.3	50	-0.007778	0.0033761	0.003333	0.00574
0.1	4	10	0.3	50	-0.010325	0.0011018	0.002523	0.001489
0.1	5	10	0.3	50	-0.00772	0.000399	-0.00111	0.000832
0.1	6	10	0.3	50	-0.004474	0.0006553	-0.00239	0.00299
0.1	7	10	0.3	50	-0.002491	0.0010656	-0.00149	0.005212
0.1	8	10	0.3	50	-0.001171	0.0014185	-1.5E-05	0.00666
0.1	9	10	0.3	50	-0.000107	0.001677	0.001247	0.007331
0.1	10	10	0.3	50	0.000808	0.0018408	0.001977	0.007386
0.1	11	10	0.3	50	0.001562	0.0019241	0.002076	0.007065
0.1	12	10	0.3	50	0.002139	0.0019348	0.00156	0.006556
0.1	13	10	0.3	50	0.00254	0.0018835	0.000529	0.006029
0.1	14	10	0.3	50	0.002778	0.0017801	-0.00082	0.005573
0.1	15	10	0.3	50	0.002868	0.0016404	-0.00227	0.005245
0.1	16	10	0.3	50	0.002809	0.0014864	-0.00358	0.005064
0.1	17	10	0.3	50	0.002594	0.0013439	-0.00457	0.004994
0.1	18	10	0.3	50	0.002207	0.0012387	-0.00508	0.004991
0.1	19	10	0.3	50	0.001642	0.0011932	-0.00502	0.005007
0.1	20	10	0.3	50	0.000893	0.001223	-0.00436	0.004973
0.1	21	10	0.3	50	-3.16E-05	0.001341	-0.00317	0.004877
0.1	22	10	0.3	50	-0.001113	0.001552	-0.00157	0.004685
0.1	23	10	0.3	50	-0.002322	0.001858	0.000265	0.004419
0.1	24	10	0.3	50	-0.003623	0.002259	0.002112	0.004116
0.1	25	10	0.3	50	-0.004965	0.002752	0.003721	0.003821
0.1	26	10	0.3	50	-0.00629	0.003332	0.004835	0.003603
0.1	27	10	0.3	50	-0.007526	0.003994	0.005171	0.003528
0.1	28	10	0.3	50	-0.008585	0.004727	0.004467	0.003644
0.1	29	10	0.3	50	-0.009364	0.005522	0.002476	0.003995
0.1	30	10	0.3	50	-0.009736	0.006367	-0.00102	0.0046

0.9	1	10	0.3	50	0.03142	-0.039773	-0.00039	-0.037057
0.9	2	10	0.3	50	-0.01792	0.030556	0.012009	0.033574
0.9	3	10	0.3	50	-0.005293	-0.001972	0.00083	0.001552
0.9	4	10	0.3	50	-0.003299	-0.019618	0.002758	-0.018892
0.9	5	10	0.3	50	0.000606	-0.014153	0.005695	-0.017532
0.9	6	10	0.3	50	0.00646	-0.003371	0.006376	-0.009141
0.9	7	10	0.3	50	0.011069	0.001164	0.005492	-0.004571
0.9	8	10	0.3	50	0.013226	-0.001854	0.004417	-0.006141
0.9	9	10	0.3	50	0.013522	-0.008253	0.004114	-0.010831
0.9	10	10	0.3	50	0.014351	-0.012108	0.005377	-0.013149
0.9	11	10	0.3	50	0.01834	-0.010565	0.008144	-0.010231
0.9	12	10	0.3	50	0.021712	-0.008718	0.009773	-0.007743
0.9	13	10	0.3	50	0.020649	-0.008634	0.009359	-0.008162
0.9	14	10	0.3	50	0.017073	-0.008341	0.008029	-0.009087
0.9	15	10	0.3	50	0.012886	-0.007135	0.006462	-0.009274
0.9	16	10	0.3	50	0.008896	-0.005283	0.004866	-0.008619
0.9	17	10	0.3	50	0.005405	-0.003267	0.003297	-0.007346
0.9	18	10	0.3	50	0.002545	-0.001472	0.001771	-0.005724
0.9	19	10	0.3	50	0.000306	-0.00012	0.000306	-0.003983
0.9	20	10	0.3	50	-0.001332	0.000739	-0.00107	-0.002299
0.9	21	10	0.3	50	-0.002464	0.001174	-0.00233	-0.000802
0.9	22	10	0.3	50	-0.003171	0.001359	-0.00344	0.000429
0.9	23	10	0.3	50	-0.003532	0.001481	-0.00434	0.001349
0.9	24	10	0.3	50	-0.003581	0.001724	-0.00501	0.0019433
0.9	25	10	0.3	50	-0.003336	0.002178	-0.00542	0.0022183
0.9	26	10	0.3	50	-0.002803	0.002861	-0.00555	0.0022001
0.9	27	10	0.3	50	-0.002048	0.003617	-0.00542	0.0019205
0.9	28	10	0.3	50	-0.001163	0.004239	-0.00506	0.0014214
0.9	29	10	0.3	50	-0.000372	0.004412	-0.00453	0.000742
0.9	30	10	0.3	50	6E-06	0.00386	-0.00389	-7.83E-05

EK 5 Seri Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	12.5	0.2	125	0.995876	-0.071877	0.004614	0.055159
0.1	2	12.5	0.2	125	0.983544	-0.142832	0.018393	0.109098
0.1	3	12.5	0.2	125	0.963119	-0.211936	0.041148	0.160595
0.1	4	12.5	0.2	125	0.934809	-0.278253	0.072553	0.20843
0.1	5	12.5	0.2	125	0.89892	-0.340837	0.112133	0.251392
0.1	6	12.5	0.2	125	0.855879	-0.398745	0.159241	0.288298
0.1	7	12.5	0.2	125	0.806247	-0.451047	0.213053	0.318011
0.1	8	12.5	0.2	125	0.750738	-0.496855	0.272544	0.339482
0.1	9	12.5	0.2	125	0.690224	-0.535356	0.336495	0.351789
0.1	10	12.5	0.2	125	0.625738	-0.565851	0.403498	0.354194
0.1	11	12.5	0.2	125	0.55846	-0.587798	0.471986	0.346185
0.1	12	12.5	0.2	125	0.489687	-0.600858	0.540275	0.327535
0.1	13	12.5	0.2	125	0.42079	-0.604929	0.606626	0.298332
0.1	14	12.5	0.2	125	0.353159	-0.600169	0.669324	0.259
0.1	15	12.5	0.2	125	0.288141	-0.587007	0.726756	0.210295
0.1	16	12.5	0.2	125	0.226968	-0.566124	0.777494	0.153274
0.1	17	12.5	0.2	125	0.170701	-0.538423	0.820364	0.089245
0.1	18	12.5	0.2	125	0.12018	-0.50498	0.854497	0.019691
0.1	19	12.5	0.2	125	0.075996	-0.466976	0.879353	-0.053811
0.1	20	12.5	0.2	125	0.038478	-0.42564	0.894726	-0.129675
0.1	21	12.5	0.2	125	0.007703	-0.382174	0.900717	-0.20638
0.1	22	12.5	0.2	125	-0.016476	-0.337711	0.897692	-0.282542
0.1	23	12.5	0.2	125	-0.034397	-0.29326	0.88623	-0.356949
0.1	24	12.5	0.2	125	-0.04654	-0.24969	0.867062	-0.428594
0.1	25	12.5	0.2	125	-0.053487	-0.207706	0.841014	-0.496683
0.1	26	12.5	0.2	125	-0.055876	-0.167857	0.808952	-0.560623
0.1	27	12.5	0.2	125	-0.054368	-0.130536	0.771743	-0.620013
0.1	28	12.5	0.2	125	-0.049615	-0.096001	0.730218	-0.674614
0.1	29	12.5	0.2	125	-0.042238	-0.064391	0.685148	-0.724322
0.1	30	12.5	0.2	125	-0.032814	-0.035745	0.637233	-0.769143
0.9	1	12.5	0.2	125	0.006817	-0.090807	0.99386	0.062853
0.9	2	12.5	0.2	125	-0.000426	-0.014288	0.999025	-0.04177
0.9	3	12.5	0.2	125	0.001434	0.025267	0.993696	-0.109212
0.9	4	12.5	0.2	125	0.005835	0.055059	0.984463	-0.166635
0.9	5	12.5	0.2	125	0.011909	0.08056	0.972221	-0.21944
0.9	6	12.5	0.2	125	0.019386	0.103529	0.957274	-0.269319
0.9	7	12.5	0.2	125	0.028118	0.124666	0.939808	-0.316905
0.9	8	12.5	0.2	125	0.037986	0.144281	0.919985	-0.362448
0.9	9	12.5	0.2	125	0.048879	0.162516	0.897962	-0.406034
0.9	10	12.5	0.2	125	0.060685	0.179436	0.873901	-0.44768
0.9	11	12.5	0.2	125	0.073293	0.19507	0.847964	-0.487374
0.9	12	12.5	0.2	125	0.086588	0.209434	0.820315	-0.525094
0.9	13	12.5	0.2	125	0.100457	0.222536	0.791118	-0.560819
0.9	14	12.5	0.2	125	0.114791	0.234387	0.760535	-0.594536

0.9	15	12.5	0.2	125	0.129479	0.245002	0.728721	-0.626239
0.9	16	12.5	0.2	125	0.144416	0.254401	0.695826	-0.655934
0.9	17	12.5	0.2	125	0.159503	0.262611	0.661993	-0.683637
0.9	18	12.5	0.2	125	0.174645	0.269665	0.627355	-0.70937
0.9	19	12.5	0.2	125	0.189753	0.275599	0.592036	-0.733166
0.9	20	12.5	0.2	125	0.204744	0.280458	0.556149	-0.755064
0.9	21	12.5	0.2	125	0.219544	0.284288	0.519796	-0.775108
0.9	22	12.5	0.2	125	0.234083	0.287141	0.483071	-0.793346
0.9	23	12.5	0.2	125	0.2483	0.289072	0.446055	-0.809827
0.9	24	12.5	0.2	125	0.262138	0.290136	0.408819	-0.824604
0.9	25	12.5	0.2	125	0.27555	0.290391	0.371427	-0.837727
0.9	26	12.5	0.2	125	0.288492	0.289896	0.333932	-0.849248
0.9	27	12.5	0.2	125	0.300927	0.288712	0.296378	-0.859214
0.9	28	12.5	0.2	125	0.312824	0.286898	0.258804	-0.86767
0.9	29	12.5	0.2	125	0.324157	0.284513	0.221241	-0.874658
0.9	30	12.5	0.2	125	0.334905	0.281617	0.183714	-0.880216
0.1	1	15	0.4	75	0.996152	-0.069656	0.004321	0.053006
0.1	2	15	0.4	75	0.984639	-0.138499	0.017234	0.104917
0.1	3	15	0.4	75	0.965548	-0.20571	0.038587	0.154636
0.1	4	15	0.4	75	0.939037	-0.270453	0.068112	0.20106
0.1	5	15	0.4	75	0.905347	-0.33188	0.105419	0.243082
0.1	6	15	0.4	75	0.864816	-0.38913	0.149969	0.279607
0.1	7	15	0.4	75	0.817899	-0.441342	0.201065	0.309565
0.1	8	15	0.4	75	0.765187	-0.487674	0.25783	0.331944
0.1	9	15	0.4	75	0.707416	-0.527331	0.3192	0.345827
0.1	10	15	0.4	75	0.645478	-0.559599	0.383927	0.350437
0.1	11	15	0.4	75	0.580412	-0.583891	0.450595	0.345191
0.1	12	15	0.4	75	0.513388	-0.599784	0.51765	0.329742
0.1	13	15	0.4	75	0.445673	-0.607062	0.583452	0.304031
0.1	14	15	0.4	75	0.378584	-0.605743	0.646342	0.26831
0.1	15	15	0.4	75	0.313433	-0.596103	0.704716	0.223153
0.1	16	15	0.4	75	0.251459	-0.578665	0.757103	0.16944
0.1	17	15	0.4	75	0.193773	-0.554188	0.802243	0.108322
0.1	18	15	0.4	75	0.141297	-0.523621	0.839144	0.041159
0.1	19	15	0.4	75	0.094729	-0.488055	0.867119	-0.030554
0.1	20	15	0.4	75	0.054521	-0.448655	0.885807	-0.105267
0.1	21	15	0.4	75	0.020875	-0.406604	0.895159	-0.18146
0.1	22	15	0.4	75	-0.006238	-0.36304	0.895405	-0.257706
0.1	23	15	0.4	75	-0.027053	-0.319008	0.887015	-0.332727
0.1	24	15	0.4	75	-0.041966	-0.275427	0.870634	-0.405432
0.1	25	15	0.4	75	-0.051497	-0.233069	0.847033	-0.474933
0.1	26	15	0.4	75	-0.056244	-0.192549	0.817049	-0.540548
0.1	27	15	0.4	75	-0.056844	-0.154329	0.781539	-0.601788
0.1	28	15	0.4	75	-0.053941	-0.11873	0.741342	-0.658335
0.1	29	15	0.4	75	-0.048163	-0.085944	0.697253	-0.710023
0.1	30	15	0.4	75	-0.040098	-0.056057	0.649997	-0.756805
0.9	1	15	0.4	75	0.071259	-0.265279	0.931569	0.238179

0.9	2	15	0.4	75	0.0084	-0.109284	0.992531	0.053565
0.9	3	15	0.4	75	-0.000802	-0.037374	0.99822	-0.046466
0.9	4	15	0.4	75	-0.000079	0.009767	0.992559	-0.121374
0.9	5	15	0.4	75	0.00457	0.046235	0.981597	-0.185226
0.9	6	15	0.4	75	0.011569	0.076875	0.966953	-0.242811
0.9	7	15	0.4	75	0.02031	0.103748	0.94928	-0.296127
0.9	8	15	0.4	75	0.030477	0.127851	0.928942	-0.346109
0.9	9	15	0.4	75	0.041858	0.149711	0.906203	-0.393231
0.9	10	15	0.4	75	0.054284	0.169625	0.881286	-0.43774
0.9	11	15	0.4	75	0.067608	0.187771	0.854395	-0.47977
0.9	12	15	0.4	75	0.081689	0.204263	0.825727	-0.519401
0.9	13	15	0.4	75	0.096396	0.21918	0.79547	-0.556683
0.9	14	15	0.4	75	0.111602	0.232585	0.763803	-0.591654
0.9	15	15	0.4	75	0.127186	0.244532	0.730901	-0.624349
0.9	16	15	0.4	75	0.143034	0.25507	0.696927	-0.654808
0.9	17	15	0.4	75	0.159037	0.264252	0.662036	-0.683071
0.9	18	15	0.4	75	0.175093	0.27213	0.626372	-0.709187
0.9	19	15	0.4	75	0.191108	0.278759	0.590067	-0.733207
0.9	20	15	0.4	75	0.206996	0.284199	0.553241	-0.755187
0.9	21	15	0.4	75	0.222677	0.288509	0.516003	-0.775189
0.9	22	15	0.4	75	0.238081	0.291751	0.47845	-0.793275
0.9	23	15	0.4	75	0.253143	0.293991	0.440667	-0.809506
0.9	24	15	0.4	75	0.267807	0.295293	0.402729	-0.823949
0.9	25	15	0.4	75	0.282024	0.295723	0.364699	-0.836663
0.9	26	15	0.4	75	0.295752	0.295347	0.326632	-0.84771
0.9	27	15	0.4	75	0.308953	0.294231	0.288573	-0.857147
0.9	28	15	0.4	75	0.321598	0.29244	0.250561	-0.865027
0.9	29	15	0.4	75	0.333662	0.290039	0.212626	-0.8714
0.9	30	15	0.4	75	0.345125	0.28709	0.174792	-0.876308

**EK 6 Seri Anahtar için Trainbr eğitim algoritması ile yapılan testin ardından
çıkan hata değerleri**

Anahtarın Konumu	Frekans	ε_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	12.5	0.2	125	-0.009436	-0.028203	-0.01399	0.029243
0.1	2	12.5	0.2	125	-0.008064	-0.024668	-0.01479	0.030452
0.1	3	12.5	0.2	125	-0.005129	-0.023514	-0.01481	0.031755
0.1	4	12.5	0.2	125	-0.002619	-0.023907	-0.01352	0.03305
0.1	5	12.5	0.2	125	-0.0018	-0.025213	-0.01078	0.034828
0.1	6	12.5	0.2	125	-0.003069	-0.026145	-0.00734	0.035752
0.1	7	12.5	0.2	125	-0.006097	-0.025393	-0.0043	0.034009
0.1	8	12.5	0.2	125	-0.010088	-0.022965	-0.00215	0.030678
0.1	9	12.5	0.2	125	-0.014004	-0.019284	-0.00035	0.027271
0.1	10	12.5	0.2	125	-0.016798	-0.014789	0.002062	0.024366
0.1	11	12.5	0.2	125	-0.01772	-0.009952	0.005784	0.021815
0.1	12	12.5	0.2	125	-0.016617	-0.005272	0.010785	0.019125
0.1	13	12.5	0.2	125	-0.01394	-0.001111	0.016224	0.015598
0.1	14	12.5	0.2	125	-0.010649	0.002409	0.020666	0.01053
0.1	15	12.5	0.2	125	-0.007781	0.005437	0.022644	0.003545
0.1	16	12.5	0.2	125	-0.006108	0.008294	0.021336	-0.005154
0.1	17	12.5	0.2	125	-0.005871	0.011293	0.016966	-0.014633
0.1	18	12.5	0.2	125	-0.00673	0.01467	0.010743	-0.0233896
0.1	19	12.5	0.2	125	-0.007943	0.018366	0.004287	-0.029881
0.1	20	12.5	0.2	125	-0.008678	0.02212	-0.0009	-0.033175
0.1	21	12.5	0.2	125	-0.008303	0.025514	-0.00388	-0.03335
0.1	22	12.5	0.2	125	-0.006579	0.028141	-0.00449	-0.031438
0.1	23	12.5	0.2	125	-0.00368	0.02975	-0.00325	-0.028901
0.1	24	12.5	0.2	125	-0.000106	0.03025	-0.00115	-0.026886
0.1	25	12.5	0.2	125	0.003481	0.029696	0.000626	-0.025777
0.1	26	12.5	0.2	125	0.006412	0.028237	0.001118	-0.025067
0.1	27	12.5	0.2	125	0.008125	0.026026	-5.3E-05	-0.023707
0.1	28	12.5	0.2	125	0.008228	0.023188	-0.0025	-0.020586
0.1	29	12.5	0.2	125	0.006517	0.019812	-0.00511	-0.015048
0.1	30	12.5	0.2	125	0.002962	0.015977	-0.00629	-0.006997
0.9	1	12.5	0.2	125	0.038061	-0.102203	-0.01123	0.107937
0.9	2	12.5	0.2	125	0.029651	-0.097252	-0.01143	0.099805
0.9	3	12.5	0.2	125	0.018963	-0.08659	-0.00857	0.085433
0.9	4	12.5	0.2	125	0.011205	-0.076287	-0.00504	0.072298
0.9	5	12.5	0.2	125	0.004665	-0.065434	-0.00132	0.06006
0.9	6	12.5	0.2	125	-0.000681	-0.054949	0.001976	0.050109
0.9	7	12.5	0.2	125	-0.004409	-0.045692	0.004302	0.043155
0.9	8	12.5	0.2	125	-0.006578	-0.037001	0.005365	0.036708
0.9	9	12.5	0.2	125	-0.007658	-0.028296	0.005348	0.029054
0.9	10	12.5	0.2	125	-0.008211	-0.020166	0.004709	0.02131
0.9	11	12.5	0.2	125	-0.008659	-0.01314	0.004066	0.014564
0.9	12	12.5	0.2	125	-0.009221	-0.007434	0.003945	0.009184
0.9	13	12.5	0.2	125	-0.009947	-0.003046	0.004652	0.005159

0.9	14	12.5	0.2	125	-0.010781	7.3E-05	0.006245	0.002356
0.9	15	12.5	0.2	125	-0.011589	0.001998	0.008509	0.000619
0.9	16	12.5	0.2	125	-0.012256	0.002819	0.011104	-0.000246
0.9	17	12.5	0.2	125	-0.012633	0.002599	0.013557	-0.000383
0.9	18	12.5	0.2	125	-0.012655	0.001415	0.015415	7E-05
0.9	19	12.5	0.2	125	-0.012243	-0.000659	0.016234	0.001006
0.9	20	12.5	0.2	125	-0.011374	-0.003548	0.015671	0.002324
0.9	21	12.5	0.2	125	-0.010084	-0.007208	0.013504	0.003918
0.9	22	12.5	0.2	125	-0.008403	-0.011551	0.009639	0.005716
0.9	23	12.5	0.2	125	-0.0064	-0.016512	0.004135	0.007617
0.9	24	12.5	0.2	125	-0.004148	-0.022006	-0.0028	0.009524
0.9	25	12.5	0.2	125	-0.00176	-0.027931	-0.01083	0.011357
0.9	26	12.5	0.2	125	0.000708	-0.034186	-0.01951	0.012998
0.9	27	12.5	0.2	125	0.003153	-0.040652	-0.02836	0.014374
0.9	28	12.5	0.2	125	0.005526	-0.047228	-0.03682	0.01538
0.9	29	12.5	0.2	125	0.007753	-0.053783	-0.0444	0.015918
0.9	30	12.5	0.2	125	0.009825	-0.060237	-0.05063	0.015936
0.1	1	15	0.4	75	-0.006632	-0.006984	0.002358	-0.002567
0.1	2	15	0.4	75	-0.005659	-0.002831	0.00567	1.3E-05
0.1	3	15	0.4	75	-0.003898	0.00181	0.011779	-0.000946
0.1	4	15	0.4	75	-0.002927	0.006313	0.02053	-0.00423
0.1	5	15	0.4	75	-0.003417	0.00952	0.029051	-0.007552
0.1	6	15	0.4	75	-0.005336	0.01139	0.035181	-0.010727
0.1	7	15	0.4	75	-0.008509	0.012882	0.038445	-0.015225
0.1	8	15	0.4	75	-0.012677	0.014294	0.03944	-0.020004
0.1	9	15	0.4	75	-0.017366	0.015681	0.03894	-0.023507
0.1	10	15	0.4	75	-0.021708	0.017209	0.037663	-0.025197
0.1	11	15	0.4	75	-0.024672	0.018881	0.036165	-0.025261
0.1	12	15	0.4	75	-0.025498	0.020504	0.0348	-0.024242
0.1	13	15	0.4	75	-0.024033	0.021792	0.033608	-0.022881
0.1	14	15	0.4	75	-0.020814	0.022553	0.032168	-0.02198
0.1	15	15	0.4	75	-0.016813	0.022823	0.029774	-0.022173
0.1	16	15	0.4	75	-0.013039	0.022785	0.025807	-0.02376
0.1	17	15	0.4	75	-0.010203	0.022778	0.020147	-0.026474
0.1	18	15	0.4	75	-0.008467	0.023061	0.013356	-0.02946
0.1	19	15	0.4	75	-0.007521	0.023765	0.006511	-0.031586
0.1	20	15	0.4	75	-0.006716	0.024805	0.000813	-0.031913
0.1	21	15	0.4	75	-0.005398	0.025904	-0.00282	-0.03016
0.1	22	15	0.4	75	-0.003147	0.02675	-0.00408	-0.026894
0.1	23	15	0.4	75	0.000103	0.027058	-0.0033	-0.023223
0.1	24	15	0.4	75	0.00406	0.026697	-0.00134	-0.020258
0.1	25	15	0.4	75	0.008195	0.025689	0.000627	-0.018507
0.1	26	15	0.4	75	0.011883	0.024109	0.001541	-0.017692
0.1	27	15	0.4	75	0.01454	0.022079	0.000801	-0.016822
0.1	28	15	0.4	75	0.015706	0.019718	-0.00148	-0.014715
0.1	29	15	0.4	75	0.015099	0.017081	-0.00434	-0.010477
0.1	30	15	0.4	75	0.012609	0.014222	-0.00624	-0.003745

0.9	1	15	0.4	75	-0.00273	0.017689	0.020791	0.002001
0.9	2	15	0.4	75	0.009867	0.002284	-0.00509	0.013066
0.9	3	15	0.4	75	-0.002288	0.012551	-0.00741	-0.003143
0.9	4	15	0.4	75	-0.010723	0.013522	-0.00401	-0.008716
0.9	5	15	0.4	75	-0.013781	0.012584	0.001713	-0.009934
0.9	6	15	0.4	75	-0.015039	0.011215	0.008117	-0.008119
0.9	7	15	0.4	75	-0.015568	0.008802	0.01406	-0.003263
0.9	8	15	0.4	75	-0.015196	0.005949	0.018738	0.001919
0.9	9	15	0.4	75	-0.013861	0.003419	0.021687	0.005161
0.9	10	15	0.4	75	-0.011843	0.000835	0.022854	0.00712
0.9	11	15	0.4	75	-0.009553	-0.002131	0.022505	0.00867
0.9	12	15	0.4	75	-0.007338	-0.005513	0.021093	0.010071
0.9	13	15	0.4	75	-0.005435	-0.00912	0.01914	0.011273
0.9	14	15	0.4	75	-0.003962	-0.012715	0.017057	0.012134
0.9	15	15	0.4	75	-0.002936	-0.016062	0.015099	0.012549
0.9	16	15	0.4	75	-0.002354	-0.01896	0.013413	0.012448
0.9	17	15	0.4	75	-0.002147	-0.021222	0.012024	0.011841
0.9	18	15	0.4	75	-0.002263	-0.02273	0.010878	0.010767
0.9	19	15	0.4	75	-0.002648	-0.023399	0.009943	0.009337
0.9	20	15	0.4	75	-0.003266	-0.023219	0.009169	0.007647
0.9	21	15	0.4	75	-0.004057	-0.022209	0.008537	0.005819
0.9	22	15	0.4	75	-0.005011	-0.020461	0.00809	0.003965
0.9	23	15	0.4	75	-0.006093	-0.018071	0.007873	0.002156
0.9	24	15	0.4	75	-0.007287	-0.015203	0.007981	0.000439
0.9	25	15	0.4	75	-0.008564	-0.011973	0.008541	-0.001187
0.9	26	15	0.4	75	-0.009922	-0.008537	0.009688	-0.00276
0.9	27	15	0.4	75	-0.011343	-0.005001	0.011597	-0.004353
0.9	28	15	0.4	75	-0.012818	-0.00147	0.014439	-0.006043
0.9	29	15	0.4	75	-0.014332	0.002001	0.018374	-0.00793
0.9	30	15	0.4	75	-0.015885	0.00536	0.023548	-0.010112

EK 7 Paralel Anahtar için yapay sinir ağlarına uygulanan test verilerinin bir kısmı

Anahtarın Konumu	Frekans	ϵ_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	12.5	0.2	125	-0.000025	-0.001123	0.999395	-0.034754
0.1	2	12.5	0.2	125	-0.000101	-0.002273	0.997581	-0.069476
0.1	3	12.5	0.2	125	-0.000236	-0.003474	0.994557	-0.104135
0.1	4	12.5	0.2	125	-0.000437	-0.004753	0.990323	-0.138699
0.1	5	12.5	0.2	125	-0.000718	-0.006132	0.984879	-0.173135
0.1	6	12.5	0.2	125	-0.001098	-0.007635	0.978223	-0.207412
0.1	7	12.5	0.2	125	-0.001595	-0.009283	0.970356	-0.241497
0.1	8	12.5	0.2	125	-0.002235	-0.011095	0.961276	-0.275357
0.1	9	12.5	0.2	125	-0.003046	-0.013087	0.950981	-0.308958
0.1	10	12.5	0.2	125	-0.004057	-0.015273	0.93947	-0.342268
0.1	11	12.5	0.2	125	-0.005304	-0.017665	0.92674	-0.37525
0.1	12	12.5	0.2	125	-0.006824	-0.020268	0.91279	-0.40787
0.1	13	12.5	0.2	125	-0.008655	-0.023087	0.897615	-0.44009
0.1	14	12.5	0.2	125	-0.010841	-0.026121	0.881213	-0.471872
0.1	15	12.5	0.2	125	-0.013426	-0.029364	0.86358	-0.503177
0.1	16	12.5	0.2	125	-0.016455	-0.032807	0.844712	-0.533961
0.1	17	12.5	0.2	125	-0.019978	-0.036434	0.824605	-0.564182
0.1	18	12.5	0.2	125	-0.024042	-0.040225	0.803253	-0.593791
0.1	19	12.5	0.2	125	-0.028698	-0.044151	0.780654	-0.622741
0.1	20	12.5	0.2	125	-0.033995	-0.04818	0.756804	-0.650977
0.1	21	12.5	0.2	125	-0.039983	-0.052271	0.7317	-0.678443
0.1	22	12.5	0.2	125	-0.04671	-0.056377	0.70534	-0.705078
0.1	23	12.5	0.2	125	-0.054222	-0.060444	0.677726	-0.730818
0.1	24	12.5	0.2	125	-0.062564	-0.064409	0.648859	-0.755592
0.1	25	12.5	0.2	125	-0.071777	-0.068203	0.618746	-0.779327
0.1	26	12.5	0.2	125	-0.081895	-0.071747	0.587396	-0.801942
0.1	27	12.5	0.2	125	-0.09295	-0.074955	0.554825	-0.823354
0.1	28	12.5	0.2	125	-0.104965	-0.077734	0.521053	-0.843471
0.1	29	12.5	0.2	125	-0.117955	-0.079984	0.486108	-0.8622
0.1	30	12.5	0.2	125	-0.131926	-0.081594	0.450027	-0.87944
0.9	1	12.5	0.2	125	-0.844638	-0.345226	0.154703	-0.378778
0.9	2	12.5	0.2	125	-0.965435	-0.146306	0.032211	-0.213293
0.9	3	12.5	0.2	125	-0.988964	-0.041723	0.005882	-0.142048
0.9	4	12.5	0.2	125	-0.994188	0.030207	-0.00325	-0.103297
0.9	5	12.5	0.2	125	-0.993003	0.087819	-0.00706	-0.078651
0.9	6	12.5	0.2	125	-0.988516	0.137844	-0.00865	-0.061326
0.9	7	12.5	0.2	125	-0.981835	0.183263	-0.0091	-0.048291
0.9	8	12.5	0.2	125	-0.973445	0.225572	-0.00889	-0.038001
0.9	9	12.5	0.2	125	-0.963596	0.265591	-0.00823	-0.029589
0.9	10	12.5	0.2	125	-0.952442	0.303797	-0.00725	-0.022532
0.9	11	12.5	0.2	125	-0.940088	0.340478	-0.00603	-0.0165
0.9	12	12.5	0.2	125	-0.926613	0.375816	-0.00461	-0.011272
0.9	13	12.5	0.2	125	-0.912089	0.409925	-0.00303	-0.006695
0.9	14	12.5	0.2	125	-0.896577	0.442876	-0.00133	-0.002662

0.9	15	12.5	0.2	125	-0.880137	0.474718	0.000493	0.000906
0.9	16	12.5	0.2	125	-0.862826	0.505479	0.002405	0.00407
0.9	17	12.5	0.2	125	-0.8447	0.535179	0.004392	0.006874
0.9	18	12.5	0.2	125	-0.825815	0.563829	0.006442	0.009354
0.9	19	12.5	0.2	125	-0.806225	0.591438	0.00854	0.01154
0.9	20	12.5	0.2	125	-0.785985	0.618011	0.010675	0.013456
0.9	21	12.5	0.2	125	-0.765149	0.643554	0.012835	0.015122
0.9	22	12.5	0.2	125	-0.743769	0.66807	0.01501	0.016555
0.9	23	12.5	0.2	125	-0.721897	0.691566	0.017189	0.017771
0.9	24	12.5	0.2	125	-0.699585	0.714047	0.019364	0.018784
0.9	25	12.5	0.2	125	-0.676882	0.735523	0.021526	0.019608
0.9	26	12.5	0.2	125	-0.653837	0.756001	0.023667	0.020252
0.9	27	12.5	0.2	125	-0.630496	0.775493	0.02578	0.020729
0.9	28	12.5	0.2	125	-0.606905	0.794012	0.027859	0.02105
0.9	29	12.5	0.2	125	-0.583108	0.811569	0.029897	0.021223
0.9	30	12.5	0.2	125	-0.559147	0.828182	0.03189	0.021259
0.1	1	15	0.4	75	0.000005	-0.000035	0.9994	-0.034643
0.1	2	15	0.4	75	0.000016	-0.000099	0.997599	-0.069255
0.1	3	15	0.4	75	0.00003	-0.00022	0.994598	-0.103802
0.1	4	15	0.4	75	0.000034	-0.000427	0.990397	-0.138254
0.1	5	15	0.4	75	0.000017	-0.000746	0.984996	-0.172578
0.1	6	15	0.4	75	-0.00004	-0.001203	0.978395	-0.206741
0.1	7	15	0.4	75	-0.000158	-0.001822	0.970595	-0.240713
0.1	8	15	0.4	75	-0.000362	-0.002626	0.961595	-0.27446
0.1	9	15	0.4	75	-0.00068	-0.003632	0.951395	-0.307951
0.1	10	15	0.4	75	-0.001144	-0.004859	0.939995	-0.341151
0.1	11	15	0.4	75	-0.001789	-0.006321	0.927394	-0.374029
0.1	12	15	0.4	75	-0.002653	-0.008027	0.913589	-0.40655
0.1	13	15	0.4	75	-0.003777	-0.009985	0.89858	-0.43868
0.1	14	15	0.4	75	-0.005206	-0.012198	0.882363	-0.470382
0.1	15	15	0.4	75	-0.006984	-0.014663	0.864935	-0.501621
0.1	16	15	0.4	75	-0.009161	-0.017375	0.846292	-0.532356
0.1	17	15	0.4	75	-0.011787	-0.020322	0.82643	-0.562549
0.1	18	15	0.4	75	-0.014914	-0.023486	0.805343	-0.592156
0.1	19	15	0.4	75	-0.018593	-0.026845	0.783026	-0.621132
0.1	20	15	0.4	75	-0.02288	-0.030369	0.759472	-0.649428
0.1	21	15	0.4	75	-0.027828	-0.034022	0.734677	-0.676992
0.1	22	15	0.4	75	-0.033491	-0.037761	0.708634	-0.703769
0.1	23	15	0.4	75	-0.03992	-0.041535	0.681338	-0.729698
0.1	24	15	0.4	75	-0.047167	-0.045286	0.652787	-0.754714
0.1	25	15	0.4	75	-0.05528	-0.048947	0.622979	-0.778746
0.1	26	15	0.4	75	-0.064304	-0.052443	0.591915	-0.801718
0.1	27	15	0.4	75	-0.074279	-0.055689	0.559599	-0.823547
0.1	28	15	0.4	75	-0.085239	-0.058594	0.526042	-0.844145
0.1	29	15	0.4	75	-0.097213	-0.061055	0.491257	-0.863417
0.1	30	15	0.4	75	-0.110218	-0.062962	0.455269	-0.881259
0.9	1	15	0.4	75	-0.413227	-0.474668	0.586577	-0.509765

0.9	2	15	0.4	75	-0.756797	-0.392693	0.241467	-0.463413
0.9	3	15	0.4	75	-0.892034	-0.253446	0.103202	-0.359721
0.9	4	15	0.4	75	-0.948198	-0.140244	0.042671	-0.281852
0.9	5	15	0.4	75	-0.972759	-0.04949	0.012471	-0.226146
0.9	6	15	0.4	75	-0.982376	0.026345	-0.00402	-0.185022
0.9	7	15	0.4	75	-0.98375	0.092214	-0.01347	-0.153474
0.9	8	15	0.4	75	-0.979953	0.15112	-0.01892	-0.128441
0.9	9	15	0.4	75	-0.972554	0.204912	-0.02191	-0.108022
0.9	10	15	0.4	75	-0.96243	0.254762	-0.02327	-0.090994
0.9	11	15	0.4	75	-0.950116	0.301434	-0.02351	-0.076544
0.9	12	15	0.4	75	-0.935963	0.345443	-0.02294	-0.064112
0.9	13	15	0.4	75	-0.920219	0.387141	-0.02175	-0.053303
0.9	14	15	0.4	75	-0.903069	0.426777	-0.0201	-0.043828
0.9	15	15	0.4	75	-0.884662	0.464528	-0.01808	-0.035474
0.9	16	15	0.4	75	-0.865124	0.500525	-0.01576	-0.02808
0.9	17	15	0.4	75	-0.844563	0.534865	-0.01322	-0.021518
0.9	18	15	0.4	75	-0.823078	0.567623	-0.01049	-0.015689
0.9	19	15	0.4	75	-0.800759	0.598857	-0.00762	-0.010513
0.9	20	15	0.4	75	-0.777691	0.628617	-0.00464	-0.005923
0.9	21	15	0.4	75	-0.753952	0.656943	-0.00158	-0.001865
0.9	22	15	0.4	75	-0.729619	0.683871	0.001538	0.001708
0.9	23	15	0.4	75	-0.704763	0.709433	0.00469	0.004838
0.9	24	15	0.4	75	-0.679454	0.733661	0.007856	0.007559
0.9	25	15	0.4	75	-0.653755	0.756584	0.01102	0.009903
0.9	26	15	0.4	75	-0.627731	0.778232	0.014166	0.011899
0.9	27	15	0.4	75	-0.601439	0.798635	0.01728	0.013573
0.9	28	15	0.4	75	-0.574937	0.817822	0.020351	0.014949
0.9	29	15	0.4	75	-0.548278	0.835824	0.023368	0.016048
0.9	30	15	0.4	75	-0.521512	0.852671	0.026321	0.016891

EK 8 Paralel Anahtar için Trainlm eğitim algoritması ile yapılan testin ardından çıkan hata değerleri

Anahtarın Konumu	Frekans	ε_r	t	W	S11 reel	S11 image	S12 reel	S12 image
0.1	1	12.5	0.2	125	0.000361	0.03872	-3.5E-05	0.0343238
0.1	2	12.5	0.2	125	0.00078	0.037682	0.000909	0.034632
0.1	3	12.5	0.2	125	-0.001827	0.035211	-9.7E-05	0.028827
0.1	4	12.5	0.2	125	1.84E-05	0.03376	-0.00411	0.025449
0.1	5	12.5	0.2	125	0.002972	0.033292	-0.00605	0.025265
0.1	6	12.5	0.2	125	0.004386	0.032973	-0.00557	0.025432
0.1	7	12.5	0.2	125	0.004769	0.03249	-0.0043	0.024897
0.1	8	12.5	0.2	125	0.004738	0.03171	-0.0031	0.023517
0.1	9	12.5	0.2	125	0.004582	0.030572	-0.00236	0.021408
0.1	10	12.5	0.2	125	0.004377	0.029058	-0.00224	0.018758
0.1	11	12.5	0.2	125	0.004114	0.0271855	-0.00276	0.01577
0.1	12	12.5	0.2	125	0.003774	0.024981	-0.00382	0.01259
0.1	13	12.5	0.2	125	0.003374	0.0224824	-0.00521	0.00935
0.1	14	12.5	0.2	125	0.002967	0.0197312	-0.00667	0.006142
0.1	15	12.5	0.2	125	0.002619	0.016777	-0.00799	0.003017
0.1	16	12.5	0.2	125	0.00239	0.01368	-0.00892	1E-06
0.1	17	12.5	0.2	125	0.002326	0.010508	-0.00933	-0.002888
0.1	18	12.5	0.2	125	0.002449	0.007334	-0.00908	-0.005649
0.1	19	12.5	0.2	125	0.002761	0.004226	-0.00821	-0.008239
0.1	20	12.5	0.2	125	0.003247	0.001252	-0.00675	-0.010633
0.1	21	12.5	0.2	125	0.003881	-0.001535	-0.00486	-0.012777
0.1	22	12.5	0.2	125	0.004629	-0.004092	-0.0027	-0.014612
0.1	23	12.5	0.2	125	0.005463	-0.006388	-0.00052	-0.016072
0.1	24	12.5	0.2	125	0.006364	-0.008411	0.001421	-0.017098
0.1	25	12.5	0.2	125	0.007332	-0.010155	0.002844	-0.017653
0.1	26	12.5	0.2	125	0.008384	-0.01163	0.003474	-0.017708
0.1	27	12.5	0.2	125	0.009573	-0.01285	0.003035	-0.017276
0.1	28	12.5	0.2	125	0.010975	-0.013832	0.001297	-0.016399
0.1	29	12.5	0.2	125	0.012695	-0.014594	-0.00196	-0.01517
0.1	30	12.5	0.2	125	0.014866	-0.015151	-0.00686	-0.01368
0.9	1	12.5	0.2	125	0.007838	0.041376	-0.01221	0.036068
0.9	2	12.5	0.2	125	0.018095	0.008446	-0.01174	0.002193
0.9	3	12.5	0.2	125	0.017614	0.024626	-0.01457	0.019968
0.9	4	12.5	0.2	125	0.017138	0.031032	-0.01737	0.029462
0.9	5	12.5	0.2	125	0.014513	0.030301	-0.0205	0.031939
0.9	6	12.5	0.2	125	0.010446	0.025746	-0.02356	0.029861
0.9	7	12.5	0.2	125	0.005505	0.020117	-0.02575	0.025543
0.9	8	12.5	0.2	125	0.000465	0.015838	-0.02615	0.021404
0.9	9	12.5	0.2	125	-0.002794	0.015689	-0.02368	0.0208018
0.9	10	12.5	0.2	125	-0.001428	0.020773	-0.01832	0.0256805
0.9	11	12.5	0.2	125	0.002148	0.025652	-0.01341	0.030174
0.9	12	12.5	0.2	125	0.003143	0.027364	-0.01111	0.030916
0.9	13	12.5	0.2	125	0.002259	0.027665	-0.01075	0.030378

0.9	14	12.5	0.2	125	0.001027	0.027504	-0.01148	0.03003
0.9	15	12.5	0.2	125	8.7E-05	0.026912	-0.01276	0.030047
0.9	16	12.5	0.2	125	-0.000444	0.025721	-0.01421	0.030221
0.9	17	12.5	0.2	125	-0.00059	0.023871	-0.01561	0.030312
0.9	18	12.5	0.2	125	-0.000475	0.021441	-0.01679	0.030125
0.9	19	12.5	0.2	125	-0.000245	0.018602	-0.01763	0.02952
0.9	20	12.5	0.2	125	-5E-06	0.015619	-0.01805	0.028407
0.9	21	12.5	0.2	125	0.000169	0.012756	-0.01801	0.026737
0.9	22	12.5	0.2	125	0.000259	0.01029	-0.01745	0.024499
0.9	23	12.5	0.2	125	0.000267	0.008364	-0.01638	0.021707
0.9	24	12.5	0.2	125	0.000235	0.007043	-0.01478	0.0184
0.9	25	12.5	0.2	125	0.000182	0.006227	-0.01268	0.014634
0.9	26	12.5	0.2	125	6.7E-05	0.005669	-0.01016	0.010482
0.9	27	12.5	0.2	125	-0.000244	0.005047	-0.00729	0.006022
0.9	28	12.5	0.2	125	-0.001005	0.003988	-0.00417	0.001339
0.9	29	12.5	0.2	125	-0.002522	0.002161	-0.00092	-0.00348
0.9	30	12.5	0.2	125	-0.005173	-0.000632	0.002328	-0.008352
0.1	1	15	0.4	75	0.001776	-0.005574	0.00011	-0.018536
0.1	2	15	0.4	75	0.004982	-0.00432	0.001621	-0.01042
0.1	3	15	0.4	75	0.004021	-0.004641	0.003182	-0.008818
0.1	4	15	0.4	75	0.000697	-0.005739	0.001543	-0.010806
0.1	5	15	0.4	75	0.001694	-0.005581	-0.00243	-0.009112
0.1	6	15	0.4	75	0.00346	-0.004653	-0.00367	-0.005149
0.1	7	15	0.4	75	0.004146	-0.003564	-0.00287	-0.001337
0.1	8	15	0.4	75	0.003998	-0.002469	-0.00155	0.00168
0.1	9	15	0.4	75	0.003445	-0.001446	-0.00035	0.003891
0.1	10	15	0.4	75	0.002906	-0.000594	0.000485	0.005371
0.1	11	15	0.4	75	0.002792	-2.99E-05	0.000916	0.006199
0.1	12	15	0.4	75	0.003417	0.0001581	0.001061	0.00646
0.1	13	15	0.4	75	0.00479	2E-06	0.00108	0.00637
0.1	14	15	0.4	75	0.006505	-0.000306	0.001097	0.006252
0.1	15	15	0.4	75	0.007974	-0.000504	0.001105	0.006461
0.1	16	15	0.4	75	0.008831	-0.000414	0.001148	0.007116
0.1	17	15	0.4	75	0.009066	5E-06	0.00129	0.008129
0.1	18	15	0.4	75	0.008863	0.000709	0.001657	0.009296
0.1	19	15	0.4	75	0.00842	0.001648	0.002354	0.010422
0.1	20	15	0.4	75	0.007884	0.002782	0.003448	0.011378
0.1	21	15	0.4	75	0.007334	0.004089	0.004903	0.012082
0.1	22	15	0.4	75	0.006813	0.005549	0.006616	0.012529
0.1	23	15	0.4	75	0.00634	0.007145	0.008432	0.012738
0.1	24	15	0.4	75	0.005933	0.00885	0.010143	0.012764
0.1	25	15	0.4	75	0.005609	0.01063	0.011511	0.012666
0.1	26	15	0.4	75	0.005397	0.012446	0.012285	0.012528
0.1	27	15	0.4	75	0.005338	0.014246	0.012201	0.012407
0.1	28	15	0.4	75	0.005493	0.01598	0.011008	0.012355
0.1	29	15	0.4	75	0.00594	0.017594	0.008493	0.012397
0.1	30	15	0.4	75	0.006778	0.019035	0.004491	0.012499

0.9	1	15	0.4	75	0.032527	-0.014562	0.043363	-0.018355
0.9	2	15	0.4	75	-0.012483	-0.007187	0.078473	-0.011227
0.9	3	15	0.4	75	0.003564	-0.040274	0.060988	-0.045609
0.9	4	15	0.4	75	0.012928	-0.042556	0.053694	-0.049168
0.9	5	15	0.4	75	0.016609	-0.033717	0.04777	-0.039734
0.9	6	15	0.4	75	0.016736	-0.028605	0.040234	-0.031898
0.9	7	15	0.4	75	0.01416	-0.030104	0.031751	-0.029616
0.9	8	15	0.4	75	0.009603	-0.03547	0.023551	-0.031309
0.9	9	15	0.4	75	0.004264	-0.040472	0.016789	-0.033358
0.9	10	15	0.4	75	0.00062	-0.040672	0.012711	-0.031176
0.9	11	15	0.4	75	0.000626	-0.035824	0.011034	-0.024276
0.9	12	15	0.4	75	3E-06	-0.032023	0.008862	-0.019407
0.9	13	15	0.4	75	-0.003931	-0.030291	0.005582	-0.017693
0.9	14	15	0.4	75	-0.009321	-0.028797	0.002086	-0.016598
0.9	15	15	0.4	75	-0.014708	-0.027018	-0.00117	-0.015052
0.9	16	15	0.4	75	-0.019506	-0.025215	-0.004	-0.012985
0.9	17	15	0.4	75	-0.023477	-0.023775	-0.0062	-0.010649
0.9	18	15	0.4	75	-0.026492	-0.022973	-0.00748	-0.008384
0.9	19	15	0.4	75	-0.028511	-0.022947	-0.00751	-0.006516
0.9	20	15	0.4	75	-0.029539	-0.023647	-0.00617	-0.005246
0.9	21	15	0.4	75	-0.029718	-0.024823	-0.00377	-0.0045017
0.9	22	15	0.4	75	-0.029361	-0.026101	-0.00114	-0.0039436
0.9	23	15	0.4	75	-0.028877	-0.027123	0.000918	-0.0032051
0.9	24	15	0.4	75	-0.028496	-0.027661	0.002062	-0.0021281
0.9	25	15	0.4	75	-0.028315	-0.027614	0.002435	-0.000773
0.9	26	15	0.4	75	-0.028289	-0.027032	0.002362	0.000717
0.9	27	15	0.4	75	-0.028361	-0.026085	0.002135	0.002213
0.9	28	15	0.4	75	-0.028553	-0.025022	0.001937	0.003633
0.9	29	15	0.4	75	-0.029002	-0.024164	0.001853	0.004935
0.9	30	15	0.4	75	-0.029958	-0.023811	0.001893	0.006101

EK 9 MEMS YSA Matlab Kodu

```
load serigiris.mat
```

```
load sericikis.mat
```

```
load testserigiris.mat
```

```
load testsericikis.mat
```

```
girish=serigiris';
```

```
out=sericikis';
```

```
datamse=0;
```

```
datasse=0;
```

```
testmse=0;
```

```
testsse=0;
```

```
disp('Selection Function name Algorithm')
```

```
disp(' 1  trainb Batch training with weight & bias learning rules')
```

```
disp(' 2  trainbfg BFGS quasi-Newton backpropagation')
```

```
disp(' 3  trainbr Bayesian regularization')
```

```
disp(' 4  trainc Cyclical order incremental training w/learning functions')
```

```
disp(' 5  traincgb Powell -Beale conjugate gradient backpropagation')
```

```
disp(' 6  traincgf Fletcher-Powell conjugate gradient backpropagation')
```

```
disp(' 7  traincgp Polak-Ribiere conjugate gradient backpropagation')
```

```
disp(' 8  traingd Gradient descent backpropagation')
```

```
disp(' 9  traingdm Gradient descent with momentum backpropagation')
```

```
disp(' 10 traingda Gradient descent with adaptive lr backpropagation')
```

```
disp(' 11 traingdx Gradient descent w/momentum & adaptive lr backpropagation')
```

```
disp(' 12 trainlm Levenberg-Marquardt backpropagation')
```

```
disp(' 13 trainoss One step secant backpropagation')
```

```
disp(' 14 trainr Random order incremental training w/learning functions')
```

```

disp(' 15 trainrp Resilient backpropagation (Rprop)')
disp(' 16 trainscg Scaled conjugate gradient backpropagation')
menu=input(' 1-16 arasi egitim foksiyonu seçiniz=')
switch (menu)
    case 1,
        net1=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainb');
        net1.TrainParam.epochs= 5000;
        net1.TrainParam.goal= 0
        net1.TrainParam.show= 1000;
        net1=train(net1,girish,out);
        datamse=mse(sericikis'-sim(net1,serigiris'))
        datasse=sse(sericikis'-sim(net1,serigiris'))
        datamatrix=(sim(net1,serigiris'))';
        testmse=mse(testsericikis'-sim(net1,testserigiris'))
        testsse=sse(testsericikis'-sim(net1,testserigiris'))
        testmatrix=(sim(net1,testserigiris'))';
    case 2,
        net2=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainbfg');
        net2.TrainParam.epochs= 5000;
        net2.TrainParam.show= 1000;
        net2.TrainParam.goal= 0;
        net2.TrainParam.time= Inf;
        net2.TrainParam.min_grad= 1.0000e-006;
        net2.TrainParam.max_fail= 5;
        net2.TrainParam.searchFcn= 'srchbac';

```

```

net2.TrainParam.scale_tol= 20;
net2.TrainParam.alpha= 0.0010;
net2.TrainParam.beta= 0.1000;
net2.TrainParam.delta= 0.0100;
net2.TrainParam.gama= 0.1000;
net2.TrainParam.low_lim= 0.1000;
net2.TrainParam.up_lim= 0.5000;
net2.TrainParam.maxstep= 100;
net2.TrainParam.minstep= 1.0000e-006;
net2.TrainParam.bmax= 26;
[net2,g2,cd2]=train(net2,girish,out);
datamse=mse(sericikis'-sim(net2,serigiris'))
datasse=sse(sericikis'-sim(net2,serigiris'))
datamtris=(sim(net2,serigiris'))';
testmse=mse(testsericikis'-sim(net2,testserigiris'))
testsse=sse(testsericikis'-sim(net2,testserigiris'))
testmatris=(sim(net2,testserigiris'))';
case 3,
net3=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainbr');
net3.TrainParam.epochs= 75;
net3.TrainParam.show= 25;
net3.TrainParam.goal= 0.1;
net3.TrainParam.time= Inf;
net3.TrainParam.min_grad= 1.0000e-010;
net3.TrainParam.max_fail= 5;

```

```

net3.TrainParam.mem_reduc= 1;

net3.TrainParam.mu= 0.3;

%net3.TrainParam.mu= 0.0050;

net3.TrainParam.mu_dec= 0.1000;

net3.TrainParam.mu_inc= 10;

net3.TrainParam.mu_max= 1.0000e+010;

[net3,g3,cd3]=train(net3,girish,out);

datamse=mse(sericikis'-sim(net3,serigiris'))

datasse=sse(sericikis'-sim(net3,serigiris'))

datamatrix=(sim(net3,serigiris'))';

testmse=mse(testsericikis'-sim(net3,testserigiris'))

testsse=sse(testsericikis'-sim(net3,testserigiris'))

testmatrix=(sim(net3,testserigiris'))';

case 4,

net4=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainc');

net4.TrainParam.epochs= 100;

net4.TrainParam.goal= 0;

net4.TrainParam.show= 25;

net4.TrainParam.time= Inf;

[net4,g4,cd4]=train(net4,girish,out);

datamse=mse(sericikis'-sim(net4,serigiris'))

datasse=sse(sericikis'-sim(net4,serigiris'))

datamatrix=(sim(net4,serigiris'))';

testmse=mse(testsericikis'-sim(net4,testserigiris'))

testsse=sse(testsericikis'-sim(net4,testserigiris'))

```

```

testmatris=(sim(net4,testserigiris'))';

case 5,

net5=newff(minmax(girish),[25 4],{'logsig','tansig'},'traincgb');

net5.TrainParam.epochs= 1000;

net5.TrainParam.show= 200;

net5.TrainParam.goal= 0;

net5.TrainParam.time= Inf;

net5.TrainParam.min_grad= 1.0000e-006;

net5.TrainParam.max_fail= 5;

net5.TrainParam.searchFcn= 'srchcha';

net5.TrainParam.scale_tol= 20;

net5.TrainParam.alpha= 0.0010;

net5.TrainParam.beta= 0.1000;

net5.TrainParam.delta= 0.0100;

net5.TrainParam.gama= 0.1000;

net5.TrainParam.low_lim= 0.1000;

net5.TrainParam.up_lim= 0.5000;

net5.TrainParam.bmax= 26;

[net5,g5,cd5]=train(net5,girish,out);

datamse=mse(sericikis'-sim(net5,serigiris'))

datasse=sse(sericikis'-sim(net5,serigiris'))

datamtris=(sim(net5,serigiris'))';

testmse=mse(testsericikis'-sim(net5,testserigiris'))

testsse=sse(testsericikis'-sim(net5,testserigiris'))

testmatris=(sim(net5,testserigiris'))';

```

case 6,

```

net6=newff(minmax(girish),[25 4],{'logsig','tansig'},'traincgf');

net6.TrainParam.epochs= 2000;

net6.TrainParam.show= 400;

net6.TrainParam.goal= 0;

net6.TrainParam.time= Inf;

net6.TrainParam.min_grad= 1.0000e-006;

net6.TrainParam.max_fail= 5;

net6.TrainParam.searchFcn= 'srchcha';

net6.TrainParam.scale_tol= 20;

net6.TrainParam.alpha= 0.0010;

net6.TrainParam.beta= 0.1000;

net6.TrainParam.delta= 0.0100;

net6.TrainParam.gama= 0.1000;

net6.TrainParam.low_lim= 0.1000;

net6.TrainParam.up_lim= 0.5000;

net6.TrainParam.maxstep= 100;

net6.TrainParam.minstep= 1.0000e-006;

net6.TrainParam.bmax= 26;

[net6,g6,cd6]=train(net6,girish,out);

datamse=mse(sericikis'-sim(net6,serigiris'))

datasse=sse(sericikis'-sim(net6,serigiris'))

datamtris=(sim(net6,serigiris'))';

testmse=mse(testsericikis'-sim(net6,testserigiris'))

testsse=sse(testsericikis'-sim(net6,testserigiris'))

```

```

testmatris=(sim(net6,testserigiris'))';

case 7,

net7=newff(minmax(girish),[25 4],{'logsig','tansig'},'traincgp');

net7.TrainParam.epochs= 2000;

net7.TrainParam.show= 400;

net7.TrainParam.goal= 0;

net7.TrainParam.time= Inf;

net7.TrainParam.min_grad= 1.0000e-006;

net7.TrainParam.max_fail= 5;

net7.TrainParam.searchFcn= 'srchcha';

net7.TrainParam.scale_tol= 20;

net7.TrainParam.alpha= 0.0010;

net7.TrainParam.beta= 0.1000;

net7.TrainParam.delta= 0.0100;

net7.TrainParam.gama= 0.1000;

net7.TrainParam.low_lim= 0.1000;

net7.TrainParam.up_lim= 0.5000;

net7.TrainParam.maxstep= 100;

net7.TrainParam.minstep= 1.0000e-006;

net7.TrainParam.bmax= 26;

[net7,g7,cd7]=train(net7,girish,out);

datamse=mse(sericikis'-sim(net7,serigiris'))

datasse=sse(sericikis'-sim(net7,serigiris'))

datamatris=(sim(net7,serigiris'))';

testmse=mse(testsericikis'-sim(net7,testserigiris'))

```

```
testsse=sse(testsericikis'-sim(net7,testserigiris'))
```

```
testmatris=(sim(net7,testserigiris'))';
```

case 8,

```
net8=newff(minmax(girish),[25 4],{'logsig','tansig'},'traingd');
```

```
net8.trainParam.epochs= 5000;
```

```
net8.trainParam.goal= 0;
```

```
net8.trainParam.lr=0.01;
```

```
net8.trainParam.max_fail= 5;
```

```
net8.trainParam.min_grad= 1.0000e-010;
```

```
net8.trainParam.show= 1000;
```

```
net8.trainParam.time= Inf;
```

```
[net8,g8,cd8]=train(net8,girish,out);
```

```
datamse=mse(sericikis'-sim(net8,serigiris'))
```

```
datasse=sse(sericikis'-sim(net8,serigiris'))
```

```
datamatris=(sim(net8,serigiris'))';
```

```
testmse=mse(testsericikis'-sim(net8,testserigiris'))
```

```
testsse=sse(testsericikis'-sim(net8,testserigiris'))
```

```
testmatris=(sim(net8,testserigiris'))';
```

case 9,

```
net9=newff(minmax(girish),[25 4],{'logsig','tansig'},'traingdm');
```

```
net9.trainParam.lr=0.02;
```

```
net9.trainParam.epochs= 1000;
```

```
net9.trainParam.goal= 0.0001;
```

```
%net9.trainParam.lr= 0.100;
```

```
net9.trainParam.max_fail= 5;
```

```

net9.trainParam.mc= 0.8;

net9.trainParam.min_grad= 1.0000e-010;

net9.trainParam.show= 200;

net9.trainParam.time= Inf;

[net9,g9,cd9]=train(net9,girish,out);

datamse=mse(sericikis'-sim(net9,serigiris'))

datasse=sse(sericikis'-sim(net9,serigiris'))

datamatrix=(sim(net9,serigiris'))';

testmse=mse(testsericikis'-sim(net9,testserigiris'))

testsse=sse(testsericikis'-sim(net9,testserigiris'))

testmatrix=(sim(net9,testserigiris'))';
case 10,

net10=newff(minmax(girish),[25 4],{'logsig','tansig'},'traingda');

net10.trainParam.epochs= 1000;

net10.trainParam.goal= 0;

net10.trainParam.lr= 0.005;

net10.trainParam.lr_inc= 1.0500;

net10.trainParam.lr_dec= 0.7000;

net10.trainParam.max_fail= 5;

net10.trainParam.max_perf_inc= 1.0400;

net10.trainParam.min_grad= 1.0000e-006;

net10.trainParam.show= 100;

net10.trainParam.time= Inf;

[net10,g10,cd10]=train(net10,girish,out);

datamse=mse(sericikis'-sim(net10,serigiris'))

```

```

datasse=sse(sericikis'-sim(net10,serigiris'))

datamatrix=(sim(net10,serigiris'))';

testmse=mse(testsericikis'-sim(net10,testserigiris'))

testsse=sse(testsericikis'-sim(net10,testserigiris'))

testmatrix=(sim(net10,testserigiris'))';

case 11,

net11=newff(minmax(girish),[25 4],{'logsig','tansig'},'traingdx');

net11.trainParam.epochs= 1000;

net11.trainParam.goal= 0.00001;

net11.trainParam.lr= 0.05;
net11.trainParam.lr_dec= 0.5000;

net11.trainParam.lr_inc= 1.0500;

net11.trainParam.max_fail= 5;

net11.trainParam.max_perf_inc= 1.0400;

net11.trainParam.mc= 0.3;

net11.trainParam.min_grad= 1.0000e-006;

net11.trainParam.show= 200;

net11.trainParam.time= Inf;

[net11,g11,cd11]=train(net11,girish,out);

datamse=mse(sericikis'-sim(net11,serigiris'))

datasse=sse(sericikis'-sim(net11,serigiris'))

datamatrix=(sim(net11,serigiris'))';

testmse=mse(testsericikis'-sim(net11,testserigiris'))

testsse=sse(testsericikis'-sim(net11,testserigiris'))

testmatrix=(sim(net11,testserigiris'))';

case 12,

```

```

%(Levenberg-Marquardt backpropagation)

net12=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainlm');

net12.trainParam.epochs= 500;

net12.trainParam.goal= 0.0001;

net12.trainParam.max_fail= 5;

net12.trainParam.mem_reduc= 1;

net12.trainParam.min_grad= 1.0000e-010;

net12.trainParam.mu= 0.01;
net12.trainParam.mu_dec= 0.1;

net12.trainParam.mu_inc= 10;

net12.trainParam.mu_max= 1.0000e+010;

net12.trainParam.show= 100;

net12.trainParam.time= Inf;

[net12,g12,cd12]=train(net12,girish,out);

datamse=mse(sericikis'-sim(net12,serigiris'))

datasse=sse(sericikis'-sim(net12,serigiris'))

datamatrix=(sim(net12,serigiris'))';

testmse=mse(testsericikis'-sim(net12,testserigiris'))

testsse=sse(testsericikis'-sim(net12,testserigiris'))

testmatrix=(sim(net12,testserigiris'))';

case 13,

net13=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainoss');

net13.trainParam.epochs= 1000;

net13.trainParam.show= 100;

net13.trainParam.goal= 0;

```

```

net13.trainParam.time= Inf;

net13.trainParam.min_grad= 1.0000e-006;

net13.trainParam.max_fail= 5;

net13.trainParam.searchFcn= 'srchbac';

net13.trainParam.scale_tol= 20;

net13.trainParam.alpha= 0.0010;

net13.trainParam.beta= 0.1000;

net13.trainParam.delta= 0.0100;

net13.trainParam.gama= 0.1000;

net13.trainParam.low_lim= 0.1000;

net13.trainParam.up_lim= 0.5000;

net13.trainParam.maxstep= 100;

net13.trainParam.minstep= 1.0000e-006;

net13.trainParam.bmax= 26;

[net13,g13,cd13]=train(net13,girish,out);

datamse=mse(sericikis'-sim(net13,serigiris'))

datasse=sse(sericikis'-sim(net13,serigiris'))

datamtris=(sim(net13,serigiris'))';

testmse=mse(testsericikis'-sim(net13,testserigiris'))

testsse=sse(testsericikis'-sim(net13,testserigiris'))

testmatris=(sim(net13,testserigiris'))';

case 14,

net14=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainr');

net14.trainParam.epochs= 100;

net14.trainParam.goal= 0;

```

```

net14.trainParam.show= 25;

net14.trainParam.time= Inf;

[net14,g14,cd14]=train(net14,girish,out);

datamse=mse(sericikis'-sim(net14,serigiris'))

datasse=sse(sericikis'-sim(net14,serigiris'))

datamatrix=(sim(net14,serigiris'))';
testmse=mse(testsericikis'-sim(net14,testserigiris'))

testsse=sse(testsericikis'-sim(net14,testserigiris'))

testmatrix=(sim(net14,testserigiris'))';

case 15,

net15=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainrp');

net15.trainParam.epochs= 5000;

net15.trainParam.show= 1000;

net15.trainParam.goal= 0.0001;

net15.trainParam.time= Inf;

net15.trainParam.min_grad= 1.0000e-006;,

net15.trainParam.max_fail= 5;

net15.trainParam.delt_inc= 1.2000;

net15.trainParam.delt_dec= 0.5000;

net15.trainParam.delta0= 0.0700;

net15.trainParam.deltamax= 50;

[net15,g15,cd15]=train(net15,girish,out);

datamse=mse(sericikis'-sim(net15,serigiris'))

datasse=sse(sericikis'-sim(net15,serigiris'))

datamatrix=(sim(net15,serigiris'))';

testmse=mse(testsericikis'-sim(net15,testserigiris'))

```

```

testsse=sse(testsericikis'-sim(net15,testserigiris'))

testmatris=(sim(net15,testserigiris'))';

case 16,

net16=newff(minmax(girish),[25 4],{'logsig','tansig'},'trainscg');

net16.trainParam.epochs= 1000;

net16.trainParam.show= 200;

net16.trainParam.goal= 0;

net16.trainParam.time= Inf;

net16.trainParam.min_grad= 1.0000e-006;

net16.trainParam.max_fail= 5;

net16.trainParam.sigma= 5.0000e-005;

net16.trainParam.lambda= 5.0000e-007;

[net16,g16,cd16]=train(net16,girish,out);

datamse=mse(sericikis'-sim(net16,serigiris'))

datasse=sse(sericikis'-sim(net16,serigiris'))

datamatris=(sim(net16,serigiris'))';

testmse=mse(testsericikis'-sim(net16,testserigiris'))

testsse=sse(testsericikis'-sim(net16,testserigiris'))

testmatris=(sim(net16,testserigiris'))';

otherwise ,

disp('1-16 arasi sayi girerek egitim fonksiyonu seçmelisiniz')

end

```

Not: Aynı Kod paralel Anahtar içinde kullanılmıştır.

EK 10 MEMS-YSA Grafik Arayüzü Matlab Kodu

```

Clc
disp(' ')
disp(' (' ' ')
disp(' ')

serpar = input('MEMS Turu [1-Seri 2-Paralel] : ');

if serpar==1
    mems='Seri';
else
    mems='Paralel';
end

disp(' ')
disp(' (.....Giris Parametreleri.....')

veri1 = input('Anahtar Konumunu [0.1-Acik 0.9-Kapali]... : ');

if veri1==0.1
    anahtar='Acik';
else
    anahtar='Kapali';
end

veri2 = input('Dielektrik Katsayisi..... : ');

veri3 = input('Dielektrik Kalinligi(µm)..... : ');

veri4 = input('Temas Alani(µm2)..... : ');

disp(' (.....Giris Parametreleri Sonu.....')

disp(' ')

io = input('Yuklenecek Veri Turu [1-Egitim 2-Test]... : ');

switch (io)

    case 1;
        if serpar==1
            load serigiris.mat
            load sericikis.mat
            a=serigiris;
            b=sericikis;
        else
            load paralelgiris.mat
            load paralelcikis.mat

```

```

a=paralelgiris;
b=paralelcikis;
end
tur=' Egitim ';
tur2='Egitim ';

case 2;
    if serpar==1
        load testserigiris.mat
        load testsericikis.mat
        a=testserigiris;
        b=testsericikis;
    else
        load testparalelgiris.mat
        load testparalelcikis.mat
        a=testparalelgiris;
        b=testparalelcikis;
    end
    tur=' Test ';
    tur2='Test ';

end

dosya = strcat(tur2,' Sonuc .xls Dosyasý [tr "?" ]... : ');

train = input(dosya,'s');

if serpar==1
    l=strcat(matlabroot,'\work\mems\seri\tr',train,'.xls');
else
    l=strcat(matlabroot,'\work\mems\paralel\tr',train,'.xls');
end

dene=xlsread(l,io);

j=0;

veri=0;

for i=1:size(a)
    if (a(i,1)==veri1) & (a(i,3)==veri2) & (a(i,4)==veri3) & (a(i,5)==veri4)
        j=j+1;
        for k=1:4
            veri(j,k)=b(i,k);
            ysa(j,k)=dene(i,k);
        end
    end
end
end
end

```

```

baslik=strcat('itMEMS= ',mems,', Anahtar= ',anahtar,', \epsilon_r= ',num2str(veri2),',
t(\mum)= ',num2str(veri3),', \omega(\mum2)= ',num2str(veri4),tur,' Fonk.= tr',train);

if veri~=0
    tur = input('Grafik Turu [1-|Sij| 2-SijReel/SijImaginer]... : ');
    switch (tur)
        case 1;
            tur1 = input('Modulu Cizdirilecek S Parametresi [1-|S11| 2-|S12|]... : ');
            switch (tur1)
                case 1;
                    for m=1:30
                        s11modulveri(m,1)= sqrt(veri(m,1)^2 + veri(m,2)^2);
                        s11modulya(m,1)= sqrt(ya(m,1)^2+ ya(m,2)^2);
                    end

                    plot(1:1:30,s11modulveri,'ro',1:1:30,s11modulya,'b*');title(baslik);legend('HFSS','YSA
                    ',-1);xlabel('Frequency [GHz]');ylabel('|S11|');
                    case 2;
                        for m=1:30
                            s12modulveri(m,1)= sqrt(veri(m,3)^2 + veri(m,4)^2);
                            s12modulya(m,1)= sqrt(ya(m,3)^2+ ya(m,4)^2);
                        end

                        plot(1:1:30,s12modulveri,'ro',1:1:30,s12modulya,'b*');title(baslik);legend('HFSS','YSA
                        ',-1);xlabel('Frequency [GHz]');ylabel('|S12|');
                        end
                    case 2;
                        sparam = input('Cizdirilecek S Parametresi [1-S11reel 2-S11imaginer 3-S12reel
                        4-S12imaginer]... : ');

                        plot(1:1:30,veri(:,sparam),'ro',1:1:30,ya(:,sparam),'b*');title(baslik);legend('HFSS','YS
                        A',-1);xlabel('Frequency [GHz]');

                        switch (sparam)
                            case 1;
                                ylabel 'S11reel'
                            case 2;
                                ylabel 'S11imaginer'
                            case 3;
                                ylabel 'S12reel'
                            case 4;
                                ylabel 'S12imaginer'
                        end
                    end
                else
                    disp ('Egitim/Test Secimine Gore Giris Parametreleri Hatali')
                end
            end
        end
    end
end

```

ÖZGEÇMİŞ

Doğum tarihi	04.12.1982
Doğum yeri	Tokat
Lise	1996–1999 Sivas Fen Lisesi
Lisans	2000–2005 Yıldız Teknik Üniversitesi Elektrik-Elektronik Fak. Elektronik ve Hab. Mühendisliği Bölümü
Yüksek Lisans	2005–2007 Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Hab. A.B.D., Haberleşme Programı

Çalıştığı kurum(lar)

2005-Devam ediyor Türksat Uydu Haberleşme ve Kablo TV A.Ş