

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DGS HATLARININ YAPAY SİNİR AĞLARI YÖNTEMİ İLE MODELLENMESİ

OĞUZ MEHMET KILIÇ

**YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI**

**DANIŞMAN
DOÇ. DR. SALİH DEMİREL**

İSTANBUL, 2015

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DGS HATLARININ YAPAY SİNİR AĞLARI YÖNTEMİ İLE MODELLENMESİ

Oğuz Mehmet KILIÇ tarafından hazırlanan tez çalışması 20.11.2015 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç.Dr. Salih DEMİREL
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç.Dr. Salih DEMİREL
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Hakan Paşa PARTAL
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Tolga ENSARİ
İstanbul Üniversitesi

ÖNSÖZ

Bu çalışmada bana gerekli yardımı yapan ve moral veren, takıldığım noktalarda hiç çekinmeden danışabildiğim Hocam Doç. Dr. Salih DEMİREL'e, yardımları için Peyman MAHOUTI'ye, Mehmet Ali BELEN'e ve Alper ÇALIŞKAN'a, bu süreçte beni hiç yalnız bırakmayan aileme ve arkadaşlarıma çok teşekkür ederim.

Kasım, 2015

Oğuz Mehmet KILIÇ

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ.....	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET	xi
ABSTRACT	xii
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı.....	1
1.3 Hipotez.....	2
BÖLÜM 2	
YAPAY SİNİR AĞLARI	4
2.1 Yapay Sinir Ağlarının Tarihçesi	4
2.2 Yapay Sinir Ağlarının Avantaj ve Dezavantajları	5
2.2.1 Avantajları:.....	5
2.2.2 Dezavantajları:	6
2.3 Uygulamada İzlenmesi Gereken Ana Adımlar	6
2.4 Yapay Sinir Ağlarının Genel Yapısı.....	7
2.4.1 Giriş Katmanı.....	7
2.4.2 Çıkış Katmanı.....	8
2.4.3 Ara (Gizli) Katman	8
2.5 Yapay Sinir Ağlarının Tanımı ve Modeli.....	8
2.5.1 Yapay Sinir Ağlarının Tanımı	8
2.5.2 Nöronun Biyolojik Yapısı ve Nöron Modeli	9
2.5.3 Öğrenme Kuralı	11

2.5.4	Perceptron (Algılayıcı)	11
2.5.5	Genelleştirilmiş Regresyon Sinir Ağları (GRNN).....	13
2.5.5.1	Genel Tanım.....	13
2.5.5.2	Algoritma	14
2.5.5.3	Düzeltilme Parametresinin Seçimi.....	16
2.5.6	Multilayer Perceptron (MLP) (Çok Katmanlı Algılayıcı).....	19
2.5.6.1	Genel Tanım.....	19
2.5.6.2	Çok Katmanlı Algılayıcıların Çalışma Alanları	21
BÖLÜM 3		
YAPAY SİNİR AĞLARI UYGULAMALARI VE SONUÇLAR.....		22
3.1	Kazınmış Toprak Yapısı	22
3.2	DGS hattı basit yapısı ve avantajları	23
3.3	Matlab NNTOOL Aracı Kullanılarak FR4 Taban Malzemesi İçin En Uygun Eğitim Yöntemine Karar Verilmesi	24
3.4	YSA'nın eğitilmesi	31
BÖLÜM 4		
DGS DEVRE ÜRETİMİ ve ÖLÇÜMLERİ.....		44
4.1	RF yükselteçler	45
4.1.1	IP2 / IP3	46
4.2	DGS ile RF Yükselteçlerde Harmonik Bastırma	47
4.3	Üç Katlı Yapı Olması Durumu	54
4.4	Devre Üretimi ve Ölçümü	56
BÖLÜM 5		
SONUÇ VE ÖNERİLER		62
KAYNAKLAR.....		64
ÖZGEÇMİŞ.....		65

SİMGE LİSTESİ

a_1	Giren dalga
a_2	Giren dalga
b_1	Yansıyan dalga
b_2	Yansıyan dalga
F	Gürültü parametresi
$F_{\min}$	Minimum gürültü parametresi
G_A	Elde edilebilir güç kazancı
G_P	Güç kazancı
G_T	Dönüştürücü kazancı
N	Gürültü vektörü
P_L	Yüke dağıtılan güç
P_{AVS}	Kaynaktan elde edilebilir güç
P_{IN}	Ağa giren güç
P_{AVN}	Ağdan elde edilebilir güç
R_N	Gürültü direnci
r_n	Gürültü direnci
Γ_L	Yük yansıma katsayısı
Γ_S	Yansıma katsayısı
Γ_{opt}	Optimum yansıma katsayısı
Γ_{IN}	Giriş tarafındaki yansıma katsayısı
Γ_{OUT}	Çıkış tarafındaki yansıma katsayısı
S_{11}	Uygun çıkış sonlandırma ile giriş yansıma katsayısı
S_{21}	Uygun çıkış sonlandırma ile ileri iletim katsayısı
S_{22}	Uygun giriş sonlandırma ile çıkış yansıma katsayısı
S_{12}	Uygun giriş sonlandırma ile ters iletim katsayısı
Z_L	Yük empedansı
Z_1	Jeneratör empedansı
Z_0	Hat empedansı
ζ	Yayılma parametresi

KISALTMA LİSTESİ

Ca	Kalsiyum
CAD	Bilgisayar destekli tasarım
DGS	DefectedGroundStructure
exp	$e^{\wedge}$
GRNN	Genel regresyon sinir ağı
Hz	Hertz
kg	Kilogram
mA	Mili amper
MLP	Çok katmanlı algılayıcı
m ²	Metre kare
mse	Ortalama hata oranı
Na	Sodyum
RF	Radio frequency
RL	Dönüş kaybı
S	Saçılma
V	Volt
VSWR	Duran dalga oranı
YSA	Yapay sinir ağı

ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1 Üç katmanlı tam birleştirilmiş yapay sinir ağı.....	7
Şekil 2.2 Basit bir nöron yapısı.....	9
Şekil 2.3 Nöron modeli	10
Şekil 2.4 YSA'nın genel blok şeması	10
Şekil 2.5 Perceptron modelinin kullanılmasıyla elde edilen sınıflandırma	12
Şekil 2.6 GRNN sinir ağı topolojisi.....	14
Şekil 2.7 Bireysel terimler tahmini için $\sigma^2=0.1$ de GRNN katkısı	15
Şekil 2.8 GRNN paralel sinir ağı	16
Şekil 2.9 Aşırı wiggle yöntemiyle bireysel sinyaller dâhil GRNN tahmini $\sigma^2 = 0.027$..	17
Şekil 2.10 Düzgün bir çizgi boyunca GRNN tahmini $\sigma^2=1$	18
Şekil 2.11 Çok katmanlı perceptronun genel yapısı	19
Şekil 3.1 DGS hattının şematığı.....	23
Şekil 3.2 DGS hattı üstten görünümü.....	23
Şekil 3.3 train_bfg fonksiyonuna ait performans sonucu	24
Şekil 3.4 train_br fonksiyonuna ait performans sonucu	24
Şekil 3.5 train_cgb fonksiyonuna ait performans sonucu	25
Şekil 3.6 train_cgf fonksiyonuna ait performans sonucu	25
Şekil 3.7 train_cgp fonksiyonuna ait performans sonucu	26
Şekil 3.8 train_gd fonksiyonuna ait performans sonucu	26
Şekil 3.9 train_gds fonksiyonuna ait performans sonucu	27
Şekil 3.10 train_gdm fonksiyonuna ait performans sonucu	27
Şekil 3.11 train_gdx fonksiyonuna ait performans sonucu	28
Şekil 3.12 train_lm fonksiyonuna ait performans sonucu	28
Şekil 3.13 train_oss fonksiyonuna ait performans sonucu	29
Şekil 3.14 train_r fonksiyonuna ait performans sonucu.....	29
Şekil 3.15 train_rp fonksiyonuna ait performans sonucu.....	30
Şekil 3.16 train_scg fonksiyonuna ait performans sonucu	30
Şekil 3.17 DGS hatlara ait model görünümü ve değişkenlerin temsil ettiği uzunluklar	32
Şekil 3.18 Simülasyon programından DGS hat üzerindeki parametrelerin değerleri ...	33
Şekil 3.19 DGS hatlarının YSA karakutu modeli giriş ve çıkış parametreleri	35
Şekil 3.20 FR4 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi	36
Şekil 3.21 FR4 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi	37
Şekil 3.22 RO3010 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi.....	37
Şekil 3.23 RO3010 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi.....	38

Şekil 3.24	RO3035 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi.....	38
Şekil 3.25	RO3035 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi.....	39
Şekil 3.26	FR4 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi	40
Şekil 3.27	FR4 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi	40
Şekil 3.28	RO3010 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi.....	41
Şekil 3.29	RO3010 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi.....	41
Şekil 3.30	RO3035 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi.....	42
Şekil 3.31	RO3035 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi.....	42
Şekil 4.1	Üst kısım çıkış hattı 2mm genişliğinde 10mm uzunluğunda DGS hattı.....	44
Şekil 4.2	Single-ended power amplifier	46
Şekil 4.3	IP2 ve IP3 parametrelerinin grafiksel gösterimi	46
Şekil 4.4	IP2 ölçümünde kullanılan güç yükseltecinin çıkış grafiği	47
Şekil 4.5	A sınıfı güç yükselteci (a) şematik (b) baskı devre	48
Şekil 4.6	0dBm giriş gücünde Kazanç-Geri dönüş kaybı.....	49
Şekil 4.7	0dBm giriş gücü için çıkış gücü	49
Şekil 4.8	VSWR değeri	49
Şekil 4.9	Güç yükselteci güç tüketimi.....	50
Şekil 4.10	Güç ekleme verimi	50
Şekil 4.11	1dB compression point	50
Şekil 4.12	Giriş gücüne bağlı olarak transistörün akım çekim değişimi.....	51
Şekil 4.13	2.4GHz için harmonikler.....	51
Şekil 4.14	DGS hat model görünümü.....	51
Şekil 4.15	DGS devresi S parametre grafiği.....	52
Şekil 4.16	Power amplifier mikroşerit yapısı.....	52
Şekil 4.17	Power amplifier mikroşerit yapısı baskı devre görünümü-1.....	52
Şekil 4.18	Power amplifier mikroşerit yapısı baskı devre görünümü-2.....	53
Şekil 4.19	DGS'li yapı S parametresi grafiği	53
Şekil 4.20	DGS'li yapı harmonik değişimi.....	53
Şekil 4.21	Üç katlı DGS model görünümü	54
Şekil 4.22	Üç katlı DGS devresi S parametre grafiği	54
Şekil 4.23	Üç katlı DGS'li yapı kazanç ve geri dönüş kaybı.....	54
Şekil 4.24	Üç katlı DGS'li yapı harmonik değişimi	55
Şekil 4.25	Üç katlı çıkış power amplifier mikroşerit yapısı-1.....	55
Şekil 4.26	Üç katlı çıkış power amplifier mikroşerit yapısı-2.....	55
Şekil 4.27	Üç katlı çıkış power amplifier mikroşerit yapısı-3.....	56
Şekil 4.28	Basılı power amplifier devresi ve DGS yapılarının görünümü.....	57
Şekil 4.29	Power amplifier'a ait S11 parametrelerinin DGS hattına göre durumları	58
Şekil 4.30	Power amplifier'a ait S11 parametrelerinin ölçüm değerleri	58
Şekil 4.31	Power amplifier'a ait S21 parametrelerinin DGS hattına göre durumları	59
Şekil 4.32	Power amplifier'a ait S21 parametrelerinin ölçüm değerleri	59
Şekil 4.33	Tek katlı DGS hattına ait S parametre değerleri.....	60
Şekil 4.34	Üç katlı DGS hattına ait S parametre değerleri	60
Şekil 4.35	Power amplifier devresi kazancının DGS hat durumuna göre değerleri	61

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Biyolojik sinir sistemi elemanlarının YSA'daki karşılıkları.....	11
Çizelge 3.1 FR4 için fonksiyonlara ait performans değerleri.....	31
Çizelge 3.2 Değişken parametrelerin değişen değerlerinin tablosu.....	33
Çizelge 3.3 Eğitim ve Test verilerinin ayrılması Veri Kümesi 1 ve Veri Kümesi 2	34
Çizelge 3.4 S11 Sonuçları İçin Malzemelere Ait Hata Değerleri	39
Çizelge 3.5 S21 sonuçları için malzemelere ait hata değerleri.....	43
Çizelge 4.1 DGS yapısının boyutları	45
Çizelge 4.2 Bütün kuvvetlendirici modellerinin simülasyon sonuçları	48
Çizelge 4.3 FR4 Bakır Yüzey Teknik Özellikleri.....	48
Çizelge 4.4 Güç yükselteci kullanılan ekipmanları	56

DGS HATLARININ YAPAY SİNİR AĞLARI YÖNTEMİ İLE MODELLENMESİ

Oğuz Mehmet KILIÇ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç.Dr. Salih DEMİREL

Bu çalışmada, toprak düzlemi kazınmış mikroşerit iletim hatlarının yapay sinir ağları ile modellenmesi hedeflenmiştir. Bu sayede, Uydurma devreleri, Filtreler, antenler ve birçok mikrodalga devre uygulamasına uygun pratik, verimli ve maliyeti düşük bir model hazırlanmış olacaktır. Doğruluğu yüksek olması için 3D simülasyon programlar kullanılarak toprak düzlemi kazınmış mikroşerit iletim hattı modeli için birçok farklı dielektrik altlık malzemede ve birçok farklı boyutlarda iletim hattı modelinden eğitim ve test verileri oluşturulmuş ve bu veriler ile çeşitli Yapay sinir ağları modelleri eğitilmiştir. Yapay sinir ağ sonuçları ölçüm sonuçları ile de kıyaslanmıştır. Ayrıca elde edilen model ile bir A sınıfı kuvvetlendiricisinin ikinci harmoniklerinin bastırılması için bir uygulama yapılmıştır.

Anahtar kelimeler: Yapay Sinir Ağları, GRNN, MLP, Mikroşerit İletim Hattı.

ABSTRACT

DESIGN OF DEFECTED GROUND STRUCTURES WITH ARTIFICIAL NEURAL NETWORKS

Oğuz Mehmet KILIÇ

Department of Electronics and Communications Engineering
MSc. Thesis

Adviser: Assoc. Prof. Salih DEMİREL

In this thesis, it is aimed to create an artificial neural network model of a microstrip transmission line with Defected Ground structure. Thus by this mean, a simple, fast, efficient, low cost and accurate model for microwave applications such as matching networks, filter and antenna designs would be obtained. In order to have an accurate model, the training and test data for our model is obtained by using 3D EM simulation tools for different dielectric substrates with different sizes. The obtained data sets are used to ANN model of defected ground transmission lines. The simulation and ANN results are compared with measurement results at the end of the thesis. Also, an application based on ANN model of Defected Ground structure is presented for harmonic suppression of a class an amplifier.

Keywords: ANN, GRNN, MLP, Microstrip transmission lines.

YILDIZ TECHNICAL UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

1.1 Literatür Özeti

Mikroşerit anten elemanları arasındaki karşılıklı bağlaşımın (uzay ve yüzey dalgaları dolayısıyla) mikroşerit anten dizilerinin performansı üstüne önemli etkileri vardır. Birçok uygulamada, düşük karşılıklı bağlaşım seviyeleri istenen bir durumdur. Özellikle de bistatik radar sistemleri gibi alıcı ve verici antenlerinin birbirine yakın olduğu sistemlerde antenlerde parazit olmaması için antenler arasındaki izolasyonun yeterli seviyelerde olması gereklidir. Ayrıca, anten elemanları arasındaki karşılıklı bağlaşım, anten dizilerinin yan loplarnı, huzme pozisyonunu ve frekans bant genişliğini olumsuz etkileyebilir. Dizi elemanları arasındaki karşılıklı bağlaşım genel olarak uzay ve yüzey dalgalarından kaynaklanmaktadır. Dizi elemanları birbirine çok yakın olduğu zaman, uzay dalgaları çok güçlü karşılıklı bağlaşımaya yol açmaktadır fakat bu durum dizi elemanlarının arasındaki uzaklığın artmasıyla tersine dönerek uzay dalgalarının karşılıklı bağlaşımaya olan etkisinin hızlıca yok olmasıyla sonuçlanmaktadır. Diğer taraftan, yüzey dalgalarının karşılıklı bağlaşımaya etkisi anten elemanları birbirine yakınolduğu zaman uzay dalgalarından daha zayıf olsa da yüzey dalgaları, dizi elemanlarının arası açık olduğu zaman karşılıklı bağlaşımaya etki eden dominant faktör haline gelmektedir. Bu durum özellikle mikroşerit anten dizileri için geçerlidir.

1.2 Tezin Amacı

Bu tezin genel amacı olarak, toprak düzlemi kazınmış mikroşerit iletim hatlarının yapay sinir ağıları ile modellenmesi hedeflenmiştir. DGS'ler, mikroşerit antenler arasındaki toprak düzlemine dambıl şeklinin veya birleşik tümler yarıklı halka rezonatörünün

elektrik alan düzlemi yönünde kazınmasıyla oluşturuluyor. Bu yapıların antenler arasındaki bağlaşımı önemli ölçüde azaltmasına rağmen antenlerin uzak alan davranışlarının, arka lop seviyelerinin önemli ölçüde artması nedeniyle olumsuz yönde etkilendiği görülmüştür. Reflektör ve kavite kombinasyonu kullanılarak bu olumsuz etkilerin belli bir seviyeye kadar düşürülebildiği gözlemlenmiştir.

İnsan beyninin üstün özellikleri bilim adamlarının dikkatini çekmiş ve bu alanda yapılan çalışmalar sonucu ortaya Yapay Sinir Ağı kavramı ortaya çıkmıştır. YSA'lar insan sinir sistemini temel alırlar. Gerek genelleme yetenekleri, gerek öğrenbilme kapasiteleri gerekse de karmaşık problemleri çözmedeki yetenekleri YSA'ları günümüzün önemli araştırma ve çalışma konularından biri haline getirmiştir. Günümüzde YSA'lar otomotivden bankacılığa, savunma sanayiinden finansa, çok geniş bir alanda yer almakta ve kullanılmaktadır.

Bu çalışmada bir DGS hattının yapay YSA kullanılarak modellenmesi hedeflenmiştir. İnterpolasyon ve ekstrapolasyon teknikleri, GRNN ve MLP olmak üzere iki farklı yapay sinir ağı türünde uygulanmış, bu yolla DGS modellemesi yapılmıştır. Daha sonra bu DGS modeli kullanılarak bir güç yükseltecinin harmoniklerinin bastırılması hedeflenmiştir. Bu sayede güç yükselteç devrelerinde DGS yapılarına ait performans etkisi görülebilecek ve uygulanabilirliği kanıtlanmış olacaktır.

Anahtar Kelimeler: Karşılıklı Bağlaşım, Uzay Dalgaları, Yüzey Dalgaları, Birleşik Tümler Yarıklı Halka Rezonatörü (BTYHR), Dambıl, Deforme ToprakYapıları, Yapay Sinir Ağları, Sinir Sistemi

1.3 Hipotez

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri otomatik olarak gerçekleştirmek amacıyla gerçekleştirilen, biyolojik sinir sistemlerinin çalışma prensibini temel alan bir bilgi işleme tekniğidir. İnsan beyninin çalışma prensibini yapay olarak modellemeyi amaçlayan yapay sinir ağları, tek katmanlı ya da çok katmanlı olarak düzenlenebilen, çok yoğun, paralel olarak çalışan çok sayıda doğrusal olmayan yapay hücreden (işlemci ünitesi) meydana gelen, dağılmış düzende çalışan bir sistem ya

da matematiksel model olarak tanımlanır. Yapay sinir ağlarının temel yapısı, beyne, sıradan bir bilgisayarinkinden daha çok benzemektedir. Yine de birimleri gerçek nöronlar kadar karmaşık olmaması ile birlikte ağların çoğunun yapısı, beyin kabuğundaki bağlantılarla karşılaştırıldığında büyük ölçüde basit kalmaktadır.

İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettiği bilgiler ile kendi deneyimlerini oluşturur ve daha sonra benzer konularda benzer kararlar verir [1].

2.1 Yapay Sinir Ağlarının Tarihçesi

1940'larda Mc. Culloch ve Pitts nöronun, lojik fonksiyonlarını sağlayan basit bir eşik cihazı olarak modellenebileceğini gösterdi. Aynı zaman aralığında mühendislik temelleri geri besleme ve beyin fonksiyonlarından faydalanan Wiener, sibernetiğin temellerini atıyordu. 1949'da Donald Hebb hücreseel seviyede beynin öğrenme seviyesi konusunda bazı çalışmalar yaptı. Hebb'in biyolojik öğrenme kuralına göre, bir nörondan dentrit yoluyla gelen bir aksonal giriş onun bir darbe üretmesine sebep olur. Sonraki aksonal girişlerin darbe üretmesi olasılığı artar. Böylece yapılan davranışın mükâfatı ortaya çıkar. Hızlı hesaplamaya yönelik ilk YSA çalışmaları 1950'li yıllarda başlamış ve basit nöron modellerine dayalı bir hesaplama modeli 1950'lerde Rosenblatt tarafından ortaya atılmıştır. 1960'lı yıllarda Widrow ve Hoff, bu basit nöron modellerini kullanarak ilk öğrenebilen adaptif sistemler üzerinde çalışmıştır. Ancak 1969'da Minsky ve Papert yayınladıkları Perceptron adlı bir kitapta YSA yardımı ile öğrenmede ve hesaplamada aşılması zor engeller olduğunu iddia etmişler ve bu iddia YSA konusundaki çalışmaları büyük ölçüde yavaşlatmıştır [7].

1982 yılında artık YSA teknolojisinin teori kısmı yapılanmasını hemen hemen tamamlamıştı ve 1982'de J.J. Hopfield tarafından yayınlanan "Neural Networks and Physical Systems" adlı çalışma ile çağdaş YSA devri başlamış oluyordu. Bu çalışmada Hopfield nöronların karşılıklı etkileşimlerine dayanan bir nöral hesaplama modeli önermiştir. Model, bir enerji fonksiyonunu, alabileceği en az değere indiren 1. mertebe lineer olmayan diferansiyel denklemlerden oluşmuştur. Hopfield ağ

seviyesinde, tek tek nöron seviyesinde var olmayan hesaplama kapasitesinin bulunduğunu öne sürdü. Bu tür YSA'ya Hopfield Ağı denmektedir. Hopfield'in geri beslemeli YSA modelini ortaya atması ve bunun pratik optimizasyon problemlerinde kullanılabilirliğini göstermesi YSA konusundaki çalışmaları bu noktada yeniden hızlandırmıştır.

1976'da Grossberg ART (Adaptive Resonance Theory) adında bir YSA yapısı geliştirdi. O sıralarda Kohonen de "kendini düzenleyen nitelik haritası" (Self-Organizing-Maps) geliştiriordu. Bu YSA nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

1986'da Rumelhart ve arkadaşlarının "Parallel Distributed Processing" grubu ileri beslemeli modellerde yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (error back propagation algorithm) geliştirerek, bu konuda daha önce iddia edilen aksaklıkların aşılabileceğini göstermişlerdir. Bugün endüstride birçok YSA uygulamasında bu öğrenme yöntemi ile bunun değişik varyasyonları kullanılmaktadır. Back-propagation algoritması, çok kullanılan, öğrenilmesi kolay bir ağıdır.

Widrow ve öğrencileri ise ADALINE'den (ADaptive LINEar Element) sonra MADALINE'yi geliştirip bu YSA'ya uygulama alanı buldular. MADALINE'i 1987'de MADALINE II, 1988'de (David Andes'in keşfettiği) MADALINE III takip etti.

Günümüzde YSA'nın teorik çalışmaları büyük ölçüde tamamlanmış olup 1986'dan bu yana uygulamaya yönelik çalışmalar son derece yoğun bir şekilde devam etmektedir [1].

2.2 Yapay Sinir Ağlarının Avantaj ve Dezavantajları

2.2.1 Avantajları:

- Eğitilebilirler.
- Adaptiftirler.
- Kendi kendine organize olabilen yapılardır.
- Algılamaya yönelik uygulamalarda kullanılabilirler.

- Elindeki verilere bağılı olarak öğrenirler.
- Örüntü sınıflandırması yapabilirler.
- Hata toleransına sahiptirler.
- Çağrışimli bellekleri sayesinde eksik bilgi ile de çalışabilirler.
- Örüntü tamamlama yapabilirler.

2.2.2 Dezavantajları:

- Probleme uygun ağ yapısı deneme – yanılma yöntemiyle belirlenir.
- YSA sayısal değerlerle çalıştığı için girişlerin sayısal verilere çevrilmesi gerekmektedir. Uygun dönüşüm yapılmadığı takdirde kabul edilebilir sonuçlar elde edilmesi mümkün olmayabilir.
- Eğitim işleminin ne zaman sonlandırılacağına dair belli bir kural yoktur.

2.3 Uygulamada İzlenmesi Gereken Ana Adımlar

Seçilmiş olan yapay sinir ağı modeli, elde edilecek sonuçlar için kritik bir etkiye sahiptir. Bu tür çalışmalarda literatür taraması çok önem teşkil etmektedir. Daha önceki çalışmalarda araştırmacıların elde ettiği sonuçlardan yola çıkarak çalışma için en doğru eğitim modeli seçilmelidir. Uygulamada kullanılacak olan ağ modelini, gerçekleştirmek istediğimiz işlemin amacına uyacak biçimde belirlemeliyiz. Çeşitli çalışmalardan elde edilen sonuçlara dayanarak, sinir ağı modelinin karmaşıklığını belirleyen ve başta kararlaştırılan serbest parametreler (düzeltme parametresi v.s.) problemin yapısına ve kullanılacak eğitici örneklerin sayısına uygun seçilmelidir. Ağ çok karmaşık olduğu takdirde, eğitim setini çok iyi öğrenecek, fakat genelleme işlemi zayıf olacaktır. İyi bir genelleme yapabilmek için yapının karmaşıklığı da iyi belirlenip akış diyagram şeması çıkarılmalıdır.


Yapay sinir ağı uygulamalarında göz önünde bulundurulması gereken faktörler şunlardır:

- Verilerin düzenlenmesi ve en uygun işlenebilir duruma getirilmesi.
- Ağ yapısının tasarlanması.

- Verilen problem için verilerin işlenmesi.
- En az hata için uygun yayılma parametresinin (düzeltme parametresi değeri) belirlenmesi.
- Öğrenme sonucunda ağıın performansının hesaplanması (ortalama karesel hata).

2.4 Yapay Sinir Ağlarının Genel Yapısı

Ağ modelinin belirli bir uygulama için yapılandırılmasında işlem elemanları, diğer adıyla nöronlar belirli bir şekilde düzenlenmelidir. Genel olarak bazı yapısal ünitelerin oluşturulmasında nöronlar birbirleriyle bağlı şekildedir ve çizgisel bir sırada dizilidir. Bu çizgisel şekilde dizilmiş nöronların oluşturduğu ünitelere katman denilmektedir. En çok kullanılan ağ modelleri çok katmanlı modellerdir.Şekil 2.1’de üç katmanlı nöronları tam olarak birleştirilmiş bir ağ modeli görölmektedir. Bu katmanlar giriş katmanı, ara (gizli) katman ve çıkış katmanıdır.



2.4.1 Giriş Katmanı

Bu katman dışarıdan gelen bilginin ağı alınmasını sağlar. Giriş katmanı kendi çıkışını ara katmana giriş olarak göndermektedir. Giriş katmanındaki nöronların sayısı, belirli bir problemi karakterize etmek için yeterli olan giriş değerlerinin sayısıdır.

2.4.2 Çıkış Katmanı

Çıkış katmanı, giriş katmanına girilen giriş sinyaline uygun olarak bir çıkış üretir. Çıkış katmanı nöronları, kendi giriş değerlerini ara katmandan elde ederler. Bu katmanda gerekli olan nöronların sayısı, tanımlanan problem için gerekli olan çıkışa eşittir. Bu kısımda ise eğitilen verilere denk gelen karşılıklar elde edilir.

2.4.3 Ara (Gizli) Katman

Bu katman, giriş ve çıkış katmanları arasında yer alır. Buradaki nöronlar, çıkış katmanı ve giriş katmanındaki nöronlara veya başka bir ara katman varsa oradaki nöronlara bağlı olmak zorundadır. Kesinlikle dış çevre ile doğrudan bağlantıları yoktur. Ne dışarıdan doğrudan giriş sinyali alabilir, ne de dışarıya doğrudan çıkış sinyali üretebilir. Ara katmanlar genellikle sinir ağı problemlerinde yer alır. Bunun nedeni, problemin çözümü için giriş ve çıkış katmanının yeterli olmayışıdır. Ara katman, ağı problem için kendi sembol setini yapılandırdığı katmandır. Kısacası bu kısım gerek veri işlemede gerek ise veri çıkışında görülmeyen gizli kısımdır.


2.5 Yapay Sinir Ağlarının Tanımı ve Modeli

2.5.1 Yapay Sinir Ağlarının Tanımı

YSA paralel dağılmış bir bilgi işleme sistemidir. Yani, YSA'nın temelinde, zekâ gerektiren işlemlerden oluşan bilgi işleme işlevi mevcuttur. Bu sistem tek yönlü işaret bağlantıları ile birbirine bağlanan işlem elemanlarından oluşur. Çıkış işareti bir tane olup isteğe göre çoğaltılabilmektedir. YSA yaklaşımının temel düşüncesiyle, insan beyninin fonksiyonları arasında büyük benzerlik vardır. Bu yüzden YSA sistemine insan beyninin modeli de denilebilir. YSA çevre şartlarına göre davranışlarını şekillendirebilir. Girişler ve istenen çıkışların sisteme verilmesi ile kendisini farklı cevaplar verebilecek şekilde ayarlayabilir. Yani son derece esnektir. Ancak son derece karmaşık bir içyapısı vardır. Onun için bugüne kadar gerçekleştirilen YSA'lar; biyolojik fonksiyonların temel nöronlarını örnek alarak yerine getiren kompoze elemanlar olmuştur [3].

2.5.2 Nöronun Biyolojik Yapısı ve Nöron Modeli


İnsanın bilgi işleme olayı beyinde gerçekleşir. Gerçekten de en karmaşık sinir ağı Cerebral Cortex denilen “beyin”dir. Sinir sisteminin en basit yapısı nöronlardır. Beyinde yaklaşık olarak 10^{10} sinir hücresi vardır. Yine hücre başına bağlantı sayısı ise 10^4 mertebesinde. Beyin için çalışma frekansı 100 Hz’dir. Fiziksel boyutları ise 1,3 kg ve 0.15 m² kesitlidir. Vücudun değişik yerleri ile bilgi alışverişi yapan nöron hücresidir. Şekil 2.2’de basit bir nöron hücresi görülmektedir.




Şekil 2.2 Basit bir nöron yapısı

Nöron, soma adı verilen hücre gövdesi dendrit denilen kıvrımlı uzantılar ve somanın dalları sayesinde nöronu dallarına bağlayan tek sinir fiberli aksondan oluşur. Dendritler hücreye gelen girişleri toplarlar. Dendrit tarafından alınan işaretler hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir. Beyindeki korteksde her nöronun bir karşılığı vardır. Bir nöronun çıkışı ona bağlı olan bütün nöronlara iletilir. Fakat korteks, işin yapılabilmesi için hangi nöron harekete geçirilecekse, sadece ona komut gönderir. Somanın içinde ve çevresinde sodyum, kalsiyum, potasyum ve klor iyonları vardır. Potasyum yoğunluğu nöronun içinde, sodyum yoğunluğu dışındadır. Somanın zarı elektriksel olarak uyarılınca (söz konusu uyarı genellikle bir gerilim düşmesidir) zar, Na ve Ca gibi diğer iyonların içeri geçmesine izin verir ve somanın iç durumunu değiştirir. Nöronlar arasındaki bağlantılar hücre gövdesinde veya "sinaps" adı verilen dendritlerdeki geçitlerde olur.

Yardımcı bir benzetme aksonlarla, dendritleri elektrik sinyallerini nörona ileten değişik empedanstaki yalıtımın iletken olmasıdır. Sinir sistemi milyarlarca nöron ile tek bir nörondan çıkan aksonun 10000 kadar diğer nöronla bağlandığı bir ağıdır. Sinapslarla düzeltilen işaretleri taşıyan aksonlar ve dendritlerle içiçe geçmiş nöronlar bir sinir ağı oluştururlar. Şekil 2.3'de en basit formda gösterilen nöron modeli, bir eşik birimi olarak algılanabilir. Şekil 2.4'de ise YSA'nın genel blok şeması gösterilmektedir.



Şekil 2.3 Nöron modeli



Şekil 2.4 YSA'nın genel blok şeması

Eşik birimi, çıkışları toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır. Bir eşik birimi olarak nöron sinapslarındaki işaretleri alır ve hepsini toplarlar. Eğer toplanan işaret gücü eşiği geçecek kadar güçlü ise diğer nöronları ve dendritleri uyaran akson boyunca bir işaret gönderilir. Kesişen dendritlerden gelen sinapslarla kapılanan bütün işaretleri soma toplar. Toplam işaret daha sonra nöronun iç eşik değeri ile karşılaştırılır ve eşik değerini aşmışsa aksona bir işaret yayar. YSA, bu basit nöronların (düğümlerin ya da ünitelerin) bağlanarak bir ağı dönüştürülmesiyle meydana getirilir. Çizelge 2.1'de sinir sistemi elemanlarının YSA'daki karşılıkları verilmiştir [4].

Çizelge 2.1 Biyolojik sinir sistemi elemanlarının YSA'daki karşılıkları

Sinir Sistemi	YSA
Dendrit	Girişler
Sinaps	Ağırlıklar
Akson	Çıkışlar
Soma	Yapay Nöron

2.5.3 Öğrenme Kuralı

Yapay sinir ağlarının öğrenme kuralı, çeşitli kontrol faktörlerine bağlıdır. Yakınsama oranını seçerken birçok nokta göz önünde bulundurulmalıdır. Yavaş öğrenme oranı sistemi yeterli derecede eğitmek için daha çok süre demektir. Hızlı öğrenme oranlarında ağ, ayrımları (sınıflandırmayı) yeteri kadar doğru biçimde yapmayabilir.

Genel olarak, ağ yapısının kompleksliği, boyutu, parametre seçimi, mimarisi, öğrenme kuralının tipi ve istenilen doğruluk gibi çeşitli faktörler ağın ne kadar süre ile eğitileceğini belirleyen faktörleri oluşturmaktadır.

Öğreticisiz öğrenmede her giriş işareti için istenen çıkış sisteme tanıtılır ve YSA giriş/çıkış ilişkisini gerçekleştirene kadar kademe kademe kendini ayarlar. Günümüzde kullanılan birçok öğrenme kuralı vardır. En çok kullanılan öğrenme kuralları şunlardır:

- Rastlantısal (Hebb) öğrenme kuralı
- Performans (Widrow ve ADALINE) öğrenme kuralı
- Genelleştirilmiş Delta Kuralı Öğrenme


2.5.4 Perceptron (Algılayıcı)

Perceptron ağı ilk olarak 1943 yılında McCulloch ve Pitts tarafından saptandı. Hebb Net modelinden sonra ortaya konan perceptron modeli, bugünkü yapay sinir ağları için önemli bir temel oluşturmaktadır. Çünkü Hebb Net'in öğrenme kavramı yerine şimdi eşikleme fonksiyonundan geçirilme kavramı gelmektedir. Bu model yardımıyla, öğrenmede eşiklemenin rolü kabul edilmektedir. Bu model, temelde kendine "hard

limiter” tipindeki eşikleme fonksiyonunu referans olarak kabul etmektedir. Perceptron modeli de yine Hebb Net’in mimarisini kullanmaktadır.

Perceptron modelinde en önemli faktör eşik değeridir. Saptanacak olan eşik değeri problemin karakteristiğine göre belirlenebilir. Eşik değeri yardımıyla perceptron modeli başarılı bir sınıflandırma yapabilmektedir. Hebb Net’te yer almayan bir kavram olan, “kararsız bölge (geçiş bölgesi)” diye adlandırılan çözüm bölgesini de önemseyen perceptron, Hebb Net’e göre sınıflandırmayı daha dikkatli yerine getirmektedir. Bilindiği gibi Hebb Net çözüm uzayını 2 parçaya bir bıçak gibi bölmekte ve bölümlemeyi sağlayan doğrunun (ya da düzlemin) bir yanına A sınıfı (+1) diğer yanına B sınıfı (-1) şeklinde eşikleme yapmaktadır. Oysa ki perceptron yine çözüm uzayını iki ayrı parçaya ayırmakla beraber, A ve B sınıfına ait özelliklerin karma şeklini üzerinde taşıyan nötr sahayı da öğrenebilme yeteneğine sahiptir.

Perceptron yapısında kullanılan döngü (iterasyon) sayısının yükseltilmesi sonucunda çözüm için daha kararlı bir yapıya ulaşılmaktadır. Bu sayede A sınıfı ve B sınıfı daha net konumlandırılabilir, arada kalan nötr bölge (kararsız bölge) daha inceltilebilecektir. Şekil 2.5’de perceptron hücresinin belli bir iterasyon sonunda 2 boyutlu girdi (x_1, x_2) örüntülerinin öğrenilmesi sonucunda elde edilen sınıflandırmayı görmekteyiz.



Şekil 2.5 Perceptron modelinin kullanılmasıyla elde edilen sınıflandırma


Perceptronun öğrenme algoritması “hata” üzerine dayandırılmış bir öğrenme metodolojisidir. Eğer sistem hata ile karşılaşıyorsa öğrenmektedir. Ne kadar hata yapılırsa o kadar öğrenme söz konusudur. Başka bir ifadeyle perceptron hataları

öğrene öğrene, sistemi en az hataya indirgemeyi hedeflemektedir. Güncel yaşamda beyin bir öğrenme stili olarak bu yaklaşımı kullanmaktadır. Örneğin bir öğrenci hep doğru yaparsa bu onda öğrenmeden çok alışkanlık halini alan bir mekanizmaya doğru gidişi sağlarken, beyin bir daha o işle meşgul olmaz ve refleks haline gelen işlemi artık omurilik gibi yan sistemler götürürler. Oysaki beyin o hatayı düzeltmeye çalışacak ve her hatalı durumda hatayı biraz daha azaltmaya çalışacaktır. Bu ise beynin hata yaparak öğrenmesini sağlamaktadır [8].

2.5.5 Genelleştirilmiş Regresyon Sinir Ağları (GRNN)

2.5.5.1 Genel Tanım

GRNN olasılıksal sinir ağları kategorilere ayrılır. Kategorilere ayrılan bu sinirsel ağlar, diğer olasılıksal sinirsel ağlar gibi bir sinir ağının ihtiyacı olarak uygulanan geri yayılım örneklerinin parçalarına gerek duyar. Bir işletim sisteminde ölçümlerden gelen veri genel olarak geri yayımlı bir sinir ağı için yeterli değildir. Bu yüzden olasılıksal bir sinir ağının kullanılması yalnızca birkaç örnek girişin uygulanması ile verinin karakteristik fonksiyonunun anlaşılması açısından avantajlıdır. Beklentiyi karşılayacak bir şekilde uyumu sağlamak için gerekli olan ek bilgi ise nispeten küçüktür ve kullanıcı tarafından ayrı bir giriş verilmeden gerçekleştirilebilir. Bu özellik GRNN’i sistem performanslarını tahmin etmede ve sistemlerin pratikteki performanslarını kıyaslamada kullanışlı bir araç haline dönüştürür.



Şekil 2.6 GRNN sinir ağı topolojisi

2.5.5.2 Algoritma

GRNN’de kullanılan olasılık yoğunluk fonksiyonu normal dağılımlıdır. Her uygulanan örnek dizi girişi X_j normal dağıtımı ifade etmek için kullanılır.

$$Y(X) = \frac{\sum_{i=1}^n Y_i \exp(-D_i^2 / 2\sigma^2)}{\sum_{i=1}^n \exp(-D_i^2 / 2\sigma^2)}, \quad D_i^2 = (X - X_i)^T \cdot (X - X_i) \quad (2.1)$$

Uzaklık (D_j), uygulanan örnek input diziler arasındaki uzaklık ve tahmin noktası, uygulanan her giriş dizisinin tahmin noktasını (X) ne kadar iyi bir şekilde gösterdiğini ölçmede kullanılır. Eğer uygulanan input dizisi ile tahmin noktası arasındaki uzaklık D_i , küçük ise $\exp(-D_j^2 / 2\sigma^2)$ büyür. $D_j=0$ için $\exp(-D_j^2 / 2\sigma^2)$ uygulanan dizilerde belirtilen değerlendirme noktalarından bir tanesi olacaktır. Diğer bütün uygulanan dizi noktalarına olan uzaklık ise daha büyüktür. Büyük bir uzaklık D_j , $\exp(-D_j^2 / 2\sigma^2)$ ifadesinin küçülmesine ve böylece diğer uygulanan dizi girişlerinin tahmine olan katkılarının nispeten küçük olması anlamına gelir.

$Y_j \cdot \exp(-D_j^2 / 2\sigma^2)$ ifadesi j. uygulanan dizi girişi olup en büyük değerli olanıdır ve tahmine katkısı çok fazladır. Standart sapma ya da düzeltme parametresi (σ^2), aranan hedeftir. Büyük bir düzeltme parametresi için, olası değerlendirme noktasının


uygulanan dizi girişı tarafından gösterimi daha büyük bir X değeri ile mümkündür. Küçük bir düzeltme parametresi gösterimi ise daha dar bir X mesafesine karşılık gelecektir.

Eşitlik 2.1 ile şunlar mümkündür.

- Az sayıda uygulanacak örnek dizi ile sistem tavrının tahmini
- Tutarlı çok boyutlu eğrilerin tahmini
- Uygulanan diziler arasında bağlantılar kurma


Şekil 2.7’de GRNN ile gerçekleştirilmiş bir tahmin gösteriliyor. Çemberler veri noktalarını ya da örneklerden geçen sürekli bir doğru elde etmek için uygulanan örnek dizileri göstermektedir. Zil şeklindeki eğriler ise eşitlik 2.1’in bağımsız terimleridir. Bu eğrilerden her biri GRNN tahmininde kullanılan eşitlik 2.1 ifadesindeki terimlerden biridir.

Bu terimler normalleştirilmiş normal dağıtımlardır. Her bir terimin her bir pozisyondaki değerlerinin toplamı tahmin edilen değeri yani veri noktalarından geçen sürekli doğruyu verir. Düzeltme parametresi rasgele seçilmiştir.



Şekil 2.7 Bireysel terimler tahmini için $\sigma^2=0.1$ de GRNN katkısı

GRNN mimarisi basitçe Şekil 2.8’de gösterilmiştir.



Şekil 2.8 GRNN paralel sinir ağı

2.5.5.3 Düzeltme Parametresinin Seçimi

Girişin ön kontrolü için herhangi bir tahmin aracı potansiyel olarak kullanılabilir. Türetilmiş bir algoritma kullanan tahmin aracı kendisi de türetilme içeren algoritmalarda değerlere ihtiyaç duyar. Bunun anlamı şudur ki tahmin aracı yalnızca tahminde yapılan hassaslığın gerçekçiliğini gösteren bir tahmin sunmak değil ayrıca tahmin eğrisini de sunmak zorundadır. Kontrol aracının kullandığı algoritmaya bağlı olarak bu tahmin eğrisi tahmin değerinden daha büyük öneme sahip olabilir. Tahmin aracının kullanımına bağlı olarak hassaslık yahut doğruluk ya da ikisine birden değinmek gereklidir. Yanlış tespit ve bunun düzeltilmesi çeşitli metodları içerebilir, bunlar bir eğri içeren algoritmaları da yaklaşımlarında kullanabilirler, fakat tekrar değinmek lazım ki tahmin aracının kullanımına göre birçok yön önemlidir.


Düzeltme parametresi uygulama prosedüründeki tek önemli parametredir. Düzeltme parametresinin aranması için tahmin edilen çıkış değerinin kullanılacağı uygulamaya göre değişen birçok yön göz önüne alınmak zorundadır.

GRNN'in gösterdiği kötü bir karakteristikte eğride salınımlar olur. Bir salınım kıvrılma olmaması gereken bir yerde kıvrılma olması olarak tanımlanır. Bu salınımlar o kadar bozucu olabilir ki merdiven şeklinde görünen, olmaması gerektiği halde ortaya çıkan

ani deęişimli tahminlere yol açar.Şekil 2.9’da yine GRNN kullanılarak yapılmış tahmin gösterilmektedir. Şekil 2.7 ile karşılaştırıldığında eğriler üzerindeki öğelerde çok yakın etkileşim mesafeleri bulunuyor. Her bir terim neredeyse tek başına bu dar yakınlıkta uygulanan örnek dizi tahminini etkileyecek durumda bulunuyor.

Salınımların görünmesindeki yegane bağlantı σ^2 düzeltme katsayısı iledir. Uygulanan dizi örneklerinde birisine yakın bir tahmin için ve yeteri kadar küçük bir düzeltme parametresi için uygulanan komşu dizilerin birbirlerine olan etkisi küçüktür. $\exp(-D_j^2 / 2\sigma^2)$, deęerinin tahmine katkısı, $\exp(-D_j^2 / 2\sigma^2)$ ifadesinin tahmin edilen deęere en yakın olan uygulanmış diziye olan katkısından çok daha küçüktür. Tahmin noktasından uzakta olan uygulanmış dizilerin etkileri göz ardı edilebilir. Normalizasyondan dolayı tahmin deęeri kendisine yakın olan uygulanmış örnek dizi deęerine ulaşacaktır.

Daha büyük bir düzeltme parametresi için komşu etkiler göz ardı edilemez. Böyle bir durumda tahmin dięer noktalardan daha çok etkilenecektir ve daha düzeltilmiş, gerçeęe daha yakın şekilde gerçekleştirilecektir.




Şekil 2.9 Aşırı wiggle yöntemiyle bireysel sinyaller dâhil GRNN tahmini $\sigma^2 = 0.027$

$$\lim_{\sigma \rightarrow 0} \left(\frac{\sum_{i=1}^n Y_i \exp\left(-D_i^2 / 2\sigma^2\right)}{\sum_{i=1}^n \exp\left(-D_i^2 / 2\sigma^2\right)} \right) = \frac{Y_j \lim_{\sigma \rightarrow 0} \exp\left(-D_j^2 / 2\sigma^2\right) + \sum_{i=1, i \neq j}^n Y_i \lim_{\sigma \rightarrow 0} \exp\left(-D_i^2 / 2\sigma^2\right)}{\lim_{\sigma \rightarrow 0} \exp\left(-D_j^2 / 2\sigma^2\right) + \sum_{i=1, i \neq j}^n \lim_{\sigma \rightarrow 0} \exp\left(-D_i^2 / 2\sigma^2\right)} = \frac{Y_j \lim_{\sigma \rightarrow 0} \exp\left(-D_j^2 / 2\sigma^2\right)}{\lim_{\sigma \rightarrow 0} \exp\left(-D_j^2 / 2\sigma^2\right)} = Y_j \quad (2.2)$$

Daha büyük bir σ^2 değeri ile tahmin eğrisi daha düzgün ve salınımsız olacaktır, bazı durumlarda istenen de budur. Mesela eldeki veri çok fazla gürültü içerdiğinde eğer veri bozulmamış doğru bir veri ise tahmin veriyi ayıklamak zorundadır. GRNN veriye daha hassas bir şekilde uyumlu olmak durumundadır ve verinin izlediği yolu izlemek zorundadır. Eğer σ^2 sonsuza ulaşırsa bu durumda tahmin sırasında alınmış olan tüm örnek noktaların ortalaması olacaktır.

Daha büyük bir düzeltme değerinin etkisi ilk başlarda görünebilir. Şekil 2.10'da bir düzeltme parametresi gösterilmektedir.



Şekil 2.10 Düzgün bir çizgi boyunca GRNN tahmini $\sigma^2=1$

$$\lim_{\sigma \rightarrow \infty} \left(\frac{\sum_{i=1}^n Y_i \exp\left(-D_i^2 / 2\sigma^2\right)}{\sum_{i=1}^n \exp\left(-D_i^2 / 2\sigma^2\right)} \right) = \frac{\sum_{i=1}^n Y_i \lim_{\sigma \rightarrow \infty} \exp\left(-D_i^2 / 2\sigma^2\right)}{\sum_{i=1}^n \lim_{\sigma \rightarrow \infty} \exp\left(-D_i^2 / 2\sigma^2\right)} = \frac{\sum_{i=1}^n Y_i}{n} \quad (2.3)$$


Verilerin her zaman ölçüm hatalarından arındırılmamış olduğu gerçeği göz önüne alınarak diyebiliriz ki ortaya çıkan durumlar uygulamadan uygulamaya değişir ve bu yüzden σ^2 seçiminde doğru ya da yanlış yol vardır denilemez.

Tahminin uygulaması ve gerekli özellikler σ^2 değerinin seçiminde önemli rol oynarlar. Veriye ve uygulamasına göre düşük hata oranı ile düzgünlük-salınımsızlık arasında bir orta yol bulunmalıdır.

2.5.6 Multilayer Perceptron (MLP) (Çok Katmanlı Algılayıcı)

2.5.6.1 Genel Tanım

Çok katmanlı perceptron, giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı YSA sistemleridir. Gizli katman (hidden layer) olarak isimlendirilen bu katmanlarda, düğümleri aracısız giriş olmayan ve aracısız çıkış vermeyen üniteler vardır.



Şekil 2.11 Çok katmanlı perceptronun genel yapısı

İki katmanlı ağlarda veriler giriş katmanı tarafından kabul edilirler. Ağ içinde yapılan işlemler sonucunda çıkış katmanında oluşan sonuç değer işlenen cevap ile karşılaştırılır. Bulunan cevap ile istenen cevap arasında herhangi bir ayrılık varsa ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Girişteki değer, ağırlıklar uygun noktaya ulaşana dek değişmez. Hesaplanan çıkışlar istenilen cevaplarla karşılaştırılarak sonuçta gerekirse hata işareti belirtilir. Hata işareti gizli birimlerden çıkış birimine olan ağırlıkları değiştirmede kullanılır. Ama bunu yaparken giriş katmanından gizli katmana gelenin değiştirilip değiştirilmediğini düşünmek gerekir. Gizli birimlerden ne tür bir çıkış

istendiği bilinmeyeceği için gizli birimlerin çıkışında hata işareti verilmesi kolay bir şey değildir. Bunun yerine her bir birimin, çıkış biriminin hatalarına olan etkisi bilinmelidir. Bu, hatalı birim için gizli birime bağlı olan çıkış birimlerinin hata işaretlerinin ağırlıkları toplamı alınarak yapılır. Çok gizli katmana sahip sistemlerde her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde giriş seviyesine varana dek devam eder. Sonuçta sistem hatalar yapar, ama bu hatalardan bir şeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yöntemle “hatanın geriye yayılma algoritması” (error-back-propagation-algorithms) denir.

Geriye yayılma algoritmasının bazı dezavantajları vardır:

1)Yerel minimuma takılma olasılığının olması: Hata fonksiyonunun tek global minimumu ve bir çok yerel minimumu olabilir. Eğitim sırasında yerel minimuma yakalanma sorunu vardır. Bu durumda ağ kabul edilmeyecek bir çözüme ulaşabilir. İdeal durumda hatanın sıfır olması veya sıfırdan büyük bir global minimuma ulaşması beklenir. Kabul edilebilir bir hata değerine ulaşıncaya öğrenmenin başarıyla gerçekleştiği düşünülür.

2)Eğitmenin yavaş olması: Ağın topolojisi, öğrenme oranı, momentum katsayısı, ağırlıkları ilk değeri eğitmeyi etkileyen faktörlerdir.

a)Ağırlıkların başlatılması: Ağırlıklar başlangıçta küçük seçilir. Çünkü büyük seçildiğinde ağırlıklı toplam büyür. Bunun sonucunda çıkış fonksiyonunun (sigmoid) değeri küçülür. Ağın çıkış değeri güncellemede çarpım olarak geleceği için ağırlıkların değişim miktarı çok küçük olacağından eğitim zamanı uzayacaktır.

b)Öğrenme oranı: Büyük öğrenme oranı değerleri, hata yüzeyinde büyük adımlar atılmasına neden olur. Bu da ağın kararsız olmasına (osilasyon yapmasına) neden olabilir. O nedenle, küçük öğrenme oranı değerleri kullanılır. Bu ise eğitim zamanının uzamasına yol açar.

Eğitim zamanını kısaltmak için momentum terimi ve adaptif öğrenme yöntemi kullanılır.

c) Momentum katsayısı: Yakınsama hızını arttırır ve yerel minimumlardan kurtulmayı sağlar. O andaki ağırlık değişimine daha önceki ağırlık değişiminin belli bir oranı eklenir.

$$\Delta w(t) = \alpha \nabla E(t) + \beta \Delta w(t-1) \quad (2.4)$$

d) Adaptif öğrenme oranı kullanılarak bir adımdaki hata bir önceki hatadan küçükse öğrenme oranı belirli bir sabitle çarpılarak arttırılır. **Hata! Düzenleme alan kodlarından nesneler oluşturulamaz.** ise yeni hesaplanan ağırlıklar ve hata iptal edilir. Öğrenme oranı belirli bir sabitle çarpılarak azaltılır.

Optimum çözüme ulaşabilmede etkili olan faktörler:

- 1) Eğitim kümesinin ele alınan problemi %100 temsil etmesi gerekir.
- 2) Başlangıç değerleri önemli faktörlerdir.
- 3) Ağın topolojisi (gizli katman ve gizli katmandaki işlem elemanı sayısı)
- 4) Normalizasyon: Giriş verilerinin dar bir aralığa taşınması ya da ölçeklenmesi gerekmektedir.
- 5) Hata fonksiyonunun seçimi: Karesel ortalama hata, toplam karesel hata, karesel ortalama hatanın karekökü gibi fonksiyonlardan biri seçilmelidir.

2.5.6.2 Çok Katmanlı Algılayıcıların Çalışma Alanları

1. Eğitim ve test kümelerinin oluşturulması
 2. Ağ topolojisinin belirlenmesi
 3. Öğrenme parametrelerinin (β, α) ve aktivasyon fonksiyonunun belirlenmesi
 4. Ağırlıkların başlangıç değerlerinin atanması
 5. Eğitim örneklerinin ağa uygulanması
 6. Ağ çıktısının hesaplanması
 7. Hatanın hesaplanması
 8. Hatanın azaltılması için ağırlıkların değiştirilmesi
- 5-8. adımlar arası hesaplamalar, istenen (kabul edilen) hata elde edilinceye kadar veya belirlenen iterasyon sayısı tamamlanıncaya kadar devam eder.


BÖLÜM 3

YAPAY SİNİR AĞLARI UYGULAMALARI VE SONUÇLAR


Bu çalışmada mevcutta bulunan DGS (Deforme Toprak Yapıları) hatlarının işaret ve gürültü davranışlarını gösteren bir yaklaşım olarak yapay sinir ağları kullanılmaya çalışılmıştır. Bu sayede yapay sinir ağları bilgisayar destekli öğrenme yoluyla yeni DGS davranışlarını modelleme ve böylece daha pratik model geliştirme yeteneğine sahip olacaktır. Devre denklemleri olmasa bile ölçülmüş ya da önceden simülasyonu yapılmış veriler kullanılarak öğrenme yoluyla, yeni bir taban malzemesi ya da değişken parametrelili devrelerde eğitilmiş yapay sinir ağı ile istenen çıktı değerlerine yaklaşık değerlere ulaşılabilir.

3.1 Kazınmış Toprak Yapısı

DGS (Deforme Toprak Yapıları) hatları taban malzemesinden metalin kazınması ile oluşmuş yapılardır. Bu yapıların çalışma prensibi taban malzemesindeki indüktif ya da kapasitif özelliklerin değişmesine dayalıdır. Fakat DGS hatlarının devreye olan etkileri önceden kestirilememektedir. Bu çalışma ile DGS hatlarının boyutlarına bağlı olarak iletim hattının çıkış değerlerine bakılarak ve bu değerlerin YSA ile modellenerek değişen değerlere karşılık ne tür cevapların verileceği anlaşılabilir ve bu hatların devreye uygulanması durumunda ne tür etkilerin olabileceğinin önceden kestirilebilmesi hedeflenmiştir. Bu çalışmada ilk olarak GRNN modeli kullanılarak yapay sinir ağları eğitilmiştir.



Şekil 3.1 DGS hattının şematığı



Şekil 3.2 DGS hattı üstten görünümü

3.2 DGS hattı basit yapısı ve avantajları


Bir dumbbell DGS yapısı itibariyle $a \times b$ lik bir dikdörtgen kazınmış yapıda ve arada $g \times w$ boyutunda bir boşluktan oluşmaktadır.

DGS hatlarının avantajları:


- Az sayıda DGS hattının periyodik yapılara nispeten band durdurma konusunda aynı karakteristikleri göstermelerine rağmen daha az yer tutması.
- DGS dumbbell yapısına ait S-parametreleri tek kutuplu alçak geçiren Butterworth filtre ile aynı karakteristiği göstermekte ve ayrıca üretimi daha makul ve eşdeğer devreleri kolayca çıkartılabilir.
- DGS aynı karakteristiği gösteren diğer yapılara göre daha az yer tutmakta, daha yüksek hassasiyet göstermekte uygulaması kolay ve yüksek gereksinime sahiptir.

3.3 Matlab NNTOOL Aracı Kullanılarak FR4 Taban Malzemesi İçin En Uygun Eğitim Yöntemine Karar Verilmesi


Aşağıda matlab nntool'daki training fonksiyonlarının FR4 taban malzemesi için test edilmiş ve en iyi performansları karşılaştırılarak DGS hatlarının neural network tool kullanılarak en iyi hangi yöntem ile modellenebileceği araştırılmıştır. Grafiklerde nöral ağın eğitimi sonucunda en iyi performanslar gösterilmiştir.




Şekil 3.3 train_bfg fonksiyonuna ait performans sonucu




Şekil 3.4 train_br fonksiyonuna ait performans sonucu




Şekil 3.5 train_cgk fonksiyonuna ait performans sonucu




Şekil 3.6 train_cgk fonksiyonuna ait performans sonucu




Şekil 3.7 train_cg fonksiyonuna ait performans sonucu




Şekil 3.8 train_gd fonksiyonuna ait performans sonucu




Şekil 3.9 train_gds fonksiyonuna ait performans sonucu




Şekil 3.10 train_gdm fonksiyonuna ait performans sonucu




Şekil 3.11 train_gdx fonksiyonuna ait performans sonucu




Şekil 3.12 train_lm fonksiyonuna ait performans sonucu




Şekil 3.13 train_oss fonksiyonuna ait performans sonucu



Şekil 3.14 train_r fonksiyonuna ait performans sonucu



Şekil 3.15 train_rp fonksiyonuna ait performans sonucu



Şekil 3.16 train_scg fonksiyonuna ait performans sonucu

Çizelge 3.1 FR4 için fonksiyonlara ait performans değerleri

Fonksiyon Kısaltması	Fonksiyon İsmi	Performans Değeri
train_br	Bayesian regularization backpropagation	6.4266
train_lm	Levenberg-Marquardt	6.5512
train_cgb	Conjugate Gradient with Powell	7.5467
train_bfg	BFGS Quasi-Newton	7.8314
train_scg	Scaled Conjugate Gradient	8.2773
train_rp	Resilient Backpropagation	12.9511
train_cgp	Polak-Ribière Conjugate Gradient	15.8197
train_r	Random order incremental training	311.5516
train_oss	One Step Secant	311.6032
train_cgf	Fletcher-Powell Conjugate Gradient	311.8063
train_gdm	Gradient descent with momentum backpropagation	312.1213
train_gda	Gradient descent with adaptive learning	312.2798
train_gdx	Variable Learning Rate Backpropagation	316.9789
train_gd	Gradient descent backpropagation	318.7899

Çizelge 3.1’de görüldüğü gibi DGS hatları için en uygun training fonksiyonu yukarıdan aşağı en uygundan başlayarak sıralanmıştır. Performans değeri küçük olan fonksiyon daha az hata ve en iyi tahmine sahip fonksiyonu belirtmektedir.


3.4 YSA’nın eğitilmesi

YSA’nın eğitilmesi işlemi için öncelikle daha önce simülasyonu yapılmış ve giriş ve çıkış parametreleri belirlenmiş olan devrelere ait verilere ihtiyaç bulunmaktadır. Bu ihtiyaç kapsamında kullanılan program ile simüle edilmiş DGS hatlarının verileri export edilerek bu ihtiyaç karşılanmıştır.

Simülasyon programında taban malzemeleri ve taban malzemesi altında DGS hattına ve iletim hattına ait uzunluklar değiştirilerek birden çok yapı için simülasyonlar gerçekleştirilmiş ve elde edilen sonuçlar text dosyası olarak dışa aktarılmıştır. Bu dosyada değiştirilen parametre uzunlukları Çizelge 3.2’de belirtildiği gibi taban malzemesine özel parametreler simülasyona ait frekans aralığı gibi değişkenler bulunmaktadır.


Daha sonra text dosyasındaki veriler matlab’e aktarılarak ilgili veriler matlab’de matrissel olarak kaydedilmiş ve matlab’de yapılacak olan işlemlere hazır hale getirilmiştir. Bunlardan YSA yı eğitecek verilerin her biri matlabde bir vektör matrisin her bir kolonu tarafından temsil edilmiştir. Bu aşama ile YSA için gerekli olan DGS hat verileri matlaba aktarılmıştır.

Programdan export edilmiş text dosyası matlabe aktarılıp text dosyasındaki istenen sütun ilgili parametreye matris olarak atanmış ve Tablo olarak oluşturmak istediğimiz veri grubuna text dosyasından okunan veriler Tablo’nun sütunlarına atanmıştır. Kod çalıştırıldıktan sonra elde edilen tablo excelde tablo olarak ve matlab de matris olarak kayıt edilmiştir.



Şekil 3.17 DGS hatlara ait model görünümü ve değişkenlerin temsil ettiği uzunluklar

Şekil 3.17’de görüldüğü üzere DGS hatlara ait devrenin şematığı şekildeki gibidir. Bu şekilde $a=dgs_x$, $b= dgs_y$ ve $line_y$ (mikroşerit hat uzunluğu) değerlerinin yapıda hangi değişkene karşılık geldiği belirtilmiştir.



Şekil 3.18 Simülasyon programından DGS hat üzerindeki parametrelerin değerleri

Çizelge 3.2 Değişken parametrelerin değişen değerlerinin tablosu

Parametreler	Rogers 3010	Rogers 3035	FR4
h (mm)	0.13 0.64	0.13 0.5	1.6
ϵ_r	11.2	3.6	4.6
$Y_{line}(\text{mm})$	0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1, 1.2, 1.4, 1.6, 1.8, 2, 2.3, 2.6, 3, 3.5, 4, 4.5, 5		
$a(\text{Dgs } x)$	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
$b(\text{Dgs } y)$	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
Thickness $T (\mu\text{m})$	35		
$f(\text{GHz})$	1, 2, 3, 4, 5, 6, 7, 8, 9, 10		
Örnek Sayısı	485379	454899	126263

Çizelge 3.2’de kullanılan taban malzemesinde parametre olarak değişen değerler belirtilmiştir. line_y, dgs_x ve dgs_y ait tüm değerler birbirleri ile simülasyona girerek meydana gelen tüm farklı yapılar için sonuç alınmıştır. İlgili veriler matlab’e aktarıldıktan sonra matlab’de yapay sinir ağı eğitmek ve eğitilmiş ağı test etmek üzere


iki parçaya ayrılmıştır. Ayırma işlemi line_y yani iletim hattının değişen değerleri için gerçekleştirilmiştir.

Eğitim ve test verilerinin line_y'nin hangi değerleri için gruplandığı Çizelge 3.3'de belirtilmiştir.

Çizelge 3.3 Eğitim ve Test verilerinin ayrılması Veri Kümesi 1 ve Veri Kümesi 2

Parametreler	Rogers 3010	Rogers 3035	FR4
h (mm)	0.13 0.64	0.13 0.5	1.6
ϵ_r	11.2	3.6	4.6
Yline (mm)	0.3, 0.5, 0.7, 0.9, 1.2, 1.6, 2, 2.6, 3.5, 4.5		
Dgs x	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
Dgs y	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
Thickness T (μm)	35		
f (GHz)	1, 2, 3, 4, 5, 6, 7, 8, 9, 10		
Örnek sayısı	227477	213876	59329
Parametreler	Rogers 3010	Rogers 3035	FR4
h (mm)	0.13 0.64	0.13 0.5	1.6
ϵ_r	11.2	3.6	4.6
Yline (mm)	0.4, 0.6, 0.8, 1, 1.4, 1.8, 2.3, 3, 4, 5		
Dgs x	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
Dgs y	0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 1.9, 2.5, 3, 3.5		
Thickness T (μm)	35		
f (GHz)	1, 2, 3, 4, 5, 6, 7, 8, 9, 10		
Örnek sayısı	257902	241023	66934

Bu şekilde ayrılmış olan eğitim ve test verileri artık matlab’de YSA’yı eğitmek ve eğitilmiş ağda başka verilerin simüle edilerek simülasyon ve YSA sonuçlarını karşılaştırmak için kullanılacaktır.




Şekil 3.19 DGS hatlarının YSA karakutu modeli giriş ve çıkış parametreleri

Şekil 3.19’de YSA modelinin girişine uygulanan veriler ve çıkışından alınacak olan verilerin diyagramı gösterilmiştir. Bu diyagramda giriş verileri S parametrelerini elde etmek için gerek duyulan ve text dosyasından export edilmiş dosyadan matlaba aktarılan verileri temsil eder. Çıkış verileri ise girişteki verilerin eğitilmiş yapay sinir ağında simüle edilmesi ile ortaya çıkmıştır. Sonucun S11 ya da S21 çıkması ise YSA’nın S11 ya da S21 bilgisi ile eğitilmiş olmasından farklılık göstermektedir.


Matlab’de kullanılmış olan kod içinde eğitim verilerinin ve test verilerinin yüklenmesinden sonra eğitim verilerinin bir döngüye sokulup $S=0.01:0.01:1$ aralığında her bir S için bir netG1 ağı oluşturulup bu ağ için test verileri simüle edilmiş. YSA sonucu ile CST sonuçları karşılaştırılarak error ve Terror olarak iki hata sonucu çıkarılmıştır. Bu hata sonuçları ağın tahmin ettiği ile simülasyon arasındaki farkların ortalama hatası olarak açıklanabilir. Bu işlem 100 defa tekrarlandıktan sonra Terror matrisinin en küçük değeri yani en az hata değeri bulunur. Bu değer oluşturulan eğitilmiş ağlar arasında test verileri ile eğitime giren ve en az hata ile hesaplamayı gerçekleştirmiş olan ağdır. Bu işlem sonrasında bu değer ile oluşturulan netG1 ağı tekrar ve son kez oluşturulur ve oluşturulan ağ ile test verileri tekrar simüle edilerek YSA sonuçları elde edilir. Bu sayede en az hatayı yapmış olan ağ ile en son simülasyon gerçekleştirilip matris olarak kaydedilmiştir.

Burada Veri Kümesi 1 ve Veri Kümesi 2 değerlerinin ayrı ayrı eğitim ve test verisi olması gerçekleştirilmiş ve bu sayede hangisinin eğitim ya da hangisinin test verisi olduğu dikkate alınmaksızın her iki şekilde de sonuçta gerçek sonuçlara yakın tahmin vermiş olduklarını göstermiş olduğu görülmektedir. Bu iki durumda da birbirine yakın hata değerleri hesaplanır ve yapay sinir ağının tahmini sonucu simülasyon sonucuna yakın değerler elde edilmektedir.


Şekil 3.20 ve Şekil 3.21’de belirtilmiş olan grafikler line_y, dgs_x ve dgs_y değerlerinin tek bir tanesi yani simülasyonu yapılmış olan birçok yapıdan birini temsil etmektedir. Bu sayede aynı uzunluk değerleri için her taban malzemesinin S parametresi cevabı incelenmiştir hem de simülasyon sonuçları üst üste gösterilerek sonuçların birbirine yakınlığı gösterilmiştir. Burada görülen x eksen 0-10 GHz frekans aralığını y eksen ise S11dB ve S21dB değerlerini temsil etmektedir. Bu grafiklerde kırmızı renk simülasyon ve mavi renk test verisi olarak belirtilmiş. İki veri aynı grafikte belirtildiğinde ortaya çıkan değerler birbirine yakınlıkları grafiklerde belirtilmiştir. Bu grafikleri simülasyon işlemi sonucunda hata oranı Veri Kümesi 1 eğitim verisi iken ve Veri Kümesi 2 eğitim verisi iken S11 ve S21 değerleri için Çizelge 3.4 ve Çizelge 3.5’de taban malzemeleri için ayrı ayrı belirtilmiştir.




Şekil 3.20 FR4 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi




Şekil 3.21 FR4 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi




Şekil 3.22 RO3010 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi



Şekil 3.23 RO3010 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi



Şekil 3.24 RO3035 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi




Şekil 3.25 RO3035 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi


$$Hata1 = \frac{1}{N} \sum_{i=1}^N |H_i - T_i| \quad (3.1)$$

Çizelge 3.4 S11 Sonuçları İçin Malzemelere Ait Hata Değerleri


Malzeme	Eğitim Verisi	Test Verisi	Hata Değeri
FR4	Veri Kümesi 1	Veri Kümesi 2	0.0463
	Veri Kümesi 2	Veri Kümesi 1	0.0560
RO3010	Veri Kümesi 1	Veri Kümesi 2	0.0883
	Veri Kümesi 2	Veri Kümesi 1	0.0858
RO3035	Veri Kümesi 1	Veri Kümesi 2	0.1071
	Veri Kümesi 2	Veri Kümesi 1	0.1050




Şekil 3.26 FR4 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi




Şekil 3.27 FR4 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi




Şekil 3.28 RO3010 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi



Şekil 3.29 RO3010 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi



Şekil 3.30 RO3035 Veri Kümesi 1 eğitim Veri Kümesi 2 test verisi




Şekil 3.31 RO3035 Veri Kümesi 2 eğitim Veri Kümesi 1 test verisi

Çizelge 3.5 S21 sonuçları için malzemelere ait hata değerleri

Malzeme	Eğitim Verisi	Test Verisi	Hata Değeri
FR4	Veri Kümesi 1	Veri Kümesi 2	0.3535
	Veri Kümesi 2	Veri Kümesi 1	0.3535
RO3010	Veri Kümesi 1	Veri Kümesi 2	1.6824
	Veri Kümesi 2	Veri Kümesi 1	4.7722
RO3035	Veri Kümesi 1	Veri Kümesi 2	3.0088
	Veri Kümesi 2	Veri Kümesi 1	3.6010

DGS DEVRE ÜRETİMİ ve ÖLÇÜMLERİ

Tezin bu kısmında elde edilen YSA temelli DGS modelinin sonuçları kullanılarak 2.4GHz de çalışan bir A sınıfı kuvvetlendiricisinin 3. Dereceden harmoniklerini bastıracak bir DGS yapısı tasarlanmıştır ve ayrıca AWR ortamında simüle edilmiştir. İstenilen frekansdaki bastırma değerini YSA modeli ve basit bir optimizasyon algoritması birlikte çalıştırılarak kolaylıkla elde edilmiştir. MATLAB de hazır optimizasyon algoritmalarından Parçacık Sürü Optimizasyonu kullanılarak, 7.2GHz S21 değerini sönmüleyecek optimum DGS yapısının parametreleri elde edilmiştir ve Çizelge 4.1’de sunulmuştur.



Şekil 4.1 Üst kısım çıkış hattı 2mm genişliğinde 10mm uzunluğunda DGS hattı


Çizelge 4.1 DGS yapısının boyutları

DGS Hat	Dgs_x	Dgs_y	ϵ_r	H	Thickness
Parametreleri	2 mm	10 mm	4.6	1.6 mm	0.035 mm

4.1 RF yükselteçler

Bu bölümde öncelikle ISM bandı frekans aralığında tek katlı, A – sınıfı güç yükselteci tasarımı yapılmıştır. Daha sonra ise güç yükselteci devresini AWR Office programını kullanarak optimize edilmiştir. Optimize edilen devreye DGS hat eklenerek harmoniklerdeki değişim incelenmiştir.

A sınıfı RF güç yükselteçleri tamamen doğrusal olarak kabul edilen tek yükselteç türüdür. Diğer yandan büyük sinyal yükselteçlerinin diğer sınıfları A sınıfına göre daha yüksek kazançla sahiptir. A sınıfı güç yükselteçlerinde giriş sinyalinin hem pozitif hem de negatif alternanslarını tam yükseltme özelliğinden dolayı doğrusallık ve kazanç parametrelerinin her ikisi de bulunmaktadır. A sınıfı yükselteçler çıkış harmoniklerinin düşük düzeyde olması nedeniyle yüksek frekanslarda diğer sınıf yükselteçlerden daha etkili çalışabilir (transistörün kendi f_{maks} frekansına çok yakın frekanslarda). A sınıfının genel olarak olumsuz özelliği çok düşük verimliliğidir ki bu da büyük sinyal uygulamalarında kritik olabilir. Bu nedenle A sınıfı yükselteçler kablosuz sistem modülasyonunun yükseltilmesinde çok yüksek doğrusallık isteneceği zaman veya düşük RF çıkış gücü gereken yerlerde kullanılır (Sayre, 2001). Şekil 4.2’de A sınıfı güç yükselteci devresi verilmiştir (Jose, 2004).




Şekil 4.2 Single-ended power amplifier

4.1.1 IP2 / IP3

Giriş sinyali yükseldikçe yükseltecin içinde oluşan harmonik sinyaller de (2. ve 3. mertebeli) yükselir. Giriş 1 dB ile yükselirse 3. Mertebeli harmonik 3 dB ile yükselmektedir. Belirli bir noktada giriş sinyali ve harmonik sinyal birbirine eşit olacaktır. Bu noktaya IP3 noktası adı verilmektedir. Bu durumda giriş sinyali yükseltecinin içinde oluşan harmonik sinyal tarafından bastırılacaktır. Bu noktaya ulaşmadan önce çıkış sinyali giriş sinyalini takip etmeyi bırakıp değer kaybedecektir.


Şekil 4.3’de bu değer kaybı ve IP3 ve IP2 noktasının gösterimi verilmektedir.



Şekil 4.3 IP2 ve IP3 parametrelerinin grafiksel gösterimi

IP2 ve IP3 değerleri, yükseltecin yüksek genlikli sinyallerle başa çıkıp çıkamadığını göstermektedir. Bir alıcının giriş katında bulunan yükselteç için bu değerler çok

önemlidir. Kısa dalgada bazen sinyaller çok yüksek olabilmektedir. Böyle bir durumda giriş yükselteci boğulur ve sinyal şeklini bozup harmonikler oluşturursa, o zaman yükseltecin ne kadar kaliteli olduğu anlaşılabilir (Mona vd. 2001). Şekil 4.4’de IP2’yi hesaplamamıza yardımcı olacak olan spektrum analizör görüntüsü verilmiştir (Vizmuller, 1995).



Şekil 4.4 IP2 ölçümünde kullanılan güç yükseltecinin çıkış grafiği


Giriş sinyali yükseldikçe yükseltecin içinde oluşan harmonik sinyaller de (2’ci ve 3’cü mertebeli) yükselir. Giriş 1 dB ile yükselirse 3’cü mertebeli harmonik 3dB ile yükselmektedir. Belirli bir noktada giriş sinyali ve harmonik sinyal bir birine eşit olacaktır. Bu noktaya IP3 noktası adı verilmektedir.

4.2 DGS ile RF Yükselteçlerde Harmonik Bastırma


Bu bölümde, Şekil 4.13’de verilmiş olan DGS yapısının A sınıfı kuvvetlendiricisine eklenmesi ile aşağıdaki şekillerde 2.4 GHz frekansında çalışan bir A sınıfı kuvvetlendiricisinin AWR ortamında, DGS yapısı ekli ve eklenmemiş durumlarındaki simülasyon sonuçları incelenmiştir. DGS yapısı önce tek daha sonra üç katlı olarak eklenerek devrenin performansı üstündeki etkisi incelenmiştir. Bu uygulamadaki hedef kuvvetlendiricinin öncelikle 3. Harmonik (7.2GHz) değerini bastırmak. Çizelge 4.2’de her 3 modele ait simülasyon sonuçları verilmiştir.

Çizelge 4.2 Bütün kuvvetlendirici modellerinin simülasyon sonuçları

Model	Kazanç (dB)	P2 Harmonik değeri (dBm)
DGS yapısı olmayan	13	-42
Tek katlı DGS yapısına sahip kuvvetlendirici	12.6	-50.5
Üç katlı DGS yapısına sahip Kuvvetlendirici	12	-64.2



(a)




(b)


Şekil 4.5 A sınıfı güç yükselteci (a) şematik (b) baskı devre

Çizelge 4.3 FR4 Bakır Yüzey Teknik Özellikleri


	Dielektrik (ϵ_r)	Kayıp tanjantı ($\tan\delta$)	Dielektrik kalınlığı (H)	Bakır kalınlığı (T)
	4.6	0.002	1.6mm	0.005mm




Şekil 4.6 0dBm giriş gücünde Kazanç-Geri dönüş kaybı




Şekil 4.7 0dBm giriş gücü için çıkış gücü




Şekil 4.8 VSWR değeri




Şekil 4.9 Güç yükseltici güç tüketimi




Şekil 4.10 Güç ekleme verimi




Şekil 4.11 1dB compression point




Şekil 4.12 Giriş gücüne bağlı olarak transistörün akım çekim değişimi




Şekil 4.13 2.4GHz için harmonikler




Şekil 4.14 DGS hat model görünümü




Şekil 4.15 DGS devresi S parametre grafiği




Şekil 4.16 Power amplifier mikroşerit yapısı




Şekil 4.17 Power amplifier mikroşerit yapısı baskı devre görünümü-1



Şekil 4.18 Power amplifier mikroşerit yapısı baskı devre görünümü-2




Şekil 4.19 DGS'li yapı S parametresi grafiği




Şekil 4.20 DGS'li yapı harmonik değişimi


4.3 Üç Katlı Yapı Olması Durumu




Şekil 4.21 Üç katlı DGS model görünümü




Şekil 4.22 Üç katlı DGS devresi S parametre grafiği




Şekil 4.23 Üç katlı DGS'li yapı kazanç ve geri dönüş kaybı




Şekil 4.24 Üç katlı DGS'li yapı harmonik değişimi



Şekil 4.25 Üç katlı çıkış power amplifier mikroşerit yapısı-1



Şekil 4.26 Üç katlı çıkış power amplifier mikroşerit yapısı-2



Şekil 4.27 Üç katlı çıkış power amplifier mikroşerit yapısı-3

Sonuçlardan da görüldüğü üzere DGS tek katlı DGS yapısı ile kazançta herhangi bir kayıp olmaksızın devrenin harmoniklerini bastırılabilir. Kullanılacak 2. veya 3. DGS yapılarının aynı frekansdan ziyade başka harmonik frekanslarda çalışacak şekilde eklenirse daha yüksek verim elde edilebilir.


4.4 Devre Üretimi ve Ölçümü

Tasarlanan DGS devre çalışması, YTÜ, elektronik ve haberleşme mühendisliği bölümü, mikrodalga laboratuvarında gerçekleştirildi. Gerçeklenen RF devrenin üretimi ve performans ölçümleri için laboratuvarında kullanılan bazı cihazlar şöyledir: LPKF S63 Baskı Devre Makinası, Anritsu Network Analizör, Rohde & Schwarz Network Analizör, Rohde & Schwarz Spectrum Analizör, 20 GHz RF sinyal üretici, Güç kaynağı, Multimetre cihazları kullanılmıştır.

Çizelge 4.4 Güç yükselteci kullanılan ekipmanları


Güç Yükselteci	Tanımlamalar
Substrate	FR4
Güç Yükselteci	Tel Katlı
BFP650	High Linearity Low Noise SiGe:C NPN RF Transistor Highly linear low noise driver amplifier for all RF frontends up to 4.5 GHz

	• Output compression point OP1dB = 17 dBm at 70 mA, 3V, 2.4 GHz, 50Ω system • Output 3rd order intermodulation point OIP3 = 30 dBm at 70 mA, 3 V, 2.4 GHz, 50 Ω system
1R	Akım Sınırlayıcı
7.5K	Gerilim Bölücü
4.7R	Gerilim Bölücü
10nF	Besleme
8.2pF	Besleme
4.7pF	DC Bias
100pF	DC Bias
1pF	Matching
15nH	Besleme
18nH	Besleme
DGS	Mikroşerit Geometri



Şekil 4.28 Basılı power amplifier devresi ve DGS yapılarının görünümü


Baskı devresi yapılan Power Amplifier Devresi DGS'li ve DGS'siz olarak iki tipte basılmıştır. Basılan devrelere ait Spectrum ve Network Analyzer ölçümlerine ait sonuçlar aşağıda grafiksel olarak ifade edilmiştir.



Şekil 4.29 Power amplifier'a ait S_{11} parametrelerinin DGS hattına göre durumları




Şekil 4.30 Power amplifier'a ait S_{11} parametrelerinin ölçüm değerleri




Şekil 4.31 Power amplifier'a ait S₂₁ parametrelerinin DGS hattına göre durumları




Şekil 4.32 Power amplifier'a ait S₂₁ parametrelerinin ölçüm değerleri



Şekil 4.33 Tek katlı DGS hattına ait S parametre değerleri



Şekil 4.34 Üç katlı DGS hattına ait S parametre değerleri



Şekil 4.35 Power amplifier devresi kazancının DGS hat durumuna göre değerleri

SONUÇ VE ÖNERİLER

YSA yöntemi kullanılarak farklı özelliklerde üç taban malzemesine ait simülasyon sonucu değerleri kullanılarak yapay sinir ağlarına bu sistem eğitilmiş daha sonrasında girdisi olan fakat çıktısının bu ağ tarafından tahmin edilmesine çalışılmıştır. Bunun için önceden simülasyonu yapılmış devrelere ait veriler ile YSA ağı eğitilmiş. Eğitilmiş ağ ile sonradan parametreleri değiştirilmiş devreye ait bilgiler simüle edilmiş ve elde edilen sonuçlar karşılaştırılmıştır. Bu işlem diğer taban malzemeleri içinde uygulanabilir hale getirilmiş ve bu sayede YSA yöntemi ile simülasyon yaparak istenen verilere ulaşılabilmektedir. Daha sonra elde edilen YSA modeli ile bir A sınıfı kuvvetlendiricisinin harmoniklerini bastıracak bir tasarım geliştirilmiş ve bu tasarım AWR ortamında simüle edilerek başarılı olduğu gözlemlenmiştir. Simülasyonu yapılan devre modellerinin baskı devreleri elde edilmiş. Bu devreleri ait Spectrum ve Network Analyzer ölçüm sonuçları simülasyon değerleri ile karşılaştırılarak YSA yönteminin doğruluğu test edilmiştir.

Bu aşamadan sonra daha farklı yapıların benzer bir yöntem ile harmoniklerinin filtrelenmesi veya daha ileri çalışmalarda elde edilen YSA temelli DGS modelinin empedans uydurma devrelerinde kullanımı hedeflenmiştir.

Laboratuvar ortamında yapılan çalışmalarda ISM bandında 2.4 GHz verici sinyallerinin harmoniklerinin bastırılması için DGS yapıları tasarlanarak A Sınıfı tek katlı güç yükselteci uygulaması yapılmıştır. Benzetim sonuçları, tasarlanan devrelerin 2.4GHz ISM bant standartları ile uyumlu verici sistemlerde etkili olarak kullanılabileceğini göstermektedir. Sonuç olarak verici sistemler için Harmonik bastırma uygulamalarına yönelik alternatif bir yöntemde sunulmuştur.

Özetle, Yapay sinir ağıları ile modellenerek DGS yapıları istenilen frekanslar için tasarlanması bu tezin temelini oluşturmaktadır. Ayrıca spektrum analizörü ve mikrodalga ekipmanları kullanılarak alınan ölçüm sonuçları, gerçekleştirilen verici devrenin, 2. ve 3. Harmoniklerin bastırılmasında verimli bir yöntem olduğunu göstermektedir.

KAYNAKLAR

- [1] Öztemel, E., (2003), Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul
- [2] David M. Pozar, Microwave Engineering, Third Edition, John Wiley&Sons Inc
- [3] Specht, D. F., (1991). "A general regression neural network", IEEE Trans. Neural Netw. 2 (6): 568–576.
- [4] Gülez K., (2004). "A General Regression Neural Network" (31): 761-777
- [5] Gonzalez, G., Microwave Transistor Amplifiers Analysis and Design, Prentice-Hall, Inc.
- [6] http://en.wikipedia.org/wiki/Scattering_parameters
- [7] <http://www.yildiz.edu.tr/~gulez/3k1n.pdf>
- [8] http://en.wikipedia.org/wiki/Neural_network

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Oğuz Mehmet KILIÇ
Doğum Tarihi ve Yeri : 16.10.1989 BEYOĞLU
Yabancı Dili : İngilizce
E-posta : oguzmehmetkilic@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Elektronik ve Haberleşme Mühendisliği	Yıldız Teknik Üniversitesi	2011
Lise	Fen Bilimleri	Sakıp Sabancı Anadolu Lisesi	2007

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2013	Tübitak	Araştırmacı