

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MINKOWSKI FRAKTAL ANTEN TASARIMI VE YAPAY SİNİR AĞI MODELİ

CİHAN METE

YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI

DANIŞMAN
PROF. DR. FİLİZ GÜNEŞ

İSTANBUL, 2011

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MINKOWSKI FRAKTAL ANTEN TASARIMI VE YAPAY SİNİR AĞI MODELİ

Cihan METE tarafından hazırlanan tez çalışması 27.06.2011 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

Prof. Dr. Filiz GÜNEŞ

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Filiz GÜNEŞ

Yıldız Teknik Üniversitesi

Doç. Dr. Korkut YEĞİN

Yeditepe Üniversitesi

Doç. Dr. Ahmet Serdar TÜRK

Yıldız Teknik Üniversitesi

ÖNSÖZ

Bitirme projesi boyunca hiçbir şekilde desteğini esirgemeyen tez danışmanım Prof. Dr. Filiz Güneş'e, yardımlarından dolayı Tübitak'daki hocam Bahattin Türetken'e, yüksek lisans eğitimi için burs aldığım TUBITAK kurumuna, yüksek lisans yapmam için derslere gitmeme izin veren başta Kadıköy Telekom müdürü Süleyman Üstüner, müdür yardımcısı Uğur Özkan ve tüm çalışma arkadaşlarıma, bana maddi, manevi her türlü desteği veren ailem ve arkadaşlarıma çok teşekkür ederim.

Haziran, 2011

Cihan METE

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ	xi
ÖZET	xii
ABSTRACT.....	xiv
BÖLÜM 1	1
GİRİŞ.....	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	1
1.3 Hipotez	2
BÖLÜM 2	3
TUBİTAK ANTEN TASARIMI	3
BÖLÜM 3	7
FRAKTAL ANTENLER	7
3.1 Kronoloji.....	7
3.2 Uygulama Alanları.....	8
3.3 Avantajlar	8
3.4 Özellikler	8
3.4.1 Boşluk Doldurma	8

3.4.2	Kendine Benzerlik	9
3.5	Kullanım Alanları	9
3.6	Fraktal Anten Tipleri	10
BÖLÜM 4		13
FRAKTAL ANTEN TASARIMI		13
BÖLÜM 5		18
YAPAY SİNİR AĞLARI		18
5.1	Genel Tanım	18
5.2	YSA'ların Avantaj ve Dezavantajları	19
5.3	YSA Nasıl Çalışır ?	22
5.4	YSA'nın Eğitimi ve Testi	23
5.5	YSA'nın Yapısı	26
5.5.1	Girdi Katmanı	27
5.5.2	Ara Katman (Gizli Katman)	27
5.5.3	Çıktı Katmanı	27
5.6	Yapay Sinir Hücresi	28
5.6.1	Girdiler	28
5.6.2	Ağırlıklar	28
5.6.3	Birleştirme Fonksiyonu	29
5.6.4	Aktivasyon Fonksiyonu	29
5.6.4.1	Doğrusal Aktivasyon Fonksiyon	30
5.6.4.2	Sigmoid Aktivasyon Fonksiyonu	30
5.6.5	Çıktı	32
5.7	Yapay Sinir Ağlarının Sınıflandırılması	33
5.7.1	YSA'ların Yapılarına Göre Sınıflandırılması	33
5.7.1.1	İleri Beslemeli Ağlar	33
5.7.1.2	Geri Beslemeli Ağlar	34
5.7.2	YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması	35
5.7.3	Danışmanlı Öğrenme	36
5.7.3.1	Danışmansız Öğrenme	36
5.7.3.2	Takviyeli Öğrenme	37
5.8	Uygulamaya Göre Öğrenme Algoritmaları	37
5.8.1	Çevrim İçi (On-line) Öğrenme	38
5.8.2	Çevrim Dışı (Offline) Öğrenme	38
5.8.3	Yapay Sinir Ağ Yapıları	38
5.9	YSA'ların Kullanıldığı Alanlar	38
5.10	YSA'ların Tarihçesi	40
BÖLÜM 6		43
FRAKTAL ANTENLERDE YAPAY SİNİR AĞI ÇALIŞMASI		43
6.1	YSA Mimarisi	44
6.2	Eğitim ve Test Verileri	48

6.3 YSA Sonuçları	48
BÖLÜM 7	55
SONUÇ VE ÖNERİLER	55
KAYNAKLAR.....	57
ÖZGEÇMİŞ.....	59

SİMGE LİSTESİ

f_r	Rezonans frekansı
S_{11}	s parametresi-geri dönüş kaybı
φ_{S11}	s parametresi açısı
VSWR	Gerilim duran dalga oranı
E	Elektrik alan
λ	Dalga boyu
ε	Dielektrik sabiti
w	Hücrenin ağırlıklar matrisi
x	Hücrenin giriş vektörü
v	Hücrenin net girişi
y	Hücre çıkışı

KISALTMA LİSTESİ

CST	Computer Simulation Technology
YSA	Yapay Sinir Ağları
IEEE	Institute of Electrical and Electronics Engineers
ANN	Artificial Neural Network
MATLAB	Matrix laboratory
Newff	İleri beslemeli geriye yayılım ağı
GEF	Geriye yayılım ağ eğitim fonksiyonu
TF	Transfer fonksiyonu

ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1 Tübitak Anteni.....	3
Şekil 2.2 Frekansa göre S parametresi genliği.....	4
Şekil 2.3 Frekansa göre gerilim duran dalga oranı	4
Şekil 2.4 3.25 GHz frekansındaki ışıma diyagramı.....	4
Şekil 2.5 4.25 GHz frekansındaki ışıma diyagramı.....	5
Şekil 2.6 5.5 GHz frekansındaki ışıma diyagramı.....	5
Şekil 2.7 10 GHz frekansındaki ışıma diyagramı	5
Şekil 2.8 Tübitak anteninin kazancı	6
Şekil 3.1 Sierpinski ara levhası.....	10
Şekil 3.2 Koch fraktal (kar tanesi).....	10
Şekil 3.3 Ağaç fraktal	11
Şekil 3.4 Hilbert eğrisi.....	11
Şekil 3.5 Gosper ada fraktal	11
Şekil 4.1 Fraktal antenin ilk safhası	13
Şekil 4.2 Fraktal antenin ikinci safhası	14
Şekil 4.3 Fraktal antenin üçüncü safhası	14
Şekil 4.4 Fraktal antenin birinci safhası için frekansa göre S parametresi.....	15
Şekil 4.5 Fraktal antenin ikinci safhası için frekansa göre S parametresi	15
Şekil 4.6 Fraktal antenin üçüncü safhası için S parametresi	15
Şekil 4.7 Fraktal antenin birinci aşaması için 2.6 GHz frekansındaki ışıma diyagramı.....	16
Şekil 4.8 Fraktal antenin ikinci aşaması için 2.2 GHz frekansındaki ışıma diyagramı...	17
Şekil 4.9 Fraktal antenin üçüncü aşaması için 2.2 GHz frekansındaki ışıma diyagramı ...	17
Şekil 5.1 (a) Genelleme ve (b) Ezberleme [10].....	25
Şekil 5.2 Verileri ezberleyen ve iyi genellemeye ulaşan ağlardaki hata eğrileri [10]...	25
Şekil 5.3 Yapay sinir ağı modeli [10].....	27
Şekil 5.4 Doğrusal fonksiyon [10]	30
Şekil 5.5 Sigmoid fonksiyon [10]	31
Şekil 5.6 Tanjant hiperbolik fonksiyonu [10].....	32
Şekil 5.7 Bir yapay sinir hücresinin çalışma örneği [10]	32
Şekil 5.8 İleri beslemeli ağ için blok diyagram [10]	33
Şekil 5.9 İleri beslemeli 3 katmanlı YSA [10]	34
Şekil 5.10 Geri beslemeli ağ için blok diyagram [10]	35
Şekil 5.11 Danışmanlı öğrenme yapısı [10]	36

Şekil 5.12	Danışmansız öğrenme yapısı [10]	37
Şekil 5.13	Takviyeli öğrenme yapısı [10]	37
Şekil 6.1	Fraktal anten için yapay sinir ağı modeli	44
Şekil 6.2	İkinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi	45
Şekil 6.3	f_{r1} 'in boyut l 'ye göre değişimi	49
Şekil 6.4	f_{r1} 'deki $ S_{11} $ (dB)'in boyut l 'ye göre değişimi	50
Şekil 6.5	f_{r1} 'deki VSWR'nin boyut l 'ye göre değişimi	51
Şekil 6.6	f_{r2} 'nin boyut l 'ye göre değişimi	52
Şekil 6.7	f_{r2} 'deki $ S_{11} $ (dB)'in boyut l 'ye göre değişimi	53
Şekil 6.8	f_{r2} 'deki VSWR'nin boyut l 'ye göre değişimi	54

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 4.1 Fraktal antenin safhalarına göre f_r , $ S_{11} $ dB ve VSWR değerleri.....	16
Çizelge 5.1 Geleneksel algoritmalar ile YSA'lar	22

MINKOWSKİ FRAKTAL ANTEN TASARIMI VE YAPAY SİNİR AĞI MODELİ

Cihan METE

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Filiz Güneş

Bu çalışmada ilk olarak fraktal TUBİTAK ambleminden yola çıkılarak tübitak anteni tasarlanmıştır. Tübitak anteni yama anten olup geniş bantta çalışacak şekilde yapılmıştır. Anten CST programında tasarlanmıştır. Boyutlar en iyi s parametre değerleri çıkacak şekilde ayarlanmıştır. Daha sonra ışıma diyagramları incelenmiştir.

İkinci olarak fraktal antenler hakkında genel bilgiler verildikten sonra bir fraktal yama anten CST programında tasarlanmıştır. Bu anten ikinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi şeklindedir. Burada fraktal antenlerin boşluk doldurma özelliğinden yararlanılmaktadır. Boşluk doldurma özelliği anten boyutunu küçültmeyi mümkün kılar. ikinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi yüzey doldurmaya uygundur. Ayrıca burada fraktal antenlerin kendine benzerlik özelliğinden de yararlanılmaktadır. Bu sayede anten multibant bir davranış sergilemektedir. Fraktal antenin oluşumundaki üç ayrı safha da CST programında tasarlanmıştır. Üç ayrı safhada elde edilen sonuçlar karşılaştırılmıştır. Aradaki farklar gösterilmiştir. Antenin ışıma diyagramı da incelenmiştir.

Daha sonra CST programında tasarlanmış olan fraktal anteni için Yapay Sinir Ağı modeli gerçekleştirilmiştir. Bunun için ilk olarak 3 girdi, 8 ara ve 6 çıktı katmanına sahip ileri beslemeli YSA mimarisi oluşturulmuştur. Oluşturulan YSA mimarisine fraktal antenin boyutlarını belirleyen iki parametresi, yalıtkan malzemenin dielektrik sabiti ve bunlara karşı oluşan CST programında elde edilen çıkış değerleri verilerek Yapay Sinir Ağı'nın

eđitimi saęlanmıřtır. Daha sonra, eđitilen yapay sinir aęını test etmek amacıyla ıkıř deęerleri bilinen farklı giriř parametreleri Yapay Sinir Aęı'na giriř deęeri olarak verilmiřtir. Girdilere (fraktal antenin boyutlarını belirleyen iki parametresi (k, l) ve yalıtkan malzemenin dielektrik sabiti (ϵ)) karřılık YSA'nın rettięi ıkıřlarla CST programında elde edilen ıkıř deęerleri (1. rezonans frekansı (f_{r1}), 1. rezonans frekansındaki $|S_{11}|$ (dB), 1. rezonans frekansındaki VSWR, 2. rezonans frekansı (f_{r2}), 2. rezonans frekansındaki $|S_{11}|$ (dB), 2. rezonans frekansındaki VSWR) antenin boyutu l 'ye baęlı olarak řekil zerinde karřılařtırılarak YSA'nın performansı incelenmiřtir. Toplam 6 tane řekil ortaya ıkmıřtır. Bu iřlemler Matlab programında yapılmıřtır. Yapay Sinir Aęı tasarımı iin Matlab'daki Yapay Sinir Aęı ara kutusundaki fonksiyonlardan yararlanılmıřtır. Bu řekiller incelendięinde iyi eđitilmiř Yapay Sinir Aęları ile elde edilen sonular ve gerek deęerler arasında farkın ok az olduęu grlmřtr. Bu durum, Yapay Sinir Aęları'nın problemin zm iin matematiksel modelin ve algoritmanın bulunmadıęı, sadece rneklerin var olduęu durumlarda bařarılı olduklarını gstermiřtir.

Anahtar Kelimeler: CST, matlab, yapay sinir aęları, fraktal anten, hilbert, minkowski

**MINKOWSKI FRAKTAL ANTENNA DESIGN AND ARTIFICIAL NEURAL
NETWORK MODEL**

Cihan METE

Department of Electronics and Communications Engineering

MSc. Thesis

Advisor: Prof. Dr. Filiz GÜNEŞ

In this work firstly Tubitak antenna is designed which is inspired by TUBİTAK logo. Tubitak antenna is a patch antenna and is working at wide band. Antenna is designed with CST. The sizes are adjusted for best values of S parameters. Then, radiation patterns are examined.

Secondly, after the general introductions about fractal antennas are given, the fractal patch antenna is designed at program of CST. This antenna is Minkowski curve combined with second iteration Hilbert curve. Fractal antennas have space-filling feature. Because of this feature antenna size is miniature. Minkowski curve combined with second iteration Hilbert curve is suitable. Furthermore, fractal antennas have self-similarity feature. Because of this feature fractal antennas exhibit multiband behaviour. Three iterations of constitution of fractal antenna are designed using CST. The results at three different iterations are compared. Differences between them are indicated. Antenna radiation pattern is examined.

Then, Artificial Neural Network model is verified for fractal antenna designed at program of CST. Therefore, a feed-forward backpropagation Artificial Neural Network architecture which has 3 input, 8 sandwich and 6 output layers is built up. Two parameters which show the size of the antenna, dielectric constant of dielectric

material and output values obtained at CST program in response to these input values are given to the Artificial Neural Network architecture and thus education of ANN is provided. Then, for the purpose of testing ANN different input parameters with known output values, are given to ANN as input value. Outputs which ANN generated as of answer for inputs (the antenna sizes (k, l) and dielectric constant (ε) of dielectric material are compared with output parameters (1. resonance frequency (f_{r1}), $|S_{11}|$ (dB) at 1. rezonance frequency, VSWR at 1. rezonance frequency, 2. rezonance frequency (f_{r2}), $|S_{11}|$ (dB) at 2. rezonance frequency, VSWR at 2. rezonance frequency) which is obtained at CST program depending on antenna size (l) on the figure. Thus ANN performance is examined. 6 figures are obtained. These operations are made with MATLAB program. MATLAB tool box is used for ANN design. When these figures are examined, it is understood that difference is very little between the results which ANN generates and real values. Thus, ANN can be used to solve for the problem when mathematical model and algorithm are not found and when only examples are found.

Key words: CST, matlab, artificial neural network, fractal antenna, hilbert, minkowski

GİRİŞ

1.1 Literatür Özeti

Fraktal antenlerle ilgili çalışmalar son yıllarda gittikçe artmaktadır. Bunu nedeni fraktal antenlerin kendine benzerlik ve boşluk doldurma özelliğidir. Kendine benzerlik özelliği sayesinde fraktal antenler multibant davranış gösterirler. Ayrıca kendine benzerlik özelliği kullanılarak bir fraktal anteni geniş bir frekans dizisini almak ve vermek için tasarlanabilir. Boşluk doldurma özelliği de anten boyutunu küçültmeyi mümkün kıldığı için bu özellik sayesinde de anten minyatürleştirilmiş olur. Bu nedenlerden dolayı fraktal antenlerin kullanım alanı gittikçe yaygınlaşmaktadır.

1.2 Tezin Amacı

Geniş bantta çalışacak tübitak ambleminden esinlenilerek bir yama anten ve fraktal antenlere örnek olacak bir fraktal anten tipi tasarlamak, bu fraktal antenin gelişimindeki safhaları incelemek, aradaki farkları bulmak ve son olarak da tasarlanan fraktal antenin değişken parametrelerine karşılık elde edilen çıkış değerlerini tahmin etmek için bir yapay sinir ağı mimarisi oluşturmak ve bu ağı anten tasarımı yapılan programdaki çıkan değerlerle en iyi şekilde eğitmektir.


1.3 Hipotez

Bir fraktal anten tasarlayarak fraktal antenlerin temel özellikleri olan boşluk doldurma ve kendine benzerlik gibi özellikleri kullanılarak hem anten boyu küçültülebilir, hem de anten multibant davranış sergileyebilir, yapay sinir ağları sayesinde de antenin değişken parametrelerine karşılık anten tasarım programında çıkan değerler tahmin edilebilir.

BÖLÜM 2


TUBİTAK ANTEN TASARIMI

Tübitak anten patch anten olup TUBİTAK ambleminden esinlenerek yapılmıştır. Anten CST programında tasarlanmıştır ve geniş bantta çalışması istenmiştir. Boyutlar en iyi S parametresi değerleri çıkacak şekilde ayarlanmıştır. Kalınlığı 2.7 mm, dielektrik sabiti 5.4 olan, 150 mm ve 155 mm ebatlara sahip olan yalıtkan malzeme kullanılmıştır. Bu yalıtkan malzemenin üstüne bir tanesi TUBİTAK amblemi olan bir metal diğeri TUBİTAK amblemi tarafı boşluk, çevresi metal olan iki tane metal konulmuştur. Bunların arasına da ayırık port konulmuştur.




Şekil 2.1 Tübitak Anteni

S parametresi geniş bantta -10 dB'den daha düşüktür.




Şekil 2.2 Frekansa göre S parametresi genliği




Şekil 2.3 Frekansa göre gerilim duran dalga oranı

Tübitak anteninin çeşitli frekanslardaki ışıma diyagramları da incelenmiştir.




Şekil 2.4 3.25 GHz frekansındaki ışıma diyagramı



farfield (f=04.2500) [1]

Frequency = 4.25
Main lobe magnitude = 6.2 dBi
Main lobe direction = 170.0 deg.
Angular width (3 dB) = 34.1 deg.
Side lobe level = -1.0 dB


Şekil 2.5 4.25 GHz frekansındaki ışıma diyagramı



farfield (f=05.5000) [1]

Frequency = 5.5
Main lobe magnitude = 7.3 dBi
Main lobe direction = 170.0 deg.
Angular width (3 dB) = 46.4 deg.
Side lobe level = -1.8 dB

Şekil 2.6 5.5 GHz frekansındaki ışıma diyagramı




farfield (f=10.0000) [1]

Frequency = 10
Main lobe magnitude = 7.4 dBi
Main lobe direction = 30.0 deg.
Angular width (3 dB) = 15.6 deg.
Side lobe level = -3.9 dB

Şekil 2.7 10 GHz frekansındaki ışıma diyagramı

Tübitak anteni TUBITAK ambleminden yola çıkılarak CST programında geniş bantta çalışacak şekilde tasarlanmıştır. Frekans bandı 3 ile 11 GHz arasındadır.



Şekil 2.8 Tübitak anteninin kazancı

BÖLÜM 3

FRAKTAL ANTENLER

Fraktal terimi kırık ve düzensiz parçacıklar anlamına gelir. İlk olarak Mandelbrot tarafından geometrik yapısında doğal kendi benzerliğine sahip olan kompleks biçimindeki kümeyi tanımlamak için kullanıldı. Fraktallar doğada çok bulunur. Örneğin kar tanesi, eğrelti otu, kıyı şeridi, dağ dizileri ve hatta galaksiler.

İlk ve belki de en tanınmış fraktal geometrisi olarak Sierpinski gasketi olarak bilinir. Üçgenin ortasında bulunan üçgenin çıkartılmasıyla üretilir. Başka bir yararlı fraktal Koch kar tanesidir. Daha küçük üçgenlerin yapıya eklenmesiyle oluşturulur.

Anten elemanları ve dizi konfigürasyonları için gelişen yeni tasarım metodlarında rastgele ya da deterministik fraktal ağaçlara dayanan çok sayıda yapının son derece yararlı olduğu kanıtlanmıştır.

Fraktal tilelar ya da fraktileler, anten teori ve tasarımında uygulama bulan fraktal nesnelerin bir başka önemli kategorisini gösterir. Fraktallar fraktal sınırlara sahip olan tile ya da adalardır. Onlar tilelar arasında hiç boşluk bırakmadan ya da üst üste binmeden düzlemi kaplamak için kullanılabilen mümkün tile geometrilerin tek kümesidir. Kar taneleri ve Gosper adaları bir tiling aracılığıyla düzlemi kaplamak için kullanılabilir.

3.1 Kronoloji

- 1947- Chu ve Wheeler küçük antenlerin performansı üzerine temel sınır kanıtlarlar. (Wheeler-1947; Chu-1948)

- 1983-Benoit B. Mandelbrot fraktal kelimesini kullanır.
- 1986-Kim ve Jaggard anten teorisinde fraktal dizilerin kullanımını rapor ederler. Bu çalışma rastgele fraktal dizilerin kullanımı hakkındadır.

3.2 Uygulama Alanları

Multi-band iletimde fraktal anten dizi uygulamalarından çok sayıda örnek vardır:

- Elle tutulan kablosuz cihazlar
- Dual mod telefonlar
- Global konumlanmış uydu sistemleri (GPS)

3.3 Avantajlar

- Büyük boy azalması elde edilir.
- Radyasyon karakteristikleri korunur.
- Daha geniş çalışma frekans bant genişliği elde edilir.
- Tasarım metodunun kolaylığı sağlanmış olur.
- Düşük yan lob seviyesi elde edilmiş olur.

3.4 Özellikler

Fraktal antenler iki genel özelliğe sahiptir:

- Boşluk doldurma
- Kendine benzerlik

3.4.1 Boşluk Doldurma

- Space-filling
- Boşluk doldurma özelliği anten boyutunu küçültmeyi mümkün kılar.

3.4.2 Kendine Benzerlik

- Self-similarity
- Belirli fraktalların kendine benzerlik özellikleri multi bant davranışıyla sonuçlanır.
- Kendine benzerlik özelliği kullanılarak bir fraktal anteni geniş bir frekans dizisini almak ve vermek için tasarlanabilir.


3.5 Kullanım Alanları

Fraktal anten dizi uygulamalarının multi bant iletiminde çok sayıda örneği vardır:


- Elle tutulan kablosuz cihazlar
- Dual-mod telefonlar
- Global konum belirleyen uydu sistemleri (GPS)
- Fraktal şekillerin boşluk doldurma ve kendine benzerlik özelliklerinden dolayı, fraktal teori mikrodalga bileşenlerin boyutunu azaltmak için mikrodalga mühendisliğinde geniş bir şekilde uygulanır.
- Elektromanyetik bant aralığı (EBG) alçak geçiren filtreler
- Kol hattı kuplörleri
- Fraktal anten belli bir bütün yüzey alanında elektromanyetik sinyalleri ileten ve alan materyalin uzunluğunu maksimize eden fraktal tasarımını kullanır.
- Bu sebeple fraktal antenler çok küçültülmüştür ve böylece cep telefonlarında ve mikrodalga haberleşmede yararlı uygulamalara sahiptirler.
- Fraktal antenin yanıtı geleneksel anten tasarımlarına göre belirgin şekilde farklıdır. Çok farklı frekans dizilerinde eş zamanlı olarak optimal çalışabilir.
- Bu özellik fraktal anteni geniş bant uygulamaları için harika bir tasarım yapar.

3.6 Fraktal Anten Tipleri


- Koch ve Minkowski antenlerinin asıl avantajları boyutların minimizasyonu ve küçük boyut için giriş empedanslarının artmasıdır.
- Sierpinski gasket fraktal anteni multibant davranış gösteren kendine benzer antenin iyi bir örneğidir.
- Hilbert eğrisi yüzey doldurmaya uygundur. Yüzey doldurma özelliği elektriksel çok uzun eğrilere götürür. Ama küçültülmüş fiziksel alana sığar.




Şekil 3.1 Sierpinski ara levhası




Şekil 3.2 Koch fraktal (kar tanesi)



Şekil 3.3 Ağaç fraktal



Şekil 3.4 Hilbert eğrisi



Şekil 3.5 Gosper ada fraktal


Koch kar taneleri ve adaları mikrodizi yama antenleri gibi minyatürize edilmiş döngü için yeni tasarımlar geliştirmek için kullanıldı. Üstelik, fraktile konseptler ve Gosper ada mikrodizi antenlerinin tasarımında görev aldı. Sierpinski ara levhaları ve halılarının kendine benzer yapısı multibant ve geniş bant anten elemanlarını geliştirmek için ortaya çıktı. Sonuç olarak minyatürize dipol ve monopol antenler için yeni tasarımlar Koch eğrileri ve fraktal ağaçların değişimine dayanarak geliştirildi.

Fraktal ağaçların kendine benzer özelliklerinden multibant karakteristikli anten elemanları yaratmak için yararlanıldı. Ek olarak, fraktal ağaç geometrileri anten tasarımlarını minyatürize etmek için kullanıldı. Bu anten kümesi, bant genişliğini ya da kazancı önemli bir şekilde etkilemeden (kıyaslanabilir uzunluktaki) standart dipol antenlerden daha düşük rezonans frekansı gösterir. Daha yoğun fraktal ağaç uç yükleri daha az yoğun yapılara göre rezonans frekansında çok daha fazla azalma gösterir. Küçük dar elevasyon açılı fraktal ağaç antenleri daha düşük VSWR'ye sahip ama daha yüksek rezonans frekansına sahiptir.


FRAKTAL ANTEN TASARIMI

Fraktal anten tipi olarak ikinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi seçilmiştir. Patch anten şeklinde olup CST programında tasarlanmıştır. Fraktal anteni gelişimindeki üç safha da ayrı ayrı CST programında tasarlanmıştır.


Üç safha için de aynı yalıtkan malzemeler kullanılmıştır. 2 mm kalınlığında, 36 mm boy ve enindeki dielektrik sabiti 4.3 olan yalıtkan malzeme seçilmiştir.



Şekil 4.1 Fraktal antenin ilk safhası




Şekil 4.2 Fraktal antenin ikinci safhası




Şekil 4.3 Fraktal antenin üçüncü safhası


Fraktal antenin gelişimindeki üç safha için de S parametreleri incelenmiştir.



Şekil 4.4 Fraktal antenin birinci safhası için frekansa göre S parametresi



Şekil 4.5 Fraktal antenin ikinci safhası için frekansa göre S parametresi



Şekil 4.6 Fraktal antenin üçüncü safhası için S parametresi

Şekillerden de görüldüğü gibi safhalar geçtikçe rezonans frekansları da düşmektedir.


Her safha için gerilim duran dalga oranı da incelenmiştir.

Çizelge 4.1 Fraktal antenin safhalarına göre f_r , $|S_{11}|$ dB ve VSWR değerleri


S a f h a	f_{r1}	f_{r1} için $ S_{11} $ dB	f_{r1} 'de VSWR	f_{r2}	f_{r2} 'de $ S_{11} $ dB	f_{r2} 'de VSWR	f_{r3}	f_{r3} için $ S_{11} $ dB	f_{r3} 'de VSWR
1	2.54	-38.50	1.0241	3.815	-23.75	1.1389			
2	2.20	-13.72	1.5188	3.16	-16.068	1.3732	4.03	-18.60	1.2661
3	2.195	-11.83	1.6886	3.125	-11.227	1.7569	3.925	-15.82	1.3863

Çizelge 4.1'den de görüleceği üzere bir fraktal anten tipi olan ikinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi için safhalar geçtikçe rezonans frekansı düşmekte, gerilim duran dalga oranı artmaktadır. Burada fraktal antenlerin boşluk doldurma özelliğinden yararlanılmaktadır. Boşluk doldurma özelliği anten boyutunu küçültmeyi mümkün kılar. İkinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi yüzey doldurmaya uygundur. Ayrıca burada fraktal antenlerin kendine benzerlik özelliğinden de yararlanılmaktadır. Bu sayede anten multibant bir davranış sergilemektedir.


Antenin ışıma diyagramı da incelenmiştir.



Şekil 4.7 Fraktal antenin birinci aşaması için 2.6 GHz frekansındaki ışıma diyagramı



Şekil 4.8 Fraktal antenin ikinci aşaması için 2.2 GHz frekansındaki ışıma diyagramı



Şekil 4.9 Fraktal antenin üçüncü aşaması için 2.2 GHz frekansındaki ışıma diyagramı

BÖLÜM 5

YAPAY SİNİR AĞLARI

Bu bölümde Yapay Sinir Ağları hakkında ayrıntılı olarak bilgi verilmiştir.

5.1 Genel Tanım

Yapay sinir ağları (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir.

Yapay sinir ağları; insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşı sonucu ortaya çıkmıştır. Bu nedenledir ki, bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamış, daha sonraları bilgisayar sistemlerinin gelişimine de paralel olarak bir çok alanda kullanılır hale gelmiştir. İnsan beyninin çalışma prensibini taklit ederek çalışan bu sistemler, her ne kadar bilgisayar teknolojisi hızlı bir gelişim göstermiş, işlem hızları nano saniyeler mertebesine inmiş olsa da, bırakalım insan beynini, ilkel bir canlı beyninin fonksiyonları dahi baz alındığında, böyle bir organizmanın yanında çok ilkel kalmaktadır. Nano saniyeler bazındaki işlem hızları ile YSA'lar, mili saniyeler mertebesindeki işlen hızları ile işlem yapan insan beyninin işlevselliğinin henüz çok uzağındadır.

Burada kısa bir hatırlatma yapmak gerekirse; insan beyinde yaklaşık 10^{11} sinir hücrelerinin varlığından bahsedilmekle birlikte, bu sayının bilgisayar ortamında modellenmesi şu an için mümkün görünmemektedir. Fakat karar hızı açısından insan beyni ile henüz yarışamaları bile, YSA'lar yapısallıkları ve hassas eşleştirmelerin başarı ile gerçekleştirebilmeleri ile gün geçtikçe daha fazla uygulama alanı bulmaktadır.

5.2 YSA'ların Avantaj ve Dezavantajları

Yapay sinir ağlarının genel olarak sayılabilecek birçok avantaj ve dezavantajları vardır.

- YSA'lar makina öğrenmesi gerçekleştirebilirler. Yapay sinir ağlarının temel işlevi zaten bilgisayarın öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında mantıklı kararlar verebilirler.
- Bilgi işleme yöntemleri geleneksel programlamadan farklıdır. Bu nedenle geleneksel programlamanın getirdiği bir çok olumsuzluk ortadan kaldırılabilir.
- Bilgiler ağı tamamında saklanır. Geleneksel programlamada olduğu gibi bilgiler veri tabanları yada dosyalarda belli bir düzende tutulmaz, ağına tamamına yayılarak değerler ile ölçülen ağı bağlantılarında saklanmaktadır. Nöronlardan bazılarının işlevini yitirmesi, anlamlı bilginin kaybolmasına neden olmaz.
- Örnekleri kullanarak öğrenirler. YSA'nın öğrenebilmesi için örneklerin belirlenmesi, bu örneklerin ağına gösterilerek istenen çıktıya göre ağına eğitilmesi gerekmektedir. Ağına başarısı, seçilen örnekler ile doğru orantılıdır, ağına olay bütün yönleri ile gösterilemezse ağına yanlış çıktılar üretebilir.
- Daha önce görülmemiş örnekler hakkında bilgi üretebilirler. YSA'lar eğitimleri sırasında kendilerine verilen örneklerden genellemeler çıkarırlar ve bu genellemeler ile yeni örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik olaylarda kullanılabilirler. YSA'ların en başarılı oldukları alanlar, algılamaya yönelik uygulama alanlarıdır. Bu alanlarda başarıları kanıtlanmıştır.
- Örüntü (pattern) ilişkilendirme ve sınıflandırma yapabilirler: YSA'lar kendilerine örnekler halinde verilen örüntüleri kendisi veya diğerleri ile ilişkilendirebilir.

Ayrıca kendisine verilen örneklerin kümelenmesi ile, bir sonraki verinin hangi kümeye dahil olacağının karar verilmesi konusunda kullanılabilirler.

- Örüntü tamamlama yapabilirler. Ağa eksik bilgileri içeren örüntüler verildiğinde eksik bilgilerin tamamlanması konusunda başarılıdır.
- Kendi kendine öğrenebilme ve organize etme yetenekleri vardır. YSA'lar online olarak öğrenebilirler ve kendi kendilerini eğitebilirler.
- Eksik bilgi ile çalışabilmektedirler. Geleneksel sistemlerin aksine YSA'lar eğitildikten sonra veriler eksik bilgi içerse dahi, çıktı üretebilirler. Bu durum bir performans kaybı yaratmaz, performans kaybı eksik bilginin önemine bağlıdır. Burada bilgilerin önem dereceleri eğitim sırasında öğrenilir.
- Hata toleransına sahiptirler. YSA'ların eksik bilgilerle çalışabilmeleri ve bazı hücreleri bozulsa dahi çalışabilmeleri, onları hatalara karşı toleranslı yapar.
- Dereceli bozulma gösterirler. Bir ağ, zaman içerisinde yavaş ve göreceli bir bozulmaya uğrar. Ağlar problemin ortaya çıktığı anda hemen bozulmazlar.
- Dağıtık belleğe sahiptirler. YSA'larda bilgi ağa dağılmış bir şekilde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisini gösterir. Bu nedenle tek bir bağlantının kendi başına anlamı yoktur.

Burada çok temel bazı avantajlardan bahsedilmekle beraber, YSA'ların daha pek çok avantajı vardır.

YSA'ların, pek çok avantajının yanında bazı dezavantajları da vardır. Belli başlı dezavantajları;

- Donanım bağımlıdır. YSA'ların en önemli sorunu donanım bağımlı olmalarıdır. YSA'ların en önemli özellikleri ve var oluş nedenlerinden birisi olan paralel işlem yapabilme yeteneği, paralel çalışan işlemciler ile performans gösterir.
- Uygun ağ yapısının belirlenmesinde belli bir kural yoktur. YSA'larda probleme uygun ağ yapısının belirlenmesi için geliştirilmiş bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yolu ile belirlenmektedir.
- Ağın parametre değerlerinin belirlenmesinde belli bir kural yoktur. YSA'larda öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin

belirlenmesinde belirli bir kural yoktur. Bu deęerlerin belirlenmesi iin belirli bir standart olmamakla birlikte her problem iin farklı bir yaklaşıım söz konusu olabilmektedir

- Öğrenilecek problemin aęa gösterimi önemli bir problemdir. YSA'lar nümerik bilgiler ile çalışabilmektedirler. Problemler YSA'lara tanıtılmadan önce nümerik deęerlere çevrilmek zorundadırlar. Burada belirlenecek gösterim mekanizması aęın performansını doğrudan etkileyecektir. Bu da kullanıcının yeteneğine baęlıdır.
- Aęın eęitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur. Aęın örnekler üzerindeki hatasının belirli bir deęerin altına indirilmesi eęitimin tamamlandığı anlamına gelmektedir. Burada optimum neticeler veren bir mekanizma henüz yoktur ve YSA ile ilgili araştırmaların önemli bir kolunu oluşturmaktadır.
- Aęın davranışları açıklanamamaktadır. Bu sorun YSA'ların en önemli sorunudur. YSA bir probleme çözüm ürettiği zaman, bunun neden ve nasıl olduğuna ilişkin bir ipucu vermez. Bu durum aęa olan güveni azaltıcı bir unsurdur.

Çizelge 5.1 Geleneksel algoritmalar ile YSA'lar

Geleneksel Algoritmalar	Yapay Sinir Ağları
Çıkışlar, koyulan kurallara girişlerin uygulanması ile elde edilir.	Öğrenme esnasında giriş çıkış bilgileri verilerek, kurallar koyulur.
Hesaplama; merkezi, eş zamanlı ve ardışıldır.	Hesaplama; toplu,eş zamansız öğrenmeden sonra paraleldir.
Bellek paketlenmiş ve hazır bilgi depolanmıştır.	Bellek ayrılmış ve ağa yayılmıştır. Dahilidir.
Hata toleransı yoktur.	Hata toleransı vardır.
Nisbeten hızlıdır.	Yavaş ve donanıma bağımlıdır.
Bilgiler ve algoritmalar kesindir.	Deneyimden yararlanır.

5.3 YSA Nasıl Çalışır ?

Sinir ağı ile hesaplamalarda istenilen dönüşüm için, adım adım yürütülen bir yöntem gerekmez. Sinir ağı ilişkilendirmeyi yapan iç kuralları kendi üretir ve bu kuralları, bunların sonuçlarını örneklerle karşılaştırarak düzenler. Deneme ve yanılma ile, ağ kendi kendine işi nasıl yapması gerektiğini öğretir. YSA'larda bilgi saklama, verilen eğitim özelliğini kullanarak eğitim örnekleri ile yapılır. Sinirsel hesaplama, algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme olayıdır. Uygulama imkanının olduğu her yerde, tamamen yeni bilgi işleme yetenekleri geliştirebilir. Bu sayede de geliştirme harcamaları ile geliştirme süresi büyük ölçüde azalır.

Bir Yapay Sinir Ağı girdi setindeki değişiklikleri değerlendirerek öğrenir ve buna bir çıktı üretir. Öğrenme işlemi benzer girdi setleri için aynı çıktıyı üretecek bir öğrenme algoritması ile gerçekleşir. Öğrenme setindeki girdilerin istatistiksel özelliklerinin çıkarılarak benzer girdilerin gruplandırılmasını sağlayan bir işlemdir. Sinir yapılarına benzetilerek bulunan ağların eğitimi de, normal bir canlının eğitimine benzemektedir. Sınıfların birbirinden ayrılması işlemi (dolayısıyla kendini geliştirmesi), öğrenme algoritması tarafından örnek kümeden alınan bilginin adım adım işlenmesi ile gerçekleşir. YSA kullanılarak makinelere öğrenme genelleme yapma, sınıflandırma, tahmin yapma ve algılama gibi yetenekler kazandırılmıştır.

5.4 YSA'nın Eğitimi ve Testi

Geleneksel bilgisayar uygulamalarının geliştirilmesinde karşılaşılan durum, bilgisayarın belli bilgisayar dilleri aracılığıyla ve kesin yazım algoritmalarına uygun ifadelerle programlanmasıdır. Bu oldukça zaman alan, uyumluluk konusunda zayıf, teknik personel gerektiren, çoğu zaman pahalı olan bir süreçtir. Oysa biyolojik temele dayalı yapay zeka teknolojilerinden biri olan yapay sinir ağlarının geliştirilmesinde programlama, yerini büyük ölçüde "eğitime" bırakmaktadır. Proses elemanlarının bağlantı ağırlık değerlerinin belirlenmesi işlemine "ağın eğitilmesi" denir. Yapay sinir ağının eğitilmesinde kullanılan girdi ve çıktı dizileri çiftinden oluşan verilerin tümüne "eğitim seti" adı verilir.

Yapay sinir ağı öğrenme sürecinde, gerçek hayattaki problem alanına ilişkin veri ve sonuçlardan, bir başka deyişle örneklerden yararlanır. Gerçek hayattaki problem alanına ilişkin değişkenler yapay sinir ağının girdi dizisini, bu değişkenlerle elde edilmiş gerçek hayata ilişkin sonuçlar ise yapay sinir ağının ulaşması gereken hedef çıktıların dizisini oluşturur.

Öğrenme süresinde, seçilen öğrenme yaklaşıma göre ağırlıklar değiştirilir. Ağırlık değişimi, öğrenmeyi ifade eder. YSA'da ağırlık değişimi yoksa, öğrenme işlemi de durmuştur. Başlangıçta bu ağırlık değerleri rastgele atanır. YSA'lar kendilerine örnekler gösterildikçe, bu ağırlık değerlerini değiştirirler. Amaç, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Ağın doğru ağırlık değerlerine

ulaşması örneklerin temsil ettiği olay hakkında, genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine, “ağın öğrenmesi” denir.


Yapay Sinir Ağı’nın öğrenme sürecinde temel olarak üç adım bulunmaktadır:

- Çıktıları hesaplamak.
- Çıktıları hedef çıktılarla karşılaştırmak ve hatayı hesaplanmak.
- Ağırlıkları değiştirerek süreci tekrarlamak.


Eğitim süreci sonucunda yapay sinir ağında hesaplanan hatanın kabul edilebilir bir hata oranına inmesi beklenir. Ancak hata kareleri ortalamasının düşmesi her zaman için yapay sinir ağının genellemeye ulaştığını göstermez. Yapay sinir ağının gerçek amacı girdi-çıkı örnekleri için genellemeye ulaşmaktır.

Genelleme, yapay sinir ağının eğitimde kullanılmamış ancak aynı evrenden gelen girdi-çıkı örneklerini ağın doğru bir şekilde sınıflandırabilme yeteneğidir. İstatistiksel açıdan genelleme bir uygun eğrinin bulunması (curve-fitting) veya doğrusal olmayan ara değer atama işi (interpolation) olarak görülebilir. Şekil 5.1 (a)'da genellemenin nasıl gerçekleştiği görülmektedir. Şekilde (x) ile görülen noktalar eğitim verileridir. Bunların arasında kalan eğri ise ağ tarafından oluşturulmaktadır. Bu eğri üzerindeki farklı bir girdi değeri için üretilen doğru çıkı değeri, ağın iyi bir genelleme yaptığını gösterir. Ancak ağ gereğinden fazla girdi-çıkı ilişkisini öğrendiğinde, ağ verileri "ezberlemektedir" (memorization). Bu durum genellikle gereğinden fazla gizli katman kullanıldığında verilerin synaptic bağlantılar üzerinde saklanması veya gereğinden fazla veri kullanılarak eğitilmesinden (overtraining) kaynaklanmaktadır. Ezberleme, genellemenin iyi gerçekleşmediğini ve girdi-çıkı eğrisinin düzgün olmadığını gösterir (Şekil 5.1 (b)). Verilerin ezberlenmiş olması yapay sinir ağı için istenmeyen bir durum olup, verileri ezberleyen ağa ait eğitim hatası oldukça düşme, test verilerinde ise hata artma eğilimi gösterir. Bundan dolayı bir çok yapay sinir ağı yazılımı ağın eğitim ve test verilerine ait hataları grafik olarak göstermektedir. Verileri ezberleyen ağ gerçek hayattaki örüntüyü iyi temsil edemeyeceği için kullanılamaz. Şekil 5.2 (a) 'da ağ verileri

ezberlediği için eğitim hatası azalma, test hatası ise artma eğilimi göstermektedir. Şekil 5.2 (b)'de ise ağ kabul edilebilir bir genellemeye ulaşmıştır.



Şekil 5.1 (a) Genelleme ve (b) Ezberleme [10]



Şekil 5.2 (a) Verileri ezberleyen ve (b) iyi genellemeye ulaşan ağlardaki hata eğrileri [10]

En uygun öğrenme seviyesi, öğrenme fonksiyonunun önceden amaçlanan bir değere ulaşması ile sağlanamayabilir. Uygulamalarda eğitim süreci boyunca performans fonksiyonunun izlenmesi ile birlikte sık sık genelleme testlerinin gerçekleştirilmesi yolu ile en uygun öğrenme seviyesi elde edilebilir. Eğer en uygun öğrenme seviyesine, performans fonksiyonunun öngörülerinden önce ulaşılmış ise eğitim süresi daha erken dönemlerde de sona erdirilebilir.

YSA sistemlerinin problemi öğrenme başarısı, gerçekleştirilen testlerle sınanmalıdır. Yapay sinir ağı geliştirme sürecinde veriler ikiye ayrılır; bir bölümü ağı eğitilmesi için kullanılır ve eğitim seti adını alır, diğer bölümü ise ağı eğitim verileri dışındaki performansını ölçmede kullanılır ve “test seti” olarak adlandırılır.

Eğitim ve test setleriyle ilgili temel sorun, yeterli eğitim ve test verisinin miktarının ne olduğudur. Sınırsız sayıda verinin bulunabildiği durumlarda, yapay sinir ağı mümkün olan en çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda emin olmanın yolu; eğitim verisinin miktarının arttırılmasının, ağın performansında bir değişiklik yaratmadığını takip etmektir. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağına eğitim ve test verileri üzerindeki performansının yakın olması da verilerin sayıca yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir. Bununla birlikte eğitim setinin içermesi gereken veri miktarı değişik yapay sinir ağı modellerine göre ve özellikle problemin gösterdiği karmaşıklığa göre farklılık gösterebilmektedir.

Test işlemi için, eğitim setinde kullanılmayan verilerden oluşan test seti kullanılır. Test setindeki girdiler YSA modeline verilir ve YSA'nın çıktı değeri ile istenilen çıktı değeri karşılaştırılır. Amaç, YSA modelinin yeterli bir genelleme yapıp yapamadığını görmektir. Eğitim ve test aşamalarında istenilen başarı elde edilirse YSA modeli kullanılabilir. (train and test) ile çapraz geçerlilik (cross validation) setinin %25 ile %90 arasında değişen miktarı eğitim seti olarak seçilir. Geri kalan kısım ise test seti olarak ayrılır. Çapraz geçerlilik tekniğinde ise, YSA'nın eğitilmesinde ve test edilmesinde tüm veri seti kullanılır. Bu yaklaşımda, tüm veri seti k adet örtüşmeyen kümeye ayrılır ve k farklı YSA elde edilir. Her YSA'nın testinde farklı bir küme kullanılmak üzere, eğitim işlemi geri kalan k-1 adet küme ile gerçekleştirilir. Uygulama kullanılacak YSA ise, tüm veri seti kullanılarak eğitilir. Bu YSA'nın performansı, k farklı YSA'nın test sonuçlarının ortalaması ile ölçülür.

5.5 YSA'nın Yapısı

Sinir hücreleri bir grup halinde işlev gördüklerinde ağ (network) olarak adlandırılırlar ve böyle bir grupta binlerce nöron bulunur. Yapay nöronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır.

Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir.

Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır.

Katmanların deęiřik řekilde bir birleriyle baęlanmaları deęiřik aę mimarilerini doęurur. YSA'lar üç katmandan oluřur. Bu katmanlar sırasıyla ařaęıdaki gibidir:

- Girdi katmanı
- Ara Katman
- Çıktı Katmanı

5.5.1 Girdi Katmanı


Bu katmandaki proses elemanları dıř dūnyadan bilgileri alarak ara katmanlara transfer ederler. Bazı aęlarda girdi katmanında herhangi bir bilgi iřleme olmaz.

5.5.2 Ara Katman (Gizli Katman)

Girdi katmanından gelen bilgiler iřlenerek çıktı katmanına gönderilirler. Bu bilgilerin iřlenmesi ara katmanlarda gerekleřtirilir. Bir aę içinde birden fazla ara katman olabilir.

5.5.3 Çıktı Katmanı

Bu katmandaki proses elemanları ara katmandan gelen bilgileri iřleyerek aęın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dıř dūnyaya gönderilir.



řekil 5.3 Yapay sinir aęı modeli [10]

5.6 Yapay Sinir Hücresi

Biyolojik sinir ağlarında olduğu gibi yapay sinir ağlarında da temel unsur, yapay sinir hücresidir. Yapay sinir hücresi, YSA'nın çalışmasına esas teşkil eden en küçük ve temel bilgi işleme birimidir. Ağ içinde yer alan tüm nöronlar bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı yapay sinir ağının dışına verilen çıktılar olabileceği gibi başka nöronlara girdi olarak da kullanılabilirler. Geliştirilen hücre modellerinde bazı farklılıklar olmakla birlikte genel özellikleri ile bir yapay hücre modeli 5 bileşenden oluşmaktadır.

Bunlar;

- Girdiler
- Ağırlıklar
- Birleştirme Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktı

5.6.1 Girdiler

Girdiler, diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir.

5.6.2 Ağırlıklar

Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girer ve ağırlıklar, ilgili girişin hücre üzerindeki etkisini belirler. Ağırlıklar bir nöronda girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) gösterir. Yapay sinir ağı içinde girdilerin nöronlar arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar her işlem elemanının her girdisi üzerinde etki yapmaktadır.

5.6.3 Birleştirme Fonksiyonu

Birleştirme fonksiyonu, bir hücreye gelen net girdiyi hesaplayan bir fonksiyondur ve genellikle net girdi, girişlerin ilgili ağırlıkla çarpımlarının toplamıdır. Birleştirme fonksiyonu, ağ yapısına göre maksimum alan, minimum alan ya da çarpım fonksiyonu olabilir.

$$v = \sum x_i w_i + \theta, y = F(v) \quad (5.1)$$

w: Hücrenin ağırlıklar matrisi

x: Hücrenin giriş vektörü

v: Hücrenin net girişi

y: Hücre çıkışı

5.6.4 Aktivasyon Fonksiyonu


Transfer fonksiyonu olarak da geçen aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili yada uyarlanabilir parametrelili seçilebilir. En uygun aktivasyon fonksiyonu tasarımcının denemeleri sonucunda belli olur. Aktivasyon fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılanı simoid ve hiperbolik tanjant fonksiyonlarıdır. Örneğin eğer ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid fonksiyon, ortalamadan sapmanın öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyon kullanılması önerilmektedir.

Aktivasyon fonksiyonları bir YSA'da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler genellikle [0,1] veya [-1,1] arasındadır. YSA'da kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gereklidir. Lineer veya doğrusal olmayan transfer fonksiyonlarının kullanılması YSA'ların karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır.

Aşağıda, hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları tanıtılmıştır.

5.6.4.1 Doğrusal Aktivasyon Fonksiyon


Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve YSA' da yada genellikle katmanlı YSA' nın çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu matematiksel olarak $y=Ax$ şeklinde tanımlanabilir. "A" sabit bir katsayıdır. YSA'ların çıkış katmanında kullanılan doğrusal fonksiyon Şekil 3.12'te verilmiştir.



Şekil 5.4 Doğrusal fonksiyon [10]

5.6.4.2 Sigmoid Aktivasyon Fonksiyonu

Sigmoid Aktivasyon Fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle uygulamada en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyon, girdinin her değeri için sıfır ile bir arasında bir değer üretir.




Şekil 5.5 Sigmoid fonksiyon [10]

Sigmoid fonksiyonunun denklemleri;

$$y = \frac{1}{1 + e^{-v}} \quad (5.2)$$

Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonunun biraz farklı şeklidir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Sigmoid fonksiyonun çıktı aralığı 0 ve 1 olurken, hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır.



Şekil 5.6 Tanjant hiperbolik fonksiyonu [10]

Tanjant fonksiyonunun formülü;


$$y = \frac{1 - e^{-2v}}{1 + e^{-2v}} \quad (5.3)$$

Yukarıda anlatılan aktivasyon fonksiyonlarından başka, literatürde geçen diğer aktivasyon fonksiyonları;

- Basamak Fonksiyonu
- Kutuplamalı Basamak Fonksiyonu
- Parçalı Doğrusal Fonksiyon

5.6.5 Çıktı

Aktivasyon fonksiyonundan geçirildikten sonra elde edilen değer, çıktı değeridir.



Şekil 5.7 Bir yapay sinir hücresinin çalışma örneği [10]

Ağırlıklı toplam alınarak hücreye gelen net bilgi, şu şekilde hesaplanır;

$$NET = 0.5*(0.1) + 0.6*(-0.2) + 0.9(-0.1) + 0.5(0.7) = 1.225 \quad (5.4)$$

Hücrenin sigmoid fonksiyonuna göre çıktısı;

$$Sonuç = \frac{1}{1+e^{-1.225}} = 0.77 \quad (5.5)$$

5.7 Yapay Sinir Ağlarının Sınıflandırılması


YSA'lar, genel olarak birbirleri ile bağlantılı işlemci birimlerden (sinir hücresi) oluşurlar. Her bir sinir hücresi arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan öğrenme algoritmasına göre, hatayı sıfıra indirecek şekilde, ağın ağırlıkları değiştirilir. YSA'lar yapılarına ve öğrenme algoritmalarına göre sınıflandırılırlar.

5.7.1 YSA'ların Yapılarına Göre Sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.


5.7.1.1 İleri Beslemeli Ağlar

İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 5.8'de ileri beslemeli ağ için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir.



Şekil 5.8 İleri beslemeli ağ için blok diyagram [10]

İleri beslemeli YSA' da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar, doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denmektedir. Şekil 5.9'da giriş, orta ve çıkış katmanı olmak üzere 3 katmanlı ileri beslemeli YSA yapısı verilmiştir.




Şekil 5.9 İleri beslemeli 3 katmanlı YSA [10]

Herhangi bir problemi çözmek amacıyla kullanılan YSA da, katman sayısı ve orta katmandaki hücre sayısı gibi kesin belirlenememiş bilgilere rağmen nesne tanıma ve sinyal işleme gibi alanların yanı sıra, ileri beslemeli YSA, sistemlerin tanınması ve denetiminde de yaygın olarak kullanılmaktadır.

5.7.1.2 Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 5.10'da bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için

uygundurlar. Geri beslemeli ağılar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağıları verilebilir.



Şekil 5.10 Geri beslemeli ağ için blok diyagram [10]

Geri beslemeli YSA' da, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir. Geriye doğru hesaplamada, ağın ürettiği çıktı değeri, ağın beklenen çıktıları ile kıyaslanır. Bunların arasındaki fark, hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Çıktı katmanında m . proses için oluşan hata, $E_m = B_m - \hat{C}_m$ olacaktır. Çıktı katmanında oluşan toplam hatayı bulmak için, bütün hataların toplanması gereklidir. Bazı hata değerleri negatif olacağından, toplamın sıfır olmasını önlemek amacıyla ağırlıkların kareleri hesaplanarak sonucun karekökü alınır. Toplam hatayı en aza indirmek için, bu hatanın kendisine neden olan proses elemanlarına dağıtılması gerekmektedir. Bu da, proses elemanlarının ağırlıklarını değiştirmek demektir.


5.7.2 YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. Birtakım metot ve kurallar, gözlem ve eğitim ile

ağıdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme kuralları aşağıda açıklanmaktadır.

5.7.3 Danışmanlı Öğrenme


Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. Bu öğrenmede ağıın ürettiği çıktılar ile hedef çıktılar arasındaki fark hata olarak ele alınır ve bu hata minimize edilmeye çalışılır. Bunun için de bağlantıların ağırlıkları en uygun çıkışı verecek şekilde değiştirilir. Bu sebeple danışmanlı öğrenme algoritmasının bir “öğretmene” veya “danışmana” ihtiyacı vardır. Şekil 5.11’de danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.



Şekil 5.11 Danışmanlı öğrenme yapısı [10]

5.7.3.1 Danışmansız Öğrenme


Bu tür öğrenmede ağına sadece girdiler verilir. Ağıın ulaşması gereken hedef çıktılar verilmez. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Şekil 5.12’de danışmansız öğrenme yapısı gösterilmiştir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.



Şekil 5.12 Danışmansız öğrenme yapısı [10]

5.7.3.2 Takviyeli Öğrenme

Takviyeli öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Takviyeli öğrenme (reinforcement training) yöntemi öğreticili öğrenme yöntemine benzemekle birlikte, ağı hedef çıktılar yerine, ağı çıktılarının ne ölçüde doğru olduğunu belirten bir skor veya derece bildirilir. Şekil 5.13'te takviyeli öğrenme yapısı gösterilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya GA takviyeli öğrenmeye örnek olarak verilebilirler.



Şekil 5.13 Takviyeli öğrenme yapısı [10]

5.8 Uygulamaya Göre Öğrenme Algoritmaları

Uygulamaya göre öğrenme algoritmalarını çevrimiçi ve çevrimdışı öğrenme algoritmaları olarak ikiye ayırabiliriz.

5.8.1 Çevrim İçi (On-line) Öğrenme

Bu kurala göre öğrenen sistemler, gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirmekte, bir taraftan da öğrenmeye devam etmektedirler. ART ve Kohonen öğrenme kuralı bu sınıfta bulunan öğrenme bu öğrenme kuralına örnek olarak verilebilir.

5.8.2 Çevrim Dışı (Offline) Öğrenme

Bu kurala dayalı sistemler, kullanıma alınmadan önce örnekler üzerinde eğitilirler. Bu kuralı kullanan sistemler eğitildikten sonra gerçek hayatta kullanıma alındığında artık öğrenme olmamaktadır. Delta öğrenme kuralı bu tür öğrenmeye örnek olarak verilebilir.

5.8.3 Yapay Sinir Ağ Yapıları

YSA'daki sinir sayısı, sinirlerin birbirine göre konumu ve sinirler arası sinyallerin akış yönleri YSA yapısını belirlemektedir. Yapısı belirlenmiş bir YSA eğitilerek YSA ile ilgili uygulamalarda kullanılır. YSA yapıları arasında performans ve karakteristik özellikleri bakımından farklar vardır. YSA yapıları, özellikle ağı modelleme yeteneğini belirledikleri için oldukça önemlidirler. Yapay sinir ağının tasarımı aşamasında bu ağ yapıları arasından uygulamaya en elverişli olanı seçilir.

5.9 YSA'ların Kullanıldığı Alanlar

Yapay sinir ağları başlıca; Sınıflandırma, Modelleme ve Tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. Başarılı uygulamalar incelendiğinde, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin olması ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece örneklerin var olduğu durumlarda yaygın olarak kullanıldıkları görülmektedir. Bu amaçla geliştirilmiş ağlar genellikle şu fonksiyonları gerçekleştirmektedirler;

- Muhtemel fonksiyon kestirimleri

- Sınıflandırma
- İlişkilendirme veya örüntü eşleştirme
- Zaman serileri analizleri
- Sinyal filtreleme
- Veri sıkıştırma
- Örüntü tanıma
- Doğrusal olmayan sinyal işleme
- Doğrusal olmayan sistem modelleme
- Optimizasyon
- Kontrol

YSA'lar pek çok sektörde değişik uygulama alanları bulmuştur. Bunlardan bazıları;

Uzay: Uçuş simülasyonları, otomatik pilot uygulamaları, komponentlerin hata denetimleri vs.

Otomotiv: Otomatik yol izleme, rehber, garanti aktivite analizi, yol koşullarına göre sürüş analizi vs.

Bankacılık: Kredi uygulamaları geliştirilmesi, müşteri analizi ve kredi müracaat değerlendirilmesi, bütçe yatırım tahminleri vs.

Savunma: Silah yönlendirme, hedef seçme, radar, sensör sonar sistemleri, sinyal işleme, görüntü işleme vs.

Elektronik: Kod sırası öngörüsü, çip bozulma analizi, non-lineer modelleme vs.

Eğlence: Animasyonlar, özel efektler, pazarlama öngörüsü vs.

Finans: Kıymet biçme, pazar performans analizi, bütçe kestirimi, hedef belirleme vs.

Sigortacılık: Ürün optimizasyonu, uygulama politikası geliştirme vs.

Üretim: Üretim işlem kontrolü, ürün dizaynı, makina yıpranmalarının tespiti, dayanıklılık analizi, kalite kontrolü, iş çizelgeleri hazırlanması vs.

Sağlık: Göğüs kanseri erken teşhis ve tedavisi, EEG, ECG, MR, kalite artırımı, ilaç etkileri analizi, kan analizi sınıflandırma, kalp krizi erken teşhis ve tedavisi vs.

Petro kimya: Arama, verim analizi vs.

Robotik: Yörünge kontrol, forklift robotları, görsel sistemler, uzaktan kumandalı sistemler, optimum rota belirleme vs.

Dil: Sözcük tanıma, yazı ve konuşma çevrimi, dil tercüme vs.

Telekomünikasyon: Görüntü ve data karşılaştırma, filtreleme, eko ve gürültü sönümlendirilmesi, ses ve görüntü işleme, trafik yoğunluğunun kontrolü ve anahtarlama vs.

Güvenlik: Parmak izi tanıma, kredi kartı hileleri saptama, retina tarama, yüz eşleştirme vs.

Bu örnekler çoğaltılabilir. Görüldüğü gibi YSA'lar günlük hayatımızda farkında olmadığımız pek çok alanda kullanılmaktadır. Gün geçtikçe uygulama alanları genişlemekte ve gelişmektedir.

5.10 YSA'ların Tarihçesi

YSA'lar ile ilgili çalışmalar 20. yy'ın ilk yarısında başlamış ve günümüze kadar büyük bir hızla devam etmiştir. Bu çalışmaları 1970 öncesi ve sonrası diye iki kısma ayırmak mümkündür. Zira 1970 yılları YSA için bir dönüm noktasını teşkil etmiş daha önce aşılması imkânsız görünen pek çok problem bu dönemlerde aşılmıştır. İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir.

1948 yılında "Wiener "Cybernetics" isimli kitabında, sinirlerin çalışması ve davranış özelliklerine değinmiş, 1949 yılında ise Hebb "Organization of Behavior" adlı eserinde öğrenme ile ilgili temel teoriyi ele almıştır. Hebb kitabında öğrenebilen ve uyum sağlayabilen sinir ağıları modeli için temel

oluşturacak "Hebb kuralı"nı ortaya koymuştur. Hebb kuralı; sinir ağının bağlantı sayısı değiştirilirse, öğrenebileceğini ön görmekteydi.

1957 yılında Frank Rosenblatt'ın Perceptron'u geliştirmesinden sonra, YSA'lar ile ilgili çalışmalar hız kazanmıştır. Perceptron; beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip bir ağ modelidir.

1959 yılında Bernard Widrow ve Marcian Hoff (Stanford Üniversitesi) ADALINE (Adaptive Linear Neuron) modelini geliştirmişler ve bu model YSA'ların mühendislik uygulamaları için başlangıç kabul edilmiştir. Bu model Rosenblatt'ın Perceptron'una benzemekle birlikte, öğrenme algoritması daha gelişmiştir. Bu model uzun mesafelerdeki telefon hatlarındaki yankıları ve gürültüleri yok eden bir adaptif filtre olarak kullanılmış, ve gerçek dünya problemlerine uygulanan ilk YSA olma özelliğini kazanmıştır. Bu yöntem günümüzde de aynı amaçla kullanılmaktadır. 1960'ların sonlarına doğru YSA çalışmaları durma noktasına gelmiştir. Buna en önemli etki; Minsky ve Papert tarafından yazılan Perceptrons adlı kitaptır. Burada YSA'ların doğrusal olmayan problemleri çözemediği meşhur XOR problemi ile ispatlanmış, ve YSA çalışmaları bıçak gibi kesilmiştir.

Tüm bunlara rağmen Anderson, Amari, Cooper, Fukushima, Grossberg, Kohonen, Hopfield gibi bilim adamları çalışmalarını sürdürmüşler, 1972 de Kohonen ve Anderson Associative memory konusunda benzer çalışmalar yayınlamışlardır. Kohonen daha sonra 1982 yılında Kendi kendine Öğrenme Nitelik Haritaları (Self Organizing Feature Maps SOM) konusundaki çalışmasını yayınlamıştır. 1960'ların sonlarına doğru Grossberg Carpenter ile birlikte Adaptif Rezonans Teorisini (ART) geliştirmiştir. 1970'lerin sonlarına doğru Fukushima, NEOCOGNITRON modelini tanıtmıştır. Bu model şekil ve örüntü tanıma amaçlı geliştirilmiştir. 1982 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar ile YSA'ların genelleştirilebileceği ve çözümü zor problemlere çözüm üretebileceğini göstermiştir. Geleneksel gezgin satıcı problemini çözmüştür. Bu çalışmaların neticesi Hinton ve arkadaşları'nın geliştirdiği Boltzman Makinası'nın doğmasına yol açmıştır. 1988 yılında, Broomhead ve Lowe radyal tabanlı fonksiyonlar modelini (Radial Basis Functions RBF) geliştirmişler ve özellikle filtreleme konusunda


başarılı sonuçlar elde etmişlerdir. Daha sonra Spect, bu ağların daha gelişmiş şekli olan Probabilistik ağlar (PNN) ve Genel Regresyon Ağlarını (GRNN) geliştirmiştir. Bu tarihten günümüze kadar sayısız çalışma ve uygulama geliştirilmiştir.

- 1890- insan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911- insan beyninin sinir hücrelerinden oluştuğu fikrinin benimsenmesi
- 1943- yapay sinir hücrelerine dayanan hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin geliştirilmesi
- 1949- öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek şekilde geliştirilmesi
- 1956 - 1962 ADALINE ve Widrow - Hoff öğrenme algoritmasının geliştirilmesi
- 1957 - 1962 Perceptron'un geliştirilmesi
- 1965- ilk makina öğrenmesi kitabının yayınlanması
- 1967 - 1969 bazı gelişmiş öğrenme algoritmalarının geliştirilmesi (Grasberg vs.)
- 1969- tek katmanlı algılayıcıların yetersizliklerinin ispatlanması
- 1969 - 1972 doğrusal ilişkilendiricilerin geliştirilmesi
- 1972- korelasyon matris belleğinin geliştirilmesi
- 1974- geriye yayılım modelinin geliştirilmesi
- 1978- ART modelinin geliştirilmesi
- 1982- çok katmanlı algılayıcıların geliştirilmesi
- 1984- Boltzman Makinası'nın geliştirilmesi
- 1988- RBF modelinin geliştirilmesi
- 1991- GRNN modelinin geliştirilmesi

FRAKTAL ANTENLERDE YAPAY SİNİR AĞI ÇALIŞMASI


Bu bölümde, 4. bölümde tasarlanmış olan fraktal anteni üzerinde yapay sinir ağları ile ilgili bir çalışma yapılmıştır. Bunun için ilk olarak uygun bir yapay sinir ağ mimarisi oluşturulmuştur. Oluşturulan YSA mimarisine CST programında elde edilen eğitim ve test verileri verilmiştir. Girdilere karşılık YSA'nın ürettiği çıkışlarla CST programında elde edilen gerçek çıkış parametreleri şekil üzerinde karşılaştırılarak YSA'nın performansı incelenmiştir.

6.1 YSA Mimarisi



Şekil 6.1 Fraktal anten için yapay sinir ağı modeli

Dördüncü bölümde CST programında tasarlanmış olan fraktal antenin YSA mimarisi oluşturulmuştur.



Şekil 6.2 İkinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi

Fraktal antenin boyutları için iki farklı değişken parametre (k ve l) belirlenmiştir. Yalıtkan malzeme ve üstündeki metal malzeme bu parametrelere bağlı olarak değişmektedir. Yalıtkanın ve metalin kalınlıkları sabit değerlerdir.

$$a = 4k + l + 4h \quad (6.1)$$

$$b = 4k + 3l + 6h \quad (6.2)$$

İlk olarak Matlab programına fraktal antenin boyutlarını belirleyen iki parametresi (k, l) ve yalıtkan malzemenin dielektrik sabiti (ϵ) ve bunlara karşı oluşan CST programında elde edilen çıkış değerleri (1. rezonans frekansı (f_{r1}), 1. rezonans frekansındaki $|S_{11}|$ (dB), 1. rezonans frekansındaki VSWR, 2. rezonans frekansı (f_{r2}), 2. rezonans frekansındaki $|S_{11}|$ (dB), 2. rezonans frekansındaki VSWR) bir dosyaya kaydedilmiştir. Böylece eğitim için her parametreden 153'er tane değer YSA'yı eğitmek için kullanılmıştır.

İleri beslemeli geriye yayılım ağı oluşturmak için 'newff' fonksiyonu kullanılmıştır. Bu ağ mimarisinde 3 girdi, 8 ara ve 6 çıktı katmanı bulunmaktadır. Aktivasyon fonksiyonu olarak ara katmanı için 'tansig', çıktı katmanı için 'purelin' kullanılmıştır. Geriye yayılım ağı eğitim fonksiyonu olarak da 'trainlm' kullanılmıştır. Ulaşılması gereken performans hedefi 0.001 seçilmiştir. Hedefe ulaşıldığında eğitim sona ermektedir. Hedefe ulaşamadığı takdirde eğitimin istenilen sürede tamamlanması için devir sayısı 3000 seçilmiştir.

YSA'yı eğitmek için 'train' fonksiyonu kullanılmıştır. Eğitim için daha önce txt uzantılı dosya halinde kaydedilen giriş ve çıkış parametrelerinden yararlanılmıştır. Böylece YSA eğitimi tamamlanmıştır.

Daha sonra, yine CST programı yardımıyla eğitim için kullanılan değerlerden farklı olarak eğitilen Yapay Sinir Ağı'nın testinde kullanılması amacıyla her biri 34 tane olmak üzere giriş ve çıkış parametreleri farklı bir dosyaya kaydedilmiştir. Test için kaydedilen dosyadaki giriş parametre değerleri YSA'ya verilerek YSA'nın çıkış üretmesi sağlanır. Bu işlem sim fonksiyonu yardımıyla olur.

Son olarak, Yapay Sinir Ağı ile elde edilen çıkış parametreleri aynı giriş parametrelerine karşılık gelen gerçek çıkış parametreleri (test için kaydedilen dosyadaki çıkış parametre değerleri) ile fraktal antenin l boyutuna bağlı olarak şekiller üzerinde karşılaştırılmıştır. Bu şekiller de figure ve plot komutları yardımıyla çıkarılmıştır.

YSA'nın iyi eğitilip eğitilmediği çıkan şekiller sayesinde anlaşılır. İlk eğitimlerde kötü sonuçlar çıkabilir. Çok iyi test sonuçları bulana kadar eğitim tekrar edilmelidir.

Bu işlemler için kullanılan fonksiyonlar:

Newff: İleri beslemeli geriye yayılım ağı oluşturur.

Söz Dizimi:

net = newff

net = newff(PR,[S1 S2...SNI],{TF1 TF2...TFNI},GEF,)

Tanım:

NET = NEWFF iletişim kutulu yeni bir ađ oluřturur.

NEWFF(PR,[S1 S2...SNI],{TF1 TF2...TFNI},GEF,)

PR : R giriř elemanlarının minimum ve maksimum deđerlerinin $R \times 2$ matrisi.

Si : N1 katmanları iin herbir katmanın boyutu.

TFi : Her bir katmanın transfer (aktivasyon) fonksiyonu, varsayım= 'tansig'.

GEF : Geriye yayılım ađ eđitim fonksiyonu, varsayım = 'trainlm'.

Böylece N katmanlı ileri beslemeli geriye yayılım ađı oluřur.

Transfer fonksiyonları (TFi) tansig, logsig veya purelin gibi bir transfer fonksiyonu olabilir.

Eđitim fonksiyonu (GEF) trainlm, trainbfg, trainrp, traingd gibi geriye yayılım eđitim fonksiyonları olabilir.

Uyarı: Trainlm olađan bir eđitim fonksiyonudur. ünkü ok hızlıdır, ama alıřması iin ok fazla hafızaya ihtiyaı vardır.

net.trainParam.epochs: Yapay sinir ađının ne kadar eđitileceđini gösterir.

net.trainParam.goal: Yapay sinir ađının ulařması iin konulan hedeftir. Yapay sinir ađının eđitim süresi bitmeden bu hedefe ulařınca eđitim biter.

Train: Sinirsel ađı eđitir.

Söz Dizimi:

NET = train(NET,P,T)

Tanım:

TRAIN NET.trainFcn and NET.trainParam'a göre ađı eđitir.

TRAIN(NET,P,T) kullanılır,

NET: Ađ.

P : Ađ giriřleri

T : Ađ hedefleri.

ve

NET: Yeni Ağ.

oluşur.

Sim : Bir simulink modelini simule eder.

SIM('model' , UT)

'**model**': Bir blok diyagram modelinin ismi.

UT: İsteğe bağlı giriş. Buraya yazılan giriş değerleri seçilen modele göre çıkış üretirler.

Figure : Yeni bir şekil penceresi oluşturur.

Plot: Şekil üzerinde oluşan noktaların birleştirilmesini sağlar.


6.2 Eğitim ve Test Verileri

Eğitim için kullanılan değerler $l = 0.8, 1.0, 1.2, 1.4, 1.6, 1.8, 2.0, 2.2, 2.4, 2.6, 2.8, 3.0, 3.2, 3.4, 3.6, 3.8, 4.0$ mm, $k = 4, 5.5, 6$ mm ve $\varepsilon = 3.4, 4.3, 5.4$ giriş değerleri olarak; bu giriş değerleri için elde edilen değerler ise çıkış olarak alınmıştır.


Test için kullanılan değerler $l = 0.8, 1.0, 1.2, 1.4, 1.6, 1.8, 2.0, 2.2, 2.4, 2.6, 2.8, 3.0, 3.2, 3.4, 3.6, 3.8, 4.0$ mm, $k = 5$ mm ve $\varepsilon = 3.8, 4.9$ giriş değerleri olarak; bu giriş değerleri için elde edilen değerler ise çıkış olarak alınmıştır.

6.3 YSA Sonuçları


Yapay Sinir Ağı ile elde edilen çıkış parametreleri aynı giriş parametrelerine karşılık gelen CST programında elde edilen çıkış parametreleri ile fraktal antenin l boyutuna bağlı olarak aşağıdaki şekiller üzerinde karşılaştırılmıştır:




Şekil 6.3 f_{r1} 'in boyut l 'ye göre değişimi




Şekil 6.4 f_{r1} 'deki $|S_{11}|$ (dB)'in boyut l 'ye göre değişimi




Şekil 6.5 f_{r1} 'deki VSWR'nin boyut l 'ye göre değişimi



Şekil 6.6 f_{r2} 'nin boyut l 'ye göre değişimi



Şekil 6.7 f_{r2} 'deki $|S_{11}|$ (dB)'in boyut l 'ye göre değişimi



Şekil 6.8 f_{r2} 'deki VSWR'nin boyut l 'ye göre değişimi

YSA'da elde edilen sonuçların hedef değerlere ne kadar yaklaştığını tespit etmek için hata analizi yapılmıştır. Toplam olarak bakıldığında hedef değerler yüzde 97.88 tutturulmuştur. f_{r1} yüzde 99.52, f_{r1} 'deki $|S_{11}|$ (dB) yüzde 94.82, f_{r1} 'deki VSWR yüzde 98.57, f_{r2} yüzde 99.48, f_{r2} 'deki $|S_{11}|$ (dB) yüzde 96.32, f_{r2} 'deki VSWR yüzde 98.60 oranında hedef değerlere yaklaşmıştır.

SONUÇ VE ÖNERİLER

İlk olarak TUBITAK ambleminden esinlenilerek geniş bantta çalışacak tübitak anteni tasarlanmıştır. Antenin çalışma frekansları 3 ile 11 GHz arasındadır.

Daha sonra fraktal anten tipi olarak ikinci safhadaki hilbert eğrisi ile birleşmiş Minkowski eğrisi seçilmiş ve CST programında tasarlanmıştır. Fraktal antenin gelişimindeki üç safha da ayrı ayrı tasarlanmış ve çıkan sonuçlar karşılaştırılmıştır. Fraktal antenin safhalar geçtikçe rezonans frekansının düştüğü, gerilim duran dalga oranının arttığı gösterilmiştir. Burada fraktal antenlerin boşluk doldurma özelliğinden yararlanılmaktadır. Boşluk doldurma özelliğinden yararlanılarak anten boyutu küçültülebilir. Ayrıca burada fraktal antenlerin kendine benzerlik özelliğinden de yararlanılmaktadır. Kendine benzerlik özelliği sayesinde fraktal antenler multibant davranış sergileyebilmektedir.

Son olarak CST programında tasarlanmış olan fraktal anteni için Yapay Sinir Ağı modeli gerçekleştirilmiştir. Bunun için ilk olarak 3 girdi, 8 ara ve 6 çıktı katmanına sahip ileri beslemeli YSA mimarisi oluşturulmuştur. Oluşturulan YSA mimarisine fraktal antenin boyutlarını belirleyen iki parametresi, yalıtkan malzemenin dielektrik sabiti ve bunlara karşı oluşan CST programında elde edilen çıkış değerleri verilerek Yapay Sinir Ağı'nın eğitimi sağlanmıştır. Daha sonra, eğitilen yapay sinir ağını test etmek amacıyla çıkış değerleri bilinen farklı giriş parametreleri Yapay Sinir Ağı'na giriş değeri olarak verilmiştir. Girdilere (fraktal antenin boyutlarını belirleyen iki parametresi (k, l) ve yalıtkan malzemenin dielektrik sabiti (ϵ)) karşılık YSA'nın ürettiği çıkışlarla CST

programında elde edilen çıkış değerleri (1. rezonans frekansı (f_{r1}), 1. rezonans frekansındaki $|S_{11}|$ (dB), 1. rezonans frekansındaki VSWR, 2. rezonans frekansı (f_{r2}), 2. rezonans frekansındaki $|S_{11}|$ (dB), 2. rezonans frekansındaki VSWR) antenin boyutu l 'ye bağlı olarak şekil üzerinde karşılaştırılarak YSA'nın performansı incelenmiştir. Toplam 6 tane şekil ortaya çıkmıştır. Bu işlemler Matlab programında yapılmıştır. Bu şekiller incelendiğinde iyi eğitilmiş Yapay Sinir Ağları ile elde edilen sonuçlar ve gerçek değerler arasındaki farkın çok az olduğu görülmüştür. Bu durum, Yapay Sinir Ağları'nın problemin çözümü için matematiksel modelin ve algoritmanın bulunmadığı, sadece örneklerin var olduğu durumlarda başarılı olduklarını göstermiştir.

KAYNAKLAR

- [1] Chavka, G.G., (2007). "Beauty of Fractals, Design of Fractal Antennas", International Conference on Antenna Theory and Techniques, 1:76-81
- [2] Hu, Z., Wan, G., Sun, C. ve Zhao, H., (2009). "Design of Modified Sierpinski Fractal Antenna for Multiband Application", School of Electronics and Information, 1:655-658.
- [3] Petko, J.S. ve Werner, D.H., (2005). "The Evolution of Optimal Linear Polyfractal Arrays Using Genetic Algorithms", IEEE Transactions on Antennas and Propagation, 11:3604-3615.
- [4] Werner, D.H., Haupt, R.L. ve Werner, P.L., (1999). "Fractal Antenna Engineering: The Theory and Design of Fractal Antenna Arrays", IEEE Antennas and Propagation Magazine, 5:37-59.
- [5] Gianvittorio, J.P. ve Rahmat-Samii, Y., (2002). "A Novel Antenna Miniaturization Technique, and Applications", IEEE Antennas and Propagation Magazine, 1:20-36.
- [6] Werner, D.H. ve Ganguly, S., (2003). "An Overview of Fractal Antenna Engineering Research", IEEE Antennas and Propagation Magazine, 1:38-57.
- [7] Petko, J.S. ve Werner, D.H., (2004). "Miniature Reconfigurable Three-Dimensional Fractal Tree Antennas", IEEE Transactions on Antennas and Propagation, 8:1945-1956.
- [8] Walker, G.J. ve James, J.R., (1998). "Fractal Volume Antennas", IEE Electronics Letters, 16:1536-1537.
- [9] Kim, Y. Ve Jaggard, D.L., (1986). "The Fractal Random Array", Proc. IEEE, 9:1278-1280.
- [10] Öztemel, E., (2006). Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- [11] Elmas, Ç., (2003). Yapay Sinir Ağları Kuram, Mimari, Eğitim, Uygulama, Seçkin Yayıncılık, Ankara.

- [12] Puente, C., Romeu, J., Pous, R. Ve Cardama, A., (1998). "On The Behavior of the Sierpinski Multiband Fractal Antenna", IEEE Transactions on Antennas and Propagation, 4:517-524.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Cihan METE

Doğum Tarihi ve Yeri : 07.06.1985, İstanbul

Yabancı Dili : İngilizce

E-posta : cihanmete@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Elektronik ve Haberleşme Mühendisliği	Yıldız Teknik Üniversitesi	2007
Lise	Fen-Matematik	Kadir Has Anadolu Lisesi	2003

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2008-	Türk Telekom	Mühendis