



KAHRAMANMARAS ST İMAM NİVERSİTESİ
FEN BİLİMLERİ ENSTİTS
ELEKTRİK-ELEKTRONİK MHENDİSLİĐİ ANABİLİM DALI

EEG İŞARETLERİNİN DALGACIK ANALİZ YNTEMLERİ
KULLANILARAK YAPAY SİNİR AĐLARI İLE SINIFLANDIRILMASI

HATİCE BATAR

YKSEK LİSANS TEZİ

KAHRAMANMARAS
Eyll - 2005



KAHRAMANMARAS ST İMAM NİVERSİTESİ
FEN BİLİMLERİ ENSTİTS
ELEKTRİK-ELEKTRONİK MHENDİSLİĐİ ANABİLİM DALI

EEG İŞARETLERİNİN DALGACIK ANALİZ YNTEMLERİ
KULLANILARAK YAPAY SİNİR AĐLARI İLE SINIFLANDIRILMASI

HATİCE BATAR

YKSEK LİSANS TEZİ

KAHRAMANMARAS
Eyll - 2005

KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

EEG İŞARETLERİNİN DALGACIK ANALİZ YÖNTEMLERİ
KULLANILARAK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

HATİCE BATAR

YÜKSEK LİSANS TEZİ

Kod No:

**Bu Tez 27/09/2005 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oy Birliği ile Kabul Edilmiştir.**

.....
Prof. Dr.
M. KEMAL KIYMIK
Danışman

.....
Yrd. Doç. Dr.
ABDÜLHAMİT SUBAŞI
Üye

.....
Yrd. Doç. Dr.
A. SERDAR YILMAZ
Üye

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof.. Dr. Özden GÖRÜCÜ
Enstitü Müdürü

Bu çalışma tarafından desteklenmiştir.
Proje No:

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

İÇİNDEKİLER

	SAYFA
İÇİNDEKİLER.....	I
ÖZET	III
ABSTRACT	IV
ÖNSÖZ	V
ÇİZELGELER DİZİNİ.....	VI
ŞEKİLLER DİZİNİ.....	VII
SİMGELER VE KISALTMALAR DİZİNİ.....	IX
1. GİRİŞ.....	1
1.1. EEG (Elektroensefalogram)	3
1.1.1 Elektroensefalogram İşaretlerinin Ölçülmesi	6
1.1.2. EEG Elektrotlarının Bağlanma Şekli	6
1.1.3. UYARILMIŞ POTANSİYELLER.....	7
2. ÖNCEKİ ÇALIŞMALAR.....	9
3. MATERYAL ve METOT	11
3.1. Materyal	11
3.1.1. Giriş	11
3.1.2 Sinyal Analiz Metotlarının Gelişimi	11
3.1.3 Fourier Temelli Sinyal Analizi	13
3.1.3.1 Akan Fourier Dönüşümü (Running Fourier Transform).....	13
3.1.3.2. Kısa Zaman Fourier Dönüşümü (KZFD).....	14
3.1.3.3. Zak Dönüşümü.....	16
3.1.3.4. Ayrık Fourier Dönüşümü (AFD) ve Hızlı Fourier Dönüşümü (HFD).....	16
3.1.4. Ölçek Temelli Dalgacık (Wavelet) Sinyal Analizi.....	18
3.1.4.1 Dalgacık Teorisinin Matematiksel Yaklaşımı	21
3.1.4.2 Sürekli Dalgacık Dönüşümü (SDD)	22
3.1.4.3 Dalgacığın Bir Ölçekleme Fonksiyonundan Elde Edilmesi	30
3.1.4.4 Dalgacık Analizi ile Gürültüden Arındırma	31
3.1.4.5 Dalgacık Analizi ile Veri Sıkıştırma.....	33
3.1.5. Yapay Sinir Ağları.....	33
3.1.5.1. Biyolojik Sinir Sistemi.....	33
3.1.5.2. Biyolojik Sinir	35
3.1.5.3. Statik ve Dinamik Yapay Sinir Modelleri	36
3.1.5.4. Yapay Sinir Ağları ile Hesaplamanın Özellikleri	40
3.1.5.5. Yapay Sinir Ağlarının Sınıflandırılması	41
3.1.5.6. Tek Katmanlı ve Çok Katmanlı İleri beslemeli Yapay Sinir Ağları.....	44
3.1.5.7. YSA'nın Donanım Olarak Gerçeklenmesi	48
3.1.5.8. Diğer Yapay Sinir Ağları	50
3.1.6. YSA'nın Mühendislik Uygulamaları	55
3.1.6.1. Biyomedikal İşaret İşlemede Yapay Sinir Ağları	56
3.1.6.2. Nörolojide Yapay Sinir Ağları.....	57
3.2. Metot	60
3.2.1. Giriş	60
3.2.2. Hata Geriayılım Algortimasının Uygulanması	60
3.2.2.1. Geriayılım Algortiması İçin Veri Hazırlanması	60
3.2.2.2. Düğüm ve Katmanlar	61

	SAYFA
3.2.2.3. Geriyayılım Eğitimi ve Öğrenimi.....	61
3.2.3. Genelleştirilmiş Delta Kuralı.....	63
3.2.4. Sayısal Hızlandırma Teknikleri	68
3.2.4.1. Momentum Metodu.....	68
3.2.4.2. Topoloji Uydurulması	69
3.2.4.3. Dinamik Öğrenme	69
4. BULGULAR VE TARTIŞMA	70
5. SONUÇ VE ÖNERİLER	79
EKLER	80
KAYNAKLAR.....	86

**KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

YÜKSEK LİSANS TEZİ

ÖZET

**EEG İŞARETLERİNİN DALGACIK ANALİZ YÖNTEMLERİ
KULLANILARAK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

HATİCE BATAR

DANIŞMAN: Prof. Dr. M. Kemal KIYMIK

Yıl : 2005 Sayfa : 102

**Jüri : Prof. Dr. M. Kemal KIYMIK
: Yrd. Doç. Dr. Abdülhamit SUBAŞI
: Yrd. Doç. Dr. A. Serdar YILMAZ**

Bu çalışmada EEG işareti gibi durağan olmayan rasgele işaretleri, uyanıklık, uyuklama ve uyku hallerinde gösterdikleri (hem zaman- genlik domeninde, hem de dalgacık dönüşümü ile elde ettiğimiz zaman-ölçek domeninde gözlemlenen) farklılıklar değerlendirilip yapay sinir ağları kullanılarak bilgisayar destekli bir otomatik sınıflandırma yapmak amaçlanmıştır.

Elde edilen bulguların grafiklerinden de anlaşılacağı üzere sinir ağının sınıflandırma probleminde kullanılması başarı ile sağlanmıştır. Sinir ağının öğrenme katsayısı, aktivasyon fonksiyon değerleri gizli katman sayısı ve gizli katman nöron sayısının değişimlerine göre sinir ağının performansı değişmektedir. Bu değerler deneysel sonuçlara göre optimal duruma getirilmiştir.

Anahtar Kelimeler: Eeg, Sinyal Analizi, Stft, Dalgacık Analizi, Yapay Siniri Ağları

**UNIVERSITY OF KAHRAMANMARAŞ SÜTÇÜ İMAM
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING**

MSc THESIS

ABSTRACT

EEG SIGNAL CLASSIFICATION BY USING WAVELET TRANSFORM AND ARTIFICIAL NEURAL NETWORKS

HATİCE BATAR

Supervisor: Prof. Dr. M. Kemal KIYMIK

Year: 2005, Pages: 102

**Jury : Prof. Dr. M. Kemal KIYMIK
: Assist. Yrd. Doç. Dr. Abdülhamit SUBAŞI
: Assis. Prof. Dr. A. Serdar YILMAZ**

In this study, it was aimed to do an automatic classification supported by computer by using artificial neural networks after evaluating differences in alert, drowsy and sleeping conditions (observed in both time- amplitude domain and in time- scale domain we got though wavelet transform) which are the signs nonstationary and random as EEG signal.

As it was understood from the discoveries' graphics which were got, it had been supplied for neural network in using classification problem successfully.neural networks performance has been changing according to the changing of neural networks learning coefficient, activation function values, hidden layer number and hidden layer neuron number. This values had been made optimal according to experimental results.

Key Words: Eeg, Signal Analysis, Stft, Wavelet Analysis, Artificial Neural Networks

ÖNSÖZ

Biyolojik sistemlerin tanınmasında ve tıbbi uygulamaların gelişmesinde mühendislik teknik ve görüşlerinin uygulanması her geçen gün önem kazanmaktadır. Bu çalışmalar genellikle çeşitli ölçümlerin yapılması ve elde edilen verilerin ileri matematik yöntemleriyle değerlendirilmesi şeklindedir.

Bu çalışmada, EEG işaretlerini sınıflandırılmak amacıyla modern parametrik sinyal analizi yöntemleri ve pek çok uygulama alanı bulunan yapay sinir ağları kullanılmıştır. Yapay sinir ağlarının, kendisine gösterilen örneklerden genelleme yapması ve daha sonra hiç görmediği örnekler ile karşılaşınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilme özelliği sayesinde sınıflandırma probleminde kullanılmıştır.

Çalışmalarım süresince bilgi ve tecrübesiyle yardımlarını esirgemeyen danışman hocam sayın Prof. Dr. M.Kemal KIYMIK'a ve tezin hazırlanması sırasında bana yardımcı olan Sayın Abdulhamit SUBAŞI' na, Sayın H. Rıza ÖZÇALIK' a, Sayın Alper DİZİBÜYÜK' e ve tüm araştırma görevlisi arkadaşlarıma teşekkürlerimi sunarım.

Maddi ve manevi desteklerini hiç bir zaman benden esirgemeyen çok sevgili babam ve annem başta olmak üzere tüm aileme teşekkürü bir borç bilirim.

Eylül 2005
KAHRAMANMARAŞ

HATİCE BATAR

ÇİZELGELER DİZİNİ

	SAYFA
Çizelge 1.1. EEG işaretlerinin kapsadıkları bantlar (Hz).....	4
Çizelge 3.1. Haar 2, Daubechies 4 ve 6 fonksiyonları için dalgacık katsayıları (Fomitchev, 1994).....	32
Çizelge 3.2. Sinir Sistemi ile YSA'nın Benzerlikleri.....	34
Çizelge 3.3. YSA ile RTF Ağlar Arasındaki Ana Farklar	47
Çizelge 4.1. Yapay sinir ağının ham data girişine karşı performansı(BGD ile)	75
Çizelge 4.2. Ağın ADD uygulanmış sinyal girişine karşı performansı.....	76
Çizelge 4.3. LVQ ağ yapısının performansı	78

SEKİLLER DİZİNİ

SAYFA

Şekil 1.1. Normal bir insanın EEG kaydı	4
Şekil 1.2. Alfa ve Beta dalgaları	5
Şekil 1.3. Teta dalgası	5
Şekil 1.4. Delta dalgası	5
Şekil 1.5. n kanallı bir EEG ölçüm sisteminin blok diyagramı (Yazgan,1996).....	6
Şekil 1.6. 10- 20 elektrot yerleştirme sistemi (Webster, 1996)	7
Şekil 3.1. Hanning Pencere	15
Şekil 3.2. Sinyal analiz yöntemleri arasındaki ilişki (Polikar, 1999).....	20
Şekil 3.3. Daubechies dalgacık (Grap, 1995b).....	20
Şekil 3.4. Mexican Hat Dalgacık fonksiyonu:	23
Şekil 3.5. Morlet Dalgacık fonksiyonu: Denklemi:	24
Şekil 3.6. Haar Dalgacık fonksiyonu. Denklemi:	24
Şekil 3.7. Değişik ölçeklerdeki dalgacıklar için frekans spektrumları (ψ_1 en küçük ölçeğe karşılık düşen dalgacığı temsil eder).	25
Şekil 3.8. Ölçekleme ve Dalgacık fonksiyonlarının spektrumları.	29
Şekil 3.9. Haar ve Daubechies 4 temel dalgacık fonksiyonları. (Fomitchev, 1994)	32
Şekil 3.10. Sıkı ve yumuşak eşikleme $\lambda=1$ (Vidakovic ve ark., 1993)	33
Şekil 3.11. Biyolojik Sinir Sisteminin Blok Gösterimi (Zurada,1990)	34
Şekil 3.12. Biyolojik Nöron	35
Şekil 3.13. Biyolojik Sinir Hücresi ve Bileşenleri.....	36
Şekil 3.14. Temel Statik Yapay Nöron (Vas,1999).....	37
Şekil 3.15. YSA'da En Çok Tercih Edilen Aktivasyon Fonksiyonları a) Tek Kutuplu Sigmoid b) Doğrusal c) Hiperbolik Tanjant d) Keskin Sınırlayıcı	39
Şekil 3.16. İleri Beslemeli YSA için Blok Diyagram	41
Şekil 3.17. Geri Beslemeli YSA için Blok Diyagram	42
Şekil 3.19. Danışmansız Öğrenme Yapısı	43
Şekil 3.20. Takviyeli Öğrenme Yapısı	43
Şekil 3.21. Tek Katmanlı YSA	44
Şekil 3.22. Çok Katmanlı YSA	45
Şekil 3.23. Üç Katmanlı RTF Ağı	46
Şekil 3.24. Bir Fark Yükselteç Kullanılan Nöron Model Uygulaması (Vas,1999).....	48
Şekil 3.25. LVQ Ağı	50
Şekil 3.26. Hopfield Ağı	51
Şekil 3.27.a) Elman Ağı	52
Şekil 3.27. b) Jordan Ağı	53
Şekil 3.28. Kohonen Ağı	54
Şekil 3.29. ART-1 Ağı	55
Şekil 3. 30. Veri Kazanç Düzenneği (Anonim, 1997)	57
Şekil 3.31. Sinyal düzenleme modülü (Anonim, 1997).	58
Şekil 3.32. Veri kazanç kartının seçimi (Anonim, 1997).	58
Şekil 3.33. Uygun aksesuarın seçimi (Anonim, 1997).....	59
Şekil 3.34. MATLAB Data Acquisition Tools	59
Şekil 3.35. Çok Katmanlı Bir Ağ İçin Geri yayılım Akış Şeması	67
Şekil 4.1. EEG çekimi	70
Şekil 4.2. Uyanık EEG işareti	71

	SAYFA
Şekil 4.3. Uyuklama evresinde EEG işareti.....	71
Şekil 4.4. Uyku evresinde EEG işareti	72
Şekil 4.5. Daubechies 4 Dalgacığı ile ADD uygulanmış uyanık EEG işareti.....	72
Şekil 4.6. Daubechies 4 Dalgacığı ile ADD uygulanmış uyuklama EEG' si	73
Şekil 4.7. Daubechies 4 Dalgacığı ile ADD uygulanmış uyku EEG' si.....	73
Şekil 4.8. Çok katmanlı sinir ağı modeli.....	74
Şekil 4.9. Ham data için BGD eğitim grafiğı.....	75
Şekil 4.10. ADD yapılmış girişler ile BGD eğitim grafiğı.....	75
Şekil 4.11. Ham data BGDM algoritması eğitim eğrisi	76
Şekil 4.12. ADD uygulanmış veriler için RP algoritmasının eğitim eğrisi	77
Şekil 4.13. ADD uygulanmış veriler için CG algoritmasının eğitim eğrisi.....	77
Şekil 4.14. LVQ eğitim eğrisi	78

SİMGELER VE KISALTMALAR DİZİNİ

EEG	: Elektroensefalogram
E	: Hata Fonksiyonu
c	: Öğrenme Katsayısı
r	: Öğrenme Fonksiyonu
D	: Eğitici Bigi
X	: Giriş Vektörü
Z	: Empedans
W	: Ağırlık Vektörü
Δw	: Ağırlıkların Değişimi
δ	: Hata Sinyali
S_i	: Net Değeri
O	: Çıkış Fonksiyonu
η	: Delta Öğrenme Katsayısı
λ	: Aktivasyon Hız Katsayısı
YS	: Yapay Sinir
YSA	: Yapay Sinir Ağı
YSAS	: Yapay Sinir Ağı Sistemleri
BMS	: Bulanık Mantık Sistemleri
BSA	: Bulanık Sinir Ağlar
SBA	: Sinir Bulanık Ağlar
GAT	: Genetik Algoritma Temelli Sistemler
GAD	: Genetik Algoritma Destekli Sistemler
MLP	: Multi Layer Perceptron
LVQ	: Learning Vector Quantization
SOM	: Self Organizing Map
ART	: Adaptive Resonance Theory
ADALINE	: Adaptive Lineer Neuron
RTF	: Radyal Temelli Fonksiyon
RBF	: Radial Basis Function
MOS	: Metal Oxide Semiconductor
FD	: Fourier Dönüşümü
DFT	(Discrete Fourier Transform : Ayrık Fourier dönüşümü
CGA	: Conjugate Gradient Algorithm
RP	: Resilient Backpropagation Algorithm
AFD	: Ayrık Fourier dönüşümü.
FFT	:(Fast Fourier Transform) Hızlı Fourier Dönüşümü.
STFT	:(Short Time Fourier Transform) Kısa Zaman Fourier Dönüşümü
AR	: Auto Regressive.
MA	: Mouving Average.
WAVELET	: Dalgacık.
CWT	: (Continous Wavelet Transform) Sürekli Dalgacık Dönüşümü.
SDD	: Sürekli Dalgacık Dönüşümü.
f	: Frekans
T	: Periyot
Δw	: Bant genişliği.
Δt	: Zaman açıklığı.

σ^2	: Varyans.
ψ	: Ana dalgacık.
$\psi_{a,b}(t)$	: Ana dalgacıktan öteleme ve ölçeklemeyle elde edilen dalgacık.
$\emptyset(x)$	: Ölçekleme fonksiyonu.
SAMK	: Spektrumun Ağırlık Merkezi Kestirimi.
DD	: Dalgacık Dönüşümü

1. GİRİŞ

Tıbbi teşhis ve araştırmalarda kullanılan EEG (Elektroensefalogram) işaretleri beynin sinirsel faaliyeti sonucu elde edilen biyoelektriksel işaretler olup frekans bileşenleri son derece önemlidir. Bu işaretlerde beynin fonksiyonları ile ilgili çok miktarda bilgi saklıdır. Bu bilgilerin kullanılabilmesi için sinyal işleyicileri çok çeşitli araştırmalar yapmaktadırlar. Bazı patolojik belirtiler zaman alanında fark edilmeyebilir. Nörologlar genellikle zaman alanına göre teşhis yapmaktadırlar. Son zamanlarda bilgisayarların bu sinyalleri kayıt etmeleri ve spektral analiz yöntemlerinin geliştirilmesi bu patolojik belirtilerin bulunmasında frekans bileşenlerinden faydalanılmayı mümkün kılmıştır (Güneş, 1999, Polikar, 1996).

Sinyal işlemecilerin en çok bildiği Fourier analizi bir sinyali zaman alanından frekans alanına dönüştürüp frekans bileşenleri önemli olduğu zaman sıkça başvurulmuş bir tekniktir. Fourier analizinde, frekans alanına geçildiğinde zaman alanı kaybolur. Durağan sinyallerde fourier analizi iyi bir yöntem olmaktadır, fakat EEG işaretleri durağan olmayıp sürekli değişir. Bu işaretlerde arada sırada kısa süreli ortaya çıkan dik darbeler ve kompleks dalgalar teşhis açısından önemli bilgiler taşır. Bu durumda bu özel spektral bileşenlerin hangi zaman aralığında meydana geldiği önemli olabilir ve fourier analizi yetersiz kalır (Yazgan, 1996).

Dalgacık analizi, Kısa Zamanlı Fourier Dönüşümünün(KZFD) bir alternatifi olarak çözünürlük probleminin üstesinden gelmek için ortaya çıkmıştır. KZFD de zaman-frekans alanında elde edilen bilgiler sınırlı bir hassasiyette elde edilebilmektedir. Bu hassasiyet pencerenin büyüklüğüne bağlıdır. Çoğu sinyaller daha hassas yaklaşıma ihtiyaç duyar ve bu pencerenin büyüklüğünün sürekli değişmesi gerekmektedir. KZFD’ de zaman penceresi bütün frekanslarda değişmeyen büyüklüktedir.

Dalgacık analizi ise bir ileri ki yöntem olup pencereleme tekniği büyüklüğü değiştirilebilir. Dalgacıklar durağan veya durağan olmayan sinyallerin zaman-ölçek analizi için olanak sağlar. Dalgacıklar sonlu süreli oldukları için bu yüzden yerel sinyal özelliklerinin analizini mümkün kılarlar. Dalgacık dönüşümleri tüm sinyal frekans-zaman bilgisini korurlar. Bu sebeplerden dolayı durağan olmayan gerçek doğal sinyallerin dalgacık temelli metotlarla işlenmesi geleneksel metotlardan daha iyi sonuçlar sağlarlar (Miner, 1998). Dalgacığın en önemli avantajlarından birisi, büyük işaretlerin yöresel analizine olanak tanımasıdır.

Dalgacık analizi ise bir ileri ki yöntem olup pencereleme tekniği büyüklüğü değiştirilebilir. Dalgacıklar durağan veya durağan olmayan sinyallerin zaman-ölçek analizi için olanak sağlar. Dalgacıklar sonlu süreli oldukları için bu yüzden yerel sinyal özelliklerinin analizini mümkün kılarlar. Dalgacık dönüşümleri tüm sinyal frekans-zaman bilgisini korurlar.

Bu sebeplerden dolayı durağan olmayan gerçek doğal sinyallerin dalgacık temelli metotlarla işlenmesi geleneksel metotlardan daha iyi sonuçlar sağlarlar (Miner, 1998). Dalgacığın en önemli avantajlarından birisi, büyük işaretlerin yöresel analizine olanak tanımasıdır.

Bu çalışmada EEG'nin spektral analizine ek olarak, sınıflandırma problemlerindeki başarılı uygulama yöntemlerinden dolayı yapay zeka uygulamalarının bir çeşidi olan yapay sinir ağları (YSA) kullanılmıştır.

YSA'nın öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerinden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak olaya çözümler üretebilme özelliği YSA'daki zeki davranışın da temelini teşkil eder.

1943 yılında bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitt, "Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap" başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur. John Von Neumann bu makaleyi, "elektronik beyinler" için bir kopya olarak görmüştür. Yapay zeka alanındaki araştırmacılar içerisinde istisnai bir yeri olan Marvin Minsky, bu makaleden aldığı ilhamla makroskobik zeka fikrini ortaya atmış ve uzman sistemlerin doğmasına neden olmuştur. Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bu bilim adamları, öğrenmenin ve zekanın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zeka konferansında tartışmışlardır.

1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve "adaline" (Adaptive Linear Neuron) olarak adlandırılan bir uyarlamalı doğrusal elemanı geliştirmiştir. Adaline ve iki tabakalı biçimi olan "madaline" (Multiple Adaline); ses tanıma, karakter tanıma, hava tahmini ve uyarlamalı kontrol gibi çok çeşitli uygulamalar için kullanılmıştır. Daha sonraları adaline, ayrık bir çıkış yerine sürekli bir çıkış üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki ekoları bastırma yok etmeye yarayan uyarlamalı filtreleri geliştirmede, uyarlamalı doğrusal eleman algoritmasını kullanmıştır. Bununla ilk defa YSA gerçek bir probleme uygulanmıştır.

Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, 1970'lerin ilk yıllarında uyarlamalı öğrenme ve birleşik hafızalar üzerine temel çalışmalar yapmış ve bu yapmış olduğu çalışmaları ile danışmansız öğrenme metodlarının gelişmesine ışık tutmuştur.

Minsky ve Papert'in perceptron isimli kitaplarında, YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri bir çok araştırmacının bu alanda çalışmaktan vazgeçmelerine sebebiyet vermiştir. YSA konusunda çalışmaya devam eden Grossberg, YSA modellerini yapılandırmak için nörolojik verinin kullanılması, algı ve hafıza için YSA tabanlı mekanizmaların önerilmesi, belirgin eşitliklerle bütünleşen bir sinaptik model için bir ilişkilendirici kural üzerinde çalışmıştır.

1982 yılında ilgi çeken bir başka gelişme, moleküler biyolojiden beyin kuramcılığına geçiş yapan bir model Caltech fizikçisi Hopfield tarafından sunulmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve bir çok alana uygulanmıştır.

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA ile ilgili araştırmalar yapan çok sayıda

bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam edeceklerdir.

Spektral analiz yöntemlerinin gelişimi, dalgacık analizi ve yapay sinir ağları konuları ile ilgili ayrıntılı bilgi daha sonraki bölümlerde verilecektir.

Bu çalışmada spektral analiz yöntemi olarak Ayrık Dalgacık Dönüşümü (ADD) kullanılmış olup, EEG işaretinde büyük önem arz eden δ (1-4 Hz), θ (4-8 Hz), α (8-13 Hz), β (13-30 Hz) alt bantları bu yöntem ile elde edilmiştir.

Elde edilen bu alt bant bileşenleri çok katmanlı algılayıcı (Ç.K.A) sinir ağının girişlerine uygulanarak değişik algoritmaların, işareti uyanık- uyuklama- uyku halleri için sınıflandırma performansları incelenerek değerlendirilmiştir.

1.1. EEG (Elektroensefalogram)

Caton 1875 tarihinde hayvanlar üzerinde yaptığı deneyler sonucunda ilk defa, beyinde bir takım elektriksel faaliyetlerin varlığını keşfetti. 1929 yılında ilk defa, Hans Berger, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre yardımıyla insan beyinde elektriksel aktivitenin varlığını ortaya koydu Berger, (1930)' da **Elektroensefalogram** adı verilen bu dalgaların gözün açılıp kapanmasıyla değiştiğini ortaya koydu.

Elektronikteki gelişmelerle birlikte EEG işaretlerinin varlığı bilimsel bir şekilde ortaya konuldu ve 1934' de Adrian ve Matthews, elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağladılar. 1939' da P. A. Davis, uyanık bir insanın EEG' sinde, sese karşı uyarılan yanıtların(EP) olduğunu buldu. H. A. Davis ve arkadaşları aynı yıl, aynı olayın uyuyan insanda da meydana geldiğini gösterdiler.

İkinci dünya savaşından sonra, elektronik ve bilgisayarlar alanlarında meydana gelen büyük gelişmelerin olumlu sonuçları, bu alanda da kendisini gösterdi ve EEG' nin klinik uygulamaları geliştirilerek tanımı üzerinde yapılan araştırmalar olumlu sonuçlar verdi.

EEG' nin çok karmaşık bir değişim şekli vardır ve yorumlanması güçtür. Yüzeyden ölçülen EEG potansiyelleri, alttaki birçok noktadan ve serebral korteksin oldukça geniş bir bölgesinden gelen potansiyellerin toplamından oluşur.

Deneyler, EEG frekansının kişinin zihin faaliyeti ile değiştiğini göstermiştir. Bu durum, beyin tabii ve boşta çalışma frekansı gibi bir senkronizasyon durumunu gösterir. Kişi uyanır uyanmaz veya düşünmeye başlarken alfa ritmi kaybolur ve yerine senkronize olmayan biçimde, genellikle beta bandında bir ritim oluşur. Günümüzde, beyinde bu işlemi yapan mekanizmayı bulma üzerine pek çok araştırma yapılmaktadır.


EEG işaretlerinin frekans bileşenleri oldukça önemli olduğu gibi, farklı bölgelerden alınan benzer EEG işaretleri arasındaki faz ilişkileri oldukça ilgi çekicidir. Bu tip bilgiler, EEG' nin kaynağının incelenmesinde çok faydalı olup beyin çalışması ile ilgili ilave bilgiler elde edilmesini sağlar. Kafa üzerinden algılanan EEG' lerin genliği tepeden tepeye

1-100 μV ve frekans bandı ise 0.5-100 Hz' dir. Ölçümler beyin üzerinden doğrudan alındığı takdirde, genlik 10 kat daha artar. EEG' de oluşan farklı frekansların oluşum mekanizmaları henüz tam olarak anlaşılamamıştır.

EEG, EKG ve EMG işaretlerinde olduğu gibi şekil bakımından değil, kapsadığı frekanslara göre değerlendirilmektedir. EEG işaretleri periyodik değildir; genlik, faz ve frekansları sürekli değişir. Bu nedenle anlamlı bir data elde etmek için ölçümlerin oldukça uzun bir sürede yapılması gerekir. EEG işaretlerinin ana frekansı ile beyin aktivitesi yakından ilişkilidir. Aktivite ile frekans birlikte yükselir. Alttaki çizelgede, EEG işaretleri, kapsadıkları frekans bantları ve bu bantlara verilen özel isimler ile birlikte verilmiştir.

Çizelge 1.1. EEG işaretlerinin kapsadıkları bantlar (Hz)


Delta (δ)	0.5 - 3.5
Teta (θ)	4 - 7
Alfa (α)	8 - 12
Beta (β)	12 - 22
Gamma (γ)	22 - 30



Şekil 1.1. Normal bir insanın EEG kaydı


Alfa Dalgaları: 8-12 Hz arasındaki beyin dalgalarıdır. Uyanık normal ve sakin kimselerde görülür. Yoğun şekilde oksipital bölgede ortaya çıkar, genlikleri 5 μV kadardır. Uyku durumunda yok olurlar. Uyanık kişi dikkatini özel bir şeye yönlertirse α dalgaları yerine, daha yüksek frekanslı, fakat düşük genlikli EEG işaretleri (β dalgaları) meydana gelir. (Yazgan, 1996)

Beta Dalgaları: Frekansları 12 Hz' in üzerindeki beyin dalgalarıdır. 25 Hz' e va nadir hallerde 50 Hz' e kadar uzırlar. Saçlı derinin parietal ve frontal bölgelerinde belirgin olarak kaydedilebilir. Beta-I (BI) ve Beta-II (BII) diye ikiye ayrılırlar. BII dalgalarının frekansı, BI' inkinin iki iki mislidir ve α dalgalarında olduğu gibi zihinsel aktivitenin artması ile ortadan kalkarlar ve yerlerine düşük genlikli asenkron işaretler oluşur. BII dalgaları, merkezi sinir sisteminin kuvvetli aktivasyonunda veya gerginlik hallerinde ortaya çıkar. (Yazgan, 1996)




Şekil 1.2. Alfa ve Beta dalgaları

Teta Dalgaları: 4-7 Hz arasındaki dalgalarıdır. Özellikle, çocuklarda parietal ve temporal bölgelerde ortaya çıkarlar. Yetişkinlerde de duygusal gerginlik, düş kırıklığı durumlarında ortaya çıkarlar. Genlikleri 100 μ V (p-p)' den küçüktür. (Yazgan, 1996)



Şekil 1.3. Teta dalgası

Delta Dalgaları: 3.5 Hz' in altındaki beyin dalgalarıdır. Bazı durumlarda 1 Hz' in altına da düşer. Süt çocuklarında ve ağır organik beyin hastalıklarında görülür. Genlikleri 100 μ V (p-p)' den küçüktür. (Yazgan, 1996)




Şekil 1.4. Delta dalgası

Gamma Dalgaları: bazı araştırmacılar tarafından kullanılmaktadır. Bazı araştırmacılar da bu dalgaların yerine, BII dalgalarını kullanmaktadır. Genlikleri, $2 \mu V$ (p-p)’ den daha küçüktür. Kafanın merkezinde, genlikleri daha büyüktür. Uykunun karakteristik belirtisini taşırlar. (Yazgan, 1996)

1.1.1 Elektroensefalogram İşaretlerinin Ölçülmesi

Şekil 1.5. de, basitleştirilmiş bir n kanallı EEG sisteminin blok diyagramı verilmiştir. Baş üzerine uygun noktalara konmuş 20 elektrot, elektrot seçici üniteyle n adet diferansiye kuvvetlendiriciden oluşan ön kuvvetlendirici ünitesi girişine uygulanmıştır. Kalibrasyon işareti dikkdörtgen şeklindedir. Kaydedilen bu işaretin genliği tüm sistemin kuvvetlendirmesini, şekli ise frekans karakteristiğini gösterir. EEG çıkışları, bir A/D yardımıyla dijital analizöre(bilgisayar) ve kaydedilmek üzere dijital manyetik teybe verilir. EEG işaretlerinin genlikleri μV lar mertebesinde olduğundan, ön kuvvetlendirici olarak diferansiyel kuvvetlendirici kullanmak gerekmektedir. Bu kuvvetlendiricilerin kazançları yüksek, gürültüleri düşük, ortak moddaki işaret reddetme oranları yüksek olmak zorundadır (örneğin $> 100 \text{ dB}$). Ayrıca giriş empedansları yüksek ($1 \text{ M}\Omega$ ’ un üzerinde) ve DC kaymaları da düşük olmalıdır. (Yazgan,1996)



Şekil 1.5. n kanallı bir EEG ölçüm sisteminin blok diyagramı (Yazgan,1996)

1.1.2. EEG Elektrotlarının Bağlanma Şekli

EEG ölçümlerinde, beş farklı tipte elektrot kullanılmakla birlikte, en yaygın olanı yeniden kullanılabilir scalp disk tipi elektrotlardır. Bunlar, uygun bir iletken krem yardımıyla deriye temas ettirilirlir. Elektrotların bağlantısına uluslar arası standartlar kullanılır. En çok kullanılanı **10-20 EEG elektrot sistemidir**. Bu yerleşme şeklinde baş dört standart noktayla işaretlenmiştir. “Nasion” , burun; “inion” , kafanın arka kısmı; sol

gözlükler yardımıyla uygulanmaktadır. Erişkinlere uygulanan göz muayenesine koopere olamayan bebeklerin görüp görmediği hakkında ciddi yardımları olmaktadır.

Beyinsapı İşitsel Uyarılmış Potansiyeller (BAEP): İşitme yollarının işitme sinirinden başlayarak beyin derin yapılarında ve son olarak ilgili beyin kabuğunda temsil edildiği yere kadar olan bölümünü test eder. İnceleme sırasında hastaya belli frekans aralığında klik ses uyarısı bir kulaktan verilir. Bu sırada saçlı deri üzerinden kayıt yapılır. İncelemede, ilk 10 ms içerisinde bahsedilen beyin yapılarının bazı bölümlerinden kaynaklandığı bilinen ve bu yapılarda bir rahatsızlığı olmayan bireylerde her seferinde aynı şekilde ve aynı aralıklarla tekrarlanan bazı yanıtlar elde edilir. Bu yanıtlar yüksek sayıda tekrarlanarak ortalama bir şekil elde edilir. Bu şekil içerisinde beklenen yanıtlar işaretlenir. Yanıtların zamana göre dağılımları, genlikleri ve şekillerine bakılarak normal değerler ve diğer kulaktan elde edilen değerler ile karşılaştırma yapılır. Aynı işlem diğer kulak için de tekrarlanır.

Somatosensoriyel Uyarılmış Potansiyeller (SEP): Bu incelemede de sinir sistemimizin diğer ikisine göre daha geniş fakat yine de işleve sınırlı bir bölümü kontrol edilir. Burada uyarıcı kol, bacak, yüz veya vücudun diğer bir alanındaki motor veya duyu sinirlerine ardışık elektrik uyarısı olarak verilir. Her verilen uyarı karşılığında uyarılan sinirin vücuttaki gidiş yolu üzerinden ve uyarının sonlandığı beyin bölgesine uyan saçlı deriden belli yanıtlar kaydedilir. Bu yanıtların tekrarlanan uyarılarla ortalaması alınır. Çeşitli işaretlemeler yapılarak yanıtların zamana göre dağılımı, genlikleri ve şekilleri kontrol edilir. Uyarılan sinir yolu üzerinde herhangi bir sorun varsa beklenen yanıt gecikebilir, genliği düşebilir, şekli bozulabilir ve hatta tamamen kaybolabilir.

Motor Uyarılmış Potansiyeller (MEP): Nadiren kullanılan bu incelemede beyine ve omuriliğe stimülatörler yardımı ile verilen uyarıların kaslardaki yanıtları kaydedilir ve yorumlanır. Bu sayede beyinden omuriliğe kadar veya omurilikteki sinir kökünden kaslara kadar olan sinir iletimi incelenebilir. Beynin veya omuriliğin uyarılması için özel kortikal elektrik stimülatörleri veya manyetik stimülatörler kullanılmaktadır. Kortikal elektrik stimülatörleri daha noktasal ve yüzeysel uyarılar verirler ve daha güçlüdürler. Manyetik stimülatörler daha derin, yaygın ve ağrısız uyarı vermektedirler.

2. ÖNCEKİ ÇALIŞMALAR

Sweldens (1994), çalışmasında bir fonksiyonun dalgacık sabitlerini bu fonksiyonun örneklerinden hesaplanması üzerine interpolasyon, quadrature formül ve filtreleme metotlarıyla uygulamalar sunmuştur.

Anderson ve ark. (1995), çalışmasında EEG işaretleri yardımıyla zihinsel durumun tanımlanması amacıyla Yapay Sinir Ağları kullanmışlardır.

Grap (1995a), makalesinde geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapmış, ayrıca henüz gelişen dalgacık analizinin uygulama alanlarından bahsetmiştir

Kalaycı ve Özdamar (1995), giriş ve çıkış datasının sinyalin karakteristik özelliklerini gösterebilecek şekilde işlenebilmesi durumunda Yapay Sinir Ağlarının daha iyi sonuç verdiğini gösteren bir çalışma yapmışlardır.

Prodhan ve ark. (1996), LVQ(Learning Vector Quantization) temelli bir Yapay Sinir Ağı kullanarak nöbet aktivitesinin sınıflandırılması için bir ön çalışma yapmışlardır.

Dograhmi ve ark. (1997), çalışmasında EEG kayıtlarının spektral analiz temelli sınıflandırılmasını amaçlayarak elektrot sayısının ve uygulanan spektral analiz yöntemi özelliklerinin bir sınıflandırıcı gibi kullanılması konusunu incelemişlerdir.

Mckeown ve ark. (1997), EEG işaretlerinin analizi ve uyarı değişikliklerinin bulunması amacıyla istatistiksel yöntemler kullanarak bir çalışma yapmışlardır

Jung ve ark. (1997) çalışmasında uyku ve uyanıklık durumlarının Yapay Sinir Ağları ile sınıflandırılmasında, hem EEG işaretlerinden ziyade Fourier Dönüşümü alınmış EEG'nin daha uygun sonuçlar verdiğini gözlemlemişlerdir.

Miner (1998), bu raporda geleneksel Fourier metotları, Dalgacık teorisi ve analizlerinin gelişimini inceleyerek sinyal işleme alanı temelli çeşitli karşılaştırmalar yapılmış, ayrıca sürekli ve ayırık dalgacık analizi algoritmaları verilmiştir.

Torrence ve ark. (1998), çalışmalarında yaygın olarak kullanılan temel dalgacık fonksiyonları sınıflandırılmış, özellikleri verilerek ayırık zaman diziler için sürekli dalgacık dönüşümü yaklaşıklığı verilmiştir. Sonlu uzunlukta zaman serilerine Pencerelemiş Fourier ve Dalgacık dönüşümü uygulayarak istatistik önem ile güvenilirlik aralığı analizleri yapmışlardır.

Önal ve ark. (1998), EEG sinyallerindeki epileptik sürecin Dalgacık Dönüşümü yöntemi ile belirlenmesini amaçlayarak bir çalışma yapmışlar ve bu çalışmada parsiyel nöbet geçiren 3 yaşındaki bir çocuktan alınan gerçek EEG işareti kullanarak epileptik süreçte özellikle düşük frekans bandı δ 'nın etkinliğini göstermişlerdir.

Güneş ve ark. (1998), EEG işaretlerine Dalgacık Dönüşümü teknikleri uygulayarak, Sürekli ve Ayrık Dalgacık Dönüşümlerinin üstünlüklerini göstermeyi amaçlayan bir çalışma yapmışlardır.

Güneş (1999), EEG işaretlerinin Dalgacık Analizi ve diğer parametrik yöntemlerle karşılaştırılması konulu bir tez çalışması yapmıştır.

Suleesathira ve ark. (2000), deterministik durağan olmayan sinyallerin gösteriminin ayrık evrimsel dönüşümle yapılabilirliği konusunda çalışmışlardır.

Girault ve ark. (2000), çalışmalarında durağan olmayan benzetim ve gerçek sinyaller üzerinde FFT, AR, Zamanla değişen parametrik model yaklaşımı metotlarını kullanmışlar, frekans kestirimi için de karşılaştırma maksadıyla spektral ağırlık merkezi hesabıyla değerlendirmelerde bulunmuşlardır.

Kıymık ve ark. (2004), gerçek zamanlı uygulamalar için EEG sinyallerindeki epileptik sürecin belirlenmesinde STFT (Short Time Fourier Transform) ve Dalgacık Analiz yöntemlerini kapsayan bir çalışma yapmışlar ve bu çalışmada Dalgacık Dönüşümü'nün diğer spektral analiz yöntemi olan STFT'ye oranla daha başarılı sonuçlar verdiğini göstermişlerdir.

3. MATERYAL ve METOT

3.1. Materyal

Bu bölümde sinyal analiz yöntemlerinin gelişimine değinilerek tez çalışmasında kullanılan Dalgacık Dönüşümü yöntemi hakkında ayrıntılı bilgi verilecektir. Sınıflandırma probleminin, Yapay Zeka yazılımlarından biri olan Yapay Sinir Ağı kullanarak çözümü amaçlandığından YSA hakkında bilgi verilerek YSA' nın temelleri ayrıntılı bir biçimde ele alınacaktır. Kullanılan materyaller hakkında bilgi verilecektir.

3.1.1. Giriş

EEG işaretlerinde beyin fonksiyonlarıyla ilgili çok miktarda bilgi saklıdır. Bu bilgilerin tıbbi araştırmalarda ve hastalık teşhisinde kullanılabilmesi için, modern parametrik yöntemlerle gerçek zamanda spektral analizinin gerçekleştirilmesi ve otomasyona geçilmesi gerekmektedir.

Sinyallerin analiz edilmesi direk sinyalin kendisi veya sinyalin gösteriminin başka boyutlara (zaman, frekans, zaman-ölçek..vb) taşınarak gerçekleştirilmesiyle yapılmaktadır. Amaç; sinyalin bilgi kaybına uğratılmadan bu boyutlardan birisine dönüşümü yapılarak işlenmemiş haldeki verilerden sağlıklı seçilemeyen anlamlı detay bilgilerine ulaşmaktır.

Öncelikle dönüşüm işlemine ihtiyaç duyulur. Her hangi bir sinyalden daha fazla bilgi almak için matematiksel dönüşüm işlemi uygulanır. Mevcut bir çok dönüşüm tekniği farklı tip sinyaller ve amaçlar için kullanılmaktadır. Hilbert, KZFD, Zak Fourier, Running Fourier, Wigner, Radon ve Wavelet dönüşümü gibi. Her bir dönüşüm tekniğinin kendine göre avantajları ve dezavantajları vardır. Bunlardan en eski olanlardan biriside Fourier Dönüşüm tekniğidir.

Çoğu sinyaller zaman alanında gösterilir. Zaman alanında bir sinyalin çizilmesi zaman-genlik gösterimi ile ifade edilir. Bu gösterim genellikle sinyal işlemede iyi bir gösterim olmamaktadır. Sinyallerin yapılarına bağlı olmakla birlikte çoğu kez ayırt edilebilir önemli bilgiler frekans bileşenlerinde gizli tutulurlar.

Fourier Dönüşümü sinyalin de mevcut olan frekans bileşenlerini bize verir. Fakat bu tip bir dönüşüm frekansların hangi zaman aralığında var olduğunu gösteremez. Bu bilgiler sinyal şayet durağan ise gerekli değildir. Çünkü durağan sinyallerde zamana göre frekans değişmez. Şayet sinyalin zamana göre frekansı değişiyorsa bunlara durağan olmayan sinyaller denir. Fourier Dönüşümünü durağan olmayan sinyallerde ne tür bir spektral bileşen olduğunu öğrenmek için kullanılabilir, fakat nerede oluştuğunu söyleyemez. (Polikar, 1999).

3.1.2 Sinyal Analiz Metotlarının Gelişimi

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier temelli dönüşüm

teknikleri daha sonraki yıllarda Ayırık Fourier Dönüşümü (DFT) ve Hızlı Fourier dönüşümü (FFT) algoritmalarının geliştirilmesiyle bilgisayarlarda veri işleme için önemli bir basamak atlanmıştır.

Denis Gabor 1946 yılında Gabor Dönüşümü olarak bilinen Fourier temelli analiz yöntemini sunmuştur. Bu metot da pencereleme yöntemini kullanarak ki pencere fonksiyonu Gauss Hata fonksiyonudur, işaretin küçük bir parçasını zaman tanım aralığında ele alınmış, işaret zaman ve frekansın fonksiyonu olarak iki boyutta ifade edilmiştir. Böylece durağan olmayan sinyallerin işlenmesi daha sağlıklı hale gelmiştir. Gabor dönüşümü bugün Kısa Zaman Hızlı Fourier Dönüşümü (KZFD) olarak yöntemin kaynağı olarak görülmektedir (Robertson ve ark., 1998).

Fourier temelli analiz yaklaşımlarının ilerleyen konularda da bahsedileceği dezavantajları (zaman ve/veya Frekans çözünürlüğü sorunu, her zaman var olacak olan Gibbs olayı..vb) (Robertson, 1998), sinyal analizcileri daha farklı yollara, modern ve parametrik yöntemlere yöneltmiştir.

Bu şekilde Fourier serisi yaklaşımıyla başlayan sinyal frekans analizi kavramı günümüze değin ölçek analizi kavramına ve bununla sıkı sıkıya bağlı dalgacık dönüşümüne kadar gelişmiştir.

Ölçek analizi, basitçe bir $f(x)$ fonksiyonunun ölçeği değişen matematiksel yapılar oluşturarak analiz edilmesidir. Önce basit bir temel fonksiyon tasarlanır, sonra bir miktar ötelenir ve ölçeği değiştirilir. Bu yapı her hangi bir fonksiyonun yaklaşımında kullanılır ve aynı işlemler tekrar edilir böylelikle yeni yaklaşımlar aynı basit yapısal temel fonksiyondan türetilerek elde edilir. Bu ölçek analizi dizisi, sinyalin farklı ölçeğe sahip ortalama dalgalanmalarını ölçtüğünden gürültüye de en az duyarlıdır. Konuyla ilgili ilk bahis A. Haar (1909) tarafından sunulmuştur

1930' larda fonksiyonların değişken ölçekli temel fonksiyonlar kullanılarak gösterilmesi ile ilgili bağımsız çalışmalar yapılmıştır. Temel fonksiyonlar ve değişken ölçekli temel fonksiyonlar kavramlarının anlaşılması dalgacıkların anlaşılmasına anahtar oluştururlar.

Aynı yıllarda Paul Levy, Haar temel fonksiyonu olarak adlandırılan değişken ölçekli temel fonksiyonunu kullanarak rasgele bir sinyal tipi olan Brownian hareketi araştırmıştır. Bu çalışmada Brownian hareketin küçük karmaşık detaylarının incelenmesinde Haar temel fonksiyonların Fourier temel fonksiyonlara oldukça üstün olduğu sonucu çıkmıştır.

1960-1980 yıllarında matematikçiler Guido Weiss ve Ronald R. Coifman “atoms” adı verilen bir fonksiyon uzayının en küçük elemanı üzerinde çalışmışlardır. Amaç sıradan bir fonksiyon için bu atomların bulunması ve bu atomlar kullanılarak fonksiyon uzayının tüm elemanlarını tekrar meydana getirecek birleştirme kuralını bulmaktır. 1980' lerde fizikçiler Morlet ve Grossman dalgacıklara quantum fiziğinde geniş yer vermişlerdir.

Alex Grossman ve Jean Morlet bu fonksiyon yapı blokları için ilk defa “Wavelet” yani DALGACIK adını önermişlerdir ve o zamana kadar Littlewood-Paley teorisi olarak

belirtilen teori “Wavelet” DALGACIK TEORİSİ olarak adlandırıla gelmiştir (Jawert ve ark., 1992)

1985’ de Stephane Mallat dalgacıkları bu alanda yeni bir sıçrama tahtası oluşturan sayısal sinyal işleme çalışmalarında kullanmış; ve Quadrature Mirror Filtre, piramit algoritmaları ve normal-dikey (Orthonormal) dalgacık temeller ve daha bir çokları arasındaki ilişkileri keşfetmiştir.

Y. Meyer ilk önemli dalgacıyı kurmuştur. Bu Haar dalgacığının tersine sürekli türevlenebilir özellikteydi fakat tam dayanaklı (Compact Support) değillerdi. Birkaç yıl sonra Ingrid Daubechies Mallat’ ın çalışmaları ışığında normal-dikey temel dalgacık fonksiyonlarını inşa etti ki bunlar belki en seçkin ve günümüzdeki dalgacık uygulamalarına köşe taşı teşkil edecek olanlardır (Grap, 1995a).

3.1.3 Fourier Temelli Sinyal Analizi

19.Yüzyılda Fourier herhangi bir periyodik fonksiyonun sonsuz sayıdaki kompleks üstel fonksiyonların toplamıyla ifade edilebileceğini söylemiştir. Fourier dönüşümü sonuçları frekans bileşenlerinin yerel zaman, başlangıç veya bitiş bilgileri hakkında kesin veriler sağlamaz çünkü bu bilgi Fourier spektrumu boyunca yayılmıştır yani Fourier dönüşümü ancak genel bir bakış sağlar. Bunun sebebi Fourier temel fonksiyonlarının (sinüs ve kosinüs) tam dayanaklı olmamalarıdır. Bundan dolayı durağan sinyallere uygulanmalarında en iyi sonuç verir (Robertson ve ark., 1998). Eşitlik 3.1’ de görüldüğü gibi herhangi bir t1 veya t2 anı entegrale aynı etkide bulunacaktır.

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (3.1)$$

$$x(t) = \int_{-\infty}^{\infty} X(f)e^{j\omega t} df \quad (3.2)$$

3.1.3.1 Akan Fourier Dönüşümü (Running Fourier Transform)

Bir f(t) sinyalinin Akan Fourier Dönüşümü ifadesi; c verilen bir sabit olmak üzere Eşitlik 3.3 ile verilir. F(t,ω), f(t) sinyalinin τ dilimine karşılık gelen f(t+τ) sinyalinin Fourier dönüşümüdür. Böylelikle durağan olmayan sinyaller için spektrumun değişimi sinyalin durağan kabul edildiği τ dilimleri ile belirlenebilmektedir.

$$F(t, \omega) = \int_{-c}^c f(t + \tau)e^{-j\omega\tau} d\tau = e^{j\omega t} \int_{t-c}^{t+c} f(\alpha)e^{-j\omega\alpha} d\alpha \quad (3.3)$$

F(t,ω) nini Ters Dönüşümü ifadesi de $\omega_0 = \frac{\pi}{c}$ olmak üzere

$$f(t) = \frac{1}{2c} \sum_{m=-\infty}^{\infty} F(t, m\omega_0) \quad (3.4)$$

eşitliği ile verilir (Papoulis, 1984)

3.1.3.2. Kısa Zaman Fourier Dönüşümü (KZFD)

Daha önce FD' nin durağan olmayan sinyaller için elverişli olmadığı ifade edilmişti. Denis Gabor, 1946 yılında pencereleme yöntemini kullanarak, işaretin küçük bir parçasını zaman tanım aralığında ele almış, işaretin zaman ve frekansın fonksiyonu olarak iki boyutta ifade etmiştir. Bu dönüşüm yönteminde işaretin belirli bir kesiminin durağan olduğu kabul edilebilecek (Miner, 1998) bir pencereden geçirilir ve yerel bir frekans parametresiyle FD işlemi gerçekleştirilir. KZFD ile FD arasında çok az bir fark bulunur. KZFD' de sinyal küçük çerçeveler bölünür ve bu çerçeve anlarında sinyalin durağan olduğu kabul edilir. Durağanlığın geçerli olduğu bu çerçeveler sinyalin bir pencere fonksiyonu ile çarpılmasıyla elde edilir. FD' nin yerelleştirilmesi fikrine dayanan bu teknik ilgilenilen yerde uygun bir pencere seçilerek dönüşüm işlemi gerçekleştirilir. (Polikar, 1999). Durağan olmayan sinyallerin spektral analizi çok iyi zaman ve frekans çözünürlüğü sunması gereken yetenekli işlevlere ihtiyaç duyar (Keeton ve Schlindwein, 1998).

KZFD temel bir pencere fonksiyonundan zaman alanında kaydırma ve frekans parametreleri olmak üzere iki ayrı şekilde türetilir. Burada kullanılan pencere fonksiyonu Eşitlik 3.5 ile ifade edilmiştir. Pencere fonksiyonu sonlu enerjiye sahip olması ve entegralinin alınabilmesi gerekmektedir.

KZFD yönteminde zaman ekseninde bir τ noktasına $w(t)$ pencere

$$g_{w,\tau}(t) = e^{j\omega\tau} w(t - \tau) \quad (3.5)$$

fonksiyonunu yerleştirilerek pencerelenmiş fonksiyonun Fourier Dönüşümü gerçekleştirilir. Daha sonra pencere kaydırılır ve tekrar Fourier dönüşümü alınarak işleme devam edilir. Bu yöntemin matematiksel ifadesi Eşitlik 3.6' de ifade edilmiştir. (Vaterli, 1995).

$$KZFD(w, \tau) = \int_{-\infty}^{\infty} f(t) w^*(t - \tau) e^{-j\omega\tau} dt = \langle g_{w,\tau}(t), f(t) \rangle \quad (3.6)$$


KZFD' deki $f(t)$ fonksiyonu tekrar elde edilebilir özelliktedir. Bu durum Eşitlik 3.7 ile gösterilmiştir.

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} KZFD(w, \tau) g_{w,\tau}(t) dw, d\tau \quad (3.7)$$

Sinyal spektrumundaki değişikliğin düzeyi en uygun çerçeve boyunu belirleme de önemli bir faktördür (Güler ve ark., 2001). KZFD ile ilgili analiz penceresinin seçimi farklı sinüzoidal bileşenlerin ortaya çıkarılmasını ve spektrumun düzgünlüğünü de belirler (Miner, 1998). KZFD' nin zaman çözünürlüğü pencere fonksiyonu zaman genişliği tarafından belirlenir dolayısıyla spektrum sonlu çözünürlükle elde edilir. KZFD Pencere fonksiyonun bant genişliği ile zaman genişliği çarpımı sabittir ve sadece kullanılan pencere fonksiyonun şekline bağlıdır dolayısıyla sabit çözünürlükle dönüşüm elde edilebilir (Fliege, 1996).

Dolayısıyla KZFD' de uygun bir pencere kullanılmalıdır. Dikdörtgensel bir pencere zayıf bir frekans çözünürlüğü doğurur. Örneğin üçgensel bir pencere $1/w^2$ 'ye göre azalan bir frekans spektrumu verir ve dikdörtgene göre daha iyi bir pencere sayılır. Fakat daha iyi pencereler sinyal analizcileri tarafından geliştirilmiştir. Bunlardan birisi olan Hanning pencere ifadesi Eşitlik 3.8 ile gösterilmiştir. (Polikar, 1999).

$$w(t) = \begin{cases} [1 + \cos(2\pi/T)]/2 & t \in [-T/2, T/2] \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.8)$$



Şekil 3.1. Hanning Pencere

KZFD' nin diğer bir ismi de Gabor Dönüşümüdür. Gabor tarafından kullanılan klasik pencerelerden biriside Gaussian penceresidir (Eşitlik 3.9).

$$w(t) = \beta e^{-\alpha t^2} \quad \alpha, \beta > 0 \quad (3.9)$$

Burada α genişliği, β ise normalizasyon faktörünü göstermektedir.

Bu metodun başlıca problemi pencere boyutunun sabit olmasıdır. KZFD zaman ve frekans bilgilerini kapsamayı yönüyle önemli olsa bile seçilen pencere $w(t)$ fonksiyonunun bütün frekanslar için sabit olması bir dezavantajdır. Bir çok işaret daha esnek yaklaşımlara yani zaman veya frekans hakkında daha çok bilgi alabilmek için değişebilen pencerelerle tekniklerine ihtiyaç duymaktadır (Keeton ve Schlindwein, 1998). Pencere fonksiyonu $w(t)$ sabit zaman-frekans çözünürlüğü vererek KZFD' yi sınırlar. Bu sınırlama Heisenberg belirsizlik ilkesi olarak adlandırılır ve matematiksel olarak Eşitlik 3.10 ve 3.11' de ifade edilmiştir.

$$W(t) \leftrightarrow \Psi(w) \quad (3.10)$$

$$\Delta t \Delta w \geq \frac{1}{2} \quad (3.11)$$

Burada Δw bant genişliği ve Δt zaman açıklığı şeklinde ifade edilirse, matematiksel olarak Eşitlik 3.12 ve 3.13' da ifade edilen sınırlamalarla karşılaşılır.

$$\Delta t^2 = \frac{\int t^2 |W(t)|^2 dt}{\int |W(t)|^2 dt} \quad (3.12)$$

Ayrıca sinyalin pencerelemesine dayanan metotlarda Gibbs olayı ile karşılaşılır. Gibbs olayı analizin doğruluğunun kaybına neden olur (Robertson ve ark., 1998).

$$\Delta w^2 = \frac{\int w^2 |\Psi(w)|^2 dw}{\int |\Psi(w)|^2 dw} \quad (3.13)$$

3.1.3.3. Zak Dönüşümü

Bir fonksiyonun Zak dönüşümü aşağıdaki gibi tanımlanır (Sweldens, 1994)

$$Zf(x, \omega) = \sum_l f(x + l) e^{-i\omega l} \quad (3.14)$$

3.1.3.4. Ayırık Fourier Dönüşümü (AFD) ve Hızlı Fourier Dönüşümü (HFD)

Fonksiyonlar teorik olarak tanımlı hallerde Fourier dönüşümleri rahatlıkla hesaplanabilir. Ancak uygulamada sinyallerin kesin fonksiyonel ifadeleri yoktur ve işlenmeleri için analog sinyallerden örneklenmiş sınırlı sayıda sayısal ayırık dizileri mevcuttur. Bu yüzden daha önce bahsedilen şekilde Fourier dönüşümleri hesaplanamaz.

Ayrıca bütün frekans boyutunun analog olarak gösterimi sonsuz sayıda örneklenmiş işareti gerektirmektedir bu ise uygulamada mümkün değildir.. Sayısal işaretler için Fourier dönüşümünün hesaplanması için belirli sınırlamalı içindeki yaklaşıklıklarla verilebilir. Bir $f[k]$ ayırık dizisinin N örneği için tanımlanan bu yeni dönüşüm Ayırık Fourier dönüşümü (AFD) olarak adlandırılır.

Tersi de alınabilen bu dönüşümün önemli özellikleri vardır. Ayırık Fourier Temelli dönüşümler dizinin periyodik olduğunu kabul ederler (Torrence ve ark., 1997) dolayısıyla bir ayırık zaman sinyali periyodik ise bunun yaklaşık Fourier dönüşümü AFD' dir (Roberts ve ark., 1987). Özellikle iki AFD' nin çarpımı bunlara karşı düşen dizilerin ayırık-zaman

boyutunda konvolusyon toplamıdır (Roberts ve ark.,1987). Ayrıca sayısal ortamdaki bir çok spektral analiz yöntemi AFD' ye dayanmaktadır.

AFD, $f(k)$, $k = 0, 1, \dots, N-1$, gibi bir sonlu diziyi , $F(n)$, $n = 0, 1, \dots, N - 1$.gibi diğer bir sonlu diziye eşleyen önemli bir operatördür. Normalize edilmiş örnekleme frekansı 2π olmak üzere (Roberts ve ark., 1987):

$$F[n] = \text{AFD}\{f[k]\} = \sum_{k=0}^{N-1} f[k]e^{-j2\pi kn/N} \quad (3.15)$$

Ters Ayırık Fourier dönüşümü (TAFD) ise $F[n]$ 'yi yeniden $f[k]$ dizisine dönüştürür:

$$f[k] = \text{TAFD}\{F[n]\} = \frac{1}{N} \sum_{n=0}^{N-1} F[n]e^{j2\pi kn/N} \quad (3.16)$$

Eğer $f[k]$ dizisi bant sınırlı bir $f(t)$ işaretinin T_0 örnekleme aralığı (f_0 örnekleme frekansı) ile Nyquist şartları sağlanmış şekildeki örneklerini temsil ediyorsa, AFD dizisi $F[n]$ (pencereleme etkisi ihmal edilerek) orijinal işaretin Fourier dönüşümünün örneklerini temsil edebileceği açıktır:

$$F[n] = F(\omega) \Big|_{\omega = \frac{2\pi f_0 kn}{N}} \quad k = 0, 1, \dots, N-1 \quad (3.17)$$

$f(t)$ sinyali toplam T süresi boyunca örneklenmişse dolayısıyla T süreli bir pencere ile sinyal örneklenmiş ise AFD, FD için sadece bir kestirim sağlar ve bunun frekans çözünürlüğü;

$$\Delta f = \frac{f_0}{N} = \frac{1}{T} \quad (3.18)$$

burada dikkat edilmesi gereken husus T ' nin örnekleme periyodu değil pencere süresi olduğudur. Dolayısıyla daha uzun pencere kullanılarak çözünürlük arttırılabilir. Daha uzun pencere kullanımı mümkün olmayan durumda mesela işaret durağan olmadığında, sıfır ekleme (zero padding) yöntemi kullanılabilir. Dizinin sonuna aynı N örnek sayıda sıfırlardan oluşan bir dizi daha eklenir:

$$f_z[k] = \{f[0], f[1], \dots, f[N-1], 0, \dots, 0\} \quad (3.19)$$

Sıfır eklenmiş dizi $f_z[k]$, $k = 0, 1, \dots, L - 1$, ; orijinal diziden N eleman içerirken L - N kadar sıfır içermektedir. Böylece daha fazla örneğe dolayısıyla daha geniş pencereye sahip bu dizinin frekans çözünürlüğü, T pencere süresi arttığı için arttırılmış olur.

Hızlı Fourier Dönüşümü (HFD): Ayrık Fourier Dönüşümünün doğrudan hesaplanmasında her bir $f[k]$ değeri için N karmaşık çarpma ve $N-1$ karmaşık toplama işlemi kullanılmaktadır. Bu nedenle N adet AFD değeri bulunurken, N^2 çarpma ve $N(N-1)$ toplama işlemi gereklidir.

Ayrıca her karmaşık çarpma işlemi için dört gerçel çarpma ve iki gerçel toplama işlemi ve her bir karmaşık toplama iki gerçel toplama işlemi ile gerçekleştirilmektedir. Neticede, dizi uzunluğu olan N nin 1000 in üzerinde olması halinde doğrudan AFD' nin hesaplanması çok fazla miktarda işlem gerektirmektedir. Yani N sayısı artarken gereken işlem sayısı çok fazla artmaktadır.

AFD hesaplanmasında bugün kullanılmakta olan verimli ve etkin bir yaklaşım hızlı Fourier dönüşüm algoritmalarıdır. Eşitlik 3.15' de ilk dönemlerde fark edilmeyen ve sonuçlardaki periyodik sayısal tekrarlama özelliğine dayanan dairesel katlama dan (circular convolution (Roberts ve ark., 1987)) yararlanılarak geliştirilen birbirinden farklı algoritmalar mevcuttur. Her ne kadar farklı bir dönüşüm olarak adlandırılmışsa da HFD AFD' den farklı değildir. Sadece kullanılan hesaplama yöntemi FD tahmini için HFD' yi cazip kılar.

Kullanılmakta olan bazı HFD algoritmalarına göre zaman desimasyonlu, frekans desimasyonlu HFD en genel olanlarıdır (Roberts ve ark., 1987).

Son olarak Ayrık zamanlı bir $f[k]$ işaretinin $w[k]$ ayrık pencere dizisi kullanılarak AFD ifadesini aşağıdaki denklemle verebiliriz:

$$F[n] = \text{AFD}\{f[k]\} = \sum_{k=0}^{N-1} f[k]w[k]e^{-j2\pi kn/N} \quad (3.20)$$

3.1.4. Ölçek Temelli Dalgacık (Wavelet) Sinyal Analizi

Dalgacık (Wavelet) teorisi matematikçilerin, bilgisayarlıların ve sinyal işleyicilerin çalıştığı popüler bir konu olup halen gelişmektedir. Dalgacık temelli sinyal analizinin durağan olmayan sinyaller ve nümerik sinyal işleme üzerine pek çok uygulama olanağı vardır ve Dalgacık Teorisi bu tip sinyal işleme konuları üzerine yeni bir konudur.

Sinyal işleyicilerin en çok bildiği Fourier temelli sinyal analizi; bir sinyali zaman alanından frekans alanına dönüştüren ve frekans bileşenlerinin önemli olduğu zaman sıkça başvurulmuş bir tekniktir. Fourier analizinde frekans alanına geçildiğinde zaman alanı yok olur. Durağan sinyallerde Fourier analizi iyi bir yöntem olmaktadır, fakat çoğu sinyaller durağan olmayan yapıya sahiptirler. Dalgacık analizi farklı frekanslarda durağan olmayan güce sahip zaman serisi sinyallerinin analizinde kullanılabilir (Daubechies, 1990; Torrence ve ark., 1997' den). Bu tip sinyallerde Fourier analizi yeterli olamamaktadır (Polikar, 1999).

Dalgacık analizi KZFD' nin bir alternatifi olarak çözünürlük probleminin üstesinden gelmek için ortaya çıkmıştır. KZFD de zaman-frekans alanında elde edilen bilgiler sınırlı bir hassasiyette elde edilebilmektedir. Bu hassasiyet pencerenin büyüklüğüne bağlıdır. Çoğu sinyaller daha hassas yaklaşıma ihtiyaç duyar ve bu pencerenin büyüklüğünün sürekli değişmesi gerekmektedir. KZFD' de zaman penceresi bütün frekanslarda değişmeyen büyüklüktedir.

Dalgacık analizi ise bir ileri ki yöntem olup pencereleme tekniği büyüklüğü değiştirilebilir. Dalgacıklar durağan veya durağan olmayan sinyallerin zaman-ölçek analizi için olanak sağlar. Dalgacıklar sonlu süreli oldukları bu yüzden yerel sinyal özelliklerinin analizini mümkün kılarlar. Dalgacık dönüşümleri tüm sinyal frekans-zaman bilgisini korurlar. Bu sebeplerden dolayı durağan olmayan gerçek doğal sinyallerin dalgacık temelli metotlarla işlenmesi geleneksel metotlardan daha iyi sonuçlar sağlarlar (Miner, 1998). Dalgacığın en önemli avantajlarından birisi, büyük işaretlerin yöresel analizine olanak tanımasıdır.

Gözle fark edilemeyecek kadar küçük süreksizliği olan işaretlerle gerçek hayatta sürekli karşılaşırız. Süreksiz sinüzoidal bir işareti ele alacak olursak, işaretin FD' nde sadece işaretin uç noktalarında pik değerleri oluşurken, Dalgacık Dönüşümü ile süreksizlik civarındaki değişimi de gerçek zamanlı olarak gözlemleyebiliriz. Süreksizlik gösteren ve keskin sıçramalar içeren sinyallerin analizinde dalgacık dönüşümünün Fourier dönüşümüne göre avantajları vardır (Fomitchev, 1994). Dalgacık analizi, başka analiz yöntemlerinin yakalayamadığı eğilimleri, bozulma noktalarını, yüksek dereceli türevlerde süreksizlikleri ve benzerlikleri çıkarmada başarılıdır.


Dalgacıklar datayı hızla ilişkisizleştirme yeteneğine sahiptirler. Bunun anlamı şudur; sinyalin dalgacık sabitleri ile gösterilmesi asıl gösteriminden daha özeldir, yani dalgacık gösterimindeki düzensizlik daha da küçüktür. Bu yüzden ki data sıkıştırma, hızlı data iletimi, gürültüden arındırma, sinyal onarımı ve hızlı sayısal algoritma uygulamaları için anahtar teşkil eder (Sweldens, 1995). Dalgacık analizi ile işaretin özelliğini bozmadan sıkıştırma ve görüntüden ayırma işlemlerini iyi bir şekilde gerçekleştirilir. Şekil 3.2 Zaman tabanlı (Shannon), frekans tabanlı (Fourier), KZFD (gabor) ve Dalgacık analizlerini ilişkilendirmektedir (Polikar, 1999).

Bir Dalgacık sınırlı yapıda olup ortalama değeri sıfır olan bir dalgacıktır. Sinüzoidal dalga, sınırı olmayan düzgün bir dalga olup Dalgacık ise düzensiz yapıya sahip ve asimetriktrir.


Dalgacık analizinin altında yatan temel düşünce sinyali ölçeğe göre analiz etmektir ve Fourier temelli analizde olduğu gibi sinüs temel fonksiyonları değil de dalgacık fonksiyonları kullanıldığından keskin süreksizlikleri içeren data yaklaşıklıkları için çok uygundur.

Dalgacık dönüşümleri ile analiz sonuçları teorik olarak sonsuz sayıda kümeden oluşur. Farklı dalgacık ailelerinin aralarında dayanaklı temel fonksiyon olmaları, uzayda nasıl yer aldıkları ve düzgünlük dereceleri açısından farklılık gösterirler ve yapılacak analiz niteliğine göre seçilebilirler. Bazı temel dalgacık fonksiyonlar fractal yapıya sahiptirler Şekil 3.3' de bir örneği verilen Daubechies dalgacık ailesi bunlara iyi bir örnektir (Grap,

1995b). Daubechies dalgacık fonksiyonu görüldüğü gibi düz ve yumuşak değildir. Esasında fractal bir yapıya ve her yerde türevlenemez özelliğe sahiptir. (Fomitchev, 1994).



Şekil 3.2. Sinyal analiz yöntemleri arasındaki ilişki (Polikar, 1999)



Şekil 3.3. Daubechies dalgacık (Grap, 1995b).

Fourier analizi sayesinde bir sinyalin, sinüzoidal bir çok frekanstan oluştuğunu biliyoruz. Dalgacık ise bir sinyalin, orijinal dalgacığın kaydırılmış ve ölçeklendirilmiş formundan oluşturulur. Sürekli Dalgacık Dönüşümü (SDD) bütün zaman aralığı boyunca Dalgacık fonksiyonu ψ 'nin ölçeklenmiş ve kaydırılmış şekliyle sinyalin çarpımından oluşur. SDD'nin sonucunda birçok Dalgacık katsayısı elde edilir bunlar ölçek ve pozisyon fonksiyonlarıdır (Fliege, 1996).

$$\text{SDD}\{f(t), a, b\} = \langle f(t), \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \rangle = \frac{1}{\sqrt{a}} \int f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (3.21)$$

Eşitlik 3.21 sürekli dalgacık dönüşümü olup b ve a değişkenlerinden oluşur ve sırası

ile translation (zaman ötelemesi) ve scale (ölçek) anlamlarını ifade ederler. $\psi(t)$ dönüşüm temel fonksiyonu olup ana dalgacık adı verilir. Farklı özellik ve kullanım amaçlarına sahip bir çok ana dalgacık mevcuttur (Fliege, 1996).

Ana Dalgacık terimi, isminden de anlaşılacağı gibi iki önemli kelimedenden oluşup bunlar sırası ile: Dalgacık terimi, küçük dalga anlamında dalgacık olarak ifade edilir. Buradaki küçüklük belirli uzunlukta pencere fonksiyonu olarak tarif edebiliriz. Dalga ise buradaki pencere fonksiyonunun titreşimli olduğunu ifade etmektedir. Buradaki ana kelimesi ise: bir ana fonksiyondan dönüşüm tekniği ile türetilip değişik alanları desteklemek için oluşturulan fonksiyonlardır. Diğer bir ifade ile ana dalgacık diğer pencere fonksiyonlarını üretmek için bir prototiptir.

ψ transfer fonksiyonunda öteleme terimi KZFD de olduğu gibi pencerenin yerini belirler ve sinyal boyunca pencereyi kaydırır. Bu terim transfer alanında zaman bilgilerini içerir. Bu dönüşümde frekans bilgisine sahip değiliz fakat ölçek parametresi $1/\text{frekans}$ olduğu için bu parametreden yararlanılır. Burada yüksek ölçek sinyalin daha az detaylı görünüşünü ve düşük ölçek ise detaylı görünüşü oluşturur. Ölçek bir matematiksel işlem olup sinyali hem açar hem de sıkıştırır. Yüksek ölçekler sinyali açar düşük ölçekler ise sinyali sıkıştırırlar (Polikar, 1999).

3.1.4.1 Dalgacık Teorisinin Matematiksel Yaklaşımı

Fourier dönüşümü temel fonksiyon kullanarak bir fonksiyonun analizini ve tekrar elde edilmesini gerçekleştirmektedir. Dalgacıklar ise durağan olmayan sürekli sinyallerin genişletilebilmesi ve ayrıştırılabilmesi için uygunlaştırılmış fonksiyonlardır. Bunlar Dalgacık dönüşümünün özünü yani zaman boyutundan zaman-frekans boyutuna eşleşmeye olanak oluşturlar (Fliege, 1996).

Vektör uzayındaki her bir vektör temel vektörlerin lineer kombinasyonları olarak yazılabilir. V vektör uzayı bir taban lineer bağımsız vektörlerin bir kümesidir. V deki herhangi bir v vektörü temel vektörlerin lineer kombinasyonu olarak yazılabilir. Bir vektör uzayında birden fazla taban olabilir. Fakat bunların hepsi aynı sayıda vektörlere sahip olup bu vektör sayısına boyut denir. Örneğin iki boyutlu uzayda taban iki vektöre sahiptir

$$v = \sum_k V^k b_k \quad (3.22)$$

Eşitlik 3.22 ile herhangi bir v vektörü b_k ve V^k katsayılarına bağlı taban vektörlerin lineer kombinasyonu olarak yazılabilir. Vektör için verilen bu kavramlar fonksiyonlar için de yazılabilir (Polikar, 1999).

Bu durumda kullanılan en temel yaklaşım olan sinyallerin basit yapı blokları veya temel fonksiyonların ağırlıklı toplamlarıyla ifade edilmesine ulaşılır (Fomitchev, 1994). Eşitlik 3.22' deki b_k yerine taban fonksiyonu $\psi_k(t)$ ve v vektörü de $f(t)$ fonksiyonu olarak yazılırsa $f(t)$ fonksiyonu Eşitlik 3.23' daki gibi ifade edilebilir.

$$f(t) = \sum_k c_k \psi_k(t) \quad (3.23)$$

Karmaşık üstel fonksiyonlar Fourier dönüşümünde temel fonksiyonlardır. Aynı zamanda dikey fonksiyonlardır ki bu özellik tekrar geri türetilmelerini sağlamaktadırlar. Şayet iki vektör iç çarpımları sıfıra eşit ise bunlara dikey vektörler denir ve Fourier serisi $V_n = c_n e^{jnx}$ sonsuz dikey bileşenlerin toplamı olarak ifade edilebilir. Burada dikey vektör $\langle v, w \rangle = \sum_n v_n w_n^* = 0$ olarak tanımlanır ve aynı şekilde $f(t)$ ve $g(t)$ fonksiyonları için Eşitlik 3.24' daki gibi tanımlanabilir.

$$\langle f(t), g(t) \rangle = \int f(t) \cdot g^*(t) dt = 0 \quad (3.24)$$

Normal-dikey (Orthonormal) bir tabanda daha önce tanımladığımız c_k katsayıları aşağıdaki gibi hesaplanabilir (Jawert ve ark., 1992).

$$c_k = \langle f, \psi_k \rangle = \int f(t) \cdot \psi_k^*(t) dt \quad (3.25)$$

$f(t)$ fonksiyonu c_k katsayılarını denklem 3.24' te yerine konarak tekrar aşağıdaki gibi Eşitlik 3.26 elde edilebilirler.

$$f(t) = \sum \langle f, \psi_k \rangle \psi_k(t) \quad (3.26)$$

$f(t)$ ve $g(t)$, $L^2[a,b]$ de tanımlı iki fonksiyon olmak üzere bu iki fonksiyonun iç çarpımı Eşitlik 3.27' deki gibi yazılabilir.

$$\langle f(t), g(t) \rangle = \int f(t) \cdot g^*(t) dt \quad (3.27)$$

3.1.4.2 Sürekli Dalgacık Dönüşümü (SDD)

Böylece denklem 3.27' deki iç çarpım tanımlamasına göre Sürekli Dalgacık Dönüşümü, temel fonksiyonu olan $\psi_{a,b}(t)$ ile $f(t)$ sinyalinin iç çarpımı olarak yazılabilir.

$$\text{SDD}\{f(t), \psi(t)_{a,b}\} = \langle f(t), \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \rangle = \frac{1}{\sqrt{a}} \int f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (3.28)$$

Ters Sürekli Dalgacık dönüşümü TSDD ise c_w ana dalgacığın kabul olunabilirlik sabiti olmak üzere aşağıdaki şekilde verilir:

$$f(t) = SDD^{-1}\{f(t), \psi(t)_{a,b}\} = \frac{1}{c_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} SDD\{f(t), \psi(t)_{a,b}\} \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \frac{dad b}{a^2} \quad (3.29)$$


Burada a ve b parametreleri sürekli değişen ölçek ve öteleme değişkenleridir. $\psi(t)_{a,b} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$ ise temel dalgacık fonksiyondan öteleme ve ölçeklemeyle türetilen dalgacık fonksiyonudur (Torrence ve ark., 1997).

Bir fonksiyonun ana-dalgacık olabilmesi için sağlaması gereken koşul Eşitlik 3.30' da verilmiştir. Bu kabul edilebilirlik koşulu' dur:

$$c_\psi \equiv \int_{-\infty}^{\infty} \frac{|\Psi(w)|^2}{|w|} dw < \infty \quad (3.30)$$


Şimdi öyle bir f fonksiyonu düşünelim ki uzayı $L^2(\mathbb{R})$ de tanımlı olsun ve $\int_{-\infty}^{\infty} |f(x)|^2 dx < \infty$ şartını sağlasın.

Normal bir sinüzoidal sinyal bu şartı sağlamaz çünkü $\pm\infty$ 'da bu sinyalin sıfıra gitmesi gerekmektedir yani öyle bir dalgacık arıyoruz ki $\pm\infty$ ' da sıfıra gitsin öyle bir ψ fonksiyonu ele alalım ki bütün reel alanı kapsasın. Sonuç olarak $L^2(\mathbb{R})$ de küçük bir dalgacık üretmeliyiz. $L^2(\mathbb{R})$ de ψ fonksiyonunun tüm uzayı kapsamasını istiyoruz. Fakat bu durumda ψ dalgacığı hızlı bir şekilde azalan fonksiyondur. ψ nin tüm uzayı kapsaması için $\mathbb{R}$ boyunca kaydırılması gerekmektedir. Buna göre $\psi(x-k)$ $k \in \mathbb{Z}$ olarak tanımlanır. Bu şartları sağlayan bazı dalgacık fonksiyonları Şekil 3.4, 3.5, 3.6' da gösterilmişlerdir.




$$\psi(x) = \left(\frac{2}{\sqrt{3}} \pi^{-1/4} \right) (1-x^2) e^{-x^2/2} \quad (\text{Torrence ve ark., 1997})$$

Şekil 3.4. Mexican Hat Dalgacık fonksiyonu: ve ark., 1997)



Şekil 3.5. Morlet Dalgacık fonksiyonu: Denklemi: $\psi(x) = Ce^{-x^2/2} \cos(5x)$ (Torrence ve ark., 1997)



$$\psi(x) = 1$$

$$0 \leq x < \frac{1}{2}$$

$$\psi(x) = -1$$

$$\frac{1}{2} \leq x < 1$$


$$x \notin [0,1]$$

Şekil 3.6. Haar Dalgacık fonksiyonu. Denklemi: $\psi(x) = 0$ (Grap,1995b)

Fourier teorisinden biliyoruz ki zaman boyutunda sıkıştırma frekans boyutunda yayılma ve yukarı doğru kaymaya denk düşer bunun tersini de söyleyebiliriz. Yani $\psi(t/a)$ fonksiyonun Fourier dönüşümü $\psi(a\omega)$ ve $\psi(at)$ fonksiyonun Fourier dönüşümü $\psi(\omega/a)$ 'dır. Bir dalgacığın değişen ölçekler için frekans tayfları aşağıdaki Şekil 3.7' de temsil edilmektedir. Her bir dalgacık bant geçiren süzgeç olarak alınırsa bunun ölçeklenmiş serisi de bant geçiren süzgeç serisi oluşturacaktır. Her bir spektrumun merkez değeri ile bant genişliği oranına bakacak olursak hepsinde bu oranın eşit olduğu görülür. Bu oran normalde süzgecin iyilik faktörü Q 'dür yani sabit- Q süzgeç serisi elde edilmiş olur (Valens, 1999).

Birçok uygulamada zaman-bant genişliği çarpımının farklı frekans ve/veya farklı zamanlarda bölümlenebilmesi istenir. İşte şekil 3.7' den de görülebileceği gibi bu amaca Dalgacık dönüşümüyle ulaşılır. Dalgacık dönüşümünün bu mahareti özel anlamını ve önemini de kesin olarak ifade eder. Her şeyden önce dalgacık dönüşümü *zaman-ölçek* boyutuna bir eşlemeyi gerçekleştirir ancak tam olarak zaman-frekans denilmemektedir.

Bununla birlikte $\psi(t)$ dalgacığının bant-geçiren yapısı bu eşlemeyi *zaman-frekans* boyutuna olan bir eşlemeyle hemen hemen aynı yapar. Sürekli a ve b parametreleriyle yapılan Dalgacık dönüşümü fazlaca gereksiz ve ters dönüşümü tek çözümlü değildir. Bu yapısıyla sürekli dalgacık dönüşümü daha az pratik öneme sahiptir. Sürekli dalgacık dönüşümündeki bu fazla gereksizlik ölçeğin 2' nin katlarıyla değiştiği dyatic dalgacık parametreleriyle ($a=2^j$ ve $b=k2^j$ gibi) ortadan kaldırılır (Fliege, 1996).



Şekil 3.7. Değişik ölçeklerdeki dalgacıklar için frekans spektrumları (ψ_1 en küçük ölçeğe karşılık düşen dalgacığı temsil eder).

Hem SDD' nin genel yapısından gelen fazlaca gereksizliği azalmak yani sadece yeterli düzeyde/sayıda öteleme ve ölçekleme yapmak hem de işareti istenilen yeterli frekans bantlarında inceleyebilmek maksadıyla $a=2^j$ ve $b=k2^j$ seçilebilir. Parametrelerin böyle seçimi değişkenleri ikinin katları oranında verecektir. Bu şekilde elde edilen ölçeklemeye ve dalgacıkları ifade etmek için dyatik terimi kullanılır.

$j>0$ ve $k\geq 0$ tam sayılar olmak üzere:

$$\psi_{j,k}(t) = \left(2^{-j/2}\right) \psi(2^{-j}t - k) \quad (3.31)$$

Eşitlik 3.31' deki temel dalgacık fonksiyonu ifadesindeki $2^{-j/2}$ sabiti dikey temel fonksiyonu normal-dikey yapar (Vidakovic ve ark., 1993) böylece her ölçekteki dalgacıkların genlikleri ve güçleri birim değere sahip olur:

$$1 = \left(2^{-j/2}\right)^2 \int \psi^2(2^{-j}x - k) dx = \left(2^{j/2}\right)^2 2^j \int \psi^2(t) dt = \left(2^{-j/2}\right)^2 2^j$$

Ölçek ve öteleme parametreleri olan a ve b' nin bu şekilde dyatik seçilmesi temel fonksiyonu seyrekleştirir. Bu seyrekleştirme dalgacığı veri sıkıştırmada çok kullanışlı yapar. Mesela FBI sayısal parmak izi sıkıştırmada dalgacık kullanımını standartlaştırmıştır. Hızlı Fourier dönüşümünde hesap sayısı $n \log_2 n$ iken Hızlı dalgacık dönüşümünde bu sayı n ' e kadar düşer (Vidakovic ve ark., 1993).

Bu çalışmada uygulamalarda da kullanılan SDD' nin ayrık yaklaşımından veya ayrık veri dizisinin SDD yaklaşımından bahsetmek gerekir. Ana dalgacık formunda a ve b için sadece dyatic değerler kullanan dalgacık dönüşümü orijinal olarak ayrık dalgacık dönüşümü olarak adlandırılmaktaydı ancak şu an bu terim muğlaktır çünkü aynı zamanda bir fonksiyonun ölçekleme fonksiyonu sabitlerinden onun dalgacık sabitlerine dönüşümü de belirtmektedir (Jawert ve ark., 1992). Aşağıda ki Eşitlik 3.32 SDD' nin ayrık yaklaşımı ifade eder burada dikkat edilmesi gereken şey dalgacığının sürekli ama dyatik, verinin ise ayrık olduğu hususudur.

$$f(t) = SDD^{-1} \{f(t), \psi(t)_{a,b}\} = \frac{1}{c_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} SDD \{f(t), \psi(t)_{a,b}\} \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \frac{dad b}{a^2} \quad (3.32)$$

Bir fonksiyonun ana-dalgacık olabilmesi için sağlaması gereken koşul denklem 3.33' de verilmiştir. Bu kabul edilebilirlik koşulu' dur:

$$c_\psi \equiv \int_{-\infty}^{\infty} \frac{|\Psi(w)|^2}{|w|} dw < \infty \quad (3.33)$$

Burada $\Psi(w)$ karelerinin integrali alınabilen sonlu enerjili $\psi(t), L^2(IR)$ fonksiyonunun FD' dür. Denklem 3.33' ün sonlu bir sayı olması ters Dalgacık dönüşümü için gerekli bir koşuldur. Yukarıdaki şartı sağlayan herhangi bir fonksiyon ana-dalgacık olabilir. Verilen bir $\psi(t)$ fonksiyonu için $c_\psi < \infty$ şartı Eşitlik 3.34 veya 3.35' de verilen şartlardan birisinin sağlanmasıyla gerçekleşir.

$$\Psi(0) = 0 \quad (3.34)$$

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.35)$$

Kabul edilebilirlik koşulundan $\psi(\omega=0)=0$ veya ortalama değerinin sıfır olması gerektiğini ve belirli olarak da dalgacığın salınımlı bir yapıda olması yani dalga olması gerektiğini görürüz (Jawert ve ark., 1992). Ayrıca fonksiyon eğrisinin altında kalan pozitif ve negatif alanların eşit olması gerektiği de görülmektedir. Bu yüzden dalgacıklar simetrik bir yapıya sahiptirler ancak bu şart değildir (Daubechies dalgacıklarında olduğu gibi).

Verilen bir $f \in L^2(R)$ fonksiyonunun $\psi(t)$ ' ye bağlı SDD ifadesi $W_\psi f(a,b)$ olarak gösterilir ve matematiksel ifadesi Eşitlik 3.36 ve 3.37 ile ifade edilmiştir.

$$W_\psi f(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (3.36)$$

$$\psi_{a,b}(t) = \left(\frac{1}{\sqrt{|a|}} \right) \psi^*\left(\frac{(t-b)}{a}\right) \quad (3.37)$$

Fonksiyon $\psi(t)$, dönüşümün ana-dalgacıdır ve denklem 3.36' yı sağlar. Herhangi bir fonksiyonunun SDD daima ana-dalgacığa göre gerçekleştirilir. $f(t)$ fonksiyonunun $\psi_1(t)$ ' ye bağlı dönüşümü ile aynı fonksiyonunun $\psi_2(t)$ ' ye bağlı dönüşüm sonuçları farklıdır. Basit olması açısından biz a gerçekte değerli pozitif alarak mutlak değerini alma zorunluluğunu ortadan kaldırırız.

Bir çok SDD materyalinde kullanılan dalgacıklar; dikey, diyatik fonksiyonlar ana-dalgacık olarak seçilmiştir. Bu dönüşüm sıklıkla a ve b içinde diyatik olarak ayrıştırılırken, zaman t sabit kalır. Bu ayrıştırma, $a = a_0^j$ ve $b = kb_0a_0^j$ $j, k \in \mathbb{Z}, a_0 > 1$ seçerek gerçekleştirilir. Ana-dalgacık $\psi(t)$, j ve k ile Eşitlik 3.38' de ifade edildiği gibi karakterize edilir (Fomitchev, 1994).

$$\psi_{j,k}(t) = \left(a_0^{-j/2} \right) \psi(a_0^{-j}t - k b_0) \quad (3.38)$$

$\psi(t)$ fonksiyonu ve a_0 , ve b_0 parametreleri uygun seçilerek $L^2(\mathbb{R})$ ' de $\psi_{j,k}$ 'nin normal-dikey taban oluşturması sağlanır. Bir çok uygulamada $a_0 = 2, b_0 = 1$ seçilerek Eşitlik 3.39' da verilen ifade tekrar elde edilir.

$$\psi_{j,k}(t) = \left(2^{-j/2} \right) \psi(2^{-j}t - k) \quad (3.39)$$

Eğer çok iyi ölçek çözünürlüğe gereksinim duyulursa, her bir ölçeğin alt ölçeklere bölünerek ele alınması ile çatılama anlamına gelen bir teknik kullanılır. Bu işlem ile işaret her bir sekizliye karşılık gelen M çatıya ayrılır. Bu durumda, ölçek eksenini her bir sekizliye karşılık gelen M ilave ölçek değerlerine bölünür. Bu işlem $a = 2^j$ 'nin $a = 2^{(j+m)/M}$ ile değiştirilmesi ile gerçekleşir ve denklem 3.40' da verilen eşitlik elde edilir. Burada m çatı olarak ifade edilir ve $m = 0, 1, \dots, M-1$ değerlerini alır..

$$\psi_{j,k}(t) = \left(2^{-((j+m)/M)/2} \right) \psi(2^{-(j+m)/M}(t - k2^j)) \quad (3.40)$$

Ana dalgacık fonksiyonun seçimi ayrı bir önem arz etmekte olup halen özel bir araştırma konusudur (Lewalle, 1995). Çünkü seçilen ana dalgacık fonksiyonu ve bundan öteleme/ölçekleme ile türetilen dalgacık fonksiyonlarının zaman ve frekans özellikleri yapılacak olan analizin sonucuna ağırlıklı olarak etki etmektedir. Bu noktada öteleme ve ölçeklemeye karşılık gelen zaman frekans büyüklüklerinden ayrıca bunların sınırlarından bahsetmek gerekmektedir.

Sürekli Dalgacık fonksiyonu $\psi(t)$ ve bunun Fourier dönüşümü $\psi(\omega)$ aşağıda tanımlı $\bar{x}$, $\bar{\omega}$ sonlu merkezlere ve benzer şekilde tanımlanacak $\Delta x, \Delta \omega$ sonlu açıklıklara sahip olsunlar.

$$\bar{x} = \frac{1}{\|\psi\|^2} \int_{-\infty}^{+\infty} x |\psi(x)|^2 dx \quad (3.41)$$

$$\Delta x^2 = \frac{1}{\|\psi\|^2} \int_{-\infty}^{+\infty} (x - \bar{x})^2 |\psi(x)|^2 dx \quad (3.42)$$

$\psi(t)_{a,b}$ ile yapılan a, b parametrelili sürekli dalgacık dönüşümü; f fonksiyonundan $[b + a\bar{x} - a\Delta x, b + a\bar{x} + a\Delta x]$ zaman aralığında ve $[(\bar{\omega} - \Delta\omega)/a, (\bar{\omega} + \Delta\omega)/a]$ frekans aralığından bilgi toplar. Bu her iki aralık için genişliği, yüksekliği ve pozisyonu a ve b parametreleri tarafından belirlenen zaman-frekans penceresini tanımlar. Pencerenin alanı sabittir ve $4\Delta x \Delta\omega$ olarak verilir. Heisenberg belirsizlik ilkesine göre bu alan 2' den büyük olmalıdır. Başka bir deyişle $\Delta x \Delta\omega > 1/2$ olmalıdır. Bu zaman-frekans pencerelerine Heisenberg kutuları adı verilir (Jawert ve Ark., 1992). İşte seçilen ana dalgacık ve a,b parametreleri ile yapılan dönüşüm sadece yukarıda verilen zaman aralığında ve frekans bandındaki sinyal bileşeni ile ilgili bilgiyi bize sunacaktır. Bu da sinyalin farklı ölçekler için bileşenlerine ayrıştırılmasıyla eşdeğerdir.

Dalgacık fonksiyonu terimi genellikle dikey (ortogonal) ve dikey olmayan (nonortogonal) dalgacıkları kapsar. Temel dalgacık terimi ise sadece dikey fonksiyonların kümesini kapsar. Dikey Temel dalgacıkların kullanımı ayrık dalgacık dönüşümü (ADD) kullanımını ifade ederken dikey olmayan dalgacık fonksiyonu hem ayrık hem de SDD' nün kullanılabilirliğini ifade eder (Farge, 1992; Torrence ve ark., 1997' den).

Kompleks değer içeren bir dalgacık fonksiyonu, sinyalin genliği ve fazı hakkında bilgi sağlar ve salınım davranışlarını yakalamakta daha uygundur. Sadece gerçek değer içeren bir dalgacık fonksiyonu ise sadece bir tek bileşen üretir, süreksizlik ve sıçramalar tespitinde kullanılabilir. Yaygın kullanılan temel dikey olmayan dalgacık fonksiyonlarına kompleks değerli olan Morlet ve Paul, gerçek değerli olan ve Gauss fonksiyonu türevi olan Meksika Şapkası fonksiyonları verilebilir. Temel dikey dalgacık fonksiyonlarına ise Haar ve Daubechies fonksiyonları örnek verilebilir (Torrence ve ark., 1997).

Dalgacık fonksiyonu seçildikten sonra dönüşümde kullanılacak s ölçeklerinin ne şekilde belirleneceği oldukça önemlidir. Dikey dalgacıklar için tüm ölçekler ayrık olmak zorundadır. Dikey olmayan dalgacıklarda ise daha detaylı analiz oluşturmak için ölçekler istenildiği gibi seçilebilir (Torrence ve ark., 1997).

Kullanılacak ölçek aşağıdaki Eşitlik 3.43' deki formda ve yukarıda bahsedilen çatılama yöntemine benzer olarak ikinin kesirli kuvvetleri şeklinde oluşturulabilir:

$$s_j = s_0 2^{j\delta_j}, \quad j = 0,1,\dots,J \quad J = \delta_j^{-1} \log_2\left(\frac{N\delta_t}{s_0}\right) \quad (3.43)$$

s_0 en küçük çözümlenebilir ölçeği ve J en büyük ölçeği belirler. δ_j nin küçük değerleri daha iyi çözünürlük sağlar ancak bu da dalgacık fonksiyonun frekans uzayındaki genişliğine bağlıdır. s_0 yaklaşık eşdeğer Fourier periyodu $2\delta_t$ ($2\delta_t$ bir örnekleme zamanı) seçilmelidir.

Sadece j_1 - j_2 ölçekleriyle elde edilen sinyal alt kümelerinin toplamı dalgacık dönüşümünün filtreleme etkisini de sunar (Torrence ve ark., 1997).

Bu konunun başında tekrar dile getirdiğimiz ifadeyi bu sefer aşağıdaki Eşitlik 3.44 ve 3.45 ile biraz genişletebiliriz:

$$f(x) = \sum_{j,l} D_{j,l} \psi_{j,l}(x) \quad (3.44)$$

$$D_{j,l} = \langle f(x), \psi_{j,l}(x) \rangle \quad (3.45)$$

bu da sürekli dalgacık dönüşümünün ayrık ters dönüşüm ifadesidir. $D_{j,l}$ j . Ölçek ve l . ötelemesi için dalgacık analiz sabitleridir. (Jawert ve ark., 1992). Sezgisel olarak $D_{j,l}$ sabitleri sinyal ile $\psi_{j,l}(x)$ dalgacığı arasındaki benzerliğin iyilik derecesinin bir ölçüsüdür (Miner, 1998).


$D_{j,k}$ dalgacık sabitleri olmak üzere sürekli zaman ayrık dalgacık dönüşümü (DWT)

$$D_{j,k} = \langle f, \psi_{j,k} \rangle = 2^{-j/2} \int_{-\infty}^{+\infty} f(x) \psi(2^{-j} - k) dx \quad (3.46)$$

Bu dalgacık sabitleri aynı zamanda sinyalin yüksek frekans bilgisini de verdikleri için detay sabitleri adını da alırlar. (Miner, 1998).

Bir sonraki konuda da görüleceği gibi ana dalgacık temel fonksiyonu öncelikle bir ölçek fonksiyonundan elde edilmektedir.

Eğer analiz ölçekleme fonksiyonu ve dalgacıkların bileşimi kullanarak yapılıyorsa ki genel olarak bu tip analize çok çözünürlüklü analiz (multiresolution) adı verilir, ölçekleme fonksiyonu (alçak geçiren bir spektruma sahiptir) spektrumun ölçeğe ait bölgesinin tamamını, dalgacıklar ise bu bölgede geri kalan detaylarını verir. Daha küçük ölçek daha fazla detay demektir (Valens, 1999). Bu işlem aşağıdaki Şekil 3.8' de temsil edilmektedir.



Şekil 3.8. Ölçekleme ve Dalgacık fonksiyonlarının spektrumları.

Dalgacık sabitlerini veren dalgacık fonksiyonunda olduğu gibi ölçekleme fonksiyonu da yaklaşık sabitlerini verir:

$$A_{j,k} = \langle f, \phi_{j,k} \rangle = 2^{-j/2} \int_{-\infty}^{+\infty} f(x) \phi(2^{-j} - k) dx \quad (3.47)$$

$A_{j,k}$ yaklaşık sabitleri ve $\phi(x)$ ölçekleme fonksiyonudur.

3.1.4.3 Dalgacığın Bir Ölçekleme Fonksiyonundan Elde Edilmesi

Bir $f(x)$ sinyalinin analizinde kullanılan en temel yaklaşım bu sinyalin basit yapı blokları veya temel fonksiyonların ağırlıklı toplamlarıyla ifade edilmesi hali olduğunu tekrar belirtelim:

$$f(x) = \sum_i c_i \psi_i(x) \quad (3.48)$$

Belki de en basit temel fonksiyon $\delta_i(x)$ fonksiyonudur. $\delta_i(x) = \begin{cases} 1, i = x, \\ 0, i \neq x. \end{cases}$

ψ ana dalgacığından öteleme ve ölçeklemeyle elde edilen dalgacık:

$$\psi_{j,k}(x) = 2^{j/2} \psi(2^j x - k) \text{ ile verilebildiğini daha önce belirtilmişti.}$$

Dalgacık yapısı aşağıdaki dilation/refinement yinelemeli fark denkleminin çözümünden gelir:

$$\phi(x) = \sum_{k=0}^{M-1} c_k \phi(2x - k) \quad (3.49)$$

M keyfi seçilebilen ve dalgacık derecesini belirten ayrıca sıfırdan farklı c_k sabitlerinin sayısıdır. Bu durumda c_k sabitleri keyfi değil $\phi(x)$ ölçekleme fonksiyona göre değişir.

Gerekli şartları sağlayan bir dalgacık fonksiyonu, c_k sabitleri ve ölçekleme fonksiyonu kullanılarak aşağıdaki eşitlik ile elde edilir:

$$\psi(x) = \sum_{k=2-M}^1 (-1)^k c_{1-k} \phi(2x - k) \quad (3.50)$$

Dolayısıyla asıl dalgacığı elde etmek için yukarıdaki 3.50 eşitliğinin çözülüp c_k dalgacık sabitlerinin bulunması gerekmektedir. Bu işlem ise ölçekleme fonksiyonun aşağıdaki şartlara zorlanmasıyla gerçekleştirilir (Fomitchev, 1994):

$$\int \phi(x) dx = 1 \quad (3.51)$$

$$\int \phi(x) \phi(x - k) dx = 1 \quad (3.52)$$

Son iki ifadeyle aşağıdaki eşitlikler türetilebilir (Fomitchev, 1994):

$$\sum_{k=0}^{M-1} c_k = 2 \quad (3.53)$$

$$\sum_{k=0}^{M-1} (-1)^k c_{1-k} c_{k-2m} = 0 \quad (3.54)$$

Ölçekleme fonksiyonu için değerlendirme bir $\phi_0(x)$ başlangıç fonksiyonu ile başlar ve aşağıdaki eşitlik tüm dyatic $x=k/2^j$ noktalarda istenilen ölçekleme fonksiyonuna yakınsayana kadar yinelenir:

$$\phi_j(x) = \sum_{k=0}^{M-1} c_k \phi_{j-1}(2x - k), \quad j = 1, 2, \dots \quad (3.55)$$

Tüm dalgacıklar içinde en eski ve basiti $\phi_H(x)$ Haar dalgacıdır.

Ingrid Daubechies 1987' de günümüzdeki bir çok dalgacık uygulamasına temel teşkil edecek normal-dikey bir temel dalgacık tasarlamıştır. Ingrid Daubechies 4 ve 6. dereceden dalgacık tasarımı için $\phi_0(x)=\phi_H(x)$ kullanmıştır.

İlgili dalgacık katsayıları için Çizelge 3.1'de ve ölçekleme fonksiyonları Şekil 3.9' da verilmiştir.

3.1.4.4 Dalgacık Analizi ile Gürültüden Arındırma

Dalgacık dönüşümü ile gürültüden arındırma işlemi neredeyse birbirlerinin aynı işlemleri kapsar. Bu tür işlemler dört adımda gerçekleştirilir:

1) Dalgacık temel fonksiyonu ile sinyal ayrıştırma: Dalgacık detay sabitlerinin (veya Ölçek yaklaşıklık) sabitlerinin bulunması.

2) Her ayrıştırma derecesi için gürültü eşiğinin seçimi.

3) Detay sabitlerinin eşik süzgeçlenmesi


4) Sinyalin son güncellenmiş detay sabitleri kullanılarak yeniden oluşturulması yani Ters Dalgacık Dönüşümünün uygulanması.

Genel olarak dalgacığın ve ayrıştırma derinliğinin seçimi kesinlikle sinyal özelliklerine bağlıdır. Bu durumda yumuşak (smooth) dalgacıklar sinyalin daha yumuşak yaklaşımını oluşturur tersi ise yani kısa dalgacıklar sıçramaları daha iyi takip ederler (Kiselev, 2001).

Detay sabitlerinin eşik süzgeçlenmesi işlemi belirlenen bir aralık için bu aralığa dahil olan detay yani dalgacık sabitlerinin sıfırlanması ile gerçekleştirilir. Diğer bir ifadeyle dalgacık sabitlerinin eşiklenmesi işlemi gürültü veya benzer şekilde değerlendirilebilecek önemsiz detay dalgacık sabitlerinin uzaklaştırılması esasına dayanır.

Çizelge 3.1. Haar 2, Daubechies 4 ve 6 fonksiyonları için dalgacık katsayıları (Fomitchev, 1994)

Wavelet	C0	C1	C2	C3	C4	C5
Haar	1	1				
Daubechies-4	$0.25(1+\sqrt{3})$	$0.25(3+\sqrt{3})$	$0.25(3-\sqrt{3})$	$0.25(1-\sqrt{3})$		
Daubechies-6	0.332671	0.806891	0.459877	-0.135011	-0.085441	0.035226



Şekil 3.9. Haar ve Daubechies 4 temel dalgacık fonksiyonları. (Fomitchev, 1994)

Sıkı Eşikleme: Mutlak değeri verilen λ değerinden daha küçük olan dalgacık sabitleri sıfırlanır şöyle ki:

$$d_{j,k} = \begin{cases} 0, & d_{j,k} < \lambda, \\ d_{j,k}, & d_{j,k} \geq \lambda. \end{cases} \quad (3.56)$$

Yumuşak Eşikleme: Tüm dalgacık sabitlerini orijine doğru çeker şöyle ki:


$$d_{j,k} = \text{sign}(d_{j,k})(|d_{j,k}| - \lambda)_+ \quad (3.57)$$

Düzeyle (Quantile) Eşikleme: En küçük dalgacık sabitinin belirli bir oranı ile sıfırlanır. Örneğin en küçük dalgacık sabitinin %30' unun sıfırlanması gibi.

$$d_{j,k}^{quant} = \begin{cases} 0, & d_{j,k} < p, \\ d_{j,k}, & d_{j,k} \geq p. \end{cases} \quad (3.58)$$

Evrensel Eşikleme: Evrensel eşik λ Donoho ve Jhonstone tarafından önerilmiştir. N adet örneğe sahip bir y_i data kümesi için, σ standart sapma ölçüsünde gürültünün miktarı olmak üzere:

$\lambda = \sigma \sqrt{\frac{2 \log(n)}{n}}$ evrensel eşik λ yukarıdaki eşikleme metotlarında da kullanılabilir.



Şekil 3.10. Sıkı ve yumuşak eşikleme $\lambda=1$ (Vidakovic ve ark., 1993)

3.1.4.5 Dalgacık Analizi ile Veri Sıkıştırma

Sinyal sıkıştırma temel prensip olarak aritmetik veya istatistik değerler açısından fazlalık olarak görülen bilgilerin uzaklaştırılarak sinyalin bilgi yükü yoğunluğunun artırılmasıdır.

Dalgacık kullanarak sıkıştırma işlemi ile dalgacık kullanarak gürültüden arındırma birbirlerine çok benzerdirler. Sadece uzaklaştırılacak detay veya yaklaşıklık sabitlerinin ölçüsü biraz farklıdır.


3.1.5. Yapay Sinir Ağları

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almaksızın otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgi işleme modelleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadırlar. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Literatürde 100'den fazla yapay sinir ağı modeli vardır.

3.1.5.1. Biyolojik Sinir Sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu üç katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da dış ortamlardan algıladıkları

uyarıları, beyine bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beynin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 3.11’de bir sinir sisteminin blok diyagramı gösterilmiştir.



Şekil 3.11. Biyolojik Sinir Sisteminin Blok Gösterimi (Zurada,1990)

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sistemi karakteristiklerini taşır.

Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron). İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapıya sahip olduğu anlaşılır. Diğer bir taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duygusal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olamayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir.

Yapay sinir ağları, insan beyninin çalışma prensibi örnek alınarak geliştirmeye çalışılmıştır ve aralarında yapısal benzerlikler bulunmaktadır. Bu benzerlikler Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Sinir Sistemi ile YSA’nın Benzerlikleri

Sinir Sistemi	YSA Sistemi
Neuron	İşlem elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar


3.1.5.2. Biyolojik Sinir

Bir insan beyni, her biri yaklaşık olarak diğer sinirlerle 10^4 bağlantıya sahip olan değişik yapı ve görevde yaklaşık olarak 10^{11} biyolojik sinir içermektedir. Buna göre toplam olarak 10^{15} birbirleriyle olan bağlantıdan söz edilebilir. Her bir nöronun aksonu ayrıştırılmıştır ve bir sinaps olarak adlandırılan bir kavşak vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Her bir nöronun diğer nöronlarla bağlantıya sahip olduğu bu yapı, Biyolojik Sinir Ağı olarak adlandırılmaktadır. Bu çok geniş bir hesaplama gücü ve hafıza sağlamaktadır. Bir biyolojik nöron (sinir hücresi) temel olarak dört ana bölüme ayrılabilir.

Girişler (Dendritler): Dendritler, kısa lifler olup diğer sinirlerden gelen bilgileri alan yapılardır.


Soma (Hücre Gövdesi): Soma, gelen bilgileri toparlayan, birleştiren ve biçimini değiştirerek diğer sinirlere gönderen yapıdır.

Çıkış (Aksonlar): Aksonlar, uzun lifler olup bilgiyi diğer sinirlere transfer etmekte kullanılan yapılardır.



Şekil 3.12. Biyolojik Nöron

Sinapslar: Akson ile diğer bir nöronun dendritinin birleşme noktası sinaps olarak adlandırılır. Tipik bir nöron 10^3 - 10^5 sinapsa sahiptir. Gerçekte akson ve akson arasında veya bir dendrit ile diğerleri arasında sinaptik birleşim tipleri de bulunmaktadır. Bununla birlikte basit nöron modelde bunlar görmezlikten gelinmektedir. Kavşak uçlarındaki iletim doğal olarak kimyasaldır ve işaret miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Şekil 3.18’de biyolojik sinir hücresi ve bileşenleri gösterilmiştir.



Şekil 3.13. Biyolojik Sinir Hücresi ve Bileşenleri

Soma (gövde), dendritler yoluyla alınan sinyallerin ağırlıklarının toplamında rol almaktadır. Eğer ağırlıkların toplamı aslında olan eşik değerinden daha büyük ise toplam sinyal, doğrusal olmayan somatik aktivasyon dönüşümüyle sinirsel çıkış verecek şekilde sinir darbeleri olarak değiştirilir. Bu çoğunlukla somanın içinde ve çevresinde bulunan sodyum ve potasyum iyonları ile sağlanır. Doğrusal olmayan aktivasyon dönüşümü, toplam sinyale karşılık gelen bir doğrusal olmayan sınırlandırılmış eşleme sağlar. Sinir darbeleri sonraki işlemler için aksonlar yolu ile diğer sinirlere iletilir. Darbelerin iletim hızı aksonun uzunluğu ve aksonun büyüklüğü gibi birçok faktöre bağlıdır. Özet olarak basit bir nöron; dendritler yoluyla sinyalleri alan ve bunları somasında işleyen buna karşı düşen cevapları çıkış olarak aksonlar yolu ile veren bir basit işlem elemanı olarak ifade edilebilir. Eğer bir nöron darbe dizileriyle uyarılıyorsa aktif olacaktır. YSA'lar insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmıştır. Bu benzerlikler Çizelge 3.2'de kısaca anlatılmaktadır.

3.1.5.3. Statik ve Dinamik Yapay Sinir Modelleri

YSA, insan beynin kaba bir modeline dayanmaktadır. Hesaplama ünitesi olarak bir çok yapay sinir içermektedir. Bunlar birbirlerine kuvvetli büyük bir paralel yapıda uyarlamalı ağırlıklarla bağlanmaktadır. Yapay sinirler, aslında belirlenmiş veri kümelerini öğrenebilen tek ve bağımsız yapılardır. Bir başka deyişle bunlar uyarlamalı fonksiyon hesaplayıcılarıdır. İnsan beyninin kaba bir biyolojik sinir ağı taklididirler. Donanım veya yazılım olarak uygulanabilirler.


Bir insan beyni aşırı geniş sayıda farklı işlemler yerine getirmektedir. Bu özellikleri taklit etmeye uğraşan birçok sayıda YSA bulunmaktadır. YSA'nın temel elemanı olan tek hesaplama sinirinin insan beynine olan benzerliği esasında; çok-girişli, genellikle doğrusal olmayan işlem elemanına ve birbirleriyle bağıntıyı sağlayan ağırlıklara sahip olmasından kaynaklanmaktadır. YSA, biyolojik sinir aktivitelerini taklit etmeye çalışmaktadır. Böyle olmasına karşın bir insan beynin sinirinin biyolojik sinir işlemlerinin doğru bir biçimde temsil edilmesi aşırı derecede güçtür. Fakat iyi bir şekilde temsil eden basit yapay sinir

modeli elde etmek mümkündür. Bu, donanım, yazılım veya hibrit teknikler kullanılarak uygulanabilir. Statik Yapay Sinir modeli olarak adlandırılan modelin dört ana bölümü mevcuttur.

1. Giriş veya girişler
2. Ağırlıklar
3. Dinamik olmayan fonksiyon (aktivasyon fonksiyonu), bir çok uygulamada nonlinear olmakta fakat lineer fonksiyonları da kullanabilen YSA modelleri bulunmaktadır.
4. Çıkış veya çıkışlar

Bu sinir modeli literatürde perceptron sinir modeli olarak geçmektedir. Fakat tam anlamıyla konuşulan ve göze alınan orijinal tanımlaması Rosenblatt (1958) tarafından yapılmıştır. Eğer aktivasyon fonksiyonu keskin sınırlayıcı gibi özel bir aktivasyon fonksiyon formunda ise sinir modeli perceptron olarak anılır.

Görüldüğü üzere statik yapay sinir ağı modeli dinamik eleman içermemektedir. Bununla birlikte, dinamik yapay sinir ağı modeli olarak adlandırılan modelde, yukarıda açıklanan dört ana bölüme ek olarak aktivasyon fonksiyon bloğunu takiben bir dinamik blok bulunmaktadır. Bu dinamik blok basit bir gecikme elemanı ile temsil edilmektedir.



Şekil 3.14. Temel Statik Yapay Nöron (Vas,1999)

Basit statik YSA modelinde soma toplama işlemi ve aktivasyon fonksiyonunu temsil etmektedir. Şekil 3.14'te birçok sinir içeren YSA'nın i . siniri olan tek bir statik yapay sinirin (YS) basit modeli görülmektedir. Şekil 3.14'te ayrıca tartışılan biyolojik terminolojiye karşı gelen terimlerde gösterilmektedir.

En basit sinir modelinde bir sinir olmasına rağmen genelde n tane giriş bulunmaktadır. Şekilde $x_1(t), x_2(t), x_3(t), \dots, x_n(t)$, olarak gösterilmektedir. Bunlar n -boyutlu giriş vektörünün elemanları olarak düşünülebilir.

$$x(t) = [x_1(t), x_2(t), x_3(t), \dots, x_n(t)]^T. \quad (3.59)$$

Sinir çıkışı sayıl bir niceliktir $y_i(t)$. Sinir toplama ağırlık toplamalarının yapıldığı toplama operatörü içermektedir. Toplama operatörünün çıkışı ağ değeri olarak (net değeri) alınır

$$S_i(t) = \sum_{j=1}^n w_{ij} x_j(t) + b_i \quad (3.60)$$

şeklinde gösterilir. Burada w_{ij} i . sinir j . giriş arasındaki bağlantı ağırlıklarını, b_i de sapma veya aktivasyon fonksiyonun eşik değeri olarak adlandırılan sabit değeri göstermektedir. Ağırlıklarla girişler çarpılarak girişler bağlantı ağırlıklarından iletilirler. Ağırlık toplamada toplanırlar ve net değeri (S_i) bunlara sapmanın eklenmesi ile elde edilir. Son olarak sinirin çıkışı sinir aktivasyon fonksiyonu kullanılarak elde edilir.

Ağırlıklar, sayısal veri taşıyan tek yönlü haberleşme kanallarıdır. Birçok YSA'nın eğitim veya öğrenme aşamalarında kullanılmak üzere ağırlık değerleri sağlanır. Eğitim veya öğrenme aşamalarında sunulan giriş eğitim verileri temelinde sistem çıkışının doğru çıkışa hemen hemen uyması için ağırlıklar değiştirilir. Ağırlıkların değişimi yalnızca eğitim ve öğrenme aşamalarında mümkündür. Genelde hepsi farklı sabit değerler alırlar. Çoğunlukla ağırlıkların başlangıç değerleri rasgele seçilir ve pozitif veya negatif değer alabilirler.


Girişler; bir nöron girişinin dışsal ve içsel olmak üzere iki kaynağı vardır. İçsel girişler diğer nöronlardan gelen girişlerdir. Şekil 3.14'te görüldüğü üzere giriş olarak sapma girişi de ele alınmalıdır. Böylelikle toplam $n+1$ giriş bulunmaktadır. Eşik değeri $x_0 = 1$ ve b_i ağırlığına karşı düşen ağırlığın kullanılması ile oluşturulmaktadır. Sapmanın $\sum_{j=1}^n w_{ij} x_j(t)$ toplamına eklenmesi nöron aktivasyon fonksiyonunun kaymasına neden olur.

Aktivasyon Fonksiyonu; Şekil 3.14'te de görüldüğü üzere nöron dinamik olmayan bir aktivasyon fonksiyonu içermektedir. Bu fonksiyonun doğrusal olmaması durumunda biyolojik hücrenin doğrusal olmayan somatik transfer fonksiyonunun yerine geçmektedir. Doğrusal olmayan aktivasyon fonksiyonunun kullanılmasının sonucu bile nöron modeline doğrusal olmama özelliği kazandırmaktır. Bundan dolayı ağda, çıkışlar ve girişler arasında daha kuvvetli bir nonlineer ilişki sağlama özelliği elde edilir. Doğrusal olmayan bir fonksiyon kullanılmaması durumunda, yapay nöron doğrusal bir sistemi temsil eder. Bu tip yapay nöronlar doğrusal olmayan sistem eşlemede kullanılmaz ve doğrusal olmayan hesaplamaları yerine getiremez. Doğrusal aktivasyon fonksiyonları gürültüyü bastıramamaktadır. Bu sebepten ağ sağlam bir doğruluk yapısında değildir. Şu da belirtilmelidir ki doğrusal aktivasyon fonksiyonu içeren nöron modeline sahip ağlar da kullanılmaktadır. Fakat bunlar sadece doğrusal sistem modellemesinde kullanılır. Doğrusal aktivasyon fonksiyonlu sinir modeli literatürde Widrow-Hoff modeli olarak bahsedilmektedir.

YSA'nda kullanılan aktivasyon fonksiyonlarının (matematiksel fonksiyonlar) çeşitli türleri bulunmaktadır. Bununla birlikte aktivasyon fonksiyonu seçiminde doğrusal olmama

ve basitlik iki anahtar faktördür. Ayrıca bazı eğitim tekniklerinde aktivasyon fonksiyonunun birinci dereceden türevi gerekmektedir. Eğer YSA'da bu teknikler kullanılacaksa aktivasyon fonksiyonu türevi alınabilir olmak zorundadır. Kronolojik olarak ilk önce aktivasyon fonksiyonları olarak keskin sınırlayıcı (hard-limit) fonksiyonu kullanılmıştır. Bunun amacı ayırık nöronlarda, ON ve OFF olarak iki bölge meydana getirmektir. Daha sonraları, sürekli tip nöronlarda asimptotik aktivasyon fonksiyonları kullanıldı. Keskin sınırlayıcı aktivasyon fonksiyonlu nöron modelleri tamamında olmamakla birlikte kesinlikle sınıflandırma amaçlı olarak kullanılmaktadır. Burada giriş uzayı iki bölgeyle ayrılmıştır. Çıkış vektörü girişlere bağlı olarak 0 yada 1 dir. Yukarıda bahsedilen keskin sınırlayıcı aktivasyon fonksiyonu kullanan sinir modeli perceptron (algılayıcı) olarak adlandırılmaktadır. Aktivasyon fonksiyonları çeşitli türde sınıflandırılabilir.

Bu sınıflandırma, yumuşak sınırlayıcı ve keskin sınırlayıcı olarak ayırt edilebilir. Yumuşak sınırlayıcı fonksiyonları bazı ağırlık uyarlamalarında gerekmektedir. Keskin sınırlayıcı fonksiyonları ayırık algoritmalarda kullanılır. Örnek olarak tek kutuplu sigmoid fonksiyon ve doğrusal aktivasyon fonksiyonları Şekil 3.15'te görülmektedir.



Şekil 3.15. YSA'da En Çok Tercih Edilen Aktivasyon Fonksiyonları a) Tek Kutuplu Sigmoid b) Doğrusal c) Hiperbolik Tanjant d) Keskin Sınırlayıcı

Darbe Tipi ve Adım Tipi Fonksiyonlar; bu sınıflandırmada aktivasyon fonksiyonları sıfır yakınındaki girişler için anlamlı çıkış değerine sahip olunmasına göre ayırt edilir. Darbe tipi fonksiyonlar, adım tipi fonksiyonların türevi alınarak yaratılabilir.

3.1.5.4. Yapay Sinir Ağları ile Hesaplamanın Özellikleri

YSA'nın hesaplama özelliklerini, paralel dağılmış yapısından, öğrenilme ve genelleme yapma yeteneğinden aldığı söylenebilir. Bu özellikleri ile YSA karmaşık ve çözümlemesi güç problemleri çözebilme yeteneğine sahiptir. Nesne tanıma, işaret işleme, sistem tanımlama ve denetimi gibi birçok alanda YSA başarılı olmuşlardır.

i. Doğrusal Olmaması

YSA'nın benzetildiği sinir ağının temeli olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesi ile meydana gelen ağ da bu özellik yayılmış olarak görülmektedir. Aynı şekilde YSA'nda aktivasyon fonksiyonunun doğrusal olmaması ile yapay sinir doğrusal olmama özelliği kazanır ve bu YSA'nın tamamında yayılmış olarak görülür. Bu özellik, YSA doğrusal olmayan problemlere çözüm getirebilmektedir.

ii. Öğrenme

İlgili problemdeki giriş-çıkış ilişkisini tanımlayacak optimum ağırlıkların bulunmasıdır.

iii. Genelleme

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Veri YSA'ya eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir.

iv. Uygulanabilirlik

YSA ağırlıkları uygulanan probleme göre değiştirilir. Belirli bir problemi çözmek için eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda eğitime devam edilir. Bu özelliği ile YSA, uyarlamalı örüntü tanıma, işaret işleme, sistem tanımlama ve denetimi gibi alanlarda etkin olarak kullanılır.

v. Dağıtılmış Birleşik Hafıza

Bilgiyi depolayabilmeleridir. Nöral hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları, nöral ağı hafıza birimleridir. Bu ağırlıklar ağı o andaki sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu bilgiyi verir.

vi. Hata Toleransı

YSA, çok sayıda işlemci elemanlarının kullanıldığı paralel dağılmış bir yapıya sahiptir. Ağı bilgisi ağıdaki tüm ağırlıklar üzerine dağıtılmıştır. Giriş veri kümesinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yolları daha fazladır.

vii. Paralel İşlem Yapma

YSA paralel yapısı nedeniyle büyük ölçekli tümleşik devre (VSLI) teknolojisi ile gerçekleştirilebilirler. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini ve örüntü tanıma, işaret işleme, sistem tanımlama ve denetimi gibi gerçek zaman uygulamalarında kullanımını artırır.

3.1.5.5. Yapay Sinir Ağlarının Sınıflandırılması


YSA, genel olarak birbirleri ile bağlantılı nöronlardan oluşurlar. Her bir nöron arasındaki bağlantıların yapısı ağı yapısını belirler. İstenilene ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Buna göre YSA, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilirler.

a) YSA'nın Yapılarına Göre Sınıflandırılması

YSA, yapılarına göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olarak ikiye ayrılırlar.

i. İleri Beslemeli Ağlar

Nöronlar, genellikle katmanlara ayrılmış olmaktadır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Nöronlar bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 3.21'de ileri beslemeli YSA için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı perceptron (Multi-Layer Perceptron – MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir.




Şekil 3.16. İleri Beslemeli YSA için Blok Diyagram

ii. Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece girişler hem ileri yönde hem geri yönde aktarılmış olur. Şekil 3.17'de bir geri beslemeli ağ blok diyagramı görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu ağlarda bir andaki çıkış, hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı özellikle önceden tahmin uygulamaları için uygundurlar. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde

oldukça başarı sağlamışlardır. Geri beslemeli YSA'na örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağırları verilebilir.




Şekil 3.17. Geri Beslemeli YSA için Blok Diyagram

b) YSA'nın Öğrenme Algoritmalarına Göre Sınıflandırılmaları

Öğrenme, gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. Bir takım metot ve kurallara bağlı olarak gözlem ve eğitim tabanında ağırlıkların değişimi sağlanmalıdır. Burada genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir.

i. Danışmanlı Öğrenme (Supervised Learning)


YSA'na örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıkış arasındaki fark hata olarak ele alınır. Bu hataya göre nöronlar arasındaki bağlantıların ağırlıkları en uygun çıkışı elde etmek için düzenlenir. Bu sebeple danışmanlı öğrenme algoritmasında bir "öğretmene" veya "danışmana" ihtiyaç duyulmaktadır. Şekil 3.18'de danışmanlı öğrenmenin blok diyagramı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri yayılım (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.



Şekil 3.18. Danışmanlı Öğrenme Yapısı

ii. Danışmansız Öğrenme (Unsupervised Learning)


Giriş verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında istenen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri YSA'na verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren örüntü oluşturmak üzere ayarlar. Şekil 3.19'da danışmansız öğrenme algoritma yapısının blok diyagramı gösterilmektedir. Grosberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralları danışmansız öğrenmeye örnek olarak verilebilir.



Şekil 3.19. Danışmansız Öğrenme Yapısı

iii. Takviyeli Öğrenme (Reinforcement Learning)

Denetimsiz öğrenme algoritması, istenen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir "öğretmen" yerine, burada YSA'na bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Şekil 3.20'de takviyeli öğrenme algoritması yapısının blok diyagramı verilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya genetik algoritmalar takviyeli öğrenmeye örnek olarak verilebilir.




Şekil 3.20. Takviyeli Öğrenme Yapısı

3.1.5.6. Tek Katmanlı ve Çok Katmanlı İleri beslemeli Yapay Sinir Ağları

a) Tek Katmanlı YSA'lar

Nöronlar, yapay sinir ağlarının yapı taşlarıdır. Tek katmanlı ileri beslemeli YSA olarak adlandırılan ağ yapısı en azından yukarıda söz edilen tipte bir nörondan oluşmaktadır. Şekil 3.21'de genel yapısı gösterilmiştir. Burada n tane giriş, giriş vektörünü $x = [x_1, x_2, \dots, x_n]$ oluşturmaktadır. YSA'nın tek katmanında k tane nöron bulunmaktadır.

Genelde nöron sayısı ile giriş sayısı birbirine eşit değildir ($k \neq n$). Girişler her bir nöronun girişine uygun ağırlıklarla bağlanır. Her bir nöron, kendi girişleri ve sapmanın ağırlıklarını toplar ve bu toplamı kendi aktivasyon fonksiyonuna uygular. Bunu takiben tek katmanlı olarak tanımlanan YSA'nın k tane çıkışı, çıkış vektörünü $y1 = [y1_1, y1_2, \dots, y1_k]$ oluşturur.



Şekil 3.21. Tek Katmanlı YSA

Çıkış vektörünün ifadesi

$$Y1 = F1[W1x + bB1] \quad (3.61)$$

olarak yazılabilir. Bu eşitlikde; $F1$, bu tek katmanın k elemanlı köşegen aktivasyon matrisidir ve bu katmanın net girişlerine bağlıdır.

$$F1(S1) = \text{diag}[f1(S_1), f1(S_2), \dots, f1(S_k)] \quad (3.62)$$

Burada k düğümlerinin her birinin aktivasyon fonksiyonları eşit kabul edilmiştir.

$$f1_1 = f1_2 = \dots = f1_k = f_1$$

$S1$ net vektörü $S1 = [S_1, S_2, \dots, S_k]^T$ oluşturulur. $S_1, S_2, \dots, S_k$; sırasıyla $1, 2, \dots, k$. nöronlara karşılık gelir ve

$$S_i = \sum_{j=1}^n w_{ij} x_j(t) + b_i \quad (3.63)$$

olarak ifade edilir. Ayrıca $W1$ çıkış katmanının ağırlık matrisi, sinir ağına yapısına bağlı olarak, k satır n sütundan oluşmaktadır.

$$W1 = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{k1} & w_{k2} & \cdots & w_{kn} \end{bmatrix} \quad (3.64)$$


Genelde w_{ij} ; j . hedef düğüm ile i . kaynağın ağırlığını temsil etmektedir. $B1$ sapma vektörü tek katmanlı ağırlarda $b1_1, b1_2, \dots, b1_k$; sırasıyla çıkış katmanının 1., 2., ..., k . düğümlerinin sapmalarıdır.

$$B1 = [b1_1 \quad b1_2 \quad \cdots \quad b1_k]^T \quad (3.65)$$

Tek katmanlı YSA sadece sınırlı sayıda sistemlerde kullanılır. Tüm doğrusal olmayan fonksiyonları temsil edemezler. Tek katmanlı YSA'nda aktivasyon fonksiyonu olarak keskin-sınırlayıcı fonksiyonu kullanıldığı zaman tek katmanlı perceptron adlı model meydana gelmektedir. Bu model bazı sınıflandırma problemlerinde aktivasyon fonksiyonunun giriş uzayını iki bölgeye bölmeye ve çıkış uzayının giriş vektörüne bağlı olarak 1 ve 0 değerleri alması ile gerçekleşir. Tek katmanlı ağırlarda doğrusal aktivasyon fonksiyonu kullanıldığında doğrusal sınırlara sahip bir ağ oluşur. Bu sinirler, ADALINE sinirlerinden (Adaptive Linear Neurons) Widrow-Hoff sinirleri olarak adlandırılır. Bu nöronlardan meydana gelen ağda adaptif öğrenme kullanılıyorsa ADALINE ağ veya MADALINE ağ olarak adlandırılır. (Widrow, 1962; Widrow ve Sterns, 1985).

a) Çok Katmanlı Yapay Sinir Ağları


Çok sayıda katman içeren yapay sinir ağlarıdır. Çok katmanlı YSA'nda sinirler ayrı paralel katmanlara yerleştirilmişlerdir. Ağda ayrı katmanlara bağlantının sonucu olarak giriş ve çıkış arasındaki doğrusal olmayan eşlemenin daha karmaşık olması mümkündür. Bu özellik sınıflandırma ve hatırlama uygulamalarında değişkenler arasındaki nonlineer ilişkiyi göstermek için kullanılır. Şekil 3.22'de çok katmanlı YSA'ndan üç katmanlı bir yapay sinir ağı şeması verilmektedir.



Şekil 3.22. Çok Katmanlı YSA

İlk katman olan giriş katmanında hesaplama için nöronlar bulunmaz sadece birinci gizli katmandaki nöronları beslemek için girişler bulunur. Bu katmanı ikinci gizli katman ve diğer gizli katmanlar takip eder. En son olarak çıkış katmanı yer alır. Genel olarak giriş katmanı ile çıkış katmanı arasındaki katmanlar gizli katman olarak anılır. Aynı katmandaki düğümler arasında bir bağlantı bulunmamaktadır. Teorik olarak çok sayıda gizli katman bulunur. Fakat bu eğitilmiş ağı karmaşıklığını önemli derecede artırır. Bir veya iki gizli katmanlı ağlarda doğruluk, sağlamlık ve genelleştirme çoğu durumda sağlanmaktadır. Eğer tek gizli katman varsa gizli katmanda nonlinear aktivasyon fonksiyon, çıkış katmanında doğrusal aktivasyon fonksiyonu kullanılarak yeterli performans elde edilebilir. İleri beslemeli YSA’nda her nöron bitişikteki katmanın tüm nöronları ile bağlantılıdır ve diğer nöronlarla bağlantısı bulunmamaktadır. Katman içindeki bağlantılara izin verilmemektedir. Genelde farklı katmanların farklı nöron sayıları ve farklı ağırlıkları bulunmaktadır. Gizli katman sayısının ve saklı katman nöron sayılarının belirlenmesinde genel bir kural yoktur. Belirlenme işlemi yapılan eşlemenin kompleksliğine bağlıdır. Giriş sayılarının ve çıkış sayılarının belirlenmesi tabiki tamamen probleme özgüdür. Nöronların ve bağlantılarının sayıları sinir ağının doğru olarak saklayabildiği örüntü sayısına kadar sınırlıdır.

Radyal Tabanlı Fonksiyon Sinir Ağları: Bir radyal tabanlı fonksiyon (RTF) (Radial-Basis Function, RBF) sinir ağları nonlinear fonksiyon yaklaştırılmasında kullanılır (Moody ve Darken, 1988). Tam bağlantılı ileri beslemeli YSA’dır. Şekil 3.23’te bir giriş katmanı, bir gizli katman ve bir çıkış katmanı içeren üç katmanlı RTF ağı gösterilmiştir. Çıkış düğümleri gizli katmanda hesaplanan temel fonksiyonların lineer bir birleşimidir. Gizli katmandaki temel fonksiyonu girişlerin lokalize edilmiş cevaplarını üretir. Temel fonksiyonları gizli katmanın aktivasyon fonksiyonları olarak görülebilir. En çok Gaussian fonksiyonu temel fonksiyon olarak kullanılır. Şekil 3.23’te gizli katmanda N tane nöron bulunmaktadır. ($j = 1, 2, \dots, N$) Gaussian fonksiyonu kullanılırsa j . gizli düğümün değeri



Şekil 3.23. Üç Katmanlı RTF Ağı

$$\phi_j = \exp\left[-\|x - c_j\| / \sigma_j^2\right] \quad (3.66)$$

Burada x , giriş vektörü; c_j , j . Gaussian fonksiyonunun merkezidir. Eşitlik 3.66’da $\|x - c_j\|$ ifadesi x ve c_j vektörleri arasındaki Euclidean uzaklığı belirtmektedir. j . saklı düğümün aktivasyon seviyesi ϕ_j ’ye eşittir. k . düğümün çıkışı Eşitlik 3.67 ile verilir.

$$o_k = \sum_{j=1}^N w_{kj} \phi_j \quad (3.67)$$

Burada w_{kj} k . çıkış düğümü ile j . gizli katman düğümü arasındaki ağırlıktır.

Genelde, sigmoidal nöronların giriş uzayının büyük bir bölümünde çıkışlara sahip olması radyal temelli nöronlar giriş uzayının diğerine göre sadece daha küçük bölgelerinde cevap verirken radyal temelli ağlar sigmoidal aktivasyon fonksiyonlu ileri beslemeli YSA'ndan daha fazla gizli düğümlere sahip olma eğilimindedir. Bundandır ki; geniş giriş uzayı çok sayıda radial temelli saklı nöron gerektirmektedir. Bununla birlikte, verilen herhangi bir giriş için saklı ünitelerin sadece girişe yeteri kadar yakın küçük oranı uyarılacaktır ve aktivasyon üniteleri ile irtibatlı o ağırlıklar hesaplanacak ve eğitileceğinden dolayı ϕ_j 'nin yerleşimi hızlı öğrenmeye yol açabilir.

Çizelge 3.3. YSA ile RTF Ağlar Arasındaki Ana Farklar

RTF ağlarda sadece bir saklı katman bulunmaktadır.
RTF ağların çıkış katmanı her zaman doğrusaldır.
RTF ağda, saklı düğümde kullanılan aktivasyon fonksiyonunun argümenti bu düğümün merkezi ile giriş vektörü arasındaki öklidyen normudur. (Çok katmanlı ileri yönlü YSA'da bu giriş vektörü ile düğüme ait ağırlık vektörünün skaler çarpımıdır.)
RTF ağlarda saklı katmanın her düğümü her giriş sinyalini alır.
RTF ağ, doğrusal olmayan giriş-çıkış eşleminin yerel tahmini için meydana getirilir.

Geleneksel çok katmanlı ileri beslemeli YSA ile RTF ağlarının arasındaki ana farklar Çizelge 3.3.'de belirtilmektedir.

RTF ağlarının eğitilmesi geleneksel çok katmanlı ileri beslemeli YSA'ndan farklıdır. Temel RTF ağında, radyal tabanlı fonksiyonun merkezleri ve genişlikleri sabittir. Bunlar öğrenme işlemi sırasında değişmezler, öğrenme işlemi sırasında sadece ağırlıklar ayarlanabilir parametrelerdir. Bununla birlikte genelde RTF ağlarının doğrusal olmayan aktivasyon fonksiyon parametreleri (radyal tabanlı fonksiyonun merkezleri ve genişlikleri) ve doğrusal çıkış ağırlıkları olmak üzere üç parametresi bilinmemektedir. Tüm bu parametrelerin öğrenilmesi gerekmektedir.

Çeşitli öğrenme stratejileri bulunmaktadır. Fakat iki ayrı aşama gerekmektedir (MacQueen, 1997). Gizli katmandaki aktivasyon fonksiyonunun doğrusal olmayan parametreleri doğrusal olmayan en iyileme teknikleri kullanılarak belirlenir. Çıkış katmanının lineer ağırlıkları bir doğrusal en iyileme tekniği kullanılarak belirlenir. Mesela ilk durumda, radyal tabanlı fonksiyonların merkezlerinin yerleştirilmesi bazı sınıflandırma algoritmaları kullanılarak ilk olarak belirlenebilir. Eğitimin diğer adımı radyal tabanlı fonksiyon genişliğinin belirlenmesidir ve bu en yakın komşu heuristic, kullanılarak yapılabilir. (σ_j, c_{js} 'nin ortalananmış mesafedeki birkaç en yakın komşuluklarından heuristic olarak elde edilir.)


$$\phi_j = (1/P) \sum_{i=1}^P \left[\|c_j - c_i\| \right]^{1/2} \quad (3.68)$$

Burada c_j , σ_j 'nin p-yakınlığındaki komşusudur. İlk aşamanın sonunda c_j ve σ_j parametreleri bilinir ve artık bunlar değiştirilmez. İkinci eğitim aşamasında çıkış katmanındaki ağırlıklar önceden küçük keyfi değerler olarak raslantısal olarak alınır ve nihai ağırlık değerleri çıkış değerlerinin hatalarının karelerinin toplamının minimize edilmesi ile elde edilir. RTF'in eğitiminin bu aşamasında, eğitim veri kümesinde verilen hedef çıkışlarla, çıkışlar karşılaştırılır ve çıkış katmanının ağırlıkları, gerçeklerşen ve hedef çıkış vektörleri arasındaki farkın en küçük hale gelmesini sağlayacak yönde güncellenir. Özel giriş-çıkış eğitim veri çiftleri YSA hatanın kabul edilebilir seviyeye düşene dek tekrarlanarak gösterilir.

3.1.5.7. YSA'nın Donanım Olarak Gerçeklenmesi

Daha iyi anlaşılması için geleneksel çok katmanlı ileri beslemeli YSA'ların analog ve dijital gerçekleştirilmelerinin kısaca tanımlanması amaçlanmaktadır. Yine de, donanım gerçekleştirilmelerinde daha ayrıntılı bilgi literatürde bulunmaktadır (Vittoz ve ark., 1991), (Bibyk ve Ismail, 1990), (Sedra ve Smith, 1991), (Kosko, 1991).

Gerilim yükselteci içeren işlemsel yükselteç tabanlı donanım sinir modelinde, işlemsel yükselteç kullanıldığı zaman bir pozitif ağırlık bir pozitif giriş sinyaline bağlı bir dirence ve bir negatif ağırlık bir negatif giriş sinyaline bağlı bir dirence uygulanarak pozitif ve negatif ağırlıklar kolaylıkla gerçekleşir. Negatif (engelleyici) ağırlıklar $w_i^{(-)}$, $i = 1, 2, \dots, n$ olmak üzere $x_i^{(-)}$ girişleri ile ilişkilidirler ve pozitif (uyarıcı) ağırlıklar $w_i^{(+)}$, $i = 1, 2, \dots, p$ olmak üzere $x_i^{(+)}$ girişleri ile ilişkilidirler. Böylece aktivasyon sinyali S engelleyici ve uyarıcı eşik değerlerinin toplamıdır $S = w^{(-)T} x^{(-)} + w^{(+)T} x^{(+)}$ ve f aktivasyon fonksiyonu olmak üzere çıkış $y = f(S)$ 'dır.



Şekil 3.24. Bir Fark Yükselteç Kullanılan Nöron Model Uygulaması (Vas, 1999)

Şekil 3.24'te kurulumu kolay gerçekleştirilmesi mümkün olan model gösterilmektedir. Burada yükseltecin gerilim toplaması giriş ağırlıklarının toplamının belirlenmesinde kullanılır ve doğrusal olmayan aktivasyon fonksiyonu $f(S)$ işlemsel kuvvetlendirici doyurularak yerine getirilir. Şekil 3.24'te ağırlıklar ve devrenin dirençleri arasındaki

ilişkide gösterilmektedir. Bu eşitlikler basitçe, işlemsel yükselteç devresine uygun Kirchhoff Eşitliklerine göre elde edilebilir ve devrenin çıkışı (y) aktivasyon fonksiyonuna girişlerin toplam ağırlıklarının uygulanmasından sonra elde edilen bir değeri verir. Eğer işlemsel yükseltecin terslemeyen girişine sadece engelleyici girişler $x_1^{(-)}, x_2^{(-)}, \dots, x_n^{(-)}$ verilirse ve hiç bir uyarıcı girişi olmazsa, giriş akımlarının toplamı geri besleme akımına karşılık gelen R_f direnç değerinin negatifidir. Böylece $\sum_j x_j^{(-)} / R_j^{(-)} = -f / R_f$ 'dir. Burada aktivasyon fonksiyonu $f = \sum_j w_j x_j^{(-)}$. Böylelikle negatif ağırlıkların ifadesi Şekil 3.29'da gösterilmiş olur.

Doyumlu işlemsel yükselteç ile sadece sınırlı aktivasyon fonksiyon şeklinin elde edilmesi mümkündür. Sigmoid gibi genel bir şekil elde edilmesinde örneğin dengeli yükselteçler (push-pull yükselteçler) kullanılabilir. Dikkat çeken şudur ki; aktivasyon değeri (S), fiziksel olarak Şekil 3.24'teki devrede gösterilmemektedir. Birkaç nöron kullanan tek katmanlı YSA için böylelikle Şekil 3.24'te gösterilenlere benzer ayrı ayrı devreler içeren işlemsel yükselteçler kullanılarak basit bir gerçekleştirilmesi yapılabilir.

Elektriksel olarak ayarlanabilen ağırlıklar; aslında rezistansının kontrol gerilimi ile değiştirilebildiği gerilim kontrollü anahtarlar olan doğrusal bölgede çalışan alan etkili veya MOS transistörlerdir. Kanal oluşturmali bir n kanal MOS (NMOS) transistörde kapı, kontrol gerilimi ile kontrol edilen terminaldir. Bununla birlikte ayarlanabilirliğe ek olarak belli bir zaman süresinde uygun çalışmayı garantilemek için bir YSA'da bu ağırlıklar saklanmış olmalıdır. Ayarlanabilen ağırlıkların saklanabilmesi aynı zamanda analog devrelerle de mesela kondansatör kullanılarak yapılabilir. NMOS transistör kullanan bir gerçeklemede, bu kondansatör aslında olan veya saklama kapasitesini çoğaltmak için dışarıdan eklenebilen kapı kapasitansı olabilir. Birkaç NMOS anahtar bulunan bir devrede bir tek gerilim kontrol jeneratörü kullanılabilir. Ne kadar da kondansatör tabanlı ağırlık saklamanın kondansatör şarjının doğal azalması ile etkilenen özgün bir limiti olsada özel devreler kullanılan ileri tekniklerle saklama zamanının uzatılması mümkündür (Vittoz ve ark., 1991).

Sigmoid aktivasyon fonksiyonunu temsil etme ilişkisi yukarıda sözü edilen dengeli yükselteçleri iki tamamlayıcı MOS (CMOS) gerilim invertörü kullanılarak gerçekleştirilebilir. Bir CMOS invertör, kapıları giriş terminali şeklinde bağlanan ve drainleri çıkış vazifesini yapmak için bağlanan NMOS ve p kanal, kanal oluşturmali MOS (PMOS) tamamlayıcı transistörler içermektedir. İki invertörün art arda bağlantısı sigmoid aktivasyon fonksiyonunu gerçekleyen istenen yöntemi verir (Zurada ve ark., 1989).

Kanal ayarlamalı MOS transistörler VLSI teknolojisi kullanılarak büyük YSA ağ oluşturmak için uygundur. Özellikle kanal ayarlamalı MOS transistörler aynı devrede ağırlık saklama ve analog çoğullama sağlarlar.


Dijital olarak programlanabilen ağırlıklar, dijital analog dönüştürücüler çoğullaması kullanılarak gerçekleştirilirler.

3.1.5.8. Diğer Yapay Sinir Ağları

Bu kısımda, literatürde adı en çok geçen YSA kısaca açıklanacaktır.

i. LVQ (Learning Vector Quantization)

Şekil 3.25., üç katmandan oluşan LVQ ağını göstermektedir. Bu katmanlar, giriş katmanı, gizli katman ve çıkış katmanıdır. LVQ ağı, giriş katmanı ile gizli katman birbirleriyle tamamen, gizli katman ile çıkış katmanı da kısmen bağlıdır. Her çıkış nöron düğümü farklı bir gizli nöron düğüm kümesine bağlıdır. Gizli ve çıkış nöronları arasındaki ağırlıklar “1”e sabitlenmiştir. Girişler ile gizli katmandaki nöronların bağlantılarının ağırlıkları “referans” vektörlerinin elemanlarını oluşturur (her gizli katman nöronuna bir referans vektör atanmıştır). Ağın öğretilmesi aşamasında bunlar yeniden değerler alırlar. Hem gizli katman nöronları (bunlar Kohonen nöronları olarak da bilinir) hem de çıkış katmanı nöronları ikili (binary) çıkışa sahiptir. Ağa bir giriş örüntüsü verildiğinde referans vektörü giriş örüntüsüne en yakın olan gizli nöron kümesi “1”, diğerleri “0” üretir. “1” üreten çıkış nöronu giriş işaretini sınıflar ve her nöron ayrı bir sınıfa atanmıştır.



Şekil 3.25. LVQ Ağı


En basit LVQ öğretme prosedürü şu sıra ile açıklanabilir.

- Referans vektörlerinin ağırlıklarının başlangıç değerlerinin belirlenmesi.
- Ağa giriş örüntüsünün uygulanması.
- Giriş deseni ile her referans vektörü arasındaki öklit (Euclidian) uzaklığının hesaplanması.
- Giriş örüntüsüne en yakın referans vektörünün ağırlıklarının yeniden düzenlenmesi. Eğer bu gizli katman nöronu, o çıkış katmanı nöronunun bağlı

olduğu gizli katman nöron kümesine bağlı ise referans vektörünü giriş örüntüsüne daha yakın hale getirir. Aksi takdirde referans vektörünü uzaklaştırır.

- ii numaralı adıma yeni bir giriş örüntüsü ile dönülür ve işlemlere sınıflandırılması istenen giriş örüntüsü kalmayana dek devam edilir.

ii. Hopfield Ağı



Şekil 3.26. Hopfield Ağı

Şekil 3.26’da Hopfield Ağı’nın bir şekli gösterilmiştir. Bu ağ genellikle ikili (0 veya 1) ve iki kutuplu (+1 veya -1) girişler kabul eder. Tek katman işlemci nöronlar vardır ve her bir nöron diğerine bağlıdır. Böylelikle geribeslemeli bir yapıya sahip olduğu görülmektedir. Hopfield ağı’nın eğitilmesi sadece bir adım alır ve w_{ij} ağırlıkları aşağıda verildiği gibi hesaplanır.

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^P x_i^c x_j^c & , \quad i \neq j \\ 0 & , \quad i = j \end{cases} \quad (3.69)$$

Burada w_{ij} , i nöronundan j nörona olan bağlantı ağırlığını, x_i^c c sınıfı için eğitime giriş deseninin i ’inci elemanını, P sınıf sayısını ve N de nöron sayısını gösterir. Eşitlik

3.69.'da $w_{ij} = w_{ji}$ ve $w_{ii} = 0$ durumları ağıın kararlılığını garantiler. Bilinmeyen bir bilgi ağı girildiğinde, ağıın çıkışları bilinmeyen bir desen elemanına eşitlenir. Yani;

$$y_i(0) = x_i \quad 1 \leq i \leq N \quad (3.70)$$

Bu başlangıç değerleri ile başlayarak hopfield ağı bir sonraki denklemi kullanarak minimum enerji durumuna geçmek için döngüye girer.


$$y_i(k+1) = f \left[\sum_{j=1}^N w_{ij} y_j(k) \right] \quad 1 < i \leq N \quad (3.71)$$

Burada f aşağıdaki gibi tanımlanan keskin sınırlama (hard-limiting) fonksiyonudur.


$$f(x) = \begin{cases} -1 & x < 0 \\ 1 & x > 0 \end{cases} \quad (3.72)$$

iii. Elman ve Jordan Ağları

Şekil 3.27.a ve Şekil 3.27.b Elman ve Jordan ağlarını göstermektedir. Bu ağlar, MLP'lere benzer bir yapıdadırlar. Her iki ağda da gizli katmana ek olarak bir "durum" katmanı denilen özel bir gizli katman daha bulunmaktadır. Bu katman gizli katmandan veya çıkış katmanından geri besleme işaretleri alır. Jordan ağının aynı zamanda durum katmanındaki her nöronun kendisine bağlantıları vardır. Her iki ağda da durum katmanındaki nöronların çıkışları ileriye doğru gizli katmana verilmektedir. Eğer sadece ileri doğru bağlantılar göz önüne alınır ve geri besleme bağlantılarına sabit değerler verilirse, bu ağlar sıradan ileri beslemeli ağlar haline gelir.



Şekil 3.27.a) Elman Ağı



Şekil 3.27. b) Jordan Ağı


iv. Kohonen Ağı

Kohonen ağı, bir giriş katmanı ve bir de çıkış katmanı olmak üzere iki katmandan oluşur. Bu ağ Şekil 3.28’de gösterilmiştir. Çıkış katmanındaki nöronlar genellikle düzenli iki boyutlu aralıklar olarak düzenlenir. Çıkıştaki her nöron bütün giriş düğümlerine bağlıdır. Bağlantıların ağırlıkları verilen çıkış elemanı ile ilgili olan referans vektörünün elemanlarını oluşturur.

Kohonen ağının öğrenme adımları aşağıdaki gibidir.

- Çıkış nöronlarının bütün referans vektörlerini küçük rasgele değerlere çekilmesi.
- Bir giriş örüntüsünün alınması.
- Giriş örüntüsüne en yakın referans vektörüne sahip nöronun belirlenmesi.
- Belirlenen nöronun ve onun komşularının referans vektörlerinin güncelleştirilmesi. Bu referans vektörleri giriş vektörüne yaklaştırılır. Bu yaklaştırma (ayarlar) belirlenen nöron için en fazla ve bu nörondan uzaklaştıkça daha azdır. Öğrenme ilerledikçe komşuların sayısı azalmakta ve öğrenme sonunda belirlenen nöronun referans vektörü ayarlanmaktadır.

Öğrenmeden sonra bir etiketleme işlemine başlanır. Bilinen sınıfların giriş örüntüleri ağı giriş olarak verilir ve bu giriş örüntüleri tarafından aktif hale gelen çıkış nöronlarına bu sınıf etiketleri verilir.




Şekil 3.28. Kohonen Ağı

c) ART (Adaptive Resonance Theory) Ağı

ART ağının, ART-1, ART-2, Fuzzy-ART, MART gibi değişik çeşitleri vardır. Şekil 3.29'da ikili girişler kabul eden ART-1 gösterilmiştir. ART-2 gerçek değerler kabul etmektedir. Şekil 3.29'da görüldüğü gibi, ART-1 ağının giriş ve çıkış olmak üzere iki katmanı vardır. İki katman birbiriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. i 'inci çıkış nöronunun ileri yöndeki bağlantılarının ağırlıklarının oluşturduğu W_i vektörü, temsil ettiği sınıfın bir örneğini oluşturur. İleri bağlantılarının W_i vektörlerinin toplamı ART ağının uzun-dönem (long-term) hafızasını oluşturur. Bu vektörler, giriş desenine benzerlikleri ölçüsünde, çıkış nöronlarını belirlerler. Çıkış nöronlarının geri bağlantılarının W_i vektörleri ise, giriş deseninin, hafızadaki desene yeterince benzeyip benzemediğini (o sınıfa ait olup olmadığını) kesin olarak belirlemek için bir çeşit test "vigilance" amacıyla kullanılır. Bu test vektörleri diyebileceğimiz V_i vektörleri ART ağının kısa-dönem (short-term) hafızasını oluştururlar. W_i , V_i 'nin normalize edilmiş halidir.

$$W_i = \frac{V_i}{\varepsilon + \sum V_{ji}} \quad (3.73)$$

Burada ε küçük bir sabittir ve V_{ji} , V_i 'nin j 'inci elemanıdır.



Şekil 3.29. ART-1 Ağı

3.1.6. YSA'nın Mühendislik Uygulamaları

YSA'lar bir çok önemli mühendislik problemlerinin çözümünde kullanılmışlardır. Bu mühendislik alanları ve uygulamalardan bazıları şunlardır.

- i. Sistem ve Kontrol Mühendisliği; esnek kollu robotun kontrolü, bir model helikopterin havada kontrolü, çok değişkenli (mafsallı) robotun yörünge koordinasyonu, iki sıvı tank sisteminin akış seviye kontrolü, anestezi derinliği kontrolü ve ölçülmesi, bir robot için optimal yolun bulunması, banyo suyu sıcaklığının kontrolü, endüstriyel robot kontrolü, sistem kimliklendirme gibi birçok alanda uygulanmaktadır.
- ii. Elektrik-Elektronik Mühendisliği; hastaların alarmla kontrolü, gürültülü resimlerin kalitesini artırma, görüntülerin sıkıştırılması, gürültü filtreleme ve resimlerdeki kenar bilgisinin çıkarılması, güç sisteminde harmoniklerin tahmini, gezgin haberleşme sisteminde kanal dağıtımı, ultrasonik müziklerden objelerin sınıflandırılması, optik okuyucu sistemler için resimlerin ön işlenmesi alanlarında kullanılmaktadır.
- iii. Kimya Mühendisliği; kimyasal reaktör seçimi, dinamik işlemlerde hata belirlenmesi, endüstriyel polimerizasyonda eritme akış indisi tahmini, endüstriyel mayalama işleminin modellenmesi, biyokimyasal işlemlerde mikrobik konsantrasyonların tahmininde uygulanmaktadır.

- iv. İnşaat ve Yapı Mühendisliği; konstrüksiyon projelerinde kaynak seviyelerini belirlenmesi bir rezervuardan çıkışı kontrol, biyolojik bilgiler yardımıyla nehir suyunun kalitesinin sınıflandırılması, nehirlerin akışının tahmin edilmesi, sonlu-eleman-temelli yapısal analiz işleminin modellenmesi, yapı malzemelerinin iç yapılarındaki çatlakların tasbit edilmesi, depreme maruz betonarme çerçevelerde emniyetli yatay taşıyıcı tahmininde uygulanmıştır.
- v. İmalat ve Makine Mühendisliği; metal kesme tezgahının kontrolü, akustik salınım ve iş parçası kuvvetiyle iş parçası yatağının kontrolü ve güç tüketimi ve iş parçası ivmesi, hücreli imalat için grup teknolojisi parça grupların tasarımı, hareket eden nesneler için engelsiz yol planlaması, makine parametrelerinin optimizasyonu, makine arızalarının sınıflandırılması, malzemelerin ısı transferinin belirlenmesi, uçak kanat kutularının yapısının tasarımında uygulanmıştır.
- vi. Anten ve Uygulamaları; YSA’nda bir dinamik öğrenme algoritması kullanılarak anten dizi elemanlarından elde edilen işaretler arasındaki faz farklılıklarının karşılaştırılmasıyla radar izleme gerçekleştirilmiştir. Mikrodalga parlaklığına bağlı jeofiziksel parametrelerin tayini gerçekleştirilmiştir. Uzaktan kontrollü görüntü sınıflama işlemi, dinamik öğrenme algoritması ve danışmansız (ART2) öğrenme algoritmaları kullanılarak yapılmaktadır. YSA kullanarak anten dizi analizi yapılmaktadır. Aynı zamanda, anten dizi tasarımında, genetik algoritma ve tabu araştırma algoritması kullanılmaktadır. Osilatör YSA ile elektromagnetik işaretlerin etkileşim modelleri oluşturulmaktadır.

3.1.6.1. Biyomedikal İşaret İşlemede Yapay Sinir Ağları

Yapay sinir ağları ile hesaplama, yapay zeka tarihindeki en hızlı gelişen alanlardan birisidir. Çünkü sinir ağları giriş ve çıkış arsında non-lineer örüntüleri tanıması için eğitilebilir ve kompleks sorunları sayısal bilgisayarlardan daha hızlı çözebilirler. Yapay sinir ağlarının geniş uygulanabilirlik alanları ve kompleks ve nonlineer ilişkileri öğrenme yetenekleri onları biyomedikal mühendisliğinde ve özellikle de biyomedikal işaretlerin analizindeki sorunları çözmede cazip hale getirmiştir.

Yapay sinir ağları, sürekli konuşma tanımda ve sentezinde, örüntü tanımda (pattern recognition), gürültülü veriyi sınıflandırmada, nonlineer özellik algılamada ve diğer alanlarda önemli gelişmelere sahiptir. Yapısı gereği yapay sinir ağları, gerçek zamanda yüksek-hız paralel işaret işleme yeteneğine sahiptir. Geleneksel teknolojilere göre oldukça avantajlıdır; çünkü, algoritmik çözümü olmayan veya algoritmik çözümü bulunamayacak kadar kompleks problemleri çözebilirler. Yapay sinir ağları, kurallar yerine örnek tarafından eğitilir ve otomatik hale getirilir. Tıbbi teşhiste kullanılırken, insan yorgunluğu, duygusal durumlar gibi faktörlerden etkilenmezler. Hızlı tanımlama, şartları analiz etme ve gerçek zamanda teşhis etme yeteneğine sahiptirler.

Yapay sinir ağlarının en yaygın kullanılan mimarisi, geri-yayılım algoritması tarafından eğitilen çok katmanlı perceptron mimarisidir. Geri-yayılım algoritması ağı

ortalama karesel hatasını minimum yapmaya çalışan bir gradient-decent algoritmasıdır. Gerçek uygulamalarda, ağ basit tek boyutlu bir sistem değildir ve hata eğrisi yuvarlak şekilli veya düzgün değildir. Bunun yerine oldukça kompleks olup tepe ve vadilerden oluşmuş çok boyutlu bir eğri şekline sahiptir.


Geri-yayılım ilk olarak P.Werbos tarafından 1974' te geliştirildi, Parker tarafından 1982' de yeniden keşfedildi ve daha sonra 1986' da Rummelhart tarafından popüler hale getirildi. Bu algoritmanın birçok değişik varyasyonları vardır. Bunlar özellikle hızını ve performansını arttırmak üzerine yapılan çalışmalardır

3.1.6.2. Nörolojide Yapay Sinir Ağları

Yapay sinir ağları nöroloji de de kendine uygulama alanı bulmuştur. Özellikle hafıza da oluşan hastalıkların belirlenmesinde ve Parkinson ve Alzheimer gibi kolaylıkla tespit edilen hastalıklarda kullanılmaktadır. Her iki hastalıkta yok edici etkiler gösterip bunun sonucunda yaşamı bozucu etki yaparlar.

Donanım: EEG kayıtları, şekil 3.30. da gösterildiği gibi bir kişisel bilgisayar ve kanal başına 150 Hz örnekleme frekansı ile 12 bit çözünürlüğünde(PCIMIO-16-E+type) veri kazanımı sağlayan DAQ(Data Acquisition Card) (PCIMIO-16-E+type) yardımıyla alınmışlardır. Cihazın 8 kanalı aynı zamanda kullanılmıştır. Bilgisayarın PCI veri yoluna takılan bu kart ile veriler vakit kaybetmeden bilgisayarın hafızasına alınmışlardır.

DAQ kartları analog ve sayısal giriş/çıkış, zamanlama, anahtarlama gibi bir çok gerçek zaman kullanılabilir özelliklerine sahiptirler. Çoğu da programlanabilir kanallara sahip olup örnekleme, çevirme modu, her bir kanal için ayrı kazanç, öncelik sonralık gecikme, analog ve dijital tetikleme gibi özelliklerle donatılmışlardır. Bu kartlar elde edilen sinyali gerçek zamanda işlerler ve çok yüksek performanslara sahiptirler.



Şekil 3. 30. Veri Kazanç Düzenegi (Anonim, 1997)

DAQ sistemlerini kullanarak yapılacak tasarım 5 aşamada özetlenebilir.

1) DAQ sisteminizi belirlemeden önce kullanılacak olan dönüştürücü giriş/çıkış sinyal tiplerinin belirlenmesi.

PC tabanlı DAQ sistemlerinde tipik olarak Giriş Çıkış Modülleri:

Analog Giriş: Sıcaklık, basınç, gergi, voltaj, akım, akustik, ve titreşim gibi sinyaller olabilir.

Analog Çıkış: Voltaj, akım, dalga jenerasyonu gibi sinyaller olabilir.


Dijital Giriş/Çıkış: TTL (Transistor-Transistor Logic) uyumlu giriş/çıkış, yüksek voltaj giriş/çıkış, paralel haberleşme, röle kontrolü gibi elemanlar olabilir.

Zamanlama Giriş/Çıkış: Frekans giriş/çıkış, darbe genişliği ölçme, darbe katarı tiplerinde olabilirler.


2) Sinyal düzenleme metodunun seçilmesi.

Çoğu dönüştürücü tipleri DAQ kartlarına bağlamadan önce düzenleme yapılmalıdır. Örneğin: Yükseltme, filtreleme, izole, yüksek kanal girişler için çoğullama gibi.

3) Uygun DAQ Giriş/Çıkış elemanlarının seçimi. Veri kazanç kartı için doğruluk, kazanç oranı, kanal sayısı, akıcılık, genişlik, bilgisayar platformu gibi kriterlerin belirlenmesi.




Şekil 3.31. Sinyal düzenleme modülü (Anonim, 1997).



Şekil 3.32. Veri kazanç kartının seçimi(Anonim, 1997).

4) Seçilen sinyal düzenleme elemanlarına göre uygun olan kablo aksesuarının seçilmesi.


DAQ modüllerinin SCXI modüllerine bağlantısı için En uygun doğrulukta, gürültü izolasyonlu iyi bir bağlantının seçilmesi gerekmektedir.



Şekil 3.33. Uygun aksesuarın seçimi (Anonim, 1997).

5) Uygun yazılımın seçilmesi

Bu çalışmada MATLAB programının DAQ Araç kutusu özellikleri uygun grafik özellikleri ve pratik uygulama kolaylıkları nedeniyle kullanılmıştır.



Şekil 3.34. MATLAB Data Acquisition Tools

3.2. Metot

3.2.1. Giriş

Bu çalışmada kullanılan EEG verileri MIT- BIH veri tabanından elde edilmiştir. Sinyaller, yaşları 21 ila 35 arasında değişen deneklere ait olup örnekleme frekansı 100 Hz dir. Sinyalleri görüntülemek ve analiz etmek için MATLAB araç kutuları kullanılmıştır.

Spektral Analizi gerçekleştirilen verilerin sınıflandırma probleminin; matematiksel olarak bağıntısı kurulamayan, yada kurulsu dahi çözümlenmesi çok karmaşık olan problemlerin sezgisel olarak çözümlenmesine imkan sağlayan YSA ile çözülmesi hedeflenerek bu yönde çalışılmıştır.

3.2.2. Hata Geriayılım Algoritmasının Uygulanması

3.2.2.1. Geriayılım Algoritması İçin Veri Hazırlanması

Geriayılımda üç tip veri kullanılır. Eğitim kümesi, test kümesi ve gerçek veri.

Eğitim kümesi, YSA'nın uygun ağırlıklarının konfigürasyon edilmesinde kullanılır. Doğru ağırlıklı YSA, test kümesi ile test edilir. Test kümesi eğitim kümesinin birinci altkümesidir. Eğer YSA eğitim kümesini ezberlemiyorsa, test verisinin uygulanmasında başarıya ulaşılmıştır. Böylelikle YSA gerçek problemlere (özel gerçek verilere) uygulanabilir. Eğitim veri kümesinin çok önemli bir rolü vardır ve özenli bir seçim gerektirmektedir. YSA ile gösterilen bilgi ancak onun eğitiminde kullanılan veri gibidir.

Verinin hazırlanması üç adım gerektirmektedir: Verinin ayrıntıları, verinin denetlenmesi ve verinin ön işleme. Bazı zamanlar ilk adım en güç olanıdır. Özgül problem hakkında neyin önemli olduğu ile etkilenirler. Açıkca problemin bütünüyle YSA ile belirtilmesi önemlidir. Bununla birlikte; her giriş karakteristiği YSA'nda giriş düğümü olarak gösterildiğinden ve çok sayıda giriş karakteristiği geniş bir YSA'ya gereksinim duyulduğundan YSA'nın karakteristiklerin her tipini içermesi mümkün değildir. Genelde geniş bir YSA, daha fazla hesaplama gücü gerektirir ve çevrim daha yavaş olur. YSA'nın sadece giriş-çıkış ilişkisinin öğrenilmesinin mümkün olduğu girişlere gereksinimi bulunmaktadır. Enterasan olan, YSA'nın kendisinin tesirli olan giriş karakteristiklerini işaret etmesidir. Eğitim başladıktan sonra, YSA'nın birkaç çevrim sonunda giriş katmanına bağlı ağırlıklar bazı sonuçlar vermektedir. YSA tarafından gereksinim duyulmayan herhangi bir ağırlık, gerçekten ihtiyaç duyulan diğer ağırlıklarla karşılaştırıldığında küçük ağırlıklara sahiptir.

Veri hazırlamanın ikinci aşamasında eğitim kümesinden herhangi sahte verilerin dışarı atılması için olağan olmayan davranışlar aranmak üzere veri gözden geçirilir.

Veri hazırlanmasında son aşamada; YSA'nın girişleri için verinin normalizasyonu gerekmektedir. Geriayılım YSA 0 ila 1 aralığında veri tercih edilir. Veri normalizasyonu

için, eğitim kümesindeki her girişin tipik aralığı göz önüne alınmak zorundadır. Çeşitli yollarla normalize değerler (n_v) tanımlanabilir.

$$n_v = \frac{\text{gerçek deger} - \text{minimum deger}}{\text{maksimum deger} - \text{minimum deger}} \quad (3.74)$$

Geriyaılım YSA'nın eğitilmesi için gereken veri sayısı da önemli bir faktördür. Eğer problem alanı kompleks ise, daha geniş veriye ihtiyaç vardır.

3.2.2.2. Düğüm ve Katmanlar

Geriyaılım algortimasının zor yönlerinden biri de direkt bir metodun olmamasından gizli katman sayısı ve gizli düğüm sayılarının seçimidir. Giriş ve çıkış düğümleri problem gözden geçirilerek tesbit edilir, gereksinim duyulan gizli katmanlar ve gizli düğümlerin sayısı önceden bilinmemektedir. Bununla birlikte bu gizli düğüm ve gizli katman seçimini kolaylaştırmamaktadır. Örneğin, tek gizli katmanlı bir YSA'da eğer gizli katman düğüm sayıları çok miktarda ise YSA kolay basit bir şekilde eğitim kümesini ezberlemesini sağlar. Çok az gizli düğüm olması durumunda ise iyi bir öğrenme gerçekleşemez. Optimal gizli düğüm sayısı sınırlayan bu iki şekil arasında bir yerde bulunmaktadır.

Uygulamalara özgü olarak ilk olarak gizli katman düğüm sayısı uydurulur. YSA tarafından test verisi kullanılarak kararlaştırılır. Genellikle YSA eğitim verisini ezberler fakat yeni bir veri uygulandığında genelde doğru olmayan sonuçlar verir. Bu durumda gizli düğüm sayıları indirgenir ve çıkış kontrol edilir. Gizli katman sayısı tekrar indirilir, YSA tekrar eğitilir. Böylelikle gizli düğüm sayısı bulunmaya çalışılır.

Tek bir gizli katman içeren YSA'nda bazen sadece bir gizli düğüm kullanılır fakat saklı düğüm sayıları problem ilişkisine bağlıdır. Bununla birlikte, bazen çoklu gizli katmanlar kullanışlı olabilirler. Buna göre; teoride durağan ileri beslemeli tek gizli katmanlı, YSA herhangi doğrusal olmayan bir sistemin eşlemesi yapılabilir. Pratikte iki gizli katmanlı YSA sıklıkla kullanılmaktadır.

Böyle YSA'nın değişik yakınsama özellikleri sunmalarına rağmen, iki katmanlı ağdan elde edilenden oldukça farklı olabilecek dayanıklılık ve genelleme karakteristikleri sunar.

3.2.2.3. Geriyaılım Eğitimi ve Öğrenimi

Eğitim aşamasında, giriş vektörleri YSA'na sırasıyla uygulanır ve eğer sinir ağının çıkışı doğru ise ağ mimarisi (ağırlıklar ve biaslar) değiştirilmez, diğer durumlarda değiştirilirler. Giriş eğitim vektörlerinin uygulanması ile eşzamanlı olarak YSA'nın eğitilmesi mümkündür. Bunun için batching gibi tekniklere başvurulur.

Geriyaılım algoritması kullanıldığında YSA'nın eğitimi genellikle yavaştır. Genelde yakınsamaya ulaşılmadan önce bu bir kaç bin devir almaktadır.

Bununla birlikte; geri yayılım algortima tabanlı simülasyonun çalıştırılması büyük problemlerde dahi sadece birkaç saniye gerektirmektedir. Teorik olarak; ileri yönlü bir çalışmada düğüm aktivasyonları giriş katmanından akış yönüne ilk önce hesaplanır. Daha sonra ağ çıkışı veya çıkışları istenilen değer veya değerlerle karşılaştırılır ve hata ağırlıkların ayarlanması için geri yayılır. Bununla beraber pratikte birkaç sayısal hızlandırma teknikleri öğrenme işlemini hızlandırmaktadır.

Geri yayılımın öğrenilmesi iki adımdan oluşur. İlk adımda giriş katmanından akış yönünde olan tüm düğümler için düğüm aktiviteleri hesaplanır. İkinci adımda, ağırlık çıkışı (çıkış düğüm veya düğümlerinin aktivasyon değeri veya değerleri) arzulanan çıkış değeri veya değerleri ile kıyaslanır. Daha sonra hata ağda çıkış katmanından akış yönüne ters yönde tüm ara bağlantıları sağlayan ağırlıkların ayarlanarak geriye doğru aktararak yayılır. Çıkış katmanında, ağırlıklar genellikle doğrudan doğruya bir kez düğüm hatası hesaplandığında modifiye edilir. Eğer bir genel çıkış düğümü j ., önceki katmanın i . düğüme bağlanırsa, ağırlık değişimi aşağıdaki gibi ifade edilebilir.

$$\Delta w_{ij} = \eta \delta_j y_i = \eta [(d_j - y_j) f'_j(S_j)] y_i \quad (3.75)$$

Bu “Delta Öğrenme Kuralı” olarak da adlandırılır. Eşitlik 3.75’te η öğrenme oranı, δ_j çıkış düğümü (j . düğüm) eşdeğer hatası ve y_j ; i . düğüm çıkış sinyali. Ağırlık değişimi; öğrenme katsayısı çarpı j . düğüm çıkışının eşdeğere hatası çarpı i . düğümün aktivasyon sinyalidir. Eşdeğer hata; d_j ’nin j . düğümün istenen çıkış değeri ve y_j , j . düğümün gerçek çıkış değeri olmak üzere hata sinyaline karşılık gelen ($e_j = d_j - y_j$) ile aktivasyon fonksiyonun türevinin $f'_j(S)$ çarpımıdır.

Bunu takiben düğüm hatası öğrenildiğinde, o düğüme etki eden tüm ağırlıkların ayarlanması hesaplanabilir ve uygulanır. Bu bazen “stokastik güncelleme metodu” olarak adlandırılır. Alternatif olarak, tüm ağırlık değişimleri saklanabilir çevrim arasında sadece bir kez uygulanır. Bu da “kümülatif güncelleme” metodu olarak adlandırılır ve özel koşullar altında yakınsama oranını geliştirmektedir. Bu teknik seyrek olarak kullanılır, fakat stokastik güncelleme veya kümülatif metodlardan biri kullanıldığında, amaç aynıdır. Amaç, hata için kabul edilebilir minimum elde etmektir. “Kabul edilebilir” olması birden fazla çözümün olduğu izlemine uyandırmaktadır.

Çıkış katmanı ile ilişkilendirilip bağlanmış ağırlıklar için 3.75 eşitliği uygulanmaz. Genelleştirilmiş Delta Öğrenme Kuralı kullanılır. Bu durumda, ağırlık güncellemesi için $\eta \delta_j y_j$ kullanımı yerine benzer bir ifade kullanılır. Bu ifadede δ_j , genel hata eşdeğeri ile yer değiştirilir. Genel eşdeğer hata, birbirine yakın takib eden düğüm katmanlarının eşdeğer hatalarının ağırlıklı toplamı ile orantılıdır. Giriş eğitim kümesindeki tüm vektörler için LMS hatası daha önceden belirlenen bir değer altında kaldığında öğrenme tamamlanmış ve bir çözüm elde edilmiştir. Çevrim sayısına karşı LMS hatasının çizimi öğrenme eğrisini verir. Eğer sistemin kabul edilebilir bir çözüme yakınsadığı düşünülüyorsa bu eğri düşer. YSA’nın öğrenme işlemleri esnasında bu eğriyi gözden geçirmek faydalı olabilir ve işlem durdurulur, bazı değerler modifiye edilir ve algoritmaya dönülür.

3.2.3. Genelleştirilmiş Delta Kuralı

YSA uygulamalarının amacı giriş/çıkış ilişkiler serilerinin öğrenilmesidir. Bunun için, ağ configure edildikten sonra temsili veri kümesi eğitilir. Geri yayılım ağılar eğitildiğinde, amaç ağırlıkların kümesinin elde edilmesidir. Şöyleki genel sistem hatası (arzu edilen çıkış ile gerçek ağ çıkışı arasında) minimum olmasıdır. Matematiksel olarak toplam ağ hatası (hataların kareleri toplamı) şu şekilde ifade edilir.

$$E = \frac{1}{2} \sum_{k=1}^P \sum_{j=1}^K (d_{kj} - o_{kj})^2 \quad (3.76)$$

Burada; E , toplam hata; P , eğitim kümesindeki örüntü sayısı; K , ağ çıkışlarının sayısı; d_{kj} , k . paternin hedef (arzu edilen) çıkışı ve $o_{kj}(=y_{kj})$, k . örüntünün j . çıkışıdır. Bu yüzden toplam hata, P hatalarının toplamıdır.

Hatanın minimizasyonu, ağırlıkların negatif gradyent yönü değiştirilmesi gerektiğinden, Δw_{ji} gradyent vektörü ile orantılıdır. Bu yüzden $\Delta w_{ji} \approx -\nabla E$, burada ∇E gradyent vektörüdür. Devamında geri yayılım ağların amacı, ağırlıkları aşağıdaki gibi değiştirmektir.

$$\nabla w_{ji} \approx -\frac{\partial E}{\partial w_{ji}} \quad (3.77)$$

Eşitlik 3.77'ye göre ağırlıklara yapılan herhangi bir değişim (Δ), ağırlıklarla ilgili hatanın değişim oranı ile (negatif) orantılıdır.

Şu da belirtilmelidir ki; enerji fonksiyonunun $E(w)$ maksimum negatif değişimin yönünü araştırma yönteminden geri yayılım tekniğinde “steepest descent gradyent tekniği”ne de başvurulur. Eşitlik 3.77, Eşitlik 3.75'teki gibi pratikte kullanılan bir forma çevrilir.

İlk olarak; çıkış katmanı nöronları ile ilişkilendirilmiş ağırlıkların ayarlanmasının tartışılması gerekmektedir. Bu amaçla, genel olarak j . çıkış nöronunun giriş sinyallerinin ağırlıkları toplamının (net değer) tanımı

$$S_j = \sum_{i=1}^J w_{ji} \cdot y_i \quad (3.78)$$

Burada; J , çıkış nöronu j 'ye uygulanan girişlerin sayılarının toplamı, w_{ji} , çıkış düğümü j ve bir önceki katmanın çıkışı y_i sinyali olan i . düğümü arasındaki ağırlıktır.

Bu yüzden; j . nöronun çıkışı

$$o_j = f_j(S_j) = f(S_j) \quad (3.79)$$

Eşitlik 3.79’da fonksiyon f (aktivasyon fonksiyonu), bir sigmoid veya bir radyal fonksiyon olabilir.

Ağırlıklar hata gradyentine uygun olarak uydurulur. w_{ji} ağırlığı, S_j ve çıkış o_j ’yi etkileyerek hatayı etkilediğinden veya matematiksel olarak $E = E(S_j(w_{ji}))$ olduğundan hatanın değişiminin sıralı diferansiyel kural uygulaması şu ifadeyi verir.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial S_j} \frac{\partial S_j}{\partial w_{ji}} \quad (3.80)$$

Eşitlik 3.80’deki çarpımın ikinci terimi ağırlıklar toplamının (S_j) türevidir. $S_j = w_{j1}y_1 + w_{j2}y_2 + \dots + w_{jJ}y_J$ ve $i = 1, 2, \dots, J$ için y_i değerleri girişte sabit bir patern için değişmezdir. Bu yüzden Eşitlik 3.42’den;

$$\frac{\partial S_j}{\partial w_{ji}} = y_i \quad (3.81)$$

Bunu takiben; Eşitlik 3.81, Eşitlik 3.82’de yerine konulur ve çıkan eşitlik, Eşitlik 3.77’de yerine konularak

$$\Delta w_{ji} \approx -\frac{\partial E}{\partial S_j} y_i \quad (3.82)$$

elde edilir. Eşitlik 3.82’deki kısmi türevden kullanışlı bir eşitlik elde etmek için sıralı diferansiyel kuralı Eşitlik 3.83’deki gibi gösterilir. E ’nin S_j ’nin karmaşık fonksiyonu olduğu göz önüne alınırsa $E = E(S_j) = E[o_j(S_j)]$

$$\frac{\partial E}{\partial S_j} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial S_j} \quad (3.83)$$

Tanıma göre, Eşitlik 3.83’ün son terimi aktivasyon fonksiyonunun türevidir.

$$\frac{\partial o_j}{\partial S_j} = f'_j(S_j) \quad (3.84)$$

Eşitlik 3.76 kullanılarak, Eşitlik 3.83’ün sağ yanının ilk kısmı türevinin gösterilmesi de mümkündür.

$$\frac{\partial E}{\partial o_j} = -(d_j - o_j) \quad (3.85)$$

Bunu takiben Eşitlikler 3.83-3.85, Eşitlik 3.82’de yerine konularak

$$\Delta w_{ji} \approx y_i (d_j - o_j) f'_j(S_j) \quad (3.86)$$

veya öğrenme sabiti olarak adlandırılan bir oransallık sabitinin (η) sokulmasıyla oransallık tek bir eşitliğe dönüştürülebilir ve bu aynı zamanda bazen ivmelendirici faktör olarak anılır. Buna göre;

$$\Delta w_{ji} = \eta \cdot y_i (d_j - o_j) f'_j(S_j) \quad (3.87)$$

Eşitlik 3.87 takip eden terimi içermektedir:

$$\delta_j = (d_j - o_j) f'_j(S_j) \quad (3.88)$$

Bu terim, geriyayılım çıkış düğüm eşdeğer hatasıdır (j . düğümün lokal gradyentidir). Bu, hata sinyaline karşılık gelen $(d_j - o_j)$ ve aktivasyon fonksiyonunun türevi $f'_j(S_j)$ 'nin çarpımıdır. Eşitlik 3.88'in Eşitlik 3.87'de yerine konulmasıyla son olarak çıkış katman ağırlığı düzeltme denklemi (delta kuralı) aşağıdaki gibi elde edilir.

$$\Delta w_{ji} = \eta y_i \delta_j \quad (3.89)$$

Bu yüzden bir önceki katmandaki i . düğümünden j . çıkış düğümü arasında işleyen ağırlık, öğrenme katsayısı değeri η (genellikle 0 ile 1 arasında bir sayıdır), düğüm hatası eşdeğeri δ_j ve i . düğümün aktivasyon değeri y_i çarpımlarına eşit miktarda değiştirilmek zorundadır. Bunu takiben de ağırlık güncellenmesi aktivasyon fonksiyonunun türevini gerektirmektedir. Tel kutuplu sigmoid fonksiyon kullanılarak bunun elde edimi çok elverişlidir. Son olarak şu da belirtilmelidir ki; Δw_{ji} kullanılarak yapılan uydurmalarla çıkış katmanı ağırlıkları iterasyonun $(k + 1)$. adımında şu hale gelir:

$$w_{ji}(k + 1) = w_{ji}(k) + \Delta w_{ji} = w_{ji}(k) + \eta \delta_j(k) y_i(k) \quad (3.90)$$

Diğer katmanlar (gizli katmanlar) için ağırlık uydurulmasının elde edilmesinde YSA'nda bir adım geri alınmalıdır. Gizli katmanlar için ağırlık uydurulmasında tekrar negatif eğim formülünden yararlanılacaktır. Bununla birlikte, şu da belirtilmelidir ki; bir gizli nöron için bilinen arzulanan cevap yoktur. Bu yüzden gizli nöron için hata sinyali, gizli nöronun bağlı olduğu tüm çıkış nöronlarının hata sinyallerinin toplamı olarak belirlenmelidir. Bunun için geriyayılım algoritması, çıkış nöronlarına göre gizli nöronlar için daha karmaşıktır.

Bir gizli nöron için ağırlık uydurulmasının elde edilmesi amacı için Şekil 3.22'de gösterilen genel bir çıkış katmanındaki j . düğüm ile genel bir önceki katmandaki (gizli katman) i . düğüm dikkate alınacaktır. Gizli katmandan önceki katmandaki bir genel düğüm h . düğüm ve bu yüzden h düğümü ve i düğümü arasında genel ağırlık w_{ih} 'tir.

j . ve i . düğüm arasındaki ağırlık w_{ji} için ağırlık uydurulmasının elde edilmesinin formülü yukarıda tartışılmıştır. Şimdi w_{ih} 'ın ağırlık uydurulmasının formülü benzer bir yolla elde edilecektir. Eşitlik 3.90 ile aynı şekilde, saklı katmanlar nöronları için negatif gradyent şu şekilde olmaktadır.

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial w_{ih}} \quad (3.91)$$

Bununla birlikte, sıralı diferansiyel kuralı kullanılarak;

$$\frac{\partial E}{\partial w_{ih}} = \frac{\partial E}{\partial S_i} \frac{\partial S_i}{\partial w_{ih}} \quad (3.92)$$

elde edilir. Burada S_i , saklı nöron i 'ye giren sinyallerin ağırlıklar toplamıdır. Eşitliğin sağ yanının ikinci terimi, h . düğümün giriş sinyaline y_h eşittir. Bunlara göre;

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial S_i} y_h = \eta \delta_{yi} y_h \quad (3.93)$$

Burada saklı katmanın i . nöronunun neden olduğu δ_{yi} hata sinyali;

$$\delta_{yi} = -\frac{\partial E}{\partial S_i} \quad (3.94)$$

Sadece çıkış nöronlarını etkileyen çıkış katman nöronunun net çıkışıyla karşılaştırılmasında; net değeri S_i şimdi Eşitlik 3.76 ile verilen K terim içeren hata toplamının her ögesine katkıda bulunmaktadır. Sıralı diferansiyel kuralı kullanılarak;

$$\delta_{yi} = -\frac{\partial E}{\partial S_i} = -\frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial S_i} \quad (3.95)$$

Burada eşitliğin sağ tarafındaki çarpımın ilk terimi şu formu alır.

$$\frac{\partial E}{\partial y_i} = \sum_{j=1}^K \frac{\partial E}{\partial y_j} f'_j(S_j) \frac{\partial S_j}{\partial y_i} = \sum_{j=1}^K (y_j - d_j) f'_j(S_j) \frac{\partial S_j}{\partial y_i} = \sum_{j=1}^K (y_j - d_j) f'_j(S_j) \sum_{j=1}^K w_{ji} = -\sum_{j=1}^K \delta_j w_{ji} \quad (3.96)$$

Eşitliğin sağ tarafındaki çarpımın ikinci terimi ise;

$$\frac{\partial y_i}{\partial S_i} = f'_i(S_i) \quad (3.97)$$


Bu yüzden Eşitlikler 3.93-3.97 göz önünde bulundurularak ağırlık uydurulması aşağıdaki gibi elde edilir.

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial w_{ih}} = \eta \delta_{yi} y_h = \eta f'_i(S_i) \left(\sum_{j=1}^K \delta_j w_{ji} \right) y_h \quad (3.98)$$

Bu, Eşitlik 3.98 ile hem fikir olunduğu yerde, genelleştirilmiş delta kuralı olarak adlandırılır.

$$\delta_j = (d_j - y_j) f'_j(S_j) \quad (3.99)$$

Eşitlik 3.99, eşdeğer çıkış düğüm hatasıdır.



Şekil 3.35. Çok Katmanlı Bir Ağ İçin Geri yayılım Akış Şeması

Böylelikle çıkış katmanından başka katmanlar için, önceki katmandaki h düğümü ile gizli katmandaki i düğümü bağlı olduğu zaman Δw_{ih} ağırlık uydurulmasının Eşitlik 3.98 kullanılarak yerine getirileceği sonucuna varılmıştır.

Burda öğrenme oranı (η), h . düğümün çıkış sinyali (aktivasyon sinyali) (y_h) ile ve genel hata $\delta_{yi} = f'_i(S_i) \sum_j \delta_j w_{ji}$ ile çarpılır. δ_{yi} ifadesinden Eşitlik 3.98 ile tanımlanan j çıkış düğümü eşdeğer hatası δ_j 'yi de içerdiği görülmektedir. Eşitlik 3.99 daki d_j ve y_j sırasıyla YSA'nın j . düğümünün arzulanan çıkış ve gerçek çıkışıdır. Bir i . gizli katman nöronu ile bir önceki düğümü (h .) bağlayan ağırlığın uydurulması, düğümlerin bitişikteki takip eden katmanlarının tüm δ_j değerlerinin (eşdeğer hataları) ağırlıkları toplamı ile oransaldır diye ifade edilebilir. Şekil 3.35'te çok katmanlı bir YSA için geri yayılım algoritmasının akış şeması verilmiştir.

3.2.4. Sayısal Hızlandırma Teknikleri

Yukarıda bahsedilen geri yayılım tekniği uygulandığında iyi bir yakınsama elde edilir. Bununla birlikte, pratikte bir YSA çoğu kez yavaş öğrenir veya bütünüyle öğrenmeyi reddeder. Bu meydana geldiği zaman, sayısal hızlandırma tekniklerinden biri kullanılmalıdır. Popüler tekniklerden bazıları şunlardır: Momentum metodu, topoloji uydurulması, dinamik öğrenme.

3.2.4.1. Momentum Metodu

Geri yayılım algoritması adım adım azalan bir metottur. Bununla birlikte, eğer lokal minima başlangıç noktası ile optimal çözüm arasında olmakta ise adım adım azalma metotları problemlere eğilimlidirler. Bu hemen hemen her zaman YSA'nda az gizli nöron olması durumuna bağlıdır.

Geri yayılımın bir noktaya yönelmesi olarak eğer bu yerel minima noktasına rastlamış ise bu onun öğrenme oranını azaltacaktır ve öğrenme bir düzeyde tamamen duracaktır. Bu kabul edilemez ve bu davranış öğrenme eğrisi tarafından gösterilir. Momentum Metodu olarak isimlendirilen başarılı bir teknik yerel minimaya bağlı bu zorlukların üstesinden gelmektedir. Bu durumda şu anki (k .) ağırlık uydurulması, en son ($k-1$.) ağırlık uydurulmasının bir kısmı ile eksikleri giderilebilir. Bu kısım Momentum Terimi olarak isimlendirilir.

$$\Delta w_{ji}^{\text{modified}}(k) = \Delta w_{ji}(k) + \alpha \Delta w_{ji}(k-1) \quad (3.100)$$

Burada $\Delta w_{ji}(k)$ daha önceki bölümlerde tartışılan $-\eta(\partial E/\partial w_{ji})$ 'den elde edilen ağırlık düzeltilmesidir ve $\alpha \Delta w_{ji}(k-1)$ momentum terimidir. Eşitlik 3.100' de α momentum katsayısı 0 ile 1 aralığındadır.

3.2.4.2. Topoloji Uydurulması


Bazı zamanlar hiç bir sayısal hızlandırma tekniği YSA'nın öğrenmesinde yardımcı olamayabilir. Bu durumlarda, çözüm iç bağlantıların sayılarının, aktivasyon fonksiyonunun değiştirilmesi ile elde edilir. Bununla birlikte, doğrudan gerekli sayıları belirleyebilecek herhangi bir teknik yoktur. İç bağlantılar eklemek bazı zamanlar, rastlanan yerel minima sayısının azaltılmasında etkilidir. Bununla birlikte, iç bağlantılarının sayılarının artırılması genel hesaplama zamanını da artıracaktır.

3.2.4.3. Dinamik Öğrenme

Öğrenme katsayısı (η)'nın geriyayılım algoritmasının etkinliğinde ve yakınsamasında direkt ve dikkate değer bir etkisi vardır. Genelde, öğrenme katsayısının optimum değeri çözülecek problem tipine bağlıdır. Eğitim başladığı zaman, çoğu kez küçük öğrenme katsayısı kararsız YSA'dan kaçınılması için gereklidir. Bununla birlikte, daha sonraları, ağ bir çözüme ulaştığı görülürse, daha yüksek öğrenme katsayısı kullanılabilir (Vas,1999).

4. BULGULAR VE TARTIŞMA

Bu çalışmada kullanılan EEG işaretleri; MIT(Massachusetts Institute of Technology) - BIH veri tabanından elde edilmiş olup; işaretlerin, yaşları 21 ile 35 arasında değişen deneklerden alındıklarını bilmekteyiz. Denekler nörolojik elemenden geçirildikten ve herhangi bir zihinsel bozuklukları olmadığı tespit edildikten sonra bu çalışmaya dahil edilmişlerdir. Bütün kayıtlar tıbbi standartlara uygun şekilde yapılmıştır. Denekler uykusuz bırakılmamış ve uyuşturucu içeren ilaçlar veya alkol almamışlardır. EEG kayıtları uzmanlar tarafından yapıp, toplamda 6 saat 20 dakikalık kayıt mevcuttur.




Şekil 4.1. EEG çekimi


Şekil 4.1. de örnekleme frekansı 100 Hz olan 30 sn. lik bir EEG çekimi gösterilmiştir. EEG çekimleri esnasında elde edilen işaretlerin tamamı beynin elektriksel aktivitesinden gelen işaretler değildir. Kayıtlarda diğer kaynaklardan gelen potansiyelleri de görmek mümkündür.

Artifakt olarak adlandırılan bu hatalar ölçüm düzeneğinden kaynaklanan hatalar (teknik hatalar; ülkemizde 50 Hz' lik şebeke gürültüsü, elektrod yerleşiminden kaynaklanan hatalar v.b), veya hastanın kendisinden kaynaklanan hatalar (fizyolojik hatalar; ölçüm esnasında hastanın hareket etmesi, heyecanlanması, göz kırpması, terlemesi gibi durumlarda oluşan gürültüler) olabilir.


Bu artifaktlar kaynaklanma sebebine göre çeşitli yöntemlerle esas EEG işaretinden ayrıştırılabilir.



Şekil 4.2. Uyanık EEG işareti




Şekil 4.3. Uyuklama evresinde EEG işareti




Şekil 4.4. Uyku evresinde EEG işareti


İşaretleri, ADD uygulayarak δ (1-4 Hz), θ (4-8 Hz), α (8-13 Hz) ve β (13-30 Hz) alt bantlarına indirgersek;



Şekil 4.5. Daubechies 4 Dalgacığı ile ADD uygulanmış uyanık EEG işareti



Şekil 4.6. Daubechies 4 Dalgacığı ile ADD uygulanmış uyıklama EEG' si




Şekil 4.7. Daubechies 4 Dalgacığı ile ADD uygulanmış uyku EEG' si

Bu çalışmada sınıflandırma yapılırken, MATLAB komut penceresi ve grafik uygulamalarından faydalanılarak, spektral analiz yapılmamış(ham) EEG işareti ile, dalgacık analizine tabi tutularak alt bantlarına ayrılmış işaret kullanılarak, sınıflandırma sonuçları karşılaştırılmıştır. Ayrıca sinir ağı mimarilerinden olan LVQ modelinin sınıflandırma için nasıl sonuçlar verdiği ortaya konulmuştur.

Sınıflandırma için oluşturulan sinir ağı mimarisi; 20 nöronlu bir gizli katman ve bir çıkış katmanı olan 3 katmanlı ileri beslemeli bir yapıya sahiptir. Eğitim algoritması olarak çok katmanlı algılayıcı ve LVQ kullanılmış olup, ÇKA için gizli katman ve çıkış katmanında aktivasyon fonksiyonu olarak sırasıyla doğrusal ve hiperbolik tanjant aktivasyon fonksiyonları kullanılmıştır. Bu yapı, ÇKA mimarisinde pek çok denemeden sonra elde edilmiş en iyi sonuç veren yapıdır.

Çıkış katmanında istenen değerler uyanıklık [1 0 0], uyuklama [0 1 0] ve uyku [0 0 1] vektörleri ile ifade edilmiştir.




Şekil 4.8. Çok katmanlı sinir ağı modeli

İlk olarak giriş vektörleri ham data kullanılarak oluşturulmuş ve ağ ÇKA algoritmalarından BGD(Batch Gradient Descent- Batch Grdayent Azaltma) ile eğitilmiştir.

Şekil 4.9.' da eğitim grafiği görülen ağ yapısı için hata değeri 10^{-15} olarak seçilmiş ve 12204. denemede bu değere ulaşarak eğitim tamamlanmıştır. Test aşamasında, ağa daha önce gösterilmeyen veriler gösterilmelidir. Bu amaçla toplam verinin %20 si test aşamasında kullanılmıştır.

Ağın performansı test edildiğinde;

$$\text{Performans} = (\text{Doğru sonuç sayısı} / \text{Toplam test verisi sayısı}) * 100$$




Şekil 4.9. Ham data için BGD eğitim grafiği

Çizelge 4.1. Yapay sinir ağının ham data girişine karşı performansı(BGD ile)

	Performans (%)
Uyanık	99.9
Uyuklama	99.7
Uyku	99.8

Aynı ağ mimarisini, ADD yapılmış veri ile bir giriş vektörü oluşturarak eğitip test ettiğimizde;




Şekil 4.10. ADD yapılmış girişler ile BGD eğitim grafiği

Şekil 4.10.' da görüldüğü gibi istenilen hata değerine 22742. denemede ulaşılmıştır. Ağın daha uzun sürede ve daha fazla deneme yaparak istenilen hata değerine ulaştığı görülmektedir. Bu, şimdilik ağın daha başarısız olduğu anlamına gelmez. Ama test sonuçları da ham datanın daha iyi bir eğitim sağladığını göstermektedir.

Çizelge 4.2. Ağın ADD uygulanmış sinyal girişine karşı performansı

	Performans (%)
Uyanık	99
Uyuklama	99.3
Uyku	99.5


Yine ham data için ÇKA algoritmalarından BGDM (Batch Gradient Descent with Momentum- Batch Gradient Azaltma ve Momentum) kullanılarak ağ eğitilmiştir.




Şekil 4.11. Ham data BGDM algoritması eğitim eğrisi

Bu durumda hata değeri 10^{-17} olup 26458. denemede bu değere ulaşılmıştır. Performansta herhangi bir azalma görülmemiş hemen hemen aynı doğruluk değerleri gözlemlenmiştir. Aynı şekilde RP (Resilient Backpropagation – Esnek Geri yayılım) ve CG (Conjuge Gradient- Gradyent Çekilmesi) (gradyentin negatife çekilmesi) algoritmaları ile eğitim sağlanarak hemen hemen aynı performansı gösterdiği gözlemlenmiştir.

Şekil 4.12.' de spektral analiz yapılmış veriler için RP ve CG Algoritmalarının eğitim eğrileri verilmiştir. Bu eğrilerden anlaşıldığı üzere RP algoritmasının uygulandığı ağ yapısı maksimum gradyent değerine ulaşıldığı için hata değerine ulaşılmadan eğitimi durdurmuştur. Ağın performansını yine %98' den aşağıya inmediği gözlemlenmiştir.




Şekil 4.12. ADD uygulanmış veriler için RP algoritmasının eğitim eğrisi



Şekil 4.13. ADD uygulanmış veriler için CG algoritmasının eğitim eğrisi

Genel olarak sınıflandırma problemlerinin çözümünde kullanılan LVQ ağ yapısı kullanıldığında Şekil 4.13.' teki eğitim eğrisi elde edilmiştir.



Şekil 4.14. LVQ eğitim eğrisi

Bu ağ yapısında çıktılarından sadece biri 1 diğerleri 0 değerlerini almaktadır. Çıktı değerlerinin 1 olması girdinin ilgili çıktının temsil ettiği sınıfa ait olduğunu göstermektedir. Kullanılan öğrenme stratejisi destekleyici (reinforcement learning) öğrenme stratejisidir. Ağ eğitilirken her iterasyonda ağın ürettiği çıktının değeri yerine sadece doğru olup olmadığı söylenir. Gizli katman (kohonen katmanı da denmektedir) ile çıktı katmanı arasındaki ağırlık değerleri sabit olup 1' e eşittir. Sadece girdi katmanı ile gizli katman arasındaki ağırlıklar değiştirilir.

Eğitim eğrisinden de anlaşıldığı gibi LVQ ağları ÇKA ağlarından çok daha kısa sürede öğrenebilmekte, sınıflandırma problemi için de çok iyi performans göstermektedir.

Çizelge 4.3. LVQ ağ yapısının performansı

	Performans (%)
Uyanık	99.4
Uyuklama	99.9
Uyku	99.8

5. SONUÇ VE ÖNERİLER

Sınıflandırma işlemi, en genel haliyle bir karar verme mekanizmasıdır. Bu çalışmada EEG işareti gibi durağan olmayan rasgele işaretleri, uyanıklık, uyuklama ve uyku hallerinde gösterdikleri (hem zaman- genlik domeninde, hem de dalgacık dönüşümü ile elde ettiğimiz zaman-ölçek domeninde gözlemlenen) farklılıklar değerlendirilip yapay sinir ağları kullanılarak bilgisayar destekli bir otomatik sınıflandırma yapmak amaçlanmıştır.

Yapay sinir ağları gibi öğrenme yöntemleri örneklerden öğrenmeye dayanmaktadır. Örneklerden öğrenmenin temel felsefesi bir olay hakkındaki gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve bu ilişkilere göre daha sonra oluşacak olan yeni örneklerin çıktılarını belirlemektir. Burada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir. Değişik örneklerin olayı değişik açılardan temsil ettiği varsayılmaktadır. Farklı örnekler kullanılarak böylece olay değişik açılardan öğrenilmektedir. Burada bilgisayara sadece örnekler gösterilmektedir. Bunlardan başka herhangi bir ön bilgi verilmektedir. Öğrenmeyi gerçekleştirecek olan sistem(bu çalışmada yapay sinir ağı) aradaki ilişkiyi kendi algoritmasını kullanarak keşfetmektedir.

Elde edilen bulguların grafiklerinden de anlaşılabacağı üzere sinir ağının sınıflandırma probleminde kullanılması özellikle de LVQ ağlarında başarı ile sağlanmıştır. LVQ ağlarının hızlı ve doğru öğrenmesi dikkat çekmiştir. Sinir ağının öğrenme katsayısı, aktivasyon fonksiyon değerleri gizli katman sayısı ve saklı katman nöron sayısının değişimlerine göre sinir ağının performansı değişmektedir. Bu değerler deneysel sonuçlara göre optimal duruma getirilmiştir.

Ham EEG verisinin sınıflandırmada daha iyi sonuç vermesi tıbbi tanı açısından gerçek zamanlı çalışmalarda umut verici olmuştur. Fakat DD ile işaretin zaman- ölçek domeni analizi de pratik bir şekilde elde edilebilmekte ve bu sayede sinyal bilgi kaybına uğratılmadan, sinyalde işlenmemiş haldeki verilerden sağlıklı seçilemeyen kimi detay bilgilerine ulaşılmaktadır. Bu yöntem değişik problemlerin çözülmesinde faydalı olabilecek bir yöntemdir. Sinyalin pencereleme aralığının değiştirilebilir olma özelliğinin, özellikle keskin sıçramaların ve süresizliklerin meydana geldiği durumları çözümlemek için oldukça etkili olmasının sinyal işleme açısından önemi düşünüldüğünde, yöntemin kullanılmasının faydaları daha iyi anlaşılabilir.

Yapay sinir ağları tabanlı sınıflandırma sistemlerinde çeşitli YSA mimarileri oluşturularak uygun YSA mimarileri seçilebilir. Bu YSA mimarilerine göre sistemin performansının değişeceği göz önünde tutulmalıdır.

Kullanılan mimaride öğrenme katsayısı, momentum sabiti gibi parametrelerin ayarlanarak sistem optimum şekle getirildiği gibi, sistem performansının artışı için sayısal hızlandırma metotlarından dinamik öğrenme metodu kullanılabilir. Bunun yanı sıra kullanılan aktivasyon fonksiyon ve parametrelerinin değişimleri ile de performans artışı mümkündür. LVQ ağlarının performansını artırma yönünde çalışmalar yapılabilir.

EKLER

Ysa Ve DD Matlab Yazılımları

%Ham Eeg İşaretlerini Uyku-Uyuklama-Uyanık Durumları İçin %Yapay Sinir Ağı Kullanarak Sınıflandıran Program

load DATA %verileri yükler

P=[a1 a2 a3 a4 a5 a6 a8 a8 a9 a10 a11 a12 a13 a14 a15 a16 a17 a18 a19 a20 d1 d2 d3 d4 ...d5 d6 d7 d8 d9 d10 d11 d12 d13 d14 d15 d16 d17 d18 d19 d20 s1 s2 s3 s4 s5 s6 s7 s8 s9 s10 s11 s12 s13 s14 s15 s16 s17 s18 s19 s20];

[illegible]

```
net=newff(minmax(P),[20,3],{'tansig','purelin'},'traingdm');
net=init(net);
net.trainParam.show = 200;
net.trainParam.lr = 0.05;
net.trainParam.epochs = 30000;
net.trainParam.goal = 1e-15;
[net,tr]=train(net,P,T);
```

%Ayrık Dalgacık Dönüşümü Yapan Program

```
load data;
s=a1(1:750);
l_s=length(s);
[C,L]=wavedec(s,4,'db1');
cA4=appcoef(C,L,'db1',4);
cD4=detcoef(C,L,4);
cD3=detcoef(C,L,3);
cD2=detcoef(C,L,2);
cD1=detcoef(C,L,1);
A4=wrcoef('a',C,L,'db1',4);
D1=wrcoef('d',C,L,'db1',1);
D2=wrcoef('d',C,L,'db1',2);
D3=wrcoef('d',C,L,'db1',3);
D4=wrcoef('d',C,L,'db1',4);
subplot(2,3,1);plot(A4);
title('Approximation A4');
subplot(2,3,2);plot(D1);
title('Detail D1');
subplot(2,3,3);plot(D2);
```

```

title('Detail D2');
subplot(2,3,4);plot(D3);
title('Detail D3');
subplot(2,3,5);plot(D4);
title('Detail D4');
%sinyalin yeniden oluşturulması
A0=waverec(C,L,'db1');
err=max(abs(s-A0));
%err=4.5475e-0.13
subplot(2,3,6);plot(A0);
title('reconstruct s');

```

%Ayrık Dalgacık Dönüşümü Uygulanmış Sinyali Yapay Sinir Ağının %Girişi İçin Kullanan Program

```

load data;
A={a1 a2 a3 a4 a5 a6 a8 a8 a9 a10 a11 a12 a13 a14 a15 a16 a17 a18 a19 a20 d1 d2 d3 d4
...d5 d6 d7 d8 d9 d10 d11 d12 d13 d14 d15 d16 d17 d18 d19 d20 s1 s2 s3 s4 s5 s6 s7 s8
.....s9 s10 s11 s12 s13 s14 s15 s16 s17 s18 s19 s20};

for j=1:60
    i=1;
    R=A{i,j};
    s=R(1:750)
    l_s=length(s);
    [C,L]=wavedec(s,4,'db1');
    cA4=appcoef(C,L,'db1',4);
    cD4=detcoef(C,L,4);
    cD3=detcoef(C,L,3);
    cD2=detcoef(C,L,2);
    cD1=detcoef(C,L,1);
    A4=wrcoef('a',C,L,'db1',4);
    D1=wrcoef('d',C,L,'db1',1);
    D2=wrcoef('d',C,L,'db1',2);
    D3=wrcoef('d',C,L,'db1',3);
    D4=wrcoef('d',C,L,'db1',4);
    Y=[A4;D4;D3;D2];
    G{i,j}=Y;
end
P=[G{1,1} G{1,2} G{1,3} G{1,4} G{1,5} G{1,6} G{1,7} G{1,8} G{1,9} G{1,10}
...G{1,11} G{1,12} G{1,13} G{1,14} G{1,15} G{1,16} G{1,17} G{1,18} G{1,19}
...G{1,20} G{1,21} G{1,22} G{1,23} G{1,24} G{1,25} G{1,26} G{1,27} G{1,28}
...G{1,29} G{1,30} G{1,31} G{1,32} G{1,33} G{1,34} G{1,35} G{1,36} G{1,37}
...G{1,38} G{1,39} G{1,40} G{1,41} G{1,42} G{1,43} G{1,44} G{1,45} G{1,46}
...G{1,47} G{1,48} G{1,49} G{1,50} G{1,51} G{1,52} G{1,53} G{1,54} G{1,55}
...G{1,56} G{1,57} G{1,58} G{1,59} G{1,60}];

```

[illegible]

```
net=newff(minmax(P),[20,3],{'tansig','purelin'},'traingdm');
net=init(net);
net.trainParam.show = 200;
net.trainParam.lr = 0.05;
net.trainParam.epochs = 60000;
net.trainParam.goal = 1e-15;
[net,tr]=train(net,P,T);
```

```
%Conjuge Gradient Algorithm Kullanan Ysa Programı
```

[illegible]

```
1 ...11111000000000000000000000;0000000000000000000000  
00 ...000000000000000000001111111111111111111];  
net=newff(minmax(P),[21,3],{'tansig','purelin'},'traincgf');  
net=init(net);  
net.trainParam.show = 200;  
net.trainParam.epochs = 10000;  
net.trainParam.goal = 1e-10;  
[net,tr]=train(net,P,T);
```

%Adaptive Gradient Descent Algorithm

[illegible]

%Resilient Backpropagation Algorithm With Discrete Wavelet %Analysis

84

%%Lvq Ağ Yapısı İle Eğitim

load lvqdata

P=[a1 a2 a3 a4 a5 a6 a7 a8 a9 a10 a11 a12 a13 a14 a15 d1 d2 d3 d4 d5 d6 d7 d8 d9 d10
d11 d12 d13 d14 d15 d16 d17 d18 d19 d20 s1 s2 s3 s4 s5 s6 s7 s8 s9 s10 s11 s12 s13 s14
s15];

Tc=[1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 3 3 3 3 3 3 3 3 3
3 3 3 3];

T = ind2vec(Tc)

targets = full(T)

net = newlvq(minmax(P),21,[.3 .4 .3]);

net=init(net);

net.trainParam.show = 200;

net.trainParam.lr = 0.05;

net.trainParam.epochs = 30000;

net.trainParam.goal = 1e-5;

net = train(net,P,T);

KAYNAKLAR

- ANDERSON, C.W., DEVULAPALLI, S. V. & STOLZ, E. A. (1995). Determining mental state from EEG signals using neural networks. Scientific Programming, 4: 171–183.
- ANONİM. 1997. National Instrument Kataloğu
- BAŞA, H. 1996. EEG Dalgalarının Spektral Analiz Yöntemleriyle İşlenmesi. K.S.Ü. Yüksek Lisans Tezi, Kahramanmaraş (Yayınlanmamış)
- DAUBECHIES, I., RUNBORG, O., SWELDENS, W. 2002. Normal Multiresolution Approximation Of Curves.
[Http://Cm.Bell-Labs.Com/Who/Wim/Papers/Normalcurve/Normalcurve.Pdf](http://Cm.Bell-Labs.Com/Who/Wim/Papers/Normalcurve/Normalcurve.Pdf)
- FLIEGE, N. J. 1996. Multirate Digital Signal Processing (Multirate Systems-Filter Banks-Wavelets). John Wiley & Sons, Chichester, s. 251
- FOMITCHEV, M. 1994. An Introduction To Wavelets And Wavelets Transforms. Systems And Programming Inc., Tulsa.
- GABOR, A. J., LEACH, R. R. & DOWLA, F. U. (1996). Automated seizure detection using a self-organizing neural network. Electroencephalography and Clinical Neurophysiology, 99: 257-266.
- GOTO, S., NAKAMURA, M. & UOSAKI, K. (1995). On-line spectral estimation of nonstationary time series based on ar model parameter estimation and order selection with a forgetting factor. IEEE Transactions on Signal Processing, 43: 1519–1522.
- GRAP, A. 1995a. An Introduction To Wavelets. IEEE Computational Science And Engineering, 2(2)
- GRAP, A., 1995b. An Introduction To Wavelets.
[Ftp://Ftp.Best.Com/Pub/Agraps/Papers/Ieeewavelet.Ps.Gz](http://Ftp.Best.Com/Pub/Agraps/Papers/Ieeewavelet.Ps.Gz)
- GULER, I., KIYMIK, M. K., AKIN, M. & ALKAN, A. (2001). AR spectral analysis of EEG signals by using maximum likelihood estimation. Computers in Biology and Medicine, 31: 441-450.
- HASELSTEİNER, E.& PFURTSCHELLER, G. (2000) Using time-dependent neural Networks for EEG classification. IEEE Trans Rehab Eng, 8: 457–63.
- JAWERT, B., SWELDENS, W., 1992. An Overview Of Wavelet Based Multiresolution Analysis. [Http://Cm.Bell-Labs.Com/Who/Wim/Papers/Overview.Pdf](http://Cm.Bell-Labs.Com/Who/Wim/Papers/Overview.Pdf)

- KALAYCI, T. & ÖZDAMAR, O. (1995). Wavelet preprocessing for automated neural network detection of EEG spikes. IEEE Engineering in Medicine and Biology Magazine, 16: 0–166.
- MINER, N.E. 1998. An Introduction to Wavelet Theory and Analysis. Sandia Report, NM, October: 1-25.
- OSARIO, I., FREI, M. G., & WILKINSON, S. B. (1998). Real-time automated detection and quantitative analysis of seizures and short-term prediction of clinical onset. Epilepsia, 39: 615-627.
- OZTEMEL, E (2003) . Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, s. 238
- PAPOULIS, A. 1984. Signal Analysis. McGraw-Hill International Editions, New York.
- PATI, Y.C., KRISHNAPARASAD, P.S. (1993). Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations. IEEE Trans. Neural Networks, 4 (1): 73-85.
- PETROSIAN, A., PROKHOROV, D., HOMAN, R., DASHEI, R., WUNSCH, D. (2000). Recurrent neural network based prediction of epileptic seizures in intra- and extracranial EEG. Neurocomputing 30: 201-218.
- POLIKAR, R. 1999. The Engineer's Ultimate Guide To Wavelet Analysis The Wavelet Tutorial.
[Http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html](http://Engineering.Rowan.Edu/~Polikar/Wavelets/Wtpart3.Html)
- PRADHAN, N., SADASIVAN, P. K. & ARUNODAYA, G. R. (1996). Detection of seizure activity in EEG by an artificial neural network: A preliminary study. Computers and Biomedical Research, 29: 303-313
- QUSSAR, Y., DREYFUS, G. (2000). Initialization by selection for wavelet network training. Neurocomputing, 34: 131-143
- ROBERTS, R. A., MULLIS, C.T. 1987. Digital Signal Processing. Addison-Wesley Publishing Company, USA, s. 85-86
- SWELDENS, W. 1994. Wavelet Sampling Technics.
[Http://W3.Nai.Net/~Alokaeng/Wavelet/Sampling.Pdf](http://W3.Nai.Net/~Alokaeng/Wavelet/Sampling.Pdf)
- SURESHBABU, A., FARRELL, J.A. (1999). Wavelet-based system identification for nonlinear control. IEEE Trans. Autom. Control 44 (2): 412–417.
- TORRENCE, C., COMPO, P.C. (1998) A Practical Guide To Wavelet Analysis. Bulletin Of American Meteorological Society, 79(1):61-78.
- TSENG, S-Y., CHEN, R-C., CHONG, F-C., KUO, T-S. (1995). Evaluation of parametric methods in EEG signal analysis. Medical Engineering And Physics, 17: 71–78.

- TSOI, A. C., SO, D. S. C., SERGEJEW, A. (1994). Classification of electroencephalogram using artificial neural networks. In Jack D. Cowan, Gerald Tesauro, and Joshua Alspector, (Eds.), *Advances in Neural Information Processing Systems 6*, (pp. 1151–1158). Morgan Kaufmann.
- VUCKOVIC, A., RADIVOJEVIC, V. A., CHEN, C. N., POPOVIC, D. (2002). Automatic recognition of alertness and drowsiness from EEG by an artificial neural network. *Medical Engineering & Physics* 24: 349–360.
- WENG, W., KHORASANI, K. (1996). An adaptive structure neural network with application to EEG automatic seizure detection. *Neural Networks*, 9: 1223-1240.
- WEBBER, W. R. S., LESSER, R. P., RICHARDSON, R. T., WILSON, K. (1996). An approach to seizure detection using an artificial neural network (ANN). *Electroencephalography and Clinical Neurophysiology*, 98: 250-272.
- WONG, K., LEUNG, A. (1998). On-line successive synthesis of wavelet networks. *Neural Processing Letters*, 7: 91–100.
- XU, J., HO, D. W.C. (2002). A basis selection algorithm for wavelet neural Networks. *Neurocomputing*, 48: 681–689
- YAZGAN, E. KORUREK, M. (1996). *Tıp Elektroniği*, İTÜ Matbaası, s.220
- ZHANG, Q. (1997). Using wavelet network in nonparametric estimation. *IEEE Trans. Neural Networks*, 8 (2): 227–236.
- ZHANG, Q., BENVENISTE, A. (1992). Wavelet networks. *IEEE Trans. Neural Networks*, 3 (6): 889-898.
- ZHANG, J., WALTER, G.G., Lee, W. (1995). Wavelet neural networks for function learning. *IEEE Trans. Signal Process*, 43 (6): 1485–1497.
- ZOUBIR, M., BOASHASH, B. (1998). Seizure Detection of Newborn EEG Using a Model Approach. *IEEE Transactions on Biomedical Engineering*, 45: 673-685.

ÖZGEÇMİŞ

1980 yılında Kars’ ta doğdu. İlk öğrenimini Kayseri ve Elazığ’ da, orta ve lise öğrenimini Malatya’ da tamamladı. 2002 yılında Kahramanmaraş Sütçü İmam Üniversitesi Elektrik- Elektronik Mühendisliği Bölümünden mezun oldu. Aynı yıl K.S.Ü. Elektrik-Elektronik Anabilim Dalında yüksek lisans öğrenimine başladı. 2003 yılında aynı üniversitede Fen Bilimleri Enstitüsüne bağlı araştırma görevlisi oldu.