

**BİYOMEDİKAL İŞARETLERİN
YENİ BİR ADAPTİF AKTİVASYON
FONKSİYONLU YAPAY SİNİR AĞI İLE
SINIFLANDIRILMASI**

Gülay TEZEL
Doktora Tezi

Elektrik-Elektronik Mühendisliği Anabilim Dalı
Konya, 2007

T.C
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BİYOMEDİKAL İŞARETLERİN YENİ BİR ADAPTİF
AKTİVASYON FONKSİYONLU YAPAY SİNİR AĞI İLE
SINIFLANDIRILMASI**

Gülay TEZEL

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Konya, 2007

T.C
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

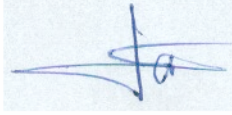
**BİYOMEDİKAL İŞARETLERİN YENİ BİR ADAPTİF
AKTİVASYON FONKSİYONLU YAPAY SİNİR AĞI İLE
SINIFLANDIRILMASI**

Gülay TEZEL

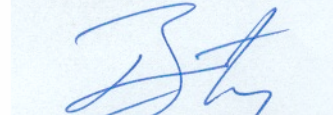
DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

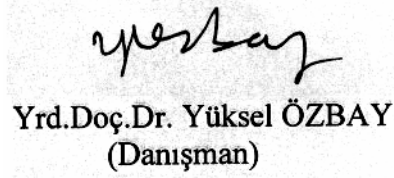
Bu tez 10.08.2007 tarihinde aşağıdaki jüri tarafından oybirliği /oyçokluğu ile kabul edilmiştir



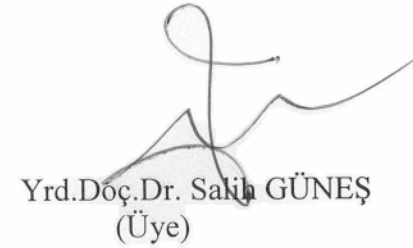
Prof.Dr. Ahmet ARSLAN
(Üye)



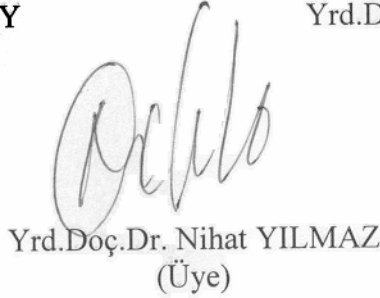
Prof.Dr. Bekir KARLIK
(Üye)



Yrd.Doç.Dr. Yüksel ÖZBAY
(Danışman)



Yrd.Doç.Dr. Salih GÜNEŞ
(Üye)



Yrd.Doç.Dr. Nihat YILMAZ
(Üye)

ÖZET

Doktora Tezi

BIYOMEDİKAL İŞARETLERİN YENİ BİR ADAPTİF AKTİVASYON FONKSİYONLU YAPAY SİNİR AĞI İLE SINIFLANDIRILMASI

Gülay TEZEL

Selçuk Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd.Doç.Dr. Yüksel ÖZBAY

2007, 162 Sayfa

Jüri: Prof.Dr. Ahmet ARSLAN
Prof.Dr. Bekir KARLIK
Yrd.Doç.Dr. Yüksel ÖZBAY
Yrd.Doç.Dr. Salih GÜNEŞ
Yrd.Doç.Dr. Nihat YILMAZ

Bu tez çalışmasında, yeni bir yapay sinir ağı (YSA) yaklaşımı olarak, gizli katman düğümlerinde serbest parametrelili adaptif aktivasyon fonksiyonu kullanan adaptif aktivasyon fonksiyonlu YSA (AAFYSA) algoritması tasarlanmıştır. Tasarımı yapılan bu algoritma geliştirilmiş, Matlab programlama dili ile üç tane AAFYSA modellerinin (AAFYSA-1, AAFYSA-2 ve AAFYSA-3) ve geleneksel çok katmanlı YSA (ÇKYSA) algoritmasının yazılımı gerçekleştirilmiştir. ÇKYSA yazılımının yapılmasında AAFYSA ile eşit koşullarda karşılaştırma amaçlanmıştır. AAFYSA ve ÇKYSA yazılımlarının gerçekleştirilmesinde, YSA formülasyonlarına uygun biçimde yeniden komutlar ve fonksiyonlar oluşturularak programları yazılmıştır. AAFYSA modelleri arasındaki fark gizli katmanlarında kullanılan adaptif aktivasyon fonksiyonlarıdır. AAFYSA-1 modelinin gizli katman düğümlerinde serbest parametrelili sigmoid fonksiyonu, AAFYSA-2 modelinin gizli katman düğümlerinde ise serbest parametrelili sigmoid fonksiyonu ile serbest parametrelili sinüs fonksiyonunun toplamı kullanılmıştır. Morlet dalgacık fonksiyonuna serbest parametreler ekleyerek YSA'nın aktivasyon fonksiyonu olarak kullanma fikri ilk defa bu çalışmada ileri sürülerek AAFYSA-3 modelinin gizli katman düğümlerinde

kullanılmıştır. Geliştirilen YSA'lar öğrenme açısından karşılaştırıldığında ağ bilgileri, geleneksel ÇKYSA'da ağırlık vektörlerinde saklanırken AAFYSA'da hem ağırlık vektörlerinde hem de aktivasyon fonksiyonunun serbest parametrelerinde saklanmaktadır.

Tasarlanıp geliştirilen ve yazılımları yapılan AAFYSA modelleri ve geleneksel ÇKYSA modeli sınıflama problemlerine uygulanmıştır. Uygulamaya ilk olarak, standart bir problem olarak kabul edilen XOR problemiyle başlanmış, daha sonra, AAFYSA modelleri ile ilk defa EKG ve EEG verilerinin sınıflandırılması problemleri üzerinde durulmuştur. Ayrıca EEG verilerinde özellik çıkartılmasının AAFYSA başarısına etkisi araştırılmıştır.

Yapılan uygulamalarda, genelde % 99.9 eğitime başarısı hem ÇKYSA hem de AAFYSA modelleri için elde edilmiştir. Fakat AAFYSA kullanıldığı zaman, ağın eğitime zamanının ve iterasyon sayısının geleneksel ÇKYSA'ya göre daha az olduğu görülmüştür. Ayrıca, aynı eğitime ve test başarısına AAFYSA'nın gizli katmanında daha az düğüm sayısı ile ulaşılabilmektedir. Sonuç olarak AAFYSA'nın ÇKYSA'ya göre hedefe daha iyi ve hızlı yakınsadığı, bunda da aktivasyon fonksiyonunun adaptif olmasının etkili olduğu gözlenmiştir.

Anahtar Kelimeler: Yapay sinir ağları, adaptif aktivasyon fonksiyonu, sınıflama, AAFYSA, XOR, EKG, EEG.

ABSTRACT

PhD Thesis

**CLASSIFICATION OF BIOMEDICAL SIGNALS VIA A NEW ARTIFICIAL
NEURAL NETWORK WITH ADAPTIVE ACTIVATION FUNCTION****Gülay TEZEL**

Selcuk University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Dr. Yüksel ÖZBAY

2007, 162 Pages

Jury: Prof.Dr. Ahmet ARSLAN
Prof.Dr. Bekir KARLIK
Asst.Prof.Dr. Yüksel ÖZBAY
Asst.Prof. Dr. Salih GÜNEŞ
Asst.Prof.Dr. Nihat YILMAZ

In this study, a neural network (NN) algorithm was proposed as a new neural network approach in which free parameter adaptive activation function (NNAAF) is used. The designed algorithm was developed to obtain three NNAAF's and for comparison, traditional multi layer NN (MLNN) models via MATLAB programming language. New commands and functions were implemented in NN formulations in developing the models. NNAAF models differ from each other in their adaptive activation functions of hidden layers. Free parameter sigmoid function was used in hidden layer neurons of NNAAF-1 model, while free parameter sinus function was used additionally in NNAAF-2. In the third model (NNAAF-3) activation function was obtained by inserting free parameters into Morlet wavelet function, which was first applied in this study. Comparison of the developed models in terms of learning mechanism indicated that network information is kept in weight vectors in traditional MLNN, while it is kept in both weight vectors and in free parameters of activation function in NNAAF's.

The developed models were applied to different types of classification problems including XOR problem, as a standard classification, ECG and EEG

signals. Additionally, effects of feature extraction on NNAAF performance were studied for EEG data.

For all models, about 99.9% training performance was achieved. NNAAF models decreased training time and number of iterations considerably as compared to traditional MLNN model. Furthermore, the same training and test performance was achieved with less number of neurons in hidden layer of NNAAF. As a result, it was observed that NNAAF converges to the target better and faster than MLNN mainly due to its adaptive activation function.

Keywords : Artificial neural network, adaptive activation function, classification, NNAAF, XOR, ECG, EEG.

TEŞEKKÜR

Doktora çalışmalarım sırasında yardımlarından dolayı; Selçuk Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Öğretim Üyesi Doktora Tez danışmanım Yrd. Doç. Dr. Yüksel ÖZBAY'a; Gazi Üniversitesi, Teknik Eğitim Fakültesi, Elektronik-Bilgisayar Bölümü Öğretim Üyesi Prof. Dr. İnan GÜLER'e; EEG konusunda yardımlarından dolayı Selçuk Üniversitesi Meram Tıp Fakültesi Nöroloji Bölümü Öğretim Üyesi Prof. Dr. Orhan DEMİR'e; manevi desteklerini esirgemeyen yakın dostlarıma ve mesai arkadaşlarıma teşekkür ederim.

Ayrıca, doktora çalışmalarım boyunca bana sabır gösteren kızım Busenur, oğlum Furkan Buğra, ve sevgili eşim Ömer TEZEL'e teşekkürü bir borç bilirim.

Gülay TEZEL

Konya, 2007

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ	xii
1. GİRİŞ	1
1.1. Çalışmanın Amacı ve Önemi	4
1.2. Çalışmanın Kapsamı	5
1.3. Bu Konuda Yapılan Çalışmaların Gelişimi	7
2. YAPAY SİNİR AĞLARI (YSA)	15
2.1. İşlemci Eleman Olarak Nöron	16
2.2. Aktivasyon Fonksiyonları	17
2.3. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)	17
2.3.1. ÇKYSA modelinin öğrenme algoritması	19
2.4. Nguyen-Widrow Yöntemi	25
2.5. ÇKYSA Programının Geliştirilmesi	26
3. ADAPTİF AKTİVASYON FONKSİYONLU YAPAY SİNİR AĞI MODELİ (AAFYSA)	30
3.1. AAFYSA Modelinin Mimarisi	32
3.2. AAFYSA Modelinin Öğrenme Algoritması	34
3.2.1. İleriye yayılma adımı	34
3.2.2. Hatanın geriye doğru yayılması ve ağırlıkların güncellenmesi	35
3.2.3. Serbest parametrelerin güncellenmesi	37
4. İNSAN BEYNİ VE ELEKTROENSEFALOGRAFİ (EEG)	38
4.1. İnsan Beyninin Makroskobik Yapısı	38
4.2. Serebral Korteks	39
4.2.1. Frontal lob korteksi	41
4.2.2. Parietal lob korteksi	42
4.2.3. Temporal lob korteksi	43
4.2.4. Oksipital lob korteksi	44
4.2.5. Limbik lob korteksi	44

4.3. Serebral Dominans	45
4.4. EEG Jeneratörleri	45
4.5. Saçlı Deri Elektrotlarıyla Elektrik Potansiyellerinin Kaydı	47
4.6. Elektrotların Yerleştirilmesi	48
4.7. EEG Cihazı: Parçaları ve İşlevleri	51
4.7.1. Giriş Tablosu	51
4.7.2. Sinyal seçici düğmeler	52
4.7.3. Kalibrasyon	52
4.7.4. Amplifikatörler	53
4.7.5. Filtreler	54
4.8. Klinik EEG Kaydı	55
4.8.1. Klinik EEG kaydı için genel teknik standartlar	55
4.9. EEG Aktivitesini Tanımlayan Nitelikler	56
4.9.1. Dalga formu	56
4.9.2. Yineleme	59
4.9.3. Frekans	59
4.9.4. Genlik	60
4.9.5. Dağılım	61
4.9.6. Faz ilişkisi	62
4.9.7. Zamanlama	62
4.9.8. Israrlılık	63
4.9.9. Reaktivite	64
4.10. EEG Verisini Oluşturan Normal Beyin Dalgaları	64
4.11. Beyindeki Patolojik Dalgalar	67
4.12. Aktivasyon Metotları	69
4.12.1. Hiperventilasyon	70
4.12.2. Fotik stimülasyon	70
5. SİNYAL İŞLEMEDE KULLANILAN ÖZELLİK ÇIKARMA YÖNTEMLERİ	72
5.1. Pencereleme işlemi	72
5.2. Welch Metodu Kullanılarak Güç Spektrum Yoğunluğunun (Power Spectrum Density-PSD) Hesaplanması	73
5.2.1. Periodogram metodu	75
5.2.2. Bartlett metodu	76
5.2.3. Welch metodu (Modifiye edilmiş periodogramların ortalaması)	76
5.3. Dalgacık Dönüşümü	77
5.3.1. Sürekli dalgacık dönüşümü	79
5.3.2. Ayrık Dalgacık Dönüşümü	80
5.4. Temel Bileşen Analizi (Principle Component Analysis -PCA)	82
6. AAFYSA YAZILIMLARININ GERÇEKLEŞTİRİLMESİ	85
6.1. AAFYSA Modelinin Tasarım Aşamaları ve Geliştirilmesi	87
6.2. AAFYSA Algoritması ve Bu Algoritmanın ÇKYSA Algoritması ile Karşılaştırılması	89
6.3. AAFYSA-1 Modelinin Serbest Parametrelerinin Güncellenmesi	94
6.4. AAFYSA-2 Modelinin Serbest Parametrelerinin Güncellenmesi	95
6.5. AAFYSA-3 Modelinin Serbest Parametrelerinin Güncellenmesi	97

6.6. AAFYSA Modelinin Başarısının Ölçülmesi.....	98
7. MATLAB NEURAL NETWORK TOOLBOX KULLANARAK EEG SİNYALLERİNİN SINIFLANDIRILMASI	100
7.1. Dalgacık Dönüşümü ve YSA Kullanılarak EEG Sinyallerinin Sınıflandırılması.....	101
7.2. DD-PCA-YSA Hibrit Yapısı Kullanılarak EEG Sinyallerinin Sınıflandırılması.....	102
7.3. Neural Network Toolbox Fonksiyonları Yerine AAFYSA Algoritmasının Seçilme Nedenleri.....	104
8. GELİŞTİRİLEN YSA MODELLERİ İLE YAPILAN UYGULAMALAR	105
8.1. Eğitim ve Test Başarısının Ölçülmesi	105
8.1.1. Eğitim ve test hatasının hesaplanması.....	106
8.1.2. Belirlilik (Specificity-SPE) ve hassasiyet (Sensitivity -SEN) analizleri.....	107
8.2. XOR Probleminin AAFYSA ile Çözümü.....	108
8.3. EKG Verilerinin AAFYSA ile Sınıflandırılması	112
8.3.1. EKG verisinin özellikleri	112
8.3.2. EKG verilerinin AAFYSA ile sınıflandırılması ile elde edilen sonuçlar.....	112
8.4. İki Sınıf EEG Verilerinin AAFYSA ile Sınıflandırılması.....	118
8.4.1. Verinin yapısı ve özellikleri.....	118
8.4.2. İstatistiksel özellikleri çıkartılmış EEG sinyallerinin AAFYSA ile sınıflandırılması	120
8.4.3. Welch metodu ile özelliği çıkartılmış EEG sinyallerinin AAFYSA modelleri ile sınıflandırılması.....	122
8.4.4. Dalgacık dönüşümü uygulanmış EEG verilerinin AAFYSA ile Sınıflandırılması	127
8.5. AAFYSA Uygulamalarının 5-Fold (Sayıda) Çapraz Değerlendirme ile Gerçekleştirilmesi.....	134
8.5.1. n-fold çapraz değerlendirme	134
8.5.2. İstatistiksel özellikleri çıkartılmış EEG verisine AAFYSA algoritmasının çapraz değerlendirme ile uygulanması	135
8.5.3. Welch Metodu ile işlenmiş EEG verisine AAFYSA algoritmasının çapraz değerlendirme ile uygulanması.....	138
9. SONUÇLAR VE ÖNERİLER	141
9.1. Sonuçlar	141
9.2. Öneriler	150
10. TARTIŞMA	152
11. KAYNAKLAR	153

SİMGELER VE KISALTMALAR

EEG:	Elektroensefalografi
EKG:	Elektrokardiogram
YSA:	Yapay sinir ağları
ÇKYSA:	Çok katmanlı yapay sinir ağları
AAF:	Adaptif aktivasyon fonksiyonu
AAFYSA:	Adaptif aktivasyon fonksiyonlu yapay sinir ağları
DD:	Dalgacık dönüşümü
DP:	Doğru pozitif
DN:	Doğru negatif
YP:	Yanlış pozitif
YN:	Yanlış negatif
N:	Normal Sinüs Ritmi
Br.:	Sinüs Bradikardisi
VT:	Ventriküler Taşikardi
SA:	Sinüs Aritmisi
APC:	Atrial Prematüre Kasılması
P:	Yapay Vuru
R:	Sağ Dal Bloku
L:	Sol Dal Bloku
Afib:	Atrial Fibrilasyon
AFlt:	Atrial Flutter
EH:	Eğitme hatası
TH:	Test hatası
Ark:	arkadaşları
Db:	Daubechies
PCA:	Principal Component Analysis (Temel Bileşen Analizi)
HZ:	Hertz
SEN:	Hassasiyet
SPE:	Belirlilik
Mc:	Momentum katsayısı (momentum coefficient)
I_k :	k. nöronun toplam girişi
$\psi(\cdot)$:	Aktivasyon fonksiyonu
O_k :	k. nöron çıkış
m:	Giriş katmanındaki düğüm sayısı
g:	Gizli katmandaki düğüm sayısı
p:	Çıkış katmanındaki düğüm sayısı
w_{ji} :	j. nöron ile bir önceki katmandaki i. nöron arasındaki ağırlık
θ_j :	j. nöronun eşik ağırlığı
$d_j(u)$:	u. segment için j. çıkış nöronunun hedef değeri
δ_j :	j. nöronun lokal eğimi
$e_j(u)$:	u. segment için j. nöronun hatası
E:	Ortalama karesel hata
β :	öğrenme oranı
Sin:	Sinüs fonksiyonu
Cos:	Kosinüs fonksiyonu
a_k, b_k, c_k, d_k :	k. nöronun serbest parametreleri

ŞEKİLLER LİSTESİ

Şekil 2.1. Lineer olmayan bir yapay nöron modeli	16
Şekil 2.2. YSA'da yaygın olarak kullanılan aktivasyon fonksiyonları	18
Şekil 2.3. Tek gizli katmana sahip bir ÇKYSA mimarisi	18
Şekil 2.4. ÇKYSA modelinin akış diyagramı	29
Şekil 3.1. Adaptif aktivasyon fonksiyonlu yapay sinir ağı modeli	33
Şekil 4.1. Sol serebral hemisferin yandan görünüşü	40
Şekil 4.2. Kayıt elektrotlarının yerleştirilmesi, a. Uluslararası 10-20 sistemindeki elektrot isimleri ve yerleştirilmesi, b-f. elektrot yerlerinin belirlenmesinin basamakları.	50
Şekil 4.3. Standart Elektrot pozisyonları	51
Şekil 4.4. EEG cihazının yapısı	53
Şekil 4.5. EEG cihazlarında amplifikasyon ve diskriminasyon işlemi	54
Şekil 4.6. EEG sinyalinin Karakteristik dalga formları	57
Şekil 4.7. Alfa dalgaları	65
Şekil 4.8. Beta Dalgaları	67
Şekil 4.9. Sağ temporal bölgede (T4) Lokalize izole ve ritmik spike ve sharp wave	69
Şekil 5.1. Birinci seviye ayrık dalgacık dönüşümü	82
Şekil 6.1. AAFYSA modelinin geliştirilmesinde kullanılan ilk algoritmanın akış diyagramı	88
Şekil 6.2. AAFYSA modelinin öğrenme algoritmasının akış diyagramı	90
Şekil 7.1. Wavelet Transformu ve YSA kullanılarak sınıflandırma algoritmasının blok olarak gösterimi	102
Şekil 7.2. Dalgacık dönüşümü-PCA-YSA yapısının blok olarak gösterimi	104
Şekil 8.1. XOR verisi için 2 gizli düğüm ve 0.5 öğrenme oranı için eğitime ve test sonuçlarına göre eğitime hatası ve iterasyon sayısının	

karşılaştırılması.....	111
Şekil 8.2. Epileptik ve Normal EEG sinyalleri (a)Epileptik EEG sinyali (b) Normal EEG sinyali	119
Şekil 8.3. (a) Normal EEG sinyalinin ve (b) Epileptik EEG sinyalinin Welch Metodu uygulanarak elde edilmiş Güç Spektrum Yoğunluğu (PSD) ...	123
Şekil 8.4. Geleneksel ÇKYSA modeli ile AAFYSA modellerinin Eğitim ve Test hatalarının karşılaştırılması	126
Şekil 8.5. Geleneksel ÇKYSA modeli ile AAFYSA modellerinin Eğitim zamanlarının ve iterasyon sayılarının karşılaştırılması	127
Şekil 8.6. db4 dalgacığı ile elde edilmiş D3-D5 ve A5 katsayıları (a) Normal EEG sinyalinden elde edilen katsayılar(b) Epileptik EEG sinyalinden elde edilen katsayılar	129
Şekil 8.7. db4 dalgacığı uygulandıktan sonra özellik çıkartılmış normal ve epileptik EEG verisiyle elde edilen sınıflandırma sonuçları (a)eğitme için gerekli zaman ve(b)eğitme için gerekli iterasyon sayısı	133

TABLOLAR LİSTESİ

Tablo 7.1. Dalgacık dönüşümü ve YSA kullanılarak elde edilen sınıflandırma sonuçları (Mc:momentum , β :öğrenme oranı, SEN:Hassasiyet ve SPE:Belirlilik)	102
Tablo 7.2. Dalgacık dönüşümü-PCA-YSA yapısı kullanılarak elde edilen sınıflandırma sonuçları	104
Tablo 8.1. AAFYSA-1, AAFYSA-2, AAFYSA-3 ve ÇKYSA ağları için kullanılan XOR Veri Seti	109
Tablo 8.2. XOR verisi için Eğitim ve test sonuçları (a) ÇKYSA modeli için, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için ve (d)AAFYSA-3 modeli için.....	110
Tablo 8.3. EKG Eğitim seti sınıfları ve segment sayıları	113
Tablo 8.4. Test için kullanılan 10 farklı hasta verisinin örnek sayısı ve segment sayısı	115
Tablo 8.5. 10 farklı hastalık içeren EKG sinyalleri ile yapılan eğitim sonucu ve bir hastadan alınan verilerle yapılan test sonuçları(a) ÇKYSA modeli için(b) AAFYSA-1 modeli için (c) AAFYSA-2 modeli için.....	115
Tablo 8.6. ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin 10 hastadan alınan verilerle yapılan test sonuçları (a)ÇKYSA modeli için (b)AAFYSA-1 modeli için (c) AAFYSA-2 modeli için.....	117
Tablo 8.7. İstatistik özellikleri çıkartılmış iki sınıf EEG verisi için Eğitim ve Test sonuçları: (a) ÇKYSA modeli için, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için i	121
Tablo 8.8. Welch metodu ile özellik çıkartılmış EEG verileri kullanılarak elde edilen eğitim ve test sonuçları(a)ÇKYSA modeli için(b)AAFYSA-1 modeli için (c)AAFYSA-2 modeli için (d)AAFYSA-3 modeli için....	124
Tablo 8.9. Örnekleme frekansı 173.6 olan EEG sinyali için db4 dalgacığının uygulanması sonucu farklı seviyelerdeki frekans bileşenleri	128
Tablo 8.10. db4 dalgacığı uygulandıktan sonra özellik çıkartılmış normal ve Epileptik EEG verisiyle elde edilen sınıflandırma sonuçları (a) ÇKYSA modeli için(b) AAFYSA-1 modeli için (c) AAFYSA-2 modeli için AAFYSA-3 modeli için	132

Tablo 8.11. Beş-fold çapraz değerlendirme için eğitime ve test setlerindeki veri segmentlerinin dağılımı	135
Tablo 8.12. İstatistiksel özellikleri çıkartılmış EEG verisinin çapraz değerlendirme uygulaması sonucunda elde edilen en iyi sonuçlar	136
Tablo 8.13. İstatistiksel özellikleri çıkartılmış EEG verisinin çapraz değerlendirme uygulaması sonucunda her fold için elde edilen sonuçlar (a) ÇKYSA modelinin, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (c) AAFYSA-3 modeli için	137
Tablo 8.14. Welch Metodu ile işlenmiş EEG verisinin 5 fold çapraz değerlendirme işlemi sonunda elde edilen iyi sonuçları	139
Tablo 8.15. Welch Metodu ile işlenmiş EEG verisinin çapraz değerlendirme uygulaması sonucunda her fold için elde edilen sonuçlar (a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için	140
Tablo 9.1. 10 sınıf aritmi içeren EKG verisi kullanılarak elde edilen eğitime ve test sonuçları	144
Tablo 9.2. ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin 10 farklı EKG verisi için elde edilen test sonuçları	145

1. GİRİŞ

Sinyal; zaman, frekans gibi herhangi bir bağımsız değişkene veya değişkenlere göre değeri değişen fiziksel bir nicelikle tanımlanmaktadır. Matematiksel olarak sinyal, bir veya daha fazla bağımsız değişkenin fonksiyonu olarak ifade edilmektedir. Ses sinyalleri, elektrokardiyogram (EKG), elektroensefalogram (EEG) ve Doppler sinyalleri gibi doğal sinyaller tek bir bağımsız değişkenin yani zamanın fonksiyonu olan bilgi taşıyıcı sinyallere birer örnektirler (Proakis ve Manolakis 1996).

Sinyaller üzerinde filtreleme, özellik çıkarma, sınıflandırma gibi işlemler yapabilen, fiziksel devreler veya yazılımlar ise sistem olarak tanımlanmaktadır. Sistem eğer bir yazılım ise, yöntem ve kurallar dizisini oluşturan bir programdır ve algoritma denilen matematiksel işlemler bütününden meydana gelmektedir. Genellikle sistemi meydana getirecek yazılım ya da donanım için pek çok algoritma söz konusudur (Proakis ve Manolakis 1996).

Bu tez çalışmasında, biyolojik sinir ağlarına dayanan ve bir bilgi işleme sistemi olan, yeni bir yapay sinir ağı algoritması geliştirilmiştir. Geliştirilen bu algoritma, gizli katman nöronlarında serbest parametrelili adaptif aktivasyon fonksiyonu kullanıldığı için adaptif aktivasyon fonksiyonlu yapay sinir ağları (AAFYSA) olarak adlandırılmıştır.

Geleneksel YSA, sinyallerde desen tanıma ve sınıflandırma gibi geniş çeşitliliğe sahip uygulamalarda sıklıkla kullanılan yöntemlerden birisidir. YSA'nın, nöronlar arasındaki bağlantılarının şekli (mimari), bağlantılardaki ağırlıkların tanımlanma tipi (öğrenme algoritması) ve aktivasyon fonksiyonu ile karakterize edildiği bilinmektedir (Fausett 1994). Geleneksel YSA modelinde, bir katmanda bulunan ve önceden tanımlanan aktivasyon fonksiyonları sabittir ve herhangi bir düğüm için aktivasyon fonksiyonunun matematiksel ifadesi değişmemektedir (Segee 1993, Wu ve ark. 1997).

Ayrıca, geleneksel YSA modelinde, eğitime işlemi sırasında sadece nöronlar arasındaki ağırlıkların değeri, hataya ve ağırlığın önceki değerine göre ayarlanabilmektedir. Bunun yanında aktivasyon fonksiyonunun eğitime

algoritmasının uygulanabilirliğini önemli derecede etkilediği de bilinmektedir. Bu nedenle, yapay nöronları biyolojik nöronun yapısına biraz daha yaklaştırarak, ağ yapısını basitleştirmek ve eğitime işlemini hızlandırmak amacıyla özel aktivasyon fonksiyonları üzerine çalışmalar yapılmıştır. Literatürde bu amaçla yapılmış çalışmalarda, özellikle sigmoid fonksiyonuna serbest parametreler eklenmiştir. Bu parametrelerin değerleri, nöronlar arasındaki ağırlıklarda olduğu gibi, elde edilen hata değerine ve önceki değerlerine bağlı olarak, eğitime sırasında değiştirilmektedir (Yazdanpanah ve ark. 2003, Wu ve ark. 1997, Liu 1993, Yu ve ark. 2002). Serbest parametrelili sigmoid fonksiyonu kullanılarak gerçekleştirilen bu çalışmalarda, XOR, N-parity, iki spiral ve fonksiyon tanıma gibi temel problemler veya karmaşık olmayan problemlerin çözümü ile ilgili uygulamalar yapılmıştır.

Adaptif aktivasyon fonksiyonunun İngilizce karşılığı olan “*adaptive activation function*” için IEEE’de 23, Science Direct’de 7, Springer’de 3, Taylor&Francis’da 0 ve Web of Science’da 6 çalışmaya rastlanmıştır. Engineering Village’de 25 makaleden 16 tanesi diğer veri tabanlarında yayınlanmış olan makalelerdir. Bunun yanında “*adaptive activation function*” terimlerine “*biomedical*” anahtar kelimesi de eklendiği zaman bu veri tabanlarında hiç bir çalışmaya rastlanmamaktadır. Bu taramalara son olarak Temmuz 2007 itibari bakılarak rakamlar güncellenmiştir.

Bu tez çalışmasında, başlangıçta, AAFYSA algoritması geliştirilmeden önce dalgacık dönüşümü ve temel bileşen analizi yöntemleri kullanılarak özellik çıkartılmış EEG sinyallerinin sınıflandırılması problemi üzerinde iki farklı çalışma yapılmıştır. Bu çalışmalarda kullanılan sınıflandırıcının yazılımı, Matlab programlama dilinin “Neural Network Toolbox” komutları ile gerçekleştirilmiştir. Bu çalışmalarda UCI KDD veri tabanından alınmış 64 kanal alkolik ve normal EEG sinyali dalgacık dönüşümü ve temel bileşen analizi yöntemleriyle işlenerek geleneksel YSA ile sınıflandırılmışlardır.

Biyomedikal sinyallerin sınıflandırılmasında geleneksel YSA yöntemleri ile yüksek başarı elde edilmesinin ötesinde daha hızlı eğitime performansı gösteren ve gerçek zamanlı sistemlere daha yakın algoritmalar üzerinde araştırmalar yapılmaktadır. Bu algoritmalara katkıda bulunmak amacıyla adaptif yapay sinir ağları yaklaşımının bir versiyonu olarak, AAFYSA yapısına ağırlık verilmiştir.

Bu nedenle, bu tez çalışmasında, Matlab programlama dili kullanılarak tasarlanan dört tip YSA yazılımı geliştirilerek uygulamalara yer verilmiştir. Algoritması tasarlanarak yazılımı geliştirilen YSA tiplerinden birincisi geleneksel çok katmanlı YSA (ÇKYSA) algoritmasıdır. Diğer üçü ise üç farklı serbest parametrelili aktivasyon fonksiyonu kullanılarak geliştirilen adaptif aktivasyon fonksiyonlu YSA (AAFYSA) modelleridir (AAFYSA-1, AAFYSA-2 ve AAFYSA-3). Tasarlanan son üç modelin, öğrenme algoritması aynı olmakla birlikte gizli katman düğümlerinde kullanılan aktivasyon fonksiyonları değişiklik göstermektedir. Aktivasyon fonksiyonlarındaki serbest parametrelerin, ağırlıkların hesaplanması ve matematiksel ifadelerin her bir YSA modeli için farklılık göstermesinden dolayı ayrı ayrı yazılımları gerçekleştirilmiştir. AAFYSA-1 modelinde, literatürde de yer alan serbest parametrelili sigmoid fonksiyonu gizli katman düğümlerinde aktivasyon fonksiyonu olarak kullanılmıştır. AAFYSA-2 modelinde, serbest parametrelili sigmoid fonksiyonu ile serbest parametrelili sinüs fonksiyonunun toplamı, gizli katman düğümlerinde aktivasyon fonksiyonu olarak seçilmiştir. AAFYSA-3 modelinde ise literatürde ilk defa bu çalışmada, serbest parametrelili Morlet dalgacık fonksiyonu adaptif aktivasyon fonksiyonu olarak kullanılmıştır.

Geliştirilen bütün YSA modelleri hem sınıflandırma başarısı hem de öğrenme hızı bakımından eşit koşullarda karşılaştırabilmesi için Matlab Neural Network Toolbox'ın komutlarını kullanmaksızın yazılımı yapılarak uygulamalar gerçekleştirilmiştir.

Geliştirilen üç farklı AAFYSA ve ÇKYSA yazılımlarının uygulama aşamalarında XOR, Elektrokardiyogram (EKG) ve Elektroensefhalogram (EEG) problemleriyle çalışılmıştır. Geliştirilen YSA yazılımları ile yapılan bütün uygulamalar birbirleriyle başarı performansı ve hız açısından karşılaştırılmıştır.

Literatürde standart bir problem olarak kabul edilen XOR probleminde, geliştirilen bütün YSA algoritmaları denenmiştir. Yapılan denemeler sonucunda XOR problemi için eğitime, test performansı ve eğitime hızı bakımından en başarılı modelin AAFYSA-2 olduğu görülmüştür.

Ritim bozukluğu açısından 10 sınıflı EKG verisinin hem ÇKYSA hem de AAFYSA algoritmalarıyla sınıflandırılması gerçekleştirilmiştir. ÇKYSA kullanarak EKG de aritmi sınıflandırılması ile ilgili yapılan önceki çalışmalar (Özbay ve Ark.

2006, Ceylan ve Özbay 2007) ve EKG de aritmi sınıflandırılmasında ilk defa AAFYSA'nın kullanımı karşılaştırılmıştır. AAFYSA-1 ve AAFYSA-2 ile yapılan EKG aritmi sınıflandırılması probleminde, %99.9 sınıflandırma başarısına daha az gizli düğüm sayısı ile hiç bir önışlem uygulanmadan ve daha az iterasyonda ulaşılmıştır.

Geliştirilen AAFYSA ve ÇKYSA modellerinin başarısını karşılaştırmak için kullanılan ve başarıyla çözümlü yapılan ikinci tip problem ise epileptik ve normal bileşenleri içeren EEG sinyalleridir. Bu amaçla, Andrzejak ve ark. (2001) tarafından genel kullanıma açılmış EEG verileri tercih edilmiştir. Bu verilere uygulanan farklı özellik çıkarma yöntemleri ile geliştirilen ÇKYSA ve AAFYSA modellerine sunulmak üzere farklı giriş vektörleri oluşturulmuştur. Böylece EEG verileri kullanılarak beş farklı uygulama gerçekleştirilerek elde edilen sonuçlar ÇKYSA ve AAFYSA algoritmaları için karşılaştırılmıştır.

Sonuç olarak, bu tez çalışmasında, algoritması tasarlanan ve ayrı ayrı yazılımları gerçekleştirilen AAFYSA ve ÇKYSA kullanılarak XOR, EKG ve EEG verilerinde sınıflama problemleri yapılarak eğitime ve test işlemlerinde bütün modeller için elde edilen sonuçlar, performans ve hız açısından karşılaştırılmıştır.

1.1. Çalışmanın Amacı ve Önemi

Bu çalışmanın amacı, daha önce biyomedikal sinyallerin sınıflandırılmasında kullanılmamış olan AAFYSA algoritmasını tasarlayarak Matlab programlama dilinde yazılımını gerçekleştirmek ve bu yazılımları kullanılarak biyomedikal veriler olan EEG ve EKG sinyallerinin sınıflandırılmasını sağlamaktır.

AAFYSA ile ilgili çalışmalar 1990'lı yıllarda başlamış fakat bu yöntemin uygulandığı veriler henüz çeşitlilik kazanmamıştır. Bazı araştırmacılar, ağ yapısını basitleştirmek ve öğrenme hızını artırmak için, özel serbest parametrelili aktivasyon fonksiyonları geliştirmeye çalışmışlardır. Liu (1993), itme ve tork sinyallerinin adaptif aktivasyon fonksiyon eğimli yapay sinir ağı kullanarak, matkap yıpranma miktarının sınıflandırmasını yapmışlardır. Yu ve ark. (2002), N-parity ve iki spiral problemleri için, adaptif aktivasyon fonksiyonlu ve sabit aktivasyon fonksiyonlu

yapay sinir ağı modellerini karşılaştırmışlardır. Xu ve Zhang (1999a, 2002), mali veri modellemesi için adaptif aktivasyon fonksiyonlu yüksek dereceli YSA oluşturmuşlardır. Vecchi ve ark.[1998], Catmull_rom kübik Spline kontrol noktalarını değiştirebilen YSA modellemişlerdir.

Bu amaçla, şimdiye kadar AAFYSA ile yapılmış çalışmalar incelenerek, öncelikle gizli katman düğümlerinde serbest parametrelili adaptif aktivasyon fonksiyonu kullanılan AAFYSA'nın temelini oluşturacak yeni bir algoritma geliştirilmiştir. Daha sonra, bu algorithmada kullanılacak farklı serbest parametrelili aktivasyon fonksiyonları tasarlanarak AAFYSA mantığına uygun yeni programlar yazılmıştır. Geliştirilen üç farklı AAFYSA modelinin yanında, bu modellerin performanslarını karşılaştırabilmek amacıyla geriye yayılma algoritmasına dayanan geleneksel ÇKYSA modelinin yazılımı gerçekleştirilmiştir. Bu çalışmada, geliştirilen AAFYSA modellerine ve ÇKYSA modeline, EKG ve EEG sinyalleri uygulanmış ve sınıflandırma doğruluğu ve hız bakımından karşılaştırmalar yapılmıştır.

1.2. Çalışmanın Kapsamı

Şimdiye kadar bu çalışmaya benzer bir uygulaması olmayan ve yazılımı bu tez kapsamında geliştirilen AAFYSA sistemi ile biyomedikal sinyal işlenmesini anlatan bu tez çalışması 11 bölümden oluşmaktadır. Birinci bölümde konunun genel bir tanımı yapılarak, bu çalışmanın önemi, amacı ve literatürde, EEG sinyali kullanılarak yapılmış geleneksel YSA uygulamaları ve AAFYSA ile yapılmış çalışmalara yer verilmiştir.

İkinci bölümde geleneksel çok katmanlı YSA'nın genel tanımı, mimarisi, hatanın geriye yayılması algoritması, üçüncü bölümde ise AAFYSA modelinin genel tanımı, mimarisi, öğrenme algoritması ve adaptif aktivasyon fonksiyonunda bulunan serbest parametrelerin güncellenmesi anlatılmıştır.

Dördüncü bölümde, bu tez çalışmasında yapılan uygulamalarda, temel veri olarak kullanılan EEG sinyali üzerinde durulmuştur. EEG sinyallerinin daha iyi anlaşılabilmesi için, öncelikle insan beyninin ve beyin korteksinin yapısı ve görevleri

anlatılmış, daha sonra EEG sinyalinin kaydedilmesi, yapısı, içerdiği frekans bileşenleri ve EEG sinyallerini oluşturan beyin dalgaları konusunda bilgi verilmiştir.

Tezin beşinci bölümünde, bu çalışmada kullanılan güç spektrum yoğunluğu, dalgacık dönüşümü, temel bileşen analizi (Principal Component Analysis-PCA) gibi sinyalden özellik çıkarma yöntemleri hakkında bilgi verilmiştir.

Altıncı bölüm ise bu çalışma için algoritması geliştirilen ve yazılımı gerçekleştirilen geleneksel YSA ile AAFYSA modelleri (AAFYSA-1, AAFYSA-2 ve AAFYSA-3) arasındaki farkları, AAFYSA modelinin kullanılan aktivasyon tipine göre öğrenme şeklini ve hem ÇKYSA hem de AAFYSA için yazılmış olan programların genel özelliklerini anlatmaktadır.

Bu çalışmanın yedinci bölümünde, tez çalışmasının ilk uygulamaları olan “The UCI KDD Archive Information and Computer Science University of California” veri tabanından alınmış olan alkolik ve normal EEG kayıtlarıyla yapılmış çalışmalar anlatılmıştır. Bu verilerin dalgacık dönüşümü ve PCA ile özellik çıkartıldıktan sonra, Matlab Neural Network Toolbox’ın hazır YSA fonksiyonları kullanılarak hazırlanmış geleneksel YSA algoritmasıyla sınıflandırılması anlatılmıştır.

Sekizinci bölümde ise bu çalışmada algoritması geliştirilen ve yazılımı gerçekleştirilen, ÇKYSA ve üç farklı AAFYSA modelleri kullanılarak yapılmış uygulamalar anlatılmıştır. Yapılan uygulamalar XOR problemi, EKG aritmisini sınıflama ve EEG verisi kullanılarak epileptik sinyallerin tespit edilmesi şeklindedir. Bu verilerin üçüyle de ÇKYSA yazılımı ile sınıflandırılma işlemi yapılmıştır. ÇKYSA ile AAFYSA modellerinin karşılaştırılması ve birbirlerine göre üstünlüklerinin belirlenmesi için, AAFYSA yanında ÇKYSA programının yazılmasına ihtiyaç duyulmuştur. XOR problemi ve EEG verisi ile yapılan denemeler, AAFYSA modellerinin her üçü için de uygulanmıştır. EKG verisi ile yapılan aritmi sınıflandırılması, adaptif modellerden AAFYSA-1 ve AAFYSA-2 modelleri kullanılarak gerçekleştirilmiştir. Adaptif modeller ile geleneksel modeller birbirleriyle sınıflandırma başarısı, eğitime zamanı ve eğitime için kullanılan iterasyon sayısı bakımından karşılaştırılmışlardır.

Dokuzuncu bölüm, XOR, EKG ve EEG verilerinin sınıflandırma sonuçlarının karşılaştırıldığı bölümdür. Karşılaştırma sonuçları hem AAFYSA

modelleri ve ÇKYSA arasında hem de literatürde yapılmış diğer çalışmalara göre değerlendirilmiştir. Onuncu bölümde, AAFYSA algoritmasının verileri sınıflandırma başarısı tartışılmıştır. Onbirinci bölümde ise literatürde yapılmış ve bu çalışmada faydalanılan kaynakların listesi verilmiştir.

1.3. Bu Konuda Yapılan Çalışmaların Gelişimi

EEG desenleri arasında ayırım yaparak işlenmemiş EEG sinyallerinin görsel analizi, medikal gruplarda hala geçerliliğini korumaktadır ve bu işlem profesyonellik gerektirmektedir. Bu amaçla, EEG sinyallerinin analizinde, başlangıçta eşik dedektörleri ile band geçiren filtreler kullanılırken, daha sonraları ise epileptik formdaki aktiviteyi tespit etmek için özel bir teknoloji ile bilgisayar tabanlı devreleri ve yazılım teknikleri kullanılmaya başlanmıştır.

EEG sinyallerinin analizi ve otomatik sınıflandırılması 1960'ların sonunda ayırık analiz teknikleri ile başlamıştır. Bu yöntemde, EEG'nin otomatik sınıflandırılması, klasik istatistik metotlarına dayandırılmıştır. Fakat bu metot, bütün EEG sinyallerinde değil, sadece özel desenlerin tanımlanmasında başarılı olduğu için uzun süre kullanılamamıştır (Oğul ve ark. 1996). Daha sonraları ise bu problemi aşmak için, otomatik EEG analizinde Fourier dönüşümü kullanmak popüler olmuştur. Fakat bu metot yüksek gürültü hassasiyeti için yeterli olsa da kısa ve değişken uzunluktaki sinyal segmentleri için uygun olmadığı görülmüştür (Palaniappan ve ark. 2000). 1990'lı yıllarda uzman sistemler kullanılarak yapay zeka yaklaşımı ile EEG sinyallerinin tanınmasını kolaylaştıran artefaktlardan temizlenmesi, diken ve keskin dalgaların tespit edilmesi gibi problemlerin çözümü için çalışmalar yapılmaya başlanmıştır (Kalaycı ve Özdamar 1995).

Kalaycı ve Özdamar (1995), uzman görüşü ile oluşturulmuş iki sınıf EEG verisine Daubechies 4(db4) ve Daubechies 20 (db20) olmak üzere iki tip dalgacık fonksiyonu uygulamış ve YSA kullanılarak sınıflandırmışlardır. YSA'da aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanmışlardır. Yapılan eğitime ve test işlemlerinden sonra test doğruluğunu eğitime doğruluğundan %2.1 daha düşük

elde etmişlerdir. En yüksek sınıflandırma doğruluğu, db20 için 4. ve 5. seviyede %91.4, duyarlılık ve belirlilik %90.8 ve %95.9 olarak bulmuşlardır.

Özdamar ve Kalaycı (1998), EEG sinyallerinden kısa süreli epileptiform deşarjları (diken ve diken/dalga) tespit etmek için bir çalışma yapmışlardır. En iyi duyarlılık ve belirlilik değerlerini bulmak için farklı uzunluklardaki, EEG pencerelerinin ve gizli düğüm sayısının ağa etkisini ölçmek için denemeler yaparak 150ms (30 örnek) uzunluğunda pencere büyüklüğü ve 6 gizli düğüm için %85 doğrulukla en iyi performansı elde etmişlerdir. İterasyon sayısına göre sınıflandırma performanslarını karşılaştırabilmek için, farklı iterasyon sayıları için sınıflandırma doğruluğunu tespit etmişlerdir. Buna göre sınıflandırma doğruluğunu 24000 iterasyonda %66 ve 360.000 iterasyonda %86 olarak bulmuşlardır.

Vigario ve ark., (2000), beyinde sinir akımlarından oluşan elektromanyetik alanların çok kanallı kayıtlarında, büyük miktarlarda veri üretildiğini ve bu sebeple, uygun özellik çıkarma metotlarının, verinin sunulması ve yorumlanmasını kolaylaştırmak için gerektiğini belirtmişlerdir

Xiaopu (1995), on-line görüntüleme sistemine uygulanabilen, hızlı sinyal işleme çalıştırılarak, doğrudan 64 kanalla kayıt edilen EEG verisinden epileptik dalgaları teşhis eden yeni bir metodu iki adımda çalıştırmışlardır. Çok çözünürlüklü dalgacık dönüşümü kullanılarak, ölçülen sinyalin farklı spektral bileşenlerini (alfa, teta, beta, gamma) elde etmişlerdir. Daha sonra bu bileşenleri, YSA'ya giriş olarak uygulayarak, bütün testler için tanıma oranını, %95 olarak elde etmişlerdir.

Hazarika ve ark.(1997), EEG sinyallerini sınıflandırmak için, bir özellik çıkarma tekniği olan dalgacık dönüşümü ile birlikte YSA uygulaması tanımlamışlardır. Veri azaltma ve sinyallerin ön işlenmesini 4. dereceden Lamarie dalgacığı kullanılarak yapmışlar ve normal, şizofren, obsessive Compulsive (OCD-zorunlu saplantılı) olmak üzere üç sınıf EEG sinyali kullanılmıştır. Sınıflandırmada kullanılan YSA yapısı, hatanın geriye yayılması öğrenme algoritmasının içeren üç katmanlı ileri beslemeli bir ağ şeklindedir. Eğitimden sonra, normal sınıfı %66 doğrulukla ve şizofren sınıfı, %71 doğrulukla sınıflandırmışlardır.

Günümüzde, verinin işlenmesi için yeni yöntemler geliştirilmiştir. EEG dalgalarına bu amaçla uygulanan teknikler genel olarak dalgacık dönüşümü, temel bileşen analizi (Principal Component Analysis-PCA) (Krajca ve ark. 1999, Mazaeva

ve ark. 2001) ve bağımsız bileşen analizi (Independent Component Analysis-ICA)(Jung ve ark. 1998) şeklinde sınıflandırılabilir. Bu metotlarla yapılmış olan çalışmaların bazılarına aşağıda yer verilmiştir.

Costa ve ark. (2000), EEG sinyallerinin beyin ve elektronik bir sistem arasında iletişimini sağlayan, beyin sinyallerini kontrol sinyallerine dönüştüren sistem *Beyin-bilgisayar arabirimi* (Brain-Computer Interface-BCI) kullanarak zihinsel görevler arasında ayırım yapmayı amaçlamışlardır. Bu amaçla insan EEG sinyallerinden Adaptif Gaussian (AG) kullanarak özellik çıkartımı yapmışlar ve YSA ile sınıflandırmışlardır. EEG kaydı yapılırken görsel uyarıları dikkate alarak, 10 gönüllü (5 bayan ve 5 erkek) sağ el ya da sol el hareketini zihinsel olarak düşünmüşlerdir. Bayanlar için ortalama %91 ve erkekler için ortalama %87 sınıflandırma başarısına ulaşılmıştır.

Jung ve ark., (1998), göz kırpma, göz hareketleri, kas gürültüsü, kardiyak sinyaller ve hat gürültüsü ile birleşen ve her zaman hissedilen EEG artefaktları, EEG'nin yorumlanması ve analizinde çok büyük bir engel olduğunu tespit etmişlerdir. Bu çalışmada, geniş çeşitliliğe sahip artefaktları, EEG kayıtlarından ayırmak için kullanılan ve genel olarak uygulanabilen ICA metodunu kullanılmışlardır.

Akın ve ark., (2001), dalgacık dönüşümü ve YSA kullanarak, epileptik rahatsızlıkların doğrudan teşhisini ve EEG sinyallerinin sınıflandırılmasını amaçlamışlardır. EEG sinyalleri delta, teta, alfa ve beta spektral bileşenlerine dalgacık dönüşümü kullanılarak ayrıştırılmış ve bu spektral bileşenler YSA'nın girişlerine uygulanmıştır. Sonra, YSA hastanın sağlık durumunu gösteren üç çıkış vermek üzere eğitilmiştir. Sinir ağı çıkışlarının doğruluğu, epileptik için %97, sağlıklı için %98 ve patolojik için %93 şeklinde elde edilmiştir.

Cincotti ve ark. (2003), yaptıkları bu çalışmada, daha önce dört araştırmacı tarafından sunulan algoritmalarla özellik seçimi yapılarak, YSA tabanlı sınıflandırıcıların performansı araştırılmıştır. Bunun için 6 kişilik grupta, düşünülen hareketlerin tespiti için, üç farklı özellik sınıflandırıcısının performansı, EEG kullanılarak karşılaştırılmaktadır. Sağ ve sol el hareketlerinin düşünülmesi sırasında 4 kanaldan 128 HZ örnekleme ile veri kaydı yapmışlardır. Hidden Markov Models (HMM), Yapay Sinir Ağı (YSA) ve Mahalanobis distance (MD) karşılaştırılan

özellik sınıflandırıcılarıdır. Yaptıkları denemeler sonucunda, HMM'ye karşılık MD ve YSA'nın daha iyi performans gösterdiğini ve MD, YSA ve HMM'nin başarılarının sırasıyla %90, %80, ve %65 olarak belirtmişlerdir.

Pang ve ark. (2003), dört farklı ön işleme yönteminin, ağ tabanlı sınıflandırıcının performansına etkisini araştırmışlardır. Bunlardan üç algoritma ile dikenleri (spike) matematiksel parametrelerle modellemiş ve dördüncü algoritmada ise, sınıflandırma işlemi için ham EEG kullanmışlardır. Böylece farklı ağ giriş setleri oluşturmuşlardır. Ön işleme yöntemi olarak Tarassenko Algoritmasını, Kalayci Algoritmasını, Ozdamar Algoritmasını ve Webber Algoritmasını kullanmışlardır. Sınıflandırıcı olarak standart geri yayımlı YSA modelini seçmişlerdir. 8 hasta ve 8 sağlıklı denekten 8 kanalla alınan veri ile ortalama tanıma oranını %89.43-%90.98 arasında bulmuşlardır.

Yukarıda anlatılan EEG ile yapılmış çalışmalara ek olarak, verinin sınıflandırılmasında ve tanınmasında sadece YSA'nın geleneksel hatanın geriye yayılma algoritması yanında farklı algoritmalar da kullanılmış veya hibrit yapılar oluşturulmuştur.

Mazaeva ve ark. (2001), YSA'nın SOM modelini kullanarak yaptıkları çalışmada EEG veri sınıflandırması işlenerek iş yükünü modellemek için sinir ağı kullanılması düşünülmüştür. Self Organizing Map (SOM) sinir ağı, iş yükü ölçümlerini simüle etmek için kullanılmıştır. SOM, aktif hale gelecek çıkış nöronlarının kendi aralarındaki bağı hesaplayabilen giriş vektörlerine benzer kümelerin oluşturduğu danışmansız bir algoritmadır. Bu çalışma için, EEG verisine ön işleme yöntemi olarak FFT (Fast Fourier Transform) uygulayarak, geçici olarak segmentlere ayırmışlar ve daha sonra ağa verilmek üzere PCA ile veriyi azaltmışlardır. Ağ, mevcut verinin 2/3'ü ile eğitmiş ve kalan 1/3 veri ile test edilmiştir. SOM ağının EEG veri sinyallerini işlemek için güvenilir olduğunu yani %89 doğrulukla çalıştığını göstermişlerdir.

Acır ve ark. (2004), çok kanallı EEG sinyalinde uyku tepeciklerinin (sleep spindle-SS), otomatik tanınması için YSA'ya dayanan iki adımlı çalışma üzerinde durmuşlardır. İlk adımda non-ss'leri elemek için yapılan ön sınıflandırma, sadece hesaplama zamanını azaltmadığını aynı zamanda işlemin tüm tanıma performansını arttırdığını göstermişlerdir. İkinci adımda ise ilk ön sınıflandırma işleminden sonra,

tanıma işlemi için geri yayımlı çok katmanlı YSA ve Radyal Tabanlı Destek Vektör Makinesi (Radial Basis Support Vector Machine-SVM) olmak üzere iki farklı ağ kullanmışlardır. 6 denekten aldıkları 19 kanallı EEG için iki EEG yorumcusu tarafından yapılan görsel değerlendirmeler karşılaştırma yaparak SVM'nin sağladığı ortalama hassasiyeti %94.6 ve ortalama hata tanıma oranını % 4 olduğunu görmüşlerdir. Yapılan uygulamalar, MATLAB 6.0'da geliştirilmiştir.

Yagneswaran ve ark. (2002), güç, frekans ve dalgacık karakteristiklerini karşılaştırmak üzere Alzheimer hastalarından ve kontrol kişilerinden alınan EEG sinyallerini kullanmışlardır. Alzheimer/normal (kontrol) gruplarını sınıflandırmak için, eğitim aşamasında YSA'ya dayanan LVQ (Learning Vector Quantization) metodunu tercih etmişlerdir. EEG'nin frekans analiziyle, Alzheimer hastalarına fotik uyartım uygulandığı zaman, delta ve teta bant gücünde artma ve beta band gücünde azalma olduğunu görmüşlerdir. 9 Alzheimer ve 10 kontrol kişisinden 9 kanal ile EEG veri kaydı yapılarak sayısallaştırmışlardır. MATLAB kullanılarak yapılan FFT ve istatistik analiz sonucunda FFT ile %95 ve dalgacık dönüşümü ile %90 başarıya ulaşmışlardır.

Literatürde, farklı YSA algoritmaları yanında EEG sinyallerinin işlenmesinde bulanık mantık gibi farklı yapay zeka teknikleri ile YSA birleştirilerek yapılmış hibrit çalışmalar da mevcuttur.

Schwaibold ve ark. (2001), biyomedikal bileşenlerin işlenmesi için yapay zeka bileşenleri birleştirilerek yeni bir yaklaşım (ARTISANA) sunmuşlardır. Uyku analizinde, bu yapay zeka (ARTISANA) algoritmasının, uzmanlar tarafından yapılan sonuçlarla karşılaştırıldığında, yüksek oranlarda doğruluk vermesini amaçlamışlardır. Bu modüler algoritmanın, uzmanın yaptıklarını adım adım takip ettiğini ve iki değerlendirme aşaması içerdiğini belirtmişlerdir. Şeffaf karar verme özelliği de olan ve uyku yapısındaki detaylı bilgilendirmeyi yapabilen bu sistem, desen tanıma için YSA'dan ve kural değerlendirme için neuro-fuzzy sistemden faydalanmıştır. Otomatik ve el ile yapılan sınıflandırma karşılaştırıldığı zaman, uyuma oranını %84.6 bulmuşlardır. Bu oran uyku güçlüğü çeken hastalarda %70.7 ve sağlıklı kişilerde % 79.8 olarak elde edilmiştir.

Palaniappan ve ark. (2002)'nin yaptığı çalışmada, tasarım uygulaması olarak Fuzzy ARTMAP(FA) ve YSA kullanarak yeni bir beyin-bilgisayar (BCI) arabirimi

tasarımı amaçlanmıştır. BCI-FA tasarımı ile her denek için EEG sinyallerinin güç spektrum yoğunluğu değerlerini kullanarak beş tane mevcut zihinsel görevden en iyi üç tanesini sınıflandırmayı amaçlamışlardır. Bu güç spektrum yoğunluğu değerlerini Wiener-Khinchine ve autoregressive metotlarını kullanarak elde etmişlerdir. Yapılan denemeler sonucunda, 4 denek için BCI-FA çıkışlarının %6'dan daha az hata verdiklerini göstermişlerdir. Sonuç olarak, BCI-FA çıkışlarının üç durumlu anahtarlama devresi gibi başarıyla kullanılabilirdiğini göstermişlerdir.

Pohl ve ark. (1995), K komplekslerinin otomatik tespiti için bulanık mantık ve YSA kullanarak bir desen tanıma metodu geliştirmişlerdir. Hafif uykunun (evre 2) karakteristik özelliği olan K-komplekslerin tanımlanmasını ve uyku tepeciklerinin tespitini, uyku poligrafındaki evre 2'nin doğrudan EEG sinyalinden değerlendirilmesini ve görselleştirilebilir olmasını amaçlamışlardır. Böylece hastanın, uyku kalitesinin değerlendirilmesi için önemli bir kriter sunmuşlardır. Önemli uyku desenlerini ve uyku evrelerin tanımlamak amacıyla tasarlanan bu sistem, yazılım modülü, sinyal işleme modülü ve neuro-fuzzy (YSA-Bulanık Mantık) tanıma modüllerinden oluşmaktadır. YSA modülü geriyayılım algoritmasıyla tasarlanmış ve sekiz saatlik uyku poligrafı kullanılmıştır. K kompleksler %50 doğrulukla tespit edilmiştir.

Zhang ve ark. (1999), EEG kullanarak anestezinin derinliğini değerlendirecek bir yöntem amaçlamışlardır. Elde edilen EEG karakteristiklerini (ölçümün karmaşıklığı, spektral kenar frekansı vb.) entegre etmek için adaptif ağ tabanlı fuzzy sonuç çıkarım sistemini (ANFIS) kullanmışlardır. Karar verebilmek için anestezi altındaki üç köpekten toplanan EEG verileri ile eğitilip test edilen sistemin doğruluğunu, %89.5 olarak bulmuşlardır. Karşılaştırmayı geriye yayımlı YSA ile yapmışlardır

İleri beslemeli YSA modelleri hem yoğun olarak hem de geniş ölçüde araştırmacılar tarafından çok sayıda problemin çözümünde etkin olarak kullanılan bir yöntemdir. Bunun yanında, geleneksel YSA modellerinin de bir takım sınırlamalarının olduğu tespit edilmiştir. Bu nedenle YSA'nın hızını ve başarısını arttırmak amacıyla son zamanlarda birtakım araştırmalar yapılmıştır. Aktivasyon fonksiyonu seçiminin ağız mimarisini, büyüklüğünü, hızını ve performansını etkilediği yapılan çalışmalarda görülmüştür (Wu ve ark. 1997, Xu ve Zhang 2005.

Bu amaçla da farklı aktivasyon fonksiyonları ileri sürülmüştür. Bu aktivasyon fonksiyonlarından birisi de serbest parametrelili adaptif aktivasyon fonksiyonudur. Bu konuda literatür de yapılmış çalışmalar sınırlıdır.

Liu (1993), itme ve tork sinyallerinin sınıflandırılmasını adaptif aktivasyon fonksiyonlu yapay sinir ağı kullanarak yapmıştır. Bu çalışmada kullanılan adaptif aktivasyon fonksiyonu sigmoid fonksiyon kullanılarak oluşturulmuştur. Sigmoid fonksiyonu için eğim değeri serbest parametre olarak seçilmiş ve ağırlıklarla birlikte eğitime sırasında güncellemesi yapılmıştır. Yapılan denemelerde, hata karşılaştırma kriterine, geleneksel YSA'dan daha az sayıda iterasyonla ulaşıldığı görülmüştür. 49 veri seti (13 set deneysel olarak bulunmuş ve 39 set ise interpolasyon yardımıyla türetilmiş) için yapılan test sonucunda çıkışta görülen en küçük hata %0.4 ve en büyük hata %19 ve ortalama hata %7.73 olarak bulunmuştur.

Wu ve ark. (1997), eğitilebilir aktivasyon fonksiyonlu YSA modelinin kapasitesini görmek ve sabit sigmoid aktivasyon fonksiyonlu YSA modeli ile performansını karşılaştırmak amacıyla deneme yapmışlardır. XOR ve 4-bit Parity için yapılan denemeler göstermiştir ki aynı YSA mimarisi için eğitilebilir aktivasyon fonksiyonlu YSA modelinin ağ kapasitesinin daha yüksek ve daha iyi fonksiyon yaklaşımı vardır.

Zhang ve ark.(1999) ve Xu ve Zhang (1999a), yaptıkları üç farklı çalışmada, adaptif yüksek dereceli YSA modelleri ileri sürmüşlerdir. Yaptıkları bu çalışmalarda, aktivasyon fonksiyonunu, serbest parametrelili üç farklı fonksiyonun toplamı şeklinde ifade etmişlerdir. Ayrıca gizli katman ve çıkış katmanındaki düğümlerin giriş değerlerinin hesaplanması, geleneksel YSA modelinden farklı kurgulanmıştır. Nöron girişi, bir önceki katmanda bulunan nöron çıkışlarının çarpımları ile aynı zamanda ağırlıklı toplamalarının toplamı şeklinde tanımlanmıştır. Geleneksel YSA modelinden farklı olarak aktivasyon fonksiyonunda bulunan serbest parametreler, nöronlar arasındaki ağırlıklar gibi hata değerine bağlı olarak güncellenmişlerdir. Kurmuş oldukları yeni ağ modellerinin başarısını geleneksel YSA modeli ile karşılaştırmak için, bir fonksiyon tanımlamışlar ve bu fonksiyonun gerçek değerleri ile ağın ürettiği değerleri karşılaştırmışlardır. Xu ve Zhang (1999a), aynı zamanda, yüksek dereceli AAFYSA modelini finansal veriye uygulamışlar ve üstün nitelikli yaklaşım kapasitesine sahip olduğunu yaptıkları denemeler sonucunda görmüşlerdir. Ayrıca

Zhang ve ark.(2002), tek boyutlu, iki boyutlu ve n-boyutlu nöron adaptif yüksek dereceli YSA modelleri kurarak, öğrenme algoritmalarını sunmuşlardır. Bu modelleri finansal verilere uygulayarak geleneksel YSA modellerinden çok daha avantajlı olduğunu gözlemlemişlerdir.

Xu ve Zhang (2000), Xu ve Zhang (2001), Xu ve Zhang (2005), nöron adaptif aktivasyon fonksiyonunu kullanmalarının gerekçelerini ve öğrenme algoritmasını anlattıkları çalışmalarında, sabit sigmoid aktivasyon fonksiyonlu ÇKYSA modeli ile serbest parametrelili aktivasyon fonksiyonlu YSA modelini karşılaştırmak için bankadan aldıkları ekonomik verilerle uygulama yapmışlardır. Yaptıkları denemeler sonunda, AAFYSA modelinin eğitime hızını arttırdığı ve hem hatayı hem de ağ boyutlarını azalttığı gözlemlemişlerdir.

Yu ve ark. (2002), N-parity ve iki spiral problemlerine, adaptif sigmoid tabanlı aktivasyon fonksiyonunu kullanan YSA modelini uygulamışlardır. Sabit sigmoid fonksiyonundan farklı olarak, adaptif sigmoid fonksiyonunda, aktivasyon fonksiyonunun eğimini serbest parametre olarak tanımlanmışlardır. N-parity için elde edilen en iyi AAFYSA mimarisini 4x2x2 olarak bulmuşlardır. AAFYSA modelinin geleneksel YSA modeline göre, değeri 0.001 olan en küçük hata kriterine çok daha hızlı (daha az sayıda iterasyonda) ulaştığına dikkat çekmişlerdir. İki spiral probleminde ise, 12 gizli düğüm ile %100 sınıflandırma doğruluğuna ulaşılmıştır. N-parity ve iki spiral problemleriyle yaptıkları denemeler sonucunda, sınıflandırma problemlerinde geleneksel YSA'dan daha uygun olduğu tespit etmişlerdir.

2. YAPAY SİNİR AĞLARI (YSA)

İnsan beyninin en önemli özellikleri öğrenme yolu ile bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfetme yeteneğidir. Beynin bu özellikleri dikkate alınarak, beyni oluşturan biyolojik hücrelerin ya da literatürde bulunan ismiyle nöronların, matematiksel modellenmesi üzerinde yoğun çalışmalar yapılmıştır (Efe ve Kaynak 2000). Nöronun matematiksel modeline dayanarak oluşturulmuş bu çalışmalarda yapılan bilgisayar sistemlerine (Öztemel 2003) ve/veya programlara Yapay Sinir Ağları (YSA) adı verilmiştir. YSA günümüzde birçok probleme çözüm üretebilecek yeteneğe sahip bir sistemdir. En genel şekilde, YSA, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) oluşmuş bir yapı olarak ifade edilir. Bu nöronların birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Bu yapılarda, bilginin öğrenme yolu ile elde edildiği ve nöronların bağlantı değerlerinde saklandığı dolayısıyla dağıtık bir hafızanın söz konusu olduğu söylenebilir (Öztemel 2003).

Günümüzde birçok alanda YSA uygulamalarına rastlamak olasıdır. Özellikle örüntü tanıma, işaret işleme, sistem tanımlama ve lineer olmayan denetim alanlarında YSA'nın farklı öğrenme stratejileri ve modelleri başarı ile kullanılmıştır (Efe ve Kaynak 2000, Öztemel 2003, Sağiroğlu ve ark. 2003). YSA ile bir problemin çözümü yapılmadan önce en iyi sonuçları elde edebilmek için, ağın öğrenme mekanizmasını, mimarisini, öğrenme algoritmasını ve parametre güncelleme işleminin zamanlamasını başlangıçta belirlemek gerekmektedir.

Literatürde, öğrenme mekanizması danışmanlı ve danışmansız olmak üzere iki gruba ayrılmıştır. Bunlar arasındaki temel farklılık, hedef çıkış değerlerinin belli olup olmamasıdır. Eğer hedef çıkış değerleri var ise öğrenme mekanizması danışmanlı öğrenme, yok ise danışmansız öğrenme olarak adlandırılır .

Problemin YSA ile çözümü için yapılacak ikinci seçim mimari tipidir. Verinin akış yönü ve sahip olabileceği yapısal farklılıklar bu bölümde seçilir.

Üçüncü önemli seçenek ise öğrenme algoritmasıdır. Öğrenme olgusunu, matematik kuralları ile ölçülebilir büyüklüklere dönüştürerek, bir başarıya yada hata ölçütünün oluşturulmasını sağlarlar. Öğrenme algoritması, başarı ölçütünün zaman

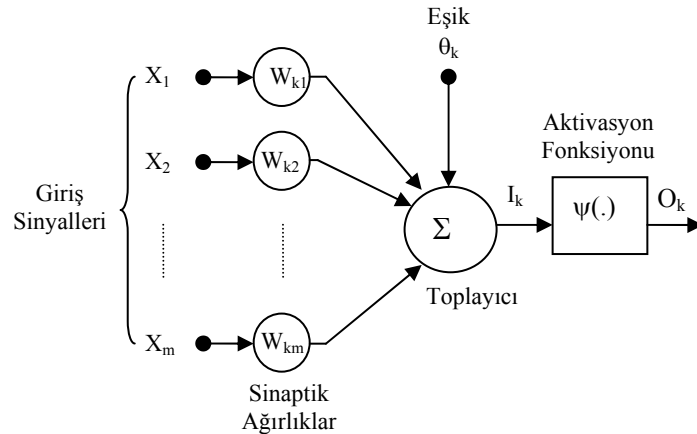
içinde artmasını ya da hata ölçütünün zaman içinde azalmasını sağlayacak parametre değişikliklerinin hesaplanmasına dayanır. Burada parametre güncelleme işlemi için türetilen bilginin hangi yöntemlerle oluşturulduğu, tasarım esnekliğinin ana temasıdır.

Diğer bir seçim ise parametre güncelleme işleminin zamanlamasıdır. Bunun için iki alternatiften söz edilebilir. Birincisinde eğitim çiftlerinin tamamı ağ üzerinden geçirildikten sonra her bir geçişte hesaplanan değişim miktarlarının toplamı ile güncelleme yapılır. Diğerinde ise her bir eğitim çifti için hesaplanan değişim miktarı o anda uygulanır.

Bu kriterler dikkate alınarak probleme uygun bir model oluşturulabilir. Bu çalışmada, danışmanlı öğrenme metotlarından çok katmanlı, ileri beslemeli YSA mimarisi kurulmuştur. Öğrenme algoritması olarak hatanın geriye yayılması (genelleştirilmiş delta kuralı) uygulanmıştır. Ağırlık parametrelerinin güncellenmesi, her bir eğitim çifti için hesaplanan hata değerine göre yapılmaktadır.

2.1. İşlemci Eleman Olarak Nöron

YSA birbirine bağlı doğrusal ve/veya doğrusal olmayan birçok işlemci elemandan oluşurlar. Bu işlemci elemanlar, tek başına çok basit yapıları olan nöronlardır. Şekil 2.1'de görüldüğü gibi bir nöronun yapısında üç ana bölüm bulunur; sinaptik ağırlıklar (bağlantı ağırlıkları), toplayıcı ve aktivasyon fonksiyonu (Efe ve Kaynak 2000, Haykin 1999).



Şekil 2.1. Lineer olmayan bir yapay nöron modeli

Şekil 2.1'den de görülebileceği gibi k . nöron girişleri, sinaptik bağlantılar üzerindeki ağırlıklar ile çarpılarak toplayıcıya uygulanmakta ve elde edilen ağırlıklı toplam (I_k), nöronun aktivasyon fonksiyonundan ($\psi(\cdot)$) geçirilerek çıkışlar (O_k) (Denk. 2.1 ve Denk. 2.2) hesaplanır (Efe ve Kaynak 2000, Sağiroğlu ve ark. 2003, Haykin 1999).

$$I_k = \sum x_k w_k + \theta_k \quad (2.1)$$

$$O_k = \psi(I_k) \quad (2.2)$$

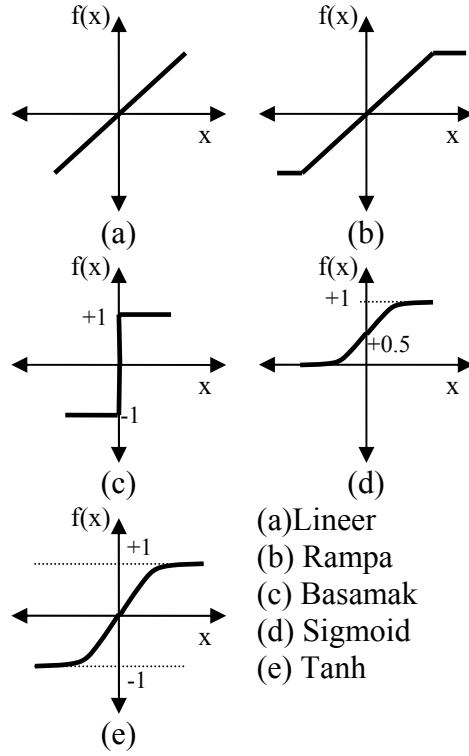
Her bir girişteki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişimin değeri, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon fonksiyonunun tipine bağlı olmaktadır.

2.2. Aktivasyon Fonksiyonları

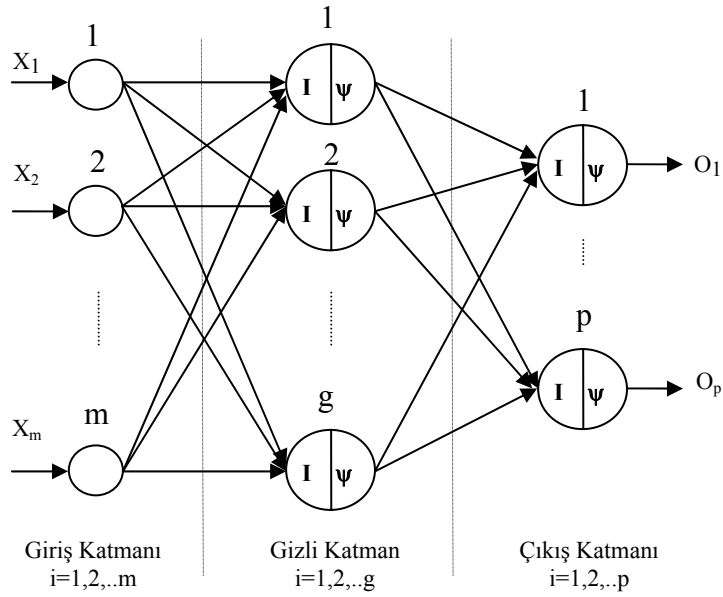
Aktivasyon fonksiyonları YSA'da bir nöronun giriş genliğini istenilen değerler arasında sınırlamak için kullanılırlar. Bu fonksiyonların türevleri alınabilmeli ve sürekli olmalıdırlar. Kullanım amacına uygun olarak tek veya çift fonksiyon olabilirler. Ayrıca ağı bütün nöronlarında aynı aktivasyon fonksiyonunun kullanılması gerekli değildir (Öztemel 2003). Yaygın olarak kullanılan aktivasyon fonksiyonları Şekil 2.2 ile gösterilmiştir (Özbay 1999).

2.3. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)

ÇKYSA modelleri, giriş ve çıkış arasında doğrusal ilişki olmadığı zaman öğrenme işlemini gerçekleştirebilen gelişmiş modellerden biridir. Giriş katmanı ile çıkış katmanı arasında bir veya birden fazla gizli katman mevcuttur. Şekil 2.3, tek gizli katmana sahip bir ÇKYSA mimarisini göstermektedir (Özbay 1999).



Şekil 2.2. YSA'da yaygın olarak kullanılan aktivasyon fonksiyonları



Şekil 2.3. Tek gizli katmana sahip bir ÇKYSA mimarisi

Gizli katmanda bulunan nöronlar lineer olmayan davranışları nedeniyle, YSA'nın toplam davranışındaki lineer olmama özelliğini sağlarlar. Giriş ve çıkış katmanındaki nöron sayısı probleme göre belirlenirken, gizli katmandaki nöron sayısını veren herhangi bir analitik yöntem yoktur (Efe ve Kaynak 2000).

Şekil 2.3 ile verilen ÇKYSA modelinde, bir giriş katmanı, bir gizli katman ve bir çıkış katmanı vardır. Katmanlarda bulunan nöron sayısı birden fazla olabilir. Ayrıca her nöronun bir çıkışı vardır ve bu çıkışlar bir sonraki katmanda bulunan bütün nöronlarla bağlıdır. Giriş katmanı, dış dünyadan gelen girişleri ara katmana gönderir. Bu katmanda bilgi işlenmeden bir sonraki katmana iletilir. Gizli katman, giriş katmanından gelen bilgileri işleyerek bir sonraki katmana yani çıkış katmanına iletir. Çıkış katmanı ise gizli katmandan gelen bilgileri işleyerek, giriş katmanına uygulanan veriye karşılık ağın ürettiği çıkışı belirleyerek dış dünyaya gönderir.

2.3.1. ÇKYSA modelinin öğrenme algoritması

ÇKYSA modeli danışmanlı öğrenme yöntemini kullanmaktadır. Ağa hem girişler hem de bu girişlere karşılık gelen hedef çıkışlar verilmektedir. Ağ kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı üretmektedir (Öztemel 2003). Bu amacı gerçekleştirmek için ÇKYSA modelinde, öğrenme algoritması olarak en küçük kareler yöntemine dayanan Delta Kuralının geliştirilmiş hali kullanılmaktadır. Bu sebeple öğrenme algoritmasına, geliştirilmiş Delta Kuralı veya Hatanın geriye yayılma algoritması (Error Backpropagation) denilmektedir. Bu algoritmaya göre ağın eğitilebilmesi için eğitim seti ve bu sete karşılık ağın üretmesi gereken hedef çıkış seti olmalıdır. Eğitim seti içinde sınıfları temsil eden segmentler her segmentte de veriyi temsil eden ve ağın girişini oluşturacak örnekleri içerir (Öztemel 2003, Fausett 1994). Hedef çıkış seti ise eğitim setindeki her segmentin hangi sınıfa ait olduğunu belirleyen çıkış katmanındaki nöronların durumunu gösterir.

Bir ÇKYSA modelinin hatanın geriye yayılması yöntemine göre eğitilmesi üç adımda gerçekleştirilir: giriş eğitme verisinin ileriye doğru yayılması, verilen hedef

değerlerine karşılık hatanın hesaplanması ve bu hatanın geriye doğru yayılarak ağırlıkların ayarlanması (Fausett 1994).

Eğitime başlamadan önce ÇKYSA modeli için öncelikle eğitim seti ve hedef çıkış seti belirlenir (Öztemel 2003, Haykin 1999, Mitchell 1997). Maksimum iterasyon sayısı, gizli düğüm sayısı, öğrenme oranının ve en küçük hata kriterinin değerleri tanımlanır. Eğitim için kullanılacak segment sayısını eğitim setinin sütun sayısı belirler. Giriş katmanı nöron sayısı, eğitim setinin satır sayısı yani her bir segmentteki örnek sayısı ile otomatik olarak tanımlanmış olur. Çıkış katmanı nöron sayısı ise hedef setinde bulunan herbir segmentin örnek sayısı ile tanımlanır. Daha sonra giriş, gizli ve çıkış katmanında bulunan nöronlar arasındaki bütün bağlantı ağırlıklarına ve eşik ağırlıklarına rasgele küçük değerler atanır (Fausett 1994, Öztemel 2003). Ağırlıkların başlangıç değerleri, ağırlık eğitilme hızını etkilemektedir. Bu nedenle Bölüm 2.4'de anlatılacak olan Nguyen-Widrow yöntemine göre ağırlıklar yeniden düzenlendikten sonra hatanın geriye yayılması algoritmasına (genelleştirilmiş delta kuralı) göre öğrenme işlemine ilk adımdan başlanır.

1. Adım: İleriye doğru yayılma

İleriye doğru yayılma adımı giriş katmanından çıkış katmanına doğru nöronların giriş ve çıkış değerlerinin, hatanın geriye yayılma algoritmasına göre hesaplandığı adımdır.

Bu adımda, öncelikle eğitim setinin bir segmenti (x_1, x_2, \dots, x_m) ve bu segmentin ağda işlenmesinden sonra ağın üretmesi beklenen hedef çıkış segmenti (d_1, d_2, \dots, d_p) ağa sunulur. Giriş katmanına uygulanan giriş değerleri hiçbir işlem uygulanmadan gizli katmana iletilir. Gizli katmanda bulunan bir nöron, giriş katmanından gelen bilgileri bağlantı ağırlıklarının etkisi ile kabul eder (Fausett 1994, Haykin 1999, Öztemel 2003). Gizli katmanda bulunan herhangi bir i . nöronun ağırlıkları girişlerinin toplamı Denk. 2.1 dikkate alınarak Denk. 2.3'deki gibi hesaplanabilir.

$$I_j(u) = \sum_{i=1}^t w_{ji} O_i(u) + \theta_j \quad (2.3)$$

Burada t , bir önceki katmanda bulunan düğüm sayısı, w_{ji} j . nöronun bir önceki katmanda bulunan i . nöron arasındaki bağlantı ağırlığının değeri, O_i bir önceki katmanda bulunan nöron çıkışı ve θ_j eşik elemanın ağırlık değeridir. Bir nöronun

ağırlıklı toplamı elde edildikten sonra Şekil 2.1 de görüldüğü gibi O_j nöron çıkışını bulmak için nöron aktivasyon fonksiyonuna ($\psi(\cdot)$) uygulanır.

$$O_j(u) = \psi(I_j(u)) \quad (2.4)$$

Bu şekilde ağ üzerinde önce gizli katmanda ve sonra çıkış katmanında bulunan bütün nöronların ağırlıklı giriş değerleri I_j ve nöron çıkış değerleri O_j sırasıyla Denk 2.3 ve Denk.2.4 ile hesaplanır.

2. Adım: Hatanın hesaplanması ve geriye yayılması

Bu adımda, ağın ürettiği çıkış ile olması beklenen çıkış arasındaki fark bütün nöronların eğimlerine yansıtılır. Bunun için, ağa sunulan giriş segmenti için ağın ürettiği çıkış ($O_j(u)$) ile bu segment için ağa gösterilen hedef çıkış değeri ($d_j(u)$), çıkış katmanındaki nöronlar için karşılaştırılır. Aradaki fark, $e_j(u)$, u. segment için j. çıkış nöronundaki hata değerini ifade eder (Denk.2.5). Toplam hatayı bulmak için eğitim setinde bulunan bütün segmentler için e_j hatalarının toplanması gerekir. Bazı hata değerlerinin negatif olma ihtimaline karşı ağın toplam hatasını bulmak için Denk.2.6 ile ifade edilen toplam karesel hata hesaplanır. Eğitimin amacı da ağ parametrelerini ayarlayarak, toplam karesel hata değerini en aza indirmektir.

$$e_j(u) = d_j(u) - O_j(u) \quad (2.5)$$

$$E = \frac{1}{2} \sum_{u=1}^n e_j(u)^2 \quad (2.6)$$

Çıkış katmanında bulunan bütün nöronlar için hata ($e_j(u)$) bulunduktan sonra ağırlıkların güncellenmesi için gerekli eğim değerleri çıkış katmanından gizli katmana doğru hesaplanır. Çıkış katmanında bulunan j. nöronun eğim değeri δ_j , karesel hatanın nöron girişine göre birinci türevi alınarak bulunur (Mittchell 1997). Çıkış katmanındaki bir nöron için eğim, δ_j , nöronun e_j hata değeri (Denk.2.9) ve aktivasyon fonksiyonunun ($\psi(\cdot)$) türevi (Denk. 2.10) ile hesaplanır (Denk.2.11).

$$\delta_j = -\frac{\partial E}{\partial I_j} \quad (2.7)$$

$$\frac{\partial E}{\partial I_j} = -\frac{\partial E}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (2.8)$$

$$\frac{\partial E}{\partial O_j} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial O_j} = -e_j \quad (2.9)$$

Denk.2.4' e göre

$$\frac{\partial O_j}{\partial I_j} = \psi'(I_j) \quad (2.10)$$

olur. Buna göre çıkış katmanındaki j. nöronun eğimi Denk. 2.11 ile ifade edilebilir.

$$\delta_j = e_j \psi'(I_j) \quad (2.11)$$

Çıkış katmanındaki bütün nöronlar için eğim hesaplandıktan sonra, gizli katman nöronlarının eğim hesabı yapılır. Bunun için çıkış katmanında bulunan nöronlarda olduğu gibi, Denk.2.7'den faydalanılır. Gizli nöron için Denk.2.7 aşağıdaki şekilde açılır. Gizli katmanda bulunan herhangi bir nöronun ÇKYSA mimarisine göre çıkış katmanındaki bütün nöronlarla bağlantısı vardır. Bu nedenle herhangi bir gizli katman nöronunun eğimini hesaplarken çıkış katmanındaki bütün nöronlardan etkilenmektedir.

$$\frac{\partial E}{\partial I_j} = -\sum_{i=1}^p \frac{\partial E}{\partial I_i} \frac{\partial I_i}{\partial I_j} \quad (2.12)$$

Burada p çıkış katmanında bulunan nöron sayısını, I_j , gizli katman nöronunun girişini ve I_i ise çıkış katmanı nöronunun girişini ifade etmektedir.

$$\frac{\partial I_i}{\partial I_j} = \frac{\partial I_i}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (2.13)$$

Denk. 2.12 ve Denk.2.13 ile gösterilen kısmi türevler alındığı zaman, gizli katmanda bulunan nöronlar için eğim ifadesi Denk. 2.14'de olduğu gibidir.

$$\delta_j = \psi'(I_j) \sum_{i=1}^p (\delta_i w_{ij}) \quad (2.14)$$

Burada δ_i çıkış katmanındaki i. düğümün eğimi ve w_{ij} çıkış katmanındaki i. nöron ile gizli katmandaki j. nöron arasındaki bağlantı ağırlığıdır. Denk. 2.14'de görüldüğü gibi gizli katmandaki nöronların eğimi için öncelikle çıkış katmanındaki nöronların eğim değeri ile bağlantı ağırlıklarının çarpımlarının toplamı bulunarak, gizli katmandaki nöron aktivasyon fonksiyonunun türevi ile çarpılır.

3. Adım: Ağırlıkların Güncellenmesi

Bu adımda ise gizli katmanda ve çıkış katmanında bulunan nöronların eğim değerlerine bağlı olarak önce giriş katmanı ile gizli katman arasındaki ağırlıklar, daha sonra gizli katman ile çıkış katmanı arasındaki ağırlıklar güncellenir. Yeni

ağırlık değerini bulabilmek için önceki değer ile ağırlıktaki değişim miktarına ihtiyaç vardır (Denk 2.15). Ağırlık değerindeki değişimi bulmak amacıyla karesel hata E'nin ağırlığa (w) göre birinci türevi alınır (Denk. 2.16) (Haykin 1999, Mitchell 1997).

$$w_{ji}^{s+1} = w_{ji}^s + \beta \Delta w_{ji} \quad (2.15)$$

$$\Delta w_{ji} = -\frac{\partial E}{\partial w_{ji}} \quad (2.16)$$

$$\frac{\partial E}{\partial w_{ji}} = -\frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial w_{ji}} \quad (2.17)$$

Burada, w_{ji}^{s+1} , bir sonraki çevrim için ağırlığın alacağı yeni değerini, w_{ji}^s ağırlığın önceki değerini, β öğrenme oranını ve Δw_{ji} ağırlık değerlerinde olması gereken değişim miktarını ifade etmektedir. Denk. 2.3 ve Denk 2.7 kullanılarak ağırlık değişim miktarı ifadesi Denk.2.18'deki gibi bulunur ve Denk. 2.15'e göre bir sonraki çevrimde kullanılmak üzere, j. nöron ile bir önceki katmanda bulunan i. nöron arasındaki ağırlık değeri w_{ji}^{s+1} hesaplanır. Denk 2.8'de, O_i bir önceki katmanda bulunan i. nöronun çıkış değerini ve δ_j çalışılan katmandaki j. nöronun eğimini ifade etmektedir.

$$\Delta w_{ji} = \delta_j O_i \quad (2.18)$$

Nöronların eşik ağırlık değerleri, nöronlar arasındaki bağlantı ağırlık değeri ile aynı şekilde hesaplanır.

$$\theta_{ji}^{s+1} = \theta_{ji}^s + \beta \Delta \theta_{ji} \quad (2.19)$$

$$\Delta \theta_{ji} = -\frac{\partial E}{\partial \theta_{ji}} \quad (2.20)$$

$$\frac{\partial E}{\partial \theta_{ji}} = -\frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial \theta_{ji}} \quad (2.21)$$

Denk. 2.3 ve Denk 2.7 kullanılarak eşik ağırlıklarındaki değişim miktarı $\Delta \theta_{ji}$ ifadesi

$$\Delta \theta_{ji} = \delta_j \quad (2.22)$$

olur. Bir sonraki çevrimde kullanılacak yeni eşik ağırlık değeri Denk. 2.22 e göre değişim hesaplandıktan sonra Denk 2.19'daki gibi hesaplanır.

Böylece Denk. (2.15-2.22) arasındaki eşitlikler kullanılarak bağlantı ve eşik ağırlık değerleri değiştirilir. İleriye doğru yayılma fazıyla başlayıp ağırlık ve eşik güncellemesiyle sona eren üç aşamanın tamamına bir “çevrim” adı verilir.

Bir çevrim boyunca, ağın girişine uygulanan eğitim veri segmenti ağırlıkların değerlerine ve nöronlarda bulunan aktivasyon fonksiyonuna göre Denk 2.3 ve 2.4 kullanılarak ileriye doğru yani giriş katmanından başlayarak çıkış katmanının nöron çıkışları hesaplanıncaya kadar yayılır. Daha sonra ise çıkış katmanından elde edilen nöron çıkış değerleri, olması gereken çıkış değerleriyle karşılaştırılır. Buradan elde edilen fark bütün ağa geriye yayılma adımıyla çıkış katmanından giriş katmanına doğru yansıtılır ve bütün nöronlar için eğim değerleri hesaplanır. Hesaplanan bu eğim değerlerine göre ağırlıkların değerleri güncellenir. Bir sonraki çevrimde, ağın girişine eğitim setinin ve hedef çıkış setinin bir sonraki segmenti sunularak, ileriye doğru yayılma adımından başlanır. Bundan sonra eğitim setinin her segmenti için bu işlem tekrarlanır. Eğitim setinin tamamı için bilgi işleme aşaması tamamlandığı zaman bir “iterasyon” oluşmuş demektir (Haykin 1999). Eğitimin amacı, giriş segmentine karşılık ağın ürettiği çıkış değerlerinin, hedef çıkış değerleriyle aynı olmasını sağlamaktır. Bunun içinde Denk. 2.6 ile verilen karesel hata değerinin, eğitim başlamadan önce verilen en küçük hata değerinden daha küçük olmasını sağlamak yani hatayı minimize etmektir.

Yukarıdaki anlatılan adımlar, ÇKYSA ağının eğitilmesi tamamlanıncaya kadar devam eder diğer bir deyişle elde edilen ağ çıkışları ile hedeflenen ağ çıkışları arasındaki hata kabul edilebilir düzeye ininceye kadar tekrar ettirilir. ÇKYSA modellerinde, maksimum iterasyon sayısı ve kabul edilebilir hata değeri (minimum hata kriteri) durdurma kriteri olarak belirlenmiştir. Eğer ağ maksimum iterasyon sayısına ulaşmamışsa, her iterasyon sonunda hesaplanan karesel hata değeri minimum hata kriteri ile karşılaştırılarak öğrenmenin gerçekleşip gerçekleşmediğine bakılır.

Ağın eğitiminin tamamlanması, ağ girişine uygulanan verilere karşılık gelecek uygun çıkışı üretmesini sağlayan ağırlık değerlerinin bulunduğu anlamına gelmektedir (Öztemel 2003). Eğitimi tamamlandıktan sonra ağın başarısını ölçmek için test veri seti kullanılmaktadır.

2.4. Nguyen-Widrow Yöntemi

YSA'nın başlangıç ağırlıklarının seçimi, hatanın en küçük değere daha hızlı ulaşmasında etkili bir faktördür. Bu nedenle YSA'nın öğrenme hızını arttırmak amacıyla kullanılan bu yöntem, hem bu bölümde anlatılan ÇKYSA için hem de Bölüm 3 ile anlatılan AAFYSA modelleri için, başlangıç ağırlık değerlerinin atanmasında kullanılmıştır. Bu nedenle burada Nguyen-Widrow Yönteminin temel prensipleri kısaca anlatılmaktadır.

Nguyen-Widrow Yöntemi bir tek girişe karşılık gizli nöronların cevabının geometrik analizine dayanır ve bu analiz Fourier dönüşümü kullanılarak bir kaç giriş olması durumuna göre genişletilebilir. Bu yöntem uygulanmadan önce, çıkış nöronları ile gizli nöronlar arasındaki ağırlıklar ile eşik ağırlıklarına, -0.5 ile 0.5 arasında küçük rasgele değerler atanır (Fausett 1994).

Nguyen-Widrow Yöntemi, giriş nöronları ile gizli nöronlar arasındaki ağırlıklara uygulanmaktadır. Ağırlıkların bu yöntemle başlangıç durumuna getirilmesi, gizli nöronların öğrenme yeteneğini artırmak için tasarlanmıştır.

Nguyen-Widrow yönteminin uygulanabilmesi için aşağıda verilen adımların takip edilmesi gerekmektedir.

Adım 1: Denk. 2.23 ile ifade edilen s skala faktörünün hesaplanması gerekmektedir. Bu eşitlikte g, gizli katman nöron sayısını ve m ise giriş katmanı nöron sayısını ifade etmektedir.

$$s = 0.7(g)^{1/m} = 0.7\sqrt[m]{g} \quad (2.23)$$

Adım 2: Giriş düğümü ile gizli düğüm arasındaki ağırlık vektörlerine, -0.5 ile +0.5 arasında rasgele küçük değerler atanır.

Adım 3: Ağırlıkların güncellenebilmesi için eski değerlerine bağlı olarak Denk. 2.24 ile verilen parametre hesaplanır.

$$\|w_j(e)\| = \sqrt{w_{1j}(e)^2 + w_{2j}(e)^2 + \dots + w_{mj}(e)^2} \quad (2.24)$$

Adım 4: Ağırlıkların yeni değerleri, Denk 2.25'e göre hesaplanır.

$$w_{ij}(y) = \frac{s \cdot w_{ij}(e)}{\|w_j(e)\|} \quad (2.25)$$

Böylece, ağırlıkların yeni değerleri $-s$ ile s arasında yeni değerlerini almış olmaktadır (Fausett 1994). Burada $i=1,2,\dots,m$ ve $j=1,2,\dots,g$ olarak tanımlanmaktadır ve $w_{ij}(e)$ ağırlığın eski değerini, $w_{ij}(y)$ ise ağırlığın yeni değerini ifade etmektedir.

2.5. ÇKYSA Programının Geliştirilmesi

Bu tez çalışmasında, hatanın geriye yayılma algoritmasına göre eğitilebilen ve Şekil 2.4 ile akış diyagramı verilen bir ÇKYSA modeli tasarlanmıştır. Tasarlanan bu modelin bilgisayar yazılımı gerçekleştirilmiş ve yapılan bütün uygulamalarda kullanılmıştır.

ÇKYSA algoritması, biyomedikal verilerin sınıflandırılmasında yaygın olarak kullanılan bir yöntemdir. ÇKYSA yazılımı, adaptif modellerle karşılaştırma yapabilmek amacıyla geliştirildiği için öğrenme şekli ve mimarisi bakımından, örtüşen algoritmaların olması gerektiği düşünülmüştür. Bu çalışmada tasarımı yapılarak geliştirilen ve Bölüm 3'de ayrıntılı olarak anlatılacak olan AAFYSA modellerinin eğitim algoritması hatanın geriye yayılması yöntemine dayanmaktadır. Bu nedenle, AAFYSA'nın eğitme ve test başarısını sağlıklı bir şekilde ölçebilmek amacıyla, temel model olarak ÇKYSA seçilmiştir.

Bu çalışma için yazılımı gerçekleştirilen ÇKYSA algoritmasının tasarımında, gizli katman ve çıkış katmanı nöronlarında, yaygın olarak kullanılan sabit sigmoid fonksiyonu, aktivasyon fonksiyonu olarak tercih edilmiştir. Giriş katmanı nöronlarında aktivasyon fonksiyonu kullanılmamıştır. ÇKYSA algoritmasında ağırlıkların eğitilmesi sırasında, her iterasyon sonunda hesaplanan ve Denk. 2.6 ile ifade edilen karesel hata değerini minimize etmek için nöronlar arasındaki ağırlıkların ve eşik ağırlıklarının değeri her çevrim sonunda güncellenir. Bunun anlamı, ağ bilgileri sadece ağırlıklara yüklenmiş demektir. Ağırlıklar değiştirilerek eğitim veri matrisi ağ tarafından öğrenilmiş olmaktadır. ÇKYSA algoritmasının eğitim sürecinin yazılımı gerçekleştirilirken kullanılan, matematiksel ifadeleri daha önce ayrıntılı olarak anlatılmakla birlikte aşağıda adım adım özetlenmektedir.

Eğitme işlemine başlamadan önce çözülecek problemin veri kümesi eğitme ve test verisi olarak ikiye bölünür. Bu veri kümelerinde bulunan segment sayısı,

sınıflandırılacak veri miktarını göstermektedir. Eğitim veri matrisinin her segmentinde bulunan örnek sayısı YSA'nın giriş katmanındaki düğüm sayısını belirler. Eğitim veri kümesi hazırlandıktan sonra verinin sınıfına ve sınıf sayısına göre eğitim hedef matrisinin tanımlanması gerekmektedir. Hedef matrisinde bulunan segment sayısı, giriş matrisinin segment sayısına eşit olmalıdır. Hedef matrisinin her segmentinde bulunan örnek sayısı ise ağın çıkış katmanındaki nöron sayısını belirlemektedir.

Ağın gizli düğüm sayısı, maksimum iterasyon sayısı, minimum hata kritri ve öğrenme oranının değeri de belirtildikten sonra aşağıda kısaca adım adım özetlenen eğitim işlemine başlanır.

Adım 1: Nöronlar arasındaki ağırlıklara, Nguyen-Widrow yönteminin matematiksel ifadeleri kullanılarak Denk. 2.23 ile değeri hesaplanan $[-s \ s]$ aralığında rasgele değerler atanır.

Adım 2: Eğitim çifti (eğitim veri segmenti ve bu segmente karşılık ağın üretmesi gereken çıkışlar) ağa sunulur.

Adım 3: Denk. 2.3 ve Denk. 2.4 kullanılarak sırasıyla gizli katman nöronlarının önce giriş değeri Denk.2.26'ya göre sonra nöron çıkışları Denk.2.27'ye göre hesaplanır.

$$I_{j=1,\dots,g}(u) = \sum_{i=1}^m w_{ji} O_i(u) + \theta_j \quad (2.26)$$

$$O_{j=1,\dots,g}(u) = \psi(I_j(u)) = \frac{1}{1 + e^{-I_j(u)}} \quad (2.27)$$

Çıkış katmanında bulunan nöronların çıkış değerleri de aynı şekilde gizli katman nöronlarından elde edilen değerlerin ağırlıklı toplamları alınarak Denk.2.28'e göre nöron girişleri ve Denk.2.29'a göre nöron çıkışları elde edilir. O_j değeri, ağa girilen her bir sete karşılık ağın ürettiği çıkış olarak adlandırılır.

$$I_{j=1,\dots,p}(u) = \sum_{i=1}^g w_{ji} O_i(u) + \theta_j \quad (2.28)$$

$$O_{j=1,\dots,p}(u) = \psi(I_j(u)) = \frac{1}{1 + e^{-I_j(u)}} \quad (2.29)$$

Adım 4: Denk. 2.30 kullanılarak çıkış katmanındaki bütün nöronlar için nöron hata değerleri hesaplanır.

$$e_{j=1,\dots,p}(u) = d_j(u) - O_j(u) \quad (2.30)$$

Adım 5: Denk. 2.31'e göre çıkış katmanındaki nöronların lokal eğim değerleri hesaplanır.

$$\delta_{j=1,\dots,p} = e_j \frac{e^{-I_j}}{(1 + e^{-I_j})^2} \quad (2.31)$$

Daha sonra Denk. 2.32'ye göre gizli katmandaki nöronların lokal eğim değerleri, çıkış katmanında bulunan nöronlarının eğimleri ve bu nöronlarla olan bağlantı ağırlıkları hesaplanır.

$$\delta_{k=1,\dots,g} = \psi'(I_k) \sum_{i=1}^m (\delta_i w_{ik}) = \frac{e^{-I_k}}{(1 + e^{-I_k})^2} \sum_{i=1}^p (\delta_i w_{ik}) \quad (2.32)$$

Adım 6: Denk. 2.33 eşitliği kullanılarak çıkış katman nöronları ile gizli katmanı nöronları arasındaki ağırlıklar ve eşik ağırlıkları bir sonraki çevrim için ayarlanır.

$$w_{ji}^{s+1} = w_{ji}^s + \beta \delta_j O_i \quad j=1,\dots,p \text{ ve } i=1,\dots,g \quad (2.33)$$

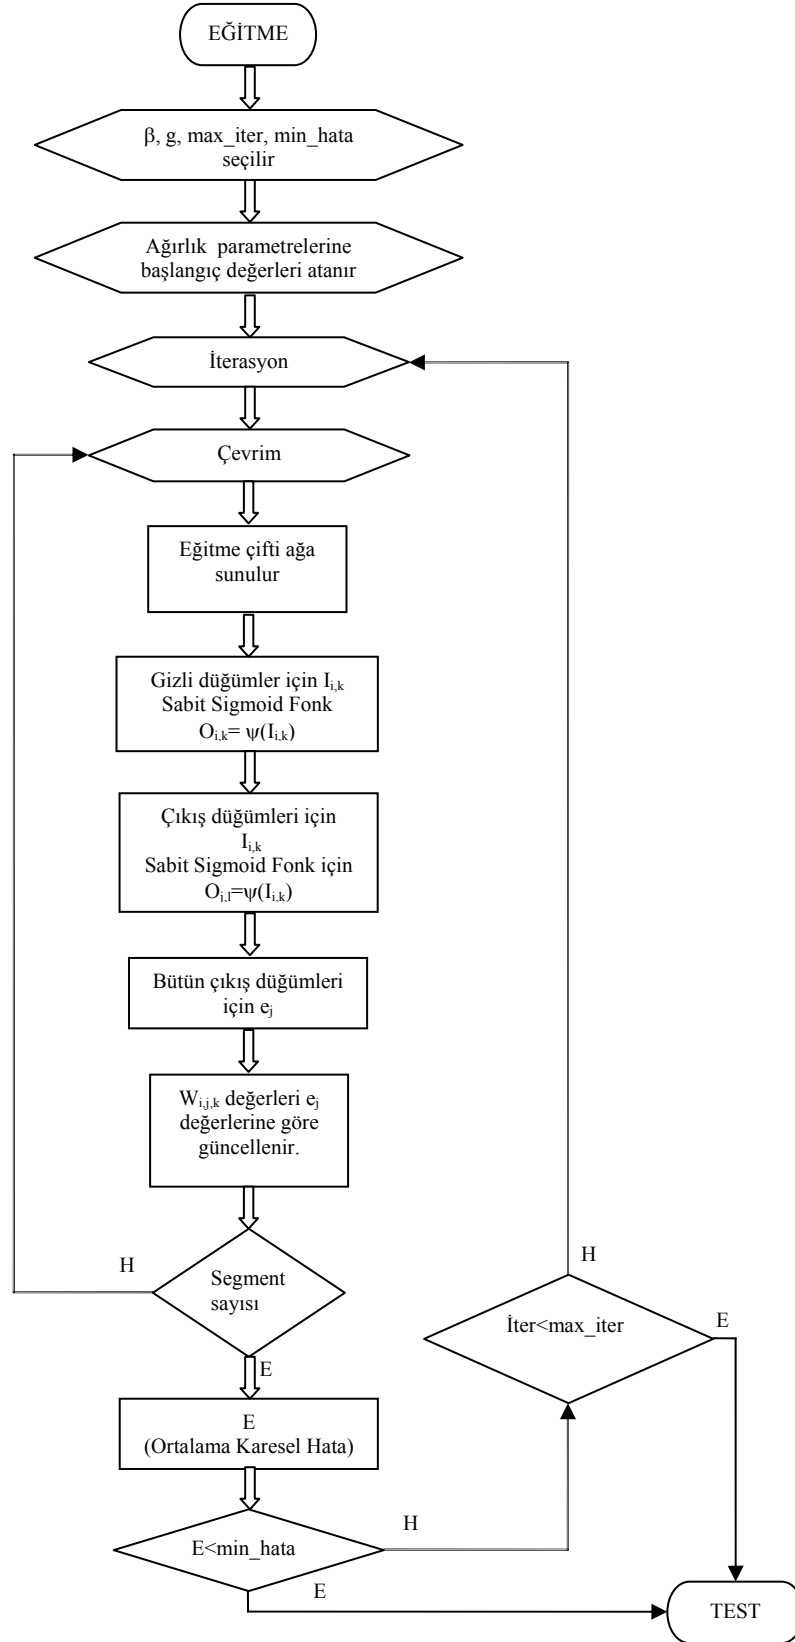
$$\theta_{ji}^{s+1} = \theta_{ji}^s + \beta \delta_j \quad j=1,\dots,p \quad (2.34)$$

Daha sonra $j=1,\dots,g$ ve $i=1,\dots,m$ 'ye kadar alınarak gizli katman ile giriş katmanı arasındaki ağırlıklar ve eşik ağırlıkları aynı şekilde Denk.2.33'e göre hesaplanır

Adım 7: Bütün eğitim segmentleri için Adım (2-7) tekrar edilir.

Adım 8: Bütün eğitim segmentleri için Adım 2-7 tamamlandıktan sonra yani iterasyon sonunda, Denk. 2.6'ya göre karesel hata (E) hesaplanarak en küçük hata kriteri ile karşılaştırılır. Eğer ortalama karesel hata, minimum hatadan küçük ise eğitime sonlandırılır ve test verisi kullanılarak test işlemi gerçekleştirilir. Aksi halde bir sonraki iterasyon için bütün Adım (2-8) tekrar edilir.

Yazılımı gerçekleştirilen yukarıda adım adım özetlenmiş ÇKYSA programında, Denk.(2.29-2.32)'de görüldüğü gibi sabit sigmoid fonksiyonu kullanılmıştır. Fakat algoritması yukarıda anlatıldığı gibi tasarlanan ve yazılımı gerçekleştirilen programın modüler olmasından dolayı farklı aktivasyon fonksiyonları da kolaylıkla programa uyarlanabilmektedir.



Şekil 2.4. ÇKYSA modelinin akış diyagramı

3. ADAPTİF AKTİVASYON FONKSİYONLU YAPAY SİNİR AĞI MODELİ (AAFYSA)

ÇKYSA, lineer olmayan işlem karakteristiğinden dolayı, desen tanıma ve sınıflandırma gibi pek çok uygulama için geniş kullanım alanına sahiptir. Bunun yanında, geleneksel ÇKYSA modellerinin de pek çok sınırlamaları vardır (Wu ve ark. 1997, Zhang ve ark. 2002). Bu sınırlamalar iki grupta değerlendirilebilir.

Birinci grup sınırlama ile ağın mimarisinin seçiminde karşılaşılmaktadır. Bir problemi çözmek için ne kadar büyüklükte ağın gerektiği açık bir problemdir. Problemin karmaşıklığı arttıkça, çözümü için daha büyük boyutlarda ağ gerekmektedir. Ayrıca uygunsuz boyutlarda ağ mimarisinin seçimi, ağın eğitilmesinde ciddi problemlere neden olabilmektedir (Wu ve ark. 1997).

ÇKYSA modelinin nöronlarında kullanılan aktivasyon fonksiyonunun seçimi, ikinci sınırlandırma grubunu temsil eder. ÇKYSA modelinde kullanılan sabit nöron aktivasyon fonksiyonu, her problem için uygun olmayabilir. Segee (1993), yaptığı çalışmada geleneksel hatanın geriye yayılma algoritmasının davranışını gözden geçirmiş ve sigmoid fonksiyonunun her zaman öğrenilecek fonksiyona uymadığını tespit etmiştir. Buna sebep olarak da sigmoid fonksiyonu kullanıldığı zaman ağın çok yavaş öğrendiğini ve kayıp parametrelere karşı daha uygun aktivasyon fonksiyonlu ağlardan daha hassas olduğunu göstermiştir. Segee'nin (1993) kararı öğreticidir fakat; açıklanamayan kısım uygun aktivasyon fonksiyonunun nasıl türetileceğidir (Wu ve ark. 1997).

Geleneksel YSA modellerinde nöronlar arasındaki ağırlıkların bilgiyi depoladığı varsayılmaktadır. ÇKYSA'nın eğitilmesinde, önceki bilgi sadece ağırlıkların hesaplanmasında kullanılmaktadır. Önceki bilgi, YSA mimarisinin tasarımına gömüldüğü zaman, daha basit bir yapı oluşturulabileceği düşünülmüştür. Bunun sonucu olarak yapılan çalışmalar, önceki bilgi nöron aktivasyon fonksiyonu ile birleştirilirse ağ kurulumunun, bir problemin çözümü için basitleştirilebileceğini göstermiştir (Wu ve ark. 1997).

Bu şekilde aktivasyon fonksiyonuna bilgiyi tutma görevi verilerek yukarıda anlatılan kısıtlamaları ortadan kaldırmayı amaçlamışlardır. Wu ve ark. (1997),

ağırlıklar gibi nöron aktivasyon fonksiyonları da, özel bir göreve uyan yeterli bilgiyi içerirse, oluşturulan ağın tatmin edici bir çözüme ulaşabileceğini belirtmişlerdir. Çünkü nöron aktivasyon fonksiyonunun YSA'nın davranışında ve performansında kritik öneme sahip olduğu bilinen bir gerçektir (Wu ve ark. 1997, Xu ve Zhang 1999b, Xu ve Zhang 2000, Xu ve Zhang 2001, Yu ve ark. 2002). Aynı zamanda, aktivasyon fonksiyonunun seçimi, bir YSA modeli tasarlariken en önemli kararlardan biridir (Xu ve Zhang 2005). Bu nedenle bazı araştırmacılar eğitme hızını arttırmak ve ağ yapısını basitleştirmek için özel aktivasyon fonksiyonları bulmaya çalışmışlardır (Segee 1993, Wu ve ark. 1997, Vecchi ve ark. 1998, Solazzi ve Uncini 2000).

İleri sürülen yeni aktivasyon fonksiyonları, değişmezliği muhafaza etmeyecek aksine, adaptif olarak özel bir göreve uyumlu olabilmesi için eğitme esnasında, öğrenme bilgisi gömülerek ayarlanabilecektir. Bu konu ile ilgili yapılan çalışmalarda, benzer aktivasyon fonksiyonlarıyla yapılan adaptif YSA uygulamalarının, geleneksel YSA'dan daha iyi özellikler sağladığı görülmüştür (Liu 1993, Vecchi ve ark. 1998, Wu ve ark. 1997, Solazzi ve Uncini 2000, Xu ve Zhang 1999a, Zhang ve ark. 1999b, Xu ve Zhang 2000, Xu ve Zhang 2001, Yu ve ark. 2002, Zhang ve ark. 2002, Xu ve Zhang 2005).

Bu tez çalışmasında amaç, ÇKYSA modelinin yukarıda ifade edilen kısıtlamalarını ortadan kaldırmak, eğitme hızını arttırmak ve ağ yapısını basitleştirmek için, serbest parametrelili adaptif aktivasyon fonksiyonuna (AAF) sahip yeni bir YSA algoritması geliştirmek ve bu algoritmayı kullanarak yeni modeller kurabilmektir. Ayrıca farklı AAF'ları kullanılarak oluşturulmuş yeni modellerle biyomedikal verilerin sınıflandırılması problemlerini çözmek ve ÇKYSA ile eğitme hızı, başarı ve ağ büyüklüğü bakımından karşılaştırmak amacıyla bu çalışma yapılmıştır.

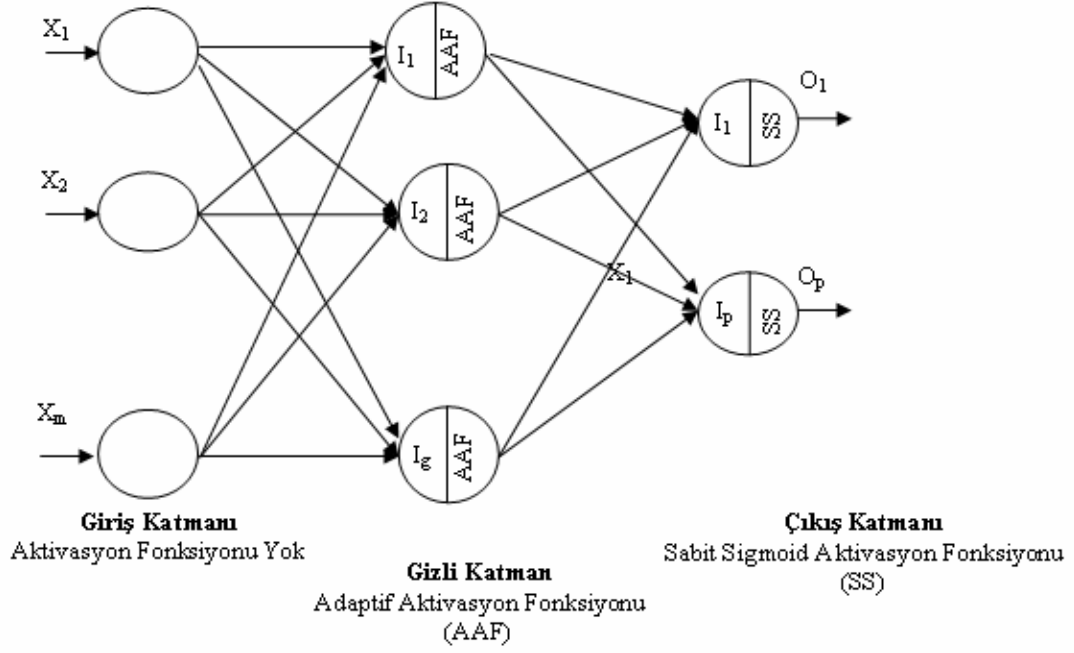
Geleneksel ÇKYSA algoritmasında, ağa sunulan verilere karşılık ağın ürettiği çıkış ile hedef çıkış arasındaki farka bağlı olarak sadece ağırlıkların değerleri ayarlanmaktadır. Yani karesel hatayı minimize etmek için ağın sadece ağırlık değerleri değiştirilmekte ve buna göre model oluşturulmaktadır. AAFYSA algoritmasında ise, ağırlıkların yanında, aktivasyon fonksiyonunda bulunan serbest parametreler de karesel hatayı minimize etmek için ayarlanmaktadır. Bu da ağın hatayı daha hızlı minimize etmesini sağlamaktadır. Bu amaçla, algoritması

geliştirilen ve yeni bir YSA modeli olan AAFYSA'nın mimarisi ve öğrenme algoritması, bu bölümde ayrıntılı olarak anlatılacaktır.

3.1. AAFYSA Modelinin Mimarisi

AAFYSA modeli, mimari ve öğrenme algoritması bakımından çok katmanlı yapay sinir ağından (ÇKYSA) çok uzak değildir. AAFYSA yapısında da hatanın geriye yayılma algoritması kullanılmış ve mimarisi ÇKYSA yapısında kurulmuştur. AAFYSA modelinin katmanları benzer şekilde giriş katmanı, gizli katman ve çıkış katmanı olarak tanımlanmaktadır. AAFYSA modelinde de giriş katmanında bulunan nöronlarda aktivasyon fonksiyonu kullanılmamıştır. Bu nedenle, giriş katmanına gelen verilerin ağırlıklı toplamı alınarak doğrudan gizli katmana iletilmektedir. Geleneksel ÇKYSA modelinden farklı olarak AAFYSA yapısında; gizli katmanda kullanılan aktivasyon fonksiyonu sabit değil adaptif yapıdadır. Bunun anlamı, gizli katman nöronlarında kullanılan aktivasyon fonksiyonunda serbest parametre olarak adlandırılan ve nöronlar arasındaki ağırlıklar gibi bir önceki değerlerine göre güncellemeleri yapılan değişkenler vardır. (Liu 1993, Wu ve ark. 1997, Solazzi ve Uncini 2000, Xu ve Zhang 2000, Talukder 2001). Aktivasyon fonksiyonundaki serbest parametrelerin sayısı, seçilen adaptif aktivasyon fonksiyonuna göre değişkenlik göstermektedir. Genel olarak AAFYSA mimarisi Şekil 3.1 ile gösterilmiştir (Xu ve Zhang 1999a, Zhang ve ark. 2002).

Bu çalışmada, üç farklı aktivasyon fonksiyonu kullanılarak üç farklı adaptif YSA modeli oluşturulmuştur (AAFYSA-1, AAFYSA-2 ve AAFYSA-3). Bu modeller arasında, gizli katmanda bulunan nöronlarda farklı aktivasyon fonksiyonunun kullanılmasından kaynaklanan algoritma değişikliği sözkonusudur. Ortak noktaları ise çıkış katmanında bulunan nöronlarında Denk.3.1 ile ifade edilen sabit sigmoid aktivasyon fonksiyonu kullanılmasıdır. Denk.3.1'de görüldüğü gibi $\psi_c(x)$ sadece x 'in değişimine bağlıdır. Yani $\psi_c(x)$ 'nin değerini belirleyen tek değişken söz konusudur.



Şekil 3.1. Adaptif aktivasyon fonksiyonlu yapay sinir ağı modeli

AAFYSA modellerinin hepsinde çıkış katmanında bulunan nöronların aktivasyon fonksiyonu,

$$\psi_c(x) = \frac{1}{1 + e^{-x}} \quad (3.1)$$

AAFYSA-1 modeli için gizli katmandaki nöronların aktivasyon fonksiyonu,

$$\psi_1(x) = \frac{a}{1 + e^{-bx}} \quad (3.2)$$

AAFYSA-2 modeli için gizli katmandaki nöronların aktivasyon fonksiyonu,

$$\psi_2(x) = a \sin(bx) + \frac{c}{1 + e^{-dx}} \quad (3.3)$$

AAFYSA-3 modeli için gizli katmandaki nöronların aktivasyon fonksiyonu,

$$\psi_3(x) = e^{-ax^2} (\cos(bx)) \quad (3.4)$$

olarak tanımlanmıştır. $\psi_1(x)$, $\psi_2(x)$ ve $\psi_3(x)$ denklemlerinde bulunan a,b,c ve d değerleri reel değişkenlerdir ve ağırlıklarda olduğu gibi değerleri her iterasyon sonunda güncellenmektedir. Bunun anlamı $\psi_1(x)$, $\psi_2(x)$ ve $\psi_3(x)$ sadece x'e bağlı olarak değil aynı zamanda bu serbest parametrelere bağlı olarak da değişmektedir.

3.2. AAFYSA Modelinin Öğrenme Algoritması

Tasarlanan bu yeni AAFYSA modeli, temel olarak, geleneksel hatanın geriye yayılması algoritmasından çok uzak değildir. Fakat eğitime sırasında nöronlar arasındaki ağırlıklar yanında aktivasyon fonksiyonunda bulunan serbest parametrelerin de değerlerinin değişmesi, AAFYSA ağının bir problemi çözerken en küçük hata kriterine daha hızlı yaklaşımını sağlamaktadır (Liu 1993, Xu ve Zhang 1999a, Yu ve ark. 2002, Solazzi ve Uncini 2004, Xu ve Zhang 2005).

AAFYSA modellerinin öğrenme algoritması üç adımdan oluşmaktadır (Fausett 1994): (1) Eğitime setinin ileriye doğru yayılması, (2) hatanın hesaplanması ve hatanın geriye doğru yayılarak ağırlıkların güncellenmesi ve (3) aktivasyon fonksiyonunda bulunan serbest parametrelerin güncellenmesi.

3.2.1. İleriye yayılma adımı

İleriye yayılma sırasında, giriş katmanında bulunan her bir giriş nöronu, eğitime seti segmentini alır ve bu sinyali gizli katmanda bulunan nöronlara yayar. Gizli katmanda bulunan her bir nöron, Denk. 3.5'de gösterildiği gibi, giriş katmanından gelen sinyalleri, ağırlıkları ile çarparak toplar. İleriye doğru yayılma adımının bu bölümünde, adaptif aktivasyon fonksiyonunun tipi önemlidir. Çünkü gizli katmandaki nöronların çıkış değerini hesaplarken, nöron girişi Denk. 3.6'da olduğu gibi adaptif aktivasyon fonksiyonuna uygulanmaktadır (Xu ve Zhang 1999b, Solazzi ve Uncini 2000, Zhang ve ark. 2002, Yu ve ark. 2002). Bu aşamada da AAFYSA modeline göre AAF değişmektedir. Uygun AAF uygulandıktan sonra elde edilen gizli nöron çıkış sinyali, çıkış katmanında bulunan bütün nöronlara, gizli katman ile çıkış katmanı arasındaki ağırlıkları kullanarak iletilir. Çıkış katmanında bulunan nöronlarda da aynı şekilde, öncelikle nöron girişlerinin ağırlıklı toplamı Denk. 3.6'ya göre hesaplanır ve daha sonra Denk. 3.1 ile verilen sabit sigmoid aktivasyon fonksiyonu uygulanarak ağın üretmiş olduğu çıkış değeri elde edilir.

$$I_{i,k}(u) = \sum_j (w_{i,j,k} o_{j,k-1}(u)) + \theta_{i,k} \quad (3.5)$$

$$O_{i,k}(u) = \psi(I_{i,k}(u)) \quad (3.6)$$

3.2.2. Hatanın geriye doğru yayılması ve ağırlıkların güncellenmesi

Geleneksel geriye yayılma algoritmasının ileriye yayılma adımında olduğu gibi, ağa sunulan her giriş segmenti için çıkış katmanında bulunan bütün çıkış nöronlarında çıkış sinyali (O_j) üretilir. Aynı zamanda eğitime amacıyla kullanılacak her bir giriş segmentine karşı gelecek bir hedef veri segmenti (d_j) başlangıçta ağa tanımlanmıştır. Elde edilen O_j değeri ile olması gereken hedef değer d_j arasındaki fark, ağırlıkların güncellenmesinde kullanılacak olan hatayı ifade eder.

Eğitimin amacı, ağırlıkları ve serbest parametreleri güncelleyerek, Denk 3.7 ile gösterilen ve ortalama karesel hata olan E 'nin hesaplanan değerinin, eğitimi durdurma kriterlerinden biri olan minimum hata kriterinden daha küçük olmasını sağlamaktır (Fauset 1994, Haykin 1999, Öztemel 2003, Xu ve Zhang 2005).

$$E = \frac{1}{2} \sum_{j=1}^p e_j^2 = \frac{1}{2} \sum_{j=1}^p (d_j(u) - O_{j,l})^2 \quad (3.7)$$

Ağırlıkların güncellenmesi işlemi en dik azalan eğim yöntemine (steepest descent) göre yapılmıştır. Buna göre Denk. 3.8 ve Denk. 3.9, sırasıyla nöronlar arasındaki ağırlıkların ve eşik ağırlıklarının güncellenmesi için gerekli eşitlikleri göstermektedir.

$$w_{i,j,k}^s = w_{i,j,k}^{s-1} + \beta \frac{\partial E}{\partial w_{i,j,k}} \quad (3.8)$$

$$\theta_{i,k}^s = \theta_{i,k}^{s-1} + \beta \frac{\partial E}{\partial \theta_{i,k}} \quad (3.9)$$

Bu eşitliklerden de görülebileceği ağırlıklardaki değişim miktarı, ortalama karesel hatanın ağırlığa göre kısmi türevinin alınmasıyla bulunabilmektedir. Bu denklemlerde yazıldığı Denk 3.10 ve Denk. 3.11 yerine konulduğu zaman, görülmektedir ki Denk. 3.14 ve Denk. 3.16 ile ifade edilen ağırlıklardaki değişimi

miktarının hesaplanması, Denk. 3.13'den dolayı gizli katmanda bulunan nöronlarda, çıkış katmanda bulunan nöronlardan farklı hesaplanmaktadır.

$$\frac{\partial E}{\partial I_{i,k}(u)} = \delta_{i,k} \quad (3.10)$$

$$\frac{\partial E}{\partial O_{i,k}(u)} = \lambda_{i,k} \quad (3.11)$$

$$\delta_{i,k} = \frac{\partial E}{\partial I_{i,k}(u)} = \frac{\partial E}{\partial O_{i,k}(u)} \frac{\partial O_{i,k}(u)}{\partial I_{i,k}(u)} = \lambda_{i,k} \frac{\partial O_{i,k}(u)}{\partial I_{i,k}(u)} \quad (3.12)$$

$$\lambda_{i,k} = \begin{cases} \sum_j \delta_{j,k+1} w_{j,i,k+1}, \Leftrightarrow 1 \leq k < l; \\ d_i(u) - O_{i,1}(u), \Leftrightarrow k = 1 \end{cases} \quad (3.13)$$

Çünkü gizli katmanda ve çıkış katmanında farklı aktivasyon fonksiyonları kullanılmaktadır. Bu nedenle, ağırlık değerlerini güncellerken, öncelikle Denk 3.10 ve Denk.3.11 ile verilen kısmi türevler, çıkış katmanında bulunan nöronlar için sabit sigmoid aktivasyon fonksiyonuna göre ve gizli katmanda bulunan nöronlar için (tasarlanan AAFYSA'nın tipine göre) serbest parametrelili AAF'nuna göre hesaplanır ve Denk. 3.15 ve Denk.3.17'ye göre güncellemeler yapılır. Sonuç olarak, ağırlıkların ve eşik değerlerinin güncellenmesi için kullanılan eşitlikler Denk. (3.8-3.17) ile verilmiştir (Xu ve Zhang 1999a, Yu ve ark. 2002, Zhang ve ark. 2002, Xu ve Zhang 2005).

$$\frac{\partial E}{\partial w_{i,k}(u)} = \frac{\partial E}{\partial I_{i,k}(u)} \frac{\partial I_{i,k}(u)}{\partial w_{i,k}(u)} = \delta_{i,k} O_{j,k-1}(u) \quad (3.14)$$

$$w_{i,j,k}^s = w_{i,j,k}^{s-1} + \beta \delta_{i,k} O_{j,k-1}(u) \quad (3.15)$$

$$\frac{\partial E}{\partial \theta_{i,k}(u)} = \frac{\partial E}{\partial I_{i,k}(u)} \frac{\partial I_{i,k}(u)}{\partial \theta_{i,k}(u)} = \delta_{i,k} \quad (3.16)$$

$$\theta_{i,k}^s = \theta_{i,k}^{s-1} + \beta \delta_{i,k} \quad (3.17)$$

Ağın eğitilmesi sırasında, her çevrimde ağa sunulan her segment için bu işlemler tekrar edilir. Eğitim setinin ağa sunulması tamamlandığında yani iterasyon sonunda, bütün segmentler için elde edilen hata değerlerinin, karelerinin toplamı alınarak ortalama karesel hata (Denk.3.7) hesaplanır ve karşılaştırma işlemi bu aşamada gerçekleştirilir.

AAFYSA algoritmasında, ÇKYSA'da olduğu gibi eğitime işlemini sona erdiren iki kriter vardır: minimum hata kriteri ve maksimum iterasyon sayısı. Eğitim sırasında minimum hata kriterine ulaşılmasa bile maksimum iterasyon sayısına ulaşıldığı zaman, eğitime işlemi sona erdirilir (Haykin 1999, Öztemel 2003).

3.2.3. Serbest parametrelerin güncellenmesi

Geleneksel ÇKYSA algoritmasından farklı olarak bu algoritmada, ağırlıklara ek olarak güncellenmesi gereken serbest parametreler de vardır. Bu nedenle bu parametrelerin güncellenmesi için gerekli matematiksel ifadelerinde hesaplanması gerekmektedir. Serbest parametrelerle, ağırlıkların güncellenmesi eş zamanlı yapılmamaktadır. Ağırlıklar her çevrim sonunda güncellenirken, eğitim tamamlanmamış ise her iterasyon sonunda gizli nöron aktivasyon fonksiyonunda bulunan serbest parametreler karesel hata fonksiyonuna göre türevi alınarak, güncellenmektedir. Ağırlıkların ve serbest parametrelerin güncellenme işlemi de en dik azalan eğim yöntemine göre yapılmıştır. Serbest parametrelerin eğitim sırasında güncellenmesi Bölüm 6'da ayrıntılı olarak anlatılacaktır.

4. İNSAN BEYİNİ VE ELEKTROENSEFALOGRAFI (EEG)

İnsan beyni, tüm aktivitelerimizi kontrol ederek, insan zekasını, duyuların yorumunu, hareketlerin denetimini oluşturmaktadır ve bilinen en karmaşık yapı olduğu düşünülmektedir.

İnsanda ve diğer canlılarda yaşamsal faaliyetlerin yerine getirilmesinde merkez konumunda bulunan beyin üzerindeki çalışmalar, yüzyıllardır yapılmakta ve bugün de tam olarak anlaşılmadığı için, birçok disiplin içeren nörolojik bilimler alanında çalışmalar hızla devam etmektedir. Bu araştırmalar sonucunda, beyne bilgiyi taşıyan ve işleyen çok sayıdaki nöron tarafından üretilen manyetik ve elektrik alanların ölçülebileceği tespit edilmiştir (Oğul ve ark. 1996). Elektroensefalografi (EEG) olarak bilinen bu işlemle elde edilen beyin elektrik dalgaları, düşük bir maliyetle çoğu zaman yeterli çözümü sağlamaktadır. Özellikle Nöroloji ve Psikoloji uzmanları nörofizyolojik bir tanı yöntemi olan EEG'den teşhis ve tedavide yararlanmaktadırlar (Costa ve ark. 2000, Oğul ve ark.1996).

Bu bölümde EEG sinyallerinin özelliklerinin anlaşılabilmesi için öncelikle beyinin ve beyin korteksinin yapısı üzerinde durulmuş daha sonra EEG sinyallerinin yapısı ve kayıt edilmesi ile ilgili bilgiler verilmiştir.

4.1. İnsan Beyninin Makroskobik Yapısı

EEG sinyallerinin, sınıflandırılması yapılırken özellikle beyinin ve beyin korteksinin karmaşık yapısının temel bileşenlerinin anlaşılması gerekmektedir. Vücudun çeşitli fonksiyonlarını kontrol etmek ve koordinasyonu sağlamakla yükümlü olan sistem, sinir sistemidir. Sinir sistemi, beyin ile vücudun diğer sistemleri arasındaki bağlantıyı sağlar (Oğul ve ark. 1996).

İnsanda sinir sistemi, kafatası (kranium) içinde, tentorium üstü bölgede (supratentotiel bölgede) yerleşmiş olan beyin yarım küreleri (hemisferler), tentorium altı (arka çukur) bölümde yer alan serebellum ve beyin sapı ile vertebral kolon içinde yer alan omurilikten oluşur. Hemisferler birtakım yarıklarla 4 loba ayrılır (Şekil 4.1).

Bunlar frontal, pariyetal, temporal ve oksipital loblardır. Bu loblar kendilerini örten ve kafatasını oluşturan yassı kemiklerin adları ile anılırlar (Oğul ve ark.,1996).

Frontal lob; rolando yarığının (sulcus centralis) önünde ve Sylvius yarığının üstünde kalan bölüm olup, üst, orta ve alt frontal girus diye adlandırılan üç kısımdan oluşur. Dominant hemisferin alt frontal girusunda Broca merkezi yer alır. Ayrıca Rolando yarığının hemen önünde yukarıdan aşağıya uzanan ve istemli hareketlerin primer kortikal merkezi olan presental girus bu lobda bulunur. Kişinin davranışlarını etkileyen yüksek psişik merkezler de frontal lobların ön kısımlarında yer alır (Oğul ve ark. 1996).

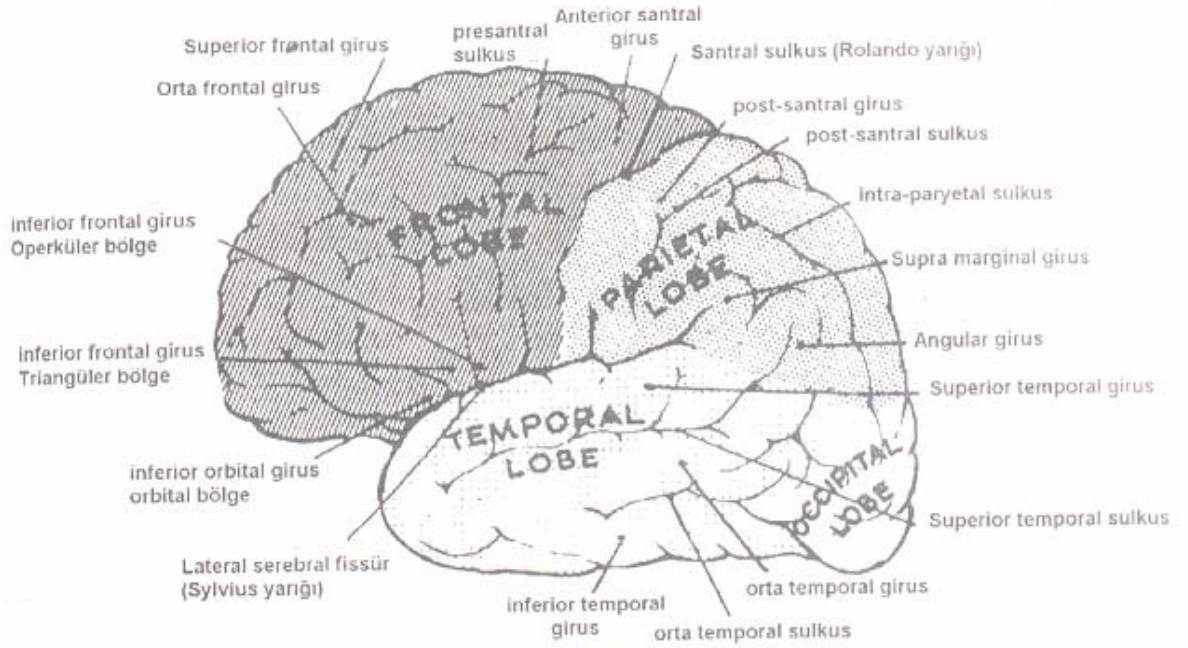
Paryetal lob; rolando yarığının arkasında ve fissura paryeto oksipitalisin önünde kalan hemisfer parçasıdır. Duyu fonksiyonunun kortikal merkezidir. Rolando yarığının arkasında bulunan ve post-santral girus adı verilen parça somatik (bedensel) duyu, bunun arkasında bulunan posterior pariyetal bölge ise kortikal (korteksle ilgili) duyu fonksiyonunun merkezidir (Oğul ve ark.,1996).

Temporal lob; Sylvus yarığının altında kalan beyin bölgesidir. Üst, orta ve alt temporal giruslar adı ile üçe ayrılır. Dominant hemisfer üst temporal lobda konuşmanın sensoryel komponenti ile ilgili Wernicke alanı yer alır. Ayrıca işitme merkezi ve psişik merkezlerde bu lobda yer alır (Oğul ve ark. 1996).

Oksipital lob; fissura paryetooksipitalisin arkasında kalan kısımdır. Görme fonksiyonunun kortikal merkezidir.

4.2. Serebral Korteks

Beyine herhangi bir yerinden yapılan koronal kesitte, çıplak gözle en dışta 2-4.5 mm kalınlığında kahverengi-grimsi bir kısmın çepeçevre beyni sardığı görülür. Bu gri bölüme beyin korteksi adı verilir. Nöronların gövdeleri bu korteks alanı içinde yer alır. Korteks altında ise beyaz cevher (substantia alba) bulunur. Burası nöronların uzantıları olan aksonların bulunduğu kısımdır (Vuckovic ve ark. 2002).



Şekil 4.1. Sol serebral hemisferin yandan görünüşü

Serebral hemisferlerin üzerini kaplayan serebral korteks yani beyin korteksi, anatomik, fizyolojik, kimyasal özellikleri ve subkortikal merkezlerle olan yoğun bağlantıları ile insanı diğer hayvan türlerinden farklı kılan istemli hareketlerin denetlenmesi, duyuların birleştirilip yönlendirilmesi, yüksek düzeydeki zihinsel ve duyuşal işlevlerin düzenlenmesinden sorumludur. Korteks gri cevherden oluşmuş olup, ortalama 14 milyar nöron, 50 milyar kadar da glia hücresi içermektedir. Korteksin alanı gerçekte ortalama 0.25 metrekaredir. Ancak bu alan hemisferin yüzeyindeki birbirinden sulkuslarla ayrılan kıvrımlar (gyrus) sayesinde üçte birine inmiştir. Korteksin ağırlığı 600 gram kadardır. (Toplam beyin ağırlığı 1400 gramdır.) İnsanda korteks maksimum ağırlığına 8 yaşında ulaşır. Ağırlık ile zeka arasında saptanmış bir ilişki yoktur (Vuckovic ve ark. 2002).

Korteksin fokal stimülasyonu ile alınan cevaplar aslında o alanın gerçek fonksiyonunu göstermez. Her korteks alan fonksiyonunu, diğer kortikal alanlar ve subkortikal alanlarla yukarıda tanımlanan bağlantılar yolu ile ilişki kurduktan sonra entegre ederek gösterdiği gibi, kompleks fonksiyonlar da birçok korteks alanının ortak fonksiyonu sonucunda gerçekleşmektedir.

Korteksin fonksiyonları değerlendirilirken Brodmann'ın belirttiği alanlar gözönüne alınarak loblara göre değerlendirme yapılacaktır. Sırasıyla Frontal Lob korteksi, parietal lob korteksi, temporal lob korteksi, oksipital lob korteksi ve limbik lob korteksinin fonksiyonları anlatılacaktır.

4.2.1. Frontal lob korteksi

Toplam korteks alanının üçte birini oluşturur ve başlıca üç bölgeye ayrılır. Bunlar motor korteks, prefrontal, orbitofrontal korteks ve broca alanlarıdır (Oğul ve ark. 1996).

a. Motor korteks: Korteksin elektriksel stimulationsu ile yapılan arařtırmalar, serebral korteksde dört ayrı motor olduđunu ortaya koymuřtur ve bu alanların lezyonunda da çeřitli tiplerde hareket bozuklukları gözlenmiřtir.

Primer motor korteks: Motor korteksin elektriksel stimulationsu homonkulusdaki vücut kısımlarında kontrilateral istemsiz motor hareketlerine neden olur.

Premotor korteks: Bu alana frontal göz alanı denir ve istemli göz hareketlerinden sorumludur.

Sekonder motor alanı: Bu alanın stimulationsu ile motor cevaptan çok, duyuşal cevaplar elde edilir. Bu da sekonder motor alanının motor aktivitede rolünün az olduđunu göstermektedir.

Suplementer motor alanı: Bu alanın elektriksel stimulationsunda bilateral jeneralize tonik veya postural hareketler görülür. (aksiyal, omuz-kuşak ve pelvis kuşak kaslarındaki aktiviteye bađlı olarak) bu esnada başta karşı tarafa dönme ve karşı kolda yukarı kalkma gözlenebilir.

b. Prefrontal ve orbifrontal korteks: Korteksin bu kısmı, soyut düşünme, çağrıřım, fikir ve aktivitenin entegrasyonu, karar verebilme, ileri görüş, olgun düşünme, bellek, emosyonel (duyuşal) reaksiyonların kořullara göre ayarlanması ile ilgilidir. Kişideki sakinlik ve aşırı sevinç keder ve mutluluk, dostluk ve huşuzluk

gibi karmaşık cevapların kaynaklandığı alanlardır. Emosyonel durumlardaki otonomik cevaplar ise (kan basıncı, solunum hızı ve gastrointestinal aktivitedeki değişiklikler) prefrontal alandan hipotalamusa projekte olan yollarla sağlanır (Oğul ve ark. 1996).

c. Broca Alanı : Broca alanı, konuşmanın motor merkezidir ve dominant merkezdeki aktiftir. Bu alanın lezyonunda konuşma bozukluğu ortaya çıkar. Hasta konuşulan kelimeleri anlar ancak ya hiç konuşamaz veya konuşmadaki kelime sayısında azalma, gramer hataları, sözcük bulmada zorluk veya gecikme gibi akıcı olmayan bir konuşma tipi ortaya çıkar (Oğul ve ark. 1996).

4.2.2. Parietal lob korteksi

Parietal lob korteksi, talamusdan gelen duyuşal işlemlerin yüksek seviyede yapılması ve işitme, görme, somestetik kortikal alanlardan gelen nöral bilgilerin entegrasyonu ile ilgilidir. Korteksin bu kısmının ayrıca motor fonksiyonu da vardır.

a. Primer somestik alan (Sometik alan I, SI): Kortikal lezyonlarda epikritik duyuşların algılanması bozulur. Yani stimulusların şiddetlerindeki farklar tanınmaz, stimulusların lokalize edilmeleri bozulur ve vücut düzeyi ile temas ettirilen cisimlerin benzerlikleri ve farklılıkları değerlendirilemez ve bunların sonucunda hastalarda “kortikal duyuş bozuklukları” ortaya çıkar. Bunlar astreognozi (gözler kapalı iken avucuna konan bir cisim tanıyamama), agrafestezi (deri üzerine çizilen bir harf veya sayıyı tanıyamama), atopognozi (stimulusun lokalize edilememesi iki nokta diskriminasyonunda bozulma), abarognozi (avuç içine konulan farklı ağırlıkları ayırt edememe), simultanagnozi (aynı anda vücudun her iki yarısına simetrik noktalar verilen stimulusun iki ayrı stimulus olarak ayırt edilememesi) şeklinde tanımlanabilir (Oğul ve ark. 1996).

b. Sekonder somestetik alan (sometik alan II, SII): Bu alan postsantral girusun tabanında sekonder motor alanla birlikte yer alır. Burada yüz, ağız ve boğaza ait alan yoktur. Sekonder somestetik alanın elektriksel stimülasyonu ile primer

somestetik alan stimülasyonunda ortaya çıkan duyuların benzerleri bilateral olarak ortaya çıkmaktadır (Oğul ve ark. 1996).

c. Somestetik assosiyasyon alanları: Bu alan işitme ve görme korteks assosiyasyon alanları ile olan yoğun bağlantılarıyla duyuların ayrıntılı algılanmasını ve böylelikle kişinin çevresinden, kendinden haberdar olabilmelerini sağlamaktadır. Bu alanların ayrıca gnozi, praksi, okuma, yazma, hesaplama, konuşulanları anlama gibi yüksek kortikal fonksiyonları da vardır (Oğul ve ark. 1996).

4.2.3. Temporal lob korteksi

Neokorteksin işitme vestibuler, emosyon, kişilik, bellek ve davranış ile ilgili fonksiyonları varken, allokorteks (koku duyusu ve limbik sistemle ilişkilidir. Aynı zamanda temporal lobun medial ve inferior kısımlarının oksipital loblardaki görme korteksi ile yoğun bağlantıları vardı (Oğul ve ark. 1996).

İşitme temporal loblarda iki taraflı edilir. Düşük tonlardaki sesler yanlarda yüksek tondaki sesler ise ortadadır. Lisan fonksiyonunda sesler için dominant hemisferdeki işitme korteksi önemli iken, diğer sesler, müzik ve ritm sesleri için ise nondominant hemisferdeki oditer korteks çok önemlidir. Belli alanların unilateral lezyonunda karşı taraf kulakta çok az işitme azlığı ile beraber o kulağa gelen seslerin yön ve mesafelerinin ayırt edilmesi güçleşir. Bunun hasta tarafından farkına varılabilmesi pek mümkün değildir (Oğul ve ark. 1996).

Primer işitme alanının hemen yanında Wernicke Alanı vardır. Bu alanın uniteral lezyonunda hasta sesleri duyar, ancak ne konuşulduğunu anlayamaz; buna kelime sağırlığı veya sensorial afazi denir. Aşırı konuşma vardır ancak anlam pek yoktur. Kelimelerde yer değiştirme (parafazi) veya yeni kelimeler üretme (neologizm) ortaya çıkar. Temporal lob korteksinin medial bölgesinin (hipokampus) öğrenme ve yakın bellek ile ilişkisi olduğu görüşü vardır. Hipokampusun bilateral lezyonlarında yakın olaylara ait bellek kaybı ve hafif derecede davranış değişiklikleri

görülür, uzak bellek ise genellikle bozulmaz. Bu hastalar yeni olaylar öğrenmede, yeni beceriler elde etmede zorluk çekerler (Oğul ve ark. 1996).

4.2.4. Oksipital lob korteksi

Oksipital lob korteksi esas olarak görme korteksinden oluşmuştur. Bu alanların özellikle dominant hemisferindeki lezyonlarında vizüel agnozi veya psişik körlük görülür. Kişinin görme keskinliği ve zekası normal olduğu halde, gördüğü cismi tanıyamaz, isimlendiremez ve fonksiyonunu söyleyemez (Oğul ve ark. 1996).

Bazı alanların lezyonunda ise hasta gördüğü cisimlerin renklerinin parlaklığını kaybettiğini ve baktığı her şeyi gri renkte gördüğünü ifade eder. Bu durum konjenital renk körlüğünden farklıdır. Oksipital loba ait görsel halüsinasyonlar yarım görme alanında olup şekilsiz veya zig-zag çizgiler biçimindedir.

4.2.5. Limbik lob korteksi

Limbik sistemin bütün kısımları birbirleri ile sıkıca bağlanmıştır. Bu devrede hipotalamus emosyonel davranışlardaki motor ve endokrin cevapları entegre ederken, telensefalon emosyonel cevapları suprese etmekte ve hipotalamusun dış dünya ile bağlantısını sağlamaktadır. Neokorteks aynı zamanda korku, öfke haz, hoşnut olma gibi emosyonel tecrübelerle ilişkilidir (Oğul ve ark. 1996).

Sonuç olarak insanı rahatsız eden veya haz veren bir stimulusun iki yönlü etkisi vardır. Birincisi bu stimuluslar hipotalamusun entegre ettiği otonomik endokrin cevapları tetikleyerek organizmaya saldırı, kaçma, seksüel deneyim veya diğer ayarlanabilir davranışlar için hazırlar. İkincisi ise telensefalonun devreye girmesi ile stimulusa karşı verilebilecek en uygun cevabı ayarlar (Oğul ve ark. 1996).

4.3. Serebral dominans

Kortikal fonksiyonlar açısından her iki hemisfer birbirinin aynı gibi düşünülürse de, bazı fonksiyonlar için birinin diğerine göre üstünlük gösterdiği bilinmektedir. Bu nedenle hemisferler dominant ve non-dominat olarak ikiye ayrılmıştır. Yapılan çalışmalar konuşma, duyarak ve okuyarak anlama, tekrarlama, isimlendirme, yazma gibi lisan fonksiyonları, çizme, sayısal hesaplama, analitik fonksiyonlar, okuma ve praksi gibi fonksiyonların daha çok sol hemisferde, müzik, emosyonel çeşitlilik, yüzleri tanıma, basit uzay kavramı ve dikkatin sürekliliğinin ise daha çok sağ hemisferle ilişkili olduğunu göstermiştir. Bunlardan en çok üzerinde durulan fonksiyon lisan fonksiyonudur (Yaltkaya ve ark. 1996).

Lisan fonksiyonlarında dominant hemisfer ile el kullanım baskınlığı yönü arasında çapraz ilişki vardır. Yapılan araştırmalarla popülasyonun %90-95'inde kesin ya da öncelikle sağ el baskınlığının olduğu ve bunlarda lisan fonksiyonunun sol hemisfer yoluyla ortaya konduğu gösterilmiştir (Yaltkaya ve ark. 1996).

4.4. EEG Jeneratörleri

EEG, serebral biyoelektrik aktivitesinin saçlı deriden kaydedilerek ölçülmesinde rutin olarak kullanılan nörofizyolojik bir tanı yöntemidir. İlk defa 1924 yılında insanda saçlı deriden elektrik dalgaları kaydedilmiştir. Günümüzde de özellikle epilepsi ve uyku araştırmalarında önemini korumaktadır ve bu konuda diğer araştırma yöntemleri EEG kadar bilgi vermemektedir. Ayrıca EEG, beyin lezyonları hakkında da bilgi vermektedir (Yaltkaya ve ark. 1996).

EEG, kortikal nöron membranlarının elektriksel yükündeki değişimlerden kaynaklanır. Diğer sinir hücreleri gibi bu nöronlarda da istirahat (resting) potansiyeli vardır. Bu potansiyel, hücre içi ve dışı ortamlar arasındaki elektrik potansiyel farkından oluşur. İstirahat potansiyeli, temas noktalarındaki diğer nöronlardan veya hücre gövdesinde veya uzantılarında yer alan sinapslardan gelen sinyal nedeniyle

dalgalanır. Bu tip uyarılar görece kararlı postsinaptik potansiyelleri (PSP) oluşturur. Böylelikle hücrenin gövde membranında ve dendritlerde elektriksel akıma neden olur. Bu değişiklikler membran potansiyelini kritik bir düzeye indirebilir. Bu noktada membran yükünü tamamen kaybederek, akson boyunca dağılan kısa süreli bir aksiyon potansiyeli yaratır. Yüzeysel EEG'deki dalgalanmalar, esas olarak görece yavaş postsinaptik potansiyellerin oluşturduğu elektrik akımlarının zamansal ve uzamsal birikimi ile gerçekleşir. Kısa süreli aksiyon potansiyellerinin bir etkisi yoktur veya çok azdır. Bir nöronun istirahat potansiyeli 50-100 μ V arasında değişir (Fisch 1997).

Elektriksel potansiyel değişikliklerinin kortekste toplanması (sumasyon), esas olarak korteksin vertikal olarak dizilmiş geniş piramidal nöronlarında gerçekleşir. Bunun nedeni ise piramidal nöronların dendritleri korteksin hemen hemen tüm katmanlarına yayılır ve korteksin derin katmanlarındaki hücre gövdelerinde ya da korteksin yüzeysel katmanlarındaki dendritlerde postsinaptik potansiyellerin yarattığı akımların yayılmasını sağlar. Ayrıca bu nöronlar birbirlerine sıkıca bağlanmış ve paralel şekilde dizilmiştir. Bu dizilim her nöron tarafından yaratılan akımların uzamsal toplanmasını kolaylaştırır. Bu nöron kümeleri benzer sinyaller alır ve benzer yön ve zamanlamasının potansiyel değişimleri ile yanıt verir. Bu nöronlarca üretilen akımlar, ekstrasellüler ortamda toplanır. Akımların çoğu kortekste sınırlı kalır. Ancak küçük bir kısmı menenksler, BOS ve kafatası yoluyla saçlı deriye nüfuz eder ve saçlı derinin değişik bölgelerinin değişik potansiyel düzeylerinde olmasına neden olur. Bu potansiyel farklılıklarının genellikle sadece 10-100 μ V'luk amplitüdü vardır; iki elektrot arasında kaydedilebilir ve EEG'yi oluşturur (Fisch 1997).

EEG, nöronal potansiyel değişikliklerinin sonucu olmakla birlikte, altta yatan nöronal olaylara dayanarak tanımlanamayacak kadar karmaşıktır. Örneğin, saçlı deride kaydedilen bir potansiyel değişim, korteks yüzeyine yakın dendritlerin ürettiği aynı polaritedeki bir potansiyel değişiklikten kaynaklanabileceği gibi, korteksin derinliklerinde yer alan hücre gövdelerinde oluşan zıt polaritedeki bir potansiyel değişiklik nedeniyle de oluşabilir. Bu nedenle bir yerdeki eksitasyon, bir başka yerdeki inhibisyondan ayırt edilemez. Tek tek nöronların veya özgül nöron gruplarının aktivitelerine ilişkin sadece spekülasyon yapılabilir. Dolayısıyla EEG'yi

oluşturan hücresel mekanizmalar bugün oldukça iyi bilinmekle birlikte, bu bilgi EEG'nin klinik yorumuna doğrudan uygulanamaz (Fisch 1997).

4.5. Saçlı Deri Elektrotlarıyla Elektrik Potansiyellerinin Kaydı

Saçlı deri üzerindeki elektrotlar esas olarak altta bulunan kortekste toplanan elektriksel değişiklikleri kaydeder. Bu elektrotlar beynin uzak alanlarında ve beyin dışında oluşan potansiyel değişikliklerini de kaydedebilir. Kaydedilen potansiyellerin amplitüdü, elektriksel kaynağın şiddetine, uzaklığına ve uzamsal yönelimine, ayrıca kaynak ile kayıt elektrotları arasındaki yapıların elektriksel direnç ve kapasitansına bağlıdır. Bu etmenler kayıt elektrotlarının yakınında oluşan, geniş bir doku alanında üretilen, yavaş hızda artan ve azalan potansiyel değişikliklerin kaydedilmesini kolaylaştırır (Fisch 1997).

Altta bulunan kortekste üretilen potansiyeller saçlı deri EEG'sinin ana kaynaklarıdır. Saçlı deriden yapılan kayıtlarla, doğrudan korteks üzerine yerleştirilen elektrotlarla eşzamanlı alınan kayıtlar (elektrokortikogram=ECoG) farklıdır. Saçlı deri EEG'si düşük genliklidir ve şekil olarak da bozulmuş olabilir. Genellikle hızlı frekanslar yavaş olanlardan daha çok zayıflar. Saçlı deri kayıtlarında çok hızlı ve kısa potansiyel değişiklikleri tamamen kaybolabilir veya sadece üretildikleri yerlerde saptanabilir. Yavaş olanlar ise daha uzağa iletilebilir ve bu nedenle daha geniş alanlar üzerinde kaydedilebilir. Bu bozulma kısmen korteks ve saçlı deri elektrotları arasındaki yapıların elektriksel özelliklerine bağlıdır. Saçlı deri EEG'sinin amplitüdü şu nedenlerle azalabilir (Fisch 1997):

- Kaynak ile kayıt elektrotları arasında elektrik empedansında, örneğin kafatası kemik kalınlığında artma kaynaktan kayıt elektrotlarına doğru akımı azaltır.
- Bu akımların izlediği yolun empedansında bir azalma, örneğin subdural kanama veya serebrospinal sıvı, akımın yönünü elektrotlara ulaşmadan değiştirir.

Saçlı deri EEG'si doğrudan lokal potansiyel değişikliklerini yansıtmakla birlikte, dolaylı olarak beynin geniş bölgelerinde benzer şekil ve zamanlaması olan kortikal

potansiyellerin oluşmasına neden olan uzak alanlardaki anormalliklerini de gösterebilir. Bu mekanizma 'projeksiyon' veya 'bilateral senkroni' olarak bilinir. Sonuçta elde edilen ritimlere 'projekte ritimler' denir. Bilateral senkron deşarjların ritm merkezinin beynin merkezinde olduğu varsayıldığından 'sentrensefalik' terimi de kullanılır. Bu ritimler uzak merkezlerin etkisiyle açığa çıkartılabilirse de, uzak alanlarda değil, elektrotların altında bulunan korteks tarafından üretilir. Uzak alanlarda üretilen potansiyeller nadiren saçlı deri elektrotlarıyla kaydedilir. Bu, işlevi tamamen yok olmuş bir korteks alanı üzerindeki saçlı deri elektrotlarının, genellikle hiçbir elektriksel aktivite göstermediğinin gözlenmesiyle açıklanmıştır. Ancak, frontal kutuptan kaynaklanan yavaş dalgalar veya beynin mesial ve bazal kısımlarındaki dikenler gibi yüksek amplitüdü aktivite, nadiren aradaki dokunun volüm kondüksiyon etkisi ile iletilir. Oldukça uzaktaki saçlı deri elektrotlarında, lokal kortikal aktiviteyi gösteren EEG üzerine binmiş olarak ortaya çıkar. Kısmen veya bütünüyle çıkartılmış hemisferler üzerindeki saçlı deri elektrotlarında görülen EEG potansiyelleri ve cerrahi olarak beyne yerleştirilen ancak EEG potansiyeli üreten nöronlardan belli bir uzaklıkta tutulan elektrotlardan alınan derin EEG (DEEG: depth EEG) de elektriksel iletimi (volüm kondüksiyon) açıklayabilir (Fisch 1997).

Beyinden başka kaynaklarca üretilen potansiyeller, genellikle saçlı deri elektrotlarınca alınır ve EEG ile birlikte kaydedilir. Bu tip ekstraserebral potansiyeller genellikle 'artifaktlar' olarak isimlendirilir. Örneğin, kas üzerine yerleşmiş bir saçlı deri elektrotu, kas fibril aktivitesini kaydedebilir. Gözlerin, dil ve diğer geniş ve elektriksel yük taşıyan yapıların hareketi, değişen elektrik alanları oluşturabilir; bunlar saçlı deri elektrotlarınca kaydedilebilir. Kalp kasının kasılması saçlı deri elektrotlarında, EKG'de kaydedilenlere benzeyen potansiyel değişiklikler açığa çıkartabilir. Kayıt alanına yakın olan güçlü değişken akım kaynakları kayda karışabilir (Fisch 1997).

4.6. Elektrotların Yerleştirilmesi

Uluslararası EEG ve Klinik Nörofizyoloji Dernekleri Federasyonu tarafından önerilen 21 elektrotun tümü ve yerleştirme biçimi kullanılmalıdır. Uluslararası 10-20

sistemi, Uluslararası EEG ve Klinik Nörofizyoloji Dernekleri Federasyonu tarafından önerilen tek sistemdir (Fisch 1997).

Bu sistem ile elektrotları yerleştirmek, tüm saçlı derinin aynı şekilde kaplanmasını sağlar. Bu sistem, Şekil 4.2’de görüldüğü gibi baş üzerindeki kemik işaret noktaları arasındaki uzaklıkları kullanır ve başı boydan boya kateden ve toplam uzunluklarının %10 veya 20’si kadar olan aralıklarla bölünen bir çizgi sistemi yaratır (Fisch 1997). *10-20 sisteminin genel özellikleri:*

- Elektrotlar kesişme noktalarına yerleştirilir.
- 10-20 sistemi, simetrik, aynen yinelenebilen bir elektrot yerleştirimi sağlar.
- Aynı hastadan veya değişik hastalardan aynı veya değişik laboratuvarlarda kaydedilen EEG’lerin karşılaştırılmasına olanak verir.
- Sistem esnek; bir anormalliğin yerleşimini doğru olarak belirlemek için gerekebilecek ek elektrotlar, kesişme noktaları arasındaki uzaklıkların daha fazla bölünmesi ile sisteme katılabilir.

Erişkinlerde kullanılan standart elektrot seti (Şekil 4.2 ve Şekil 4.3) 21 kayıt elektrotundan ve bir toprak elektrotundan oluşur. Kayıt elektrotları bir harf ve bir satır altı harfi veya rakam ile gösterilir. Harf, elektrotun altındaki bölgeyi tanımlar: prefrontal veya frontopolar (Fp), frontal (F), santral (C), parietal (P), oksipital (O) ve auriküler (A). Satır altı, ya sıfır ya da orta hat yerleşimini gösteren z’dir veya lateral yerleşimi gösteren bir rakamdır. Tek sayılar sol taraftaki elektrotları, çift sayılar sağ taraftaki elektrotları işaret eder. Rakamlar orta hattan uzaklaştıkça yükselir. Ancak, temporal ve frontopolar elektrotların rakamları önden arkaya doğru yükselir.

Her kayıt elektrotunun yerini kesin olarak belirlemek için kesin ölçümler gereklidir. Ölçümler en iyi, plastik veya kumaştan yapılmış bir metreyle yapılır. Elektrot yerlerini işaretlemek için yağlı bir kalem kullanılır ve bunları belirlemek için ara ölçümler gerekir. Ölçümler, kafatasının 3 kemik işaret noktasına dayanır:


- *İnion*; başın arka kısmında, orta noktadaki kemik çıkıntı,
- *Nasion*; alnın altında yer alan burun köprüsü,
- *Preauriküler nokta*; kulak kanalı önünde yer alan çukurluk.

Elektrotlar, Fz, Cz ve Pz’ye, bunların yukarıda gösterilen bütün lateral noktalarına, A1 ve A2 olarak isimlendirilen pozisyonlarda kulaklara veya yakınlara veya M1 ve M2 denilen pozisyonlardaki mandibüler açı üzerine ve toprak elektrotu için


seçilen noktaya, genellikle başın orta noktasına veya mastoidlerden biri üzerine yerleştirilir (AEEGD 1996, Fisch 1997, Tükel 1979, Yaltkaya ve ark. 1996).

Günümüz teknolojisinde, üzerine 10-20 sistemine göre elektrotların yerleştirildiği esneyebilen başlıklar kullanılmaktadır. Bu sebeple de özel durumlar dışında EEG kayıtlarını yapacak olan teknisyenin her seferinde ölçüm yapıp elektrot yerlerini belirlemesine gerek yoktur.

Rutin EEG'de daha az sayıda elektrot kullanılması, artık gerekli düzeyin altında kabul edilmektedir. Eğer gerekirse bu elektrotlar arasına ilave elektrotlar yerleştirilebilir. Bazı vakalarda saçlı deri lezyonları, kafatası asimetrisi veya diğer anormallikleri 10-20 sistemi ile elektrot yerleştirilmesini olanaksız kılabilir. Böyle hastalarda elektrotlar, bu noktalara olabildiğince yakın ve olabildiğince her iki tarafta simetrik yerleştirilmelidir. Standart yerleşimden sapmalar EEG kaydı üzerindeki bir diyagramda belirtilmelidir (AEEGD 1996, Fisch 1997).



Şekil 4.2: Kayıt elektrotlarının yerleştirilmesi, a. Uluslararası 10-20 sistemindeki elektrot isimleri ve yerleştirilmesi, b-f. elektrot yerlerinin belirlenmesinin basamakları.



Şekil 4.3. Standart Elektrot pozisyonları

4.7. EEG Cihazı: Parçaları ve İşlevleri

EEG cihazının başlıca parçaları, giriş tablosu, sinyal seçici düğmeler, kalibrasyon, amplifikatörler, filtreler, ve yazıcı veya kayıt birimleridir (Şekil 4.4).

4.7.1. Giriş Tablosu

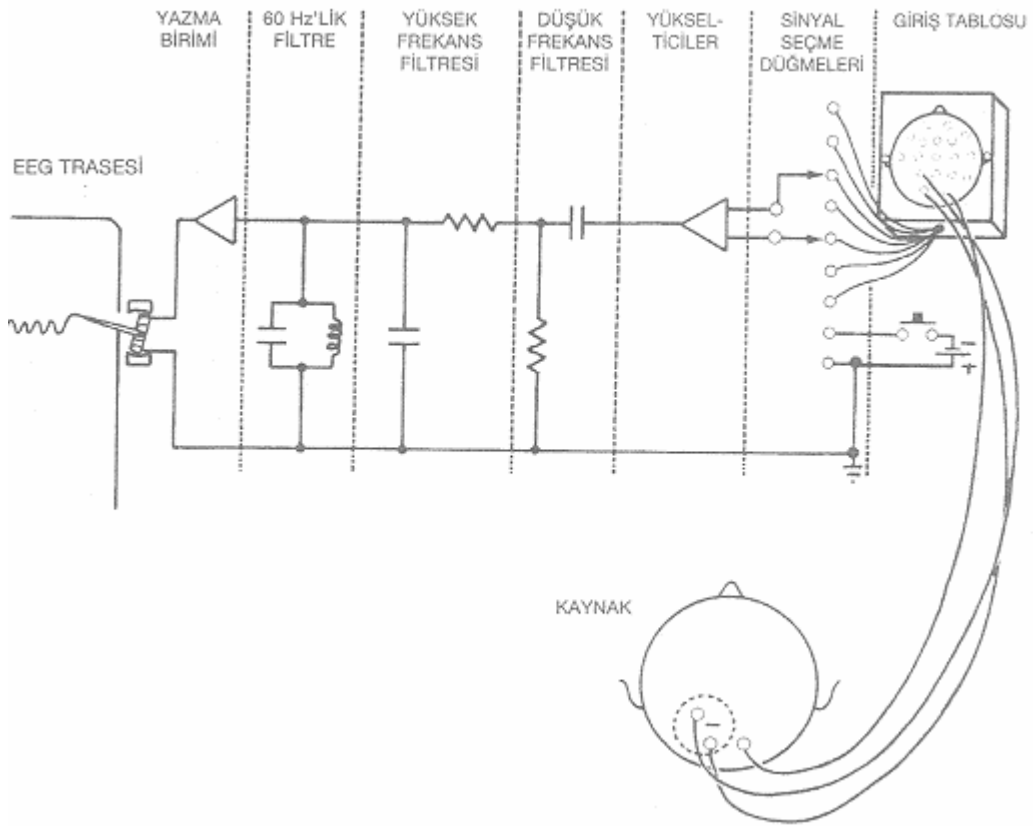
Hastanın başındaki elektrotları, EEG cihazındaki sinyal seçici düğmelere bağlamaya yarayan bir kutudur. Elektrotların uç noktaları, giriş tablosu üzerinde bir baş şeması olarak düzenlenmiş ve standart sembollerle işaretlenmiş yuvaya bağlanır. Giriş tablosunda elektrotlar arasındaki akımı sınırlandıracak devreler de bulunmalıdır. Hastanın güvenliği için giriş tablosu ve bağlantılarının, her elektrottan $20 \mu A$ 'den fazla bir akımın hastadan toprağa geçmesini önleyecek şekilde düzenlenmesi gerekir. Böyle akım kaçaklarını en aza indirmek için hasta, giriş tablosunda sonlanan bir toprak elektrotu aracılığıyla EEG cihazının toprak hattına bağlanır. Eğer EEG cihazı ve akım girişleri düzgün olarak topraklanmışsa, bu toprak elektrotu EEG cihazının şasisi ve odadaki diğer topraklanmış metal cihazlar ile eşit potansiyelde olur. Hastadan kazayla akım geçme olasılığını daha da azaltmak için hasta, toprak hattına sadece bir elektrot ile bağlanmalıdır (Fisch 1997).

4.7.2. Sinyal seçici düğmeler

Her amplifikatöre bağlanacak iki elektrotu seçmek için kullanılır. Seçilen elektrotlar, amplifikatör ve yazıcı birim bir sistem oluşturur ve bir elektrot çiftinin arasındaki potansiyel farkını saptar, kuvvetlendirir ve yazdırır. Bu sisteme 'kanal' adı verilir.

4.7.3. Kalibrasyon

Klinik EEG'de kalibrasyonun iki esas amacı vardır: EEG potansiyellerinin voltajını, voltajı bilinen bir potansiyelle karşılaştırarak ölçmek ve tüm kanallarda aynı sinyalin aynı şekilde amplifiye olup olmadığını saptamaktır (Fisch 1997).



Şekil 4.4. EEG cihazının yapısı

En sık kullanılan kalibrasyon yöntemi olan tüm amplifikatör kanallarına eşzamanlı standart voltaj sinyalleri gönderilmesi ile her iki amaca da ulaşılır.

Biokalibrasyon ise amplifikatörlerin performansını karşılaştırmak, daha da önemlisi tüm kayıt sisteminin doğruluğunu test etmek için hastanın EEG'sinde kullanılabilir. Bu karşılaştırma için, göreceli yüksek amplitüdü EEG frekanslarının geniş bir dizisini elde etmek üzere, genellikle bir frontopolar elektrot ile karşı hemisferde bir oksipital elektrot tüm amplifikatörler için sinyal (input) olarak seçilir. Tüm kalemlerin traseleri aynı olmalıdır (Fisch 1997).

4.7.4. Amplifikatörler

EEG amplifikatörlerinin iki esas amacı vardır: Bunlar Diskriminasyon ve amplifikasyondur (Fisch 1997).


a. Diskriminasyon: İki girişe bağlanan elektrotlar arasındaki elektrik potansiyel farklılıklarını algılama yeteneğidir. Her iki elektrotta ortak olan potansiyeller ise rejeksiyona uğrar. Bu duruma common mode rejeksiyon olarak adlandırılır.

EEG cihazının her amplifikatöründe iki adet giriş terminali bulunur. Bunlara 'giriş 1' ve 'giriş 2' adı verilir Her terminale uygulanan potansiyel değişiklikleri veya sinyaller aynı derecede ancak amplifikatörün toprak hattına göre ters yönde amplifiye edilirler. Bu, giriş 2'ye uygulanan sinyalin polaritesini ters çevirerek, giriş 1'e uygulanan sinyalden efektif olarak çıkarılmasıyla yapılır. Bu uygulama biçimine 'diferansiyel' veya 'dengeli' amplifikasyon denir (Şekil 4.5).

Bu nedenle bir diferansiyel amplifikatörün çıkış sinyalinin polaritesi, sadece giriş sinyalinin polaritesine değil, aynı zamanda hangi giriş terminaline uygulandığına da bağlıdır.

Diferansiyel amplifikasyonun esas amacı beyinden gelmeyen elektrik potansiyellerini dışlamaktır. Beyinden gelen potansiyeller genellikle saçlı deri üzerinde eşit olarak dağılmamıştır. Bu nedenle, amplifikatör girişlerine bağlı bazı saçlı deri elektrotlarında değişik potansiyel düzeylerinin görülmesine neden olur. Beyin dışından kaynaklanan potansiyeller ise tersine, genellikle tüm saçlı deri elektrotlarını eş düzeyde etkiler; diferansiyel amplifikatör bunları atar ya da yok eder. Bu, özellikle 50 Hz'lik

elektrik girişimi için doğrudur. Ancak diferansiyel amplifikasyon her zaman serebral aktivite ve artefaktları ayırt etmez; çünkü bir kısım artefaktlar bazı saçlı deri elektrotlarında biraz farklı potansiyeller oluşturabilir (Fisch 1997)



Şekil 4.5. EEG cihazlarında amplifikasyon ve diskriminasyon işlemi

b. Amplifikasyon : Amplifikasyon, potansiyel farklılıklarının EEG cihazının kalemlerini oynatabilecek ve kağıda yazdırılmasına olanak verecek düzeyde artırılmasına hizmet eder. Amplifikatör, bu işlemi girişler arasındaki voltaj farkını artırarak yapar. Bu büyütme eylemi, duyarlılık ve kazanç (gain) terimleri ile karakterize edilebilir. Duyarlılık, giriş voltajının, kendi yarattığı kalem sapmasına oranıdır (Fisch 1997)

4.7.5. Filtreler

Filtreler EEG'den gelen görece yüksek veya düşük frekanslardaki dalgaları dışlamak için kullanılır. Böylelikle yaklaşık 1-30 Hz'lik en önemli orta frekans aralığındaki dalgalar açıkça ve bozulmadan kaydedilebilmektedir.

50Hz filtresi, yüksek ve alçak frekans dalga formlarının önemli bir zayıflama olmadan geçmesine izin verdiği için dar frekans bandı ya da 'notch' (çentik) filtre olarak isimlendirilir. 50 Hz'lik filtre, en sık görülen elektrik artefaktını yani, alternatif

akım kullanan cihazların yarattığı girişimi ortadan kaldırmak için birçok EEG cihazında bulunmaktadır. Bu filtre 50 Hz'lik sinüzoidal dalgaların amplitüdünü azaltır. Ancak bunu, komşu frekanslardaki dalgaların amplitüdünü de bir miktar azaltmadan yapamaz. 50 Hz'lik sinüzoidal dalgaların genellikle beyinden kaynaklanmamasına ve EEG kayıtlarında ayırt edilebilmesine karşın, 50 Hz'lik filtreler bazı nedenlerden dolayı rutin olarak kullanılmamalıdır. (1) Dikenler gibi bazı EEG bileşenlerinin 50 Hz frekansına karşılık gelen bir eğimi olabilir. 50 Hz'de süzme, yüksek frekans filtresiyle süzme gibi, bu bileşenleri tanınamayacak kadar azaltabilir. (2) 50 Hz'lik girişim, zayıf bir elektrot temasını veya doğru olmayan bir giriş seçimini gösterebilir. Dikkatsizce 50 Hz filtre kullanılması halinde bunlar saptanamaz ve düzeltilemez (Fisch 1997).

4.8. Klinik EEG Kaydı

Klinik EEG kaydı klinik yorum için gerekli olan normal ve anormal paternleri yeterli düzeyde sergilemelidir. Bu amaca hizmet etmek için kayıt yöntemleri belirli genel teknik gereksinimleri karşılamalıdır. Süt çocukları ve küçük çocukların kayıtları, tüm gece uykusu kaydı, beyin ölümü kuşkusunu değerlendiren kayıtlar ve telefonla aktarılan kayıtlar için özel gereksinimler vardır. Bu gereksinimler Amerikan EEG Derneği'nce yayınlanan 'EEG kılavuzunda tanımlanmıştır (AEEGD 1996, Fisch 1997).

4.8.1. Klinik EEG kaydı için genel teknik standartlar

Elektrotların yerleştirilme düzeninin Uluslararası 10-20 sistemine göre belirlendiğinden daha önce de bahsedilmişti. Bu sisteme göre her birinin 5000 ohm empedans değeri altında elektrik teması olan en azından 21 kayıt elektrotu yerleştirilmelidir. Kayıt en az 8 kanalla yapılmalıdır. Amplifikatörlerin başlangıç duyarlılığı (sensivitesi) 5-10 $\mu\text{V}/\text{mm}$ olmalı ve sonradan gerektiği gibi ayarlanmalıdır. Filtreler, yüksek frekans filtresi 70 Hz ve alçak frekans filtresi 1 Hz olan en düşük frekansa (%30 zayıflama) göre düzenlenmelidir. Kaydın başında ve

sonunda kalibrasyon sinyalleri, elektrot testi ve bütün kanallara bağlı aynı elektrot çiftinden alınan serebral aktivitenin kullanıldığı bir kayıt testiyle kalibrasyon yapılmalıdır. Kağıt hızı genellikle 3 cm/sn olarak seçilir. Uyanıklık durumunda en az 20 dakikalık artifaktan arınmış bir kayıt elde edilmelidir. Uyanıklık, uyarıcı sorular sorarak (örn. tarih, hesap etme) daima açıkça gösterilmeli ve hastanın yanıtları kayıt üzerine belirtilmelidir. Ayrıca konvülfif bir bozukluktan kuşkulandığında hiperventilasyon, fotik uyan ve uyku sırasında mutlaka kayıt yapılmalıdır (AEEGD 1996, Fisch 1997).


4.9. EEG Aktivitesini Tanımlayan Nitelikler

EEG aktivitesini tanımlayan nitelikler, dalga formu, tekrarlama, frekans, amplitüd, dağılım, faz ilişkisi, zamanlama, kararlılık ve reaktivitedir.

4.9.1. Dalga formu

Dalga formu veya biçimi bir dalganın görünüşünü tanımlamak için kullanılan basit terimlerdir. Formuna bakılmaksızın, iki kayıt elektrotu arasındaki herhangi bir elektriksel potansiyel değişikliğine dalga denir (Şekil 4.6). Her dalga veya dalga dizisi aktivite olarak adlandırılır. Birçok dalga formu düzenlidir. Yani, simetrik yükselme ve alçalma fazı nedeniyle oldukça değişmez bir yapıya sahiptir (Şekil 4.6-1) (Fisch 1997).

Bazı düzenli dalgalar sinüs dalgalarına benzerler. Bu nedenle sinüzoidal olarak tanımlanır (Şekil 4.6- 2). Diğer düzenli dalga formları, yay şeklinde veya testere dişi şeklinde olabilir. Düzensiz dalgaların şekilleri ve süreleri eşit değildir (Şekil 4.6-4). Monofazik dalga, izoelektrik çizgiden yukarı veya aşağı yönde tek bir defleksiyon gösteren dalgadır. Difazik dalganın zıt yönlerde iki bileşeni, trifazik dalganın ise izoelektrik çizgi etrafında değişen üç bileşeni vardır. Polifazik dalganın değişik yönlerde, iki veya daha fazla bileşeni vardır. Bu terimler bir dalganın pozitif veya negatif polaritesini ya da kaydın bipolar veya referans elektrot montajı ile yapıp yapılmadığını göstermez (Fisch 1997).



Şekil 4.6. EEG sinyalinin Karakteristik dalga formları

Transient, zemin aktivitesinden belirgin olarak ayrılan bir olaydır. Tek bir dalgayı içerebileceği gibi kompleks de olabilir. Yani ayırt edici bir formu olan ya da oldukça tutarlı biçimiyle yineleyen iki veya daha fazla dalga dizisinden oluşabilir. (Şekil 4.6- 5).

Keskin dalga (sharp wave) 70-200 msn sürelidir ve diken kadar keskin konturlu olmayabilir (Şekil 4.6- 6). Keskin konturlu dalga formları eğer; zemin ritminin bir parçası ise (örn. mu ritmi), izole ya da zemin ritminin bir parçası olarak değişik zamanlarda gözleniyorsa (değişken bir morfoloji gösteriyorsa, tüm kayıt süresince sadece bir kez görülmüşse, keskin transientler olarak anılır. Çünkü konvülfif bozuklukların tanısında stereotipik dikenler ya da keskin dalgalara göre daha az önemlidir (Fisch 1997).

Keskin transientler, alışılmış EEG kayıt hızlarında keskin bir pike sahip, herhangi bir süredeki dalgadır. Anormal epileptiform tarzında olmayan keskin konturlu dalga formları sıklıkla keskin transientler olarak kabul edilir. Epileptiform, özellikle nöbet ya da epilepsi ile bağlantılı olanlarla özdeş EEG paternlerini tanımlamak için kullanılan bir terimdir. Epileptiform paternler genellikle diken veya keskin dalgalardan kabul edilen apiküler dalga formlarıdır. Diken (spike), 20-70 msn'lik keskin konturlu dalga formudur (Şekil 4.6- 7) .

Diken bazen yavaş bir dalga tarafından izlenebilir ve düzenli aralıklarla yineleyebilen diken ve dalga kompleksi oluşur (Şekil 4.6-8).

Üç Hz'den düşük hızlarda yineleyen diken-dalga kompleksleri yavaş diken-ve-dalga kompleksleri olarak isimlendirilir. Bir keskin dalgayı yavaş bir dalga izlerse keskin-ve-yavaş dalga kompleksini oluşturur. Bu tür kompleksler genellikle saniyenin üçte birinden daha uzun sürmez, bu nedenle de 3 Hz'lik bir hızın üzerinde yinelemez. Bazı durumlarda iki ya da çok diken ard arda ortaya çıkıp polispike kompleksi olarak da isimlendirilen multiple diken kompleksini (multiple spike complexes) oluşturur (Şekil 4.6- 9) (Fisch 1997).

Bu kompleksler yavaş bir dalga tarafından izlenebilir ve böylece çoklu diken-yavaş dalga kompleksinin ya da polispike ve yavaş dalga kompleksinin bir parçasını oluşturur (Şekil 4.6-10). EEG'de kaydedilen bu dikenler, sadece 1 msn kadar süren ve beyne yerleştirilen mikroelektrotlarla kaydedilen tek nöronun aksiyon potansiyeli ile karıştırılmamalıdır.

Birkaç saniyeden kısa süren ve diken ve keskin dalga içeren kompleksler ile tek diken ve keskin dalgalar interiktal epileptiform aktivite olarak isimlendirilir. Bu aktivitelerin ve bazı diğer tiplerin birkaç saniyeden daha uzun sürmesi durumunda bunlar nöbet paterni ya da iktalpatern olarak değerlendirilir. Nöbet paternleri çoğunlukla klinik nöbet tablosuyla ilişkilidir ancak bu tür bir ilişki olmaksızın da ortaya çıkabilir (Fisch 1997). Paroksizim ya da paroksizmal deşarj, ani başlayan, maksimum amplitüde hızla ulaşan ve aniden kaybolan bir veya daha fazla sayıdaki dalgadır. Bu dalgalar zeminden belirgin bir biçimde ayrılır, genellikle anormaldir ve sıklıkla epileptiform paternler içinde görülür. Paroksizimler sıklıkla kompleksleri içerir (Şekil 4.6-5). Ancak tüm kompleksler aniden başlayıp bitmez ve tüm paroksizimler benzer biçimlerde yinelenmez.

Diken(ler), keskin dalga(lar), paroksizim ve paroksizmal deşarj terimleri sıklıkla epileptiform paternleri tanımlamak için kullanılmakla birlikte, bunların epileptiform aktivite ile eş anlamlı olmadığını belirtmekte yarar vardır (Fisch 1997).

4.9.2. Yineleme

Dalgaların yinelemesi ritmik veya aritmik olabilir. Ritmik yinelemeli dalgalarda, tek tek dalgalar arasında benzer aralıklar vardır; genellikle düzenli ve sıklıkla da sinüzoidaldir (Şekil 4.6- 1-3). Uyku içcikleri (spindles) amplitüd olarak yavaş yavaş yükselen ve daha sonra alçalan ritmik yinelemeli dalga gruplarıdır (Şekil 4.6, 3). Önceleri ritmik yinelemeli dalgalar 'monoritmik' ya da 'monomorfik' olarak isimlendirilirdi. Aritmik yinelemeli dalgalar, tek tek dalgalar arasında değişken, düzensiz aralıklarla tanımlanır (Şekil 4.6, 4). Bunlar değişik frekanslardaki dalga dizileri olarak kabul edilebilir. Genelde düzensiz bir biçimleri vardır. Aritmik düzensiz dalgalar önceleri 'poliritmik' ya da 'polimorfik' olarak isimlendirilirdi (Fisch 1997).

4.9.3. Frekans

Frekans, yinelemeli bir dalganın bir saniye içinde kaç kez yinelendiğini gösterir. Bir saniyede 3 çevrimi tamamlayan bir dalgaya 3 Hz'lik ya da saniyede 3 kez yineleyen

dalga denir. Bir dalganın ya da yinelenmeli dalganın frekansı tek bir dalganın süresi ve dalgaboyu ölçülerek (Şekil 4.6-1) ve evrik değeri hesaplanarak belirlenir. Örneğin, yinelesin ya da yinelenmesin, 250 msn ya da 1/4 saniye süren bir dalganın, 4 Hz'lik frekansı vardır denir. Tek dalgalar ve kompleksler dalga boylarından daha uzun aralıklarla yineleyebilir, bu durumda periyodik diye isimlendirilirler. Dalgalar arasındaki zaman aralığına da periyot denir. EEG dalgalarının frekansı genellikle 4 gruba ya da frekans bandına ayrılır:

- $\delta < 4 \text{ Hz}$
- $4 < \theta < 8 \text{ Hz}$
- $8 < \alpha < 13 \text{ Hz}$
- $13 < \beta$

Bu ayrımlar biraz keyfidir. Çoğu EEG'de bantların sınırları dışına yayılan dalga frekansları vardır; örneğin, 3-5 Hz'lik dalgalar. Yine de frekans bantları, EEG'deki en önemli normal ve anormal dalgaları ayırmaya yardım eder ve frekans, klinik EEG'de anormalliklerin belirlenmesinde en önemli ölçütlerden biridir. 8 Hz'nin altındaki dalgalar genellikle yavaş dalgalar ve 13 Hz üzerindeki de hızlı dalgalar olarak isimlendirilse de, aktivitenin frekansını belirtmek ya da bulunduğu frekans bandına göre tanımlamak (örn. delta ve teta aktivite) daha doğrudur. 1/2 Hz altındaki ve 20 Hz üstündeki frekansların, rutin saçlı deri kayıtları açısından sınırlı bir klinik yararı vardır. Çünkü çoğunlukla bu aktivitenin serebral kökenli olup olmadığı açık değildir (Fisch 1997, Tükel 1979).

4.9.4. Genlik

EEG dalgalarının amplitüdü, mikrovolt (μV) düzeyinde ölçülür. Bir dalganın toplam vertikal uzunluğunun, aynı kazanç (gain) ve filtre ayarlarında kaydedilmiş kalibrasyon sinyali yüksekliğiyle kıyaslanması ve ölçülmesiyle belirlenir. Örneğin, bir EEG dalgasının yüksekliği 14 mm ve 50 μV 'lik kalibrasyon sinyali 7 mm olarak ölçülmüşse, dalganın amplitüdü 100 μV 'dir. Eğer bir amplifikatörün duyarlılığı 7 $\mu\text{V}/\text{mm}$ olarak biliniyorsa doğrudan bir kıyaslama yapmadan kalibrasyon uyarısıyla (pulse) 7 mm'lik bir dalganın 50 μV 'luk bir amplitüdü olduğu anlaşılabilir (Fisch

1997). Amplitüd hiçbir zaman kalem sapmasının boyuna dayanarak belirtilmemelidir, çünkü, sapma, cihazın ayarlanmasına bağlı olarak değişir.

Önemli bir anormallik, başın karşılıklı iki yanında eşzamanlı olarak kaydedilen aktivitenin amplitüdündeki asimetridir. Eğer sürekli ise, amplitüddeki en ufak değişiklik bile klinik önem taşır. Bu, özellikle erişkin EEG'si açısından alfa ritmi dışında geçerlidir.

Amplitüddeki değişimler bazen beyin dışı etmenler, özellikle empedans farkı olan ve eşit mesafelerde yerleştirilmeyen elektrotlar nedeniyle oluşabilir. Bu nedenle anormal amplitüdün gerçek olduğunu kabul etmezden önce teknisyen, elektrotların doğru yerleştirildiğini ve empedansı denetlemelidir.

4.9.5. Dağılım

Dağılım başın farklı bölgeleri üzerine yerleştirilen elektrotlarla kaydedilen elektriksel aktivitenin oluşumunu anlatır. EEG paternleri başın her iki tarafında geniş alanlarda olabileceği gibi tek hemisferde de bulunabilir ya da küçük bir alanda sınırlı kalabilir (Fisch 1997).

- *Yaygın, difüz veya jeneralize dağılım*, başın tümünde veya tümüne yakın kısmında aynı zamanda görülen aktiviteyi ifade eder. Jeneralize aktivitenin, dağılım alanı içinde açıkça maksimum bir amplitüdü olabilir ve bulunduğu alanda yapılan bipolar kayıtlarda faz karşılaşması ve referans montajda çok yüksek amplitüdle tanınır

- *Lateralize dağılım*, sadece ya da çoğunlukla başın tek yanında görülen aktiviteyi ifade eder. Lateralize aktivite anormaldir; ya anormal aktivitenin bulunduğu tarafta ya da normal aktivitenin bulunmadığı tarafta serebral bir anormalliği düşündürür. Bazı normal paternler başın bir tarafında bir süre görüldükten birkaç saniye ya da dakika sonra diğer alanda oluşabilir.

- *Fokal aktivite*, başın bir alanı üzerindeki bir veya birkaç elektrotla sınırlı olarak saptanabilen aktivitedir. Bazı komşu elektrotlar bu aktiviteyi daha düşük amplitüdü olarak alabilir. Bu sınırlı dağılım, bir bölgede maksimum amplitüdü olabilecek geniş ya da jeneralize bir dağılımdan ayırt edilmelidir. Bu ayırımı özellikle anormal yavaş ve keskin dalga söz konusu olduğunda önemlidir. Bu ayırımın yapılmasında kimi zaman yararı olan ölçüt, jeneralize yavaş dalgaların tersine, fokal yavaş dalgaların

maksimum amplitüdün olduğu alanda sıklıkla daha düşük bir frekansa sahip olmasıdır. Yayılma eğilimi olan fokal keskin dalgalar, lokal maksimum amplitüdü jeneralize keskin dalgalardan, odakta kalmaktaki daha büyük ısrarıyla ayrılabilir. Tek bir ünilateral odaktan kaynaklanan aktivite her zaman anormaldir. Orta hat bir odaktan ya da iki hemisferde simetrik olarak bulunan iki odaktan kaynaklanan aktiviteler normal bir paternin parçası olabilir (Fisch 1997).

4.9.6. Faz ilişkisi

Faz, bir veya birkaç kanaldaki dalga bileşenlerinin zamanlama ve polaritesini ifade eder. Değişik frekanstaki dalgalar değişik kanallarda ortaya çıkabilir Böylece aynı anda pikler ve çukurlar oluşur. Bu dalgaların faz birlikteliği (in phase) içinde olduğu söylenir. Eğer bu tarzda bir araya gelmemişlerse o zaman faz ayrılığı (out of phase) vardır denir. Faz farklılıkları, faz açılarına dayanarak ifade edilebilir. Örneğin, zıt yöndeki pik noktalan 180° faz ayrılığı gösterir. Böylesi bir 'faz karşılaşması', bipolar kayıtlarda EEG potansiyellerinin kaynağının en büyük göstergesidir. Faz, tek bir kanalda, bir ritmin değişik bileşenleri arasındaki zaman ilişkisini gösterir (Fisch 1997).

4.9.7. Zamanlama

Başın değişik alanlarındaki dalgaların zamanlaması, aynı veya farklı olabilir. Simültane (eşzamanlı) ve senkron terimleri iki olayın aynı zamanda oluştuğunu ifade eder. Bu terimler genellikle aynı anlamda kullanılır. Ancak 'senkron' terimi bazen tam bir aynı anda oluşumu vurgulamak için kullanılırken, 'simültane' daha geniş olarak, EEG'nin görece daha yavaş kayıt hızı sınırları içinde, sadece kesin olmayan bir tarzda görülebilen aynı anda oluşumu belirtmek için kullanılabilir. Komşu kanallarda olsa bile, iki dalga üzerindeki karşılıklı noktalar arasındaki lmm'den az yatay farklılık çıplak gözle zorlukla ayırt edilebilir. Alışılmış EEG kayıt hızında sadece 1 mm'lik yatay uzaklık, 33 msn'lik bir zaman farkına karşılık gelir. Eğer yazıcı birimler tam olarak sıraya konulmamışsa ve daha uzak kanallar kıyaslanıyorsa, zaman ilişkilerinin çözülümü bozulur; kalemlerin dairesel

hareketi nedeniyle farklı amplitüdlerin senkronik hareketi farklı zamanlarda oluşmuş gibi görünür (Fisch 1997).

Başın her iki tarafında aynı zamanda oluşan dalgalar için bilateral senkron veya bisenkron terimleri kullanılır. Bu terimler esas olarak her iki hemisfer arasındaki ilişkiyi dikkate alır; aynı hemisferdekiler için böyle bir zorunluluk yoktur. Bu nedenle bilateral senkron dalgalar aynı hemisfer içinde faz ayrılığı gösterebilir. Bazı durumlarda, başın önünden arkasına doğru yerleştirilen elektrotlar aracılığıyla aktiviteleri kaydedilen dalgalar, önden arkaya doğru yayıldıkları izlenimi yaratarak ardışık kanallarda eşit süreyle gecikebilir. Örneğin bu tip bir gecikme metabolik ensefalopatilerin trifazik dalgalarında görülebilir. Değişik kanallarda oluşan ve aralarında sabit zaman ilişkisi olmayan dalgalara asenkron dalgalar denir. Bu genellikle, aynı frekansta olmasalar ya da aynı fazda birleşmeseler bile, değişik alanlarda aynı zamanda ortaya çıkan dalgaları gösterir. Eğer dalgalar bir an bir alanda, başka bir zaman da başka bir alanda oluşuyorsa, bunlara bağımsız denir. Örneğin temporal loblardaki dikenler bisenkron veya bağımsız oluşabilirler; her vakada olası tetikleyici mekanizmalar farklılık gösterir (Fisch 1997).

4.9.8. Israrlılık

Israrlılık, bir kayıt esnasında bir dalga veya paternin hangi sıklıkla oluştuğunu tanımlar. Bazı dalgalar, tek bir dalga formunda ya da dalga silsilesi biçiminde, çok seyrek ya da aralıklı olarak oluşur. Diğer dalgalar tüm kayıt süresince ya da büyük bir kısmında görülür. Bir dalga formunun ısrarlılığı o dalganın toplam tekrar süresinin tüm traseye oranı ile tahmin edilebilir. Buna indeks denir. Örneğin delta indeksi %20 denildiğinde, delta aktivitesinin bir kaydın 5'te 1'i süresince görüldüğü anlaşılır. EEG paternlerinin klinik öneminin sıklıkla, sadece ısrarlılıklarına değil, aynı zamanda amplitüdlere de bağlı olması nedeniyle, ısrarlılık ve amplitüd, genellikle kantite, miktar veya belirginlikle tanımlanır (quantity, amount, prominence). Önceleri ısrarlılık ve amplitüd kombinasyonunu tanımlamak için kullanılan abundans terimi terk edilmiştir. Tek tek dalgalar ve kompleksler yüksek, orta ve düşük ısrarlılıkla oluşabilir. Bunların ısrarlılığı en iyi, bir saniye veya bir dakika içindeki ortalama sayıları ile ifade edilir. Belirli aralıklarla ya da düzensiz aralarla oluşabilir. Düzensiz ve seyrek oluşum

bazen sporadik olarak adlandırılır. Random veya difüz terimleri EEG paternlerinin ısrarlılığını tanımlamak için kullanılmamalıdır (Fisch 1997).

4.9.9. Reaktivite

Reaktivite, çeşitli manevralarla bazı normal ve anormal paternlerde ortaya çıkabilen değişiklikleri anlatır. Bazı paternler, gözlerin açılıp kapatılması, hiperventilasyon, fotik ya da duyuşal uyarılar, uyanıklık düzeyinde değişiklikler, hareket veya diđer manevralar ile kışkırtılabilir ya da artırılabilir, azaltılabilir ya da engellenebilir. Toksik ve metabolik ensefalopatilerde anormal yavaş dalgalar genellikle hastanın uyarılmasıyla azalır, hiperventilasyon ve uyuklamayla artarken, yapısal lezyon vakalarında görülen anormal yavaş dalgalar uyarıcı manevralar sırasında genellikle daha az azalır ya da engellenir (Fisch 1997).


Bu nedenle bir kayıt, EEG üzerinde uyandırmanın etkilerini göstermek için en azından basit uyarıcı manevralar yapmadan tamamlanmış olarak kabul edilemez. Bu manevralar göz açıp kapatma (bu, sözel komutlara yanıt veremeyen kişilerde ve çocuklarda pasif olarak yapılabilir) ve hafızayı ölçen sorular ve basit hesaplamaları içerir. Eğer hasta sözel komutlara yanıt veremiyorsa, o zaman işitme ve dokunma ile ilgili etkin uyarılar uygulanmalıdır. Bu manevralar, gerçekten bir zemin yavaşlığı mı olduğunu ya da kayıt sırasında hastanın sadece fazlasıyla mı uyuklu olduğunu belirlemeye de yardımcı olur (Fisch 1997).

4.10. EEG Verisini Oluşturan Normal Beyin Dalgaları

Normal bir yetişkinde görülen beyin dalgaları, genellikle aşağıda kaydedilecek normal dalga tiplerinden oluşur. Bununla beraber bundan sonraki bölümde bahsedilecek patolojik dalgalardan bazılarının da normal beyin dalgalarına karışabildiği görülmektedir. Otomatik analizörle yapılacak bir tetkik, bu karışmaları daha açık olarak gösterebilir.

a. Alfa dalgaları: Dalga formu sinüzoidal ve düzenli olan bu dalgalar, genellikle 8-13 Hz frekansında ve 40-50 mikrovolt amplitüdedir. Alfa dalgalarının tepede veya tabanda keskin noktaları olabilir. Keskin tepeleri olan tekli alfa dalgaları, aynı kayıttaki yineleyici alfa dalgalarına olan benzerliği ile anormal keskin dalgalardan ayırt edilebilir (Şekil 4.7, P3-O1 trasesi) (Fisch 1997).

Alfa dalgalarının beyinin, daha çok arka yarısında ve Parieto-okspital bölgede hakim olduğu görülmüştür. Nadiren alfa dalgalarının temporal, central hatta frontal alanlara kadar yayıldığı gözlenmektedir. Alfa dalgaları, belirtildiği gibi, saniyede 8-13 frekans göstermektedir. Memleketimizde en hakim frekans 8 ve 9'dur. Bazen daha düşük amplitüde (10-20 mikrovolt) olduğu gibi 90-110 mikrovolt gibi daha yüksek amplitüd'lerde de (Yüksek Voltajlı Alfa - High Voltage Alpha) olabilir.



Şekil 4.7. Alfa dalgaları

Her iki parieto-okspital bölgeden senkron olarak müşahade edilen alfa dalgaları, bir uyarım sonucu desenkronize olarak silinirler. Buna alfa bloğu denir. Bu uyarımın en basiti gözlerin açılmasıdır ki bütün traselerde bu özellik belirtilir. Göz kapatılınca, alfalar yine geriye dönerler. Bazı kimselerde bloke olan alfa dalgaları, daha göz kapatılmadan da geriye dönebilirler. Bu da normal bir durumdur, Önemli olan, gözlerin açılması ile alfanın aynen devam etmesidir. Bu halde, tartışmasız, bir patoloji düşünülmelidir. Gözleri açmak suretiyle yapılan ışık uyarımlarından başka, bir ses uyarımı, bir fikir çalışması meselâ bir hesap problemi yapma, hatta karanlıkta görmeye, çalışmada da alfa bloku dediğimiz desenkronizasyon meydana gelir. Alfa dalgaları, özellikle vasküler ve yer kaplayan lezyonlarda tek taraflı, yani hastalığın bulunduğu tarafta silindir veya disorganize olurlar (Tükel 1979).

b. Beta dalgaları: Bunlar daha hızlı frekans ve daha düşük amplitüd gösterirler. Beta dalgaları 13-30Hz. frekansda ve genellikle 10-20 mikrovolt amplitüd'dedir (Şekil4.8).

Genellikle Fronto-central bölgelerde görülür. Alfa uyarımlar sonucu bloke olduktan sonra, o bölgede görülen trase, beta aktivitesidir. EEG tetkiki sırasında anksiyetesi olan ve ne olacağı öğretilmediği için korku duyan kimselerde bu dalgalar bütün bölgeleri kaplayarak traseye düşük amplitüdü (Low Voltage Fast Record - Düşük voltajlı Hızlı Trase) bir görünüm verirler. Hastanın sükûnet bulması veya korkusunun geçmesiyle, arka bölgelerde alfa dalgaları meydana çıkabilir. Düşük voltajlı hızlı trase, ruhi gerginlik ve anksiyete hallerinin, bioelektrik olarak klinik teşhise yardım eden bir şeklidir. Bu gösterinin, tetkik süresince devamı veya çeşitli uyarımlar sonucu kaybolması (telkin, gözlerin açılıp kapanması, hiperventilasyon, aralıklı ışık uyarması, ses uyarması), anksiyetenin ciddi veya hafif oluşunu göstermek bakımından da kliniğe ışık tutabilir. Beta dalgalarının tıkaçıcı damar hastalıklarında, hasta tarafta depresyona uğradığı, bazı subdural hematoma vakalarında hiç bulunmadığı, buna karşılık epilepsi ve infiltratif tümörlerde hastalığın bulunduğu hemisferde, potansiyalize olduğu da ifade edilmektedir (Tükel 1979).


c. Gamma Dalgaları: Beta dalgaları gibi düşük amplitüdü ve fakat ondan daha hızlı dalgalarıdır. Frekansları 35-50 Hz arasındadır. Şiddetli uyarımla korteksin ve özellikle sensori-motor bölgenin cevabı olarak kabul edilebilir. Klinik EEG'de bir önemi yoktur (Tükel 1979).

d. Mu dalgaları: Tarak ağzına benzemesi ile comb-ritm adı da verilmektedir. Özellikle, koronal bir derivasyonla alınan traselerde C₃ ve C₄ standard elektrod pozisyonlarında görülür Bazan her iki taraftan senkrondur. Bir tarafta hiç meydana çıkmaması, meydana çıkmadığı tarafta bir patolojiyi düşündürülebilir. Daha çok sensori-motor korteks hizasında görülen bu dalganın çıkan dalı kesin ve inen dalı ise yayvancadır. Frekansı saniyede 9 ± 2 Hz'dir Gözlerin açılıp kapanması ile bloke olmayışı ve daha ziyade karşı beden yarısında hareket yapılmasıyla bloke oluşu ile, alfa dalgalarından ayrılır. Hiç nöbet geçirmeyen normallerde de 10% oranında görülebilmektedir (Tükel 1979).

e. Lambda dalgaları: Bu testere ağzı şeklinde bir dalgadır. Ancak oksipital bölgede ve pek seyrek olarak da parietal bölgede görülür. Şimdiye dek bahsedilen

dalgaların aksine, bir uyarım sonucunda, gözlerin açılması ile ortaya çıkar. Gözler kapalı olduğunda veya karanlıkta görülmezler. Fotik stimülasyon sırasında ve özellikle yavaş fotik frekanslarla, kolayca görülebilirler (Tükel 1979).

f. Kappa dalgaları: Temporal bölgelerde görülen, 10Hz. frekansdaki bu dalgalar, düşünmenin bir göstergesi olarak kabul edilmiştir. Bu dalganın pek bir önemi yoktur, bir hareket artefaktı olarak kabul edilebilir.



Şekil 4.8. Beta Dalgaları

4.11. Beyindeki Patolojik Dalgalar

Patolojik dalgalar deyimi daha önce de belirtildiği gibi, yetişkinler için kullanılır. Bu dalgalar da frekanslarına veya morfolojilerine göre isimlendirilmişlerdir. Beyindeki patolojik dalgalar ya sporadik olur veya kompleksler tarzında ortaya çıkar.

İster sporadik isterse kompleksler tarzında olsun, anormal dalgalar morfoloji bakımından aktivasyon uygulanmayan dönemdeki normal dallardan farklı oldukları kadar, ortaya çıktıkları bölgenin temel aktivitesinden daha fazla amplitüd göstermektedirler (Tükel 1979).

a. Sporadik Dalgalar: Bunlar, arızı, izole veya belirli frekanslar tarzında ritmik olarak meydana çıkarlar. Çoğunlukla hemisferin bir bölgesinde lokalize olmakla beraber, bazan her iki hemisferin benzer bölgelerinden senkron bir tarzda da görülebilirler. Sporadik dalgalar aşağıda ayrıntılı olarak anlatılacağı gibi, spike, sharp wave, slow wave olarak gruplandırılabilirler (Tükel 1979).


I. Spike (Diken): Spike, elektronegatif bir dalgadır. Yani, izoelektrik çizginin üzerine doğru bir defleksiyon, bir çıkıştır. Bazan bifazik hatta trifazik olduğu görülebilir. Spike, hızlı bir anomalidir. Başladığı andan bitişine 20-60 milisaniye sürer. Bu süre, saniyede 30 milimetre yazan bir trase kâğıdında 2 milimetrelik bir alanı kapsar. Spike ya korteksin yüzünden çıkar veya uzak bir bölgeden ya da subkortikal bir bölgeden o hizaya projete olur (Şekil 4.9) (Tükel 1979).

II. Sharp Wave (Keskin Dalga Veya Sivri Dalga): Aslında uzamış, yavaşlamış bir spike'dır. Bu da Elektronegatif bir dalgadır. Tıpkı spike gibi, bifazik hatta trifazik olabilir. Süresi 60-150 milisaniyedir. Bu süreden daha fazla olan ve sert bir çıkışı çok yavaş bir iniş izleyen ve neticede süresi 150-300 milisaniye olan şekillerine *sharp-slow wave* denilmektedir. Gerek Sharp Wave ve gerekse Sharp-slow wave sporadik veya ritmik olabilir. Aynısı karşı hemisferin aynı bölgesinde senkron olarak meydana çıkabilir. Spike, Sharp-wave ve Sharp-slow wave, sırasıyla, epileptojen (epilepsiyi doğuran) bir bölgenin, bioelektrik gösterisi olarak büyük önem taşırlar. Epileptojen odaklarda en sık görüleni sharp-slow wave'dir. Sharp wave daha az sıklıkla görülür, en karakteristik gösteri olan spike ise hepsinden seyrek orantıda görülmektedir. Bazen de aynı odaktan, bu üç anomali şekli beraberce, hatta başka anomali örnekleri ile birlikte de çıkabilirler (Tükel 1979).

III. Slow Wave (Yavaş Dalga): Bir yetişkinde, 8Hz. altında bulunan bu dalgalar, çok çeşitli morfoloji ve frekans göstermekte ve bu çeşitlere göre klinik yönünden bazı sonuçlara varılmaktadır. Bu sebeple bu dalgaları yalnız morfoloji veya yalnız frekans bakımından nitelendirmek sakıncalıdır. Yavaş dalgalar, teta dalgaları (4-8Hz) ve delta dalgaları (0-4Hz) olmak üzere ikiye ayrılır. Aslında bu frekans niteliği

kadar, hatta ondan da fazla, dalganın morfolojisi önem taşır. Yavaş dalgalar ya düzenli ya da düzensiz olurlar. Bu düzeni koruma veya koruyamama, özellikle, 0-4Hz. arası frekanslarda büyük önem taşır.

b. Kompleks dalgalar: Bunlar, çeşitli şekillerde, sporadik dalgaların birleşmesi sonucu belirli bir kişilik gösteren anormal görüntülerdir. Başlıcaları dalga ve diken, çoklu diken ve dalga, yavaş diken ve dalga, şeklinde sıralanabilir.



Şekil 4.9. Sağ temporal bölgede (T4) Lokalize izole ve ritmik spike ve sharp wave

4.12. Aktivasyon Metotları

Klinik olarak varılan kanının bioelektrik karşıtını meydana koymak amacı ile, çok çeşitli prosedürler öne sürülmüştür. Bunlar, genel olarak, aktivasyon metotları adı altında toplanmaktadır. Bu metotlarda asıl gaye, anomaliyi provoke etmek veya aslında var olanı daha potansiyel hale getirmektir. Aktivasyon metotlarının bir

kısmı, rutin EEG tetkikinde kullanılır. Diğer bazı metodlar ise rutin metodların sonuç vermediği hallerde veya özel tesir mekanizmaları göz önüne alınarak uygulanır. Bir EEG tetkikinde uygulanan rutin aktivasyon metodları hipervantilasyon ve fotik stimülyasyondur (Tükel 1979).

4.12.1. Hipervantilasyon

Hastaya gözü kapalı olarak, ortalama dakikada 20 defa olmak üzere derin derin nefes alıp vermesi ve bu sırada ağzını mümkün olduğu kadar açık tutması söylenir. Hipervantilyasyona 3 veya 5 dakika devam edilip kesilir ve hastanın normal nefes alıp vermeye başladığı yere işaret edilir. Zira, çok zaman, hastadan hipervantilyasyona son vermesi istenildiği halde, onun derin derin nefes alıp vermeye devam ettiği görülmektedir. Hakiki anomaliler, hipervantilyasyonun son bulmasından sonra da devamlılık gösterirler. Hipervantilyasyonun metabolik etkisine bağlı olanlar ise ilk dakika içinde hızla kaybolurlar. Hipervantilyasyon hem fokal, hem difüz hem de projete tipte anomalileri meydana çıkarabildiği gibi daha evvel aktivasyonun uygulanmadığı dönemde rastlanan anomali çeşitlerinin daha belirgin bir kişilik almasına da sebep olur. Bu, klinikte, en çok vasküler patolojilerde ve epilepside dikkati çeker. Öte yandan daha evvel görülmeyen ve yalnız hipervantilyasyon sırasında meydana çıkan projete tipte bazı paroksizimlerin hemen epileptik olarak kabullenilmemelerinin gerektiğine de işaret etmek gerekir.

4.12.2. Fotik stimülyasyon

Aralıklı ışık uygulanması, ortalama 60000-80000 mum kuvvetinde mavi-beyaz renkte ışık verebilen stroboskoplarla yapılır. Alet bir elektrotla, elektrod tablosuna bağlanarak, verilen ışık frekansları en üst veya en alt kanalda yazdırılabilir. Kullanılan frekanslar saniyede 1-50Hz arasındadır. Bununla beraber 9-20Hz arası frekanslar da yeterlidir. Stroboskopu hastadan en az 30-40 santimetre uzaklıkta, heriki göze simetrik ışık verecek tarzda tutmalıdır. Daha yakına gelmesi tehlikeli

olabilir. Stimulasyon sırasında hastanın gözünü kapalı tutması gerekir. Aralıklı ışık uygulanmasının, ençok sentrasefalik bölgeden çıkan 3Hz spike and wave deşarjları ve miyoklonik epilepsideki multiple spike and wave deşarjları bu metodla meydana çıkarılır. Bununla beraber hiçbir aktivasyon tekniđi uygulanmamış iken ve çeşitli aktivasyon metodlarında meydana çıkarılamayan temporal lobdaki bazı epileptojen odakları, aralıklı ışık tenbihi ile meydana çıkarmak mümkün olabilir (Tükel 1979).

5. SİNYAL İŞLEMEDE KULLANILAN ÖZELLİK ÇIKARMA YÖNTEMLERİ

Bir YSA modelinin öğrenme başarısında ağın girişine uygulanan verinin önemi büyüktür. Bölüm 3’de bahsedildiği gibi ÇKYSA’nın bir takım sınırlamaları vardır ve bu sınırlamalardan biri de ağın büyüklüğüdür. EEG ve EKG gibi biyolojik sinyallerin birçoğunda üretilen veri miktarı çoktur. Bu nedenle verilerin işlenmesi için bir takım önileme yöntemlerine ihtiyaç duyulmaktadır. Böylece ham veriden yeni yöntemler kullanılarak o veriyi en iyi şekilde temsil edecek yeni alt veri kümeleri elde edilmektedir.

Bu tez çalışmasında, EEG verilerinin işlenmesinde, pencereleme metodu, Welch metodu, dalgacık dönüşümü ve temel bileşen analizi kullanılmıştır. Bu bölümde, sinyalleri segmentlere ayırmak için kullanılan pencereleme yöntemi, sinyalin içerdiği frekans bileşenlerini gösteren, güç spektral yoğunluğunu elde edebilmek için kullanılan Welch metodu, sinyali içerdiği frekans bileşenlerine ayırmada başarılı sonuçlar veren dalgacık dönüşümü ve bilgi kaybı olmaksızın çok değişkenli bir vektörü daha az sayıda değişkenle ifade etmek için kullanılan temel bileşen analizi yöntemleri ayrıntılı olarak anlatılmıştır.

5.1. Pencereleme işlemi

Pencereleme işleminin amacı, spektral sızma ve lekelenmelerin zararlı etkilerini uygun bir pencere yardımıyla en aza indirmektir (Semmlöv 2004).

Bir sinyal sonsuz uzunlukta bir segment de olsa ya periyodiktir ya da rasgeledir. Ayrıca benzer dalga şekillerinin sadece bir bölümü sonlu belleğe sahip bilgisayara sunulabilir ve bu durumda da dalganın nasıl parçalanacağı önem kazanır. En basit haliyle bir segment basitçe bir dalga şeklinden kesilir ve bu bütün veriye rectangular pencerenin uygulanması ile aynıdır. Analiz sadece dalganın pencerelenmiş bölümü ile sınırlıdır. Rectangular dışındaki pencere şekilleri, istenilen şekilde dalganın zaman domeninde çarpılmasıdır (Semmlöv 2004).

Bunun yanında pencereleme, hem zaman domeninde (veri pencereleri) hem de frekans domeninde (frekans pencereleri) yapılabilir. Çünkü zaman domeninde çarpma frekans domeninde konvolüsyon işlemi ile aynıdır. Frekans domeninde pencereleme, frekans domen penceresi ile sinyal spektrumunun konvolüsyonu şeklinde uygulanır (Ifeachor ve Jervis 2002).

Pencere şekilleri, bazı durumlarda incelen fonksiyonlar olarak sunulur. Ayrıca pencerenin dışında kalan noktaların doğru olmasa da sıfır olduğu varsayılır. Güç spektrumu yaklaşımında pencere seçimi etkili bir faktördür. Çünkü bir veri seçildiği zaman pencerenin frekans karakteristiği spektral sonucun bir parçası olur. Bütün pencereler iki tip artefakt üretir: analob (mainlob) ve yanlob (sidelob) (Semmlöv 2004). Pencere tarafından üretilen artefakt pencerenin Fourier dönüşümü alınarak bulunabilir. Gerçek spektrum analob denilen artefakt ile genişletilir ve yanlob adı verilen ek pikler üretilir. Eğer işlem, yakın frekans uzayındaki iki darbantlı sinyalin çözümü ise en dar bantlı pencere (rectangular) tercih edilir. Bir güçlü ve bir zayıf sinyal söz konusu ise güçlü sinyallerin yan loblarının zayıf sinyaller tarafından yok edilmesini önlemek için hızla azalan yan lobları olan pencereler tercih edilir. Eğer iki tane orta derecede güçlü sinyal var ise (bunlardan biri zayıf sinyale daha yakın diğeri daha uzak olduğu zaman) orta derecede dar analob ve orta derecede zayıflayan loblar en iyi çözümdür. Genellikle bir sinyale hangi tipte pencere uygulanacağını bulması için farklı tipte pencerelerle denemeler yapılması gerekmektedir (Semmlöv 2004). Aşağıda verilen Tablo 5.1 ile en sık kullanılan pencere tipleri ve denklemleri verilmiştir (Stearns ve David 1988).

5.2. Welch Metodu Kullanılarak Güç Spektrum Yoğunluğunun (Power Spectrum Density-PSD) Hesaplanması

Spektral analiz bir sinyalin frekans içeriğinin tanımlanmasıdır. Bazı durumlarda, sinyallerin frekans bilgileri, zaman bölgesi çözümünden daha fazla gerekli bilgi sağlarlar. EEG, EKG, EMG gibi pek çok biyolojik sinyal, frekans bölgesinde işlendiği zaman, tatmin edici veya tanısal olarak gerekli bilgileri göstermektedir. Bir sinyalin spektrumunun başarısı, sinyalin periyodik, sonlu

uzunlukta ve gürültüsüz olmasını gerektirir. Pek çok biyolojik uygulamada, dalga ya sonsuz uzunlukta veya analiz için yeterli uzunlukta. Her iki durumda biyolojik sinyallerin analizinde problem olarak görülmektedir. Dahası, biyolojik sinyaller çoğunlukla gürültü ve artefakt ile bozulmuşlardır. Oysa gerçek sinyalin bir bölümü analiz edilebilse ve/veya gürültü sinyal boyunca olsa, bütün spektrum analiz yöntemleri mutlaka gerçek spektruma yaklaşır. Farklı spektrum analiz yaklaşımları özel spektral özelliklerin yaklaşım doğruluğunu artırmak için çalışır (Semmlov 2004).

Tablo 5.1. Pencere tipleri ve formülleri

Pencere Tipi	Örnek değerleri	K dizisi
Rectangular	$w_k=1$	$0 \leq k \leq N-1$
triangular	$w_k = 1 - \left 1 - \frac{2k}{N-1} \right $	$0 \leq k \leq N-1$
Hanning	$w_k = \frac{1}{2} \left(1 - \cos \frac{2k\pi}{N-1} \right)$	$0 \leq k \leq N-1$
Hamming	$w_k = 0.54 - 0.46 \cos \frac{2k\pi}{N-1}$	$0 \leq k \leq N-1$
Blackman	$w_k = 0.42 - 0.5 \cos \frac{2k\pi}{N-1} + 0.08 \cos \frac{4k\pi}{N-1}$	$0 \leq k \leq N-1$

Genel olarak spektrum yaklaşımı yöntemleri iki kategoride incelenmektedir. Welch metodunun da içinde bulunduğu, spektral yaklaşım veya parametrik olmayan yaklaşım olarak adlandırılan ilk kategori, spektrumun tamamının şekli ile ilgilidir. İkinci kategori olan parametrik yaklaşımda ise spektrumun tamamının yanında yerel özelliklerini de dikkate alır (Semmlov 2004). Autoregressive Model parametrik spektrum yaklaşımının en çok bilinen yöntemlerinden biridir. Parametrik olmayan yöntemlerin Hızlı Fourier Dönüşümüne (HFD) göre avantajları olmakla birlikte kısa veri uzunluklarında sınırlı frekans çözünürlükleri dezavantajlarıdır (Ifeachor ve Jervis 2002).

Sonlu enerjisi olmayan ve dolayısıyla Fourier dönüşümü alınamayan, sinyallerin sonlu ortalama güçleri vardır ve güç spektral yoğunluğu ile karakterize

edilir (Proakis ve ark. 1992). Güç spektrum yoğunluğu (PSD) diğer bir deyişle güç spektrumunun en basit şekli periodogram ile ifade edilir. Welch metodu periodogram metoduna yeni düzenlemeler eklenerek elde edilmiş bir yöntemdir. Bu nedenle Welch metodunun daha iyi anlaşılabilmesi için öncelikle periodogram metodu ve Barlett metodu anlatılacaktır

5.2.1. Periodogram metodu

Güç spektrumu temel olarak otokorelasyon fonksiyonunun Fourier dönüşümü olarak tanımlanabilir. Sonlu enerjisi olmayan ve dolayısıyla Fourier dönüşümü alınamayan durağan rasgele sinyallerin sonlu ortalama güçleri vardır ve güç spektral yoğunluğu ile karakterize edilir (Proakis ve ark. 1992). $x(t)$ durağan rasgele bir sinyaldir ve aşağıdaki şekilde tanımlanabilir.

$$x(t)=[x_k]=[x_0, x_1, \dots, x_{N-1}] \quad (5.1)$$

N örnekli $[x_k]$ verisinin periodogramı ($P_{xx}(f)$), $[x_k]$ verisinin Ayırık Fourier Dönüşümünün (AFD) ($F(j\omega)$) karesi olarak tanımlanabilir.

$$P_{xx}(f) = |F(j\omega)|^2 \quad (5.2)$$

Eğer N veri noktası var ise en az N noktada AFD hesaplanır ve $f_k=k/N$ frekansında

$$P_{xx}\left(\frac{k}{N}\right) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \right|^2 \quad k=0,1,\dots,N-1 \quad (5.3)$$

Pratik olarak seyrek örneklenen spektrumlarda sürekli $P_{xx}(f)$ yaklaşımına göre iyi bir sonuç elde edilemez. Bu problemin aşılması için $P_{xx}(f)$ 'in ek frekanslarda da hesaplanması yapılmalıdır. Aynı şekilde, sıfır eklemesi yapılarak dizinin uzunluğu artırılabilir ve daha sonra $P_{xx}(f)$ daha yoğun frekanslarda hesaplanabilir. Böylece veri dizisinin büyüklüğü L noktaya artırılarak L noktada AFD alınır. Bir sinyale sıfır eklenmiş ve $L>N$ noktada AFD'si hesaplanmış olması spektral yaklaşımda frekans çözünürlüğünü iyileştirmemektedir. Bu durum sadece daha fazla frekansta, ölçülen spektrumun interpolasyonunu sağlar. Spektral yaklaşımda, frekans çözünürlüğü $P_{xx}(f)$ veri kaydının N uzunluğu ile tanımlanır (Proakis ve ark. 1992).

5.2.2. Bartlett metodu

Periyodogramdaki varyansı azaltmak için öne sürülen Bartlett metodu üç adım içerir. İlk adımda, N noktalı veri dizisi üst üste binmeyen K tane segmente bölünür. Her birinin uzunluğu M olan K tane veri segmenti için veri yapısı

$$x_i(n) = x(n+iM) \quad \begin{matrix} i=0,1,\dots,K-1 \\ n=0,1,\dots,M-1 \end{matrix} \quad (5.4)$$

şeklinde tanımlanır ve her segment için ayrı ayrı periodogram hesaplanır.

$$P_{xx}^i(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} x_i(n) e^{-j2\pi fn} \right|^2 \quad i=0,1,\dots,K-1 \quad (5.5)$$

Son olarak Bartlett güç spektrumun yaklaşımını hesaplamak için K tane segmentin periodogramlarının ortalaması alınır (Proakis ve ark. 1992).

$$P_{xx}^B(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx}^i(f) \quad (5.6)$$

5.2.3. Welch metodu (Modifiye edilmiş periodogramların ortalaması)

Welch metotta Bartlett metoda göre iki yeni uyarılama yapılmıştır. Öncelikle veri segmentlerinin üst üste binmesine izin verilmektedir. Daha sonra her segmente pencereleme işlemi uygulanmaktadır (Proakis ve ark. 1992).

Veri segmentleri aşağıdaki şekilde tanımlanabilir.

$$x_i(n) = x(n+iD) \quad \begin{matrix} i=0,1,\dots,L-1 \\ n=0,1,\dots,M-1 \end{matrix} \quad (5.7)$$

burada $i.D$, i . segment için başlangıç noktasıdır. Eğer $D=M$ ise segmentlerde üst üste binme yoktur. Eğer $D=M/2$ ise ardışık veri segmentleri arasında %50 üst üste binme vardır ve $L=2K$ olarak elde edilir (Proakis ve ark. 1992). eğer üst üste binme %50 veya %75 civarında olursa, verinin en çok özelliği muhafaza edilmiş olur (Ifeachor ve Jervis 2002).

Bartlett metoduna göre ikinci düzenleme ise periodogramın hesaplanması için veri segmentlerinin pencerelenmesidir. Sonuçta her segment için modifiye edilmiş periodogram,

$$P_{xx}^i(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad i=0,1,\dots,L-1 \quad (5.8)$$

şeklinde tanımlanır. Burada $w(n)$ pencere fonksiyonu ve U pencere fonksiyonundaki güç için normalizasyon faktörüdür

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w(n)^2 \quad (5.9)$$

Welch güç spektrum yaklaşımı, bu modifiye edilmiş periodogramların ortalamasıdır(Proakis ve ark. 1992).

$$P_{xx}^W(f) = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}^i(f) \quad (5.10)$$

Welch yaklaşımının beklenen değeri,

$$E[P_{xx}^W(f)] = \frac{1}{L} \sum_{j=0}^{L-1} E[P_j(f)] = E[P_j(f)] \quad (5.11)$$

ile bulunur. Bu değer Bartlett metodu ile bulunan değer ile aynıdır. $N \rightarrow \infty$ ve $M \rightarrow \infty$ olursa, bu değer gerçek güç spektral yoğunluğuna yakınsar. Bu nedenle büyük N ve M değerleri için Welch güç spektrum yoğunluğu tarafsızdır. Bu şartlar altında Welch metodunun varyansı sifira yakınsar (Ifeachor ve Jervis 2002).

Ayrıca Welch göstermiştir ki $L=K$ durumunda üst üste binme yok iken

$$\text{var}[P_w] \approx \left(\frac{1}{K} \right) P^2(f) \quad (5.12)$$

şeklindedir. Bu değer aynı şartlar altındaki Bartlett varyansına eşittir. %50 binme olduğu zaman ise aşağıdaki şekilde olur. Bu değer Bartlett varyansından daha azdır ((Ifeachor ve Jervis 2002, Proakis ve ark. 1992).

$$\text{var}[P_w] \approx \left(\frac{9}{8L} \right) P^2(f) \quad (5.13)$$

5.3. Dalgacık Dönüşümü

Dalgacık dönüşümü (DD), matematik, sinyal işleme ve görüntü işleme gibi pek çok alanda kabul görmüş ve geçerliliğini uzun süredir korumuştur. Bunun sebebi de durağan olmayan sinyaller ve nümerik sinyal işleme üzerine pek çok uygulama

olanağının olmasıdır (Güneş 1999). Sinyal işleme, zaman domeninde verilmiş sinyale herhangi bir matematiksel dönüşüm uygulanması ile gerçekleştirilir. Birçok sinyal pratikte zaman domeninde ifade edilir. Yani sinyal zamanın fonksiyonudur. Matematiksel dönüşümlerin kullanım amacı, zaman domeninde verilmiş sinyalden elde edemediğimiz bilgilere ulaşmaktır. Bu nedenle, dönüşüm, orijinal sinyalden daha fazla bilgi elde etmek için, sinyalin tekrar haritalandırılması olarak düşünülebilir ve matematiksel dönüşümlerin sinyal işleme açısından önemi büyüktür (Polikar 2001, Semmlov 2004).

DD, işlenmemiş sinyali içerdiği farklı frekans bileşenlerine ayıran ve her bir bileşeni; kendi skala değerine göre bir çözünürlükte inceleyen bir matematiksel dönüşüm fonksiyonudur (Graps 1995).

DD, Kısa zamanlı Fourier dönüşümünün (Short Time Fourier Analysis-STFT) bir alternatifi olarak çözünürlük probleminin üstesinden gelmek için ortaya atılmıştır. STFT'de zaman-frekans alanında elde edilen bilgiler sınırlı bir hassasiyette elde edilebilmektedir. STFT'de zaman penceresi bütün frekanslarda değişmeyen büyüklüktedir. Çoğu sinyaller daha hassas yaklaşıma ihtiyaç duyar. Bu hassasiyet pencerenin büyüklüğüne bağlıdır. Bunun için de pencere büyüklüğünün sürekli değişmesi gerekir (Güneş 1999). DD' de işaret içindeki düşük frekans eğilimlerini açmak için geniş bir pencere, yüksek frekans detaylarını analiz etmek için sıkıştırılmış bir pencere kullanılır. Bunun için, DD ölçeklenebilir temel bir dalgacık fonksiyonu kullanarak STFT'nin sabit çözünürlük problemine çözüm getirerek, işaretin farklı çözünürlüklerde daha esnek bir zaman bölgesi analizini yapar (Türkoğlu 2002). Dalgacık dönüşümü zaman-ölçek metoduna dayalı olduğu için, odağa tam olarak ayarlanarak işaretin farklı kısımlarını gözetleyebilen bir matematik mikroskobu gibi davranır.

Sonuç olarak, DD bir sinyalin zaman-frekans gösterimini elde edebileceğimiz bir matematiksel dönüşümdür. STFT'den bu nedenden ötürü üstündür ve sinyal işleme uygulamaları için büyük bir avantajdır. Çünkü yüksek frekanslar zamanda, alçak frekanslar ise frekansta daha iyi çözülür.

Dalga, bir doğrultu boyunca salınım yapan bir fonksiyon olarak tanımlanabilir. Fourier analizinde de kullanılan sinüsler dalgalara birer örnektir ve sinüsler sürekli dalgalardır. Dalgacık dönüşümünde kullanılan dalgalar ise sınırlı bir

uzunluğa sahiptirler. Dalgacık orijinal dalganın (ana dalgacık-mother wavelet) kaydırılmış ve ölçeklenmiş formundadırlar ve sonsuza dek salınım yapmazlar (Güneş 1999, Keskin 2002). Dalgacık dönüşümü iki sürekli ve ayrık dalgacık dönüşümü olmak üzere iki tipte anlatılmaktadır.

5.3.1. Sürekli dalgacık dönüşümü

Sürekli dalgacık dönüşümünde (SDD) sinyal, STFT'deki pencere fonksiyonuna benzer bir fonksiyon olan dalgacık fonksiyonu ile çarpılır ve zaman domeninde farklı zaman aralıkları için dönüşüm hesaplanır. Başka bir deyişle, farklı genişlikte baz fonksiyonları yani dalgacıklar, ortalaması sıfır olan ve sonlu enerjili ana dalgacık fonksiyonu $\psi(t)$ 'in ötelenmesi ve skalalandırılması ile istenilen genişlik ve zaman aralığında meydana getirilirler. Ayrıca ana dalgacık fonksiyonu $\psi(t)$, skalalandırma fonksiyonu $\phi(t)$ 'in lineer kombinasyonu olarak ifade edilebilir .

Sürekli dalgacık dönüşümü (CWT), işaretin, $\psi(t)$ dalgacık fonksiyonunun skalalandırılmış ve kaydırılmış haliyle çarpılıp tüm zaman boyunca toplanmasından elde edilir (Vetterli ve Kovacevic 1995).

$$C(a, b) = \int x(t) \cdot \psi_{a,b}^*(t) dt \quad (5.14)$$

Burada $a \in \mathbb{R}^+$ ölçeklendirme parametresi, $b \in \mathbb{R}^+$, öteleme parametresi, $*$ ise kompleks eşleniği ifade etmektedir. Sürekli dalgacık dönüşümünün sonucu, ölçeklendirme ve öteleme parametrelerinin fonksiyonu olan çok sayıda C katsayılarından oluşmaktadır. $\psi(t)$ 'den elde edilen $\psi_{a,b}^*(t)$ fonksiyonu, a ölçeği ve b öteleme zamanında, aşağıdaki gibi yazılmaktadır (Vetterli ve Kovacevic 1995).

$$\psi_{a,b}^*(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5.15)$$

Genellikle dalgacık dönüşümü uygulamalarında, ana dalgacık olarak ortogonal diydik fonksiyonlar seçilmektedir. Buna göre a ve b parametrelerine göre seçilen ana dalgacık aşağıdaki gibidir.

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k) \quad (5.16)$$

Bir dalgacığın ölçeklendirilmesi ifadesi basitçe, işaretin genişletilmesi veya sıkıştırılması anlamına gelmektedir. Öteleme parametresi ise basitçe işareti başlangıcından geciktirme veya öncesine almaktır.

Sürekli dalgacık dönüşümünün alınması için takip edilmesi gereken beş adım aşağıda gösterilmiştir (Keskin 2002).

- i. Bir dalgacık alınır ve orijinal sinyalin başlangıcındaki kesitle karşılaştırılır.
- ii. İşaretle ilişkili C sayısı hesaplanır. C sayısının büyüklüğü dalgacığın işaretle ne karda benzeştiğini ortaya çıkarmaktadır. C sayısı ne kadar büyükse işaret o kadar benziyor demektir. Daha da kesin bir şekilde, sinyalin enerjisi ve dalgacık enerjisi bire eşitse, C, korelasyon katsayısı olarak da yorumlanabilir. Unutulmamalı ki, sonuçlar seçilen dalgacığın şekline bağlıdır.
- iii. Dalgacık, işaretin tümünü kapsayacak şekilde sağa doğru kaydırılarak ve adım i ve ii tekrarlanır.
- iv. Dalgacık genişletilir ve i ve iii'ye kadar tekrarlanır.
- v. Bütün skala değerleri için i'den iv'e kadar tekrarlanır.

Bütün bu işlemler yapıldığı zaman, işaretin farklı kesitlerinde farklı skalalarda üretilen katsayılar elde edilmiş olur. Katsayılar, işaret üzerinde düzenlenen dalgacıkların regresyonunun sonuçlarını oluşturmaktadır (Keskin 2002).

5.3.2. Ayrık Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünde, tüm ölçek değerleri için dalgacık katsayıları, bütün zaman eksenini boyunca hesaplanmaktadır. Bunun sonucunda çok sayıda veri ve işlem yükü gelmektedir. Bu dezavantajları ortadan kaldırmak için ayrık dalgacık dönüşümü geliştirilmiştir. Ayrık dalgacık dönüşümünde (ADD), ölçek değerleri dyadic(2'nin kuvvetleri şeklinde) seçilerek yalnızca belirli noktalarda dalgacık katsayıları hesaplanmakta ve böylece işlem sayısı azaltılmaktadır. Denk b 'de verilmiş olan ana dalgacık denkleminde a ölçek katsayısı yerine 2^{-j} ve b öteleme katsayısı yerine $k2^{-j}$ konular ve denklem tekrar düzenlenirse, ayrık dönüşüm için dalgacık fonksiyonu bulunabilir (Misiti ve ark. 2000, Keskin 2002).

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k) \quad j,k \in \mathbb{Z} \quad (5.17)$$


J indisi dalgacığın ölçeğini belirlemektedir. J arttıkça ölçek azalmaktadır. Ayrık dalgacık dönüşümü seviye seviye yapılmaktadır. Dönüşüm seviyesi ilerledikçe dalgacığın ölçeği iki kat artmaktadır. Böylece ölçek eksenini 2'nin kuvvetleri şeklinde örneklenmiş olur. Görüldüğü gibi dönüşüm seviyesi, j indisi ile ters orantılıdır. Zaman eksenini de aynı şekilde örneklenmektedir. Seviye her arttırıldığında dalgacık fonksiyonu iki kat genişlemekte ve hesaplanacak katsayı miktarı yarıya düşmektedir (Misiti ve ark. 2000, Keskin 2002). Bu işlemi gerçekleştirmek için uygulanan en etkin yol 1988 yılında MALAT tarafından filtreler kullanılarak geliştirilmiştir. Mallat Algoritması, işaret işleme topluluğu arasında iki-kanal alt bant kodlayıcı olarak bilinen klasik bir yoldur. Bu işlem, hızlı dalgacık dönüşümü yapan çok pratik bir filtre algoritmasıdır (Arserim 2001).

Ayrık dalgacık dönüşümü kullanılarak, alt bantlardan yaklaşım(A) ve detay katsayıları (D) elde edilir. Yaklaşım katsayıları alçak geçiren filtreler ile elde edilmektedir. Bir işaretin ana hatları, alçak frekans bileşenlerinde gizlidir. İşaret alçak geçiren filtreden geçirildiğinde hala gerçek işarete benzemektedir. Bu nedenle A katsayıları yaklaşım katsayısı olarak adlandırılır. Bunun tersine, D ayrıştırma katsayıları yüksek frekans bileşenlerini yani hızlı değişimleri ve detayları göstermektedirler ve yüksek geçiren filtre ile elde edilmektedirler (Keskin 2002, Güler ve Ubeyli 2005).

Sürekli dalgacık dönüşümünde farklı ölçek çözünürlükleri elde etmek için dalgacığın ölçeği değiştirilmektedir. Ayrık dalgacık dönüşümünde ise farklı ölçek çözünürlükleri sağlamak için alçak geçiren ve yüksek geçiren filtreler kullanılmaktadır. Değişik kesim frekanslı filtreler ile değişik ölçek çözünürlükleri elde edilmektedir ve bu filtreler ile frekans spektrumu alt frekans bantlarına bölünerek analiz edilen işaret bu alt bantlar cinsinden gösterilmektedir. Ayrık dalgacık dönüşümünde, dönüşüm uygulanacak sinyal, $x(n)$, alçak geçiren ve yüksek geçiren filtrelerden geçirilerek bir çeşit aşağı-örnekleme yapılarak yaklaşım (A1) ve detay (D1) katsayıları hesaplanır.

Aşağı örnekleme işleminde $x(n)$ giriş dizisi için $y(n)=x(2n)$ gibi bir çıkış dizisi oluşmakta, eleman sayısı yarıya düşmektedir. Eleman sayısının yarıya düşmesi örnekleme frekansını da yarıya düşürecektir. Dolayısıyla, işaretin sahip olduğu en yüksek frekansın yarı değerine kadarki tüm frekanslar kalacaktır (Keskin 2002).

Şekil 5.1, tek seviyeli dalgacık dönüşümünü ifade etmektedir. İşarete birkaç seviyede DWT uygulanabilir. Böylece bir işaret daha az çözünürlüklü birçok alt bileşenine ayrılacaktır. Her seviyede bir önceki seviyenin yaklaşım katsayılarına ayrık dalgacık dönüşümü uygulanır (Misiti ve ark. 2000).



Şekil 5.1. Birinci seviye ayrık dalgacık dönüşümü

5.4. Temel Bileşen Analizi (Principle Component Analysis -PCA)

PCA, çok değişkenli analiz olarak bilinen istatistiğin bir dalına girer. Adından da anlaşılacağı gibi, çok değişkenli analiz, çoklu değişkenlerin (ölçümlerin) analizi ile ilgilenir, onlara tek bir varlıkmiş gibi davranır. Çoklu analizde, bu çoklu değişkenler çoğunlukla, tek bir vektör değişkeni ile ifade edilir. Bu vektör değişken, farklı değişkenler içerir (Smith 2002).

PCA, genellikle, bilgi kaybı olmaksızın, değişkenlerin sayısını azaltmak için kullanılan bir teknik olarak sunulmaktadır. Maalesef, PCA bir set değişkenini başka daha küçük sete dönüştürmekte kullanılabilen iken, yeniden oluşturulan değişkenleri yorumlamak genellikle kolay değildir. Pek çok uygulamada, PCA, sadece veri setinin gerçek boyutlarında bilgiyi sağlamak için kullanılır (Semmlow 2004). Bu yöntem, verideki desenleri tanımak ve benzerlikleri ve farklılıkları ortaya çıkarmak için kullanılan bir yoldur. Bir veri setinin üzerine PCA uygulanmasını gerçekleştirmek için uygulanacak adımlar aşağıda anlatılmıştır (Smith 2002).

Adım 1: Veri seti alınır.

Adım 2: Veri seti içindeki her bir veriden, veri setinin ortalaması çıkartılır. Böylece sıfır ortalamalı veri seti elde edilmiş olur.

Adım 3: Kovaryans matrisi hesaplanır.

Ölçümle belirtilen iki değişken boyutu arasındaki doğrusal ilişkiyi gösterir. Eğer tek boyut arasındaki kovaryans hesaplanırsa bu değer varyansı ifade eder. Elde edilen kovaryans matrisi, p boyutlu(p tane değişken seti) bir veri seti için, p x p boyutlu olur. Kovaryans hesabında elde edilen değer, pozitif ise, değişkenlerden birinin değeri artarken diğerinin değeri de artıyor ya da değişkenlerden birinin değeri azalıyorsa diğerinin değeri de azalıyor demektir. Değişkenlerden birinin değeri artarken diğeri azalıyor veya değişkenlerden birinin değeri azalırken diğeri azalıyorsa kovaryans değeri negatif olur. Eğer değişkenler arasında belirgin bir ilişki yoksa kovaryans sıfıra yakın bir değer olur (Smith 2002).

$$\text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n - 1} \quad (5.18)$$

Adım 4: Kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanır.

Özvektör ve özdeğerleri hesaplamak için kovaryans matrisi karesel olmalıdır fakat bütün kare matrislerin özvektörleri yoktur. Özvektörleri olan n x n matrisin n tane özvektörü vardır.

Verilen n mertebeli bir A matrisi için λ gibi bir skala ve X gibi sıfır olmayan bir vektör belirlenir ki bu değerler Denk 5.19 ile verilen denklem sistemini sağlarlar. Yapılan bu işleme özdeğer bulma problemi denir (Smith 2002).

$$AX = \lambda X \quad (5.19)$$

Burada A n. dereceden bir kare matristir. Matris işlemleri uygulandığı zaman, denklem sistemi, Denk. 5.20 şekline dönüşmüş olmaktadır. Denk.5.20 homojen bir denklem sistemidir.

$$(A - \lambda I)X = 0 \quad (5.20)$$

X'in sıfırdan farklı olabilmesi için (A - λI) matrisin determinantının 0 olması gerekir. Yani $|A - \lambda I| = 0$ olur. Buna göre λ cinsinden polinomial bir karakteristik denklem bulunur. Yani bu denklemin derecesi A matrisinin derecesine eşittir. İkinci dereceden bir A matrisi için iki tane kök (λ_1 ve λ_2) vardır. Bu kökler gerçek yada karmaşık olabilir. Eğer matris simetrikse kökler gerçek sayılardır. A p x p boyutlu bir matris ise, bu matrisin karakteristik denkleminin p tane kökü vardır (Smith 2002).

Özvektörler bulunurken, (A - λI)X = 0'da her bir özdeğer (λ_i) için bir tane özvektör (v_i) vardır. Özvektörleri bulmak için aşağıdaki adımlar izlenebilir. Herbir λ_i

için $(A-\lambda_i I)$ matrisi bulunur. Daha sonra, $(A-\lambda_i I)$ 'nin adjointi (A 'nın transpozu alınmış matris) bulunur. $\text{Adj}(A-\lambda_i I)$ matrisinin sütunlarının tümünün birbiriyle orantılı olması gerekir (Smith 2002). Her sütunun elemanları, ilgili sütundaki elemanların kareleri toplamının kareköküne bölünür. Elde edilen sayılar v_i 'nin elemanları olup $v_i \cdot v=1$ 'dir.

Adım 5: Bileşenleri seçme ve özellik vektörü oluşturma

Bu adım verinin sıkıştırıldığı ve boyutun azaltıldığı adımdır. Daha önceki bölümde de belirtildiği gibi, özdeğerler birbirlerinden farklı değerler alırlar. En yüksek değerli özdeğer, veri setinin temel bileşenidir. Bu durum bileşenlerdeki sıralamanın önemini gösterir. Bundan sonra daha az önemli bileşenin atılma işlemi gerçekleştirilir. Bu durumda bazı bilgiler kaybolacaktır. Eğer özdeğerler küçükse bilgi kaybı da az olacaktır. Bazı bileşenler atıldıktan sonra elde edilecek olan veri matrisinin boyutu, orijinal veri matris boyutundan daha küçük olur. Bu durum daha açık olarak ifade edilirse, n boyutlu bir veri seti için, n adet özvektör ve özdeğer hesaplanır. Bu özvektörler arasından p tanesi seçilirse, son veri seti sadece p boyutta olur. Bundan sonra ise özellik vektörünün oluşturulması işlemi vardır. Bu özellik vektörü, özvektörler listesinden seçilen özvektörlerin sütun formundan matris formuna getirilmesiyle elde edilir (Smith 2002).

$$\text{Özellik Vektörü} = [\text{öz}_1 \text{ öz}_2 \text{ öz}_3 \dots \text{öz}_n] \quad (5.21)$$

Adım 6: Yeni veri setinin türetilmesi

Bu son adım en kolay olanıdır. Öncelikle bileşenler seçilip, özellik vektörü oluşturulduktan sonra vektörün transpozu alınır. Sonra veri setinin sol tarafına konularak transpozu alınır.

$$\text{Son_veri} = \text{Satır_özellik_vektörü} \times \text{Satır_veri_matrisi} \quad (5.22)$$

Satır_özellik_vektörü, en anlamlı özvektör en üste olacak şekilde, sütunun transpozu alınarak elde edilen özvektör matrisidir. Satır_veri_matrisi, sıfır ortalamalı ve veri başlıkları ayrı sütunda olacak şekilde hazırlanmış veri matrisinin, transpozu alınarak elde ediliyor. Bu matriste her satır farklı bir boyutu tutuyor. Son_veri ise son olarak elde edilecek veri setidir. Veri başlıkları sütunlardadır (Smith 2002).

6. AAFYSA YAZILIMLARININ GERÇEKLEŞTİRİLMESİ

Yapay sinir ağları, insan beyninin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve bu amaçla nöronların matematiksel modellenmesi üzerinde yoğunlaşmıştır (Efe ve Kaynak 2000). Bu şekilde yapılan çalışmalarla, YSA, bir problemin örneklerine bakarak, genellemeler yapmakta, bilgiler toplamakta ve daha sonra hiç görmediği örneklerle karşılaşınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Ama karar hızı açısından insan beyni ile yarışabilecek aşamayı henüz katedememiş olmalarına rağmen yapısal zenginliklerinden dolayı uygulama alanları gün geçtikçe genişlemektedir. Özellikle çok sayıda bilginin değerlendirilmesini gerektiren problemlerde bu sistemler etkin olarak kullanılabilir. Endüstriyel hayattan finansal hayata, tıp biliminden askeri sistemlere kadar birçok alanda YSA ile yapılmış uygulamalar görülmektedir (Öztemel 2003). Bu uygulamalarda elde edilen başarılar, hem YSA'nın önemini arttırmakta hem de daha fazla ilgi duyulmasına sebep olmakta bu nedenle daha iyi sonuçlar elde etmek ve karar hızını daha da artırmak amacıyla bu konu ile ilgili çalışmalar günümüzde de halen devam etmektedir.

Bu amaca yönelik olarak, YSA'nın başarısını etkileyen faktörlerle ilgili yeni bakış açıları geliştirilmeye çalışılmaktadır. Bir problemin çözümü için kullanılacak olan YSA'nın tipini karakterize etmek için, mimarisini, öğrenme algoritmasını ve aktivasyon fonksiyonunu tanımlamak gerekmektedir (Fausett 1994). Bunun yanında aktivasyon fonksiyonunun tipi YSA'nın başarısını etkileyen en önemli faktörlerden biridir (Wu ve ark. 1997, Xu ve Zhang 2005). Bu nedenle, YSA'nın hem başarısını hem de hızını artırmak amacıyla 1990'lı yıllarda aktivasyon fonksiyonu ile ilgili çalışmalara başlamış ve YSA'nın temel aktivasyon fonksiyonlarından olan ve Denk. 3.1 ile ifade edilen sigmoid fonksiyonuna farklı şekillerde ve sayılarda serbest parametreler ilave edilmiş ve geleneksel YSA ile karşılaştırmalar yapılmıştır (Liu 1993, Wu ve ark. 1997, Yazdanpanah ve ark. 2003).

AAFYSA ile yapılmış çalışmalarda, sıklıkla kullanılan bir aktivasyon fonksiyonu olan ve daha önce Denk.3.2 ile verilen serbest parametrelili sigmoid

fonksiyonu, bu tez çalışmasında AAFYSA-1 modelinin gizli katman aktivasyon fonksiyonu olarak seçilmiştir. Wu ve ark (1997) ve Yazdanpanah ve ark. (2003), sigmoid fonksiyonuna bir tane serbest parametre ve Liu (1993), Yu ve ark. (2002) ve Xu ve Zhang (1999a, 2000, 2005) ise iki tane serbest parametre ilave etmişlerdir. Bu tez çalışması için literatürde yapılan bu çalışmalar dikkate alınarak, AAFYSA-1 modelinde iki adet serbest parametre kullanılması uygun görülmüştür.

Xu ve Zhang (1999a, 2001), adaptif aktivasyon fonksiyonu olarak serbest parametrelili sigmoid fonksiyonu ile serbest parametrelili sinüs fonksiyonunun toplamını seçmişler ve bu aktivasyon fonksiyonunu kullanarak tek değişkenli sinüs ve kosinüs fonksiyonunun tanınması ve finansal veri simülasyonu uygulaması gerçekleştirmişlerdir. Bu tez çalışmasında, Xu ve Zhang'in (1999b, 2001) yaptıkları bu çalışma dikkate alınarak, AAFYSA-2 modeli için, daha önce Denk. 3.3'de de verilmiş olan aktivasyon fonksiyonu kullanılmıştır. Bu fonksiyon, iki serbest parametrelili sigmoid fonksiyonu ile iki serbest parametrelili sinüs fonksiyonunun toplamı şeklinde oluşturulmuş ve AAFYSA-2 modelinin gizli katman düğümlerinde kullanılmıştır.

Son olarak, daha önce literatürde hiç uygulanmamış olan ve ilk defa bu çalışmada serbest parametrelili aktivasyon fonksiyonu olarak kullanılan ve Denk.3.4 ile ifade edilen, serbest parametrelili Morlet dalgacık fonksiyonu ile AAFYSA-3 modeli geliştirilmiştir. AAFYSA-3 yapısında kullanılan bu fonksiyonda kullanılacak serbest parametre sayısı iki olacak şekilde tasarlanmıştır.

Bu tez çalışmasında, yukarıda anlatıldığı gibi farklı adaptif aktivasyon fonksiyonları kullanılarak algoritmaları tasarlanmış ve geliştirilerek Matlab programının yapay sinir ağları fonksiyonları kullanılmaksızın yazılmış olan AAFYSA modelleri ile yapılmış uygulamalar gerçekleştirilmiştir. Bu programlar sırasıyla AAFYSA-1, AAFYSA-2 ve AAFYSA-3 olarak adlandırılmışlardır.

Bu bölümde öncelikle bu modellerin tasarımı ve geliştirilmesi sırasında karşılaşılan problemler, ÇKYSA'dan farklılıkları ve aktivasyon fonksiyonlarında bulunan serbest parametrelerin güncellenmesi için kullanılan algoritma ayrıntılı olarak anlatılmıştır. Burada kullanılan her bir modelin gizli katmanda kullanılan serbest parametrelili aktivasyon fonksiyonunun tipi ve serbest parametre sayısı farklı olduğu için ayrı ayrı yazılımları gerçekleştirilmiştir.

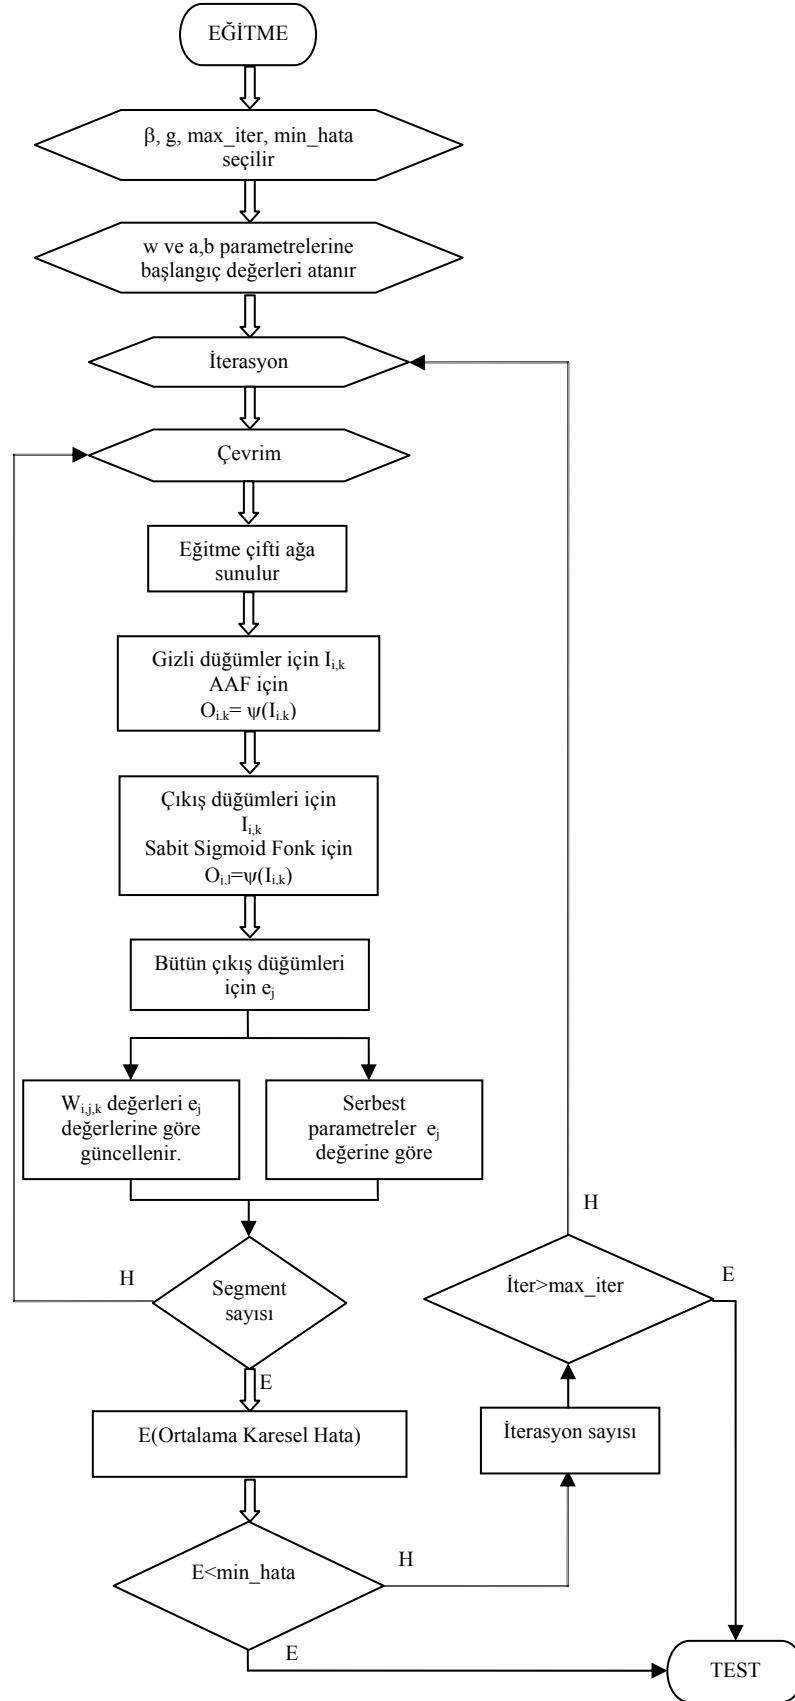
6.1. AAFYSA Modelinin Tasarım Aşamaları ve Geliştirilmesi

AAFYSA'nın ağ mimarisi ve ağırlıkların öğrenme algoritması bu tez çalışması için geliştirilen bütün modellerde ortak olduğu için Bölüm 3'de ayrıntılı olarak anlatılmıştır. Bunun yanında, AAFYSA'nın herbirinde farklı adaptif aktivasyon fonksiyonu kullanıldığı için serbest parametrelerin güncellenmesinde gerekli olan matematiksel ifadeler değişmektedir. Çünkü her model için gizli katman aktivasyon fonksiyonuna bağlı olarak ayrı ayrı gizli katman nöron parametrelerini hesaplamak gerekmektedir. Bu nedenle, yazılımları gerçekleştirilmiş olan AAFYSA modellerindeki aktivasyon fonksiyonunun her birinin tipine bağlı olarak ağın öğrenmesi ayrıntılı olarak anlatılmıştır.

Bu tez çalışmasında, adaptif aktivasyon fonksiyonunun hangi katmanda kullanılacağını ve nöronlar arasındaki ağırlıkların ve aktivasyon fonksiyonunda bulunan serbest parametrelerin güncelleme zamanını tespit etmek, algoritmayı oluştururken karşılaşılan en büyük problemler olmuştur. Bu nedenle de kullanılan AAFYSA'nın geliştirilmesi sırasında başarılı bir sonuç elde edilinceye kadar farklı algoritmalarla denemeler yapılmıştır.

Şimdiye kadar bu konuda yapılmış çalışmalar göz önünde tutularak, hem gizli katman nöronlarında hem de çıkış katmanı nöronlarında serbest parametrelili sigmoid fonksiyonu (Denk.3.2) aktivasyon fonksiyonu olarak seçilmiştir (Liu 1993, Wu ve ark. 1997, Yazdanpanah ve ark. 2003, Wu ve ark 1997). Çalışan bir algoritma kuruluncaya kadar yapılan denemelerin tamamında bu fonksiyon tercih edilmiştir.

Şekil 6.1 ile akış diyagramı gösterilen ilk algoritmada, adaptif aktivasyon fonksiyonunda bulunan serbest parametrelerin güncellenmesi işlemi, nöronlar arasındaki ağırlıkların güncellenmesi ile eş zamanlı olarak yapılmıştır. Diğer bir deyişle, her eğitim çifti ağı sunulduktan sonra hedef çıkış değeri ile çıkış nöronlarından elde edilen değer arasındaki farka bağlı olarak lokal eğimler hesaplanmıştır. Daha sonra çıkış katmanından gizli katmana doğru, nöronlar arasındaki ağırlıklar ve serbest parametrelerin güncellenmesi eş zamanlı olarak gerçekleştirilmiştir.



Şekil 6.1. AAFYSA modelinin geliştirilmesinde kullanılan ilk algoritmanın akış diyagramı

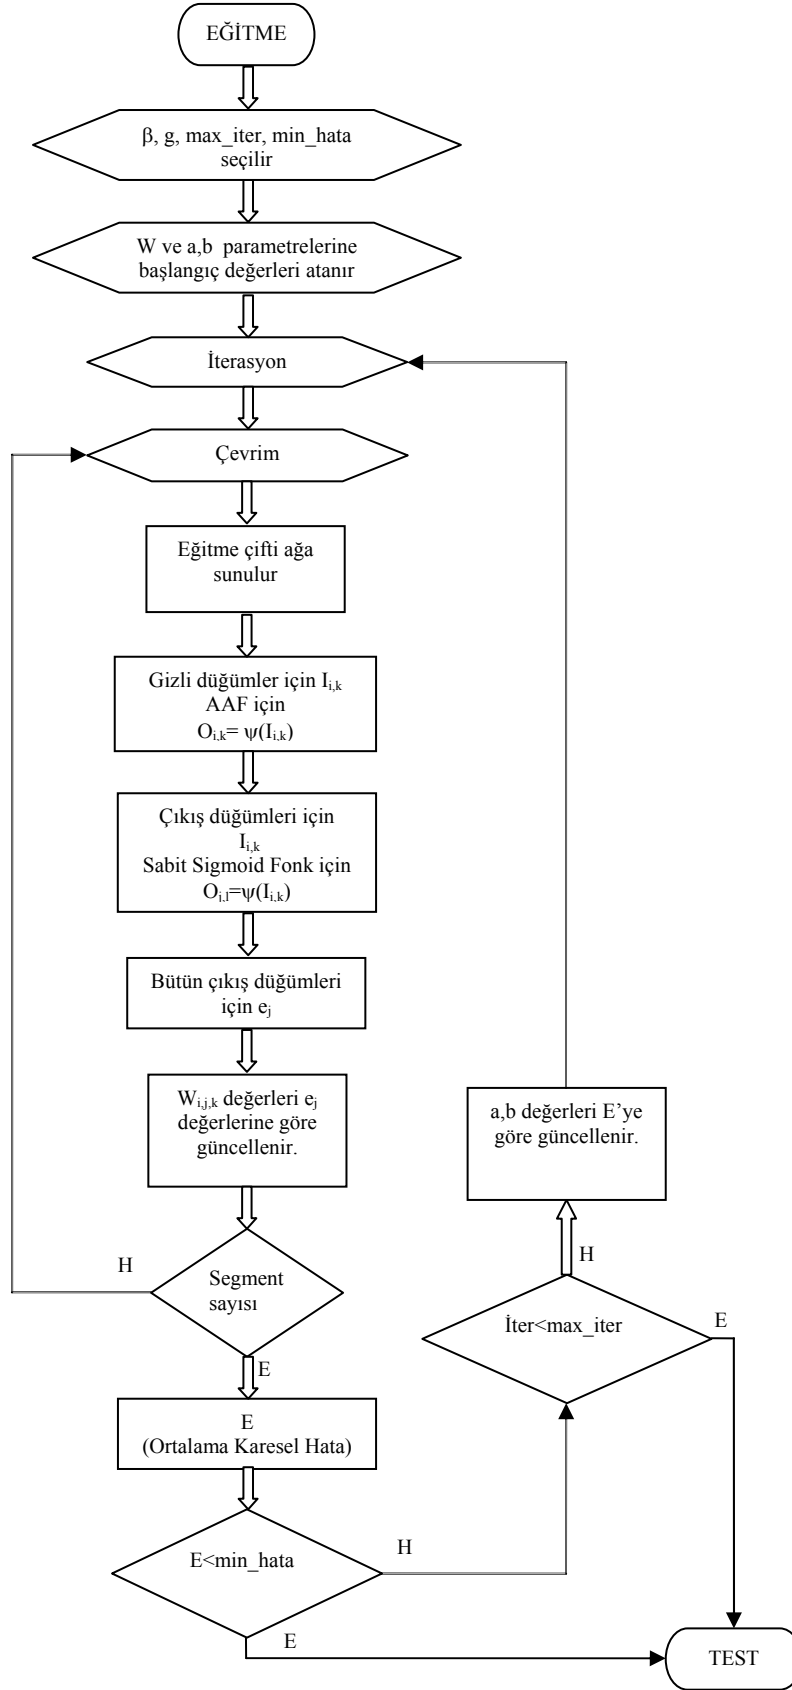
Şekil 6.1’de gösterilen akış diyagramına uygun olarak yapılan algoritma kurulduğu zaman, gizli katmanda bulunan nöronların aktivasyon fonksiyonları, her eğitim çifti ağı sunulduktan sonra değiştirilmektedir. Bu şekilde oluşturulan yazılımın işlem yükü oldukça artmaktadır. Çünkü her çevrimde hesaplaması gereken parametre sayısı daha fazla olmakta ve ağ yükünü arttırmaktadır. Bunun sonucu olarak da, ağı öğrenemediği ve çok yavaş işlediği görülmüştür. Bu durumda serbest parametrelerin güncelleme zamanının değiştirilmesi gerektiğine karar verilmiştir.

AAFYSA’nın algoritması tasarlanırken karşılaşılan ikinci problem ise adaptif aktivasyon fonksiyonunun kullanılması gereken ağ katmanının seçimi sırasında ortaya çıkmıştır. Başlangıçta adaptif aktivasyon fonksiyonunun hem gizli katman nöronlarında hem de çıkış katmanı nöronlarında kullanılması kararlaştırılmıştır. Bu mimari kullanılarak yapılan algoritmanın yazılımında her iterasyonda güncellenmesi gereken parametre sayısı çok fazla olduğu için, adaptif YSA eğitime sırasında öğrenme eğilimi göstermekle birlikte yüksek iterasyon sayısına ulaşıldığı halde istenilen minimum hata kriterine ulaşılamamıştır. Bu nedenle başarısız bir algoritma olarak nitelendirilmiş ve adaptif aktivasyon fonksiyonunun sadece gizli katmanda kullanılması uygun görülmüştür. Çıkış katmanının nöronlarında ise Denk.2.1 ile ifade edilen sabit sigmoid fonksiyonu, aktivasyon fonksiyonu olarak kullanılmıştır.

6.2. AAFYSA Algoritması ve Bu Algoritmanın ÇKYSA Algoritması ile Karşılaştırılması

Yukarıda anlatılan problemler aşıldıktan sonra geliştirilen yeni algoritmaya göre, sadece gizli katman nöronlarında adaptif aktivasyon fonksiyonu kullanılmış, çıkış katmanı nöronlarında ise sabit sigmoid fonksiyonu tercih edilmiştir. Bu şekilde Bölüm 3’de ayrıntılı olarak anlatılan AAFYSA’da ağırlıkların güncellenmesi esasına dayanarak, Şekil 6.2 ile verilen akış diyagramı doğrultusunda AAFYSA algoritması tamamlanmış ve Matlab dili ile yazılımı gerçekleştirilmiştir. Bu algoritma adım adım aşağıda ifade edildiği gibi özetlenebilir.

AAFYSA’nın modeline bağlı olarak gizli katman aktivasyon fonksiyonu değiştirildiği için, parametrelerin güncellenmesi ayrı başlıklar altında anlatılacaktır.



Şekil 6.2. AAFYSA modelinin öğrenme algoritmasının akış diyagramı

Adım 1: Gizli katman nöronlarında kullanılacak adaptif aktivasyon fonksiyonu belirlenir. Daha sonra aktivasyon fonksiyonunun serbest parametrelerine ve ağırlıklara rasgele değerler atanır ve sonra ağırlık değerleri Nguyen-Widrow yöntemine göre yeniden düzenlenir.

Adım 2: Maksimum iterasyon sayısı, gizli katman düğüm sayısı, öğrenme oranı ve minimum hata kriteri eğitime başlamadan önce belirlenir.

Adım 3: Giriş nöron sayısını, eğitime veri setinin her segmentinde bulunan örnek sayısı (matrisin satır sayısı) ve çıkış nöron sayısını hedef veri setinde bulunan herbir segmente karşılık gelen örnek sayısı (matrisin satır sayısı) belirlemektedir.

Adım 4: Ağa eğitime çifti (eğitime veri setinin bir segmenti ve bu segmente karşılık gelen hedef veri setinin segmenti) sunulur.

Adım 5: Gizli katman nöronlarının girişini hesaplamak için, giriş katman nöronlarından gelen sinyallere göre Denk. 6.1 kullanılmaktadır. Daha sonra gizli katmanda kullanılan adaptif aktivasyon fonksiyonunun tipi değiştiği için seçilen AAFYSA modeline göre Denk. 2.4'e uygun olarak gizli nöron çıkışı hesaplanır.

$$I_{j=1,\dots,g}(u) = \sum_{i=1}^m [w_{ji} O_i(u)] + \theta_j \quad (6.1)$$

AAFYSA-1 algoritması için gizli katman nöron çıkışları,

$$O_j(u) = \psi_1(I_j(u)) = \frac{a}{1 + e^{-bI_j(u)}} \quad (6.2)$$

AAFYSA-2 algoritması için gizli katman nöron çıkışları,

$$O_j(u) = \psi_2(I_j(u)) = a \sin(bI_j(u)) + \frac{c}{1 + e^{-dI_j(u)}} \quad (6.3)$$

AAFYSA-3 algoritması için gizli katman nöron çıkışları,

$$O_j(u) = \psi_3(I_j(u)) = e^{-a(I_j(u))^2} (\cos(bI_j(u))) \quad (6.4)$$

denklemleri ile hesaplanmaktadır.

Adım 6: Gizli katman nöronlarının çıkışlarından alınan sinyallerin ağırlıklı toplamı alınarak çıkış katmanı nöronlarının girişleri Denk. 2.3'e göre Denk. 6.1 ile hesaplanır. Bu giriş değerlerine göre çıkış değerleri Denk.3.1 ile verilen sabit sigmoid aktivasyon fonksiyonu kullanılarak, Denk.6.5'e göre elde edilir. Çıkış katmanında bulunan nöronların çıkış değerleri, ağa girilen sete karşılık ağırlık ürettiği çıkış olarak adlandırılmaktadır.

$$O_j(u) = \psi_c(I_j(u)) = \frac{1}{1 + e^{-I_j(u)}} \quad (6.5)$$

Adım 7 : Ağa sunulan eğitim segmenti için ağın ürettiği çıkış ile hedef çıkış arasındaki farka bağlı olarak nöron hataları Denk. 3.13'e göre ve nöronlar için eğitim değeri Denk.3.12'ye göre hesaplanır. Öncelikle çıkış katmanındaki nöronlar için,

$$\lambda_{j=1,\dots,p} = d_j(u) - O_j(u) \quad (6.6)$$

$$\delta_{j=1,\dots,p} = \lambda_j \frac{e^{-I_j}}{(1 + e^{-I_j})^2} \quad (6.7)$$

değerleri hesaplanır ve daha sonra gizli katman nöronlarına geçilir.

$$\lambda_{k=1,\dots,g} = \sum_{j=1}^p \delta_j w_{jk} \quad (6.8)$$

Herbir gizli nöron için nöron hatası hesaplandıktan sonra, gizli katmanda nöronlarının adaptif aktivasyon fonksiyonlarının tipine bağlı olarak nöron eğimleri Denk. 6.9 ile hesaplanır.

$$\delta_{k=1,\dots,g} = \lambda_k \frac{\partial O_k(u)}{\partial I_k(u)} = \lambda_k \psi'(I_k(u)) \quad (6.9)$$

Adım 8: Denk. (3.8 ve 3.9) ile verilen nöronlar arasındaki ağırlıkların ve eşik ağırlıklarının güncellenme denklemlerine göre karesel hata fonksiyonunun kısmi türevi alınarak ağırlıkların değişimi hesaplanır.

$$w_{i,j}^s = w_{ij}^{s-1} + \beta \delta_i O_j(u) \quad (6.10)$$

$$\theta_i^s = \theta_i^{s-1} + \beta \delta_i \quad (6.11)$$

Burada O_j bir önceki katmanda bulunun j . nöron çıkışını ifade etmektedir.

Adım 9: Denk. 6.10 ve Denk. 6.11 eşitliklerine göre nöronlar arasındaki ağırlıklar ve eşik ağırlıkları bir sonraki çevrim için ayarlanır.

Adım 10: Bütün eğitim segmentleri için Adım (4-9) tekrar edilir. Eğitim segmentlerinin tamamı için bu adımlar takip edildikten sonra, yeni bir iterasyon için bir sonraki adıma geçilir.

Adım 11: Denk. 3.7'ye göre karesel hata (E) hesaplanarak en küçük hata kriteri ile karşılaştırılır. Eğer ortalama karesel hata, minimum hatadan veya iterasyon sayısı maksimum iterasyon sayısından küçük ise eğitime sonlandırılır ve test işlemi yapılır.

Adım 12: Aksi halde bir sonraki iterasyona başlamadan önce gizli katmanda bulunan serbest parametrelerin güncellenmesi gerekmektedir. AAFYSA'nın modeline bağlı olarak adaptif aktivasyon fonksiyonu da değişeceği için, her bir modelde bu parametrelerin güncellenmesi Bölüm 6.3'de ayrıntılı olarak, ayrı başlıklar altında anlatılmıştır.

Adım 13: Adaptif aktivasyon fonksiyonundaki serbest parametrelerin güncellenmesi işlemi tamamlandıktan sonra Adım 4'e dönülerek eğitime çiftinin ilk setinden eğitime işlemine devam edilir.

Şekil 6.2'den ve yukarıda anlatılan algoritmadan da görülebileceği gibi, AAFYSA yapısı için, ağırlıkların güncellenmesi, Bölüm 3.2 ile anlatılan geleneksel ÇKYSA yapısında olduğu gibi her eğitime çiftinin ağına sunulmasından sonra hedef değer ile ağına çıkışında elde edilen değer arasındaki farka göre yapılmaktadır. Şekil 2.4'de bulunan ÇKYSA akış diyagramını ile AAFYSA modelinin akış diyagramını gösteren Şekil 6.2 karşılaştırıldığı zaman anlatılan benzerlik görülebilmektedir.

Ayrıca Şekil 6.2 ile Şekil 2.4 karşılaştırıldığı zaman adaptif yapıda serbest parametrelerin güncellenmesinin ağırlıkların güncellenmesiyle farklı zamanlarda yapıldığı dikkati çekmektedir. Serbest parametrelerin güncellenmesi, bütün eğitim seti ağına sunulduktan sonra, diğer bir deyişle her iterasyon sonunda hesaplanan hata değerine bağlı olarak yapılmaktadır. Bunun anlamı gizli katman düğümlerinde kullanılan adaptif aktivasyon fonksiyonunun değeri her iterasyon sonunda değişmektedir.

AAFYSA'nın eğitime süreci, ÇKYSA' da olduğu gibi maksimum iterasyon sayısı veya minimum hata değerlerinden birine bağlı olarak sonlandırılmaktadır. Eğitime işleminin ardından test verileriyle adaptif ağına performansı test edilmektedir.

Bölüm 3'de anlatılmış olan ve gizli katman nöronlarında adaptif aktivasyon fonksiyonu olarak kullanılan Denk.(3.2-3.4) eşitlikleri ve Denk. 3.1 ile ifade edilen çıkış katmanı nöronu yada nöronlarında kullanılan sabit sigmoid aktivasyon fonksiyonuna bağlı olarak AAFYSA-1, AAFYSA-2 ve AAFYSA-3 modelleri için serbest parametrelerinin güncellenmesi işlemi her model için ayrıntılı olarak aşağıda tanımlanmıştır.

6.3. AAFYSA-1 Modelinin Serbest Parametrelerinin Güncellenmesi

Daha önce bahsedildiği gibi çalışılan modele bağlı olarak gizli katmanda bulunan adaptif aktivasyonu değişmektedir. AAFYSA-1 modelinde, Denk.3.2 ile verilen serbest parametrelili sigmoid fonksiyonu, gizli katmanda bulunan nöronlar için aktivasyon fonksiyonu olarak belirlenmiştir (Denk.6.2).

Bölüm 6.3 ile verilen, algoritmada da bahsedildiği gibi her iterasyon sonunda, Denk.3.7 ile ifade edilen ortalama karesel hata değeri (E) minimum hata değeri ile karşılaştırılır. Aynı zamanda iterasyon sayısı da kontrol edilir. Adım 12 ile ifade edilen durumda yani eğitime devam edeceksen, Denk.3.2 ile gösterilen adaptif aktivasyon fonksiyonu içinde bulunan iki adet serbest parametrenin değeri (a ve b), ortalama karesel hata fonksiyonunun kısmi türevine göre Denk. 6.10 ve Denk.6.11’de olduğu gibi hesaplanır. Burada r. iterasyon için gizli katmanda bulunan i. nöronun aktivasyon fonksiyonunda bulunan parametrelerin hesaplanabilmesi için, Denk.3.2, Denk.3.10 ve Denk.3.11 eşitliklerinin kullanılması gerekmektedir (Xu ve Zhang 2001, Xu ve Zhang 2005, Zhang ve ark. 1999, Zhang ve ark. 2002).

$$a_k^r = a_k^{r-1} + \beta \frac{\partial E}{\partial a_k} \quad (6.12)$$

$$b_k^r = b_k^{r-1} + \beta \frac{\partial E}{\partial b_k} \quad (6.13)$$

Serbest parametrelerdeki değişimleri bulmak için, Denk 6.12 ve Denk. 6.13’de olduğu gibi aktivasyon fonksiyonunun bu parametrelere göre kısmi türevi alınır. Ayrıca daha önce Denk.3.11 ile verilmiş olan nöron çıkışına göre kısmi türevini gösteren λ_k parametresinin Denk.6.8’e göre hesaplanabilmesi için çıkış katmanındaki nöronlar için hesaplanan lokal eğim değerine (δ_j) (Denk 6.7) ve çıkış katmanı ile gizli katman arasındaki ağırlık değerlerine (w_{jk}) ihtiyaç vardır.

$$\frac{\partial E}{\partial a_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial a_k(u)} = \lambda_k \frac{1}{1 + e^{-b_k I_k}} \quad (6.14)$$

$$a_k^r = a_k^{r-1} + \beta \lambda_k \frac{1}{1 + e^{-b_k I_k}} \quad (6.15)$$

$$\frac{\partial E}{\partial b_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial b_k(u)} = \lambda_{i,k} \frac{a_k I_k(u) e^{-b_k I_k}}{(1 + e^{-b_k I_k})^2} \quad (6.16)$$

$$b_k^r = b_k^{r-1} + \beta \lambda_k \frac{a_k I_k(u) e^{-b_k I_k}}{(1 + e^{-b_k I_k})^2} \quad (6.17)$$

AAFYSA-1 modeli ile uygulama yapılırken, bir sonraki r iterasyonu için gizli katman nöronlarının aktivasyon fonksiyonunda bulunan a_k ve b_k serbest parametrelerinin değeri, Denk. 6.15 ve Denk 6.17' de gösterildiği şekilde hesaplanır. Bu denklemlerden de görülebileceği gibi, serbest parametrelerin yeni değerinin elde edilebilmesi için önceki değerine, öğrenme oranına, karesel hata fonksiyonunun nöron çıkışına göre kısmi türevine ve adaptif sigmoid fonksiyonunun parametreye göre kısmi türevine gerek vardır.

6.4. AAFYSA-2 Modelinin Serbest Parametrelerinin Güncellenmesi

AAFYSA-2 modelinde daha önce Denk.3.3 ile verilen serbest parametrelili sigmoid fonksiyonu ile serbest parametrelili sinüs fonksiyonunun toplamı, gizli katmanda bulunan nöronlar için aktivasyon fonksiyonu olarak belirlenmiştir Denk.(6.3). Bu modelde, bu adaptif aktivasyon fonksiyonu içinde bulunan dört adet serbest parametre (a_k , b_k , c_k ve d_k) vardır. AAFYSA algoritmasına uygun olarak serbest parametrelerin güncellenmesi için gerekli eşitlikler, Denk. (6.18-6.14) ile verilmiştir. Şekil 6.2'de verilen akış diyagramına göre, herbir iterasyon sonunda, ortalama karesel hata değeri (Denk.3.7) ile minimum hata değeri karşılaştırılır. Adım 12'ye göre eğitime devam edecekse gizli katman düğümlerinde kullanılan adaptif aktivasyon fonksiyonundaki sinüs fonksiyonunun serbest parametreleri a_k ve b_k , Denk.6.18 ve Denk.6.19 ile ve sigmoid fonksiyonu serbest parametreleri c_k ve d_k ise Denk.6.20 ve Denk.6.21 ile güncellenmektedirler (Xu ve Zhang 2001, Zhang ve ark. 2002, Xu ve Zhang 2005).

$$a_k^r = a_k^{r-1} + \beta \frac{\partial E}{\partial a_k} \quad (6.18)$$

$$b_k^r = b_k^{r-1} + \beta \frac{\partial E}{\partial b_k} \quad (6.19)$$

$$c_k^r = c_k^{r-1} + \beta \frac{\partial E}{\partial c_k} \quad (6.20)$$

$$d_k^r = d_k^{r-1} + \beta \frac{\partial E}{\partial d_k} \quad (6.21)$$

Bu denklemlerde yer alan, kısmi türevler, Denk.6.3 ile verilen aktivasyon fonksiyonu dikkate alınarak elde edilir. Bu aktivasyon fonksiyonunda bulunan serbest parametrelerin bir sonraki iterasyon için değişimleri λ_k parametresine bağlıdır. Bu parametre Denk.6.8 ile verilmiştir ve çıkış katmanındaki nöronların eğimlerine ve çıkış katmanı ile k. nöron arasındaki ağırlık değerlerine bağlıdır. k. Nöron için λ_k parametresi hesaplandıktan sonra aktivasyon fonksiyonunda bulunan a_k serbest parametresinin önceki değerine bağlı olarak r. iterasyon için değeri,

$$\frac{\partial E}{\partial a_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial a_k(u)} = \lambda_k \sin(b_k I_k) \quad (6.22)$$

$$a_k^r = a_k^{r-1} + \beta \lambda_k \sin(b_k I_k) \quad (6.23)$$

b_k serbest parametresinin önceki değerine bağlı olarak r. iterasyon için değeri,

$$\frac{\partial E}{\partial b_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial b_k(u)} = \lambda_k I_k a_k \cos(b_k I_k) \quad (6.24)$$

$$b_k^r = b_k^{r-1} + \beta \lambda_k I_k a_k \cos(b_k I_k) \quad (6.25)$$

c_k serbest parametresinin önceki değerine bağlı olarak r. iterasyon için değeri,

$$\frac{\partial E}{\partial c_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial c_k(u)} = \lambda_k \frac{1}{1 + e^{-d_k I_k}} \quad (6.26)$$

$$c_k^r = c_k^{r-1} + \beta \lambda_k \frac{1}{1 + e^{-d_k I_k}} \quad (6.27)$$

d_k serbest parametresinin önceki değerine bağlı olarak r. iterasyon için değeri,

$$\frac{\partial E}{\partial d_k(u)} = \frac{\partial E}{\partial O_k(u)} \frac{\partial O_k(u)}{\partial d_k(u)} = \lambda_k \frac{c_k I_k(u) e^{-d_k I_k}}{(1 + e^{-d_k I_k})^2} \quad (6.28)$$

$$d_k^r = d_k^{r-1} + \beta \lambda_k \frac{c_k I_k(u) e^{-d_k I_k}}{(1 + e^{-d_k I_k})^2} \quad (6.29)$$

hesaplanır. AAFYSA-2 modeli ile uygulama yapılırken, bir sonraki iterasyonu için hesaplanan gizli katman nöronlarının aktivasyon fonksiyonunda bulunan serbest parametrelerin değeri hesaplandıktan sonra algorithmada verilen Adım 13'den program işlemeye devam eder. Bu denklemlerden de görülebileceği gibi, serbest parametrelerin yeni değerinin elde edilebilmesi için öğrenme oranına, karesel hata fonksiyonunun nöron çıkışına göre kısmi türevine ve adaptif sigmoid fonksiyonunun parametreye göre kısmi türevine gerek vardır.

6.5. AAFYSA-3 Modelinin Serbest Parametrelerinin Güncellenmesi

Üçüncü algoritma olan AAFYSA-3'de Denk. 3.4 ile verilen, gizli katmanda bulunan nöronlar için aktivasyon fonksiyonu olarak belirlenmiştir. Şimdiye kadar, serbest parametrelili Morlet dalgacık fonksiyonu adaptif aktivasyon fonksiyonu olarak hiçbir çalışmada kullanılmamıştır. Bu fonksiyonda a_k ve b_k olmak üzere iki adet serbest parametre vardır. Bu parametrelerin güncellenmesi, Denk 6.23 ve Denk. 6.24 ile verilmiştir (Xu ve Zhang 1999b, Xu ve Zhang 2000, Xu ve Zhang 2001, Zhang Xu ve Zhang 2005).

$$a_k^r = a_k^{r-1} + \beta \frac{\partial E}{\partial a_k} \quad (6.30)$$

$$b_k^r = b_k^{r-1} + \beta \frac{\partial E}{\partial b_k} \quad (6.31)$$

Bir aktivasyon fonksiyonu olarak iki serbest parametrelili Morlet dalgacığının ifadesi Denk. 6.3 ile gösterilmiştir. Bölüm 6.3 ile verilen, algorithmada da bahsedildiği gibi her iterasyon sonunda, Denk.3.7 ile ifade edilen ortalama karesel hata değeri (E), minimum hata değerinden küçük değilse ve aynı zamanda iterasyon sayısı maksimum iterasyon sayısından daha az ise eğitime devam edecek demektir (Adım 12). Bu durumda serbest parametrelerin değeri ortalama karesel hata fonksiyonunun kısmi türevine göre Denk. 6.32 ve Denk. 6.33'de olduğu gibi hesaplanır. a_k serbest parametresinin, gizli nöron aktivasyon fonksiyonuna göre bir sonraki iterasyon için değeri,

$$\frac{\partial E}{\partial a_{i,k}(u)} = \frac{\partial E}{\partial O_{i,k}(u)} \frac{\partial O_{i,k}(u)}{\partial a_{i,k}(u)} = -\lambda_{i,k} (I_{i,k})^2 e^{-a_{i,k}(I_{i,k})^2} \cos(b_{i,k} I_{i,k}) \quad (6.32)$$

$$a_{i,k}^r = a_{i,k}^{r-1} - \beta \lambda_{i,k} (I_{i,k})^2 e^{-a_{i,k}(I_{i,k})^2} \cos(b_{i,k} I_{i,k}) \quad (6.33)$$

ile ve b_k serbest parametresinin, gizli nöron aktivasyon fonksiyonuna göre bir sonraki iterasyon için değeri,

$$\frac{\partial E}{\partial b_{i,k}(u)} = \frac{\partial E}{\partial O_{i,k}(u)} \frac{\partial O_{i,k}(u)}{\partial b_{i,k}(u)} = -\lambda_{i,k} I_{i,k} e^{-a_{i,k}(I_{i,k})^2} \sin(b_{i,k} I_{i,k}) \quad (6.34)$$

$$b_{i,k}^r = b_{i,k}^{r-1} - \beta \lambda_{i,k} I_{i,k} e^{-a_{i,k}(I_{i,k})^2} \sin(b_{i,k} I_{i,k}) \quad (6.35)$$

denklemleri ile hesaplanmaktadır.

Bu aktivasyon fonksiyonunda bulunan serbest parametrelerin bir sonraki iterasyon için değişimleri λ_k parametresine bağlıdır. Daha önce Denk.6.8 ile verilmiş olan ve nöron çıkışına göre kısmi türevini gösteren λ_k parametresi, çıkış katmanındaki nöronlar için hesaplanan lokal eğim değerine (δ_j) ve çıkış katmanı ile gizli katman arasındaki ağırlık değerlerine (w_{jk}) bağlı olarak değişmektedir. Bu durumda serbest parametrelerin değeri, çıkış katmanı ile gizli katman arasındaki ağırlıklara bağlıdır. Bilindiği gibi ağırlıklar ağ bilgisini tutan öğelerdir. Sonuç olarak, bu ifadeler dikkate alınarak serbest parametrelerin de ağ bilgisini tuttuğu söylenebilir.

6.6. AAFYSA modelinin başarısının ölçülmesi

Bu çalışmada tasarımı yapılan üç farklı AAFYSA modelinin eğitime algoritması, gizli katmanlarında bulunan aktivasyon fonksiyonları dışında birbirlerinden çok uzak değillerdir. Bunun yanında farklı aktivasyon fonksiyonu kullanılması, ağırlıkların ve serbest parametrelerin güncellenmesinde kullanılacak matematiksel ifadeleri tamamen değiştirmektedir. Bu nedenle AAFYSA'nın modeline bağlı olarak kurulan algoritmada Bölüm 3 ve Bölüm 6'da anlatıldığı gibi, farklı matematiksel ifadeler kurulmuştur. AAFYSA modellerinin ortak özellikleri ise çıkış katmanlarında bulunan nöronların aktivasyon fonksiyonu olarak sabit sigmoid

aktivasyon fonksiyonunu kullanmalarıdır. Bu çalışma için yazılımı oluşturulan AAFYSA modellerinin literatürde yapılmış çalışmalardan (Xu ve Zhang 1999a, Xu ve Zhang 1999b, Xu ve Zhang 2000, Xu ve Zhang 2001, Zhang ve ark. 2002, Xu ve Zhang 2005, Liu 1993, Yu ve ark. 2002) farkı, çıkış katmanında bulunan nöron sayıları, aktivasyon fonksiyonunun tipi, serbest parametrelerin öğrenme algoritması ve çıkış katmanında kullanılan aktivasyon fonksiyonunun tipidir.

Literatürde yapılan çalışmaların büyük çoğunluğunda serbest parametrelili sigmoid fonksiyonu, adaptif aktivasyon fonksiyonu olarak kullanılmıştır (Wu ve ark. 1997, Liu 1993, Yu ve ark. 2002, Yazdanpanah ve ark. 2003). Farklı adaptif aktivasyon fonksiyonlarının kullanıldığı çalışmalarda ise tek giriş nöronuna sahip mimariler kullanılmıştır. Yapılan çalışmalarda genellikle çıkış katmanında bulunan nöron sayısı birdir. Çok karmaşık ağ yapılarında adaptif aktivasyon fonksiyonlu mimari ile yapılmış çalışmalar literatürde bulunmamaktadır.

Bunun yanında karmaşık ağ mimarisi ile ÇKYSA kullanılarak yapılmış pek çok çalışma söz konusudur. Bu nedenle AAFYSA algoritmasının da karmaşık problemlerin çözümünde başarılı olabileceği düşünülmüştür.

Bu nedenle, bu çalışmada, ÇKYSA modeli ile üç farklı AAFYSA modelinin karşılaştırılması, öncelikle literatürde sıkça kullanılan verilerden biri olan XOR ile ve daha sonra EKG ve EEG biyomedikal verileriyle yapılmıştır. Geliştirilen yazılımlar ile eğitime yapılırken eğitime süreleri ve iterasyon sayısı açısından doğru karşılaştırma yapılabilmesi için her zaman aynı bilgisayarın kullanılmasına dikkat edilmiştir. Aynı zamanda hem ÇKYSA için hem de AAFYSA için Bölüm 8'de anlatılacak olan eğitime ve test hataları ile performans karşılaştırılması yapılmıştır.

7. MATLAB NEURAL NETWORK TOOLBOX KULLANARAK EEG SİNYALLERİNİN SINIFLANDIRILMASI

Beyin fonksiyonlarının tanınmasında ve nörolojik hastalıkların teşhisinde yaygın olarak kullanılan EEG sinyalleri karmaşık, yorumlanması zor ve veri miktarı çok fazla olan sinyallerdir. Beyin fonksiyonlarının anlaşılması ve epileptik verilerin tanımlanması için yapılan çalışmalarda yaygın olarak geleneksel YSA, dalgacık dönüşüm ve temel bileşen analizi yöntemleri kullanılmıştır (Kalaycı ve Özdamar 1995, Krajca ve ark. 1999). Oysa alkolik ve normal kişilere ait EEG sinyallerinin sınıflandırılmasında bu yöntemlerin hibrit yapılarından meydana gelen çalışma sayısı çok fazla değildir. Bu nedenle bu bölümde anlatılacak olan çalışmalarda, The UCI KDD Archive Information and Computer Science University of California veri tabanından alınan EEG verilerinin dalgacık dönüşümü, temel bileşen analizi ve geleneksel YSA kullanılarak sınıflandırılması amaçlanmıştır. Bu amaçla, EEG sinyallerinden özellik çıkarma işlemlerini gerçekleştirebilmek için kullanılan dalgacık dönüşümü ve temel bileşen analizi yazılımları ve geleneksel ÇKYSA yazılımı Matlab programlama dilinde yazılmıştır. Burada yazılımı gerçekleştirilen ÇKYSA yazılımı, Bölüm 2 ile anlatılan ÇKYSA yazılımından ve Bölüm 3 ile anlatılan AAFYSA yazılımından farklı olarak Matlab hazır komutları kullanılarak gerçekleştirilmiştir.

Bu çalışma için, The UCI KDD Archive Information and Computer Science University of California veri tabanından alkolik ve normal denek EEG verileri alınmıştır. Bu veriler çoklu elektrotlu zaman serileri şeklinde yapılmış EEG kayıtlarıdır. Bu veri tabanında genel kullanıma açılmış olan EEG kayıtları, alkolizme genetik yatkınlığın EEG sinyallerine etkisini görmek için yapılmış kayıtlar olarak tanımlanmıştır. EEG kayıtları 64 kanal 256 örnekleme frekansı ile kafa derisine yerleştirilmiş elektrotlarla yapılmış kayıtlardır. Alkolik EEG sinyali ve normal (kontrol) EEG sinyali olmak üzere iki sınıf veri söz konusudur.

Bu bölümde anlatılan çalışmalarda, 40 alkolik, 40 normal olmak üzere 80 denekten alınmış verilerle çalışılmıştır. 20 alkolik ve 20 normal denekten alınan veri, eğitime veri seti için, kalan 20 normal ve 20 alkolik kişiden alınan veriler ise test


seti olarak kullanılmıştır. Veri setindeki her segment, toplam 30 saniyeden yani 7680 örnekten oluşmaktadır.

Her iki çalışmada hem eğitime hem de test verisine 5. seviyede db4 dalgacık dönüşümü uygulanarak her segmentte bulunan örnek sayısının azaltılması sağlanmıştır. 5. dereceden dalgacık dönüşümü uygulandıktan sonra alçak frekans bileşenlerini içeren 5. dereceden yaklaşım katsayıları olan A5 katsayıları elde edilmiştir. Bu şekilde her bir segment sayısı 7680 örnekten 246 örneğe azaltılmış olmaktadır.

7.1. Dalgacık Dönüşümü ve YSA Kullanılarak EEG Sinyallerinin Sınıflandırılması

Alkolik ve normal EEG verilerine dalgacık dönüşümünü uygulayarak, elde edilen özellik vektörünü doğrudan sınıflandırıcıya uygulanmıştır (Tezel ve Özbay 2006). Yukarıda anlatıldığı şekilde db4 dalgacığı kullanılarak elde edilmiş A5 katsayıları, ÇKYSA'nın giriş vektörünü oluşturmuştur. Bu çalışmada, verinin işlenmesi ve sınıflandırılması için kullanılan yöntemler blok olarak Şekil 7.1 ile ifade edilmiştir. Şekil 7.1'de görüldüğü gibi, ham veriye 5. dereceden db4 dalgacık dönüşümü uygulanarak, her segmentte bulunan örnek sayısı, 7680 değerinden 246 değerine azaltılmış olmaktadır. Daha sonra ise sınıflandırıcı olarak kullanılan YSA girişine elde edilen yeni özellik vektörü uygulanır. İki sınıf veri sınıflandırıldığı için YSA'nın çıkış katmanında bir tane nöron kullanılmıştır. Yapılan deneyler sonucunda Şekil 7.1'de verilen yapıya göre Tablo 7.1 de belirtilen sınıflandırma sonuçları elde edilmiştir.

Deneysel sonuçlar göstermiştir ki, iki gizli katmanlı bir mimari ile daha başarılı sonuç elde edilmiştir. Buna göre en başarılı mimari, 0.05 öğrenme oranı ve 0.8 momentum sabiti için 246x100x10x1 şeklinde bulunmuştur. Gizli katmanda ve çıkış katmanında bulunan nöronlarda logaritmik sigmoid fonksiyonu aktivasyon fonksiyonu olarak kullanılmıştır. Eğitime için durdurma kriteri 10^{-21} olarak belirlenmiştir.



Şekil 7.1.Dalgacık dönüşümü ve YSA kullanılarak sınıflandırma algoritmasının blok olarak gösterimi

Tablo 7.1.Dalgacık dönüşümü ve YSA kullanılarak elde edilen sınıflandırma sonuçları (Mc:momentum katsayısı, β :öğrenme oranı, SEN:Hassasiyet ve SPE:Belirlilik)

No	YSA Mimarisi	İterasyon	Mc	β	Eğitime Hatası(%)	Test Hatası (%)	Eğitime Zamanı(s)	SEN (%)	SPE (%)
1	246:75:10:1	2903	0,8	0,1	4E-09	4E-09	1406.9	100	100
2	246:75:10:1	5449	0.8	0.2	9,45E-10	9.45E-10	1148	100	100
3	246:75:10:1	10000	0.8	0.3	0.05	0.0497	2174	99.9	100
4	246:75:10:1	1986	0.8	0.05	3.85E-9	3.85E-9	405.6	100	100
5	246:100:10:1	1736	0.8	0.05	3,11E-09	3,11E-09	421	100	100
6	246:150:10:1	1002	0.8	0.05	3.59E-9	3.59E-9	355.69	100	100

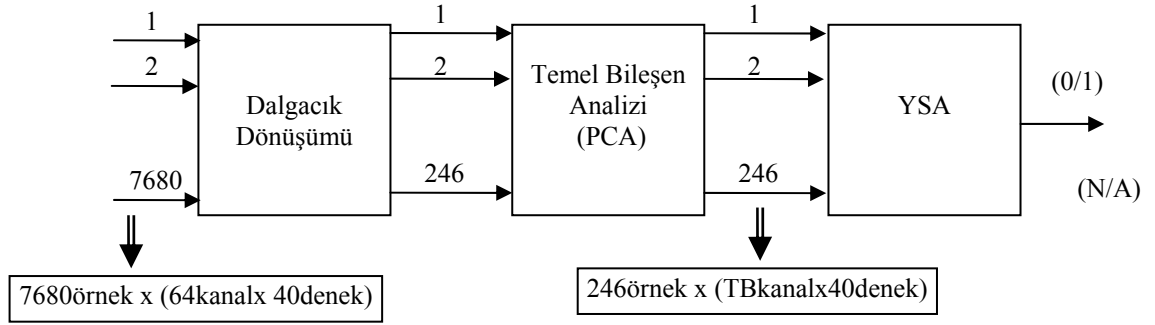
7.2. DD-PCA-YSA Hibrit Yapısı Kullanılarak EEG Sinyallerinin Sınıflandırılması

Bölüm 7.1 ile anlatılan çalışmaya ek olarak 64 kanal olan bir kişiye ait EEG verisini daha az sayıda kanal ile ifade etme amacıyla PCA yönteminin kullanılması düşünülmüştür. Bu nedenle, veri matrislerinin boyutları DD-PCA-YSA hibrit yapısı kullanılarak azaltılmış ve sonra sınıflandırılmıştır.

Bu çalışmada (Tezel ve ark. 2007), giriş verisine dalgacık dönüşümü (DD) uygulanarak A5 katsayıları elde edildikten sonra 64 kanal veriyi daha az sayıda kanal ile temsil edebilmek amacıyla Bölüm 5’de anlatılan PCA yöntemi uygulanmıştır. Şimdiye kadar EEG sinyallerine dalgacık dönüşümü ve PCA uygulayarak hem veri hem de kanal azaltılması yapılmış bir çalışma yapılmamıştır. Bu nedenle bu tip bir hibrit yapı kullanılması düşünülmüştür. Bu uygulamada kullanılan yeni sistem, DD-PCA-YSA şeklinde adlandırılmıştır. Bu çalışmada 64 kanal EEG segmentlerine öncelikle 5. dereceden db4 dalgacık dönüşümü uygulanmış ve 5. seviyedeki yaklaşım katsayıları özellik vektörü olarak alınmıştır. Bu şekilde her bir denek için 7680x64 olan veri matrisi (246x64) boyutlarına indirgenmiş olmaktadır. Daha sonra

indirgenmiş veri matrisine, PCA yöntemi uygulanarak kanal sayısının azaltılması işlemi gerçekleştirilmiştir. Bu yöntemle azaltılan kanal sayısı, seçilen temel bileşen (TB) miktarı ile ifade edilmektedir. Bu ön işlem yönteminden sonra da bir deneğe ait veri matrisi boyutları (246xTB) şeklinde elde edilmektedir.

Bu sistemin blok olarak gösterimi ve matris boyutlarındaki değişim Şekil 7.2’de gösterilmiştir. Bu çalışma için en iyi sonuçların, 40 nöronlu tek gizli katmanlı mimaride elde edildiği görülmüştür. Gizli katman düğümlerinde tanjant sigmoid fonksiyonu ve çıkış katmanı düğümlerinde sigmoid fonksiyonu aktivasyon fonksiyonu olarak kullanılmıştır. Tablo 7.2 ile bu çalışma için yapılan uygulama sonuçları verilmiştir.



Şekil 7.2. Dalgacık dönüşümü-PCA-YSA yapısının blok olarak gösterimi

Tablo 7.2. Dalgacık dönüşümü-PCA-YSA yapısı kullanılarak elde edilen sınıflandırma sonuçları

TB	Eğitme Hatası(%)	Test Hatası (%)	Eğitme Zamanı(s)	SEN (%)	SPE (%)
1	$1.8 \cdot 10^{-9}$	$1.8 \cdot 10^{-9}$	70	100	100
2	0.23	0.93	136	100	100
3	$1.86 \cdot 10^{-9}$	$1.67 \cdot 10^{-9}$	192	100	100
4	$5.74 \cdot 10^{-9}$	$9.12 \cdot 10^{-9}$	255	100	100
5	$1.93 \cdot 10^{-9}$	$4.84 \cdot 10^{-9}$	334	100	100
10	0.5	0.28	624	99	99
15	0.345	2.75	1300	99	99

7.3. Neural Network Toolbox Fonksiyonları Yerine AAFYSA Algoritmasının Seçilme Nedenleri

“The UCI KDD Archive Information and Computer Science University of California” veri tabanından alınmış 64 elektrotla zaman serileri şeklinde kayıt yapılmış EEG verileri ile yapılan bu çalışmalarda, Matlab R2006 “Neural Network Toolbox” kullanılarak yapılmış sınıflandırma işlemlerinde başarılı sonuçlar elde edilmiştir. Fakat literatürde, dalgacık dönüşümü ve ÇKYSA kullanılarak yapılmış epileptik EEG sinyallerinin işlenmesi ile ilgili çok sayıda çalışma vardır. Bunun yanında alkolik verilerle yapılmış çalışma sayısı sınırlıdır. Ayrıca ikinci çalışmada dalgacık dönüşümü yanında PCA yöntemi de kullanılarak veri setinin boyutlarının azaltılması ile ilgili uygulamaya raslanmamıştır.

Bu bölümde anlatılmış olan çalışmalarla başarılı sonuçlar elde edilmesine rağmen, kullanılan bu yöntemlere EEG uygulamalarında sıklıkla rastlanmaktadır. Bu nedenle, daha önce sinyali sınıflandırma ya da tanıma uygulamalarında hiç denenmemiş yeni bir yöntem arayışına girilmiştir. Yapılan literatür taramaları sonunda henüz sinyal işleme konusunda kendisine bir yer bulamayan ve 1990’lı yıllardan beri üzerinde çalışılmakta olan AAFYSA algoritması üzerinde durulmuştur. AAFYSA ile EEG sinyallerinin sınıflandırılması konusunda henüz literatürde yapılmış bir çalışma yoktur. Bu nedenle, bu yöntemin bu tez çalışmasına daha iyi katkı sağlanacağı düşünülmüş ve bu amaçla da, Bölüm 3’de algoritması anlatılmış olan AAFYSA ile ilgili çalışmalara başlanmıştır.

8. GELİŞTİRİLEN YSA MODELLERİ İLE YAPILAN UYGULAMALAR

Bu bölümde, tez çalışması kapsamında, algoritması geliştirilen ve yazılımı yapılan üç tane AAFYSA modeli (AAFYSA-1, AAFYSA-2 ve AAFYSA-3) ve eşit koşullarda karşılaştırma yapmak için yazılımı gerçekleştirilen ÇKYSA modeli ile yapılmış uygulamalara yer verilmiştir. ÇKYSA ağı, AAFYSA ağlarının başarısını geleneksel yöntemlerle karşılaştırabilmek amacıyla geliştirilmiş ve yazılımı gerçekleştirilmiştir. Geliştirilen AAFYSA ağları ile ÇKYSA ağı, ilk olarak, literatürde standart bir problem olarak kabul edilen XOR problemine uygulanmıştır. Daha sonra, AAFYSA modelleri ile hiç uygulama yapılmamış olan EKG ve EEG verilerinin sınıflandırılması problemleri üzerinde durulmuştur.

Bu tez çalışmasında geliştirilen üç adet AAFYSA ağının sonuçları hem birbirleriyle hem de geleneksel ÇKYSA ile karşılaştırılmıştır. Yapılan denemelerin başarısı eğitime hatası, test hatası, öğrenme zamanı ve minimum hataya ulaşılan iterasyon sayısı, belirlilik ve hassasiyet kriterlerine göre ölçülmüştür. Yapılan bütün uygulamalarda başarı ölçütü olarak kullanılan hata parametreleri, belirlilik ve duyarlılık analizi Bölüm 8.1’de anlatılmaktadır.

8.1. Eğitime ve Test Başarısının Ölçülmesi

Yapılan herhangi bir çalışmanın veya uygulamanın geçerliliğini kanıtlayabilmek için birtakım başarı kriterleri belirlemek gerekmektedir. Bu kriterler YSA söz konusu olduğu zaman eğitime hatası, test hatası, zaman, maksimum iterasyon sayısı, hassasiyet ve belirlilik kriterlerdir.

Bu bölümde, uygulamaların başarılarının ölçülmesi ve geliştirilen algoritmaların literatürde anlamlı bir yer kazanabilmesi için yaygın olarak kullanılan eğitime ve test başarı ölçütleri anlatılmıştır.

8.1.1. Eğitim ve test hatasının hesaplanması

ÇKYSA ve AAFYSA ile yapılan uygulamaların sonuçlarının gösterildiği tablo ve şekillerde verilen eğitim ve test hatası değerleri Denk.8.1 ile ifade edilen Hata(%) eşitliğine göre hesaplanmıştır (Özbay ve ark. 2006).

$$\text{Hata(\%)} = \left(\frac{\sum_{j=1}^n \sum_{i=1}^p |d_i(j) - O_i(j)|}{pn} \right) \times 100 \quad (8.1)$$

Bölüm 2’de de anlatıldığı gibi, bu formülde kullanılan p, çıkış nöron sayısı, n eğitim setindeki segment sayısı, $d_i(j)$, i. çıkış nöronunun hedef değeri ve $O_i(j)$ i.nöronun çıkış değeridir. Burada j eğitim setindeki segment numarasını ifade etmektedir. Denk. 8.1’e göre hata hesaplanırken çıkış katmanındaki bütün nöronlar için ağın ürettiği değer ile olması gereken değer arasındaki farkların mutlak toplamı alınır. Bu işlem eğitim ya da test veri setindeki bütün segmentler için yapıldıktan sonra elde edilen toplam değer, çıkış düğüm sayısı ile veri setinde bulunan segment sayısının çarpımına bölünür ve 100 ile çarpılır. Bu denkleme göre hata değeri yüzde olarak hesaplanmaktadır ve hem test hem de eğitim hatasının hesaplanması için kullanılabilir. Bu denklem kullanılarak hata hesabının yapılabilmesi için hedef çıkış değerinin bilinmesi gerekmektedir.

Denk 8.1 XOR problemi ve EEG verilerinin sınıflandırılması problemlerinde hem eğitim hem de test hatasının hesaplanması için kullanılmıştır. EKG verilerinin sınıflandırılması probleminde ise sadece eğitim hatasının hesabında kullanılmıştır.

Bunun yanında eğer herhangi bir test veri seti için hedef değer verilmediği zamanlarda ise hata hesabının yapılabilmesi için farklı bir yöntem uygulanmıştır (Özbay ve Ark. 2006).

Özbay ve ark. (2006)’nın geliştirdiği bu algoritmada, çıkış katmanındaki nöronların hedef çıkış değerleri Lojik 1 veya Lojik 0 olarak ifade edilmektedir. Buna göre çıkış nöronunun değerinin, 0 ile 1 arasında değiştiği kabul edilmektedir.

Bu durumda bir segment için ağın çıkışında elde edilen i. çıkış nöronu için, ağın ürettiği değer $O_i \geq 0.5$ ise nöron hatası,

$$h_i = |1 - O_i| \quad (8.2)$$

olur ve yeni bir karşılaştırma daha yapılır ve nöron değeri çıkış katmanındaki diğer nöron değerleri ile karşılaştırılır. Buna göre aynı zamanda $O_i \geq$ (diğer çıkış nöron değerleri) ise bu çıkış olması gereken çıkış olarak tanımlanır.

Yukarıda anlatılanın aksine ağıın ürettiği i nöron çıkış değeri, $O_i \leq 0.5$ ise istenen çıkış değildir ve nöron hatası aşağıdaki formüle göre yapılır.

$$h_i = |0 - O_i| \quad (8.3)$$

Ayrıca eğer bütün çıkış nöronları için ağıın ürettiği değer $O_i < 0.5$ değerinde olursa giriş segmenti, tanımlanamayan segment olarak nitelendirilmektedir. Bu durumda YSA bu segmenti sınıflandırılmamıştır ve benzer şekilde, bu tip bir segment YSA'ya öğretilmemiştir. Sonuç olarak, test veri setinde bulunan bütün segmentler ve çıkış nöronları için yukarıdaki karşılaştırmalar yapıldıktan sonra ortalama test hatası Denk. 8.4'e göre hesaplanabilmektedir. Bu formüle göre, toplam nöron hataları bulunduğundan sonra test verisindeki segment sayısına ve çıkış nöron sayısına bölünerek 100 ile çarpılarak test hatası yüzde olarak hesaplanmaktadır (Özbay ve Ark. 2006).

$$\text{TestHatası}(\%) = \left(\frac{\sum_{j=1}^n \sum_{i=1}^p h_i(j)}{pn} \right) \times 100 \quad (8.4)$$

Denk. 8.4. ile verilen Test hatası eşitliği, EKG verilerinin sınıflandırılması probleminde test hatasını bulmak için kullanılmıştır.

8.1.2. Belirlilik (Specificity-SPE) ve hassasiyet (Sensitivity -SEN) analizleri

Herhangi bir modelin test performansı belirlilik (specificity-SPE) ve hassasiyet (sensitivity-SEN) ile hesaplanabilmektedir. Bu analizlerin yapılabilmesi için ağıın ürettiği çıkış ile uzman görüşüyle belirlenmiş hedef çıkış değerleri aşağıda verilen kriterlere göre değerlendirilir (Tarrasenko ve ark. 1998, Dirgenali ve Kara 2006).

(1) *Doğru pozitif (DP)*: YSA, uzman tarafından hastalıklı olarak tanımlanan segmenti hastalıklı bulmuştur.

(2) *Doğru negatif (DN)*: Uzman tarafından normal olarak tanımlanmış segmenti YSA'da normal olarak tespit etmiştir.

(3) *Yanlış pozitif (YP)*: Uzman tarafından normal olarak tanımlanmış segmenti YSA hastalıklı olarak tespit etmiştir

(4) *Yanlış negatif (YN)*: Uzman tarafından hastalıklı olarak tanımlanmış segmenti YSA normal olarak tespit etmiştir.

Bulunan bu kriterlere bağlı olarak belirlilik (SPE) ve hassasiyet (SEN) Denk.8.5 ve Denk.8.6'ya göre hesaplanır

(1) *Hassasiyet (SEN)*: Sınıflandırıcının hastalıklı veriyi tespit etme yeteneğidir.

$$SEN(\%) = \frac{DP}{(DP + YN)} 100 \quad (8.5)$$

(2) *Belirlilik (SPE)*: Sınıflandırıcının normal veriyi tespit etme yeteneğidir

$$SPE(\%) = \frac{DN}{(DN + YP)} 100 \quad (8.6)$$

8.2. XOR Probleminin AAFYSA ile Çözümü

XOR problemi, YSA'da bir devrin kapanıp bir devrin açılmasına neden olmuş önemli bir kilometre taşıdır (Öztemel 2003). Bu nedenle, adaptif aktivasyon fonksiyonlu YSA modeli ile geleneksel ÇKYSA modelinin performansını ve hızını karşılaştırmak için ÇKYSA modellerinin bulunmasının en önemli nedenlerinden biri olan XOR problemi üzerinde durulmuştur. Bu çalışmada, Tablo 8.1 ile ifade edilen XOR verisi kullanılmıştır. Tablo 8.1'de XOR verisinin eğitim seti, test seti ve eğitim ve test işlemi sonunda ağın üretmesi beklenen hedef çıkış seti verilmiştir. XOR verisi ile yapılan denemeler için algoritması geliştirilen ve yazılımı gerçekleştirilen AAFYSA-1, AAFYSA-2, AAFYSA-3 ve ÇKYSA ağları kullanılmıştır. Bütün modeller için farklı gizli düğüm sayılarında ve farklı öğrenme oranlarında eğitim yapılmıştır. XOR probleminin çözümü için kullanılan modellerin başarısı, eğitim hatası (EH), test hatası (TH), eğitim zamanı ve iterasyon sayısı bakımından

değerlendirilmiştir. XOR verisi ile yapılan denemeler sonucunda elde edilen sonuçlar Tablo 8.2’de gösterilmektedir.

Tablo 8.1 AAFYSA-1, AAFYSA-2, AAFYSA-3 ve ÇKYSA ağları için kullanılan XOR Veri Seti

Eğitme Seti		Hedef Çıkış	Test Seti	
0.1	0.1	0	0.2	0.01
0.1	0.9	1	0.05	0.8
0.9	0.1	1	0.8	0.1
0.9	0.9	0	0.9	0.9

Tablo 8.2.a’da ÇKYSA için en küçük eğitme hatası % 2.14, 2x3x1 mimarisi ile test hatası ise % 1.94 olarak 2x2x1 mimarisi ile elde edilmiştir. İki mimari içinde maksimum iterasyon sayısı olan 10000 değerine ulaşılmadan, karesel hata değeri en küçük hata kriterine yakınsamıştır.

Tablo 8.2.b’de AAFYSA-1 için 0.2 öğrenme oranında en küçük eğitme hatası 2x4x1 mimarisinde %2.11 ve test hatası 0.5 öğrenme oranı ve 2x3x1 mimarisi için %2.24 olarak elde edilmiştir.

Tablo 8.2.c’de AAFYSA-2 için 0.5 öğrenme oranı ve 2x2x1 mimarisinde en küçük eğitme hatası % 1.8 ve test hatası %1.66 elde edilmiştir. Bu başarıya 4 saniyede 452 iterasyonda ulaşılmıştır.

Tablo 8.2.d’de AAFYSA-3 için genel olarak bütün mimarilerde yaklaşık olarak %2.2 eğitme ve test hatasına ulaşılmıştır. Bu model zaman bakımından değerlendirildiğinde 0.5 öğrenme oranı ve 2 gizli düğüm, 4 saniye ile en başarılı mimaridir denilebilir.

Sonuç olarak Tablo 8.2 ile verilen bütün tablolar karşılaştırıldığında, en küçük eğitme hatası ve test hatası, 0.5 öğrenme oranı (β) ve 2 gizli düğüm için AAFYSA-2 modeliyle elde edilmiştir. AAFYSA-2 modelinde eğitme için harcanan zaman 4 saniye iken en başarılı ÇKYSA eğitimi için harcanan zaman 47 saniyedir. Dolayısıyla, ÇKYSA eğitimi için harcanan zaman, AAFYSA-2 modelinin eğitimi için harcanan zamanın, yaklaşık olarak 10 katı olduğu Tablo 8.2.a ve Tablo8.2.c’den görülebilmektedir.

Şekil 8.1 ÇKYSA, AAFYSA-1, AAFYSA-2 ve AAFYSA-3 modelleri için en iyi sonuçların elde edildiği verilere göre çizilmiştir.

Tablo 8.2. XOR verisi için Eğitim ve test sonuçları (a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için ve (d) AAFYSA-3 modeli için

(a) ÇKYSA modeli

β	Gizli Düşüm	EH (%)	TH (%)	Zaman (s)	İterasyon Sayısı
0.2	2	4.07	3.54	51	10000
	3	3.25	3.52	70	10000
	4	2.96	3.20	56	10000
0.5	2	2.22	1.94	55	8032
	3	2.14	2.34	56	7895
	4	2.18	2.40	47	6539

(b) AAFYSA-1 modeli

β	Gizli Düşüm	EH (%)	TH (%)	Zaman (s)	İterasyon Sayısı
0.2	2	2.61	2.86	130	10000
	3	2.57	2.66	86	10000
	4	2.11	2.75	3	10000
0.5	2	33.25	34.04	80	10000
	3	2.16	2.24	44	5397
	4	2.18	2.34	42	4928

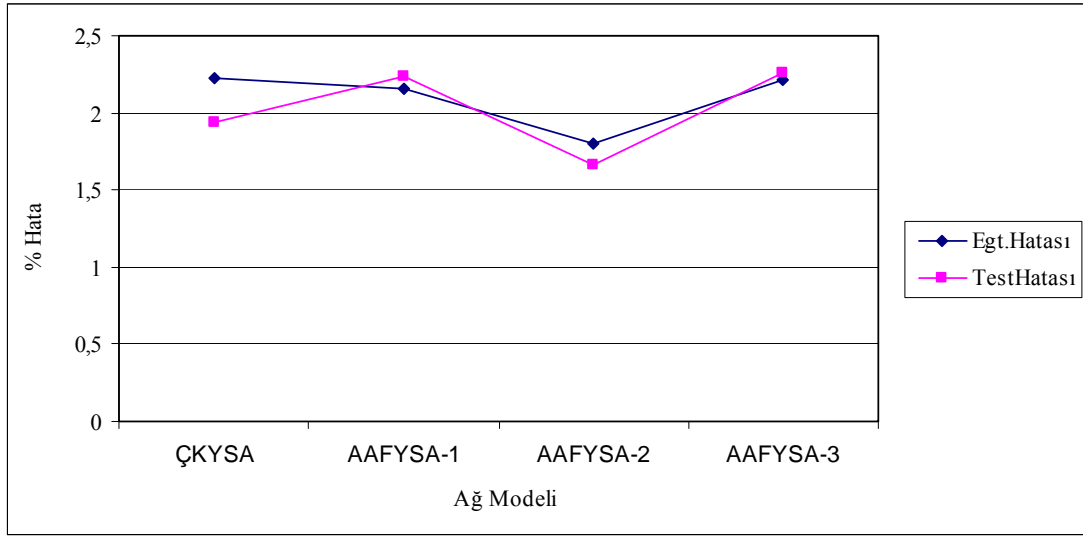
(c) AAFYSA-2 modeli

β	Gizli Düşüm	EH (%)	TH (%)	Zaman (s)	İterasyon Sayısı
0.2	2	1.80	2.97	9	1161
	3	2.22	2.43	8	1032
	4	2.20	3.60	3	688
0.5	2	1.80	1.66	4	452
	3	2.10	3.80	4	475
	4	2.09	2.70	3	308

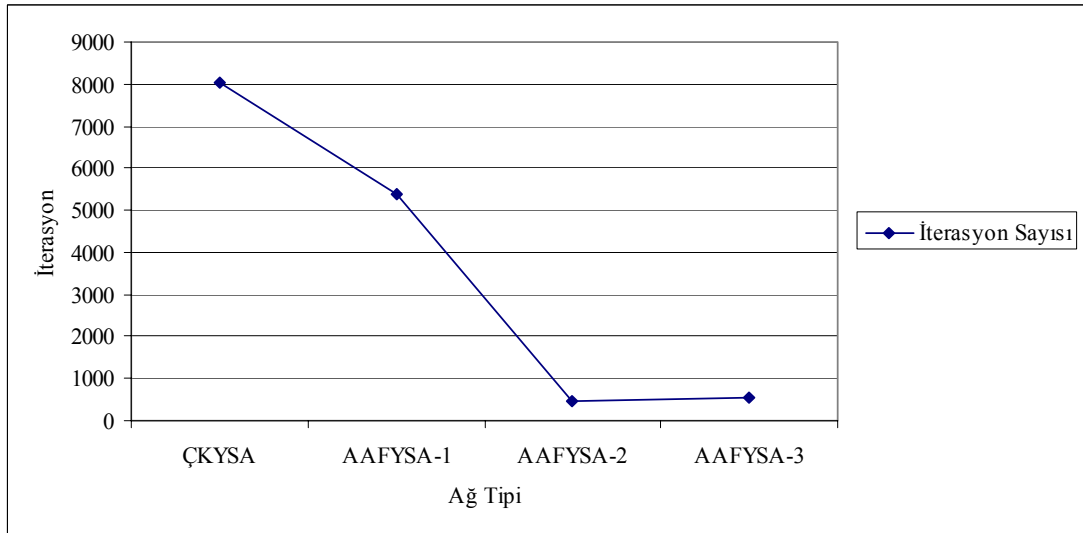
(d) AAFYSA-3 modeli

β	Gizli Düşüm	EH (%)	TH (%)	Zaman (s)	İterasyon Sayısı
0.2	2	2.20	2.24	27	3086
	3	2.20	2.24	60	6726
	4	2.20	3.64	12	3086
0.5	2	2.21	2.26	4	544
	3	2.20	2.40	22	2689
	4	2.20	2.26	8	920

Tablo 8.2'den de görülebileceği gibi, eğitim AAFYSA-2 ve AAFYSA-3 modellerinde diğer modellere göre çok daha kısa zamanda bitmektedir. Şekil 8.1'de gösterilen grafikler dört model ile yapılan XOR sınıflandırılmasında en iyi sonuçların elde edildiği değerler için çizilmiştir. Şekil 8.1.a eğitim ve test hatasının AAFYSA-2 modelinde en düşük olduğunu göstermiştir. Şekil 8.1.b ise iterasyon sayısı bakımından AAFYSA-2 ve AAFYSA-3'ün daha başarılı olduğu görülmüştür. Ayrıca, bu grafiklerde de görüldüğü gibi bütün sınıflandırıcılar için de birbirine yakın eğitim ve test hatası elde edilmesine rağmen eğitim iterasyon sayısı açısından ÇKYSA ve AAFYSA-1 çok büyük değerleri göstermektedir



(a)



(b)

Şekil 8.1. XOR verisi için 2 gizli düğüm ve 0.5 öğrenme oranı için eğitime ve test sonuçlarına göre eğitime hatası ve iterasyon sayısının karşılaştırılması

8.3. EKG Verilerinin AAFYSA ile Sınıflandırılması

8.3.1. EKG verisinin özellikleri

Kalpte meydana gelen elektriksel aktivitenin kaydedilmesine elektrokardiyografi, elde edilen traseye de elektrokardiyogram (EKG) denir. Teşhis için standart bir yöntem olan EKG, insan vücuduna cerrahi bir müdahale olmadan (noninvasive) takılan elektrotlar ve EKG cihazı ile kayıt edilir. EKG sinyallerinde çok miktarda veri olduğu için sınıflandırılırken parametrelerin ve ölçüm noktalarının hesaplanması, doktorların işini zorlaştırmaktadır. Bu nedenle EKG sinyallerinin bilgisayar kullanılarak otomatik olarak sınıflandırılması önemlidir (Acharya ve ark. 2002, Osowski ve Linh 2001).

Bu çalışmada kullanılan EKG sinyalleri, Dr. Yüksel ÖZBAY'ın "EKG Aritmilerini Hızlı Tanıma" adlı doktora çalışmasında kullanmış olduğu verilerden seçilmiştir (Özbay 1999). Bu EKG verileri iki gruptan oluşmaktadır. Birinci grup veriler, MIT-BIH ECG Arrhythmia Database'den alınmış on farklı hastalık sınıfını içermektedir. Bu hastalık sınıfları, normal sinüs ritmi (N), sinüs bradikardisi (Br), ventriküler taşikardi (VT), sinüs aritmisi (SA), atrial prematüre kasılması (APC), yapay vuru (P), sağ dal bloku (R), sol dal bloku (L), atrial fibrilasyon (Afib) ve atrial flutter (AFlt) şeklindedir. İkinci grup veriler ise, yine Dr. Yüksel ÖZBAY'ın Selçuk Üniversitesi Tıp Fakültesi Kardiyoloji A.B.D. Kliniği'nde hastalardan yaptığı EKG kayıtlarından seçilmiştir (Özbay 1999).

Uygulamalarda, eğitime için oluşturulan veri seti, MIT-BIH ECG Arrhythmia Database'den alınmış ve yukarıda bahsedilen 10 farklı aritmiden meydana gelmektedir. Eğitime veri setinde, 106 segment EKG sinyali bulunmaktadır. Bu 106 segment verinin hastalıklara göre dağılımı Tablo 8.3 ile verilmiştir.

8.3.2. EKG verilerinin AAFYSA ile sınıflandırılması ile elde edilen sonuçlar

Tablo 8.3 ile tanımlanan 106 segmentten oluşan eğitime setinin her bir segmentinde 200 örnek vardır. Bu nedenle, EKG verisinin eğitimi ve testi için

kullanılan bütün ağ mimarilerinde giriş düğüm sayısı 200 ve çıkış katmanındaki düğüm sayısı ise 10 farklı sınıfı temsil etmek için 10 olarak tanımlanmıştır. Bu mimari göz önüne alınarak, Bölüm 2’de anlatılan ÇKYSA modeli ve Bölüm 3’de teorisi anlatılan ve Bölüm 6’da algoritması ve yazılımı geliştirilen AAFYSA modellerinden ikisi (AAFYSA-1 ve AAFYSA-2) için EKG sinyalleri ile eğitime yapılmıştır.

Tablo 8.3: EKG Eğitim seti sınıfları ve segment sayıları

<i>Hastalık Sınıfı</i>	<i>Kısaltması</i>	<i>Segment sayısı</i>
Normal Sinüs Ritmi	N	15
Sinüs Bradikardisi	Br,	15
Ventriküler Taşikardi	VT	6
Sinüs Aritmisi	SA	15
Atrial Prematüre Kasılması	APC	6
Yapay Vuru	P	10
Sağ Dal Bloku	R	10
Sol Dal Bloku	L	10
Atrial Fibrilasyon	Afib	10
Atrial Flutter	AFlt	9
<i>TOPLAM</i>		<i>106</i>

Eğitime işlemi için farklı gizli katman düğümleri ve farklı öğrenme oranları için denemeler yapılmış ve eğitime sonuçları Tablo 8.5’te verilmiştir. Eğitime için tanımlanan maksimum iterasyon sayısı 5000 ve minimum hata kriteri 0.01 olarak tanımlanmıştır. Test başarısını ölçmek için, öncelikle eğitime işlemi tamamlamış olan, ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerine 15 segmentlik normal sinüs ritmi verisi sunulmuş ve test edilmiştir. Eğitimi yapılan bütün modeller normal sinüs ritmi ile test edildiği zaman %100 başarı elde edilmiştir.

İkinci olarak, test işlemi için 61 segmentten oluşan ve bir hastadan kayıt edilen Tablo 8.4’deki 10 nolu hastaya ait veri seti kullanılmıştır. Tablo 8.5, ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin eğitimi için farklı öğrenme oranları ve farklı gizli düğüm sayılarıyla yapılan denemeleri göstermektedir. Bu tabloda 106 segmentten oluşan eğitime veri seti ile yapılan eğitime sonuçları ve 61 segmentten oluşan test verisi ile yapılan test sonuçlarını göstermektedir. Bu tabloda verilen bütün mimarilerde, normal sinüs ritmi ile test edildiği zaman %100 başarı elde edildiği için Tablo 8.5’te gösterilmemiştir.

EKG ile ilgili tablolarda yer alan, K1, normal sinüs ritmi (N), K2 sinüs bradikardisi (Br), K3 ventriküler taşikardi (VT), K4 sinüs aritmisi (SA), K5 atrial prematüre kasılması (APC), K6 yapay vuru (P), K7 sağ dal bloku (R), K8 sol dal bloku (L), K9 atrial fibrilasyon (Afib) ve K10 atrial flutter (AFIt), K11 ise YSA tarafından sınıflanamayan segmentleri göstermektedir.

Tablo 8.5.a'da ÇKYSA'nın eğitime sonuçlarını ve 61 setlik test verisinden elde edilen test sonuçlarını ifade etmektedir. ÇKYSA modeli için 0.8 öğrenme oranı (β), 30 gizli düğüm için, % 0.2 eğitime hatası ve % 2.57 test hatası elde edilmiştir. Bu durumda sınıflandırılmayan veri sayısı 58 segmenttir.

Tablo 8.5.b'de AAFYSA-1 modelinin EKG verilerini, eğitime ve test sonuçları verilmiştir. Bu modelde de test işlemi için 61 segmentlik veri seti kullanılmıştır. AAFYSA-1 ile elde edilen en iyi sonuçlar, 0.7 öğrenme oranı, 17 gizli düğüm için, % 0.10 eğitime hatasına ve %2.04 test hatasına ulaşılmıştır. Sınıflandırılmayan segment sayısı 57 olarak tespit edilmiştir.

Tablo 8.5.c'de ise AAFYSA-2 modelinin EKG verilerini, sınıflandırma sonuçları eğitime ve test olarak ayrı ayrı verilmiştir. Bu modelde de test işlemi için 61 segmentlik veri seti kullanılmıştır. AAFYSA-2 için elde edilen en iyi eğitime ve test hatası değerleri sırasıyla %0.08 ve %1.48 şeklindedir. Bu sonuçlar 0.7 öğrenme oranı ve 17 gizli düğüm için elde edilmiştir. Ayrıca bu mimari için sınıflandırılmayan tset segment sayısı 11 tanedir.

Tablo 8.5'de verilen tablolar karşılaştırıldığı zaman, en küçük test hatasının 0.7 öğrenme oranı (β) için AAFYSA-2 modeliyle elde edildiği ve aynı zamanda en iyi eğitime ve test performansının elde edildiği mimaride kullanılan gizli düğüm sayısının 17 olduğu görülmüştür. Buna göre denilebilir ki en iyi sonuç, AAFYSA-2 modeli için 200x17x10 mimarisi ile elde edilmiştir. Aynı zamanda sınıflandırılmayan segment sayısının en az olduğu mimari de AAFYSA-2'dir.

Tablo 8.5 ile verilen sonuçlara göre ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin en iyi sonuçları karşılaştırıldığı zaman, eğitime ve test hatası bakımından, AAFYSA-2 modeli daha başarılıdır. Üstelik AAFYSA modeli geleneksel ÇKYSA modelinden gizli katmanda kullanılan nöron sayısı bakımından daha avantajlıdır. Bunun anlamı AAFYSA kullanılarak daha iyi başarı, daha az karmaşık bir mimari ile sağlanabilmiştir.

AAFYSA-2 için elde edilen en iyi eğitim sonuçlarına göre 10 farklı kişiden alınmış EEG veri setleri ile test işlemi yapılmıştır. Tablo 8.4 ile verilen, bu 10 farklı veri grubu ile yapılan test işlemlerinde, hedef dosya tanımlanmamıştır. Bu nedenle, her veri grubu için test hatası, daha önce Bölüm 8.1.1'de verilen, Denk.(8.2-8.4)'e göre hesaplanmıştır. Elde edilen test hatalarının değeri ve segmentlerin hangi hastalık grubuna ait oldukları Tablo 8.6 ile verilmiştir. Tablo 8.6'da aynı zamanda bütün veri grupları için elde edilen test hatalarının ortalaması hesaplanmış ve bu değer her tablonun son satırına eklenmiştir.

Tablo 8.6.a, 0.7 öğrenme oranı ve 17 gizli düğüm ile ÇKYSA modeli için toplamda 268 segment olan 10 sınıflı 10 farklı hastaya ait EKG veri setleriyle elde edilmiş test sonuçlarını göstermektedir. Tablo 8.6.a'da en düşük test hatası %0.12 ile 6.hastadan ve en yüksek test hatası %7.57 ile 1. hastadan elde edilmiştir. Bunun yanında sınıflandırılmayan segment sayısı 57 değeriyle 10. hastada en fazladır. ÇKYSA modeli için elde edilen ortalama test hatası %3.94 ve toplam sınıflandırılmayan segment sayısı 71'dir.

Tablo 8.6.b, 0.7 öğrenme oranı ve 17 gizli düğüm ile AAFYSA-1 modeli için toplamda 268 segment olan 10 sınıflı 10 farklı hastaya ait EKG veri setleriyle elde edilmiş test sonuçlarını göstermektedir. Bu tabloda en düşük test hatası, %0.12 ve en yüksek test hatası %7.57'dir. Sınıflandırılmayan segment sayısı yine 57 ile onuncu hasta için en fazladır. Ortalama test hatası %3.65 ve sınıflandırılmayan segment sayısı 114'tür.

Tablo 8.6.c, 0.7 öğrenme oranı ve 17 gizli düğüm ile AAFYSA-2 modeli için toplamda 268 segment olan 10 sınıflı 10 farklı hastaya ait EKG veri setleriyle elde edilmiş test sonuçlarını göstermektedir. AAFYSA-2 için test sonuçlarının verildiği bu tabloda, en küçük ve en yüksek test hataları sırasıyla, %0.11 ve %4.87'dir. Sınıflandırılmayan segment sayısının en fazla olduğu hasta yine 10. hasta ve segment sayısı 11'dir. AAFYSA-2 için ortalama test hatası 1.97'dir.

Bu tablolardan da görülebileceği, gibi elde edilen ortalama test hatasının ve sınıflandırılmayan segment sayısının en küçük olduğu model AAFYSA-2'dir. Bu durumda test hatası ve EKG verilerinin sınıflarının tanınması bakımından da en başarılı model olarak AAFYSA-2 modeli gösterilebilir.

Tablo 8.6. ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin 10 hastadan alınan verilerle yapılan test sonuçları (a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için

(a) ÇKYSA modeli test sonuçları

Hasta No	Örnek Sayısı	Segment Sayısı	K1 N	K2 Br	K3 T	K4 S	K5 Apc	K6 P	K7 R	K8 L	K9 Afib	K10 Aflt	K11 ?	Hata %
1	3000	15	0	0	0	0	0	0	15	0	0	0	0	7.57
2	2400	12	0	0	0	0	0	0	12	0	0	0	0	7.29
3	6000	30	0	0	0	0	0	0	30	0	0	0	0	7.22
4	3400	17	0	16	0	0	0	0	0	0	0	0	1	3.72
5	4400	22	0	21	0	0	0	0	0	0	0	0	1	1.38
6	3000	15	15	0	0	0	0	0	0	0	0	0	0	0.12
7	6200	31	27	0	0	2	0	0	0	0	2	0	1	0.54
8	7000	35	0	0	0	35	0	0	0	0	0	0	10	6
9	6000	30	29	0	0	0	0	0	0	0	0	0	1	0.57
10	12100	61	1	0	0	0	0	0	0	0	3	0	57	5
Toplam	53600	268	72	37	0	37	0	0	57	0	5	0	71	3.94

(b) AAFYSA-1 modeli test sonuçları

Hasta No	Örnek Sayısı	Segment Sayısı	K1 N	K2 Br	K3 T	K4 S	K5 Apc	K6 P	K7 R	K8 L	K9 Afib	K10 Aflt	K11 ?	Hata %
1	3000	15	0	0	0	0	0	0	5	0	0	0	10	7.57
2	2400	12	0	0	0	0	0	0	6	0	0	0	6	7.29
3	6000	30	0	0	2	0	0	0	16	0	0	0	12	7.22
4	3400	17	0	7	0	0	0	0	0	0	0	0	3	3.72
5	4400	22	0	8	0	0	0	0	0	0	0	0	14	1.38
6	3000	15	15	0	0	0	0	0	0	0	0	0	0	0.12
7	6200	31	27	0	0	0	2	0	0	0	2	0	1	0.54
8	7000	35	0	0	0	15	0	0	0	0	0	0	10	6
9	6000	30	29	0	0	0	0	0	0	0	0	0	1	0.57
10	12100	61	1	0	0	0	0	0	0	0	3	0	57	2.04
Toplam	53600	268	72	15	2	15	2	0	27	0	5	0	114	3.65

(c) AAFYSA-2 modeli test sonuçları

Hasta No	Örnek Sayısı	Segment Sayısı	K1 N	K2 Br	K3 T	K4 S	K5 Apc	K6 P	K7 R	K8 L	K9 Afib	K10 Aflt	K11 ?	Hata %
1	3000	15	0	0	0	0	0	0	15	0	0	0	0	2.34
2	2400	12	0	0	0	0	0	0	12	0	0	0	0	2.17
3	6000	30	0	0	0	0	0	0	30	0	0	0	0	2.17
4	3400	17	0	14	0	0	0	0	0	0	0	0	3	2.76
5	4400	22	0	20	0	0	0	0	0	0	1	0	1	2.45
6	3000	15	15	0	0	0	0	0	0	0	0	0	0	0.11
7	6200	31	27	0	0	2	0	0	0	0	1	0	1	0.65
8	7000	35	1	0	0	0	0	0	0	0	34	0	0	4.87
9	6000	30	29	0	0	0	0	0	0	0	0	0	1	0.71
10	12100	61	0	0	0	0	0	0	0	0	50	0	11	1.48
Toplam	53600	268	72	34	0	2	0	0	57	0	86	0	17	1.97

Özbyay ve ark. 'nın (2006) yaptıkları çalışmada, bu tez çalışmasında kullanılan 106 segment 10 sınıf EKG eğitme veri seti kullanılarak, Matlab programlama dili hazır komutları ile yazılımı gerçekleştirilmiş geleneksel ÇKYSA ile sınıflandırma yapmışlardır. 10000 iterasyon için yapılan eğitme yapıldıktan sonra sınıflandırma başarısı olarak, 48 gizli nöron sayısı ile %0.28 eğitme hatası elde etmişlerdir.

Bu tez çalışmasında ise, aynı EKG eğitme verisi kullanılarak 5000 iterasyonda eğitilen AAFYSA-2 modeli ile 17 gizli nöron için %0.08 eğitme hatası elde edilmiştir. Elde edilen bu sonuca göre AAFYSA-2 modeli kullanılarak, daha az gizli düğüm sayısı ile yani daha az karmaşık YSA mimarisi ile daha az eğitme başarısına ulaşılabilmektedir.

8.3. İki Sınıf EEG Verilerinin AAFYSA ile Sınıflandırılması

EEG sinyalleri deterministik sinyaller değildir ve EKG gibi özel formları yoktur. Bu nedenle, EEG sinyallerinin analizinde, istatistik ve parametrik analiz yöntemleri kullanılmaktadır. Bu tez çalışmasında, EEG sinyallerinden özellik çıkartıldıktan sonra geliştirilen ÇKYSA ve AAFYSA modelleri ile sınıflandırma yapılmıştır.

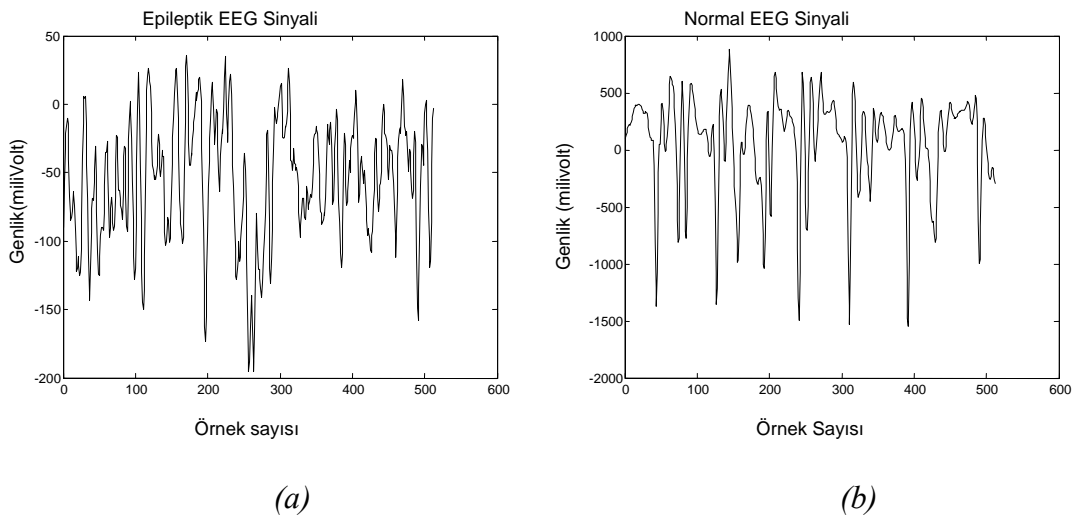
8.4.1. Verinin yapısı ve özellikleri

Bu tez çalışmasında, Andrzejak ve ark. (2001) tarafından tanımlanan genel kullanıma açık EEG verisi ile uygulamalar yapılmıştır. Bu bölümde, verilerle ilgili olarak bir tanımlama yapılmıştır. Daha fazla bilgi için Andrzejak ve ark.(2001) referans gösterilebilir. Veri setinin tamamı, her biri 100 tek kanal EEG segmentinden oluşan ve A-E ile ifade edilen 5 setten oluşmaktadır. Bu segmentler, artefaktların görsel olarak tespit edilmesinden sonra, çok kanallı sürekli EEG kayıtlarından seçilmiştir. Set A ve Set B, 5 sağlıklı gönüllüden sırasıyla gözler açık ve kapalı iken yapılmış yüzey elektrotlu EEG kayıtlarından alınan segmentlerden oluşmuştur. Set C beynin hemisferindeki hipokampal oluşumdan ve D setindeki segmentler,

epileptojenik bölgeden ve kayıt edilmişlerdir. Set C ve Set D, atak olmayan aralıktan ölçülen aktiviteleri içerirken, set E sadece epileptik atakların bulunduğu aktiviteleri kapsamaktadır. Bütün EEG kayıtları, aynı 128-kanal yükselteç sistemi ile ortak toprak referans kullanarak kaydedilmiş ve veri 173.61 saniyedeki örnek sayısı ile 12 bit çözünürlükte sayısallaştırılmıştır Andrzejak ve ark. (2001). Band geçiren filtre 0.53-40 Hz olarak ayarlanmıştır.

Bu çalışmada, A ve E olmak üzere iki veri seti kullanılmıştır. A veri seti normal kişiden gözler açık iken E veri seti ise epileptik atakların olduğu bölgeden seçilmiştir. Şekil 8.2’de A setine ait normal ve E setine ait epileptik EEG sinyalleri gösterilmiştir.

Bu çalışmada yapılan uygulamanın amacı, sınıflandırıcının girişine uygulanan A ve E veri setlerinin iki sınıftan (normal veya epileptik) hangisine ait olduğunu doğru olarak tanımlayabilmektir. Bu amaçla da eğitime ve test matrislerinin seçimi önemlidir. Veriyi sınıflandırıcıya vermeden önce her iki sınıfa ait (epileptik ve normal) EEG verilerini segmentlere ayırabilmek için önce iki sınıfa ait tek boyutlu dizi şeklindeki veri, 512 örnekli, rectangular (dikdörtgen) pencereleme yöntemi kullanılarak segmentlere bölünmüştür. Böylece her iki sınıf içinde ayrı ayrı her bir segmentte 512 örnek olan toplam 800 segment elde edilmiştir. AAFYSA modelinin başarısını ölçebilmek için, her iki sınıfı içeren toplam 1600 segmentten rastgele seçilen 1000 segment eğitime verisi olarak geriye kalan 600 segment ise test verisi olarak kullanılmıştır.



Şekil 8.2. Epileptik ve Normal EEG sinyalleri (a)Epileptik EEG sinyali (b) Normal EEG sinyali

8.4.2. İstatistiksel özellikleri çıkartılmış EEG sinyallerinin AAFYSA ile sınıflandırılması

Desen sınıflandırma problemlerinde, YSA'nın tasarımını yaparken giriş vektörünün seçimi, önemli bir konudur. Kötü seçilmiş girişler kullanıldığı zaman en iyi sınıflandırıcı bile iyi performans göstermeyebilir. Sınıflandırılacak veriyi en iyi temsil edecek şekilde YSA'nın giriş vektörlerinin seçimi yapılmalıdır (Güler ve Übeyli 2005). Bu çalışmada EEG sinyalinin aşağıda tanımlanan istatistiksel özellikleri çıkarılarak AAFYSA modelinin giriş vektörü oluşturulmuştur. Daha sonra elde edilen yeni özellik matrisinin değerlerine [0 1] aralığında normalizasyon işlemi uygulanmıştır. EEG segmentlerinden çıkartılan özellikler;

- Her segmentin minimum değeri,
- Her segmentin maksimum değeri,
- Her segmentin ortalama değeri,
- Her segmentin standart sapma değeri

Bu özellik çıkarma yöntemi ile her bir segmentte bulunan örnek sayısı 512 örnekten 4 örneğe düşürülmüştür. Böylece sınıflandırıcı olarak kullanılacak ağların giriş nöron sayısı azaltılmış olmaktadır. Bu çalışma için kullanılan ÇKYSA ve AAFYSA modellerinin mimarisi, tek gizli katmanlı olarak kurulmuştur. Bu mimarilerin giriş katmanında 4 nöron ve iki sınıf veri kullanıldığı için çıkış katmanında tek çıkış nöronu vardır. Eğer çıkış nöronunda ağın ürettiği değer "1" ise giriş segmenti, epileptik veri olarak sınıflandırılmıştır. Aksi halde giriş segmenti normal olarak tanımlanmıştır.

ÇKYSA ve AAFYSA modellerinin tamamı için istatistiksel özellikleri çıkartılmış EEG verileri ile farklı gizli düğüm sayıları ve öğrenme oranları (β) için yapılan eğitime ve test denemeleri sonucunda elde edilen değerler Tablo 8.7 ile verilmiştir.

Tablo 8.7.a'da istatistiksel özellikleri çıkartılan EEG verilerinin ÇKYSA ile sınıflandırılma sonuçları gösterilmiştir. Bu tabloya göre en iyi sonuç, 0.4 öğrenme oranı, 2 gizli düğüm ve 5000 iterasyon için, 464 saniyede eğitime hatası %0.02 ve test hatası %0.1 olarak bulunmuştur.

Tablo 8.7: İstatistik özellikleri çıkartılmış iki sınıf EEG verisi için Eğitim ve Test sonuçları(a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için

(a) ÇKYSA Modeli

β	Gizli Düğüm	EH %	TH %	Zaman (s)	İterasyon Sayısı
0.2	2	0.06	0.07	467	5000
	4	0.06	0.06	642	5000
	6	0.06	0.07	818	5000
0.3	2	0.04	0.09	468	5000
	4	0.03	0.08	636	5000
	6	0.03	0.08	812	5000
0.4	2	0.02	0.10	464	5000
	4	0.02	0.10	639	5000
	6	0.10	0.02	814	5000

(b) AAFYSA-1 Modeli

β	Gizli Düğüm	EH %	TH %	Zaman (s)	İterasyon Sayısı
0.2	2	0.06	0.07	721	5000
	4	0.06	0.06	1086	5000
	6	0.06	0.07	1511	5000
0.3	2	0.03	0.09	721	5000
	4	0.03	0.08	1095	5000
	6	0.03	0.08	1451	5000
0.4	2	0.02	0.10	721	5000
	4	0.02	0.09	1100	5000
	6	0.02	0.10	1458	5000

(c) AAFYSA-2

β	Gizli Düğüm	EH %	TH %	Zaman (s)	İterasyon Sayısı
0.2	2	0.06	0.06	465	5000
	4	0.06	0.06	635	5000
	6	0.05	0.20	1601	5000
0.3	2	0.07	0.14	426	2775
	4	0.09	0.08	1176	5000
	6	0.04	0.07	868	2721
0.4	2	0.08	0.11	394	2559
	4	0.06	0.09	1188	5000
	6	0.05	0.12	785	2463

(d) AAFYSA-3 Modeli

β	Gizli Düğüm	EH %	TH %	Zaman (s)	İterasyon Sayısı
0.2	2	0.08	0.26	543	3688
	4	0.07	0.19	1124	5000
	6	0.08	0.08	524	1735
0.3	2	0.08	0.24	396	2683
	4	0.07	0.13	628	2794
	6	0.06	0.07	583	1921
0.4	2	0.08	0.29	788	2147
	4	0.09	0.11	1277	2298
	6	0.08	0.08	1301	1735

Tablo 8.7.b'de istatistiksel özellikleri çıkartılan EEG verilerinin AAFYSA-1 ile sınıflandırılma sonuçları gösterilmiştir. Bu model için de 0.4 öğrenme oranı, 2 gizli düğüm ve 5000 iterasyon için 721 saniyede eğitim hatası %0.02 ve test hatası %0.10 olarak bulunmuştur.

Tablo 8.7.c'de istatistiksel özellikleri çıkartılan EEG verilerinin AAFYSA-2 ile yapılmış sınıflandırma sonuçları gösterilmiştir. 0.3 öğrenme oranı, 6 gizli düğüm, 2721 iterasyon ve 868 saniye için %0.04 eğitim hatası ve % 0.07 test hatasına ulaşılmıştır.

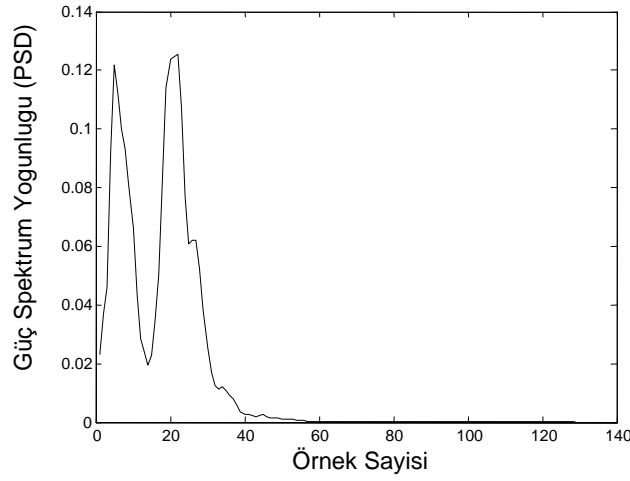
Tablo 8.7.d'de istatistiksel özellikleri çıkartılan EEG verilerinin AAFYSA-3 ile yapılmış sınıflandırma sonuçları gösterilmiştir. 0.3 öğrenme oranı, 6 gizli düğüm, 1921 iterasyon ve 583 saniyede %0.06 eğitim hatası ve %0.07 test hatası elde

edilmiştir. Tablo 8.7’ de görülebileceği gibi en küçük eğitime hatası, %0.02 ile ÇKYSA modelinde 5000 iterasyon sayısı için elde edilmiştir. Bunun yanında, eğitime işlemi, AAFYSA-3 modelinde, maksimum iterasyon sayısı olan 5000 değerine ulaşmadan, minimum hata kriteri olan 0.01 değerine ulaşarak tamamlanmaktadır. Fakat AAFYSA-2 ve AAFYSA-3 modellerinde minimum hata kriterine ulaşılardan iterasyon sayısından dolayı eğitime tamamlanmıştır. Sonuç olarak, bütün modeller için elde edilen yaklaşık %99.9 eğitime ve test başarısına rağmen adaptif modellerde iterasyon sayısı azalmaktadır. ÇKYSA’da 5000 iterasyonda iken AAFYSA-3 ‘de 1921 ve AAFYSA-2’de 2721 iterasyonda eğitime tamamlanmıştır (Tezel ve Özbay 2007).


8.4.3. Welch metodu ile özelliği çıkartılmış EEG sinyallerinin AAFYSA modelleri ile sınıflandırılması

Bölüm 5’de bahsedildiği gibi, bir sinyalin güç spektrumunu (güç spektrum yoğunluğu) bulmak için kullanılan bir yöntemdir. Welch metodu ile güç spektrumu hesaplanırken, belirlenmiş bir pencereleme yöntemi ile segmentlere ayrılarak her bir segmentin güç spektrumu hesaplanır ve daha sonra elde edilen spektrumların ortlaması alınır.

Bu tez çalışmasında, iki sınıf EEG verisine Welch metodu uygulanırken öncelikle 512 örnekli Hamming penceresi her bir EEG segmentine uygulanmıştır. Daha sonra pencerelenmiş segmentlere, %50 üstüste binme (overlapped) özelliği ve 128’lik pencerelerle Welch yöntemi uygulanarak güç spektrum yoğunluğu (PSD) hesaplanmıştır. Böylece ağın özellik matrisindeki her bir segmentin örnek sayısı, 512 örnekten 129 örneğe azaltılmış olmaktadır. Daha sonra ağın performansını arttırmak için [0,1] normalizasyon işlemi yapılmıştır. Şekil 8.2 ile ifade edilen normal ve epileptik kişilere ait EEG sinyallerine, pencereleme işleminden sonra Welch metodu uygulanarak elde edilen güç spektrum yoğunluğu Şekil 8.3 ile ifade edilmiştir. Şekil 8.3’de görüldüğü gibi, güç spektrum yoğunluğunun maksimum değerleri normal denekte daha yüksektir.



(a)



(b)

Şekil 8.3. (a) Normal EEG sinyalinin ve (b) Epileptik EEG sinyalinin Welch Metodu uygulanarak elde edilmiş Güç Spektrum Yoğunluğu (PSD)

Tablo 8.8 farklı gizli nöron sayıları kullanılarak AAFYSA modelleri ve ÇKYSA modeli için elde edilen sonuçları göstermektedir. Bütün denemelerde öğrenme oranı (β) 0.9 olarak alınmıştır.

Tablo 8.8.a, Welch metodu kullanılarak özellik çıkartılmış EEG sinyallerinin ÇKYSA modeli kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir. ÇKYSA modeli için en iyi eğitime sonucu, 10 gizli düğüm, 7814 iterasyon ve 2467 saniyelik eğitim süresi için, %0.026 eğitime ve % 0.180 test hatası değeri elde edilmiştir

Tablo 8.8. Welch metodu ile özellik çıkartılmış EEG verileri kullanılarak elde edilen eğitime ve test sonuçları uygulanan (a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için

(a) CKYSA Modeli

β	Gizli Düşüm	Egt.Hatası (%)	TestHatası (%)	Zaman (s)	İterasyon Sayısı
0.9	5	0.039	0.219	1455	7788
	10	0.026	0.180	2467	7814
	12	0.027	0.185	2847	7761
	15	0.037	0.208	3302	7303
	20	0.026	0.180	4498	7880

(c) AAFYSA-1 Modeli

β	Gizli Düşüm	Egt.Hatası (%)	TestHatası (%)	Zaman (s)	İterasyon Sayısı
0.9	5	0.026	0.178	507	7810
	10	0.027	0.180	4490	7780
	12	0.028	0.187	8206	7815
	15	0.026	0.184	6521	7822
	20	0.026	0.139	8260	7695

(c) AAFYSA-2 Modeli

β	Gizli Düşüm	Egt.Hatası (%)	TestHatası (%)	Zaman (s)	İterasyon Sayısı
0.9	5	0.035	0.157	2458	7060
	10	0.024	0.124	4495	7157
	12	0.022	0.110	5111	6959
	15	0.030	0.116	5540	6095
	20	0.026	0.139	8243	7038

(d) AAFYSA-3 Modeli

β	Gizli Düşüm	Egt.Hatası (%)	TestHatası (%)	Zaman (s)	İterasyon Sayısı
0.9	5	0.045	0.152	2211	6646
	10	0.055	0.500	4112	6898
	12	0.032	0.122	4100	5922
	15	0.046	0.150	5914	6908
	20	0.033	0.129	7422	6669

Tablo 8.8.b, Welch metodu kullanılarak özellik çıkartılmış EEG sinyallerinin AAFYSA-1 modeli kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir. AAFYSA-1 modeli için en iyi eğitime sonucu, 20 gizli düğüm, 7695 iterasyon ve 8260 saniyelik eğitim süresi için, %0.026 eğitime ve % 0.139 test hatası değeri elde edilmiştir.

Tablo 8.8.c, Welch metodu kullanılarak özellik çıkartılmış EEG sinyallerinin AAFYSA-2 modeli kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir. AAFYSA-2 modeli için en iyi eğitime sonucu, 12 gizli düğüm, 6959 iterasyon ve 5111 saniyelik eğitim süresi için, %0.022 eğitime ve % 0.110 test hatası değeri elde edilmiştir.

Tablo 8.8.d, Welch metodu kullanılarak özellik çıkartılmış EEG sinyallerinin AAFYSA-3 modeli kullanılarak elde edilen sınıflandırma sonuçlarını göstermektedir. AAFYSA-3 modeli için en iyi eğitime sonucu, 12 gizli düğüm, 5922 iterasyon ve 4100 saniyelik eğitim süresi için, %0.032 eğitime ve % 0.122 test hatası değeri elde edilmiştir.

Bütün modeller için en iyi sonuçların elde edildiği mimariler dikkate alındığı zaman, en iyi eğitime ve test hatasının elde edildiği model AAFYSA-2'dir. Bunun yanında ÇKYSA modeli ile AAFYSA-3 modeli karşılaştırıldığı zaman, AAFYSA-3'ün test hatası daha düşüktür ve aynı zamanda daha az sayıda iterasyonda eğitime tamamlanmıştır. Ayrıca ÇKYSA modeli için 10 gizli düğüm ve 20 gizli düğüm için aynı eğitime ve test hatası elde edilmiştir. Bütün düümler için en başarılı test hataları ile AAFYSA-2 modeli ile sağlanmıştır.

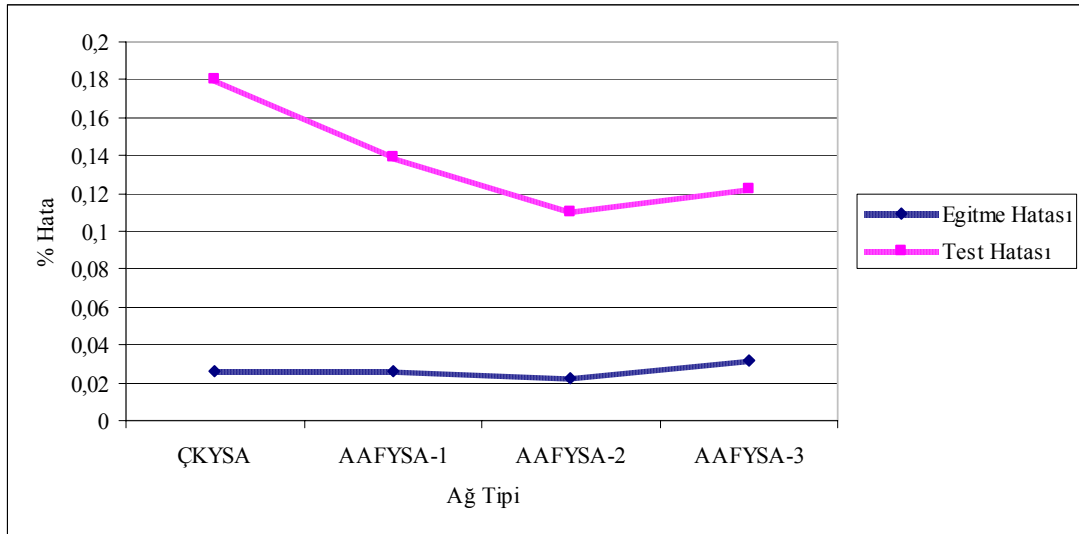
Şekil 8.4, dört YSA modeli için en iyi sonuçların elde edildiği mimarilerde, eğitime ve test hatasının ağa göre değişimini göstermektedir. Bu mimariler ÇKYSA'da 129x10x1, AAFYSA-1'de 129x20x1, AAFYSA-2'de 129x12x1 ve AAFYSA-3'de 129x12x1'dir. Şekil 8.4, bu mimariler için her modelin elde edilen eğitime ve test hatası sonuçlarını göstermektedir. Şekilden de görülebileceği gibi, en küçük test ve eğitime hataları AAFYSA-2 modeliyle elde edilmiştir.

Ayrıca, geleneksel ÇKYSA modeli ile tasarımı yapılan AAFYSA modellerinin eğitime ve test başarıları karşılaştırıldığı zaman bütün modeller için yaklaşık olarak % 99.9'luk değere ulaşılmıştır. Test hatası bakımından ÇKYSA ile


elde edilen en iyi başarı değeri, AAFYSA modelleriyle elde edilen sonuçlardan daha kötüdür.

Şekil 8.5 ile gösterilen grafik ise, dört YSA modeli için en iyi sonuçların elde edildiği mimarilerde, eğitime süreleri ve iterasyon sayıları karşılaştırılmıştır. İterasyon sayısı ve eğitime süresi bakımından en iyi model AAFYSA-3 modelidir. Bunun yanında bütün modeller için Welch metodu uygulanarak işlenmiş EEG verilerinin sınıflandırılmasında % 99.9 eğitime ve en az %99.8 test başarısına ulaşılmıştır.

Sonuç olarak bu uygulamada, AAFYSA-3 mimarisi eğitime süresi ve test süresi bakımından ÇKYSA algoritmasına göre daha iyi performans göstermiştir. Bunun yanında, AAFYSA-2 algoritması ise eğitime ve test başarısı yönünden daha iyi durumdadır. Ayrıca ağ mimarisinin karmaşıklığına göre karşılaştırma yapıldığı zaman adaptif yapı ile daha az sayıda gizli nöron kullanılarak daha iyi başarı sağlanabildiği söylenebilir.



Şekil 8.4. Geleneksel ÇKYSA modeli ile AAFYSA modellerinin Eğitime ve Test hatalarının karşılaştırılması



Şekil 8.5. Geleneksel ÇKYSA modeli ile AAFYSA modellerinin Eğitime zamanlarının ve iterasyon sayılarının karşılaştırılması

8.4.4. Dalgacık dönüşümü uygulanmış EEG verilerinin AAFYSA ile sınıflandırılması

EEG sinyallerinin tanımsız bir sinyal olması kolaylıkla sınıflandırılabilmesini engellemektedir. Bu nedenle sinyalin frekans bileşenleri elde edilerek daha kolay sınıflandırılabilmesi sağlanabilmektedir. Ayrıca dalgacık dönüşümü, Bölüm 5.3.2’de de anlatıldığı gibi pek çok mühendislik ve bilimsel uygulamada sinyal işleme amacıyla kullanılan bir yöntemdir. Dalgacık dönüşümünün farklı frekans bantlarında ve farklı çözünürlüklerdeki sinyalleri analiz edebiliyor olmasından dolayı EEG sinyallerinin işlenmesinde sıklıkla tercih edilen bir yöntem olmuştur (Kalaycı ve Özdamar 1995, Hazarika ve ark. 1997, Akın ve ark. 2001). Bu nedenle bu çalışmada sinyalin alçak frekans bileşenlerini ve yüksek frekans bileşenlerini filtreler kullanılarak elde edebilen dalgacık dönüşümü özellik çıkarma yöntemi olarak kullanılmıştır.

Dalgacık dönüşümünde bir sinyali analiz ederken, uygun dalgacığın ve ayrıştırma seviyesinin seçimi önemlidir. Ayrıştırma seviyesinin seçimi sinyalin dominant frekans bileşenine göre yapılmalıdır. Ayrıştırma seviyesi öyle seçilmelidir

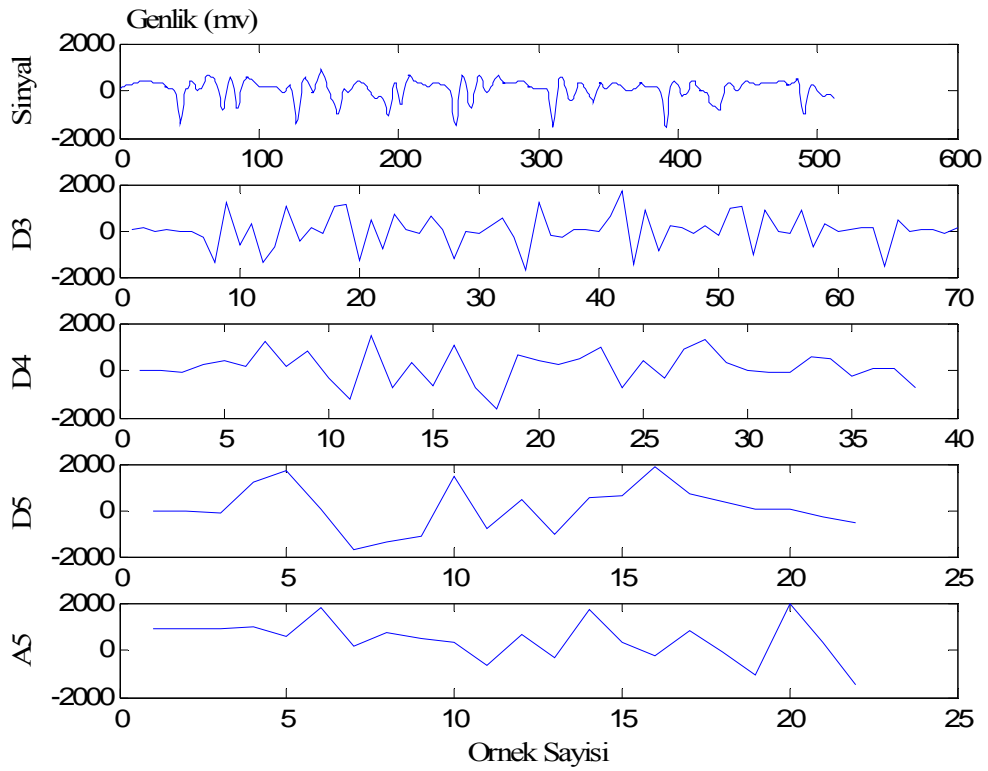
ki, sınıflandırma için kullanılacak dalgacık katsayılarında tutulan sinyal için gerekli olan frekanslarla en çok ilişkili ana sinyal bölümü ele alınabilsin (Subaşı 2006).

Bu çalışmada, EEG sinyalleri 30 Hz'in üstünde gerekli frekans bileşeni içermediği için, ayrıştırma seviyesi 5 olarak seçilmiştir. Böylece sinyal D1-D5 detay bileşenlerine ve A5 yaklaşım bileşenlerine ayrılmıştır. Dördüncü dereceden Daubechies dalgacığı (db4), EEG sinyallerindeki değişimler için daha uygun olduğu tespit edilmiş (Subaşı 2006) ve bu nedenle de bu çalışmada db4 dalgacık tipi uygulanmıştır. (Tablo 8.9). Buna göre db4 dalgacığı ile ayrıştırılan EEG sinyalinin alt bantlarda içerdiği frekans bileşenleri Tablo 8.9 ile verilmiştir (Subaşı 2006).


Bölüm 4.8.3'de de anlatıldığı gibi, EEG dalgalarının frekansı, delta, teta, alfa ve beta dalgaları olmak üzere dört gruba ya da frekans bandına ayrılmaktadır. Tablo 8.9'da görüldüğü gibi D3-D5 ve A5 bantları yaklaşık olarak EEG sinyallerinin bu dalga tiplerine karşı gelmektedir. Şekil 8.6, normal ve epileptik EEG sinyalleri için 5. dereceden db4 dalgacığı uygulandıktan sonra elde edilen D3-D5 ve A5 dalgacık katsayılarını ifade etmektedir.

Tablo 8.9. Örnekleme frekansı 173.6 olan EEG sinyali için db4 dalgacığının uygulanması sonucu farklı seviyelerdeki frekans bileşenleri

<i>Ayrıştırılmış Sinyal</i>	<i>Örnek sayısı</i>	<i>Frekans Aralığı (Hz)</i>	<i>Sinyalin Dalga Tipi</i>
D1	259	43.4-88.8	
D2	133	21.7-43.4	
D3	70	10.8-21.7	Delta
D4	38	5.4-10.8	Teta
D5	22	2.7-5.4	Alfa
A5	22	0-2.7	Beta



(a) Normal EEG sinyalinden elde edilen katsayılar



(b) Epileptik EEG sinyalinden elde edilen katsayılar

Şekil 8.6. db4 dalgacığı ile elde edilmiş D3-D5 ve A5 katsayıları

Tablo 8.9’de gösterildiği gibi, 5. dereceden db4 dalgacığı ile ayrıştırıldığı zaman başlangıçta 512 olan her segmentteki örnek sayısı, alt seviyelerde azalmaktadır. Buna göre D3-D5 ve A5 altbantları ÇKYSA ve AAFYSA ağlarının giriş vektörü olarak kullanılsaydı, giriş katmanı düğüm sayıları (70+38+22+22) toplamı olan 152 olması gerekirdi. Bu nedenle, db4 dalgacığı ile dalgacık dönüşümü uygulanarak elde edilen, D3-D5 ve A5 dalgacık katsayılarından, YSA algoritmalarının giriş vektörünün boyutunu azaltabilmek için istatistiki yöntemler kullanılarak yeni bir özellik vektörünün çıkarılması düşünülmüştür. Bu çalışmada, EEG sinyallerinin zaman frekans dağılımını temsil etmek üzere, D3-D5 ve A5 dalgacık katsayılarından aşağıda verilen özellikler elde edilmiştir.

- i. Her alt banttaki katsayıların mutlak değerlerinin ortalaması.
- ii. Her alt anttaki dalgacık katsayılarının ortalama gücü.
- iii. Her alt banttaki katsayıların standart sapma değeri.
- iv. Komşu alt bantların mutlak değerlerinin ortalamalarının oranı.

Elde edilen bu özelliklerden ilk ikisi sinyalin frekans dağılımını ve diğer ikisi ise frekans dağılımındaki değişimi ifade etmektedir. Bu şekilde veri matrislerinin her bir segmentindeki örnek sayısı 512 değerinden 15 değerine azaltılmış olmaktadır.

Elde edilen eğitime ve test özellik vektörleri, sınıflandırıcı olarak kullanılan ÇKYSA ve AAFYSA modellerine uygulanmıştır. Bu uygulamada en küçük hata kriteri 0.001 olarak eğitimden önce belirlenmiştir. Eğitim ve test sonucunda elde edilen değerler Tablo 8.10 ile gösterilmiştir.

Tablo 8.10.a, 5.dereceden db4 dalgacığı uygulanmış EEG sinyalinin ÇKYSA ağı ile sınıflandırma sonuçlarını göstermektedir. ÇKYSA’da elde edilen en iyi sonuç, 9 gizli düğüm, 2887 iterasyon ve 641 saniye için %0.028 eğitim hatası ve % 0.213 test hatası elde edilmiştir.

Tablo 8.10.b, 5.dereceden db4 dalgacığı uygulanmış EEG sinyalinin AAFYSA-1 ağı ile sınıflandırma sonuçlarını göstermektedir. AAFYSA-1 ile elde edilen en iyi sonuç, 9 gizli düğüm, 943 iterasyon ve 1221 saniye için %0.028 eğitim hatası ve % 0.210 test hatası elde edilmiştir.

Tablo 8.10.c, 5.dereceden db4 dalgacığı uygulanmış EEG sinyalinin AAFYSA-2 ağı ile sınıflandırılma sonuçlarını göstermektedir. AAFYSA-2 ile elde

edilen en iyi sonuç, 6 gizli düğüm, 2289 iterasyon ve 730 saniye için %0.039 eğitime hatası ve % 0.419 test hatası elde edilmiştir.

Tablo 8.10.d, 5.dereceden db4 dalgacığı uygulanmış EEG sinyalinin AAFYSA-3 ağı ile sınıflandırma sonuçlarını göstermektedir. AAFYSA-3'de elde edilen en iyi sonuç, 6 gizli düğüm, 983 iterasyon ve 302 saniye için %0.039 eğitime hatası ve % 0.277 test hatası elde edilmiştir.

Tablo 8.10'dan da görülebileceği gibi, bu çalışmada, kullanılan bütün YSA modelleri için belirlenen gizli nöron sayılarında, 0.5 öğrenme oranı için, %99.9 eğitime başarısına ulaşılmıştır. Eğitmenin ardından yapılan test sonucunda elde edilen değerlerinde ise bakıldığı zaman elde edilen en düşük test başarısı %99.45 ve yaklaşık olarak elde edilen en yüksek test başarısı %99.8'dir.

Şekil 8.7, Tablo 8.10'da verilen sonuçlara göre, çizilmiştir. Tablo 8.9.a, bütün modeller için gizli nöron sayısına göre zamanın değişimini ifade etmektedir. Bu şekilden görülebileceği gibi, %99.9 eğitime başarısı için AAFYSA-3 modeli, diğer modellere göre EEG sinyallerinin sınıflandırılabilmesi için, daha kısa sürede öğrenmiştir. Tablo 8.9.b ise bütün modeller için gizli nöron sayısına göre iterasyon sayısının değişimini göstermektedir. Bu şekilde de ÇKYSA ve AAFYSA-1 modellerinin eğitime iterasyon sayıları birbirine çok yakındır. Bunun yanında, en az iterasyon sayısında eğiten model AAFYSA-3 modelidir.

Bunun yanında belirlilik analizinde %100 başarı elde edilebilmesine rağmen hassasiyet analizinde %99.67 başarı elde edilmiştir. Bunun anlamı kullanılan algoritmalar, normal özellikli verinin tamamını tanıyabilmesine rağmen epileptik verilerden bir tanesini sınıflandıramamıştır.

Sonuç olarak Tablo 8.10'da ifade edilen bütün uygulamalar için başarı değerleri oldukça yüksektir. Eğitime ve test hatasına göre ve belirlilik ve hassasiyet analizinde yüksek başarı elde edildiği için karşılaştırma kriteri olarak eğitime için harcanan zaman ve iterasyon sayısı dikkate alınmıştır. Şekil 8.7'dan da görülebileceği gibi AAFYSA-3 modeli daha hızlı eğitmekte ve daha az iterasyon sayısında en küçük hata kriteri olana 0.01 değerine ulaşmaktadır.

Tablo 8.10. db4 dalgacığı uygulandıktan sonra özellik çıkartılmış normal ve epileptik EEG verisiyle elde edilen sınıflandırma sonuçlar (a) ÇKYSA modeli için (b)AAFYSA-1 modeli için (c) AAFYSA-2 modeli için AAFYSA-3 modeli için

(a) ÇKYSA için elde edilen sonuçlar

Gizli Düşüm	Egt.Hatası %	TestHatası %	Zaman (s)	İterasyon Sayısı	SEN %	SPE %
3	0.029	0.219	359	3182	99.67	100
6	0.028	0.218	487	2916	99.97	100
9	0.028	0.213	641	2887	99.67	100
12	0.028	0.214	800	2910	99.67	100
15	0.028	0.224	970	2920	99.67	100

(b) AAFYSA-1 için elde edilen sonuçlar

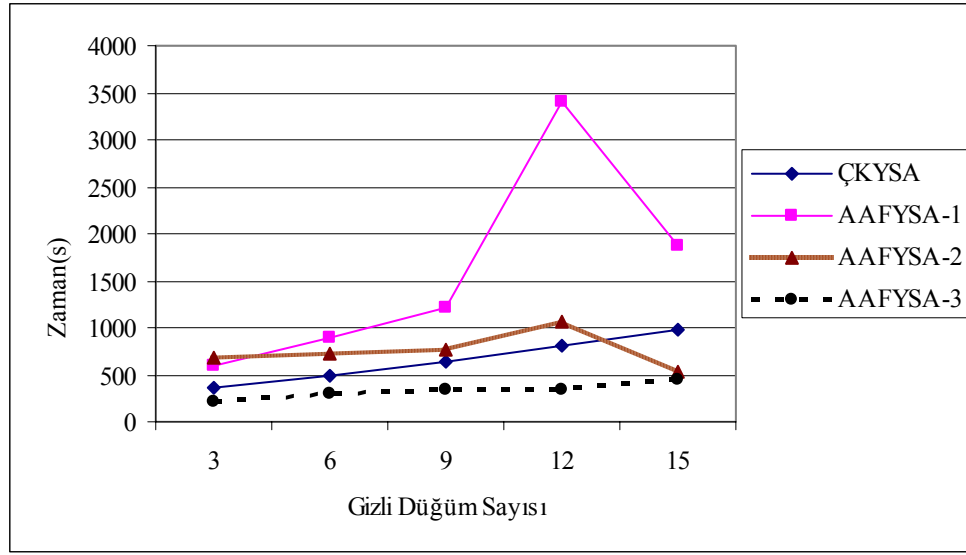
Gizli Düşüm	Egt.Hatası %	TestHatası %	Zaman (s)	İterasyon Sayısı	SEN %	SPE %
3	0.029	0.215	595	3217	99.67	100
6	0.029	0.215	897	2982	99.67	100
9	0.028	0.210	1220	2943	99.67	100
12	0.028	0.211	3413	2951	99.67	100
15	0.028	0.218	1875	2924	99.67	100

(c) AAFYSA-2 için elde edilen sonuçlar


Gizli Düşüm	Egt.Hatası %	TestHatası %	Zaman (s)	İterasyon Sayısı	SEN %	SPE %
3	0.060	0.443	687	3426	99.67	100
6	0.039	0.419	730	2289	99.67	100
9	0.051	0.426	768	1692	99.67	100
12	0.041	0.438	1064	1839	99.67	100
15	0.046	0.507	533	755	99	100

(d) AAFYSA-3 için elde edilen sonuçlar

Gizli Düşüm	Egt.Hatası %	TestHatası %	Zaman (s)	İterasyon Sayısı	SEN %	SPE %
3	0.057	0.395	220	1162	99.67	99.67
6	0.039	0.277	302	983	99.67	100
9	0.047	0.278	340	801	99.67	100
12	0.049	0.257	344	637	99.67	100
15	0.047	0.307	446	669	99.67	100



(a) ÇKYSA ve AAFYSA modelleri için eğitime için gerekli zamanın gizli nöron sayısına göre değişimi



(b) ÇKYSA ve AAFYSA modelleri için eğitime için gerekli iterasyon sayısının gizli nöron sayısına göre değişimi

Şekil 8.7. db4 dalgacığı uygulandıktan sonra özellik çıkartılmış normal ve epileptik EEG verisiyle elde edilen sınıflandırma sonuçları (a)eğitime için gerekli zaman ve(b)eğitime için gerekli iterasyon sayısı

Subaşı'nın (2006) aynı veri tabanından aldığı EEG verilerine, aynı özellik çıkarma yöntemlerini kullanarak yaptıkları çalışmada, sınıflandırılmayan segment sayısı epileptik sınıf için 15 tane ve normal sınıf için 18 tanedir. Bu durumda belirlilik değerini %94.5 ve hassasiyet değerini % 95 olarak hesaplamıştır. Bu tez çalışmasında ise Tablo 8.10'da görüldüğü gibi, adaptif modeller kullanarak, %100 belirlilik ve % 99.67 hassasiyet elde edilmiştir.

8.5. AAFYSA Uygulamalarının 5-Fold (Sayıda) Çapraz Değerlendirme ile Gerçekleştirilmesi

Bu bölümde, daha önce EEG sinyallerinin istatistiksel özelliklerinin çıkartılması ve Welch metodu kullanılarak özelliklerin çıkartılması ile yapılmış çalışmalar ve ÇKYSA ve AAFYSA algoritmalarıyla sınıflandırma problemlerine, beş fold çapraz değerlendirme yöntemi uygulanmış ve sınıflandırma sonuçları tekrar incelenmiştir. Beş-fold çapraz değerlendirme yöntemi verilerin ve modellerin güvenilirliğini kanıtlamak için kullanılmıştır. Bu yöntem kullanılarak, bütün EEG segmentleri için eğitime ve test işlemi yapılmıştır.

8.5.1. n-fold çapraz değerlendirme

n-fold çapraz değerlendirme yönteminde, veri seti, n tane alt sete bölünür. Her seferinde diğer bir deyişle her çevrimde, n tane alt setin biri test seti olarak kullanılır ve kalan (n-1) tane alt setin tamamı ise eğitime seti olarak birleştirilir. Bu veri setleri için eğitime ve test işlemi yapılarak hatalar hesaplanır. Daha sonra ortalama hata, bütün çevimler için hesaplanır. Bütün veri segmentleri kesinlikle bir defa test verisinin içinde ve (n-1) defa eğitime setinin içinde bulunur (Kohavi ve Provost 1998).

Bu tez çalışmasında, kullanılan ağların güvenilirliğini kanıtlamak amacıyla çapraz değerlendirmeyle yapılacak eğitime ve test işlemi için fold sayısı beş olarak seçilmiştir. Her iki sınıfı da içeren 1600 segmentlik EEG verisi rasgele karıştırılarak

beş adet alt sete bölünmüştür. Her çevrimde bu alt setlerden birisi test işlemi için ayrılmış, kalan dört tane alt set ise eğitime işlemi için kullanılmıştır. Bu işlem 5 defa tekrar edilmektedir. Dolayısıyla, her bir çevrim için, eğitime setindeki segment sayısı 1280 ve test setindeki toplam segment sayısı 320 olacak şekilde ayrılmış olur. Tablo 8.11, 5-fold çapraz değerlendirme işleminde her fold için kullanılan eğitime ve test segmentlerinin sayısını göstermektedir.

Tablo 8.11. Beş-fold çapraz değerlendirme için eğitime ve test setlerindeki veri segmentlerinin dağılımı

<i>Fold No</i>	<i>1. fold</i>		<i>2. fold</i>		<i>3. fold</i>		<i>4. fold</i>		<i>5. fold</i>	
<i>Sınıf Tipi</i>	<i>Test</i>	<i>Eğitime</i>	<i>Test</i>	<i>Eğitime</i>	<i>Test</i>	<i>Eğitime</i>	<i>Test</i>	<i>Eğitime</i>	<i>Test</i>	<i>Eğitime</i>
<i>Normal</i>	152	648	163	637	164	636	167	633	154	646
<i>Epileptik</i>	168	632	157	643	156	644	153	647	166	634
<i>Toplam</i>	320	1280	320	1280	320	1280	320	1280	320	1280

8.5.2. İstatistiksel özellikleri çıkartılmış EEG verisine AAFYSA algoritmasının çapraz değerlendirme ile uygulanması

Bu çalışmada, 512x1600 (800 segment normal ve 800 segment epileptik) büyüklüğündeki iki sınıf EEG veri seti öncelikle çapraz değerlendirme işlemi için rasgele karıştırılmıştır. Daha sonra veri setinde bulunan her bir segmentin aşağıda verilen istatistiksel özellikleri (en küçük değeri, en büyük değeri, ortalama değeri ve standart sapma değeri) çıkartıldıktan sonra [0 1] aralığında normalizasyon işlemi uygulanmış ve böylece bütün YSA modelleri için yeni veri seti oluşturulmuştur. EEG segmentlerinden çıkartılan özellikler;

- Her segmentin minimum değeri,
- Her segmentin maksimum değeri,
- Her segmentin ortalama değeri,
- Her segmentin standart sapma değeri

Bu özellik çıkarma yöntemi ile her bir segmentte bulunan örnek sayısı 512 örnekten 4 örneğe düşürülmüştür. Daha sonra bu yeni veri seti Tablo 8.11'de görüldüğü gibi, 5 adet alt sete bölünerek çapraz değerlendirme işlemi uygulanmıştır. Bu yeni veri setinin 4x1600 boyutlarındadır. Her fold için önce eğitime veri seti kullanılarak eğitime yapıldıktan sonra test veri seti ile test edilir ve eğitime ve test

hataları hesaplanır. Bütün foldlar için aynı işlem yapıldıktan sonra eğitime ve test hatasını bulmak için ortalamaları alınır. Çapraz değerlendirme işlemi uygulandıktan sonra ÇKYSA ve AAFYSA algoritmalarıyla elde edilen en iyi sonuçlar Tablo 8.12 ile verilmiştir.

Tablo 8.12. İstatistiksel özellikleri çıkartılmış EEG verisinin çapraz değerlendirme uygulaması sonucunda elde edilen en iyi sonuçlar

<i>Ağ Tipi</i>	<i>Optimum Mimari</i>	<i>Egt. Hatası (%)</i>	<i>Test Hatası (%)</i>	<i>SEN (%)</i>	<i>SPE (%)</i>	<i>Zaman (s)</i>	<i>Ortalama İterasyon</i>
ÇKYSA	4:3:1	0.034	0.054	100	100	676	4822
AAFYSA-1	4:3:1	0.034	0.054	100	100	1854	4814
AAFYSA-2	4:2:1	0.036	0.051	100	100	1043	2562
AAFYSA-3	4:6:1	0.078	0.099	100	100	628	1613

Bu çalışmada, Tablo 8.12'den görülebileceği gibi en düşük eğitime hatası %0.034 ile ÇKYSA ve AAFYSA-1, en düşük test hatası ise %0.051 değeriyle AAFYSA-2 modeliyle elde edilmiştir. Bütün modeller için %99.9 eğitime ve test başarısı ve %100 belirlilik ve hassasiyet elde edilmiştir. Bunun yanında eğitime zamanı ve iterasyon sayısı açısından değerlendirme yapılırsa AAFYSA-3 modeli en başarılı modeldir. Kullanılan ağlar eğitime hızı ve iterasyon sayısı yönünden kullanılan ağlar karşılaştırılırsa, %99.9 başarı için en iyi model AAFYSA-3 modelidir. Bütün segmentler doğru olarak sınıflandırılmıştır.

Tablo 8.13'de ise Tablo 8.12'de verilen en iyi sonuçlar için, bütün modellerin her foldda elde edilen hata değerlerini, belirlilik değerini, hassasiyeti, eğitime için yapılan iterasyon sayısını ve zamanını ve bu değerlerin ortalamaları ayrı ayrı verilmiştir.

Tablo 8.13.a, ÇKYSA modeli için her foldda elde edilen sonuçları göstermektedir. En yüksek eğitime ve test hatası beşinci foldda elde edilmiştir. Bunun yanında en küçük iterasyon sayısı ve en az eğitime zamanı bu fold için bulunmuştur. Bu tablo 0.3 öğrenme oranı ve 3 gizli düğüm için oluşturulmuştur.

Tablo 8.13.b, AAFYSA-1 modeli için her foldda elde edilen sonuçları göstermektedir. Bu tablo 0.3 öğrenme oranı ve 3 gizli düğüm için oluşturulmuştur. En yüksek eğitime ve test hatası bu model için de beşinci foldda elde edilmiştir. Bunlardan ikinci fold en başarılı olanıdır. Bunun yanında en küçük iterasyon sayısı ve en az eğitime zamanı beşinci fold için bulunmuştur.

Tablo 8.13. İstatistiksel özellikleri çıkartılmış EEG verisinin çapraz değerlendirme uygulaması sonucunda her fold için elde edilen (a) ÇKYSA modeli, (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için

(a) ÇKYSA modeli için gizli düğüm sayısı 3, $\beta=0.3$ iken elde edilen fold değerleri

Fold No	Egt Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Time (s)	Ort. iterasyon
1	0.033	0.010	100	100	705	5000
2	0.033	0.002	100	100	700	5000
3	0.031	0.025	100	100	699	5000
4	0.032	0.025	100	100	699	5000
5	0.041	0.210	100	100	575	4110
Ort. Değer	0.034	0.054	100	100	676	4822

(b) AAFYSA-1 modeli için gizli düğüm sayısı 3 $\beta=0.3$ iken elde edilen fold değerleri

Fold No	Egt Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Time (s)	Ort. iterasyon
1	0.033	0.010	100	100	1155	5000
2	0.033	0.002	100	100	1151	5000
3	0.030	0.025	100	100	1215	5000
4	0.032	0.025	100	100	2840	5000
5	0.041	0.210	100	100	2308	4072
Ort. Değer	0.034	0.054	100	100	1854	4814

(c) AAFYSA-2 modeli için gizli düğüm sayısı 2, $\beta=0.3$ iken elde edilen fold değerleri

Fold No	Egt Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Time (s)	Ort. iterasyon
1	0.036	0.023	100	100	877	2154
2	0.030	0.006	100	100	1087	2673
3	0.023	0.010	100	100	1368	3354
4	0.028	0.008	100	100	1136	2789
5	0.065	0.208	100	100	747	1843
Ort. Değer	0.036	0.051	100	100	1043	2562

(d) AAFYSA-3 modeli için gizli düğüm sayısı 6, $\beta=0.3$ iken elde edilen fold değerleri

Fold No	Egt Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Time (s)	Ort. iterasyon
1	0.069	0.047	100	100	670	1725
2	0.073	0.047	100	100	653	1679
3	0.088	0.099	100	100	732	1881
4	0.083	0.059	100	100	699	1796
5	0.078	0.024	100	100	383	984
Ort. Değer	0.078	0.099	100	100	628	1613

Tablo 8.13.c, AAFYSA-2 modeli 0.3 öğrenme oranı ve 2 gizli düğüm için için her foldda elde edilen sonuçları göstermektedir. En yüksek eğitime ve test hatası beşinci foldda ve en düşük eğitime ve test hatası ikinci foldda elde edilmiştir. Bunun yanında en küçük iterasyon sayısı ve en az eğitime zamanı beşinci fold için bulunmuştur. Bu tablo oluşturulmuştur. bu model için herbir foldun başarısı tek tek ÇKYSA ile karşılaştırılırsa, bütün foldlar için AAFYSA-2'nin daha başarılı olduğu görülmektedir.

Tablo 8.13.d, AAFYSA-3 modelinin, 0.3 öğrenme oranı ve 6 gizli düğüm için her foldda elde edilen sonuçlarını göstermektedir. Eğitime ve test hataları üçüncü foldda en yüksek ve eğitime hatası birinci foldda ve test hatası beşinci foldda en düşük değerlerindedir. Bunun yanında en küçük iterasyon sayısı ve en az eğitime zamanı beşinci fold için bulunmuştur.

Tablo 8.7 ve Tablo 8.12 karşılaştırıldığı zaman 5-fold çapraz değerlendirme işleminin modellerin başarısını etkilediği görülmektedir. Beş-fold çapraz değerlendirme ile eğitime ve test başarıları yükselirken eğitime süresi ve iterasyon sayısı ile azalmıştır.

8.5.3. Welch Metodu ile işlenmiş EEG verisine AAFYSA algoritmasının çapraz değerlendirme ile uygulanması

Bu uygulamada, çapraz değerlendirme işlemi uygulamadan önce (512x1600) boyutlarındaki karıştırılmış veri matrisinin her segmentinin Welch metodu uygulanarak güç spektrumu hesaplanır. Bunun için öncelikli olarak, 1600 segmentten oluşan veri matrisinin her segmentine önce 512 örnek büyüklüğünde Bölüm 5.1 ile anlatılan pencereleme yöntemlerinden olan, Hamming penceresi uygulanır. Bu işlemden sonra ise daha önce Bölüm 5.2'de ayrıntılı olarak anlatılan, % 50 üst üste binme (overlapping) özelliği kullanılarak 128 pencereli Welch metodu ile güç spektrum yoğunluğu elde edilir. Bu şekilde welch metodu veri setini (129x1600) boyutlarına indirgenmiş olmaktadır.

Daha sonra yeni (129x1600) boyutlarındaki veri seti Tablo 8.11'de görüldüğü gibi, 5 adet alt sete bölünerek çapraz değerlendirme işlemi uygulanmıştır. Her fold

için önce eğitime veri seti kullanılarak eğitime yapıldıktan sonra test veri seti ile test edilmiş ve eğitime ve test hataları hesaplanmıştır. Bütün foldlar için aynı işlem yapıldıktan sonra eğitime ve test hatasını bulmak için ortalamaları alınmıştır.

Tablo 8.11, bu veri setinde, her çevrimde eğitime ve test setinin veri sınıfına göre segment sayısını göstermektedir. Tablo 8.14, 5 fold çapraz değerlendirme işlemi sonunda elde edilen iyi sonuçları ifade etmektedir. Tablo 8.15 ise Tablo 8.14 ile verilen mimariler kullanılarak elde edilen sonuçların her fold için değerleri ayrı ayrı ifade edilmiştir.

Tablo 8.14. Welch Metodu ile işlenmiş EEG verisinin 5 fold çapraz değerlendirme işlemi sonunda elde edilen iyi sonuçları

<i>Ağ Tipi</i>	<i>Optimum Mimari</i>	<i>Egt. Hatası (%)</i>	<i>Test Hatası (%)</i>	<i>SEN (%)</i>	<i>SPE (%)</i>	<i>Zaman (s)</i>	<i>Ortalama İterasyon</i>
ÇKYSA	129:20:1	0,049	0,063	100	100	3144	4321
AAFYSA-1	129:15:1	0.045	0.063	100	100	4674	4439
AAFYSA -2	129:12:1	0.034	0.063	100	100	2257	2436
AAFYSA -3	129:5:1	0.068	0.083	100	100	1804	2290

Tablo 8.14'de görüldüğü gibi, eğitime test hatası bakımından en başarılı model AAFYSA-2 modelidir. Bu modelle elde edilen hatalar ÇKYSA ile elde edilen hatalardan daha düşüktür. Ayrıca zaman ve iterasyon sayısı açısından karşılaştırılma yapılırsa AAFYSA-2, ÇKYSA modelinden daha hızlıdır. Bunun yanında bu tabloda en iyi sonuçları verilen imarilerin tamamı için yaklaşık olarak %99.9 başarıya ulaşılmıştır. Bu başarıyı AAFYSA-3 modeli 5 gizli düğüm sayısı ile ÇKYSA ise 20 gizli düğüm sayısı ile yakalamıştır. Bu durumda AAFYSA-3 modeli ile karmaşıklığı daha az mimarilerde aynı başarının elde edilebileceği görülmüştür. Ayrıca, AAFYSA-3 mimarisi zaman ve iterasyon sayısı yönüyle bütün modellerden hızlıdır. Eğitime için harcanan zaman ve en küçük hata kriterine yakınsadığı iterasyon sayısı AAFYSA-3 modelinde, geleneksel ÇKYSA'nın yaklaşık olarak yarısı kadardır. Dahası, bütün modeller için %100 hassasiyet ve belirlilik elde edilmiştir.

Tablo 8.15'e dikkat edildiği zaman bütün modeller için en başarılı eğitim ve test sonucunun elde edildiği fold 1. ve en başarılı sonuçların elde edildiği fold ÇKYSA için 2. ve AAFYSA modelleri için 3. folddur. Ayrıca 5 fold çapraz değerlendirme Welch metodu ile işlenmiş EEG verisinin test başarısını arttırmıştır.

Tablo 8.15. Welch Metodu ile işlenmiş EEG verisinin çapraz değerlendirme uygulaması sonucunda her fold için elde edilen sonuçlar (a) ÇKYSA modeli (b) AAFYSA-1 modeli için, (c) AAFYSA-2 modeli için, (d) AAFYSA-3 modeli için

(a) ÇKYSA modeli için Gizli düğüm sayısı 20 olduğunda elde edilen fold değerleri

Fold No	Egt.Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Zaman (s)	Ort. iterasyon
1	0.080	0.137	100	100	3657	5000
2	0.023	0.010	100	100	2150	2959
3	0.075	0.061	100	100	3637	5000
4	0.024	0.016	100	100	3276	4512
5	0.045	0.090	100	100	3003	4138
Ort. Değer	0.049	0.063	100	100	3144	4321

(b) AAFYSA-1 modeli için Gizli düğüm sayısı 15 olduğunda elde edilen fold değerleri

Fold No	Egt.Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Zaman (s)	Ort. iterasyon
1	0.081	0.139	100	100	5295	5000
2	0.053	0.050	100	100	4753	4521
3	0.021	0.013	100	100	4679	4452
4	0.026	0.020	100	100	4190	3982
5	0.045	0.090	100	100	4454	4240
Ort.Değer	0.045	0.063	100	100	4674	4439

(c) AAFYSA-2 modeli için Gizli düğüm sayısı 12 olduğunda elde edilen fold değerleri

Fold No	Egt.Hatası (%)	TestHatası (%)	SEN (%)	SPE (%)	Zaman (s)	Ort. iterasyon
1	0.058	0.244	100	100	1719	1858
2	0.032	0.013	100	100	1743	1865
3	0.022	0.014	100	100	3275	3575
4	0.028	0.009	100	100	1939	2071
5	0.028	0.036	100	100	2603	2815
Ort. Değer	0.034	0.063	100	100	2257	2436

(d) AAFYSA-3 modeli için Gizli düğüm sayısı 5 olduğunda elde edilen fold değerleri

Fold No	Egt.Hatası (%)	Test Hatası (%)	SEN (%)	SPE (%)	Zaman (s)	Ort. iterasyon
1	0.079	0.159	100	100	1692	1620
2	0.072	0.053	100	100	2100	2008
3	0.060	0.060	100	100	3335	3343
4	0.067	0.065	100	100	958	2264
5	0.062	0.081	100	100	936	2216
Ort. Değer	0.068	0.083	100	100	1804	2290

9. SONUÇLAR VE ÖNERİLER

9.1. Sonuçlar

Geleneksel YSA algoritmasında, gizli katmanda ve çıkış katmanında bulunan nöronlarda sabit aktivasyon fonksiyonu kullanılmakta ve hatanın geriye yayılma algoritmasına göre öğrenme işlemi gerçekleştirilmektedir. Literatürde biyomedikal verilerle birlikte geleneksel YSA algoritmalarıyla yapılmış çok sayıda çalışma vardır. Bu çalışmaların çoğunda da başarılı sonuçlar elde edilmiştir. Bunun yanında, ağ mimarisini basitleştiren ve daha hızlı öğrenen yeni YSA algoritmaları üzerinde çalışmalar devam etmekte ve bu amaçla aktivasyon fonksiyonunun, bir YSA algoritmasının performansında etkili bir faktör olmasından yola çıkılarak, nöronlarda kullanılan bu fonksiyonların yapıları ile ilgili yeni yaklaşımlar üzerinde durulmaktadır.

Bu tezde faydalanılan ve sınırlı sayıda çalışma yapılmış olan yaklaşımlardan birinde, aktivasyon fonksiyonlarının değerinin probleme göre değişkenlik göstermesini sağlayarak aktivasyon fonksiyonuna nöronlar arasındaki ağırlıklarda olduğu gibi ağ bilgilerini yükleme görevi verilmiştir. Bu durumda, ağ bilgilerini tutabilmesi için aktivasyon fonksiyonuna serbest parametreler eklenerek, bu parametrelerin değerinin, ağırlıklar gibi eğitime sırasında önceki değerlerine ve ağırlık ürettiği çıkışa bağlı olarak değiştirilmesi sağlanmıştır. Bu şekilde tasarlanan fonksiyon ise serbest parametrelili adaptif aktivasyon fonksiyonu (AAF) olarak adlandırılmıştır.

Bu tez çalışmasında, gizli katman nöronlarında adaptif aktivasyon fonksiyonu kullanan ve ÇKYSA'dan öğrenme tipi ve aktivasyon fonksiyonunun karakteristiği bakımından farklılıklar gösteren yeni bir algoritma geliştirilmiştir. Geliştirilen bu algoritma adaptif aktivasyon fonksiyonlu yapay sinir ağları (AAFYSA) olarak adlandırılmış ve farklı AAF kullanılarak üç tane AAFYSA modeli (AAFYSA-1, AAFYSA-2 ve AAFYSA-3) tasarlanmıştır.

Algoritması geliştirilerek tasarımı gerçekleştirilmiş üç adet AAFYSA modeli ve geleneksel çok katmanlı YSA (ÇKYSA) algoritması kullanılarak yapılmış

uygulamalara yer verilmiştir. Bu dört YSA algoritmasının mimarisinde birtakım ortak özellikler vardır. Bu YSA algoritmalarının yazılımları, Matlab programlama dili ile ama “NN Toolbox” komutları kullanılmadan gerçekleştirilmiştir. Bu ağların mimarileri, üç katmanlı olarak tasarlanmışlardır. Giriş katmanlarında bulunan nöronlarında aktivasyon fonksiyonu kullanılmamıştır ve çıkış katmanlarında bulunan nöronlarında sabit sigmoid fonksiyonu kullanılmıştır. Bunun yanında en büyük farklılıkları gizli katman nöronlarında kullanılan aktivasyon fonksiyonunun tipidir. ÇKYSA algoritmasının gizli katman nöronlarında sabit sigmoid aktivasyon fonksiyonu kullanılırken, AAFYSA algoritmalarının gizli katman nöronlarında serbest parametrelili adaptif aktivasyon fonksiyonları kullanılmıştır.

Algoritması geliştirilen ve yazılımı gerçekleştirilen üç AAFYSA modelinin herbiri için farklı adaptif aktivasyon fonksiyonu kullanılmıştır. AAFYSA-1 modelinin gizli katman nöronlarında, literatürde yapılmış benzer çalışmalarda yaygın olarak kullanılan serbest parametrelili sigmoid fonksiyonu tercih edilmiştir. AAFYSA-2 modelinin gizli katmanlarında ise serbest parametrelili sigmoid fonksiyonu ile serbest parametrelili sinüs fonksiyonunun toplamı kullanılmıştır. AAFYSA-3 modelinin gizli katmanlarında ise serbest parametrelili Morlet dalgacık fonksiyonu aktivasyon fonksiyonu olarak kullanılmıştır. Bu fonksiyon ile yapılmış bir çalışmaya literatürde rastlanmamıştır.

Serbest parametrelili adaptif aktivasyon fonksiyonu kullanılarak algoritması geliştirilmiş ve yazılımı yapılmış AAFYSA modellerinin ÇKYSA modelinden, farklılıkları vardır. Bunlardan biri, ÇKYSA’dan farklı olarak AAFYSA modellerinde kullanılan aktivasyon fonksiyonunun serbest parametrelerinin değeri eğitime sırasında hataya bağlı olarak değişmektedir. Fakat serbest parametrelerin değerlerinin ayarlanması hatanın geriye yayılma algoritmasına dayanmakta ve fakat ağırlıklara göre farklı zamanda değiştirilmektedir. Ayrıca bir fonksiyonun karakteristiğini o fonksiyon içindeki sabitler de etkilediği için, gizli katman düğümlerinde, farklı serbest parametrelerle farklı aktivasyon fonksiyonları elde edilmiş olmaktadır. Bunun anlamı ÇKYSA modelinde bir katmandaki bütün nöronlar aynı aktivasyon fonksiyonunu kullanırken AAFYSA’da gizli katmanda bulunan her bir nöron farklı aktivasyon fonksiyonuna sahip olabilmektedir.

Şimdiye kadar, AAFYSA algoritması ile yapılmış çalışmaların sayısı sınırlıdır ve bu çalışmalar sadece XOR, n-bit parity, fonksiyon tanıma gibi temel problemlere uygulanmışlardır. Sınıflandırıcı olarak kullanılan AAFYSA algoritması ile biyomedikal verilerin sınıflandırılması üzerine yapılmış bir çalışmaya, literatürde rastlanmamıştır.

Bu tez çalışmasında, AAFYSA algoritmaları üzerine herhangi bir çalışma yapılmadan önce EEG sinyallerinin sınıflandırılmasında yaygın olarak kullanılan dalgacık dönüşümü, temel bileşen analizi ve Matlab NN Toolbox komutlarıyla yapılmış ÇKYSA ile iki farklı uygulama yapılmıştır. Bu uygulamalarda, hibrit yapılar kullanılarak alkolik ve normal EEG sinyallerinin sınıflandırılması yapılmış ve % 100 başarı elde edilmiştir. Bu çalışmalarla başarılı sonuçlar elde edilmesine rağmen, kullanılan bu yöntemlere EEG uygulamalarında sıklıkla rastlandığı için daha önce sinyali sınıflandırma ya da tanıma uygulamalarında hiç denenmemiş yeni bir yöntem arayışına girilmiş ve YSA'ya farklı bir yaklaşım getiren AAFYSA modelleri geliştirilmiştir. AAFYSA ile biyomedikal sinyallerin sınıflandırılması konusunda henüz literatürde yapılmış bir çalışma yoktur. Bu nedenle, bu yeni yöntemin bu tez çalışmasına daha iyi katkı sağlayacağı düşünülmüştür.

ÇKYSA ve farklı aktivasyon fonksiyonları ile geliştirilen AAFYSA algoritmalarının performanslarını karşılaştırabilmek için, başlangıçta XOR verisi kullanılarak denemeler yapılmıştır. Yapılan denemeler göstermiştir ki adaptif aktivasyon fonksiyonunun kullanılması öğrenme hızını arttırmaktadır. Çünkü ağırlıkların yanında serbest parametrelerinde ağ bilgisini tutması ve probleme bağlı olarak değerlerinin değişkenlik göstermesi, hatanın minimum hata kriterine daha hızlı yakınsamasına neden olmaktadır. Bunun yanında AAFYSA-3 modeli için eğitime hatası ÇKYSA'ya göre %0.03 fazla olmakla birlikte, test hatası %0.14 daha küçük değerlerdedir. Ayrıca bütün modellerde ulaşılan başarı, % 99.9'a kadar yükselmiştir. Aynı zamanda eğitime hızı ve iterasyon sayısı yönüyle başarı değerlendirmesi yapılırsa; özellikle AAFYSA-2 ve AAFYSA-3, ÇKYSA'ya göre yaklaşık 5 katı hız ile eğitime işlemini tamamladığı tespit edilmiştir.

Bu çalışmada kullanılan EKG sinyalleri, Dr. Yüksel ÖZBAY'ın "EKG Aritmilerini Hızlı Tanıma" adlı doktora çalışmasında kullanmış olduğu verilerden seçilmiştir (Özbay 1999). Bu EKG verileri iki gruptan oluşmaktadır. Birinci grup

veriler, MIT-BIH ECG Arrhythmia Database'den alınmış on farklı hastalık sınıfını içermektedir. İkinci grup veriler ise, yine Dr. Yüksel ÖZBAY'ın Selçuk Üniversitesi Tıp Fakültesi Kardiyoloji A.B.D. Kliniği'nde hastalardan yaptığı EKG kayıtlarından seçilmiştir (Özbay 1999).

Uygulamalarda, eğitime için oluşturulan veri seti, MIT-BIH ECG Arrhythmia Database'den alınmış ve yukarıda bahsedilen 10 farklı aritmiden meydana gelmektedir. Eğitime veri setinde, 106 segment EKG sinyali bulunmaktadır. Test amaçlı kullanılan 10 farklı hastaya ait veriler ise ikinci grup veriler arasından seçilmiştir. Eğitime ve test matrisinde bulunan bütün veri segmentlerinde 200 örnek mevcuttur.

EKG verisinin sınıflandırılması için kullanılan ağ mimarisi 200 giriş katman nöronu ve 10 sınıf veriyi sınıflandırabilmek için 10 çıkış katman nöronu ile oluşturulmuştur. Eğitime işlemi 5000 iterasyon için 106 setten oluşan, 10 sınıf veriyi içeren karma eğitime kümesi ile yapılmıştır. Test işlemi, öncelikle sadece normal EKG verileriyle hazırlanmış test matrisi kullanılarak yapılmış ve %100 test başarısı elde edilmiştir. En iyi sınıflandırma performansı $200 \times 17 \times 10$ mimarisi ile AAFYSA-2 algoritmasında elde edilmiştir. EKG verisinin sınıflandırılmasında, 106 segmentlik karma veriyle yapılan eğitime sonuçlarının ve 61 segmentlik bir hastadan alınan EKG verisiyle yapılmış test sonuçlarının en başarılı olanları Tablo 9.1 ile ifade edilmiştir. Bu tablodan görülebileceği gibi, ÇKYSA en iyi sonucu %97.43 test başarısı ile 30 gizli nöron sayısında, AAFYSA-1 % 97.96 test başarısını 17 gizli nöron sayısında ve AAFYSA-2 % 98.52 test başarısını 17 gizli nöron sayısında yakalamışlardır. Geliştirilen AAFYSA'lar ile elde edilen test başarılarının ÇKYSA'ya göre daha az gizli düğümde daha iyi olması özellikle gerçek zamanlı sistemlerin donanım tasarımlarında önemli bir iyileştirme sağlayabileceği anlamını taşımaktadır.

Tablo 9.1. 10 sınıf aritmi içeren EKG verisi kullanılarak elde edilen eğitime ve test sonuçları

<i>YSA Tipi</i>	β	<i>Gizli Nöron</i>	<i>EgtH %</i>	<i>TestH %</i>	<i>Zaman (s)</i>	<i>İterasyon Sayısı</i>
ÇKYSA	0,8	30	0,20	2,57	173	1370
AAFYSA-1	0,7	17	0,10	2,04	1069	5000
AAFYSA-2	0,7	17	0,08	1,48	1117	5000

Daha sonra, farklı hastalık sınıflarını içeren 10 farklı test veri kümesi oluşturularak bütün algoritmalar test edilmiş ve ortalama test hataları hesaplanmıştır. Tablo 9.2, bu kümelerle yapılmış test işlemi sonunda, ortalama sınıflandırma başarısını ve her hastalığa göre sınıflandırılan segment sayısını göstermektedir. Tablo 9.2'den görüldüğü gibi, AAFYSA-3 algoritmasında, sınıflandırılmayan toplam segment sayısı 17 ve ortalama test hatası 1.97 ile diğer algoritmalara göre en düşük değerdedir. Sınıflandırılmayan segment sayısı ÇKYSA'da 71 tane ve AAFYA-1'de 114 tanedir.

Tablo 9.2 ÇKYSA, AAFYSA-1 ve AAFYSA-2 modellerinin 10 farklı EKG verisi için elde edilen test sonuçları

Ağ Tipi	Örnek Sayısı	Segment Sayısı	K1 N	K2 Br	K3 T	K4 S	K5 Apc	K6 P	K7 R	K8 L	K9 Afib	K10 Aflt	K11 ?	Hata %
ÇKYSA	53600	268	72	37	0	37	0	0	57	0	5	0	71	3,94
AAFYSA-1	53600	268	72	15	2	15	2	0	27	0	5	0	114	3,65
AAFYSA-2	53600	268	72	34	0	2	0	0	57	0	86	0	17	1,97

Özby ve ark. 'nın (2006) yaptıkları çalışmada, bu tez çalışmasında kullanılan 106 segment 10 sınıf EKG eğitme veri seti kullanılarak, Matlab programlama dili hazır komutları ile yazılımı gerçekleştirilmiş geleneksel ÇKYSA ile sınıflandırma yapmışlardır. 10000 iterasyon için yapılan eğitme yapıldıktan sonra sınıflandırma başarısı olarak, 48 gizli nöron sayısı ile %0.28 eğitme hatası elde etmişlerdir.

Bu tez çalışmasında ise, aynı EKG eğitme verisi kullanılarak 5000 iterasyonda eğitilen AAFYSA-2 modeli ile 17 gizli nöron için %0.08 eğitme hatası elde edilmiştir. Elde edilen bu sonuca göre AAFYSA-2 modeli kullanılarak, daha az gizli düğüm sayısı ile yani daha az karmaşık YSA mimarisi ile aynı eğitme başarısına ulaşılabilmektedir.

Bu tez çalışmasında, ikinci biyomedikal veri olarak EKG sinyaline göre yorumlanması daha zor bir sinyal olan EEG sinyali ile çalışmalar yapılmıştır. Denemeler için kullanılan EEG verisi Andrzejak et al.(2001) tarafından genel kullanıma açılmış olan veritabanından elde edilmiştir. Normal ve epileptik olmak üzere iki sınıf EEG verisi kullanılmıştır. Veriyi sınıflandırıcıya vermeden önce her iki sınıfa ait (epileptik ve normal) EEG verilerini segmentlere ayırabilmek için önce iki sınıfa ait tek boyutlu dizi şeklindeki veri, 512 örnekli, dikdörtgen (rectangular)

pencereleme yöntemi kullanılarak segmentlere bölünmüştür. Böylece her iki sınıf içinde ayrı ayrı her bir segmentte 512 örnek olan toplam 800 segment elde edilmiştir. AAFYSA modelinin başarısını ölçebilmek için, her iki sınıfı içeren toplam 1600 segmentten rasgele seçilen 1000 segment eğitime verisi olarak geriye kalan 600 segment ise test verisi olarak kullanılmıştır.

Daha sonra eğitime ve test veri setlerine üç farklı özellik çıkarma yöntemi uygulanmış ve elde edilen yeni özellik vektörleri kullanılarak toplam olarak beş farklı uygulama yapılmıştır.

İlk uygulamada, istatistiki özellikler çıkartılarak, elde edilen yeni özellik vektörü kullanılarak ÇKYSA ve AAFYSA modellerinin tamamının sınıflandırma başarısı karşılaştırılmıştır.

Bu uygulamada, özellik çıkarma yöntemi olarak eğitime ve test veri setinde bulunan EEG segmentlerinden, istatistik özellikler çıkartılarak her bir segmentte bulunan örnek sayısı 512'den 4'e düşürülmüştür. Bu yöntemde çıkartılan özellikler sırasıyla, her segmentin minimum değeri, her segmentin maksimum değeri, her segmentin ortalama değeri ve her segmentin standart sapma değeridir.

İki sınıf EEG verilerinden bu istatistiksel özellikler çıkartıldıktan sonra sınıflandırıcıya uygulanmıştır. Yapılan bu ilk çalışmada veri matrislerinin boyutları 512x800 iken 4x800 boyutlarına azaltılmıştır. Daha sonra rasgele seçilen 500 normal ve 500 epileptik segment eğitime matrisini, 300 normal ve 300 epileptik segment test matrisini oluşturacak şekilde birleştirilmiştir. Yapılan eğitime ve test sonuçları bütün modeller için elde edilen yaklaşık %99.9 eğitime ve test başarısına ulaşılmıştır. Bunun yanında, AAFYSA modellerinde eğitime için gerekli olan iterasyon sayısı azalmıştır.

İkinci EEG uygulamasında ise, eğitime ve test veri matrislerine özellik çıkarma yöntemi olarak Welch metodu uygulanarak elde edilen özellik vektörünün, daha sonra ÇKYSA ve AAFYSA modellerinin tamamı ile sınıflandırması sağlanmıştır.

Bu uygulamada kullanılan özellik çıkarma yönteminde, iki sınıf EEG verisine Welch metodu uygulanırken öncelikle 512 örneklili Hamming penceresi her bir EEG segmentine uygulanmıştır. Daha sonra pencerelenmiş segmentlere, %50 üstüste binme (overlapped) özelliği ve 128'lik pencerelerle Welch yöntemi uygulanarak güç

spektrum yoğunluğu (PSD) hesaplanmıştır. Böylece ağın özellik matrisindeki her bir segmentin örnek sayısı, 512 örnekten 129 örneğe azaltılmış olmaktadır.

Bu şekilde EEG sinyallerinin frekans bileşenleri ortaya çıkarılmaya çalışılmıştır. Bu durumda, veri matrisleri 512x 800 iken 129x800 boyutlarına azaltılmıştır. Daha sonra rasgele seçilen 1000 veri (500 normal ve 500 epileptik) eğitime matrisi ve geriye kalan 600 segment ise (300 normal ve 300 epileptik) test matrisi olarak seçilmiştir. Elde edilen bu eğitime ve test matrisleri kullanılarak yapılan denemeler sonucunda, tasarımı yapılan dört model için de %99.9 başarıya ulaşılmasına rağmen, ÇKYSA modelinin en iyi sonuçların elde edildiği 20 gizli düğümlü mimaride, eğitime süresi 2467 s ve iterasyon sayısı 7814 iken AAFYSA-3 modelinin en iyi sonuçlarının elde edildiği 12 gizli düğümlü mimaride eğitime süresi 4100 s ve iterasyon sayısı 5922'dir. Bu çalışmada yapılan denemeler göstermiştir ki eğitime hatası ve test hatasına bakımından modeller birbirleriyle karşılaştırıldığı zaman en başarılı model % 0.022 eğitime hatası ve % 0.11 test hatası ile AAFYSA-2 modelidir. En başarılı mimariler ÇKYSA 129x10x1, AAFYSA-1 için 129x20x1, AAFYSA-2 ve AAFYSA-3 için 129x12x10 mimarileri şeklinde elde edilmiştir. Bununla birlikte, zaman ve iterasyon sayısı yönüyle en başarılı model AAFYSA-3'dür. Bunun anlamı AAFYSA algoritması ağın eğitimi hızlandırmaktadır.

Üçüncü EEG uygulamasında, dalgacık dönüşümü ve istatistiksel özellikler kullanılarak elde edilen yeni özellik vektörü ile ÇKYSA ve AAFYSA modellerinin tamamının sınıflandırma başarısı karşılaştırılmıştır.

Bu uygulama için kullanılan özellik çıkarma yönteminde, normal ve epileptik EEG sinyallerine 30 Hz'in üstünde gerekli frekans bileşeni içermedikleri için, 5. dereceden db4 dalgacığı uygulandıktan sonra elde edilen alt bantlarda D3-D5 ve A5 seçilmiştir. Seçilen bu alt bantların her birine istatistiksel özellik çıkarma yöntemleri uygulanarak giriş vektörünün boyutu azaltılmıştır. Çıkarılan istatistiksel özellikler sırasıyla, her alt banttaki katsayıların mutlak değerlerinin ortalaması, her alt banttaki dalgacık katsayılarının ortalama gücü, her alt banttaki katsayıların standart sapma değeri ve komşu alt bantların mutlak değerlerinin ortalamalarının oranıdır. Bu ön işleme yönteminde veri matrislerinde bulunan her bir segmentin örnek sayısı 15'e indirgenmiş olmaktadır. Bu özellik çıkarma yöntemi ile her bir segmentteki örnek sayısı 512 değerinden 15 değerine azaltılmış olmaktadır. Bu çalışmada, kullanılan

bütün YSA modelleri için belirlenen gizli nöron sayılarında, 0.5 öğrenme oranı için, %99.9 eğitime başarısına ulaşılmıştır. Eğitmenin ardından yapılan test sonucunda elde edilen değerlerinde ise bakıldığı zaman elde edilen en düşük test başarısı %99.45 ve yaklaşık olarak elde edilen en yüksek test başarısı %99.8'dir.

Bu şekilden görülebileceği gibi, %99.9 eğitime başarısı için AAFYSA-3 modeli, diğer modellere göre EEG sinyallerinin sınıflandırılabilmesi için, daha kısa sürede öğrenmiştir.

Bunun yanında belirlilik analizinde %100 başarı elde edilebilmesine rağmen hassasiyet analizinde %99.67 başarı elde edilmiştir. Bunun anlamı kullanılan algoritmalar, normal özellikli verinin tamamını tanıyabilmesine rağmen epileptik verilerden bir tanesini sınıflandıramamıştır.

Bundan sonra yapılacak olan EEG uygulamaları, 800 segmentlik epileptik ve 800 segmentlik normal EEG verileri birleştirilerek 1600 segmentlik tek veri seti oluşturulmuştur. Daha sonra bu veri setleri rasgele karıştırılarak, (512x1600) boyutlarında karışık sıralı tek bir veri seti beş fold çapraz değerlendirme için elde edilmiş olmaktadır.

Dördüncü uygulamada, karışık sıralı EEG veri setinin ilk EEG uygulamasında tanımlanan istatistikî özellikleri çıkarılarak, beş-fold çapraz değerlendirme yöntemiyle ÇKYSA ve AAFYSA modelleri kullanılarak sınıflandırılmıştır. 5 fold çapraz değerlendirme işlemi için 5 adet alt sete bölünen veri matrisinin her foldunda eğitime seti 4x1280 ve test seti 4x320 boyutlarındadır. Her fold için önce eğitime veri seti kullanılarak eğitime yapıldıktan sonra test veri seti ile test edilir ve eğitime ve test hataları hesaplanmıştır. Bütün foldlar için aynı işlem yapıldıktan sonra eğitime ve test hatasını bulmak için ortalamaları alınmıştır. 5-fold çapraz değerlendirme işleminin modellerin başarısını yükselttiği görülmüştür. Eğitime ve test başarıları yükselirken eğitime süresi ve iterasyon sayısı 5 fold çapraz değerlendirme ile azalmıştır.

Son EEG uygulamasında, karışık sıralı (512x1600) boyutlarındaki veri matrisine ikinci uygulamada anlatılan Welch metodu uygulanarak, her segmentin güç spektrumu hesaplanmıştır. Daha sonra elde edilen yeni (129x1600) özellik matrisi, 5 alt sete bölünmüştür. Bu durumda her bir alt set için eğitime seti 129x1280 ve test seti 129x320 boyutlarındadır. Her bir alt set ile eğitime ve test işlemleri yapılarak daha

sonra ortalamaları alınmıştır. Bu çalışma ile ÇKYSA modelinde 20 gizli nöron için %99.9 başarı elde edilebiliyorken 12 gizli nöronla AAFYSA-2 en başarılı algoritma olmuştur. Bunun yanında AAFYSA-3, eğitime hızı ve iterasyon sayısı bakımından 12 gizli nöronla en başarılı algoritma olmuştur. Eğitime için harcanan zaman ve en küçük hata kriterine yakınsadığı iterasyon sayısı AAFYSA-3 modelinde, geleneksel ÇKYSA'nın yaklaşık olarak yarısı kadardır.

Yapılan bu uygulamalar değerlendirildiği zaman aşağıda verilen sonuçlar elde edilmiştir.

i. AAFYSA algoritmasında gizli katmanda kullanılan aktivasyon fonksiyonu ÇKYSA'da olduğu gibi başarıyı etkileyen bir faktördür.

ii. AAFYSA'nın performansını ÇKYSA'da olduğu gibi giriş katmanı düğüm sayısı etkilemektedir.

iii. Yapılan uygulamalarda, AAFYSA kullanıldığı zaman, ağı eğitime zamanı ve eğitime iterasyon sayısının ÇKYSA'ya göre daha az olduğu görülmüştür. Oysa AAFYSA algoritması ile ÇKYSA'nın algoritması ve Matlab yazılımları karşılaştırıldığı zaman, AAFYSA programları daha karmaşık yapıdadır. Şekil 6.2 ile verilen AAFYSA akış diyagramı ile Şekil 2.4 ile verilen ÇKYSA akış diyagramı karşılaştırıldığı zaman, AAFYSA'da daha fazla güncellenecek parametre vardır. Bu da programların döngü sayısını dolayısıyla karmaşıklığını arttırmaktadır. Buna rağmen AAFYSA, ÇKYSA'dan daha hızlı eğitime işlemini tamamlamaktadır.

iv. AAFYSA kullanıldığı zaman ÇKYSA'ya göre ağ mimarisinin donanımsal karmaşıklığı azalmıştır. Diğer bir deyişle aynı eğitime ve test başarısına gizli katmanda daha az nöron sayısı ile ulaşılmıştır.

v. AAFYSA gizli katman nöronlarında kullanılan aktivasyon fonksiyonu serbest parametreleri, hataya bağlı olarak ağırlıkların güncellenmesine benzer bir şekilde eğitime sırasında değerleri değiştirilerek güncellendiğinden, ağı hedef değerlere yakınsama hızı artmaktadır.

AAFYSA kullanılmasının en önemli avantajı, eğitime hızını arttırarak daha az iterasyon sayısında ve daha basit mimaride ÇKYSA ile aynı ya da daha yüksek eğitime ve test başarısına ulaşılabilmesidir.

9.2. Öneriler

Bu çalışmada EKG ve EEG gibi karmaşık biyomedikal sinyallerle yapılan denemeler sonucunda, AAFYSA ve ÇKYSA uygulamaları karşılaştırıldığı zaman bu modellerle ilgili birtakım yargılara varılabilmektedir.

Aktivasyon fonksiyonlarında kullanılan serbest parametrelerden dolayı, ağın EEG ve EKG dışında farklı sinyalleri yorumlanmasında ve sınıflandırmasında başarısının iyi olacağı düşünülmektedir.

Aktivasyon fonksiyonlarında kullanılan serbest parametrelerin sayısı da AAFYSA'nın performansını ve hızını etkilemektedir. Farklı sayılarda serbest parametrelerle uygulamalar gerçekleştirilebilir. Ayrıca gizli katman düğümlerinde de literatürde kullanılan farklı aktivasyon fonksiyonlarına değişik sayılarda serbest parametreler eklenerek kullanılabilir.

ÇKYSA'da kullanılan sabit sigmoid aktivasyon fonksiyonundan farklı olarak tanjant sigmoid fonksiyonu gibi başka fonksiyonlar da, daha sonraki çalışmalarda, AAFYSA modellerinin çıkış katmanı aktivasyon fonksiyonu olarak kullanılabilir..

AAFYSA modelleri yeniden ele alınarak farklı eğitme algoritması kullanan diğer yapay sinir ağı algoritmaları ile de karşılaştırılabilir.

Bu çalışmada özellik çıkarmada kullanılan dalgacık dönüşümü, Welch metodu ve istatistiki özellikler dışında farklı özellik çıkarma yöntemleri de uygulanarak veri azaltılması ile AAFYSA ile sınıflamalar gerçekleştirilebilir.

AAFYSA modelleri ile yapılan denemeler sonucunda, daha az sayıda gizli düğüm kullanılarak, ÇKYSA modeliyle aynı başarı elde edilebilmiştir. Bunun anlamı AAFYSA modellerinde daha az karmaşık ağ mimarileri ile ÇKYSA'dan daha yüksek başarıya ulaşılabilmektedir. Bu da gerçek zamanlı ve donanım olarak tasarımı yapılacak sistemler için bir avantajdır. Benzer sistemlerde AAFYSA modeli donanıma eklenebilir.

10. TARTIŞMA

Geliştirilen AAFYSA algoritması, mühendislik, tıp bilimi ve endüstriyel alanlarda çok sayıda uygulaması olan geleneksel YSA'nın hızını ve performansını arttırmak için yapılan çalışmalardan biridir. Araştırmacılar YSA'yı insan beyninin kavrama hızına yaklaştırmak amacıyla sürekli bu konuda çalışmalara devam etmektedirler. Bu nedenle öğrenme başarısına ek olarak öğrenme hızı YSA'da önemli bir unsur haline almıştır. XOR problemi ve EKG ve EEG verilerinin sınıflandırılması uygulamaları göstermiştir ki AAFYSA algoritması eğitime zamanını ve eğitime için harcanan iterasyon miktarını azaltmaktadır. Bunun yanında, AAFYSA ile daha az gizli düğüm sayısında ÇKYSA ile aynı ya da daha yüksek başarıya ulaşılabilmektedir.

Aynı zamanda bu tezde yapılan çalışmalar, daha önce aynı verilerle yapılmış çalışmalarla da karşılaştırılmıştır.

EKG verisinin sınıflandırılması amacıyla yapılan uygulamalarda, ÇKYSA, AAFYSA-1 ve AAFYSA-2 ağları kullanılmıştır. Bu çalışmada kullanılan EKG verilerine herhangi bir özellik çıkarma yöntemi uygulanmadığı halde AAFYSA ağları ile % 99.9 eğitime başarısına, 17 gizli katman nöronu ve 5000 iterasyon sayısı ile ulaşılabilmektedir.

Özbay ve ark. 'nın (2006) aynı EKG verileri ile yaptıkları çalışmada, 10000 iterasyonda, 48 gizli nöron sayısı ile %0.28 eğitime hatası elde etmişlerdir. Elde edilen bu sonuca göre AAFYSA-2 modeli kullanılarak, daha az gizli düğüm sayısında (17) daha düşük eğitime hatasına (% 0.08) ulaşılabilmektedir.

Literatürde Andrzejak ve ark.'nın (2001) genel kullanıma açmış olduğu EEG verileri kullanılarak yapılmış pek çok çalışma mevcuttur. Subaşı'nın (2006) bu veri tabanından aldığı EEG verilerine, aynı özellik çıkarma yöntemlerini kullanarak yaptıkları çalışmada, sınıflandırılmayan segment sayısı epileptik sınıf için 15 tane ve normal sınıf için 18 tanedir. Bu durumda belirlilik değerini %94.5 ve hassasiyet değerini % 95 olarak hesaplamıştır. Bu tez çalışmasında ise AAFYSA kullanarak, %100 belirlilik ve % 99.67 hassasiyet elde edilmiştir. Sınıflandırılmayan normal

sınıfa ait segment sayısı bir iken epileptik sınıfa ait bütün segmentler doğru sınıflandırılmıştır.

AAFYSA modelleri ile biyomedikal verilerin sınıflandırılması çalışmaları, literatürde daha önce yapılmış bu çalışmalarla karşılaştırıldığı zaman, geliştirilen AAFYSA modellerinin özellikle eğitime zamanı, iterasyon sayısı ve ağ mimarisinin karmaşıklığı konusunda daha başarılı oldukları görülmüştür.

11. KAYNAKLAR

Acharya R., Bhat P.S. Iyengar S.S., Roo A., Dua S. 2002. Classification of heart rate data using artificial neural network and Fuzzy equivalence relation, Journal Pattern Recognition Society.

Acır N., Güzeliş C. 2004. Automatic recognition of sleep spindles in EEG by using artificial neural Networks, Expert Systems with Applications. 27(3):451-458.

Akın M., Arserim M.A., Kıymık M.K., Türkoğlu I. 2001. A new Approach for Diagnosing Epilepsy by Using Wavelet Transform and Neural Networks, Proceedings of the 23rd Annual EMBS International Conference, 25-28 Oct. İstanbul.

Amerikan EEG Derneği 1986. Amerikan EEG Derneği Kayıt Klavuzu, Amerikan EEG Derneği, Cilt 3. Ek1,1-37.

Andrzejak R.G., Lehnertz K., Mormann F., Rieke C., David P., Elger C.E. 2001. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity:dependence on recording region and brain state. *Phys Rev E*, 64:061907.

http://www.epileptologie-bonn.de/front_content.php?idcat=193&lang=3&changelang=3

Arserim M.A., 2001 Beyin Sinyallerinin Modern Spektral Analiz Yöntemleri ile Kestirimi, Dicle Üniversitesi Fen Bilimleri Enstitüsü.

Ceylan R., Özbay Y., Comparison of FCM, PCA and WT techniques for Classification ECG Arrhythmias using Artificial Neural Network, Expert Systems with applications, 33;286-295, 2007.

- Cincotti, F., Mattia, D., Babiloni, C., Carducci, F., Salinari, S., Bianchi, L., Marciani, M.G., Babiloni, F. 2003. The use of EEG modifications due to motor imagery for brain-computer interfaces, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2): 131 – 133 June.
- Cincotti, F., Scipione, A., Timperi, A., Mattia, D., Marciani, A.G., Millan, J., Salinari, S., Bianchi, L., Babiloni, F. 2003. Comparison of different feature classifiers for brain computer interfaces. *Neural Engineering, Conference Proceedings. First International IEEE EMBS Conference on 20-22 March* 645 – 647.
- Costa, E. J.X., Cabral, E F. Jr. 2000. EEG-based discrimination between imagination of left and right hand movements using adaptive gaussian representation. *Medical Engineering & Physics*:345–348.
- Dirgenali F., Kara S. 2006. Recognition of early phase of atherosclerosis using principles component analysis and artificial neural networks from carotid artery Doppler signals. *Expert Systems with Applications* 31:861-874.
- Efe Ö., Kaynak O., 2000. *Yapay Sinir Ağları ve Uygulamaları*, Boğaziçi Üniversitesi, İstanbul.
- Fauset L. 1994. *Fundamentals of neural networks: Architectures, Algorithms and Applications*. Prentice Hall, Inc. A Simon&Schuster Company.
- Fisch, B.J. 1997. *Spehlmann'ın EEG El kitabı*, 6.Baskı Turgut Yayıncılık ve Ticaret A.Ş.
- Graps, A. 1995. *An introduction to wavelets*, IEEE Computer Society, USA 1-18.

- Güler, İ., Übeyli E.D. 2005b. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients”, Journal of Neuroscience Methods 148: 113-121.
- Güler, İ., Übeyli E.D. 2005a ECG beat classifier designed by combined neural network model. Pattern Recognition, 38, 199–208.
- Güneş M. 1999. EEG işaretlerinin Dalgacık Analizi ve Diğer Yöntemlerle Karşılaştırılması, Yüksek Lisans Tezi KSÜ Fen Bilimleri Enstitüsü.
- Haykin S. 1994. Neural Networks: A Comprehensive Foundation. New York: Macmillan.
- Hazarika N., Chen J.Z., Ah Chung Tsoi, Sergejew A., 1997 Classification of EEG signals using the wavelet transform. 13 th International Conference on Digital Signal Processing Proceedings 1:89 – 92.
- Ifeachor E.C., Jervis B.W.2002. Digital Signal Processing-A Practical Approach, 2nd ed. Pearson Education Limited USA.
- Jung T.-P., Humphries C., Lee, T.-W., Makeig S., McKeown M.J., Iragui V., Sejnowski T.J. 1998 Removing electroencephalographic artifacts: comparison between ICA and PCA. Neural Networks for Signal Processing VIII, Proceedings of the 1998 IEEE Signal Processing Society Workshop 63 – 72.
- Kalaycı T., Özdamar Ö. 1995 Wavelet Preprocessing for Automated Neural Network Deection of EEG spikes IEEE Engineering in Medicine and Biology, Mart/Nisan.
- Keskin B., 2002 Ses işaretlerinin Analizinde Kısa Zamanlı Fourier ve Dalgacık Dönüşümlerinin Uygulamaları, Gebze İleri Teknoloji Ens. Müh. ve Fen Bilimleri Enstitüsü.

- Liu T.I. 1993. On-line Sensing of Drill Wear Using Neural Network Approach. IEEE International Conference on Neural Networks 2: 690-694.
- Mazaeva N., Ntuen C., Leby G. 2001 Self-Organizing Map (SOM) model for mental workload classification IFSA World Congress and 20th NAFIPS International Conference Joint 9th 3:1822 – 1825.
- Misiti M., Misiti Y., Oppenheim G., Poggi J.M. 2000. Wavelet Toolbox User's Guide, MathWorks Inc.
- Mitchell T.M. 1997. Machine Learning. The McGraw-Hill Companies, Inc. Portland.
- Oğul,E., Sadıkoğlu,S., Bora,İ., Zarifoğlu M., Turan,Ö.F., Bakar,M. 1996 Temel ve Klinik Nöroloji 1. Basım, ,Uludağ Üniversitesi Basımevi.
- Osowski S., Linh T.H., 2001 ECG beat recognition using fuzzy hybrid neural network, IEEE Transaction Biomed Engineering, 48:11:1265-1271.
- Özbay Y. 1999. EKG Aritmilerini Hızlı Tanıma, Dr. Tezi, Selcuk Üniversitesi Fen Bilimleri Ens. Konya.
- Özbay Y., Ceylan R., Karlık B. 2006. A fuzzy clustering neural network architecture for classification of ECG arrhythmias, Elsevier Science Computers in Biology and Medicine, 36: 376-388.
- Özdamar Ö., Kalaycı T. 1998 Detection of Spikes with Artificial Neural Networks Using Raw EEG. Computers and Biomedical Research, 31:122-142.
- Öztemel E. 2003 Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

- Palaniappan R., Raveendran P. 2002 Genetic algorithm to Select Features for Fuzzy Artmap Classification of Evoked EEG, , 2002. APCCAS '02 Asia-Pacific Conference on Circuits and Systems 2:53 - 56, 28-31 Oct.
- Palaniappan R., Raveendran P., Nishida S., Saiwaki N. 2000 Evolutionary fuzzy ARTMAP for autoregressive model order selection and classification of EEG signals Systems IEEE International Conference on Man and Cybernetics, 5:3682 – 3686.
- Pang, C.C.C., Upton, A.R.M., Shine, G., Kamath, M.V. 2003 A comparison of algorithms for detection of spikes in the electroencephalogram IEEE Transactions on Biomedical Engineering, 50(4): 521 – 526 April.
- Pohl V., Fahr E. 1995 Neuro-fuzzy recognition of K-complexes in sleep EEG signals Engineering in Medicine and Biology Society, IEEE 17th Annual Conference 1:789 - 790
- Polikar, R. 2001 Fundamental Concepts &An overview of the Wavelet Theory, Second Edition,
<http://engineering.rowan.edu/~polikar/WAVELETS/WTtutorial.html>,
- Proakis J.G., Manolakis D.G. 1996. Digital Signal Processing: Principles, Algorithms and Applications, 3th ed.,Prentice Hall Inc. New Jersey.
- Proakis J.G., Rader C.M., Ling F., Nikias C.L. 1992. Advanced Digital Signal Processing, Macmillian Publishing Company, USA.
- Sağıroğlu Ş., Beşdok E., Eler M., 2003. Mühendislikte Yapay Zeka Uygulamaları-1/Yapay Sinir Ağları, Ufuk Kitap Kırtasiye Yayıncılık Ltd. Şti., Kayseri.
- Schwaibold, M.H., Penzel T., Schochlin J., Bolz A. 2001 Combination of AI components for biosignal processing application to sleep stage recognition.

Engineering in Medicine and Biology Society, Proceedings of the 23rd Annual International Conference of the IEEE 2:1692 – 1694.

Segee B.E. 1993. Using spectral techniques for improved performance in artificial neural networks. IEEE International Conference on Neural Networks, 1:500 - 505 28 March-1 April

Semmlov, J.L. 2004. Biosignal and Biomedical Image Processing, Marcel Deccer Inc. USA.

Solazzi M., Uncini A. 2000. Artificial Neural Networks with Adaptive Multidimensional Spline Functions. Neural networks 17: 247-260.

Solazzi M., Uncini A. 2004. Regularising Neural Networks using Flexible Multivariate Activation Function, Neural Networks 17: 247-260.

Stearns D.S., David A.R. 1988. Signal Processing Algorithms, Prentice-Hall Inc., Englewood Cliffs, New Jersey.

Subaşı A. 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model, Expert Systems with Applications, Volume 32(4):1084-1093.

Talukder A., 2001, Adaptive Activation Function Neural Net for Face Recognition, Proceedings of the International Joint Conference on Neural Networks, 1:549-552.

Tarassenko L., Khan Y.U., Holt M.R.G. 1998 Identification of Interictal spikes in the EEG using Neural Network Analysis. In Gaven S., editor IEEE proceedings, Science Measurements and Technology. United Kingdom:IET 270-278.

Tezel G. Özbay Y., 2007, “A New Neural Network with adaptive activation function for classification of ECG Arrhythmias “, KES 2007 11th Int. Conf. On

Knowledge-Based and Intelligent Information&Engineering Systems, 12-14 Eylül, İtalya.(Kabul edildi)

Tezel G., Ceylan R.,Özbay Y. 2006. “Neural Classifier with Wavelet Transform and Principal Component Analysis for Classification of EEG Signals” The 12th Internatioanl Conference on Applied Stochastic Models and Data Analysis, 29 Mayıs-1 Haziran, Yunanistan

Tezel G., Özbay Y. 2006. EEG classification using wavelet transform and artificial Neural Network, Proceedings of Internatioanal Conference on Modeling and Simulation, 28-20 Ağustos Konya.

Tezel G., Özbay Y. 2007. EEG Sinyallerinin Sınıflandırılmasında Yeni Bir Yaklaşım, SİU 2007

The UCI KDD Archive Information and Computer Science University of California, Irvine

<http://kdd.ics.uci.edu/databases/eeg/eeg.html>

Tükel,K.,1979, Klinik Elektroensefalografi, Çeliker Matbaacılık.

Türkoğlu İ., 2002 Durağan Olmayan İşaretler İçin Zaman Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, Dr. Tezi Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

Vecci L., Piazza F. Uncini A. 1998 Learning and approximation capabilities of adaptive spline activation function neural Networks. Neural Networks 11: 259-270.

Vetterli M., Kovacevic J. 1995. Wavelets and Subband Coding, Prentice Hall Inc. USA.

- Vigario R., Sarela j., Jousmaki V., Hamalainen M., Oja E., 2000, Independent Component Approach to the Analysis of EEG and MEG Recordings, IEEE Transactions on Biomedical Engineering, 47(5):589 - 593) May 2000.
- Vuckovic A., Radivojevic V., Chen A.C.N., Popovic D. 2002 Automatic recognition of alertness and drowsiness from EEG by an artificial neural network. Medical Engineering & Physics, 349–360.
- Wang, X., Paliwal, K. K. 2003. Feature extraction and dimensionality reduction algorithms and their applications in vowel recognition, Pergamon. The Journal of the Pattern Recognition Society, 36, 2429–2439.
- Wu Y., Zhao M., Ding X. 1997. Beyond weights Adaptation:A new Neuron Model with Trainable Activation Function and Its Supervised Learning,
- Xiaopu Y., Mingui S., Sonmex, M.; Sclabassi, R.J. 1995. On divided neural network and its application to source localization in the brain. Engineering in Medicine and Biology Society, 1995. IEEE 17th Annual Conference 1:795 - 796 ,20-23 Sept.
- Xiaopu Y., Mingui S., Sclabassi, R.J. 1995. novel Model for source localization on neural substrates, 1995., IEEE 21st Annual Northeast, Proceedings of the Bioengineering Conference, 67 - 69, 22-23 May.
- Xu S., Zhang M. 1999a. Adaptive Higher-Order Feedforward Neural Networks, IJCNN '99 IEEE International Joint Conference on Neural Networks, 10-16 July, 1, 328 - 332.
- Xu S., Zhang M. 1999b. Approximation to Continuous Functionals and Operators Using Adaptive Higher-Order Feedforward Neural Networks. International Joint Conference on Neural Networks IJCNN'99, 10-16 July, 1, 337-374.

- Xu S., Zhang M. 2000. Justification of A Neuron-Adaptive Activation Function, Proceeding of IEEE-INNS-ENNS International Joint Conference on Neural Networks, IJCNN 2000, 24-24 July, 3, 465-470.
- Xu S., Zhang M. 2001. A Novel Adaptive Activation Function, Proceedings IJCNN'01 International Conference on Neural Networks, 4:2779-2782, 15-19 July.
- Xu S., Zhang M. 2005. Data Mining-An Adaptive Neural Network Model for Financial Analysis. Third International Conference on Information Technology and Applications IEEE ICITA'05, 1, 336 – 340.
- Yagneswaran, S. Baker, M. Petrosian, A. 2002. Power frequency and wavelet characteristics in differentiating between normal and Alzheimer EEG, Engineering in Medicine and Biology, 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society EMBS/BMES Conference, 2002. Proceedings of the Second Joint, 1:46 – 47.
- Yaltkaya,K., Balkan,S.,Oğuz,Y.. 1996., Nöroloji Ders Kitabı, 2. Basım, Pame Yayıncılık.
- Yazdanpanah M.J., Semsar E., Caro L. 2003. Minimization of actuator repositioning in delayed processes using flexible neural networks, IEEE Conference on Control Applications-Prpceedings, 1:331-335.
- Yu C.C., Tang Y.C., Liu B.D. 2002. An adaptive Activation Function for Multilayer Feedforward Neural Networks. Proceeding of IEEE TENCON'02.
- Zhang M., Xu S., Fulcher J. 2002. Neuron-Adaptive Higher Order Neural-Network Models for Automated Financial Data Modeling, IEEE Transactions on Neural Networks, 13(1): 188-204.

Zhang M., Xu S., Fulcher J. 2002. Neuron-Adaptive Higher Order Neural-Network Models for Automated Financial Data Modeling, IEEE Transactions on Neural Networks, 13(1):188-204.

Zhang M., Xu S., Lu B. 1999. Neuron-Adaptive Higher Order Neural Network Group Models, International Joint Conference on Neural Networks, IJCNN'99, 1:333-336 10-16 July.

Zhang X.S., Roy R.J., 1999. Depth of anesthesia estimation by adaptive-network-based fuzzy inference system” [Engineering in Medicine and Biology, 1999. 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc.] BMES/EMBS Conference, 1999. Proceedings of the First Joint ,1:391.