

T.C.
MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EPİLEPSİ HASTALIĞININ DALGACIK DÖNÜŞÜMLERİ VE YAPAY
SİNİR AĞLARI İLE TANILANMASI**

YÜKSEKLİSANS TEZİ
Ezgi ÖZER

Anabilim Dalı: İstatistik
Programı: İstatistik

Tez Danışmanı: Yrd.Doç.Dr. Ozan KOCADAĞLI

ARALIK 2015

Ezgi ÖZER tarafından hazırlanan EPİLEPSİ HASTALIĞININ DALGACIK DÖNÜŞÜMLERİ VE YAPAY SINIR AĞLARI İLE TANILANMASI adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylıyorum.



Yrd. Doç. Dr. Ozan KOCADAĞLI

Tez Yöneticisi

Bu çalışma, jürimiz tarafından İstatistik Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: : Yrd. Doç. Dr. Ozan KOCADAĞLI



Üye : Prof. Dr. Gülay BAŞARIR



Üye : Doç. Dr. Esra AKDENİZ

Bu tez, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.

ÖZET

Elektroensefalogram, magnetoencefalogram, bilgisayarlı tomografi, magnetik rezonans görüntüleme gibi yöntemlerle nörolojik hastalıkların teşhisi önemli gelişmeler kaydetmiştir. Bu çalışmada, epilepsi hastası olan bir bireyden alınmış Elektroensefalogram (EEG) sinyallerinin dalgacık dönüşümleriyle spektral analizi gerçekleştirilerek, bu sinyaller hakkında önemli bilgi içeren dalgacık katsayıları elde edilmiştir. Bu katsayılar yardımıyla, analizlerde kullanılacak olan öznitelik vektörleri oluşturulmuştur. Daha sonra öznitelik vektörleri, çok kategorili lojistik regresyon ve çeşitli yapay sinir ağlarına girdi olarak verilerek, bireyden alınan sinyallerin bireyin durumunu teşhis edecek şekilde sınıflandırılması sağlanmıştır.

Birinci bölümde, insan beyninin yapısı, sinir hücreleri, biyolojik işaretlerin nasıl oluştuğu ve epilepsiden söz edilmiştir. Bunun yanısıra, EEG kaydı ve ölçümleri hakkında bilgi verildikten sonra epileptik olan ve olmayan beyin dalgaları tanıtılmıştır.

İkinci bölümde, konuyla ilgili literatür araştırmasına yer verilerek, Epileptik EEG verilerinin sınıflandırılmasında kullanılan klasik yöntemler ve yeni metodolojiler tartışılmıştır.

Üçüncü bölümde, nöronun yapısı açıklanmış, EEG kaydı ve kayıt sonucu elde edilen farklı frekanslardaki beyin dalgaları gösterilmiştir.

Dördüncü bölümde, yöntemler tartışılmıştır. Fourier dönüşümü, dalgacık türleri, dalgacık dönüşümü, yapay sinir ağları, çok kategorili lojistik regresyon ve model seçme kriterleri tanıtılmıştır. Beşinci bölümde yapay sinir ağlarıyla, altıncı bölümde çok kategorili lojistik regresyonla ve yedinci bölümde model seçme kriterleriyle ilgili tanımlara yer verilmiştir.

Sekizinci bölümde, analizleri gerçekleştirmek için önerilen prosedürün adımları ve içeriği verilerek analiz sonuçları tartışılmıştır.

Dokuzuncu bölüm ise sonuç bölümüdür. Bu bölümde çalışmanın analiz sonuçları yorumlanarak, kullanılan yöntemlemlerin zayıf ve güçlü tarafları tartışılmıştır. Bunun yanısıra gelecek çalışmalardan söz edilmiştir.

Analiz sonuçlarına göre; model karmaşıklığı, aşırı uyum ve eğitim algoritmasının seçimi gibi eğitim performansını etkileyen faktörlerin göz öünde bulundurulmasıyla yapay sinir ağlarının, logistik regresyona göre daha iyi bir sınıflandırma performansı sağladığı görülmüştür.

Anahtar Kelimeler: Epilepsi, Elektroensefalogram (EEG), Sinyal İşleme, Ayrık Dalgacık Dönüşümü, Yapay Sinir Ağı, Çok Kategorili Lojistik Regresyon, Gradyan Tabanlı Öğrenme.

ABSTRACT

Recently, electroencephlogram (EEG), magnetoencephalogram, computed tomography, magnetic resonance imaging has made significant advances in the diagnosis of neurological diseases. In this study, EEG signals taken from an individual who suffers from epilepsy has been performed the spectral analysis using by the wavelet transforms. By means of these transformations, the wavelet coefficients which provide important information about these signals are obtained. From these coefficients, the feature vectors are constructed to use in the analysis, because they include important information related to EEG signals. These feature vectors are considered as the system inputs for the multiple logistic regression analysis and artificial neural networks, and then the classification process is performed over these signals.

In the first chapter, the structure of human brain, nerve cells, biological signals, occurring biological signals and epilepsy are introduced. In addition, the examples of brain wavelets which are epileptic and non-epileptic are displayed over EEG recording and measures.

The second chapter is left to the literature review. In this chapter, the classical methods and new methodologies have been discussed in the classification of epileptic signals. In the third chapter, the structures of neuron and epilepsy, EEG recording and brain waves have been introduced. In the fourth chapter; Fourier transform, wavelet types, wavelet transform are explained. In the fifth chapter, the functional structures of neural networks are given. In the sixth chapter, the theory of multiple logistic regression model is introduced. In the seventh chapter, the model selection criteria are discussed. The eighth chapter includes analysis. In this chapter, the steps of proposed approach and its structure are introduced. In addition, The analysis results are given in this chapter.

The last chapter is left to the conclusion part. In this part, the analysis results are discussed in detail. Lastly, the contribution and limitations of techniques used in analysis are explained, and the future works are mentioned regarding to EEG signal classifications.

According to analysis results, the ANNs are superior to the multiple logistic regression in terms of classification performance over the EEG signals considering some issues such as model complexity, overfitting and selection of learning algorithm which directly affect the training performance.

Keywords: Epilepsy, Electroencephalogram, Signal Processing, Discrete Wavelet Transform, Artificial Neural Networks, Multiple Logistic Regression, Gradient Based Learning.

ÖNSÖZ

Bu çalışmanın her aşamasında benden yardımını, desteğini, sabrını ve zamanını hiçbir zaman esirgemeyen tez danışmanım Yrd. Doç. Dr. Ozan KOCADAĞLI'ya ve beni her zaman destekleyen anneme ve babama teşekkür ederim.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
ÖNSÖZ	v
ÇİZELGE LİSTESİ	ix
ŞEKİL LİSTESİ	x
KISALTMALAR LİSTESİ	xii
1 GİRİŞ	1
2 LİTERATÜR ARAŞTIRMASI	3
3 AMAÇ VE KAPSAM	6
3.1 GENEL TANIMLAR.....	8
3.1.1 Nöron.....	8
3.1.2 Epilepsi.....	9
3.1.3 Elektroensefalografi (EEG).....	11
3.1.4 Beyin Dalgaları.....	13
4 METADOLOJİ	15
4.1 FOURIER DÖNÜŞÜMÜ.....	15
4.2 DALGACIK TÜRLERİ.....	16
4.2.1 Haar Dalgacık.....	16
4.2.2 Daubechies Dalgacık.....	16
4.2.3 Biortogonal Dalgacık.....	17
4.2.4 Coiflets Dalgacık.....	18
4.2.5 Symlets Dalgacık.....	19
4.2.6 Morlet Dalgacık.....	19
4.2.7 Mexican Hat Dalgacık.....	20
4.2.8 Meyer Dalgacık.....	20
4.3 DALGACIK DÖNÜŞÜMÜ.....	21
4.3.1 Ayrık Dalgacık Dönüşümü.....	22
4.3.2 Sürekli Dalgacık Dönüşümü.....	23
5 YAPAY SİNİR AĞLARI	24
5.1 YAPAY SİNİR AĞLARININ TANIMI.....	24
5.2 YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI.....	25

5.3	YAPAY SİNİR AĞLARININ KULLANIM AMAÇLARI	26
5.4	YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ	27
5.5	YAPAY SİNİR AĞLARININ AVANTAJLARI.....	28
5.6	YAPAY SİNİR AĞLARININ DEZAVANTAJLARI	28
5.7	YAPAY SİNİR AĞININ YAPISI.....	29
5.8	AKTİVASYON FONKSİYONLARI.....	30
5.9	AĞ YAPILARI.....	32
5.10	YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI.....	32
5.10.1	İleri Beslemeli Yapay Sinir Ağları	32
5.10.2	Geri Beslemeli Yapay Sinir Ağları.....	33
5.10.3	Yapay Sinir Ağının Fonksiyonel Gösterimi.....	33
5.11	YAPAY SİNİR AĞLARINDA RİSK FONKSİYONLARI	36
5.12	YAPAY SİNİR AĞLARINDA ÖĞRENME STRATEJİLERİ	37
5.13	YAPAY SİNİR AĞLARINDA ÖĞRENME KURALLARI.....	38
5.14	GRADYAN TABANLI ÖĞRENME ALGORİTMALARI.....	38
5.14.1	En Dik Azalış (Gradient Descent).....	38
5.14.2	Ölçekli Eşlenik Gradyan Algoritması	41
5.14.3	Yarı Newton Metodu (BFGS Quasi-Newton Methods).....	41
5.14.4	Levenberg- Marquardt	41
5.14.5	Lyapunov Üsteli	42
5.15	YAPAY SİNİR AĞLARINDA DURDURMA KRİTERLERİ	42
6	LOJİSTİK REGRESYON	44
6.1	İKİ KATEGORİLİ LOJİSTİK REGRESYON.....	44
6.2	ÇOK KATEGORİLİ LOJİSTİK REGRESYON	45
6.2.1	Çok Kategorili Lojistik Regresyon Model Çıkarımı	46
6.3	LOJİSTİK REGRESYON MODELİNDE MODEL KATSAYILARI SINAMASI	47
6.3.1	6.3.1. Wald Testi	48
6.3.2	Olabilirlik Oran Testleri	48
6.3.2	Modelin Uyum İyiliği	49
7	MODEL SEÇİM KRİTERLERİ.....	50
7.1	AKAİKE BİLGİ KRİTERİ (AIC: AKAIKE INFORMATION CRITERION)	50
7.2	BAYES BİLGİ KRİTERİ (BIC: BAYES INFORMATION CRITERION).....	51
7.3	İŞLEM KARAKTERİSTİK EĞRİSİ (ROC)	51
8	UYGULAMA	53
8.1	VERİ SEÇİMİ VE KAYIT TEKNİKLERİ	53
8.2	ANALİZ ADIMLARI	53
8.2.1	Öznitelik Çıkarma	53
8.2.2	Öznitelik Seçme.....	54
8.2.3	Girdilerin Ölçeklendirilmesi.....	54
8.2.4	YSA'nın Yapısının Belirlenmesi	55
8.3	GRADYAN ALGORİTMALARLA EĞİTİM	58

8.3.1	<i>EN DİK AZALIŞ ALGORİTMASI</i>	58
8.3.2	<i>YARI NEWTON METODU</i>	58
8.3.3	<i>ÖLÇEKLİ EŞLENİK GRADYAN</i>	59
8.3.4	<i>LEVENBERG - MARQUARDT</i>	60
8.3.5	<i>EN İYİ YSA MODELLERİNİN KARŞILAŞTIRILMASI</i>	61
8.4	ÇOK KATEGORİLİ LOJİSTİK REGRESYON	63
8.5	EN İYİ ÇKLR MODELLERİN KARŞILAŞTIRILMASI.....	67
8.6	EN İYİ MODELLERİN KARŞILAŞTIRILMASI	69
9	SONUÇ VE ÖNERİLER	70
	KAYNAKLAR	72

ÇİZELGE LİSTESİ

Sayfa No

ÇİZELGE 5.1 İnsan beyni ile bilgisayar sistemlerinin karşılaştırılması.....	25
ÇİZELGE 5.2 Sinir sistemi ile YSA benzerlikleri	25
ÇİZELGE 5.3 Kullanım amaçlarına göre YSA topolojileri.....	26
ÇİZELGE 8.1 Sınıflamada kullanılan bağımlı ve bağımsız değişkenler	56
ÇİZELGE 8.2 En dik azalış algoritması kullanılarak elde edilen YSA modelleri.....	58
ÇİZELGE 8.3 Yarı Newton Metodu algoritması kullanılarak elde edilen YSA modelleri	59
ÇİZELGE 8.4 Ölçekli eşlenik gradyan algoritması kullanılarak elde edilen YSA modeller	60
ÇİZELGE 8.5 Levenberg-Marquard algoritması kullanılarak elde edilen YSA modelleri	61
ÇİZELGE 8.6 En iyi YSA modellerinin karşılaştırılması.....	61
ÇİZELGE 8.7 Pseudo R-Square tablosu	64
ÇİZELGE 8.8 Sınıflandırma tablosu	64
ÇİZELGE 8.9 Modelin uyum iyiliği	64
ÇİZELGE 8.10 Model uyum bilgisi tablosu	65
ÇİZELGE 8.11 Olabilirlik oran testleri tablosu	66
ÇİZELGE 8.12 En iyi çoklu lojistik regresyon modellerinin karşılaştırılması.....	68
ÇİZELGE 8.13 En iyi modellerin karşılaştırılması.....	69
ÇİZELGE EK 1 A veri setinin ADD katsayılarının parametre değerleri.....	81
ÇİZELGE EK 2 B veri setinin ADD katsayılarının parametre değerleri	81
ÇİZELGE EK 3 C veri setinin ADD katsayılarının parametre değerleri	82
ÇİZELGE EK 4 D veri setinin ADD katsayılarının parametre değerleri.....	82
ÇİZELGE EK 5 E veri setinin ADD katsayılarının parametre değerleri	83

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
ŞEKİL 3.1 Bir nöronun yapısı.....	8
ŞEKİL 3.2 Bir aksiyon potansiyeli.....	9
ŞEKİL 3.3 21 elektrotun yerleştirilmesi için geleneksel 10-20 EEG elektro- pozisyonları.....	12
ŞEKİL 3.4 Epileptik nöbet sırasındaki EEG kaydı	12
ŞEKİL 3.5 Beyin dalgaları	14
ŞEKİL 4.1 Sürekli Fourier Dönüşüm süreci	15
ŞEKİL 4.2 Haar dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi	16
ŞEKİL 4.3 Daubechies dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi .	17
ŞEKİL 4.4 Biortogonal dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi.	18
ŞEKİL 4.5 Coiflet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi.....	18
ŞEKİL 4.6 Symlet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi	19
ŞEKİL 4.7 Morlet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi.....	20
ŞEKİL 4.8 Mexican Hat dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi	20
ŞEKİL 4.9 Meyer dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi	20
ŞEKİL 4.10 Ayrık dalgacık dönüşüm ağacı.....	22
ŞEKİL 4.11 Sürekli Dalgacık Dönüşümü süreci.....	23
ŞEKİL 5.1 Basit YSA yapısı.....	29
ŞEKİL 5.2 Aktivasyon fonksiyonları ve grafikleri	31
ŞEKİL 5.3 İleri beslemeli nöron ağı.....	33
ŞEKİL 5.4 Geri beslemeli nöron ağı	33
ŞEKİL 5.5 Sınıflamada kullanılan çok katmanlı algılayıcı YSA modeli.....	36
ŞEKİL 5.6 Uygun öğrenme parametrelili en dik azalışın, ardışık küçük adımların yol açacağı düşük eğimli bir yüzeyde azalışı.....	40
ŞEKİL 5.7 En dik azalışın ardışık adımlarındaki bir durum için salınımlar	40
ŞEKİL 7.1 İdeal ve kötü performans gösteren testlere ilişkin ROC eğrileri.....	52
ŞEKİL 8.1 Çalışmada kullanılan çok katmanlı algılayıcı YSA modeli	55
ŞEKİL 8.2 YSA'nın akış diyagramı.....	57
ŞEKİL 8.3 En iyi YSA modeline ait ROC eğrileri	62
ŞEKİL 8.4 En iyi YSA modeline ait sınıflama değerleri	63
ŞEKİL EK 1 A sınıfındaki sinyallerin parçalanması.....	83
ŞEKİL EK 2 B sınıfındaki sinyallerin parçalanması	84
ŞEKİL EK 3 C sınıfındaki sinyallerin parçalanması	84

ŞEKİL EK 4 D sınıfındaki sinyallerin parçalanması.....	85
ŞEKİL EK 5 E sınıfındaki sinyallerin parçalanması	85

KISALTMALAR LİSTESİ

EEG	: Elektroensefalogram
ADD	: Ayrık Dalgacık Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü
FD	: Fourier Dönüşüm
KZFD	: Kısa Zamanlı Fourier Dönüşümü
AZFD	: Ayrık Zamanlı Fourier Dönüşümü
YSA	: Yapay Sinir Ağları
MLR	: Çok Kategorili Lojistik Regresyon
ROC	: İşlem Karakteristik Eğrisi
MEG	: Magnetoencefalogram
CT	: Bilgisayarlı tomografi
MRI	: Magnetik Rezonans Görüntüleme
fMRI	: Fonksiyonel Magnetik Rezonans Görüntüleme
PET	: Pozitron Emisyon Tomografi
SPET	: Tek Foton Emisyon Tomografisi
K-means	: K Orta Kümeleme
ÇKA	: Çok Katmanlı Algılayıcı
LVQ	: Öğrenmeli Vektör Kuantulama
PNN	: Olasılıksal Sinir Ağları
GRNN	: Genelleştirilmiş Regresyon Sinir Ağı
RBF	: Radyal Tabanlı Fonksiyon
RTFA	: Radyal Tabanlı Fonksiyon Ağı
TBA	: Temel Bileşenler Analizi
BBA	: Bağımsız Bileşen Analizi
DAA	: Dalgacık Dönüşümü Analizi
DVM	: Destek Vektör Makine
RNN	: Yinelenebilir Sinir Ağları
BIC	: Bilgisayar Arayüzü
MSE	: Hata Kareler Ortalaması

AIC	: Akaike Bilgi Kriteri
AICc	: Düzeltilmiş Akaike Bilgi Kriteri
BIC	: Bayes Bilgi Kriteri
KZDF	: Kısa Zamanlı Fourier Dönüşümü
RBN	: Radyal Tabanlı Yapay Sinir Ağı
PBNN	: Olasılık Tabanlı Ağlar
ÖEG	: Ölçekli Eşlenik Gradyan
BFSG	: Yarı Newton Metodu
ÇKLR	: Çok Kategorili Lojistik Regresyon

1 GİRİŞ

Nöroloji, beyin, beyin sapı, omurilik ve çevresel sinir sistemleriyle kasların hastalıklarını inceleyen bilim dalıdır. Başlıca nörolojik hastalıkların arasında, migren, epilepsi (sara), baş dönmesi, Parkinson, siyatik, beyin kanaması, beyin tümörleri, çevresel sinir hastalıkları, yüz felci bulunmaktadır.

Epilepsi, sinir hücrelerinde geçici anormal elektrik boşalması sonucu ortaya çıkan nörolojik bir bozukluktur ve genelde bilinç kaybına yol açar. Dünyada en sık rastlanan ciddi bir nörolojik hastalık olan epilepsinin dünya çapında yaklaşık olarak 70 milyon insanı etkilediği tahmin edilmektedir. Düşük ve orta gelirli ülkelerdeki epilepsi yaygınlığı, yüksek gelirli ülkelerdekine yaklaşık iki katı kadardır. (Ngugi ve diğ., 2010). Epilepsinin başlıca sebepleri arasında, kafa travmaları, beyin damar hastalıkları ve doğum travması gelmektedir (Wang ve diğ. 2003).

İnsan vücudundan gelen sinyaller ve görüntülerin kazanılması, çeşitli hastalıkların erken tanısı için oldukça önemlidir. Bu tür veriler, elektrobiyolojik sinyaller biçiminde olabilir. Electroencephalogram (EEG) ve magnetoencephalogram (MEG), bilgisayarlı tomografi (CT), magnetik rezonans görüntüleme (MRI) ya da fonksiyonel MRI (fMRI), pozitron emisyon tomografi (PET) ve tek foton emisyon tomografisi (SPET) gibi yöntemlerle beyindeki fonksiyonel ve fizyonal değişiklikler kaydedilebilir (Saeid ve Chambers, 2007).

Kaydedilen sinyaller Avustralya yöntemi, Amerikan (HCM) yöntemi ve İngiliz (webster) yöntemi başta olmak üzere farklı birçok hesaplama yöntemi kullanılarak analiz edilebilir. EEG dalgalarının ayrımı, biçimsel özellikleri, yerleri, hangi koşul ve zamanda ortaya çıktığı doğru değerlendirilmelidir. Özellikle nöbet öyküsünü ve klinik bulgu değerlendirmesi çok önemli olduğu için bu incelemelerin yapılmaması ya da EEG sinyallerinin yanlış değerlendirilmesi sonucu epilepsi olma ya da olmama kararı yanlış verilebilir.

Epilepsi nöbeti beynin kabuk bölgesinde oluşuyorsa, yüzey elektrot yardımıyla, merkezi beyinde oluşuyorsa, kafa içi özel elektrot yardımıyla EEG kaydı oluşturulur

ve normal EEG kaydıyla karşılaştırılır. Kabaca görsel bir değerlendirme yapıldığında, epileptik EEG kaydının, normal EEG kayıtlarına göre çok sayıda diken sinyali içerdiği ve genliğinin fark edilir düzeyde arttığı gözlenir. Diken, çoklu diken, sivri uçlu diken gibi şekillere sahip olan epileptik EEG kaydı, epileptik nöbetlerin beynin hangi kısmında başladığını ve hangi tedavi şeklinin uygulanması gerektiği konusunda bilgi vermektedir. Bazı durumlarda, bir EEG sinyalinde epileptik yapıya, kanalların birinde ve sadece birkaç saniyelik kesitinde rastlanabilir.

EEG incelemesi kısa süreli olduğu için, ilk incelenmede bozukluk saptanmayabilir. Eğer klinik olarak şüpheli ya da tekrarlayan durumlar varsa birden fazla EEG incelenmesi yapılmalıdır ve gerekirse hasta uykusuz bırakılarak (uykusuzluk nöbeti tetikler) kısa ya da uzun süreli uyku incelemeleri yapılmalıdır.

Kaydedilen EEG sinyalleri, Fourier dönüşümü, Dalgacık dönüşümü, güç spektrumu dönüşüm metodu, kümeleme analizi, temel bileşenler analizi, bağımsız bileşenler analizi gibi yöntemler kullanılarak öznitelik çıkarımı yapılır. Daha sonra EEG sinyallerini sınıflandırmak için, yapay sinir ağları, destek vektör makineleri, istatistiksel sinir ağları, karar ağaçları, bayes sınıflandırıcılar gibi yöntemler kullanılır.

Bağımlı değişken kategorik, bağımsız değişken sayısal olduğu için lojistik regresyon analizi yapılmıştır. Ayrıca, bağımlı değişkenin kategori sayısı birden fazla olduğu için ve de lojistik regresyonda doğrusal regresyondaki varsayımlar aranmadığı için çok kategorili lojistik regresyon analizi yapılmıştır.

2 LİTERATÜR ARAŞTIRMASI

Electroencephalogram gibi görüntüleme cihazlarından elde edilen sinyallerin hastalık teşhisi için analiz edilmesi oldukça önemlidir. Elde edilen bu sinyallerin spektral analizi için, Fourier dönüşümü, dalgacık dönüşümü, temel bileşenler analizi, bağımsız bileşen analizi gibi yöntemler kullanılır. Daha sonra elde edilen girdi vektörü, yapay sinir ağları, probabilistic neural network, general regression neural network gibi sınıflayıcılarla sınıflandırılır. Bu çalışmada, EEG cihazından elde edilen sinyaller epilepsi teşhisi için analiz edilmiştir ve kullanılan metodoloji ile ilgili bazı çalışmalar aşağıdaki gibidir.

Rajna (1997), epileptik hastaların klinik prodrom olarak bilinen belli belirsiz algılamalar ile nöbet geçireceği zaman aralıklarının ayarlanabileceğini göstermiştir (Rajna, 1997).

Petrosian ve diğ. (2000), EEG sinyallerini sınıflandırmak için dalgacık parçalanması yapmışlar ve daha sonra Yinelenen Sinir Ağları (RNN) kullanmışlardır. Nöbetlerden yaklaşık bir dakika öncesinde sinyallerdeki değişimin fark edilebilir olduğu sonucuna varmışlardır (Petrosian ve diğ., 2000).

Kıymık (2004), EEG sinyallerindeki epileptik sürecin belirlenmesinde Kısa Zaman Fourier Dönüşümü ve Dalgacık Dönüşümü analiz yöntemlerini kullanmıştır. Dalgacık Dönüşümü'nün Kısa Zamanlı Fourier Dönüşümü'ne göre daha başarılı bir yöntem olduğu sonucuna varmıştır (Kıymık, 2004).

Güler ve diğ. (2005), EEG sinyallerini sınıflandıran RNNs, ileri beslemeli YSA'dan daha yüksek performans göstermiştir (Güler ve diğ., 2005).

Toprak (2007), EEG sinyalleri epilepsi teşhisi için ayırık dalgacık dönüşümü ile sinyal dalgacık katsayılarına (2. seviye ve 4. seviye) ayırılmış ve daha sonra YSA ile sınıflandırma yapmıştır. Farklı dalgacıklar, değişik öğrenme algoritmalarıyla eğitilen farklı yapıdaki ÇKA sinir ağları ve RTFA üzerindeki etkisini incelemiş ve en yüksek sınıflama performansını BFG algoritması ile elde etmiştir (Toprak, 2007).

Özkaya (2007), EEG sinyallerinin rasgele üretilen sinyaller olup olmadığının anlaşılması için EEG işaretlerine zaman serileri uygulamıştır. Epilepsi krizinin tek bir kaynaktan başlayıp yayıldığı sonucuna varmıştır (Özkaya, 2007).

Tzallas ve diğ. (2007), EEG sinyalleri zaman frekans analizine dayanan bir metotla analiz etmişler ve bu analizden elde edilen özellikleri YSA'ya girdi olarak vermişlerdir. Yüksek performanslı sonuçlar elde etmişlerdir (Tzallas ve diğ., 2007).

Gürsoy ve Subaşı (2008), EEG sinyallerine özbağlanımlı (AR) uygulanarak güç spektrumu elde etmişler ve daha sonra elde edilen öznelik vektörleri TBA, BBA ve DAA kullanılarak boyut indirgemesi yapmışlardır. Elde edilen değerleri DVM ile sınıflandırmışlardır. DVM ile yapılan EEG sınıflandırmasında DAA'nın performansının diğerlerine göre daha iyi olduğunu göstermişler. (Gürsoy ve Subaşı, 2008).

Sezer (2008), epilepsi teşhisi için EEG sinyallerini dalgacık dönüşümü ile sinyal dalgacık katsayılarına (4. seviye) ayırmış ve daha sonra YSA ile sınıflandırma yapmıştır. LVQ, PNN, GRNN ve RBF YSA yapılarıyla yüksek başarı elde edilmiştir. Ayrıca Elman ağı ile %95.6'lık bir başarı elde etmiştir (Sezer, 2008).

Diez ve diğ. (2009), EEG sinyallerinden çıkarılan öznelikler Beyin Bilgisayar Arayüzü (BIC) için zihinsel görevler sınıflandırmasında AKA yöntemi kullanarak önemli ölçüde başarı elde etmişlerdir. (Diez ve diğ., 2009).

Orhan (2011), Epileptik aktivitelerin tespiti için ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımını kullandı. EEG sinyallerini hem zaman hem de zaman-frekans boyutunda, eşit genişlikli ayırıklaştırma, eşit frekanslı ayırıklaştırma ve K-means yöntemleri kullanılarak EGA, EFA ve K-means yöntemleri ile ayırttı. Bu yöntemlerin başarı sıralamasının EFA, K-means ve EGA şeklinde elde etmiştir. (Orhan, 2011).

Doğan (2011), epilepsi hastalarına uygulanacak tedavide, mineral madde düzeyleri ve mineral madde değerleri arasında oluşan değişim ve korelasyonların göz önünde bulundurulmasının tedavinin etkinliği açısından önemli olup olmadığını araştırmıştır. Analiz sonucunda, önemli olabileceği sonucuna varmıştır (Doğan, 2011).

Mutlu (2011), mevcut antiepileptik tedavilerine LEV eklenmesi ile nöbet kontrolü sağlanan dirençli epilepsi hastalarının, tedaviye yanıtız hastalara kıyaslanarak klinik

zellik farklılıkları, tedaviye verilen yanıt ve nbet kontroln belirleyen etkenlerin arařtırılmasını amalamıřtır (Mutlu, 2011).

Tekin ve dię. (2011), beynin farklı blgelerinden elde edilen epileptik EEG sinyallerinin analizi iin Dalgacık Dnřm analiz yntemini kullanmıř ve elde edilen zellikleri K-Means kmeleme yntemi ve YSA ile sınıflandırmıřlardır. Geleneksel yntemle uygulanan YSA' ya gre KM-YSA ynteminde daha bařarılı sonular elde etmiřlerdir (Tekin ve dię., 2011).

Yalın (2012), EEG kayıtlarının deęerlendirilip epilepsi teřhisinin yapılabilmesi iin YSA kullanmıřtır. alıřmasında, paracık srs optimizasyonunu ęrenme algoritması geri yayılım algoritması ile kıyaslamıř ve paracık srs optimizasyonunun geri yayılım sinir aęına gre daha yksek performanslı sınıflandırma yaptığı sonucuna varmıřtır (Yalın, 2012).

Yalın ve dię. (2015), EEG kayıtlarının deęerlendirilip sınıflandırma yapılabilmesi iin paracık sr optimizasyon tabanlı yapay sinir aęlarını kullanmıř ve olduka yksek sınıflama bařarıları elde etmiřlerdir (Yalın ve dię., 2015).

3 AMAÇ VE KAPSAM

Elektrotlar yardımıyla elde edilen sinyallerdeki bilgi, epilepsinin teşhisi için oldukça önemlidir. Epileptik sinyal, saniyenin çok küçük bir zamanında ve yüksek frekanslarda ortaya çıkabilir. EEG sinyallerinin kısa sürede algılanıp, frekans ve fazların analiz edilmesi ve sinyalde bilgi kaybı olmaması için sinyali analiz eden Fourier analizi, dalgacık dönüşümü gibi analiz yöntemleri kullanılır.

Üzerinde çalışılan sinyale benzeyen dalgacığa görsel olarak karar vermek pek mümkün olmadığından hangi dalgacık türünün kullanılması gerektiğine karar verme kriterleri kullanılarak karar verilir. Bu çalışmada, daubechies, coiflets ve symlets dalgacık türleri ile farklı analizler yapılmış ve en iyi sonucun coif5 dalgacığı ile elde edildiğı görülmüştür.

Sinyallerin analizi için Fourier Dönüşümü, bir sinyal içinde farklı frekans bileşenlerinden ne kadar bulunduğunu gösterir fakat bu frekans bileşenlerinin zamanın hangi anında bulunduğunun ya da tekrarladığının bilgisini vermediğı için (Mallat, 1999; Strang and Nguyen, 1996), Dalgacık dönüşümünün Fourier dönüşümünden üstün olduğu söylenebilir. Bu yüzden analizde dalgacık dönüşümü tercih edilmiştir.

Ayrık Dalgacık Dönüşümü, sinyali tüm frekans bileşenlerine analiz eden bir filtreleme görevi de görür. ADD ile sinyalin gürültü bileşenleri, uygulanan eşik değerleri ile sınırlanabilir ya da tamamen çıkarılabilir. Daha sonra güncellenen bu sinyal birleştirilir ve gürültüden temizlenmiş olarak özgün sinyal elde edilir. Epileptik EEG işaretleri küçük frekanslarda görülmektedir. ADD, sürekli küçük frekanslarda analiz yaptığı için bu çalışmada tercih edilmiştir.

Bu çalışmanın amacı, farklı YSA yapıları incelenerek, EEG sinyallerini en yüksek performansla sınıflayan YSA yapısını elde etmektir.

En iyi YSA yapısının elde edilmesi için kullanılması gereken bağımsız değişken sayısı ve gözlem sayısı oldukça önemlidir. Kullanılacak bağımsız değişken sayısına

karar vermek için, farklı seviyelerde (2, 3, 4, 5, 6, 7) ADD dönüşümü yapılmıştır. Bu dönüşüm sonucu elde edilen detay ve yaklaşıklık katsayılarının her biri için sırasıyla maksimum, minimum, ortalama, standart sapma, aralık genişliği, medyan ve hausdorff metrik değerleri bulunmuştur. Gözlem sayısına karar vermek için 64, 128, 256, 512 ve 1024 olmak üzere 5 farklı pencere genişliği ile analiz yapılmış ve bu pencere genişliklerinde sırasıyla 32000, 16000, 8000, 4000 ve 2000 gözlem elde edilmiştir.

Ağın öğrenme algoritmasının belirlenmesi için, en dik azalış, yarı Newton metodu, ölçekli eşlenik gradyan ve Levenberg – Marquardt öğrenme algoritmalarıyla denemeler yapılmış ve en yüksek sınıflama performansının hangi algoritma(lar)ca sağlandığı araştırılmıştır.

EEG sinyalinin kompleks yapısından dolayı YSA'lar tercih edilmiş. Bunun nedeni, YSA'ların fonksiyonel yapısı tam olarak bilinmeyen, lineer olmayan ve modellenmesi oldukça zor problemlerin çözümünde iyi sonuçlar vermesidir.

Bu çalışmada, kullanım kolaylığı ve kontrol parametrelerinin azlığı nedeniyle gradyan tabanlı algortimalar tercih edilmiştir. En iyi sınıflama performansı seçilirken, eğitim, test, geçerlilik verileri ve tüm verinin performans değerlerinin yanı sıra AIC, AICc ve BIC bilgi kriterlerinden de yararlanılmıştır. Ayrıca ROC eğrisi de incelenmiştir. Çalışmada, sınıfların (A, B, C, D, E) aynı anda mümkün olan en yüksek sınıflama performansı ile sınıflandırılması amaçlanmıştır.

Çalışmada, Andrzejak ve diğ. (2001) elde edilen EEG sinyalleri kullanılmıştır. Sinyallerin, 173.6 Hz frekans ve 23.6 saniyelik kayıtlar halinde elde edilmesi, sinyallerin kaydı için 10-20 elektrot sisteminin kullanılması, sinyallerin beynin belli bölgeleri ve belli durumlarda alınması, sinyallerin beş bireyden elde edilmesi çalışmanın kısıtları arasında yer almaktadır.

Yukarıdaki literatür araştırmasında da görüleceği gibi, konuyla ilgili yapılan çalışmalar içinde her bir dalgacık için yedi farklı istatistik değeri elde edilmemiştir. Bu çalışmada farklı olarak, coif5 dalgacığında, ölçekli eşlenik gradyan öğrenme algoritması ile en iyi performans elde edilmiştir. Ayrıca farklı olarak, spektral analiz sonucu elde edilen girdi değerleri çok kategorili lojistik regresyon analizi ile analiz edilmiştir.

Bağımlı deęişken kategorik, bağımsız deęişken sayısal olduęu için lojistik regresyon analizi yapılmıştır. Ayrıca, bağımlı deęişkenin kategori sayısı birden fazla olduęu için ve de lojistik regresyonda doğrusal regresyondaki varsayımlar aranmadığı için çok kategorili lojistik regresyon analizi yapılmıştır.

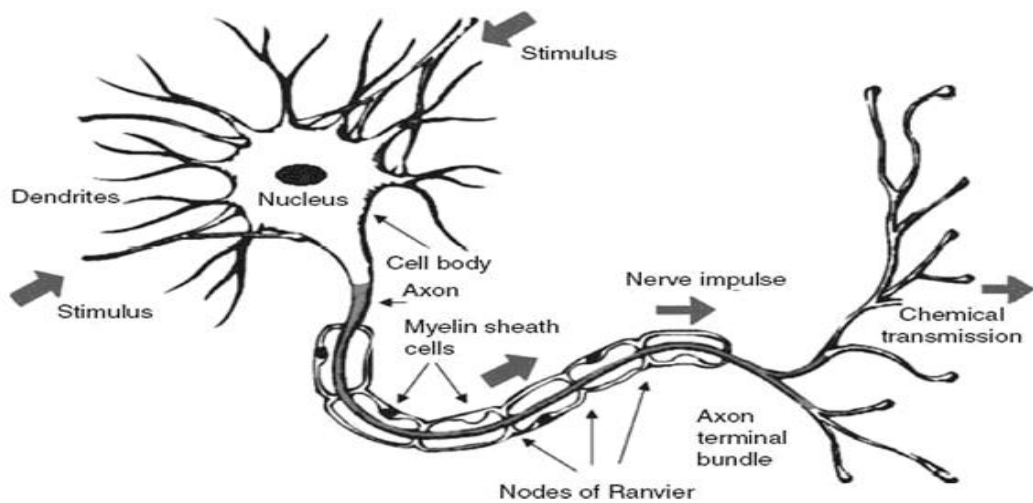
3.1 GENEL TANIMLAR

3.1.1 Nöron

Beyin, merkezi sinir sisteminin yönetim merkezidir (Jensen, 1998). Beyin, ön beyin, orta beyin ve arka beyin olmak üzere 3 temel kısımdan oluşur. Bu kısımlar birbirleriyle haberli ya da birbirlerinden bağımsız olarak görevlerini yerine getirebilirler. Hatırlama, düşünme ve her harekette daha önceki deneyimlere başvurma yeteneğini sağlayan insan beyninin en temel parçası nöronlardır. İnsan beyninde yaklaşık 10^{11} nöron bulunmaktadır. Her bir biyolojik nöronun uyarı aldığı yaklaşık 10.000 komşu bağıntısı vardır (Elmas, 2011).

3.1.1.1 Nöronun Yapısı

Tüm doğal nöronların dendritler, soma, akson ve sinaps olmak üzere 4 temel bileşeni vardır. Biyolojik nöron, diğer kaynaklardan girişleri alır, soma girişleri genelde doğrusal olmayan bir şekilde işler, akson işlenmiş girişleri çıkışa aktarır ve sinaps diğer nöronlara çıkışı gönderir. Nöronlar, çok kutuplu, iki kutuplu, tek kutuplu ve anaksonik olmak üzere sınıflandırılır (Elmas, 2011). Nöronlarda iletimi hızlandıran miyelin yalıtım maddesi olan nöron yapısı kullanılır.




Şekil 3.1 Bir nöronun yapısı (Sanei, 2013; Attwood ve Mackay, 1989)

3.1.1.2 Biyolojik İşaretlerin Oluşumu

Bir nöronun sinapsa işaretlerinin taşınması kimyasal bir süreçtir. Özel verici maddeler birleşmeden sonra giden son işaretle serbest kalır ve eğer alınan işaret hücrenin içindeki elektrik potansiyelinden küçükse etki ortaya çıkmaz ve eğer alınan işaret hücrenin içindeki elektrik potansiyelinden büyükse etki ortaya çıkar. Potansiyel bir eşik değerine ulaşırsa akson içine bir işaret gönderir ve buna da hücrenin uyarılması denir. Nöronun görevi, sinaps boyunca dendrite ulaşan uyarıları alıp, bunlardan aksiyon potansiyeli oluşturmak ya da oluşturmamaktır (Elmas, 2011).

İki hücrenin birbirleriyle bilgi alışverişi sinaptik bağlantılarda nörotransmitterler yoluyla yapılır. (Öztemel, 2012). Bir nöronun yüzey zarının iç ve dış tarafında potansiyel fark vardır. Komşu nöronun sinapsından gönderilen nörotransmitter kimyasal işaretler nöronun zar potansiyelini ayarlar ve sinapslar darbe-kodlu elektriksel sinirsel işaretleri nörotransmitter işaretlere dönüştürür (Elmas, 2011).



Şekil 3.2 Bir aksiyon potansiyeli (Sanei, 2013; Peter ve diğ., 2002)

3.1.2 Epilepsi

Epilepsi, ani bir paroksizmal nöronal ateşleme meydana gelmesiyle karakterize edilen yaygın bir nörolojik bozukluktur. En sık görülen merkezi sinir sistemi hastalığıdır (Vecchio ve diğ., 2014). Dünya nüfusunun yaklaşık %1'inde görülür.

Epilepsi çocukluk çağında ve yetişkinlikte en yüksek düzeyde iken erken erişkinlikte daha düşük düzeydedir (Zupec-Kania ve Spellman, 2009). Doğuştan gelen hastalıklar, doğum sonrası meydana gelen menenjit, beyin iltihabı, kazalarda meydana gelen beyin zedelenmesi gibi durumlar epilepsiye neden olabilir. Epilepsinin cerrahi ve ilaçlı tedavisi mümkündür.

3.1.2.1 Epileptik Nöbet

Epileptik nöbet, inme, senkop, psikojenik nöbet, öfke patlaması gibi aniden ortaya çıkan nörolojik bir olaydır (Blume ve diğ., 2001). Uluslararası epileptik nöbet sınıflamasına göre epileptik nöbetler 2 temel sınıfta incelenir;

- i. parsiyel nöbetler: EEG değişikliklerinin, başlangıçta bireyin hemisferinin bir kısmındaki sınırlı bir nöronlar sisteminin aktivasyonunu gösteren epileptik nöbettir (Epilesia, 1981). Parsiyel nöbetler, ilk olarak nöbet sırasında bilinç bozulup bozulmamasına göre sınıflandırılır. Eğer bilinç bozulmuyorsa *basit parsiyel nöbet*, bilinç bozuluyorsa *kompleks parsiyel nöbet* denir. Kompleks parsiyel nöbet, ilk klinik bulgu olarak bilinç bozukluğu ile başlayabilir ya da basit parsiyel nöbet kompleks parsiyel nöbete dönüşebilir. Ayrıca, basit parsiyel nöbetlerde çoğunlukla tek taraflı nadiren çift taraflı hemisfer tutulumu olmasına karşın, kompleks parsiyel nöbetlerde genellikle çift taraflı hemisfer tutulumu olduğuna dair güçlü kanıtlar bulunmaktadır. Bilinç bozulduğunda, hastada bazı davranış sapmaları yani otomatizmalar görülebilir. Bir parsiyel nöbet durmayabilir ve jeneralize motor nöbete ilerleyebilir (Yiğit, 2008).
- ii. jeneralize nöbetler: Başlangıç semiyolojisinin (gösterge bilimi), her iki beyin hemisferinde, minimalden çok daha fazla tutulma gösterdiği epileptik bir nöbettir (Blume ve diğ., 2001). Jeneralize nöbetlerde ilk gösterge olarak bilinç bozukluğu görülebilir. Motor gösteriler çift taraflı olur. İktal EEG görüntüleri, ilk başta çift taraflıdır ve her iki hemisferde yaygın nöronal boşalım görülür (Epilesia, 1981).
- iii. sınıflanmayan nöbetler: Uygun ve tam olmayan veriler içeren ve de yukarıdaki tanımlanan sınıflara uymayan epileptik nöbetlerdir. Ritmik göz hareketleri, çiğneme ve yüzme hareketleri gibi bazı yenidoğan nöbetleri örnek verilebilir (Epilesia, 1981).


3.1.3 Elektroensefalografi (EEG)

Elektroensefalografi beynin elektriksel aktivitelerini kaydeden (Taywade ve Raut 2012) ve genellikle nöbet değerlendirilmesi için kullanılan gerekli tanı aracıdır. Özellikle, sinyalin epileptik olup olmadığı, epilepsinin hangi türü olduğu, antiepileptik bir tedavi uygulanırsa etkisinin ne olacağı (özellikle epileptik durumda tedavi ile durdurulabilir mi?) gibi sorulara cevap vermek için EEG kullanılır (Fowle ve Binnie, 2000).

EEG, 1929'da Alman ruh hekimi Hans Berger tarafından geliştirilmiştir. Uyanık dinlenme durumunda çekilen standart EEG, genelde 20-30 dakika sürer ve 3 dakikalık derin soluma ve aralıklı ışık uyarımı ile aktive edilir. Eğer gerekiyorsa, uyku sırasında da EEG çekilebilir. EEG, klinik epilepsi tanısının doğrulanmasının yanı sıra, jeneralize ve fokal epilepsilerin ayırımında da yararlıdır. Fakat eğer ayrıntılara dikkat edilmezse EEG'nin kötüye kullanımı da mümkündür (Fowle, 2000). Antiepileptik ilaç tedavisi nöbet döneminden sonra kesilirse, EEG nöbetin tekrarlama olasılığını tahmin etmek için kullanılabilir (Pillai and Sperling, 2006).

3.1.3.1 EEG Kayıt ve Ölçümü

Elektrotlar saçlı deriye pasta denilen iletken bir madde aracılığıyla yerleştirilerek EEG çekimi yapılır. Elektronlar arasındaki potansiyel değişiklikler bilgisayara kaydedilir ve sonuçlar yorumlanır. EEG'de elektrot yerleşimi, 1958'de Uluslararası Federasyon tarafından kabul edilen 10-20 elektrot yerleştirme sistemi olarak kabul edilen standardizasyona göre yapılır:



Şekil 3.3 21 elektrotun yerleştirilmesi için geleneksel 10-20 EEG elektrot pozisyonları (Jasper, 1958; Saeid ve Chambers, 2007; Taywade ve Raut, 2012)


F: Ön kısım lobları

T: Şakağa ait loblar

C: Merkezi (orta) loblar

P: Parietal (kafatası yan kemiği) loblar

O: Oksipital (kafanın arka kısmına ait) loblar



Şekil 3.4 Epileptik nöbet sırasındaki EEG kaydı (Duran, 2010; Lee, 2010)

Yukarıdaki şekilde, EEG sinyalinin nöbet sırasındaki değişiklikleri zaman alanında görülür. Genelde olduğu gibi, 3 Hz frekansında diken şeklindeki bir sinyal aniden ortaya çıkar ve birkaç saniye sonra kaybolur (Lee, 2010).

3.1.4 Beyin Dalgaları

EEG geniş bir frekans bileşen alanına sahiptir. Frekans, dalganın birim zamandaki tekrarının bir ölçümüdür. Genlik ise, bir dalganın tepesi ile çukuru arasındaki düşey uzunluğun yarısıdır.

3.1.4.1 Gama Dalgası

Frekansı 30 Hz nin üzerinde olanlar (genelde 45 Hz ye kadar) gamma aralığıdır (bazen hızlı beta dalgası olarak adlandırılır). Bu ritmin genliği çok düşük olmasına ve nadiren meydana gelmesine rağmen, bu ritimlerin tespiti bazı beyin hastalıklarının anlaşılması için kullanılabilir. Yüksek EEG frekans bölgeleri ve serebralin en yüksek seviyelerinde kan akışı (oksijen ve glikoz alımının yanı sıra) frontosantral bölgede yer almaktadır (Pfurtscheller ve diğ., 1994).

3.1.4.2 Beta Dalgası

Beta dalgası, genelde odaklanmış dikkat, zihinsel iş, duyuşal enformasyon işleme, uykunun hızlı göz hareketleri gibi beynin en yüksek aktivite düzeyinde ve normal yetişkinlerde görülür. İnsan panik durumundayken bir üst düzet beta dalgası elde edebilir. Frekans aralığı 14-26 Hz dir. Genliği, normalde 30 μ V un altındadır (Serman ve diğ., 1974).

3.1.4.3 Alfa Dalgası


Alfa dalgası, beynin posterior yarısında ve genellikle beynin occipital bölgesinden alınan kayıtlarda belirgin biçimde gözlenir. Bireylerin, fiziksel ve zihinsel olarak tam dinlenme durumunda olduđu, dış uyarıların olmadığı ve çoğunlukla gözlerin kapalı olduđu durumlarda görülür. Frekans aralığı 8-13 Hz dir ve yuvarlak ya da sinüzoidal olarak şekillenen sinyalleri yaygın görülür. Alfa dalgası, occipital alanlar üzerinde 50 μ V den az olan yüksek genliğe sahiptir (Sanei ve Chambers, 2007).

3.1.4.4 Teta Dalgası

Teta dalgası, bireylerde rüyalı uyku, orta derinlikteki anestezi, derin meditasyon gibi beynin düşük aktivite gösterdiği durumlarda görülür. Bebeklikte ve çocukluk çağında önemli bir rol oynar. Uyanık yetişkinlerde, teta dalga aktivitesinin büyük miktarı, normal değildir ve çeşitli patolojik sorunlarda kaynaklanır. Frekans aralığı, 4-8 Hz dir. Genliği, 5- 100 μ V arasındadır (Ashwal ve Rust, 2003).

3.1.4.5 Delta Dalgası

Delta dalgası, genelde, derin uykuya ilişkilendirilir ve uyanık durumda da görülebilir. Beynin çok düşük aktivite gösterdiği durumlarda görülür. EEG verilerine basit sinyal analiz yöntemleri uygulayarak, aşırı hareketten kaynaklanan cevap çok kolay görülür. Frekans aralığı, 0.5- 4 Hz dir. Genliği, 20-400 μ V arasındadır. Bir delta dalgası diğer frekanslarla ve uyarılma düzeyi ile ilişkili görünür (Ashwal ve Rust, 2003).



Şekil 3.5 Beyin dalgaları (Sanei ve Chambers, 2007)

4 METADOLOJİ

4.1 FOURIER DÖNÜŞÜMÜ


Fourier dönüşüm, sürekli olarak tanımlanan fonksiyonlar için kullanılan matematiksel bir yöntemdir. Fourier dönüşüm, zaman tanım kümesindeki bir işaretin frekans içeriğini analiz etmede büyük yarar sağlar. Bu dönüşüm, önce tanım kümesi zaman olan bir fonksiyonu, tanım kümesi frekans olan bir fonksiyona çevirir. Böylece sinyalin frekans içeriği incelenir.

Zamansız $x(t)$ fonksiyonu için Fourier dönüşümü,

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega) e^{i\omega t} d\omega \quad (4.1)$$

$$X(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} x(t) e^{-i\omega t} dt \quad (4.2)$$

Gibidir. Burada w , temel frekanstır. Fourier dönüşümü, değişim olmadan, bir süre içinde kendini tam tekrarlayacak sabit periyodik fonksiyonların analizi için uygundur. Fourier dönüşümü tekniği sabit sinyal işlemede çok önemli bir tekniktir (Vernekar, 2014). Sürekli Fourier dönüşüm süreci Şekil 4.1 de gösterilmiştir.



Şekil 4.1 Sürekli Fourier Dönüşüm süreci (Misiti ve diğ., 2009)

kısa zamanlı fourier dönüşümü: Kısa zamanlı Fourier dönüşümü (KZDF), zamanla değişen olarak bir sinyalin belli kısımlarının faz içeriği ve sinüzoidal sıklığını belirlemek için kullanılan bir Fourier dönüşümdür (Sejdic ve diğ., 2009).


ayrık zamanlı fourier dönüşümü: Ayrık zamanlı fourier dönüşümü, 2π periyodu ile periyodiktir. Analizi için 2π 'lik bir temel aralığın incelenmesi yeterlidir (Ertürk, 2005).

4.2 DALGACIK TÜRLERİ

Dalgacık, konum ve ölçeklendirmede belirli bir işlevi yerelleştirmek için kullanılan fonksiyonların bir sınıfıdır. Sinyal işleme ve zaman serisi analizleri gibi uygulamalarda kullanılır. Dalgacık, aynı zamanda, farklı frekans bileşenlerindeki operatör ya da fonksiyonların verisini kesen dalgacık dönüşümünün temel formudur (Daubechies, 1992). Dalgacık türleri aşağıdaki gibidir (Misiti ve diğ., 2009; Chan and Shen, 2005).

4.2.1 Haar Dalgacık

Dalgacıkların herhangi bir konusu, ilk ve en basit olarak Haar dalgacıkla başlar. Haar dalgacık düzensizdir ve bir adım fonksiyona benzer. Bu Daubechies db1 ile aynı dalgacığı temsil eder. Haar dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.2 de verilmiştir.




Şekil 4.2 Haar dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

4.2.2 Daubechies Dalgacık

Ingrid Daubechies tarafından bulunan ve sıkıştırılmış destekli ortonormal dalgacıklar olarak adlandırılan dalgacık sayesinde ayrık dalgacık analizi için uygulanabilir hale geldi.

Daubechies tür dalgaların isimleri dbN olarak yazılır. N, sıra numarasıdır ve db dalgacığının soyadıdır. db1 dalgacığı, yukarıda bahsedildiğı gibi Haar dalgacığının

aynısıdır. Daubechies dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.3 de verilmiştir.



Şekil 4.3 Daubechies dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)


Db4 dalgacığı için fonksiyonu için, sıkıştırmanın (daralma ya da genişleme) derecesini ölçen a ölçeklendirme parametresi ve zaman ekseninde ana dalgacığın yerini belirleyen b dönüşüm parametresi aşağıdaki gibidir (Walker, 1999):

$$a_1 = \frac{1+\sqrt{3}}{4\sqrt{2}}, a_2 = \frac{3+\sqrt{3}}{4\sqrt{2}}, a_3 = \frac{3-\sqrt{3}}{4\sqrt{2}}, a_4 = \frac{1-\sqrt{3}}{4\sqrt{2}} \quad (4.3)$$

$$\beta_1 = \frac{1-\sqrt{3}}{4\sqrt{2}}, \beta_2 = \frac{\sqrt{3}-3}{4\sqrt{2}}, \beta_3 = \frac{3+\sqrt{3}}{4\sqrt{2}}, \beta_4 = \frac{-1-\sqrt{3}}{4\sqrt{2}} \quad (4.4)$$

4.2.3 Biortogonal Dalgacık


Dalgacıkların bu türü, sinyal ve görüntüyü yeniden yapmak için gereken lineer fazın özelliğini gösterir. Tek tek aynısının yerine, solda ayrıştırma için ve sağda yeniden yapılandırma için iki dalgacık kullanarak farklı özellikleri üretir. Biortogonal dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.4 de verilmiştir.



Şekil 4.4 Biortogonal dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

4.2.4 Coiflets Dalgacık

Daubechies tarafından coiflet dalgacık fonksiyonu, sıfıra eşit $2N$ momente ve ölçeklendirme fonksiyonu sıfıra eşit $2N-1$ momente sahiptir. İki fonksiyon $6N-1$ uzunluğunu destekler. Coiflet dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.5 de verilmiştir.



Şekil 4.5 Coiflet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

Coif dalgacıđı da Daubechies'e benzer şekilde ifade edilebilir. Coif6 dalgacıđı için fonksiyonu için, sıkıştırmanın (daralma ya da genişleme) derecesini ölçen a ölçeklendirme parametresi ve zaman ekseninde ana dalgacıđın yerini belirleyen b dönüşüm parametresi aşağıdaki gibidir (Walker, 1999):


$$a_1 = \frac{1-\sqrt{7}}{16\sqrt{2}}, a_2 = \frac{5+\sqrt{7}}{16\sqrt{2}}, a_3 = \frac{14+2\sqrt{7}}{16\sqrt{2}}, a_4 = \frac{14-2\sqrt{7}}{16\sqrt{2}}, a_5 = \frac{1-\sqrt{7}}{16\sqrt{2}}, a_6 = \frac{-3+\sqrt{7}}{16\sqrt{2}} \quad (4.5)$$

$$\beta_1 = a_6, \beta_2 = -a_5, \beta_3 = a_4, \beta_4 = -a_3, \beta_5 = a_2, \beta_6 = -a_1 \quad (4.6)$$

Daha üst seviyeler için yaklaşıklık katsayıları benzerdir. Fakat doğruluk genelde düzey sayısı arttıkça azalır. Bu dalgacıklar, orijinal sinyal ile trend değerleri arasında sürdürülebilir yakın bir eşleşme amacıyla tasarlanmıştır. Coif6 dönüşümü, altsinyaller ve orijinal dalga arasında DaubJ dönüşümleriyle elde edilebilenden çok daha yakın bir eşleşme üretir (Walker, 1999).

4.2.5 Symlets Dalgacık


Daubechies tarafından önerilen Symletler, db türlerine farklılık olarak yaklaşık simetrik dalgacıklardır. İki dalgacık türünün özellikleri benzer. Symlet dalgacık türüne ait zaman-genlik gösterimi Şekil 4.6 da verilmiştir



Şekil 4.6 Symlet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diđ., 2009)

4.2.6 Morlet Dalgacık


Morlet dalgacıđın ölçekleme fonksiyonu yoktur ama belirgindir. Morlet dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.7 de verilmiştir.



Şekil 4.7 Morlet dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

4.2.7 Mexican Hat Dalgacık


Mexican Hat dalgacığının, ölçekleme fonksiyonu yoktur ve Gauss olasılık yoğunluk fonksiyonunun ikinci türev fonksiyonuna orantılı bir fonksiyondan elde edilmiştir. Mexican Hat dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.8 de verilmiştir.



Şekil 4.8 Mexican Hat dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

4.2.8 Meyer Dalgacık

Meyer dalgacığı ve ölçekleme fonksiyonu frekans alanında tanımlanır. Meyer dalgacık ailesine ait zaman-genlik gösterimi Şekil 4.9 da verilmiştir



Şekil 4.9 Meyer dalgacık ailesine ait fonksiyonların zaman-genlik gösterimi (Misiti ve diğ., 2009)

4.3 DALGACIK DÖNÜŞÜMÜ

Dalgacık dönüşümü, öznitelik uzayında bir sinyali hiyerarşik bir ölçek frekansına dahil eden çok çözünürlüğü ve dönüşen katsayılardan optimum varyans dağılımına en uygun olanı gösterir (Jain, 1986). Dalgacık dönüşümü, farklı frekanslarda durağan olmayan yapıda zaman serisi sinyallerinin analizinde kullanılabilir (Proch'azka ve diğ., 1994) ve sinyalin dalgacığın zaman ekseninde kaydırılması ve boyutunun değiştirilmesi ile elde edilen fonksiyonu ayırıştırır. Temelde dalgacık dönüşümü, düzgün ve sürekli tekrar eden frekans eksenini parçalar ve kendi ölçeğinde uygun bir çözünürlüğe sahip her bölümü (frekans bandını) analiz eder (Daubechies, 1992).

Dalgacık dönüşümü, düşük frekanslar için geniş, yüksek frekanslar için dar olarak değişen pencere boyutları oluşturduğu için, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğünü sağlayabilir (Zhang ve diğ. 2001; Übeyli ve İnan, 2003).

Jean Morlet 1982'de, dalgacık dönüşümü fikrini hayata geçirmiş ve sismik dalga analizi için yeni bir matematiksel yöntem geliştirmiştir. Morlet, başlangıçta dalgaları dönüşümden elde edilen fonksiyonların bir ailesi olarak düşünmüş ve tek fonksiyonlu bir germe ya da genişletme işlemine "ana dalga" $\Psi(t)$ adını vermiştir (Sifuzzaman ve diğ., 2009). Dalgacık dönüşümü eşitliği aşağıdaki gibidir (Grossmann ve Morlet, 1984).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), \quad a, b \in \mathbb{R}, a \neq 0 \quad (4.7)$$

Yukarıdaki formülde, a parametresi, ölçeklendirme parametresi ya da ölçektir ve sıkıştırmanın (daralma ya da genişleme) derecesini ölçer. b parametresi, zaman ekseninde ana dalgacığın yerini belirleyen dönüşüm parametresidir. Eğer $|a| < 1$ ise, o zaman (4.7) deki dalgacık, ana dalganın sıkıştırılmış halidir (zaman-etki alanını daha az destekleyen) ve özellikle daha yüksek frekanslara karşılık gelir. Diğer taraftan $|a| > 1$ olduğunda, o zaman $\psi_{a,b}(t)$, $\psi(t)$ den daha büyük bir zaman genişliğine sahiptir ve daha düşük frekanslara karşılık gelir. Sonuçta, dalgacık-zaman genişlikleri kendi frekanslarına adapte olmuştur. Bunun temel nedeni ise, zaman-frekans sinyal analizi ve sinyal işlemede Morlet Dalgacıklarının başarısıdır (Sifuzzaman ve diğ., 2009). Ayrıca, dalgacık dönüşümü geleneksel yöntemlerle

sadece iki tane aj adımı kalana kadar ADD yapılabilir. Bu adımlara fonksiyon ölçekleme katsayıları denir (Mallat, 1998).


Dalgacık dönüşümü, son dönemde tıbbi alanlarda özellikle EEG, EKG, EMG, MRG, BT gibi medikal işaretlerin sınıflandırılmasında da kullanılmaktadır.

4.3.2 Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü, zamanın bir fonksiyonu olarak sinyalin frekans içeriğini gösteren spectogramlar için kullanılır. $x(t)$ fonksiyonunun sürekli zaman dalgacık dönüşümü, aşağıdaki gibidir:

$$X_{\psi}(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \Psi^* \left(\frac{t-b}{a} \right) dt, \quad a, b \in R, a \neq 0 \quad (4.10)$$

Yukarıdaki eşitlikte $\Psi(t)$, zaman alanında sürekli bir fonksiyondur. Ψ^* , analiz edilen dalganın $\Psi(t)$ kompleks eşleniğini içerir. a parametresi, ölçekleme parametresi ve b parametresi de öteleme parametresi olarak adlandırılır. $X_{\psi}(a, b)$ dönüştürülmüş sinyali, öteleme parametresi b ve ölçekleme parametresi a nın bir fonksiyonudur (Vernekar ve diğ., 2014). Sürekli Dalgacık dönüşümü süreci Şekil 4.11 de verildiği gibidir.



Şekil 4.11 Sürekli Dalgacık Dönüşümü süreci (Misiti ve diğ., 2009)

5 YAPAY SİNİR AĞLARI

5.1 YAPAY SİNİR AĞLARININ TANIMI

Yapay sinir ağı (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığı ile birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır (Elmas, 2011). Bir başka deyişle yapay sinir ağı, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzeyen bazı performans özellikleri olan bir bilgi işleme sistemidir (Fausett, 1994).

Yapay sinir ağı, normal olmayan, belirsiz bilgileri işleyebilen güçlü bir problem çözme tekniği olmasının yanı sıra insan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda da başarılı bir şekilde uygulanır. YSA, bir girdi setini (örnekleri) alarak onları çıktı setine çevirir. Bunun için ağına, kendisine gösterilen girdilere doğru çıktılar üretebilmesi yani eğitilmesi gerekir (Öztemel, 2012).

YSA, özellik çıkarımı ve sınıflama için doğrusal olmayan algoritmaların yeni bir versiyonudur. Dahası, mevcut özellik çıkarımı ve sınıflama algoritmaları YSA'da etkili bir uygulamadır (Basu ve diğ., 2010).

Sinir hücreleri, insan beyninin hatırlama, düşünme, her harekette daha önceki deneyimlere başvurma yeteneğini sağlayan en temel hücrelerdir (Elmas, 2011). Biyolojik sinir ağı beyinde bulunan milyarlarca sinir hücresinin bir araya gelmesiyle oluşur. Sinir hücreleri birbirleri ile bağlanarak fonksiyonlarını yerine getirirler. Beyinde yaklaşık 10^{10} adet sinir hücresi ve bunlarında 6×10^{13} ten fazla sayıda bağlantısının olduğu söylenir. Biyolojik sinir ağlarının performansları çok yüksek olmakla beraber, karmaşık olayları işleyebilir. YSA ile bu yeteneğin bilgisayar sistemlerine kazandırılması amaçlanır (Öztemel, 2012).

Çizelge 5.1 İnsan beyni ile bilgisayar sistemlerinin karşılaştırılması (Crone, 2004)

<i>Özellikler</i>	<i>İnsan Beyni</i>	<i>Bilgisayar</i>
İşlemci Hızı	10^{-3} ms (0.25 MHz)	10^{-9} ms (2500 MHz)
Nöron/ Transistör	10^{11} & 10^{33} bağlantı	10^{19} Yonga
Ağırlık	1500 gr.	Kilogramlarca
Enerji Tüketimi	10^{-16} Joule	10^{-6} Joule
Hesaplama	100 Adım	Milyarlarca Adım

Üçüncü ünite de detaylı anlatıldığı gibi nöronlar, dendritler, soma, akson ve sinaps olmak üzere 4 temel bileşenden oluşur. Temel olarak biyolojik sinir diğer kaynaklardan girişleri alır, soma girişleri genelde doğrusal olmayan bir şekilde işler. Akson girişleri çıkarır. Sinaps diğer sinirlere çıkışı gönderir. Bir yapay sinir ağı, birbirleriyle bağlantılı, çok sayıda düğümden oluşur ve biyolojik sinirlere göre daha basit olmasına rağmen, biyolojik sinirlerin 4 temel işlevini taklit etmektedir (Elmas, 2011). Sinir sistemi ile YSA benzerlikleri Çizelge 5.2 de ifade edildiği gibidir.

Çizelge 5.2 Sinir sistemi ile YSA benzerlikleri

Sinir Sistemi	YSA sistemi
Nöron Dendrit Hücre gövdesi Aksonlar Sinapslar	İşlem elemanı Toplama fonksiyonu Transfer fonksiyonu Eleman çıkışı Ağırlıklar

5.2 YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI

YSA'da, ilk olarak 1890'da insan beyninin yapısı ve fonksiyonları ile ilgili yayın yazılmıştır. Daha sonra 1943'te insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellenmiştir. 1957'de Perceptron, 1970'de geriye yayılım algoritması, 1982'de çok katmanlı algılayıcılar geliştirilmiştir. YSA ile ilgili çalışmalar hala sürmektedir.

YSA'lar doğrusal olmayan sistemlerde kullanılmalarının yanı sıra, bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu çok değişik problemlerin çözümünde de kullanılmaktadır. YSA'larının başlıca uygulama alanları sınıflama, tahmin ve modelledir. Denetim, ses tanıma, el yazısı tanıma, parmak izi tanıma, otomatik

araç denetimi, fizyolojik işaretleri izleme, tanıma ve yorumlama gibi alanlarda da YSA'dan faydalanılır (Elmas, 2011).

5.3 YAPAY SİNİR AĞLARININ KULLANIM AMAÇLARI

YSA'nın kullanım ve uygulama alanlarından önceki bölümde bahsedilmiştir. Bu bölümde YSA'nın kullanım amaçlarına göre kullandıkları topolojiler Çizelge 5.3 de verildiği gibidir.

Çizelge 5.3 Kullanım amaçlarına göre YSA topolojileri (Anderson ve McNeill, 1992)

<i>Kullanım Amaçları</i>	<i>Uygulanılan Ağ Topolojileri</i>
Tahmin – Öngörü	<ul style="list-style-type: none"> • Geri Yayılım • Yönlendirilmiş Rassal Tarama • Yüksek Dereceli Sinir Ağları • Geri Yayılım İçinde SOM • Radyan Tabanlı Fonksiyon • Elman Ağı • Jordan Ağı
Fonksiyon Yaklaşırma	<ul style="list-style-type: none"> • Geri Yayılım • Radyan Tabanlı Fonksiyon
Desen (Örüntü) Sınıflandırma	<ul style="list-style-type: none"> • Öğrenme Vektörü Nicelendirme • Uyarlanır Rezonans Ağı • Olasılık Tabanlı Ağlar • Tek veya Çok Katmanlı Algılayıcı • Boltzmann Makinesi • Radyan Tabanlı Fonksiyon
Veri İlişkilendirme	<ul style="list-style-type: none"> • Kohonen's SOM • Hopfield Ağları • Boltzmann Makinesi • Hamming Ağları • Çift Yönlü İlişki Hafıza • Spatio- Temporal Desen Tanıma • Uyarlanır Rezonans Ağı
Kavramlaştırma / Kümeleme	<ul style="list-style-type: none"> • Öğrenme Vektörü Nicelendirme • Özörgütlemeli Harita Ağı • Uyarlanır Rezonans Ağı
Veri Filtreleme	<ul style="list-style-type: none"> • Yeniden Dolaşım
Optimizasyon	<ul style="list-style-type: none"> • Geri Yayılım • Olasılık Tabanlı Sinir Ağları • Radyan Tabanlı Fonksiyon
Kontrol	<ul style="list-style-type: none"> • Geri Yayılım • Öğrenme Vektörü Nicelendirme • Radyan Tabanlı Fonksiyon

5.4 YAPAY SINIR AĞLARININ GENEL ÖZELLİKLERİ

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Aşağıda bütün modeller için geçerli olan genel karakteristik özellikler verilmiştir.

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Programları, çalışma stili bilinen programlama yöntemlerine benzerler.
- YSA'da bilgi ağın bağlantılarının değerleri ile ölçülür ve bağlantılarda saklanır.
- YSA örnekleri kullanarak öğrenirler.
- YSA'nın güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler.
- Hata toleransına sahiptirler.
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dereceli bozulma gösterirler.
- Dağıtık belleğe sahiptirler.
- Sadece nümerik bilgiler ile çalışabilirler.
- Paralel yapılarından dolayı hızlı çalışabilirler.

(Öztemel, 2012; Sağıroğlu ve diğ., 2003; Haykin, 1994).

5.5 YAPAY SİNİR AĞLARININ AVANTAJLARI

- YSA önceki deneyimlerden öğrenebilir, bir kez eğitildiklerinde yeni bir veri kümesine hemen cevap verebilir. Bir örnekten hareket ederek diğer örnekleri açıklayabilir.
- YSA matematiksel modele ihtiyaç duymaz. Yapay sinir ağı yazınında verilerin yapay sinir ağının eğitiminde kullanılması için gerekli bir varsayıma rastlanmamıştır.
- YSA verilerden hareketle bilinmeyen ilişkileri akıllıca hemen ortaya çıkarabilir. Ağların bu özelliği, uygulama açısından önemlidir.
- Geleneksel bilgisayar sistemleri, sistemde oluşacak hatalara karşı çok hassastır. Sistemde meydana gelebilecek en ufak bir hata sonuca ulaşamama ya da sonuçlarda büyük hataya yol açabilir. Ancak YSA'nın bir veya birkaç nöronunun zarar görmesi sistemi geleneksel bilgi işlem teknolojilerinde olduğu kadar etkilemez.
- Ağ ağırlık katsayısı ve yapısı gibi kendi parametreleri değiştiğinde somut bir problemin çözümü için kendini adapte edebilme özelliğine sahiptir.
- Ağlar doğrusal değildir. Bu nedenle karmaşık problemleri doğrusal tekniklerden daha doğru çözebilirler. Doğrusal olmayan davranışlar hissedilir, algılanır ve bilinebilir. Ancak, bu problemleri ve davranışları matematiksel olarak çözmek zordur (Tolon ve Tosunoğlu, 2008; Garver, 2002).


5.6 YAPAY SİNİR AĞLARININ DEZAVANTAJLARI

- Probleme uygun ağ mimarisinin belirlenmesi (ara katman sayısı, burada bulunacak sinir sayısı), toplama ve aktivasyon fonksiyonlarının belirlenmesi, öğrenme kuralının ve eğitiminin ne zaman sonlandırılacağı belirlenmesi için geliştirilmiş bir kural bulunmamaktadır. Bunlar yapılan analizler ve ağ tasarımcısının öngörülleri sonucu belirlenir. Bu yüzden YSA, en iyi çözümü garanti edemez bunun yerine kabul edilebilir çözümler üretir.
- Yapay sinir ağlarının davranışlarının açıklanamaması, yönetime getirilen en önemli eleştiridir (black box yakıştırması). YSA'lar, bir probleme çözüm

ürettiği zaman, bu çözüm için sorulacak nasıl ve neden sorularına cevap veremezler yani açıklama yetenekleri yoktur (Şen, 2004).

5.7 YAPAY SİNİR AĞININ YAPISI

Temel olarak yapay sinir ağlarında, giriş katmanı dış çevreden gelen uyarıları alırken, son katman ağ yapısında işlenen bu uyarıcılara karşılık gelen çıkışları üretir. Genelde bu iki katman arasında birkaç gizli katman vardır. Gizli katmanlar nöronlardan oluşmaktadır ve bu nöronlar aşırı kompleks fonksiyonel yapılara yol açmamalı ve ağın öğrenim kabiliyetini arttıracak sayıda belirlenmelidir (Kocadağlı, 2015). Diğer bir ifadeyle, gizli katman sayısı ile birlikte nöron sayısı da aşırı arttırılırsa, YSA'nın fonksiyonel yapısı aşırı kompleks hale gelecek ve bu durum öğrenim aşamasında veriye aşırı uyuma yol açacaktır (Feritas, 2000; Elmas, 2011; Haykin, 2005, Kocadağlı ve Aşıkil, 2014; Kocadağlı, 2015). Nöronlar, dış çevreden gelen uyarıları işleyen aktivasyon fonksiyonları içermektedir. Basit bir yapay sinir ağı yapısı şekil 5.1 deki gibi gösterilebilir.



Şekil 5.1 Basit YSA yapısı (Kurup ve Dudani, 2002; Tolon ve Tosunoğlu, 2008)

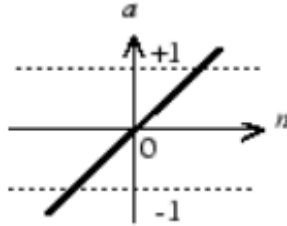
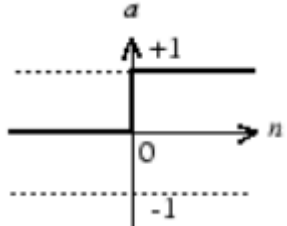
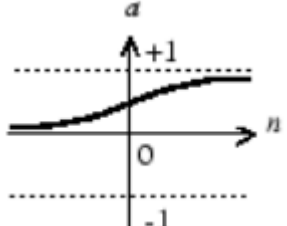
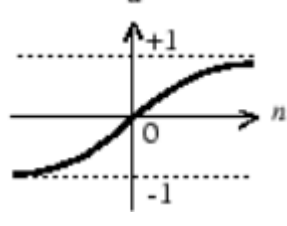
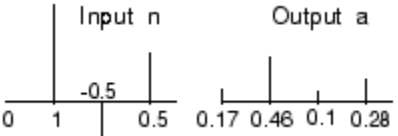
YSA'nın doğrusal olmayan sistemlerin modellenmesi hususunda üstüm yönleri olmasına rağmen, öğrenim algoritmasının gradyan temelli olması, risk fonksiyonunun ortalama kareler hatası gibi L^2 normunu temel alması, yaklaşım ve kestrim hatası gibi iki temel probleme yol açmaktadır (Feritas, 2000; Kocadağlı, 2012).

5.8 AKTİVASYON FONKSİYONLARI

Aktivasyon enerjisi, nöron davranışını etkileyen önemli etmenlerden biridir (Kaynak ve Efe, 2004). YSA'da kullanılan aktivasyon fonksiyonlarının farklı türleri bulunmaktadır. Aktivasyon fonksiyonunun seçiminde doğrusal olmama ve basitlik özelliklerinin yanı sıra bazı problemlerde aktivasyon fonksiyonunun birinci dereceden türevinin alınabilir olması gerekebilir. Bazı aktivasyon fonksiyonları aşağıda verilmiştir (Öztemel, 2012; Neural, 2001; Neural, 2002).

- i. *Doğrusal (Lineer) Fonksiyonu:* Doğrusal problemlerin çözümü amacıyla aktivasyon fonksiyonu olarak doğrusal bir fonksiyon seçilebilir. Toplama fonksiyonundan çıkan sonuç belli bir katsayı (A sabit sayısı) ile çarpılarak hücrenin çıktısı hesaplanır.
- ii. *Adım-Eşik Fonksiyonu:* Adım fonksiyonunu aşağıdaki koşulları sağlama durumuna göre tek ya da çift kutuplu fonksiyon olabilir.
- iii. *Sigmoid Fonksiyonu:* Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmadığı için yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
- iv. *Tanjant Hiperbolik Fonksiyonu:* Tanjant hiperbolik aktivasyon fonksiyonu, sigmoid fonksiyonuna benzer. Bu fonksiyonda çıkış değerleri 1 ile -1 arasında değişir.
- v. *Softmax Fonksiyonu:* Softmax fonksiyonu, bir ağ transfer fonksiyonudur. Softmax fonksiyonu çıkış katmanının toplam sonucunun 1 olmasını sağlayacak şekilde çıkışları normalize eder. Her sınıfın çıkış aktivasyonunun değeri, girişin o sınıfa ait olma olasılığını gösterebilir (Shimodaira, 2015; Hajek, 2005; Bishop, 1995).

Yukarıda açıklananların dışında, Satlin Aktivasyon Fonksiyonu, Radyal Tabanlı Aktivasyon Fonksiyonu, Yarışmacı Aktivasyon Fonksiyonu, Lojistik Aktivasyon Fonksiyonu, Üçgen Aktivasyon Fonksiyonu, Bulanık Aktivasyon Fonksiyonları, Eşik Değer Fonksiyonu, Sinüs Fonksiyonu da bulunmaktadır.

<p>Doğrusal aktivasyon fonksiyonu</p> $F(Net) = A * NET$	 <p>$a = \text{pürelin}(n)$</p>
<p>Adım-eşik aktivasyon fonksiyonu</p> $F(Net) = \begin{cases} 1, & \text{if } Net > \text{Eşik Değer} \\ 0, & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	 <p>$a = \text{hardlim}(n)$</p>
<p>Sigmoid aktivasyon fonksiyonu</p> $F(Net) = \frac{1}{1 + e^{-Net}}$	 <p>$a = \text{logsig}(n)$</p>
<p>Tanjant hiperbolik aktivasyon fonksiyonu</p> $F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$	 <p>$a = \text{tansig}(n)$</p>
<p>Soft-max aktivasyon fonksiyonu</p> $a = \text{softmax}(Net) = \frac{e^{Net}}{\sum e^{Net}}$	 <p>$a = \text{softmax}(n)$</p>

Şekil 5.2 Aktivasyon fonksiyonları ve grafikleri (Beale ve diğ., 2015)

5.9 AĞ YAPILARI

Yapay sinir ağıları, birbirlerine bağlı çok sayıda işlem elemanlarından (basit sinirlerden) oluşan, genelde paralel işleyen yapılardır. Yapay Sinir Ağları, tek katmanlı (sadece girdi ve çıktı katmanından oluşan) ve çok katmanlı (girdi katmanı, en az bir gizli katmanı ve çıktı katmanı) olmak üzere iki yapıda incelenir. En basit tek katmanlı sinir ağı modeli perseptrondur. Çok katmanlı YSA yapılarından bazıları ise aşağıda verildiği gibidir:


- Geri yayılım ağı (Rumelhart ve diğ., 1986).
- Delta bar delta ağı (Jacobs, 1988).
- Genişletilmiş delta bar delta ağı (Minai and Williams 1990).
- Hopfield ağı (Golden, 1996).
- Boltzman makinesi (Golden, 1996).
- Hamming ağı (Hagan ve diğ., 2002)
- Olasılıksal sinir ağıları (Haykin, 2009).

5.10 YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI

Yapılarına göre YSA, ileri beslemeli YSA, geri beslemeli YSA olmak üzere 2 sınıfa ayrılır.

5.10.1 İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli YSA' da, hücreler katman şeklinde düzenlenir, sadece önceki katmanlardan girdi alır, bir katmandaki hücrelerin çıktısı bir sonraki katmanın girdisidir ve çıktıdan girdiye geribildirim yoktur (Bhattacharjee ve Kothari, 2007). Giriş ve çıkış katmanlarının arasında gizli katmanlar bulunur. Bu katmanlardaki doğrusal olmayan davranışa sahip sinirler, sinir ağının toplam davranışındaki doğrusal olmamanın kaynağını oluşturur. LVQ (öğrenmeli vektör kuantulama) ve ÇKA (çok katmanlı ağ) örnek olarak verilebilir (Kaynak ve Efe, 2004).



Şekil 5.3 İleri beslemeli nöron ağı (Deveci ve Yavuz, 2013)

5.10.2 Geri Beslemeli Yapay Sinir Ağları

Geri besleme ağ yapıları, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılır. Bu tür ağ yapılarında, bir tür geri besleme işlemi vardır. Geri beslemeli ağlarda, bir sinirin çıkışı diğer tüm sinirlerin girişine bağlıdır (Elmas, 2011). Geri beslemeli ağ, önceden belirlenen bir ağ topolojisine sahiptir. Geri besleme ağı, ağırlıklarını elde etmek için öğrenme algoritması olarak Genelleştirilmiş Delta Kuralını kullanır (Wasserman, 1989; Freeman and Skapura, 1991).



Şekil 5.4 Geri beslemeli nöron ağı (Deveci ve Yavuz, 2013)

5.10.3 Yapay Sinir Ağının Fonksiyonel Gösterimi

Tez çalışmasında sınıflandırma problemleri için, Şekil 5.5 de gösterilen üç katmanlı ileri beslemeli bir YSA kullanılmıştır. X , n gözlem ve m özellik içeren $n \times m$ lik bir matris olmak üzere; x , $m \times 1$ lik girdi vektörüne karşılık YSA'nın ürettiği çıkış $y_c = [o_1, o_2, \dots, o_k]$ ($c = 1, 2, \dots, k$) olarak tanımlanmıştır. Burada, c , sınıf sayısını

göstermek üzere toplamda k bileşenden oluşan y_c çıktısı, k sınıftan herhangi birine aittir:

$$y_c \in \left\{ \underbrace{\{1,0,0, \dots, 0\}}_{1.\text{sınıf}}, \underbrace{\{0,1,0, \dots, 0\}}_{2.\text{sınıf}}, \underbrace{\{0,0,1, \dots, 0\}, \dots, \{0,0,0, \dots, 1\}}_{k.\text{sınıf}} \right\} \quad (5.1)$$

$y_c = [o_1, o_2, \dots, o_k]$ çıktısının herhangi bir c 'inci bileşeninin matematiksel formülasyonu aşağıdaki gibidir:

$$o_c = f(W^I, W^{II}, x) = \frac{e^{[b_c^{II} + w_c^{II} A(W^I x + b^I)]}}{\sum_{j=1}^k e^{[b_j^{II} + w_j^{II} A(W^I x + b^I)]}} \in [0, 1] \quad c = 1, 2, \dots, k \quad (5.2)$$

Bu yapı, matematiksel olarak sınıflandırma problemlerinde sıkça kullanılan softmax fonksiyonuna karşılık gelmektedir. Burada, softmax fonksiyonuyla hesaplanan o_c bileşenleri, $[0, 1]$ kapalı aralığında değer almaktadır. Bu hesaplama işleminin sonunda, $y_c = [o_1, o_2, \dots, o_k]$ çıktısının sınıfını belirlemek için bu çıktıya ait bileşenlerden en büyük değere sahip olanı "1" diğerleri "0" değerine dönüştürülerek ikili sistemde kodlamalar gerçekleştirilir:

$$\chi_{o_c} = \begin{cases} 1, & \text{Eğer } o_c = \max [o_1, o_2, \dots, o_k] \text{ ise} \\ 0, & \text{Aksi durumda} \end{cases} \quad c = 1, 2, \dots, k \quad (5.3)$$

Böylece, x girdi vektörüne karşılık y_c çıktısının k sınıftan hangisine ait olduğu ikili kodlama ile belirlenmektedir.

(5.2) formülasyonundaki diğer notasyonlar aşağıdaki gibidir:

W^I : Gizli katmandaki girdiler ve nöronlar arasındaki tüm ağırlık değerlerini içeren matristir. Şöyle ki, sistemdeki tüm girdi (inputs) sayısı r , gizli katmandaki nöron sayısı s , i . nöron ile tüm girdi değerleri arasındaki ağırlıkları içeren vektör $w_i^I = [w_{i,1} \ w_{i,2} \ \dots \ w_{i,r}]$ ($i = 1, 2, \dots, s$) sütun vektörlerini içeren W^I matrisi, vektörel formda aşağıdaki gibi tanımlanabilir:

$$W^I = [w_1^I \ w_2^I \ \dots \ w_i^I \ \dots \ w_s^I]' \quad s: \text{Gizli katmandaki sinir sayısı} \quad (5.4)$$

veya

$$W^I = \begin{pmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,r} \\ \vdots & \vdots & \ddots & \vdots \\ w_{s,1} & w_{s,2} & \dots & w_{s,r} \end{pmatrix} \quad (5.5)$$

W^{II} : Gizli katman ve çıktı katmanındaki nöronlar arasındaki tüm ağırlıkları içeren matristir. Şöyle ki, gizli katmandaki nöron sayısı s , çıkış katmanındaki nöron sayısı k ($c = 1, 2, \dots, k$), çıkış katmanındaki c . nöron ile gizli katmandaki tüm nöronlar arasındaki ağırlıkları içeren satır vektör $w_c^{II} = [w_{c,1} \ w_{c,2} \ \dots \ w_{c,s}]$ olmak üzere, W^{II} matrisi vektörel formda aşağıdaki gibi tanımlanabilir:

$$W^{II} = [w_1^{II} \ w_2^{II} \ \dots \ w_c^{II} \ \dots \ w_k^{II}]' \quad k: \text{Çıktı sayısı (Sınıf sayısı)} \quad (5.6)$$

veya

$$W^{II} = \begin{pmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,s} \\ \vdots & \vdots & \ddots & \vdots \\ w_{k,1} & w_{k,2} & \dots & w_{k,s} \end{pmatrix} \quad (5.7)$$

b^I : gizli tabakadaki tansig aktivasyon fonksiyonu için tüm yan değerlerini içeren vektördür:

$$b^I = [b_1^I \ b_2^I \ \dots \ b_s^I] \quad (5.8)$$

b^{II} çıktı katmanındaki softmax aktivasyon fonksiyonu için tüm yan değerlerini içeren vektördür:

$$b^{II} = [b_1^{II} \ b_2^{II} \ \dots \ b_k^{II}] \quad (5.9)$$

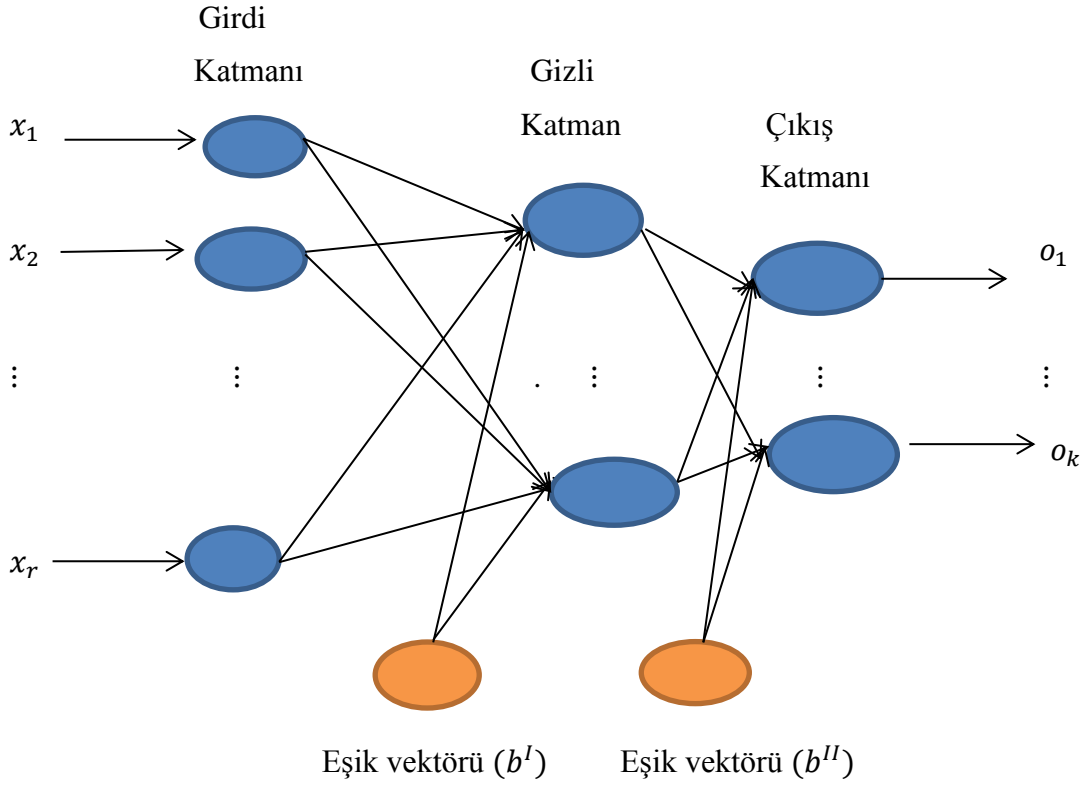
$A(w^I x + b^I): R^s \rightarrow R^s$ gizli katmandaki s adet nöronun aktivasyon fonksiyonu çıktısını içeren vektör fonksiyondur:

$$A(W^I x + b^I) = G(A_1(w_1^I x + b_1^I), A_2(w_2^I x + b_2^I), \dots, A_s(w_s^I x + b_s^I)) \quad (5.10)$$

burada,

A_i , gizli katmandaki i . hiperbolik tanjant fonksiyonudur:

$$A_i = \frac{e^{Net_i} + e^{-Net_i}}{e^{Net_i} - e^{-Net_i}}; \quad Net_i = w_i^I x + b_i^I \quad i = 1, \dots, s \quad (5.11)$$



Şekil 5.5 Sınıflamada kullanılan çok katmanlı algılayıcı YSA modeli

5.11 YAPAY SİNİR AĞLARINDA RİSK FONKSİYONLARI

Üzerinde çalışılan veri kümesinde doğru bir sınıflandırma yapabilmek için tüm ağırlık ve yan değerleri, risk ve uyum fonksiyonları dikkate alınarak kestirilmelidir. Literatürde, YSA'ların eğitimi için farklı türlerde risk ve uyum fonksiyonları kullanılmaktadır. Bunların en bilinenleri; ortalama karesel hata (mean squared errors), ortalama mutlak hata yüzdesi (mean absolute percentage errors), sınıflandırma hatası (classification errors), entropi kriteri (entropy criterion) ve bilgi kriterleridir (information criteria). Daha detaylı bilgi Golden (1996), Faraway ve diğ. (1998), Bozdoğan (2000), McQuarrie ve diğ., (2007), Silva ve diğ. (2008), Bishop (2010), Soydaner ve Kocadağlı (2015) den bulunabilir. Bu çalışmada, iyi bir sınıflandırma performansı sağlamak için ortalama karesel hatanın yanında sınıflandırma hatası ve model kompleksliğini kontrol altına almak için AIC, AICc ve BIC bilgi kriterleri kullanılmıştır. Bunun yanısıra, eğitim esnasında YSA'ların sınıflandırma performansını arttırmak için erken durdurma (early stopping), çapraz geçerlilik (cross-validation) ve değişken seçimi teknikleri uygulanmıştır.

YSA'ların eğitiminde, diğer bir önemli mesele, gizli katmandaki nöron sayısının belirlenmesidir. Nöron sayısının belirlenmesi, doğrudan karmaşıklığı modellemek ile

ilgilidir (Neal, 1996; Freitas, 2000; Bishop, 2010; Kocadađlı, 2012). Dolayısıyla AIC, AICc ve BIC bilgi kriterlerinin göz önünde bulundurulması, nöron sayısının en etkin sayısını belirlenmesinde kullanışlı bir yaklaşımdır (Anders et al. 1999; Qi et al. 2001; May et al., 2008; McQuarrie ve diđ., 2007, Kocadađlı, 2015; Soydaner ve Kocadađlı, 2015).

Literatürde, karmaşıklığı modellemek için çođunlukla AIC ve BIC tercih edilir. AIC asimptotik olarak yansız ve büyük örneklem için etikili olmasına rağmen, küçük örneklerde aşırı uyuma neden olur. Bu durumda, küçük örneklemde aşırı uyuma eğilme başa çıkabildiđi için AIC c, AIC yerine tercih edilmelidir (McQuarrie ve diđ., 2007). Buna rağmen, AIC büyük örneklemde AICc ye asimptotik olarak eşdeđerdir ve hemen hemen aynı performansı sağlar. Dahası, BIC ekstra paratreleri cezalandırmada AIC den daha etkindir ve bu karmaşık modellerden ziyade basit modeller sağlar. Cezalandırma yeteneđi bakımından, AICc'nin BIC'e oldukça yakın olduđu söylenebilir (Faraway ve diđ., 1998).

5.12 YAPAY SİNİR AĐLARINDA ÖĐRENME STRATEJİLERİ

Öđrenme algoritmalarına göre YSA genel olarak denetimli öđrenme, destekleyici öđrenme, denetimsiz öđrenme ve karma stratejiler olmak üzere 4 sınıfa ayrılır:

- Denetimli Öđrenme
- Destekleyici Öđrenme
- Denetimsiz Öđrenme
- Karma Stratejiler

Denetimli öđrenmede, sistemin olayı öđrenebilmesi için yardımcı bir denetmen vardır. Denetmen sisteme öđrenilmesi istenen olay ile ilgili örnekleri girdi/çıktı seti olarak verir. Her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilir. Girdiler, denetimin belirlediđi çıktıları haritalanır ve bu sayede olayın girdileri ile çıktıları arasındaki ilişki öđrenilir (Golden, 1996). Eğitim işlemi, tüm eğitim seti için kabul edilebilir düzeyde bir hata oluncaya kadar tekrarlanır (Weng, 1994).

Destekleyici öğrenmede denetmen, her girdi seti için olması gereken (üretilmesi gereken) çıktı setini sisteme göndermek yerine sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru ya da yanlış olduğunu gösteren bir sinyal üretir (Öztemel, 2012).

Denetimsiz öğrenmede çıktı için hedef vektör yoktur yani önceden belirlenen çıktılar için karşılaştırma yapılamaz. Eğitim seti sadece girdi vektörünü içerir. (Weng, 1994).

Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Genelde sınıflandırma problemleri için kullanılır (Öztemel, 2012).

Karma stratejiler olarak, yukarıda verilen 3 stratejiden bir kaçını birlikte kullanarak öğrenme gerçekleştiren ağlarda vardır (Elmas, 2011).

5.13 YAPAY SİNİR AĞLARINDA ÖĞRENME KURALLARI

Danışmalı öğrenmede eğitilmiş sinirlere öğretme işaretini göndererek sinirler eğitilir ve bu işaretin bağlantısındaki ağırlıkları ayarlamakta kullanılır (Elmas, 2011).

Önemli öğrenme algoritmalarından bazıları aşağıda verilmiştir:

- a. Hebb Kuralı (Anderson ve McNeill, 1992).
- b. Hopfield Kuralı (Golden, 1996).
- c. Delta Kuralı (Anderson ve McNeill, 1992).
- d. Eğimli İniş Kuralı (Larose, 2005).
- e. Kohonen Kuralı (Golden, 1996).

5.14 GRADYAN TABANLI ÖĞRENME ALGORİTMALARI

5.14.1 En Dik Azalış (Gradient Descent)

En dik azalış, steepest descent olarak da bilinen, en basit ağ öğrenme algoritmalarından birisidir. Bu yöntemde, genelde tesadüfi olarak seçilen bir ağırlık vektörü ile başlanır (w_0). Ağırlık vektörü, (5.12) deki eşitlik kullanılarak güncellendikten sonra, negatif gradyan yönünde yani hatanın en çok azaldığı yönde kısa bir mesafe taşınır.

$$\Delta w_0 = -\eta \nabla E(w_0) \quad (5.12)$$

En dik azalışın (5.12) deki formülünden beklenen, E (hata) değerinin her bir ardışık adımda azalması ve sonunda,

$$E = \eta k \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.13)$$

eşitliğini sağlayan bir ağırlık vektörüne ulaşmasıdır. Ayrıca, (5.13) ün ardışık güncellemeleri için, hatada düzenli bir azalma olması beklenebilir. Çünkü yeterince küçük bir η değeri için, ağırlık uzayında hareketin ortalama yönü gradyanın negatif değerine yakınsamalıdır. En dik azalış, birçok küçük adımla minimuma ulaşır. Yaklaşık minimumda hata fonksiyonuna quadratik yaklaşımı düşünülebilir.

(5.12) eşitliği yardımı ile elde edilen hata en küçük olana kadar ağırlık güncellemesine devam edilir. N . adımda hata azalmasının en iyi olduğu negatif gradyan güncellenmesi aşağıdaki gibi olur:

$$\Delta w_1 = -\eta \nabla E(w_1) \quad (5.14)$$

.

.

.


$$\Delta w_n = -\eta \nabla E(w_n) \quad (5.15)$$

Momentum sabitli öğrenme;


En dik azalış yönteminde geniş anlamda farklılıklar gösteren özdeğer problemiyle başa çıkmak için kullanılan en basit tekniklerden birisi, (5.12) formülüne bir momentum terimi eklemektir. Momentum, ağırlık uzayı yoluyla harekete eylemsizlik ekler.

$$\Delta w_n = -\eta \nabla E(w_n) + \mu \Delta w_{n-1} \quad (5.16)$$

Momentum, öğrenme oranının etkisini artırır, genelde, en dik azalışın performansında önemli gelişmelere neden olur fakat genelde bu algoritma nispeten yetersiz kalmaktadır.



Şekil 5.6 Uygun öğrenme parametrelili en dik azalışın, ardışık küçük adımların yol açacağı düşük eğimli bir yüzeyde azalışı



Şekil 5.7 En dik azalışın ardışık adımlarındaki bir durum için salınımlar

Yukarıdaki şekilde de görüldüğü gibi, uygun bir öğrenme parametresiyle yüzeydeki eğriliği azalan en dik azalış, ardışık daha küçük adımların neden olduğu azalan eğrilik ile eğri yüzeyinde azalır. Böyle bir durumda, momentum teriminin etkisi öğrenme oranı parametresi etkisindeki artışa benzer.

En dik azalışın ardışık adımlarının salınımindaki konum için, momentum teriminin öğrenme oranı parametresindeki etkisi çok azdır.

En dik azalışın kısıtlarından biri, öğrenme oranı parametresi için uygun bir değer seçilmesi gerekliliğidir. Eğer bu değer çok büyük olursa algoritma hata değerinde (E) bir artışı aşabilir ve belki de algoritmanın çökerek farklı salınımlarla sonuçlanmasına neden olabilir. Eğer bu değer çok küçük seçilirse, araştırma çok yavaş ilerleyebilir, uzun bir hesaplama zamanına ihtiyaç duyulabilir. Ayrıca bu parametrenin optimum değeri minimizasyon boyunca sürekli değişebilir. Dahası, hata yüzeyinin çoğu noktasında lokal gradyan minimuma doğru direkt olarak işaret etmez (Bishop, 1995).

5.14.2 Ölçekli Eşlenik Gradyan Algoritması

Ölçekli eşlenik gradyant algoritması, sayısal analizde eşlenik gradyant olarak bilinen optimizasyon tekniklerinin bir sınıfına dayanır. Hessian matrisi hesaplamak zorunda kalmadan seçilecek eşlenik algoritmasında adım genişliğine olanak veren arama yolunun nasıl kullanıldığı görülmektedir. Fakat, her yol minimizasyonu birçok hata değeri içerir. Hata fonksiyonu, gradyan vektörü de içeren ÖEG algoritması aşağıda verilmiştir (Bishop, 1995):

$$\Delta_j = \frac{2\{E(w_j) - E(w_j + a_j d_j)\}}{a_j d_j^T g_j} \quad (5.17)$$

ÖEG, denetimsiz bağımlı parametreler içeren tamamen otomatik yapıdadır. Ve uygun adım büyüklüğünü belirlemek için her bir iterasyonda CGB ve BFGS'nin kullandığı zaman alıcı bir arama yolunu öner (Moller, 1990).

5.14.3 Yarı Newton Metodu (BFGS Quasi-Newton Methods)

Yarı Newton yaklaşımı, sadece hata fonksiyonunun birinci türevindeki bilgileri kullanan Hessian'ın ters matrisi (H^{-1}) için giderek artan kesinlikteki yaklaşımları temsil eden art arda bir dizi matris ($G^{(\tau)}$) içerir. Burada, pozitif tanımlı olmayan Hessian matrisinden kaynaklanan sorun, birim matris gibi pozitif tanımlı bir matrisle başlayarak ve Hessian matrisinin tersinin pozitif kalmasını garanti eden Hessian matrisin tersine yaklaşım gibi güncel yöntemle sağlayarak çözülür. BFGS algoritması aşağıda verildiği gibidir (Bishop, 1995) :

$$G^{(\tau+1)} = G^\tau + \frac{pp^T}{p^T v} - \frac{(G^{(\tau)}v)v^T G^{(\tau)}}{v^T G^{(\tau)}v} + (v^T G^{(\tau)}v)uu^T \quad (5.18)$$

Eşlenik gradyan yöntemine göre daha az yaklaşımda en uygun noktayı bulur. Fakat her yaklaşımda daha fazla hesaplama yapar ve daha fazla belleğe ihtiyaç duyar (Stephan ve diğ., 2002).

5.14.4 Levenberg- Marquardt

Optimizasyon algoritmalarının çoğunda, geniş kapsamlı hata fonksiyonlarıyla çalışmak için genel amaçlı metotlar tasarlanmıştır. Levenberg- Marquardt metodunda hata kare ortalamasını minimum yapmak için özel bir algoritma tanımlanmıştır.

$$\tilde{E} = \frac{1}{2} \|\epsilon(w_{old}) + Z(w_{new} - w_{old})\|^2 + \lambda \|w_{new} - w_{old}\|^2 \quad (5.19)$$

λ parametresinin çok küçük deęerleri için Newton formülü kullanılırken, bu parametrenin çok büyük deęerleri için standart en dik azalış yöntemi kullanılır. Pratikte, λ için deęer seçilmeli ve bu deęer en küçükleme süresi boyunca farklı yaklaşımları sağlamalıdır. λ için yaygın bir yaklaşım, 0.1 gibi rasgele bir deęerle başlamak ve her adımda deęişimi takip etmektir. Eęer hata artarsa, λ parametresinin deęeri de artar ve aęırlık vektörü yenilenir ve yeni güncellenmiş aęırlık hesaplanır. Eęer aęırlık vektörünün deęişmemesiyle tahmin edilen adımdan sonra hata azalır, λ 'nın deęeri azalır ve süreç tekrarlanır. E' de yeni bir azalma elde edene kadar bu durum tekrarlanır (Bishop, 1995).

5.14.5 Lyapunov Üsteli

Düzensiz sinyaller genelde rasgele olmamasına rağmen, başlangıç koşullarına baęımlı ve geniş bant güç spektrumlu rasgele gibi davranışlarla karakterize edilir. Eęer oldukça küçük farklılıkları olan iki tane başlangıç koşulu ile başlayan iki özdeş düzensiz sistem varsa, onların sistemlerinin davranışları oldukça farklı olacaktır. Bundan dolayı, kaotik (düzensiz) sistemin uzun süreli tahmini pratikte imkansızdır. Kaotik davranışın varlığını tahmin eden yöntemlerden biri Lyapunov Üsteli'dir. Bu yöntem, başlangıç koşullarına duyarlılığın baęımlılığını ölçer. Özellikle iki yörünge bir başlangıç ayırımındaysa δ_0 , onlar;

$$|\delta(t)| \approx |\delta_0| \exp(\lambda t) \quad (5.20)$$

olarak (λ , Lyapunov üsteli) ayrılır. Eęer λ pozitifse o zaman sistem kaotiktir, eęer negatifse o zaman sistem kaotik değildir (Tamura ve Shimakage, 2013). Pozitif Lyapunov üsteli, iki yakın yörünge için ortalama üstel ayrılığını ölçer (Gencay ve Dechert, 1992). Sistemin Lyapunov üstellerini analiz ederek, sistemin durumu açıkça tarif edilebilir ve sistem durumu ile sinyal genişliği arasında karşılık gelen bir ilişkiye karar vermek kolay olur (Hu ve Liu, 2012).

5.15 YAPAY SİNİR AĞLARINDA DURDURMA KRİTERLERİ

Yapay sinir aęları, esnekliklerinden dolayı, aşırı uyuma (overfitting) eğilimlidir. Yani, bilinmeyen veriyi genelleştirmek yerine eğitim setinde kendine özgü desenleri ezberler. Bu yüzden, YSA'nın eğitilmesinin yanı sıra gereęinden fazla eğitilmemesi de önemlidir. Çünkü eğitilmek istenen bir aęda çözüm için istenen aęırlıklar elde

edildikten sonra eğitime devam edilirse, bu ağın ağırlıklarında hataya neden olabilir ve ağın performansını düşürebilir ya da öğrenemeyen ağlara dönüştürebilir. Bu yüzden ağın eğitiminin durdurulma zamanı önemlidir. Eğer durdurma kriterleri göz ardı edilirse, hata kareler toplamı için yerel minimum olarak bilinen optimum çözüm noktasına ulaşmayabilir. Eğer optimum çözüm olmazsa, algoritma, bir yerel minimumda sıkışabilir. Ağın eğitiminin durdurulması ile ilgili bazı durdurma kriterleri aşağıda verildiği gibidir (Neural, 2002; Öztemel, 2012; Larose, 2005; Alpaydın, 2010):

- *Hatanın belli bir değerin altına düşmesi:* Hatanın, bütün eğitim seti için kabul edilebilir bir değerin altına düşmesi kriter olarak alınabilir. Yani, öğrenme performansının %98-99 gibi bir düzeyde olması kabul edilebilir olabilir. Kabul edilebilir hata miktarı problemden probleme değişebilir. Ağ tasarımcısı bunu kendisi belirler.
- *Ağın belli bir iterasyon sayısını tamamlaması:* İterasyon sayısının az olması hatanın yeterince düşmemesine neden olur, iterasyon sayısının fazla olması da aşırı uyuma neden olur. Ağdan ağa farklılık gösterebilen en uygun iterasyon sayısı, önceden bilinemez, deneme yoluyla anlaşılır. Kabul edilebilir hatanın belirlenemediği durumlarda bu yöntem kullanılabilir.
- *Çapraz geçerlilik (cross validation):* Genellemeyi arttırmak için, veri, eğitim, geçerlilik ve test olmak üzere 3 alt veri setine ayrılır. Eğitim seti, ağ ağırlıkları ve yanlarını güncellemek ve gradyanti hesaplamak için kullanılır. Geçerlilik seti, eğitimin başlangıç süresince hatanın genellikle azalmasını sağlar. Eğer, ağın veriye aşırı uyumu başlarsa, geçerlilik setindeki hata da artmaya başlar. Belli bir iterasyonda geçerlilik hatası artarsa, eğitim durur ve geçerlilik hatasının en küçük olduğu ağırlıklar ve yanlara dönlür. Test seti hatası eğitim süresince kullanılmaz ancak farklı modelleri karşılaştırmak için kullanılır. Eğer test setindeki hata geçerlilik setindeki hatadan daha farklı iterasyon sayısında anlamlı bir minimum değere ulaştıysa, bu, setin bölünmesinin zayıf olduğunun göstergesi olabilir. Genel olarak, sinir ağı için en uygun genelleme performansını elde etmek için kullanılır.

6 LOJİSTİK REGRESYON

Lojistik regresyon analizi bir ya da birden fazla bağımsız değişken ile bağımlı değişken arasındaki ilişkiyi modeller. Lojistik regresyon modelde, genelde, bağımlı değişken iki ya da daha fazla olası değer alır. Lojistik regresyon model bir çok alanda kullanılır (Hosmer ve Lemeshov, 2000).

Lojistik regresyon analizi, normallik, ortak kovaryansa sahip olma gibi varsayımların olmadığı durumlarda diskriminant analizi ve çapraz tablolara bir alternatiftir (Tatlıdil, 1996). Bağımsız değişkenler hem kategorik hem de sürekli olduğunda çok değişkenli normallik varsayımı geçersizdir. Böyle durumlarda bağımsız değişkenin dağılımı hakkında hiçbir varsayımda bulunmayan lojistik regresyon analizi tercih edilir (Sharma, 1996). Lojistik regresyonda, minimum sayıda parametre içeren modelin oluşturulması zordur, bu amaçla yararlanılan en yaygın kriter AIC'dır (Tatlıdil, 2002).

Lojistik regresyon en az değişkeni kullanarak en iyi uyuma sahip, bağımlı değişken ile bağımsız değişkenler kümesi arasındaki ilişkiyi tanımlayabilen ve genel olarak kabul edilebilir bir model kurmayı amaçlar (Aktaş ve Erkuş, 2009).

Lojistik regresyon modeli, doğrusal regresyon modelinden ayıran şeylerden biri, lojistik regresyondaki ikili bağımlı değişkendir. Diğer farklılık ise model varsayımı ve parametrelerin seçimidir.

6.1 İKİ KATEGORİLİ LOJİSTİK REGRESYON

Regresyonda, bağımsız değişken x verildiğinde, bağımlı değişken y nin koşullu ortalaması (beklenen değeri) $E(Y|x)$ ile gösterilir. Doğrusal regresyonda bu ortalamanın x 'e göre doğrusal bir fonksiyon olduğu varsayılır.

$$E(Y|x) = \beta_0 + \beta_1 x \quad (6.1)$$

Doğrusal regresyon analizinde kullanılan teknikler, lojistik regresyona modifiye edilebilir. Lojistik regresyon formülü aşağıdaki gibidir (Hosmer ve Lemeshov, 2000):

$$\pi(x) = E(Y|x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} \quad 0 \leq E(Y|x) \leq 1. \quad (6.2)$$

Burada, $g(x) = \ln \frac{\pi(x)}{1 - \pi(x)}$ logit dönüşümü uygulanırsa, aşağıdaki eşitlik elde edilir (Anderson, 1997):

$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 x \quad (6.3)$$

(6.3) eşitliğinde, $\pi/(1 - \pi)$ oranı odds adını alır (Montgomery ve diğ., 2012).

6.2 ÇOK KATEGORİLİ LOJİSTİK REGRESYON

Çok kategorili lojistik regresyon modelinde, modeldeki bağımlı ve bağımsız değişkenler farklı ölçüm düzeylerinde olabilirler (Hosmer ve Lemeshov, 2000). Bu modelde, çıktı değişkeni vektörü $Y = (0, 1, \dots, c - 1)$, bağımsız değişken vektörü $x = (x_1, x_2, \dots, x_p)$ olmak üzere bağımsız değişkenlerin her birinin en az aralık ölçeğinde olduğu varsayalım. Herbir çıktı değerinin çok terimli olasılıkları bağımsız değişken x verildiği koşulu altında:

$$P(Y = 0 \setminus x) = \frac{1}{1 + e^{g_1(x)} + \dots + e^{g_{c-1}(x)}} \quad (6.4)$$

$$P(Y = 1 \setminus x) = \frac{e^{g_1(x)}}{1 + e^{g_1(x)} + \dots + e^{g_{c-1}(x)}} \quad (6.5)$$

⋮

$$P(Y = c - 1 \setminus x) = \frac{e^{g_{c-1}(x)}}{1 + e^{g_1(x)} + \dots + e^{g_{c-1}(x)}} \quad (6.6)$$

Olarak elde edilir. Burada aşağıdaki gibi logit dönüşüm uygulanırsa:

$$g_j(x) = \ln \left[\frac{P(Y=j \setminus x)}{P(Y=0 \setminus x)} \right], \quad i = 1, \dots, p, \quad j = 1, \dots, c - 1 \quad (6.7)$$

$$= \beta_{j0} + \beta_{j1}x_1 + \dots + \beta_{jp}x_p \quad (6.8)$$

İfadesi elde edilir (Fagerland ve diğ., 2008).

Eğer bağımsız değişkenler cinsiyet, meslek gibi farklı nominal ölçüm düzeyinde olursa, o zaman nominal ölçümlerin seviyelerini gösteren ve sayısal olarak anlamlılığı olmayan sayılar verilir (1,2,.. gibi) ve *dummy değişkenleri* kullanılır (Hosmer ve Lemeshov, 2000).

Çok kategorili lojistik regresyonda, kullanılan model kestirim yöntemleri iki kategorili lojistik regresyon durumunda uygulanan yöntemlerin genellemesidir. Model kestirimi için, en çok olabilirlik, yeniden ağırlıklandırılmış iteratif en küçük kareler, minimum lojit khi-kare ve Begg-Gray kestirim yöntemleri kullanılabilir (Tatlıdil, 2002).

6.2.1 Çok Kategorili Lojistik Regresyon Model Çıkarımı

n bağımsız gözlem için bir örneğin (x_i, y_i) , $i = 1, 2, \dots, n$ olduğu varsayalım. Tek değişkenli analiz durumundaki gibi, model çıkarımı için $\beta' = (\beta_0, \beta_1, \dots, \beta_p)$ gibi tahmin vektörü gereklidir. Modelin tahmini için, tek değişkenlide kullanıldığı gibi en çok olabilirlik yöntemi kullanılır. Olabilirlik eşitlik sistemi aşağıdaki gibi verilebilir:

$$\sum_{i=1}^n [y_i - \pi(x_i)] = 0 \quad (6.9)$$

ve

$$\sum_{i=1}^n x_{ij} [y_i - \pi(x_i)] = 0, \quad j = 1, 2, \dots, p \quad (6.10)$$

Tahmin modelinde varyans ve kovaryansın tahmini katsayıları için en çok olabilirlik teorisinden faydalanılır. Bu teoride, log olabilirlik fonksiyonunun ikinci kısmi türevinden elde edilen kestirimler ifade edilir. Bu türevler aşağıdaki gibi ifade edilir:

$$\frac{\partial^2 L(\beta)}{\partial \beta_j^2} = - \sum_{i=1}^n x_{ij}^2 \pi_i (1 - \pi_i) \quad (6.11)$$

ve

$$\frac{\partial^2 L(\beta)}{\partial \beta_j \partial \beta_l} = - \sum_{i=1}^n x_{ij} x_{il} \pi_i (1 - \pi_i), \quad j, l = 0, 1, \dots, p \quad (6.12)$$

Burada, $\pi(x_i) = \pi_i$ dir. $(p + 1) \times (p + 1)$ matrisi, (6.9) ve (6.10) daki eşitliklerdeki negatif terimleri içeren matristir. Bu matris gözlenen bilgi matrisi olarak adlandırılır.

Varyans ve kovaryansın kestirim değerleri bu matrisin tersinden elde edilen $Var(\beta) = I^{-1}(\beta)$ matrisi ile bulunur. Burada $Var(\beta_j)$, $\hat{\beta}_j$ 'nin varyansı olan j. köşegen elemanıdır ve $Cov(\beta_j, \beta_l)$, $\hat{\beta}_j$ ile $\hat{\beta}_l$ arasındaki kovaryanstır.

Kestirim katsayılarının standart hata tahmini için aşağıdaki eşitlikten faydalanılır:

$$\widehat{SE}(\hat{\beta}_j) = [\widehat{Var}(\hat{\beta}_j)]^{1/2} \quad j = 0, 1, \dots, p \quad (6.13)$$

Model için parametre kestirimi $\hat{j}(\hat{\beta}) = X'VX$ matrisinden elde edilir. Burada X, $p + 1$ satır, n sütunu olan bağımsız değişken matrisi ve V, $\hat{\pi}_i(1 - \hat{\pi}_i)$ elemanlarından oluşan matrisin gösterimi aşağıdaki gibidir:

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix}$$

ve

$$V = \begin{bmatrix} \hat{\pi}_1(1 - \hat{\pi}_1) & 0 & \dots & 0 \\ 0 & \hat{\pi}_2(1 - \hat{\pi}_2) & \dots & 0 \\ \vdots & 0 & \ddots & \vdots \\ 0 & \dots & 0 & \hat{\pi}_n(1 - \hat{\pi}_n) \end{bmatrix}$$

gibi olur.

6.3 LOJİSTİK REGRESYON MODELİNDE MODEL KATSAYILARI SINAMASI

Lojistik regresyon analizinde tahmin edilen katsayıların modele uygun olup olmadığının sınanmasında olabilirlik oran testi (likelihoodratio test) ve Wald testi yaygın olarak kullanılan yöntemler arasındadır. Katsayıların anlamlılığı için aşağıdaki hipotez çifti kurulur (Sharma, 1996).

$$H_0: \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \quad H_1: \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix} \neq \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

6.3.1 6.3.1. Wald Testi

Lojistik regresyon modelindeki her bir bağımsız değişkenin modeldeki varlığının anlamlı olup olmadığını sınavan Wald testi, t değerlerinin karelerinden oluşan, "1" serbestlik dereceli, asimptotik χ^2 dağılımına sahip bir istatistiktir (Sharma, 1996). Wald test istatistiği aşağıdaki gibidir:

$$W_i = \left(\frac{\hat{\beta}_j}{s(\hat{\beta}_j)} \right)^2, \quad i = 1, 2, \dots, p \quad (6.14)$$

6.3.2. Olabilirlik Oran Testleri

Lojistik regresyon modelindeki regresyon katsayılarının anlamlılığını test etmek için kullanılan Olabilirlik Oran Testleri, (bağımlı değişkenin kategori sayısı-1)(tahmin edilen parametre sayısı-1) serbestlik dereceli, χ^2 dağılımına sahip bir istatistiktir (Agresti, 1990). Lojistik regresyonda analiz yaparken, R-square istatistiği elde edilmez, çünkü minimum varyans için model tahmini yapılmaz. Bunun yerine en çok olabilirlik yöntemi kullanılarak model tahmini yapılır. Lojistik regresyonda, modelin uyum iyiliğini değerlendirmek için R-square'den geliştirilen Pseudo R-square değeri kullanılır. Pseudo R-square değerleri arasında en yaygın kullanılanları Cox and Snell's R-square ve Nagelkerke's R-square'dir (Meyers ve diğ., 2006).

Cox and Snell's R-square değeri:

$$\frac{1-L_{final}}{L_{null}} \quad (6.15)$$

ile hesaplanır. Burada, L_{final} değeri, sabit değer ve tahmin değerlerinin olduğu son model için log olabilirlik değeridir. L_{null} değeri ise, geçersiz model için log olabilirlik değeridir.

Nagelkerke's R-square, en büyük pozitif değer görüldüğü Cox and Snell's R-square bölünmesiyle türetilir ve 0 ile 1 arasında değer alır. Pseudo R-square, model tarafından açıklanan bağımlı değişkendeki varyans miktarının tahminini gösterir (Mertler ve Vannata, 2002).

Çok kategorili lojistik regresyonda, modelin yeterliliğini test etmek için sözde R^2 (pseudo) istatistikleri de incelenebilir. Mcfadden R^2 , Cox-Snell ve Nagelkerke R^2 istatistikleri en sık kullanılan sözde R^2 istatistikleridir. Bu katsayılar, doğrusal

regresyondan farklı olarak küçük çıkar. Daha çok model oluşturma safhasında farklı modellerin performansını karşılaştırmak için kullanılmaları önerilir. Olabilirlik oran indeksi olarak da adlandırılan Mcfadden R^2 , çok kategorili lojistik regresyonda elde edilen R^2 ye göre oldukça küçük değerler alma eğiliminde olduğu için, 0.20-0.40 arasındaki bir değer çok yüksek olduğu söylenebilir. Cox-Snell R^2 en küçük 0 değerini alır fakat en büyük değeri 1 değildir. Nagelkerke R^2 değeri Cox-Snell R^2 istatistiğinin en büyük değerinin 1 olabilmesi için yapılan düzeltmeyle olduğu için bu değeri yorumlamak daha kolaydır (Alpar, 2011).

6.3.2 Modelin Uyum İyiliği

Modelin veriye uyumunun iyi olup olmadığını araştırmak için kullanılan istatistikler arasında Pearson ki-kare testi, Hosmer-Lemeshow testi ve sapma (deviance) istatistikleri en çok tercih edilenleridir. Pearson ki-kare ve sapma istatistikleri gözlenen ve beklenen değerler arasındaki farkı kullanarak modelin uyumunu değerlendirir ve bu formül aşağıdaki şekilde ifade edilir (Fidell ve Tabachnick, 2007):

$$\chi^2 = 2[LL(B) - LL(O)] \quad (6.16)$$

Olarak elde edilir. Burada,

$$LL = \sum_{i=1}^N [Y_i \ln(\hat{Y}_i) + (1 - Y_i) \ln(1 - \hat{Y}_i)] \quad (6.17)$$

dir. $LL(B)$, tüm tahminlerin olduğu büyük modeldir, $LL(O)$ ise b katsayılarının olduğu küçük modeldir.

Elde edilen sonuçlar tablo değerinden büyük ve $p < \text{anlamlılık değeri}$ ise modelin uyumlu olması üzerine kurulan hipotez reddedilir ve modelin uyumlu olmadığı sonucuna varılır (Fidell ve Tabachnick, 2007).

7 MODEL SEÇİM KRİTERLERİ

İstatistiksel bir model oluştururken hangi değişkenlerin modelde yer alacağı, modelin anlamlılığı ve alternatif modeller içinde en iyi modelin seçilmesi son derece önemlidir. Genel anlamda, bu soruların cevabı Occam's Razor kuralı olarak ta bilinen cimrilik prensibinde yatmaktadır (Box ve Jenkins, 1977). Bu prensibe göre, basit modeller kompleks olanlara tercih edilmelidir. Diğer bir ifadeyle, bir model mümkün olduğunca az parametre oluşturulmalıdır.

Modelin yapısının doğruluğunun sınanmasında R^2 , Durbin-Watson, Ramsey's RESET, değişken eklemede Lagrange Çarpanı, White test vb gibi testler kullanılabilir. Bunların dışında, kurulan modeller arasında en iyi performansa sahip olan modelin seçilmesi de önemlidir. En iyi performansa sahip modelin seçilmesi için bazı kriterler aşağıda açıklanmıştır.

7.1 AKAIKE BİLGİ KRİTERİ (AIC: AKAIKE INFORMATION CRITERION)

Akaike Bilgi Kriteri, modele eklenen değişkenlerin yarattığı artışı sınırlandırarak düzenlenmiştir (Akaike, 1973, 1974; Siungiura, 1978; Hurvich ve Tsai, 1989). AIC, K-L (Kullback-Leibler Uyumsuzluğu) ye dayanan bir model seçim kriteridir (Akaike, 1973, 1974, 1985, 1994). AIC'in en çok olabilirlik tahmini aşağıdaki gibidir (Tsai ve McQuarrie, 2007):

$$AIC = -2 \log(L(\hat{\theta}|data)) + 2K \quad (7.1)$$

Burada L, en çok olabilirlik fonksiyonudur. Diğer bir gösterimle, normal dağılımlı hataya sahip AIC aşağıdaki gibi ifade edilebilir:

$$AIC = n \log(\hat{\sigma}^2) + 2K \quad (7.2)$$

Yukarıdaki eşitlikte,

$$\hat{\sigma}^2 = \frac{\sum(\hat{\epsilon}_i)^2}{n} \quad (7.3)$$

dir. Burada $\hat{\epsilon}$, uygun bir modelden tahmin edilen artıklardır.

Model seçimi esnasında, AIC değerinin en düşük olduğu model tercih edilmektedir (Vrieze, 2012). Örneklerin varyanslarının bağımsız olduğunu varsayan AIC model seçimi, bazı çapraz doğrulama özelliklerine sahiptir (Stone, 1974, 1977).

AIC'ın üretilmesinden daha sonraki dönemlerde, küçük örnek zaman serisi regresyon modelleri (Hurvich ve Tsai, 1989) için kullanılan eğimsiz AIC'dan AICc türetilmiştir ve aşağıdaki gibi ifade edilir (Zucchini, 2000; Sugiura, 1978; Hurvich ve Tsai, 1989, 1995):

$$AICc = -2 \log \left(L(\hat{\Theta}) \right) + 2K + \frac{2K(K+1)}{n-K-1} \quad (7.4)$$

7.2 BAYES BİLGİ KRİTERİ (BIC: BAYES INFORMATION CRITERION)

Her model için Bayes Bilgi Kriteri hesaplanır ve en küçük BIC değerine sahip olan model seçilir. Doğrusal regresyonda seçilmiş model problemleri için BIC model seçim kriteri üretilmiştir (McQuarrie, Tsai, 1998). BIC, hedef modelin bir tahmini olarak, büyük olmayan örnek genişliklerinde oldukça yanlı olabilir ve aşağıdaki gibi ifade edilir (Burhnam ve Anderson, 2004):

$$BIC = -2 \ln(L) + K \log(n) \quad (7.5)$$


7.3 İŞLEM KARAKTERİSTİK EĞRİSİ (ROC)

Sürekli ve sıralı sonuç veren tanı testlerinin performansını bir bütün olarak irdelemek amacıyla kullanılan yöntemlerden en popüler olanı işlem karakteristik eğrisi (ROC) dir. ROC, olası tüm kesim noktaları için “duyarlılık” (doğru pozitiflik) değerlerine karşılık “1- seçicilik” (yanlış pozitiflik) değerlerinin noktalanması ve bu noktaların birleştirilmesi ile elde edilen grafiktir. ROC' un içerdiği bilgiyi özetleyecek değişik ölçütler üzerinde durulmuşsa da, en yaygın olarak kullanılanı ROC eğrisi altında kalan alandır. ROC eğrisi altında kalan alanın tahmin edilmesinde parametrik olan ve olmayan yöntemler kullanılır (Öztuna, 2011).

ROC eğrisi, testin ayırt etme gücünün belirlenmesine, çeşitli testlerin kıyaslanmasına, uygun pozitiflik eşliğinin belirlenmesine, laboratuvar sonuçlarının

kalitesinin izlenmesine, uygulayıcının gelişiminin izlenmesine ve farklı uygulayıcılarının gelişiminin izlenmesine ve farklı uygulayıcılarının tanı etkilerinin kıyaslanmasını mümkün kılar (Dirican, 2001).

ROC, farklı değerler için hesaplanan, dikey eksen üzerinde doğru duyarlılık ve yatay eksen üzerinde yanlış duyarlılık oranları yer alan bir grafikdir (Tomak ve Bek, 2009).



Şekil 7.1 İdeal ve kötü performans gösteren testlere ilişkin ROC eğrileri (Dirican, 2001)

Dikey eksenin duyarlılığı ve yatay eksenin özgüllüğü gösterdiği ROC eğrisi altında kalan alan etkinlik düzeyine bağlı olarak 0.5 ile 1.0 arasında değerler alabilir. Bu alan ne kadar büyükse, tanı testi o kadar ayırım yeteneğine sahip demektir. Bu alan 0.975 ve daha üzeri ise mükemmel sayılmaktadır (Dirican, 2001).

ROC, birçok farklı alanda kullanılır. Örneğin; radar uygulamalarında, bir alıcının gürültüden sinyali ne kadar iyi algılayabildiğini ölçmek için kullanılırken sağlık alanında ROC eğrisi, negatif örneklerden pozitifleri ayırma yeteneğini ölçmek için kullanılır (Zweih ve Campell, 1993).

8 UYGULAMA

8.1 VERİ SEÇİMİ VE KAYIT TEKNİKLERİ

Çalışmada, Bonn Üniversitesi Klinik für Epileptologie laboratuvarından alınan EEG verileri kullanılmıştır. Bu veriler, 128 kanallı aynı amplifikatör sistemiyle kaydedilen EEG kayıtlarını içermektedir. Kayıtlar, 23.6 saniyede 173.61 Hz. örnekleme frekansı ile uluslararası 10-20 elektrot yerleştirme düzenine göre toplanan, 12 bitlik analog-sayısal dönüştürmeyle kaydedilen ve 0.53-40 Hz'lik bant geçiren filtreden geçirilmiş sinyallerdir. Bu sinyaller A, B, C, D, E olarak adlandırılan 5 veri setine ayrılmış olup her veri setinde 100 kanaldan sağlanan sinyaller tutulmaktadır. Tek bir kanal 4096 sinyal içermektedir. A ve B veri seti sağlıklı; C, D ve E veri setleri, epilepsi hastası bireylere aittir. A veri setindeki sinyaller sağlıklı gözü açık bireylerden, B veri setindekiler ise sağlıklı gözleri kapalı bireylerden alınmıştır. C deki veriler epilepsi hastası bireylerin beyinlerinin epileptik olmayan bölümlerinden, D dekiler ise epilepsi hastası bireylerin beyinlerinin epileptik bölümünden alınmıştır. Son olarak E veri seti ise, epilepsi hastası bireylerden kriz anında elde edilen verileri içermektedir (Andrzejak ve diğ., 2001).

8.2 ANALİZ ADIMLARI

8.2.1 Öznitelik Çıkarma

Her bir kanaldan (elektrot) elde edilen sinyalin sayısı 4096 dır. Elde edilen 4096 sinyal, ADD ile, sırasıyla 64, 128, 256, 512, 1024 sinyal içeren pencere genişliklerine ayrılmıştır. Bu kümelemeyi yapmaktaki amaç analizde kullanılacak gözlem sayısına karar vermektir. Gözlem sayısını bulmak için $(4096/\text{pencere genişliği}) \times 100$ formülü kullanılmıştır. Yapılan kümeleme sonucunda her birinde 100 kanal bulunan 5 veri seti için toplam 32000, 16000, 8000, 4000 ve 2000 gözlem elde edilmiştir. En iyi sonuç, 4096 sinyalin her bir kümesinde 512 sinyal içeren pencere genişliğine ayrılmasıyla yani 4000 gözlemle çalışılmasıyla bulunmuştur.

Analizde kullanılacak dalgacığa görsel olarak olarak karar vermek pek mümkün olmadığından, veri setlerindeki 512 sinyal içeren kümelerin her biri, öncelikle MATLAB Dalgacık Dönüşümü kullanılarak incelenmiş ve alt bantlarda ayırt edici özellikler bulunmaya çalışılmıştır. Farklı dalgacık aileleri (Daubechies, coiflets ve symlets) ve farklı dalgacık ayrıştırma seviyelerinde (1,2, ...,12) dalgacık dönüşüm denemeleri yapılmış ve en yüksek sınıflama performansı 5. dereceden Coiflet (coif5) ana dalgacık fonksiyonu ile 6. seviyede ayrıştırma sonucu detay (D) ve yaklaşım (A) katsayıları $D_1, D_2, D_3, D_4, D_5, D_6$ ve A_6 alt bantları elde edilmiştir.

8.2.2 Öznitelik Seçme

EEG sinyallerinden dalgacık dönüşümü sonucu elde edilen dalgacık katsayıları sinyali temsil eden öznitelik vektörleri olarak alındı. Dalgacık dönüşümünden elde edilen $D_1, D_2, D_3, D_4, D_5, D_6$ ve A_6 alt bantları için:

1. Her bir alt banttaki katsayıların maksimum değeri
2. Her bir alt banttaki katsayıların minimum değeri
3. Her bir alt banttaki katsayıların ortalama değeri
4. Her bir alt banttaki katsayıların standart sapma değeri
5. Her bir alt banttaki katsayıların aralık genişliği değeri
6. Her bir alt banttaki katsayıların medyan değeri
7. Her bir alt banttaki katsayıların housdorff metrik değeri

elde edilmiştir.


8.2.3 Girdilerin Ölçeklendirilmesi

Problemin verileri elde edilirken bazı durumlarda problemin girdileri arasında aşırı büyük ya da küçük değerler olabilir. NET girdiler hesaplanırken bu değerler aşırı büyük ya da küçük değerlerin doğmasına yol açarak ağı yanlış yönlendirebilirler. Problemden, bütün girdilerin belirli bir aralıkta ölçeklendirilmesi [1,-1] hem farklı ortamalardan gelen bilgilerin aynı ölçek üzerine indirgenmesine, hem de yanlış girilen çok büyük ve küçük değerlerin etkisinin ortadan kalkmasını sağlar. Çünkü bu durumda olası en büyük değer 1 değerini alır ve ondan büyük değerlerde öğrenme setine 1 değerini alarak girer. En küçük değer ise -1 değerini alır ve ondan küçük değerler öğrenme setine -1 olarak girer. Ölçeklendirmede kullanılacak yöntem

girdiler içindeki olumsuz etkileri önleyecek şekilde olmalıdır (Öztemel, 2012). Öznitelik matrisi elemanları, YSA'nın eğitim ve öğrenme performansını arttırmak için MATLAB da normalize edilmiştir.

8.2.4 YSA'nın Yapısının Belirlenmesi

Bu çalışmada, Şekil 8.1 de gösterilen bir girdi katmanı, bir gizli katman ve bir çıktı katmanı olmak üzere toplam üç katmandan oluşan bir YSA kullanılmıştır. YSA'nın gizli katmanında tansig aktivasyon fonksiyonu, çıktı katmanında ise soft-max aktivasyon fonksiyonu kullanılmıştır. Gizli katmanda soft-max aktivasyon fonksiyonunun kullanılmasıyla, YSA'lara girdi değerlerine göre sınıflandırma kabiliyeti kazandırılmaktadır. En iyi performansı gösteren modeli tespit etmek için, gizli katmandaki sinir sayılarını ve kestirilen modellerin kompleksliğini ölçmek için AIC, AICc, BIC bilgi kriterleriyle birlikte sınıflandırma doğruluk oranları kullanılmıştır. YSA'lerden daha genel modeller kestirebilmek için veri seti farklı oranlarda eğitim, geçerlilik ve test veri setlerine parçalanmış ve erken durdurma yaklaşımı kullanılmıştır. YSA'ların eğitiminde en dik azalış, ölçekli eşlenik gradyan, yarı Newton metodu ve Levenberg-Marquardt öğrenme algoritmalarından yararlanılmıştır.



Şekil 8.1 Çalışmada kullanılan çok katmanlı algılayıcı YSA modeli

Beş farklı sınıfı içeren EEG sinyalleri, ayırık dalgacık dönüşümü ile analiz edilip frekans alt-bantlarına ayrılmıştır. Bu bantlardan, elde edilen öznitelik vektörleri MATLAB da normalleştirildikten sonra farklı mimarilerdeki YSA lar için giriş olarak kullanılmış ve bu beş sınıf için sınıflama yapılmıştır. Sınıflamada YSA lar için giriş olarak kullanılan bağımlı ve bağımsız değişkenler Çizelge 8.1 de verildiği gibidir.

Çizelge 8.1 Sınıflamada kullanılan bağımlı ve bağımsız değişkenler

Bağımlı Değişken	Ölçüm Türü
A, B, C, D, E	Kategorik
Bağımsız Değişken	Ölçüm Türü
Alt banttaki katsayının maksimum değeri	Sayısal
Alt banttaki katsayının minimum değeri	Sayısal
Alt banttaki katsayının ortalama değeri	Sayısal
Alt banttaki katsayının standart sapma değeri	Sayısal
Alt banttaki katsayının aralık değeri	Sayısal
Alt banttaki katsayının medyan değeri	Sayısal
Alt banttaki katsayının housdorff met değeri	Sayısal

YSA'lar ile EEG sinyallerinin sınıflandırılmasında aşağıdaki adımlar takip edilmiştir:

Adım1: Sinyallerin analize hazır hale getirilmesi,

Adım2: Sinyallere ADD dönüşümü uygulayarak girdi değerlerinin elde edilmesi,

Adım3: Veri setinin öğrenme, test ve geçerlilik olarak üç kısma ayrılması,

Adım3: Ağın mimari yapısının belirlenmesi,

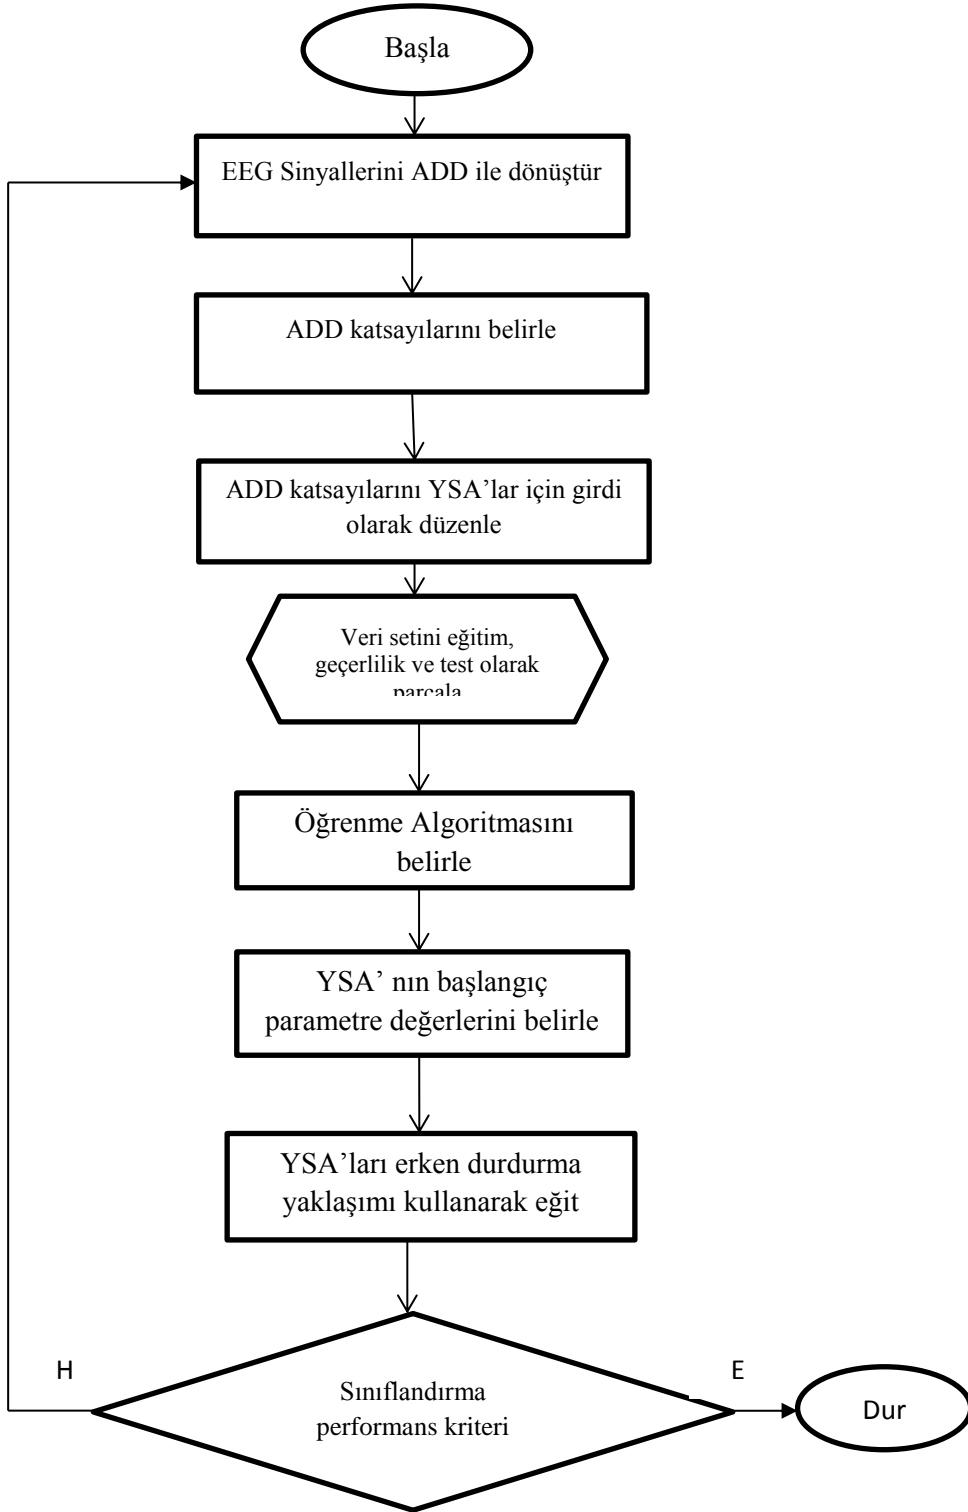
Adım4: Öğrenme algoritmasının belirlenmesi,

Adım5: Ağırlık başlangıç değerlerinin atanması,

Adım6: YSA'nın eğitilmesi,

Adım7: Bilgi Kriterleri ve sınıflandırma performansı yardımıyla en iyi YSA konfigürasyonunun belirlenmesi,

Yukarıdaki adımlar Şekil 8.2’de görselleştirilmiştir:



Şekil 8.2 YSA'nın akış diyagramı

8.3 GRADYAN ALGORİTMALARLA EĞİTİM

8.3.1 EN DİK AZALIŞ ALGORİTMASI

En dik azalış öğrenme algoritması ile oluşturulan YSA'da, eğitim, geçerlilik, test verileri ve tüm veri için doğru sınıflama yüzdesi, performans değerleri ve AIC, AICc ve BIC bilgi kriterlerinin değerleri incelendiğinde, gizli katmanında 12 nöron bulunan YSA modelinde elde edilen bu değerlerin yeterince küçük olduğu ve böylece en iyi doğru sınıflama performansının sağlandığı görülmüştür.

Çizelge 8.2 En dik azalış algoritması kullanılarak elde edilen YSA modelleri

Nöron sayısı	MSE	Eğitim verisi MSE	Geçerlilik verisi MSE	Test verisi MSE	AIC	AICc	BIC	Zaman (sn)	Eğitim seti sınıflama %	Geçerlilik seti sınıflama %	Test seti sınıflama %	Toplam sınıflama %
2	0,2286	0,2250	0,3964	0,2323	-5936,5778	-5936,4413	-5827,1671	0,0207	88,0	83,8	83,8	85,9
3	0,2268	0,2220	0,3959	0,2317	-5976,6908	-5976,4132	-5816,2218	0,0206	89,5	21,0	84,2	86,8
4	0,2158	0,2116	0,3976	0,2200	-6153,9071	-6153,4385	-5942,3797	0,0203	95,2	20,0	90,2	92,7
5	0,2131	0,2073	0,3986	0,2189	-6222,1214	-6221,4116	-5959,5356	0,0208	96,9	20,0	90,2	93,5
6	0,2142	0,2092	0,3985	0,2192	-6171,0353	-6170,0340	-5857,3911	0,0208	95,9	20,0	90,2	93,0
7	0,2130	0,2072	0,3990	0,2189	-6196,5529	-6195,2094	-5831,8504	0,0207	96,5	20,0	90,3	93,4
8	0,2123	0,2074	0,3991	0,2173	-6177,7951	-6176,0585	-5762,0343	0,0209	96,2	21,0	91,1	93,7
9	0,2115	0,2067	0,3993	0,2162	-6177,0682	-6174,8872	-5710,2491	0,0222	96,6	20,0	91,8	94,2
10	0,2132	0,2056	0,3988	0,2208	-6185,3623	-6182,6855	-5667,4848	0,0223	97,3	20,0	89,5	93,4
11	0,2105	0,2062	0,3993	0,2148	-6160,2489	-6157,0244	-5591,3130	0,0216	96,8	20,0	92,3	94,5
12	0,2074	0,2018	0,3995	0,2130	-6231,0278	-6227,2036	-5611,0336	0,0209	99,1	20,0	93,3	96,2
13	0,2115	0,2063	0,3994	0,2166	-6130,0493	-6125,5731	-5458,9967	0,0213	96,8	20,0	91,5	94,2
14	0,2099	0,2038	0,3993	0,2160	-6163,6305	-6158,4496	-5441,5195	0,0211	98,0	20,0	91,8	94,9
15	0,2097	0,2033	0,3992	0,2160	-6159,3093	-6153,3710	-5386,1401	0,0214	98,3	20,0	91,9	95,1

8.3.2 YARI NEWTON METODU

Yarı Newton metodu öğrenme algoritması ile oluşturulan YSA'da, eğitim, geçerlilik, test verileri ve tüm veri için doğru sınıflama yüzdesi, performans değerleri ve AIC, AICc ve BIC bilgi kriterlerinin değerleri incelendiğinde, gizli katmanında 11 nöron bulunan YSA modelinde elde edilen bu değerlerin yeterince küçük olduğu ve böylece en iyi doğru sınıflama performansının sağlandığı görülmüştür.

Çizelge 8.3 Yarı Newton Metodu algoritması kullanılarak elde edilen YSA modelleri

Nöron sayısı	MSE	Eğitim verisi MSE	Geçerlilik verisi MSE	Test verisi MSE	AIC	AICc	BIC	Zaman (sn)	Eğitim seti sınıflama %	Geçerlilik seti sınıflama %	Test seti sınıflama %	Toplam sınıflama %
2	0,2249	0,2212	0,3951	0,2286	-6004,9843	-6004,8477	-5895,57	00:29:20	90,5	21,0	85,5	88,0
3	0,2182	0,2143	0,398	0,2222	-6118,4132	-6118,1355	-5957,94	00:29:39	93,5	21,0	88,5	91,0
4	0,218	0,2139	0,3981	0,2221	-6110,0797	-6109,6111	-5898,55	00:29:43	93,8	21,0	89,1	91,4
5	0,2164	0,2117	0,3986	0,2211	-6138,9448	-6138,235	-5876,36	00:29:31	94,6	20,0	89,0	91,8
6	0,2136	0,2095	0,399	0,2177	-6165,5946	-6164,5934	-5851,95	00:30:12	95,5	20,0	91,0	93,2
7	0,2138	0,2076	0,3989	0,2199	-6188,1094	-6186,7659	-5823,41	00:31:09	96,5	20,0	89,9	93,2
8	0,2137	0,208	0,3992	0,2195	-6166,6377	-6164,9011	-5750,88	00:30:19	96,0	20,0	90,1	93,1
9	0,2122	0,2057	0,3989	0,2186	-6196,7415	-6194,5605	-5729,92	00:30:47	97,3	20,0	90,5	93,9
10	0,2122	0,2055	0,3991	0,2189	-6187,9308	-6185,2539	-5670,05	00:32:09	97,2	20,0	90,3	93,7
11	0,2069	0,2012	0,3994	0,2127	-6258,3794	-6255,1549	-5689,44	00:32:00	99,5	20,0	93,3	96,4
12	0,2089	0,2025	0,3993	0,2153	-6217,8256	-6214,0014	-5597,83	00:32:47	98,8	20,0	92,2	95,5
13	0,2121	0,2072	0,3993	0,2169	-6112,0077	-6107,5315	-5440,96	00:31:46	96,3	20,0	91,5	93,9
14	0,2108	0,2049	0,3992	0,2167	-6142,3962	-6137,2153	-5420,29	00:30:33	97,4	20,0	91,5	94,4
15	0,2097	0,2037	0,3992	0,2157	-6153,3566	-6147,4182	-5380,19	00:31:04	98,1	20,0	91,8	94,9

8.3.3 ÖLÇEKLİ EŞLENİK GRADYAN

Ölçekli eşlenik gradyan öğrenme algoritması ile oluşturulan YSA'da, eğitim, geçerlilik, test verileri ve tüm veri için doğru sınıflama yüzdesi, performans değerleri ve bilgi kriterlerinin değerleri incelendiğinde, gizli katmanında 7 ve 8 nöron bulunan YSA modelinin değerleri birbirine yakın çıktığı için, en iyi performansın bu iki model için elde edildiği görülmektedir. Doğru sınıflama yüzdesi, gizli tabakasında 8 nöron bulunan YSA modeline kadar artmış daha sonra azalmıştır. Yani, gizli nöron sayısı en fazla 8 olana kadar arttırmak model başarısını artırır, 8den fazla nöron sayısı ile çalışmak sınıflama başarısını düşürür.

Çizelge 8.4 Ölçekli eşlenik gradyan algoritması kullanılarak elde edilen YSA modeller

Nöron sayısı	MSE	Eğitim verisi MSE	Geçerlilik verisi MSE	Test verisi MSE	AIC	AICc	BIC	Zaman (sn)	Eğitim seti sınıflama %	Geçerlilik seti sınıflama %	Test seti sınıflama %	Toplam sınıflama %
2	0,2286	0,225	0,3964	0,3964	-5936,5778	-5936,4413	-5827,1671	00:28:02	88,0	19,0	83,8	85,9
3	0,2268	0,222	0,3959	0,2317	-5976,6908	-5976,4132	-5816,2218	00:27:31	89,5	22,0	84,2	86,8
4	0,2185	0,2149	0,3965	0,2222	-6092,4538	-6091,9852	-5880,9264	00:30:15	93,6	21,0	89,1	91,3
5	0,2136	0,2083	0,3983	0,2189	-6203,2964	-6202,5867	-5940,7106	00:29:07	96,4	20,0	90,5	93,5
6	0,2114	0,2048	0,3981	0,218	-6256,8486	-6255,8473	-5943,2044	00:28:31	98,5	21,0	90,6	94,5
7	0,2057	0,2018	0,3989	0,2097	-6301,8663	-6300,5228	-5937,1638	00:28:15	99,6	20,0	95,3	97,5
8	0,2045	0,2018	0,3989	0,2072	-6287,3051	-6285,5684	-5871,5442	00:28:35	99,6	20,0	96,8	98,2
9	0,2058	0,2019	0,399	0,2098	-6272,7823	-6270,6013	-5805,9632	00:28:01	99,5	20,0	95,0	97,3
10	0,2051	0,201	0,3996	0,2092	-6274,8656	-6272,1888	-5756,9881	00:29:16	99,5	20,0	95,3	97,4
11	0,2113	0,206	0,3994	0,2166	-6163,6818	-6160,4573	-5594,7459	00:31:22	97,0	20,0	91,3	94,1
12	0,2126	0,2069	0,3992	0,2183	-6131,3877	-6127,5636	-5511,3935	00:31:35	96,5	20,0	90,6	93,5
13	0,2106	0,2046	0,3993	0,2166	-6162,5798	-6158,1037	-5491,5273	00:30:13	97,5	20,0	91,5	94,5
14	0,2109	0,2046	0,3992	0,2172	-6149,6287	-6144,4479	-5427,5178	00:31:17	97,6	20,0	91,0	94,3
15	0,2076	0,2015	0,3995	0,2137	-6196,7017	-6190,7634	-5423,5325	00:32:07	99,3	20,0	92,8	96,0

8.3.4 LEVENBERG - MARQUARDT

Levenberg-Marquard öğrenme algoritması ile oluşturulan YSA'da, eğitim, geçerlilik, test verileri ve tüm veri için doğru sınıflama yüzdesi, performans değerleri ve AIC, AICc ve BIC bilgi kriterlerinin değerleri incelendiğinde, gizli katmanında 10 nöron bulunan YSA modelinde elde edilen bu değerlerin yeterince küçük olduğu ve böylece en iyi doğru sınıflama performansının sağlandığı görülmüştür. Gizli katmandaki nöron sayısı arttırılırsa modelin sınıflama başarısının düştüğü görülmektedir.

Çizelge 8.5 Levenberg-Marquard algoritması kullanılarak elde edilen YSA modelleri

Nöron sayısı	MSE	Eğitim verisi MSE	Geçerlilik verisi MSE	Test verisi MSE	AIC	AICc	BIC	Zaman (sn)	Eğitim seti sınıflama %	Geçerlilik seti sınıflama %	Test seti sınıflama %	Toplam sınıflama %
2	0,2172	0,2142	0,3968	0,2202	-6132,5065	-6132,3699	-6023,0958	01:19:06	93,7	21,0	90,0	91,8
3	0,215	0,2116	0,3982	0,2183	-6167,7497	-6167,4721	-6007,2807	01:23:29	94,8	22,0	91,0	92,9
4	0,2507	0,2497	0,3897	0,2517	-5491,6574	-5491,1887	-5280,1299	01:30:20	76,8	22,0	75,3	76,1
5	0,2178	0,2138	0,3963	0,2219	-6098,889	-6098,1792	-5836,3032	01:40:07	94,6	20,0	89,9	92,3
6	0,2268	0,2234	0,3903	0,2301	-5908,8219	-5907,8207	-5595,1778	01:50:58	92,5	21,0	87,8	90,1
7	0,2167	0,212	0,3966	0,2213	-6104,4184	-6103,0749	-5739,7159	01:53:56	95,3	20,0	89,8	92,5
8	0,2239	0,2205	0,3915	0,2274	-5933,3085	-5931,5718	-5517,5476	02:06:07	94,0	20,0	89,0	91,5
9	0,2247	0,2204	0,3912	0,2291	-5920,7251	-5918,5441	-5453,9059	02:20:51	93,7	21,0	87,8	90,8
10	0,2169	0,2128	0,394	0,2211	-6048,313	-6045,6362	-5530,4355	02:32:48	96,5	20,0	91,3	93,9
11	0,2211	0,2169	0,3928	0,2253	-5957,683	-5954,4585	-5388,7471	02:47:10	94,5	20,0	89,1	91,8
12	0,2241	0,2206	0,3917	0,2276	-5875,9478	-5872,1236	-5255,9536	03:04:07	93,3	20,0	89,0	91,2
13	0,2234	0,2192	0,3926	0,2275	-5887,0786	-5882,6024	-5216,026	03:24:39	93,6	20,0	88,2	90,9
14	0,2266	0,2227	0,3907	0,2304	-5808,8677	-5803,6869	-5086,7568	03:42:40	92,5	20,0	87,4	89,9
15	0,2281	0,2245	0,3901	0,2318	-5764,3679	-5758,4296	-4991,1987	03:56:10	91,8	20,0	87,5	89,6


8.3.5 EN İYİ YSA MODELLERİNİN KARŞILAŞTIRILMASI

Çalışmada, farklı eğitim, geçerlilik ve test verisi oranları ile 4 farklı algoritma kullanılarak eğitilen YSA'lerden elde edilen en iyi modellerin karşılaştırılması aşağıdaki gibidir.

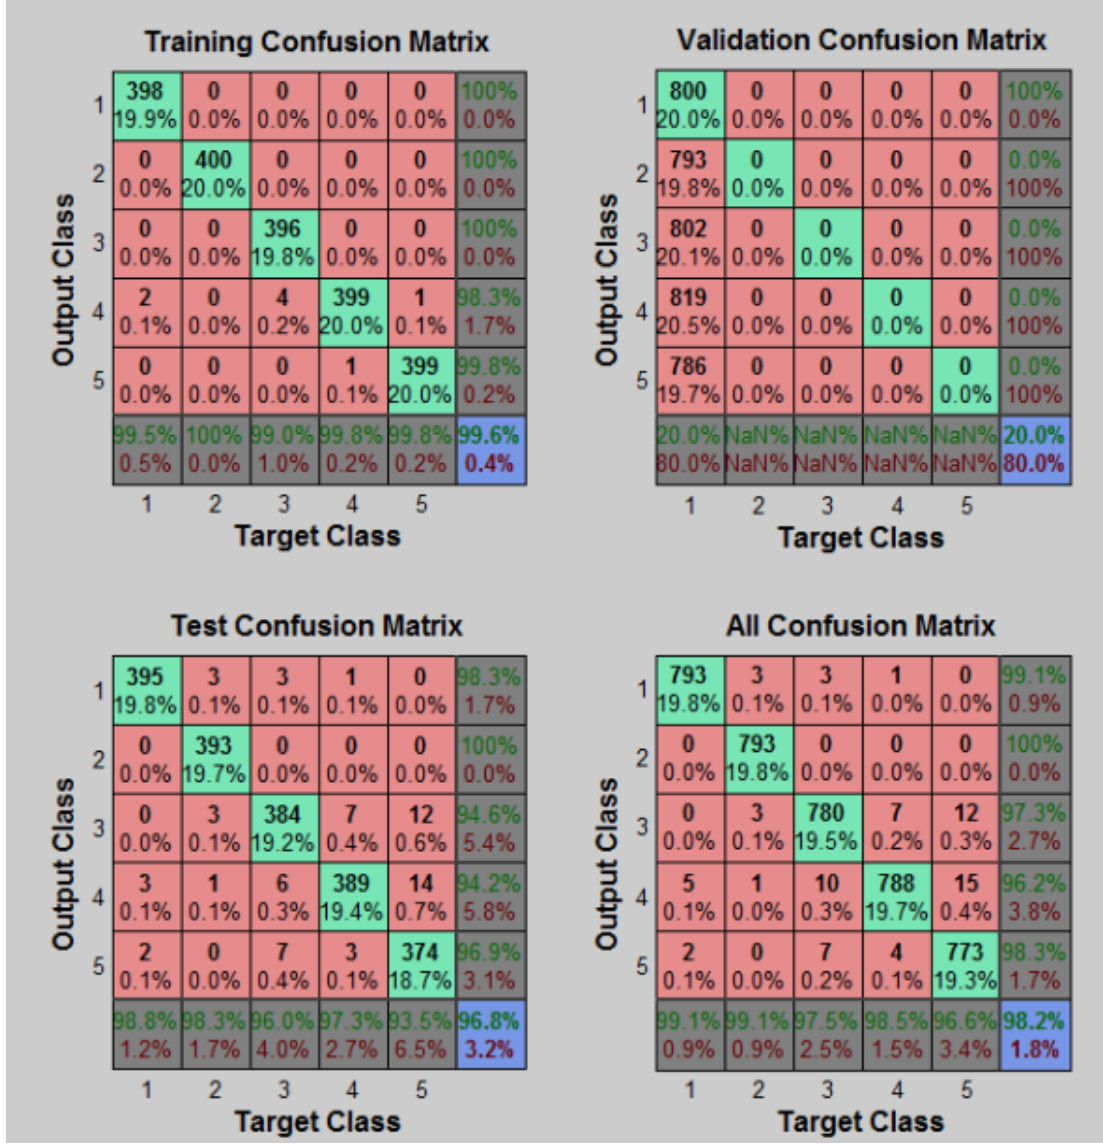
Çizelge 8.6 En iyi YSA modellerinin karşılaştırılması

Nöron sayısı	MSE	Eğitim verisi MSE	Geçerlilik verisi MSE	Test verisi MSE	AIC	AICc	BIC	Zaman (sn)	Eğitim seti sınıflama %	Geçerlilik seti sınıflama %	Test seti sınıflama %	Toplam sınıflama %
Levenberg- Marquardt												
10	0,2169	0,2128	0,394	0,2211	-6048,31	-6045,64	-5530,4355	02:32:48	96,5	20	91,3	93,9
En Dik Azalış												
12	0,2074	0,2018	0,3995	0,213	-6231,03	-6227,2	-5611,0336	00:30:10	99,1	20	93,3	96,2
Yarı Newton Metodu												
11	0,2069	0,2012	0,3994	0,2127	-6258,38	-6255,15	-5689,4435	00:32:00	99,5	20	93,3	96,4
Ölçekli Eşlenik Gradyan												
8	0,2045	0,2018	0,3989	0,2072	-6287,31	-6285,57	-5871,5442	00:28:35	99,6	20	96,8	98,2

Levenberg – Marquardt algoritması ile elde edilen YSA modelinde elde edilen en iyi doğru sınıflama başarısı %93.9 iken, en dik azalış algoritması ile elde edilen YSA modelinde bu başarı %96.2, yarı Newton metodu algoritması ile elde edilen YSA modelinde bu %96.4 ve ölçekli eşlenik gradyanda ise elde edilen bu başarı %98.2dir. Görüldüğü gibi, farklı öğrenme algoritmaları ile eğitilen YSA modellerinin başarıları karşılaştırıldığında en yüksek başarı ölçekli eşlenik eşlenik gradyan algoritmasına aittir. En iyi modeldeki eğitim verisi, geçerlilik verisi, test verisi ve tüm veriye ait ROC değerleri de Şekil 8.3. de verildiği gibidir.



Şekil 8.3 En iyi YSA modeline ait ROC eğrileri



Şekil 8.4 En iyi YSA modeline ait sınıflama değerleri

8.4 ÇOK KATEGORİLİ LOJİSTİK REGRESYON

Bu çalışmada elde edilen EEG sinyalleri (Andrzejak ve diğ., 2001) farklı coif dalgacıkları (2, 3, 4, 5), farklı gözlem sayıları (2000, 4000, 8000) ve farklı bağımsız değişken sayıları (35, 42, 49) ile ADD dönüşümüne uğrayan sinyallerden elde edilen değerler, SPSS 21.0 kullanılarak çok kategorili lojistik regresyon analizine girdi olarak verilmiş ve bağımlı değişkeni beş kategori olan çok kategorili lojistik regresyon ile sınıflama yapılmıştır. SPSS 21.0 da Analyze > Regression > Multinomial Logistic Regression seçeneğinden Multinomial Logistic Regression penceresi görüntülenmiştir. Açılan pencerede, bağımsız değişkenler *covariate* bölümüne, bağımlı değişken *dependent* bölümüne aktarılmıştır. Model olarak *main*

effects seçilmiştir, dağılım ölçekleme için *none* seçilmiştir. Güven aralığı %95 alınmıştır. En iyi sonuç, coif 2 dalgacık türü, 2000 gözlem ve 49 bağımsız değişkenli model ile elde edilmiştir. En iyi model için modelin yeterliliğini test etmede kullanılan Mcfadden R^2 , Cox-Snell ve Nagelkerke R^2 , sözde R^2 istatistikleri yorumlar aşağıdaki gibidir:

Çizelge 8.7 Pseudo R-Square tablosu

Pseudo R-Square	
Cox and Snell	,920
Nagelkerke	,958
McFadden	,785

gibi elde edilir. Pseudo R-Square istatistiklerinden Cox and Snell ve Nagelkerke istatistikleri 1'e oldukça yakın değerler olduğu için modelin istatistiksel olarak yeterli olduğu söylenebilir. McFadden istatistiğinin de oldukça büyük bir değere sahip olduğu görülmektedir.

Çizelge 8.8 Sınıflandırma tablosu

Classification						
Observed	Predicted					Percent Correct
	1,00	2,00	3,00	4,00	5,00	
1,00	364	26	9	1	0	91,0%
2,00	39	359	1	0	1	89,8%
3,00	9	0	302	89	0	75,5%
4,00	4	1	126	268	1	67,0%
5,00	0	0	1	1	398	99,5%
Overall Percentage	20,8%	19,3%	22,0%	18,0%	20,0%	84,6%

Sınıflandırma tabloları, uyum iyiliği için kullanılan bir başka ölçüttür. Yukarıdaki sınıflandırma tablosuna göre, modelin %84,6 doğru sınıflandırma yüzdesine sahip olduğu görülmektedir. A setinde sınıflama oranı %91,0, B setinde sınıflama oranı %89,8, C setinde sınıflama oranı %75,5, D setinde sınıflama oranı %67,0 ve E setinde sınıflama oranı %99,5 olarak bulunmuştur.

Çizelge 8.9 Modelin uyum iyiliği

Goodness-of-Fit			
	Chi-Square	df	Sig.
Pearson	8307,435	7884	,000
Deviance	1384,224	7884	1,000

$H_0 =$ Tahmin edilen model uyumludur.

$H_1 =$ Tahmin edilen model uyumlu değildir.

Verinin modele uygunluğunun testi için model uyum iyiliği tablosu incelenebilir. Yukarıdaki tablo incelendiğinde Pearson ve Deviance istatistiklerinin anlamlılık değerlerine bakıldığında 0 ve 1 olduğu görülmektedir. Bu değerlerin birinin anlamlılık değerinin 0.05 den küçük diğerinin büyük olduğu görülmektedir. Burada olduğu gibi, Pearson ve Deviance istatistiklerinin sonucu her zaman aynı çıkmayabilir. Bu durumda model uyum bilgisi tablosundaki anlamlılık değerinin ne olduğuna bakılarak yorum yapılır.

Çizelge 8.10 Model uyum bilgisi tablosu

Model Uyum Bilgisi						
Model	Model Fitting Criteria			Likelihood Ratio Tests		
	AIC	BIC	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	6445,752	6468,155	6437,752			
Final	1616,224	2265,929	1384,224	5053,528	112	,000

$H_0 =$ Bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişki anlamsızdır.

$H_1 =$ Bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişki anlamlıdır.

Model uyum bilgileri çizelgesi incelendiğinde, final modelinin anlamlılık değerinin 0 olduğu görülmektedir. Buradan modelin anlamlı olduğu söylenebilir. Yani, modelde bağımsız değişkenler ile bağımlı değişkenler arasında anlamlı bir ilişki olduğu söylenebilir. Ayrıca, AIC ve BIC değerlerinin de son modelde daha küçük olduğu görülmektedir.

Wald istatistiği zaman zaman güvenilir olmayan sonuçlar verebilir bu yüzden olabilirlik oran değişken elemeye daha iyi bir ölçüttür (Field, 2005).

Çizelge 8.11 Olabilirlik oran testleri tablosu

Likelihood Ratio Tests						
Effect	Model Fitting Criteria			Likelihood Ratio Tests		
	AIC of Reduced Model	BIC of Reduced Model	-2 Log Likelihood of Reduced Model	Chi-Square	df	Sig.
Intercept	2176,191	2803,492	1952,191	567,967	4	,000
X1	1616,224	2265,929	1384,224 ^a	,000	0	.
X2	1616,224	2265,929	1384,224 ^a	,000	0	.
X3	1616,224	2265,929	1384,224 ^a	,000	0	.
X4	1790,801	2418,102	1566,801	182,577	4	,000
X5	1616,224	2265,929	1384,224 ^a	,000	0	.
X6	1616,224	2265,929	1384,224 ^a	,000	0	.
X7	1641,076	2268,377	1417,076 ^b	32,852	4	,000
X8	1616,224	2265,929	1384,224 ^a	,000	0	.
X9	1616,224	2265,929	1384,224 ^a	,000	0	.
X10	1616,224	2265,929	1384,224 ^a	,000	0	.
X11	1678,144	2305,445	1454,144	69,920	4	,000
X12	1616,224	2265,929	1384,224 ^a	,000	0	.
X13	1616,224	2265,929	1384,224 ^a	,000	0	.
X14	1613,682	2240,983	1389,682	5,458	4	,243
X15	1616,224	2265,929	1384,224 ^a	,000	0	.
X16	1616,224	2265,929	1384,224 ^a	,000	0	.
X17	1616,224	2265,929	1384,224 ^a	,000	0	.
X18	1761,389	2388,690	1537,389	153,165	4	,000
X19	1616,224	2265,929	1384,224 ^a	,000	0	.
X20	1616,224	2265,929	1384,224 ^a	,000	0	.
X21	1661,766	2289,067	1437,766 ^b	53,542	4	,000
X22	1616,224	2265,929	1384,224 ^a	,000	0	.
X23	1616,224	2265,929	1384,224 ^a	,000	0	.
X24	1616,224	2265,929	1384,224 ^a	,000	0	.
X25	1644,025	2271,326	1420,025	35,801	4	,000
X26	1616,224	2265,929	1384,224 ^a	,000	0	.
X27	1616,224	2265,929	1384,224 ^a	,000	0	.
X28	1610,277	2237,578	1386,277	2,053	4	,726
X29	1616,224	2265,929	1384,224 ^a	,000	0	.
X30	1616,224	2265,929	1384,224 ^a	,000	0	.
X31	1616,224	2265,929	1384,224 ^a	,000	0	.
X32	1627,435	2254,736	1403,435	19,211	4	,001
X33	1616,224	2265,929	1384,224 ^a	,000	0	.
X34	1616,224	2265,929	1384,224 ^a	,000	0	.

X35	1609,907	2237,209	1385,907	1,683	4	,794
X36	1616,224	2265,929	1384,224 ^a	,000	0	.
X37	1616,224	2265,929	1384,224 ^a	,000	0	.
X38	1616,224	2265,929	1384,224 ^a	,000	0	.
X39	1669,509	2296,810	1445,509 ^b	61,285	4	,000
X40	1616,224	2265,929	1384,224 ^a	,000	0	.
X41	1616,224	2265,929	1384,224 ^a	,000	0	.
X42	1616,224	2265,929	1384,224 ^a	,000	0	.
X43	1616,224	2265,929	1384,224 ^a	,000	0	.
X44	1616,224	2265,929	1384,224 ^a	,000	0	.
X45	1616,224	2265,929	1384,224 ^a	,000	0	.
X46	1630,590	2257,891	1406,590	22,366	4	,000
X47	1616,224	2265,929	1384,224 ^a	,000	0	.
X48	1616,224	2265,929	1384,224 ^a	,000	0	.
X49	1616,224	2265,929	1384,224 ^a	,000	0	.

The chi-square statistic is the difference in -2 log-likelihoods between the final model and a reduced model. The reduced model is formed by omitting an effect from the final model. The null hypothesis is that all parameters of that effect are 0.

a. This reduced model is equivalent to the final model because omitting the effect does not increase the degrees of freedom.

b. The log-likelihood value cannot be further increased after maximum number of step-halving.

$H_0 =$ Bağımsız değişkeninin modeldeki varlığı anlamsızdır.

$H_1 =$ Bağımsız değişkeninin modeldeki varlığı anlamlıdır.

Olabilirlik oran testlerinin olduğu tablo incelendiğinde $X_4, X_7, X_{11}, X_{18}, X_{21}, X_{25}, X_{32}, X_{39}, X_{46}$ değişkenleri yani D_1 altbandı için standart sapma ve housdorff metrik değeri, D_2 altbandı için standart sapma değeri, D_3 altbandı için standart sapma ve housdorff metrik değeri ve D_4, D_5, D_6 ve A_6 altbantları için standart sapma değerleri için p değerleri 0.05 (anlamlılık) değerinden küçük olduğu için H_0 hipotezi red edilir ve H_1 hipotezi kabul edilir ve bu bağımsız değişkenlerin katsayılarının anlamlı olduğu sonucuna varılır.

8.5 EN İYİ ÇIKLAR MODELLERİN KARŞILAŞTIRILMASI

Aşağıdaki çizelgede farklı coif dalgacığı ile, farklı gözlem sayıları ve farklı bağımsız değişkenlerle ve beş kategorisi olan bağımlı değişken ile çok kategorili lojistik regresyon analizleri yapılmıştır. Çizelge incelendiğinde, bağımsız değişkenin sayısının artmasının modelin sınıflama performansında çok etki göstermemesine

karşın, gözlem sayısının azalmasıyla sınıflama başarısında artış olduğu görülmüştür. En yüksek sınıflama başarısı, coif2 dalgacık türü, 2000 gözlemlilik, 49 bağımsız değişkenli çoklu lojistik regresyon modelidir.

Çizelge 8.11 En iyi çok kategorili lojistik regresyon modellerinin karşılaştırılması

coif2																
Gözlem Sayısı	Bağımsız Değişken Sayısı	Cox and Snell	Nagelkerke	McFadden	Final AIC	Final BIC	-2 Log Likelihood	Pearson Chi-Square	Deviance Chi-Square	Final Chi-Square	Percent Correct A %	Percent Correct B %	Percent Correct C %	Percent Correct D %	Percent Correct E %	Percent Corrent All %
8000	35	0,882	0,919	0,664	8821,946	9408,87	8653,946	27279369	8653,946	17097,06	82,6	79,7	65,2	56,6	96,7	76,1
8000	42	0,884	0,921	0,67	8685,526	9384,246	8485,526	10366524	8485,526	17265,48	82,6	79,9	65,6	55,8	97,0	76,2
8000	49	0,877	0,913	0,651	9226,456	10036,97	8994,456	1,24E+34	8994,456	16756,55	82,9	79,8	66,7	55,1	96,4	76,2
4000	35	0,9	0,938	0,717	3816,767	4345,468	3648,767	271134,4	3648,767	9226,736	86,1	84,0	70,6	58,9	98,0	79,5
4000	42	0,9	0,937	0,714	3880,751	4510,156	3680,751	1,91E+16	3680,751	9194,753	86,0	84,3	69,1	57,3	98,0	78,9
4000	49	0,754	0,785	0,436	7498,577	8228,687	7266,577	1,2E+228	7266,577	5608,927	84,0	79,4	69,8	60,0	90,4	76,7
2000	35	0,916	0,954	0,769	1656,292	2126,768	1488,292	15903,62	1488,292	4949,46	88,0	88,5	72,3	64,0	99,5	82,5
2000	42	0,912	0,95	0,756	1768,082	2328,172	1568,082	5,14E+23	1568,082	4869,67	90,0	88,8	70,8	66,0	99,0	82,9
2000	49	0,92	0,958	0,785	1616,224	2265,929	1384,224	8307,435	3184,224	5053,528	91,0	89,8	75,5	67,0	99,5	84,6
coif3																
Gözlem Sayısı	Bağımsız Değişken Sayısı	Cox and Snell	Nagelkerke	McFadden	Final AIC	Final BIC	-2 Log Likelihood	Pearson Chi-Square	Deviance Chi-Square	Final Chi-Square	Percent Correct A %	Percent Correct B %	Percent Correct C %	Percent Correct D %	Percent Correct E %	Percent Corrent All %
8000	35	0,882	0,919	0,664	8813,844	9400,768	8645,844	8417050	8645,844	17105,16	82,5	79,5	65,2	55,3	96,6	75,8
8000	42	0,885	0,921	0,671	8674,833	9373,553	8474,833	2769482	8474,833	17276,17	83,1	79,8	66,3	55,7	96,9	76,4
8000	49	0,885	0,922	0,672	8677,982	9488,497	8445,982	2171549	8445,982	17305,02	83,2	80,3	67,3	54,4	97,0	76,4
4000	35	0,9	0,938	0,717	3817,806	4346,506	3649,806	456051,6	3649,806	9225,698	86,1	85,0	71,0	58,4	98,3	79,8
4000	42	0,902	0,94	0,723	3767,865	4397,27	3567,865	226958,7	3567,865	9307,639	86,0	84,5	69,6	57,4	98,0	79,1
4000	49	0,875	0,912	0,647	4781,424	5511,534	4549,424	3,99E+75	4549,424	8326,079	86,0	83,3	71,5	61,0	95,5	79,5
2000	35	0,915	0,954	0,767	1665,448	2135,924	1497,448	20048,42	1497,448	4940,304	89,8	88,5	72,8	65,3	99,3	83,1
2000	42	0,918	0,957	0,778	1629,501	2189,591	1429,501	6868,51	1429,501	5008,25	90,3	89,5	72,0	66,5	99,5	83,6
2000	49	0,699	0,728	0,373	4267,733	4917,438	4035,733	-	4035,733	4035,733	90,8	90,3	74,0	66,8	99,0	84,2
coif4																
Gözlem Sayısı	Bağımsız Değişken Sayısı	Cox and Snell	Nagelkerke	McFadden	Final AIC	Final BIC	-2 Log Likelihood	Pearson Chi-Square	Deviance Chi-Square	Final Chi-Square	Percent Correct A %	Percent Correct B %	Percent Correct C %	Percent Correct D %	Percent Correct E %	Percent Corrent All %
8000	35	0,882	0,919	0,664	8821,781	9408,706	8653,781	9721714	8653,781	17097,23	82,4	80,1	65,1	54,7	96,6	75,8
8000	42	0,884	0,921	0,67	8687,466	9386,185	8487,466	1778390	8487,466	17263,54	83,1	79,9	66,7	55,3	96,9	76,4
8000	49	0,885	0,922	0,672	8687,783	9498,297	8455,297	1371197	8455,783	17295,22	83,2	80,3	67,2	53,6	96,9	76,2
4000	35	0,875	0,912	0,647	4716,126	5244,826	4548,126	7,56E+22	4548,126	8327,377	86,1	81,5	72,1	58,0	94,6	78,5
4000	42	0,886	0,922	0,673	4406,01	5035,415	4206,01	2,55E+81	4206,01	8669,493	86,5	84,4	68,9	58,0	97,1	79,0
4000	49	0,815	0,849	0,525	6347,659	7077,769	6115,659	9,8E+196	6115,659	6759,844	83,8	82,0	70,5	61,1	94,1	78,3
2000	35	0,915	0,953	0,766	1675,213	2145,689	1507,213	21404,44	1507,213	4930,538	90,3	89,5	73,0	65,0	99,3	83,4
2000	42	0,918	0,956	0,778	1631,551	2191,641	1431,551	8786,756	1431,551	5006,201	90,5	90,3	72,3	66,3	99,3	83,7
2000	49	0,91	0,948	0,75	1843,447	2493,152	1611,447	1,47E+25	1611,447	4826,304	89,8	89,8	73,8	66,0	98,5	83,6
coif5																
Gözlem Sayısı	Bağımsız Değişken Sayısı	Cox and Snell	Nagelkerke	McFadden	Final AIC	Final BIC	-2 Log Likelihood	Pearson Chi-Square	Deviance Chi-Square	Final Chi-Square	Percent Correct A %	Percent Correct B %	Percent Correct C %	Percent Correct D %	Percent Correct E %	Percent Corrent All %
8000	35	0,882	0,919	0,664	8832,567	9419,492	8664,567	18190602	8664,567	17086,44	82,6	80,2	64,7	54,1	96,8	75,7
8000	42	0,884	0,921	0,67	8704,052	9402,772	8504,052	1537788	8504,052	17246,95	82,6	80,2	66,7	54,6	96,8	76,2
8000	49	0,885	0,922	0,671	8701,276	9511,791	8469,276	1207968	8469,276	17281,73	83,1	80,3	67,3	53,1	96,9	76,1
4000	35	0,816	0,85	0,526	6276,987	6805,687	6108,987	1,2E+163	6108,987	6766,517	86,6	83,5	71,1	57,0	94,8	78,6
4000	42	0,833	0,868	0,556	5920,091	6549,496	5720,091	1,4E+202	5720,091	7155,412	86,0	84,3	68,5	57,1	96,9	78,6
4000	49	0,89	0,927	0,685	4289,761	5019,871	4057,761	3,9E+51	4057,761	8817,742	86,5	84,6	71,8	61,0	96,8	80,1
2000	35	0,915	0,953	0,765	1682,716	2153,191	1514,716	19895,87	1514,716	4923,036	90,0	89,8	73,8	64,8	99,0	83,5
2000	42	0,918	0,956	0,775	1646,028	2206,118	1446,028	11245,47	1446,028	4991,724	91,0	90,3	72,0	65,0	99,3	83,5
2000	49	0,914	0,952	0,762	1762,877	2412,582	1530,877	33557900	1530,877	4906,874	89,8	88,8	73,5	67,3	98,0	83,5

8.6 EN İYİ MODELLERİN KARŞILAŞTIRILMASI

Yapay sinir ağları ile model oluşturulduğunda, Çizelge 8.12 de gösterildiği gibi en iyi sınıflama oranı %98.2 olarak elde edilmiştir. Çok kategorili lojistik regresyon ile model oluşturulduğunda ise, Çizelge 8.7 de gösterildiği gibi en iyi sınıflama oranı %84.6 olarak elde edilmiştir. Bu iki model karşılaştırıldığında, YSA modelinin ÇKLR modeline göre daha iyi sonuç verdiği görülmektedir.

Çizelge 8.12 En iyi modellerin karşılaştırılması

Model	Öğrenme Algoritması	Gözlem Sayısı	Bağımsız Değişken Sayısı	AIC	BIC	A Seti Sınıflama %	B Seti Sınıflama %	C Seti Sınıflama %	C Seti Sınıflama %	D Seti Sınıflama %	Toplam Sınıflama %
YSA	lm	4000	49	-6048,31	-5530,4355	98,5	98,9	91,6	89,9	90,6	93,9
	gd	4000	49	-6231,03	-5611,0336	99,3	99,3	95,8	93,8	93	96,2
	bfg	4000	49	-6258,38	-5689,4435	99	99	94,3	95,5	94,3	96,4
	scg	4000	49	-6287,31	-5871,5442	99,1	99,1	97,5	98,5	96,6	98,2
ÇKLR	-	2000	49	1616,224	2265,929	91	89,8	75,5	67	99,5	84,6

9 SONUÇ VE ÖNERİLER

Bu çalışmada, (Andrzejak ve diğ., 2001) çalışmasındaki veri tabanı kullanılarak EEG sinyalleri kullanılmıştır. Her setteki EEG verisi kendi aralarında kümeler ayrıştırılmıştır. Daha sonra bu kümelerdeki sinyaller ADD ile dönüşüme uğramış ve öznelik vektörleri elde edilmiştir. Elde edilen bu öznelik vektörleri, farklı nöronlar denenerek AIC, AICc ve BIC bilgi kriterleri yardımıyla belirlenen nöron sayısı ve 3 katmanlı YSA sınıflayıcısı için girdi olarak kullanılmıştır. Sınıflandırma sonucunda, eğitim ve test verisi ve tüm verinin performansı, doğru sınıflama yüzdesi ve bilgi kriterleri (AIC, AICc, BIC) değerlendirilerek en iyi sınıflama yüzdesinin %98.2 olduğu görülmüştür. Ayrıca, eğitim verisini %99.6 ve test verisini de %96.8 doğruluk oranı ile sınıflamıştır. Bunun yanı sıra Daubechies dalgacı ile ADD dönüşümü yapılmış ve YSA ile sınıflandırma yapıldıktan sonra, elde edilen en iyi sonuç altıncı seviyeden ayrıştırma, scg algoritması, 3 katmanlı ve gizli katmanında 13 nöron bulunan db10 dalgacı ile %97.9 olarak bulunmuştur. Ayrıca, eğitim verisini %99.6 ve test verisini de %96.3 doğruluk oranı ile sınıflamıştır. Son olarak Symlet dalgacı ile yapılan ADD dönüşümü ve YSA sınıflandırmasından sonra, elde edilen en iyi sonuç altıncı seviyeden ayrıştırma, scg algoritması, 3 katmanlı ve gizli katmanında 13 nöron bulunan sym3 dalgacı ile %96.4 olarak bulunmuştur. Ayrıca, eğitim verisini %99 ve test verisini de %92.9 doğruluk oranı ile sınıflamıştır.

Uygun bir YSA yapısının fonksiyon tipinin belirlenmesi, aynı YSA yapısının eğitime tabi tutulmasında bile başlangıç ağırlık değerleri rasgele atandığı için benzer sonuçlar üretilemeyebilir. Bu yüzden, YSA'lar birden fazla kez çalıştırılıp onların içinden performansı en iyi olanların parametre değerleri başka bir eğitim için başlangıç değerleri olarak alınabileceği gibi daha önceki parametre değerlerinin ortalamaları da başlangıç değeri olarak kullanılabilir. YSA'ların eğitiminde diğer bir problem olan model kompleksliği, bu çalışmada bilgi kriterlerinin ve erken durdurma yaklaşımının kullanılmasıyla en aza indirgenmeye çalışılmıştır.

Çok kategorili lojistik regresyonda en iyi sınıflama performansı coif2 dalgacığı ile yapılan ADD ile 2000 gözlem ve 49 bağımsız deęişkenli regresyon modeli %84.6 olarak elde edilmiştir.

Gelecek çalışmalarda gradyan algoritmalar yerine meta-sezgisel algoritmaların kullanılması ve klasik YSA'lar yerine hibrit yaklaşımların modifikasyonunun ele alınması düşünölmektedir.

KAYNAKLAR

- Agresti, A.**, 1990. Categorical Data Analysis, *John Wiley & Sons*, New York.
- Akaike, H.**, 1973. Information Theory and an Extension of The Maximum Likelihood Principle, *Second International Symposium on Information Theory*, 267-281.
- Akaike, H.**, 1974. A New Look at The Statistical Model Identification, *IEEE Transactions on Automatic Control AC-19*, 716-723.
- Akaike, H.**, 1985. Prediction and Entropy, *A Celebration of Statistics*, 1-24.
- Akaike, H.**, 1994. Implications of The Informational Point of View on The Development of Statistical Science, *Engineering and Scientific Applications*, **3**, 27-38.
- Akçay, A. ve Demirel, A.**, 2011. Pyometralı Köpeklerde Bazı Kan Paramterelerinin Optimal Pozitiflik Eşiğinin Özgün Oranlar ve ROC (Receiver Operating Characteristic) Eğrisi Yöntemi ile Belirlenmesi, *Erciyes Üniversitesi Veterinerlik Fakültesi Dergisi*, **8(3)**, 153-163.
- Aktaş, C. ve Erkuş, O.**, 2009. Lojistik Regresyon Analizi ile Eskişehir'in Sis Kestirimin İncelenmesi, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, **8(16)**, 47-59.
- Alpar, R.**, 2011. Uygulamalı Çok Değişkenli İstatistiksel Yöntemler, *Detay Yayıncılık*, Ankara.
- Alpaydın, E.**, 2010. Introduction to Machine Learning, Second Edition, *The MIT Press*, London.
- Anders, U and Korn, O.**,1999. Model selection in neural networks, *Neural networks*, **12**, 309-323.
- Anderson, D. and McNeill, G.**, 1992. Artificial Neural Networks Technology, *A DACS State-of-the-Art Report*, New York.
- Andersen, E.B.**, 1997. Introduction to The Statistical Analysis of Categorical Data, *Springer-Verlag*, Berlin.
- Andrzejak, R.G., Lehnertz, K., Rieke, C., Mormann, F., David, P. and 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, *Pyhsical Review E*, **64(6)**, 1-8.
- Apolloni, B., Avanzini, G., Cesa-Bianci, N. and Ronchini, G.**, 1990. Diagnosis of Epilepsy via Back-Proagation, *Proceedings of International Joint Conference on Neural Networks*, **2**, 571-574.
- Ashwal, S. and Rust, R.**, 2003. Child Neurology in The 20th Century, *Pedia. Res.*, **53**, 345-361.

- Attwood, H.L. and Mackay, W.A.,** 1989. Essentials of Neurophysiology, B. C. Decker, Hamilton, Canada.
- Basu, J.K., Bhattacharyya, D. and Kim, T.,** 2010. Use of Artificial Neural Network in Pattern Recognition, *International Journal of Software Engineering and Its Application*, **4(2)**, 23-34.
- Beale, M.H., Hagan, M.T. and Demuth, H.B.,** 2001. Neural Networks Toolbox.
- Beale, M.H., Hagan, M.H. and Demuth, H.B.,** 2010. Neural Network Toolbox: User's Guide, The MathWorks, Inc., Natick, MA.
- Beale, M.H., Hagan, M.T. and Demuth, H.B.,** 2015. Neural Network Toolbox, User's Guide, Natick, MA.
- Bhattacharjee, D. and Kothari, V.K.,** 2007. A Neural Network System for Prediction of Thermal Resistance of Textile Fabrics, *Textile Research Journal*, **77**, 4-12.
- Bishop, C.M.,** 1995. Neural Network for Pattern Recognition, Microsoft Research Cambridge, UK.
- Bishop, C.,** 2010. Neural Networks for Pattern Recognition, *Oxford University Press*, New York.
- Blume, W.T., Luders, H.O., Mizrahi, E., Tassinari, C., van Emde Boas, W. and Engel J.,** 2001. Jr. Glossary of Descriptive Terminology for Ictal Semiology: Report of The ILAE Task Force on Classification and Terminology, *Epilepsia*, **42(9)**, 1212-1218.
- Box, G.E.P and Jenkins, G.M.,** 1970. Time Series Analysis: Forecasting and Control, *Holden- Day*, San Francisco.
- Bozdogan, H.,** 2000. Akaike's Information Criterion and Recent Developments in Information Complexity, *Journal of Mathematical Psychology*, **44**, 62-91.
- Burnham, K.P. and Anderson, D.R.,** 2004. Multimodel Inference Understanding AIC and BIC in Model Selection, *Sociological Methods & Research*, **33(2)**, 261-304.
- Chan, T.F. and Shen, J.,** 2005. Image Processing and Analysis, SIAM Publications, Philadelphia, PA.
- Commission on Classification and Terminology of The International League Against Epilepsy. Proposal for Revised Clinical and Electroencephalographic Classification of Epileptic Seizures. *Epilepsia* 1981, **22**, 489-501.
- Crone, S.F.,** 2004. Business Forecasting with Artificial Neural Networks, *Presantation of IBF Tutorial-Institute of Business Forecasting*, August 5th, Boston.
- Çetin, M., Uğur, A. ve Bayzan, Ş.,** 2006. İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı, *Akademik Bilişim Kongresi*, Pamukkale Üniversitesi, Denizli, Şubat 9-11.
- Daubechies, I.,** 1992. Ten Lectures on Wavelets, SIAM, Philadelphia.
- Demuth, H.B., Hagan, T.M. and Beale, M.H.,** 2015. Neural Network Toolbox, 4 User's Guide, Natick.

- Deveci, M. and Yavuz, S.,** 2013. İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağının Performansına Etkisi, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **40**, 167-187.
- Diez, P.F., Mut, V., Laciari, E., Torres, A. and Avila, E.,** 2009. Application of The Empirical Mode Decomposition to The Extraction of Features from EEG Signals for Mental Task Classification, in *31st Annual International Conference of the IEEE EMBS*, 2579-2582.
- Dirican, A.,** 2001. Tanı Testi Performansının Değerlendirilmesi ve Kıyaslanması, *Cerrahpaşa Tıp Dergisi*, **32**, 25-30.
- Doğan, E.,** 2011. Parsiyel ve Jeneralize Epilepsili Kadın ve Erkek Hastalarda Bazı Serum Mineral Değerlerinin Karşılaştırmalı Analizi, *Yüksek Lisans tezi*, Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü, Van.
- Duran, S.,** 2010. EEG Sinyallerinin Epilepsi Durumunun Model – Tabanlı Spektral Analiz Teknikleri İle Belirlenmesi, *Yüksek Lisans Tezi*, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Elmas, Ç.,** 2011. Yapay Zeka Uygulamaları, Yapay Sinir Ağları-Bulanık Mantık-Genetik Algoritma, *Seçkin Yayıncılık*, Ankara.
- Fagerland, M.W., David, W.H. and Bofin, A.M.,** 2008. Multinomial Goodness-of-Fit Tests for Logistic Regression Models, *Statistics in Medicine*, 17 January, **27**, 4238-4253.
- Fausett, L.,** 1994. Fundamentals of Neural Networks: Architectures, Algorithms and Applications, Prentice Hall International, New Jersey.
- Faraway, J. and Chatfield, C.,** 1998. Time Series Forecasting with Neural Networks: A Case Study, *Applied Statistics*, **47**, 231-250.
- Freitas, A.A.,** 2000. Understanding the Crucial Differences Between Classification and Discovery of Association Rules: A Position Paper, *ACM SIGKDD Explorations*, **2(1)**, 65-69.
- Fidell, L.S. and Tabachnick, B.G.,** 2007. Using Multivariate Statistics, *Pearson*, Boston.
- Field, A.,** 2005. Discovering Statistics Using SPSS, 2nd ed., London.
- Fowle, A.J. and Binnie, C.D.,** 2000. Uses and Abuses of The EEG in Epilepsy, *Epilepsia*, **41(3)**, 10-18.
- Freeman, J.A. and Skapura, D.M.,** 1991. Neural Networks, Algorithms, Applications and Programming Techniques, Addison-Wesley Publishing Co., MA.
- Gabor, A.J. and Seyal, M.,** 1992. Automated Interictal EEG Spike Detection Using Artificial Neural Networks, *Electroencephalography and Clinical Neurophysiology*, **83**, 271-280.
- Garver, M.S.,** 2002. Using Data Mining For Customer Satisfaction Research, *Journal of Marketing Research*, Spring, **14(1)**, 8-12.
- Gencay, R. and Dechert, D.W.,** 1992. An Algorithm for The N Lyapunov Exponents of An N-Dimensional Unknown Dynamical System, *Physica D: Nonlinear Phenomena*, **59**, 142-157.

- Grossmann, A. and Morlet, J.**, 1984. Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape. *SIAM Journal of Analysis*, **15**, 723-736.
- Golden, R.M.**, 1996. Mathematical Methods for Neural Network Analysis and Design, *The MIT Press*, Massachusetts.
- Güler, N.F., Übeyli, E.D. and Güler, İ.**, 2005. Recurrent Neural Networks Employing Lyapunov Exponents for EEG Signals Classification, *Expert Systems with Applications*, **29(3)**, 506-514.
- Güler, İ. and Übeyli, E.D.**, 2005. Adaptive Neuro-Fuzzy Inference System for Classification of EEG Signals Using Wavelet Coefficients, *Journal of Neuroscience Methods*, 15 April.
- Gürsoy, M.I. and Subaşı, A.**, 2008. DVM ile EEG İşaretlerinin Sınıflandırılmasında TBA, BBA ve DDA'nın Performansının Karşılaştırılması, *16. IEEE SIU (Signal Processing, Communication and Application) Konferansı*, 20-22 Nisan, 1-4.
- Hagan, M.T., Demuth, H.B., Beale, M.H. and Jesús, O.D.**, 2002. Neural Network Design, 2nd Edition, *Campus Publication Service*, Colorado.
- Haykin, S.**, 1994. Neural Networks: A Comprehensive Foundation, *Macmillan College Publishing Company*, New York.
- Haykin, S.**, 2005. A Comprehensive Foundation, *Pearson Prentice Hall*, 2nd Edition, New Jersey.
- Haykin, S.**, 2009. Neural Networks and Learning Machines, Third Edition, *Pearson Prentice Hall Inc.*, New Jersey.
- Hosmer, D.W. and Lemeshov, S.**, 2000. Applied Logistic Regression, *John Wiley & Sons*, New York.
- Hu, H., Liu, D.**, 2012. The Judgement of Chaotic Detection System's State Based on The Lyapunov Exponent, *Procedia Engineering* **29**, 2894-2898.
- Hurvich, C.M. and Tsai, C.**, 1989. Regression and Time Series Model Selection in Small Samples, *Biometrika*, **76(2)**, 297-307.
- Jacobs, R.A.**, 1988. Increased Rate of Convergence through Learning Rate Adaptation, *Neural Networks*, **1**, 295-307.
- Jain, A.K.**, 1989. Fundamentals of Digital Image Processing, *Prentice Hall*, New Jersey.
- Jasper, H.H.**, 1958. The Ten-Twenty Electrode System of The International Federation. *Electroencephalography and Clinical Neurophysiology*, **10**, 371-375.
- Jasper, H.**, 1958. Report of Committee on Methods of Clinical Exam in EEG, *Elektroencephalogr. Clin. Neurophysiol.*, **10**, 370-375.
- Jensen, E.**, 1998. Teaching with The Brain in Mind. Association for Supervision and Curriculum Development Alexandria, Virginia, USA.
- Kıymık, K.M, İnan, G., Dizibüyük, A. and Akın, M.**, 2005. Comparison of STFT and Wavelet Transform Methods in Determing Epileptic Seizure Activity in EEG Signals for Real Time Application, *Computers in Biology and Medicine*, **35**, 603-616.

- Kocadağlı, O.**, 2012. Hybrid Bayesian Neural Networks with Genetic Algorithms and Fuzzy Membership Functions, *PhD Thesis*, MSGSU, Institute of Science and Technology, İstanbul.
- Kocadağlı, O. and Aşıkil, B.**, 2014. Nonlinear Time Series Forecasting with Bayesian Neural Networks, *Expert Systems with Applications*, **41(15)**, 6596-6610.
- Kocadağlı, O., Ekin, T., Griffin, P., Bastian, N. and Fulton, V.L.**, 2014. Fuzzy Resource Allocation in Health Systems, *INFORMS*, San Francisco.
- Kociolek, M., Materka, A., Strzelecki, M. and Szczypiński, P.**, 2001. Discrete Wavelet Transform- Derived Features for Digital Image Texture Analysis, *Proc. of Interational Conference on Signals and Electronic Systems*, Lodz, 18-21 September, 163-168.
- Koç, T. ve Cengiz, M.A.**, 2012. Genelleştirilmiş Lineer Karma Modellerde Tahmin Yöntemlerinin Uygulamalı Karşılaştırılması, *Karaelmas Fen ve Mühendislik Dergisi*, **2(2)**, 47-52.
- Kurup, P.U. and Dudani, N.K.**, 2002. Neural Networks for Profiling Stress History of Clays from PCPT Data. *Journal of Geotechnical&Geoenvironmental Engineering*, **128**, 569-579.
- Larose, D.T.**, 2005. Discovering Knowledge in Data, *John Wiley&Sons Inc.*, New Jersey.
- Lee, P., G.**, 2010. Neuropsychology of Epilepsy and Epilepsy Surgery, Oxford University Press, New York.
- Mallat, S.**, 1998. A Wavelet Tour of Signal Processing, Academic Press, San Diego.
- Mallat, S.**, 1999. A Wavelet Tour of Signal Processing, Academic Press, Second Edition, San Diego.
- May, R.J., Maier, H.R., Dandy, G.C. and Fernando, T.M.K.G.** 2008. Non-linear variable selection for artificial neural networks using partial mutual information. *Environmental Modelling & Software*, **23**, 1312-1326.
- McQuarrie, A.D., Tsai, C. and Tsai, L.**, 1998. Regression and Time Series Model Selection, *World Scientific Publishing Co.*, Singapore.
- McQuarrie A.D.R., Tsai, C. and Tsai L.**, 2007. Regression and Time Series Model Selection, *World Scientific*, New Jersey.
- Mertler, C.A. and Vannata, R.A.**, 2002. Advanced and Multivariate Statistical Methods: Practical Application and Interpretation, 2nd ed, *Pyrzczak Publishing*, Los Angeles.
- Meyers, L.S., Gamst,, G. and Guarion, A.J.**, 2006. Applied Multivariate Research: Design and Interpretation, Sage Publications, Newbury Park, CA.
- Minai, A.A. and Williams, R.D.**, 1990. Acceleration of Backpropagation Through Learning Rate and Momentum Adaptation, *International Joint Conference on Neural Networks*, IEEE, **1**, 676-679.
- Minai, A.A. and Williams R.D.**, 1990. Back-Propagation Heuristics: A Study of the Extended Delta-Bar-Delta Algorithm, *Proceedings of International Joint Conference on Neural Networks*, 17-21 June, **1**, 595-600, San Diego.

- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.M.**, 2004. User's Guide on Wavelet Toolbox 4 for MATLAB. Matworks Incooperation.
- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.,M.**, 2009. Wavelet Toolbox 4 User's Guide.
- Moller, F. M.**, 1993. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, **6**, 525-533.
- Montgomery, D.C., Peck, E.A. and Vining, G.G.**, 2012. Introduction to Linear Regression Analysis, Fifth Edition, *John Wiley & Sons, Inc.*, New Jersey.
- Mutlu, N.**, 2011. Ek Tedavi Olarak Levetirasetam Alan Dirençli Epilepsi Hastalarında Nöbetsizliği Belirleyen Etkenlerin Geriye Dönük Araştırılması, *Uzmanlık tezi*, İstanbul Üniversitesi, Sağlık Bilimleri Enstitüsü, İstanbul.
- Ngugi, A.K., Bottomley, C., Kleinschmidt, I., Sander, J.W. and Newton, C.R.**, 2010. Estimation of The Burden of Active and Life-time Epilepsy: A Meta-Analytic Approach, *Epilepsia*, **51**, 883-890.
- Orhan, U.**, 2011. EEG İşaretlerinden Epilepsi Hastalığının Teşhisi İçin Yeni Yaklaşımlar, *Doktora Tezi*, Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Zonguldak.
- Özdemir, H.**, 2013. Yapay Sinir Ağları ve Doküma Teknolojisinde Kullanımı. *Tekstil Teknolojileri Elektronik Dergisi*, **7(1)**, 51-68.
- Özkaya, A.**, 2007. A New Approach for The Epilepsy Diagnosis and for The Localization of Epileptogenic Brain Regions. *Master Thesis*, İstanbul Technical University, Institute of Science and Technology, İstanbul.
- Öztemel, E.**, 2012. Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul.
- Öztuna, D., Ateş, C., Gültekin, S. ve S., Genç, Y.**, 2011. Kümelenmiş Verilerde İşlem Karakteristiği Eğrisi (İKE) Altında Kalan Alanın Tahmini, *Türkiye Klinikleri*, **3(2)**, 57-62.
- Perry, E.K., Ashton, H. and Young, A.H.**, 2002. Neurochemistry of Consciousness, *John Benjamins Publishing Company*, Amsterdam.
- Petrosian, A., Prokhorov, D., Homan, R., Dasheiff, R. and Wunsch, D.**, 2000. Recurrent Neural Network Based Prediction of Epileptic Seizures in İntra and Extracranial EEG, *Neurocomputing*, **30**, 201-218.
- Pfurtscheller, G., Flotzinger, D. and Neuper, C.**, 1994. Differentiation Between Finger, Toe and Tongue Movement in Man Based on 40 hz EEG. *Electroencephalogr Clin Neurophysiol*, **90**, 456-460.
- Pillai, J. and Sperling, M.R.**, 2006. Interictal EEG and The Diagnosis of Epilepsy, *Epilepsia*, **47**, 14-22.
- Proch'azka, A., Jech, J. and Smith, J.**, 1994. Wavelet Transform Use in Signal Processing, in *31st International Conference in Acoustics*, Czech Technical University, 209-213.
- Rajna, P., Clesmens, B., Csibri, E., Dobos, E., Geregely, A., Gottschal, M., György, I., Horváth, A., Horváth, F., Mezöfi, L., Velkey, I., Veres, J. and Wagner, E.**, 1997. Hungarian Multicenter Epidemiologic Study of The Warning and Initial Symptoms (Prodrome, Aura) of Epileptic Seizures, *Seizure*, **6**, 361-368.

- Rumelhart, D.E., Hinton, G.E. and Williams, R.J.,** 1986. Learning Representations by Back-Propagating Errors, *Nature*, **323**, 533-536.
- Sander, J.W.,** 2003. The Epidemiology of Epilepsy Revisited, *Curr Opin Neurol*, **16**, 165-170.
- Saeid Sanei,** 2013. Adaptive Processing of Brain Signals, *Wiley*, England.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M.,** 2003. Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları, *Ufuk Yayınevi*, Kayseri.
- Sanei, S. and Chambers, J.A.,** 2007. EEG Signal Processing, *Wiley*, England.
- Sausa, D. A.,** 2001. How The Brain Learns: A Classroom Teacher's Guide. Thousand Oaks, California: Corwin Press, Inc.
- Sejdić, E., Djurović, I. and Jiang, J.,** 2009. Time-Frequency Feature Representation Using Energy Concentration: An Overview of Recent Advances, *Digital Signal Processing*, **19**, 153-183.
- Sezer, E.,** 2008. Epilepsi Teşhisi İçin EEG Sinyali Analizi, *Yüksek Lisans Tezi*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Sharma, S.,** 1996. Applied Multivariate Technique, *John Wiley & Sons, Inc.*, New York.
- Shimodaira, H.,** 2015. Single Layer Neural Networks, Learnin and Data Note 11.
- Sifuzzaman, M., Islam, M. R., and Ali, M.Z.,** 2009. Application of Wavelet Transform and its Advantages Compared to Fourier Transform, *Journal of Physical Sciences*, **13**, 121-134.
- Silva, L.M., Marques de Sá, J. and Alexandre, L.A.,** 2008. Data Classification with Multilayer Perceptrons Using A Generalized Error Function, *Neural Networks*, **21**, 1302-1310.
- Soydaner, D. and Kocadağlı, O.,** 2015. Artificial Neural Networks with Gradient Learning Algorithm for Credit Scoring, *Istanbul University Journal of the School of Business*, **44(2)**, 3-12.
- Sprenger, M.B.,** 2002. Becoming a "Wiz" at Brain- Based Teaching, Thousand Oaks, *Corwin Press*, California.
- Stephan, C., Jung, K., Diamandis, E. P., Rittenhouse, H.G., Lein, M. and Loening, S.A.,** 2002. Prostate Specific Antigen, its Molecular Forms and Other Kallikrein Markers for Detection of Prostate Cancer, *Urology*, **59(1)**, 2-8.
- Stone, M.,** 1974. Cross-Validatory Choice and Assessment of Statistical Predictions (with Discussion), *Journal of The Royal Statistical Society*, **B39**, 111-147.
- Stone, M.,** 1977. An Asymptotic Equivalence of Choice of Model by Cross-Validation and Akaike's Criterion, *Journal of The Royal Statistical Society*, **B39**, 44-47.
- Sterman, M.B., MacDonald, L.R. and Stone, R.K.,** 1974. Biofeedback Training of Sensorimotor EEG Rhythm in Man and Its Effect on Epilepsy, *Epilepsia*, **15**, 395-416.

- Sugiura, N.**, 1978. Further Analysis of The Data by Akaike's Information Criterion and The Finite Corrections, *Communications in Statistics- Theory and Methods*, **A7**, 13-26.
- Strang, G. and Nguyen, T.**, 1996. Wavelets and Filter Banks, Wellesley-Cambridge Press, Wellesley, MA.
- Tamura, Y., Shimakage, H.**, 2013. Lyapunov Exponent Analyses of Chaotic Oscillations in Rf-Biased Josephson Junctions, *Physics Procedia*, **58**, 191-194.
- Tatlıdil, H.**, 2002. Uygulamalı Çok Değişkenli İstatistiksel Analiz, *Ziraat Matbaacılık*, Ankara.
- Taywade, S.A. and Raut, R.D.**, 2012. A Review: EEG Signal Analysis With Different Methodologies.
- Tekin, R., Kaya, Y. ve Tağluk, M.E.**, 2011. K-Means ve YSA Temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması. *Elektrik-Elektronik-Bilgisayar Sempozyumu*, Elazığ, 5-7 Ekim.
- Tolon, M. ve Tosunoğlu, N.G.**, 2008. Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları ve Regresyon Analizi Karşılaştırması, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **10(2)**, 247-259.
- Tomak, L. ve Bek, Y.**, 2010. İşlem Karakteristik Eğrisi Analizi ve Eğri Altında Kalan Alanların Karşılaştırılması. *Journal of Experimental and Clinical Medicine*, **27(2)**, 58-65.
- Toprak, İ. B.**, 2007. EEG Sinyallerinden Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Analizi, *Yüksek Lisans Tezi*, Isparta Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- Tzallas, A.T., Tsipouras, M.G. and Fotiadis, D.I.**, 2007. Automatic Seizure Detection Based on Time – Frequency Analysis and Artificial Neural Networks, *Computational Intelligence and Neuroscience*, August,
- Übeyli, E.D. and İnan, G.**, 2003. Dalgacık Dönüşüm Tabanlı Sinir Ağları ile Oftalmik Atardamar Doppler İşaretlerinin Sınıflandırılması, *Elektrik-Elektronik-Bilgisayar Mühendisliği 10. Ulusal Kongresi*, 18-21 Eylül, İstanbul.
- Vecchio, F., Miraglia, F., Curcio, G., Marca, G.D., Vollono, C., Mazzucchi, E., Bramanti, P. and Rossini, P.M.**, 2014. Cortical Connectivity in Fronto-Temporal Focal Epilepsy from EEG Analysis: A Study via Graph Theory, *Clinical Neurophysiology*, Italy.
- Vernekar, K., Kumar, H. and Gangadharan, K.V.**, 2014. Computational and Experimental Approach for Fault Detection of Gears, *Journal of Vibration Analysis, Measurement and Control*, **2**, 16-29.
- Vrieze, S. I.**, 2012. Model Selection and Psychological Theory: A Discussion of The Differences Between The Akaike Information Criterion (AIC) and The Bayesian Information Criterion (BIC), *Psychological Methods*, **17(2)**, 228-243.
- Walker, J.S.**, 1999. A Primer on Wavelets and Their Scientific Applications, *Chapman & Hall/CRC*, Florida.
- Wang, W.Z., Wu, J.Z., Wang, D.S., Dai, X.Y., Yang, B., Wang, T.P., Yuan, C. L., Scrott, R.A., Prilipko, L.L., de Boer, H.M. and Sander, J.W.**, 2003. The

- Prevalence and Treatment Gap in Epilepsy in China, an ILAE/IBE/WHO Study, *Neurology*, **60**, 1544-1545.
- Wasserman, P.D.**, 1989. Neural Computing Theory and Practice, *Van Nostrand Reinhold Co.*, New York.
- Weng, W.**, 1994. Adaptive Structure Neural Networks with Applications to EEG Automatic Seizure Detection, *National Library of Canada*, Canada.
- Yalçın, N.**, 2012. Sezgisel Algoritma Öğrenmeli Yapay Sinir Ağları ile Epilepsi Hastalığının Teşhisi, *Yüksek Lisans tezi*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Yalçın, N., Tezel, G. and Karakuzu, C.**, 2015. Epilepsy Diagnosis Using Artificial Neural Network Learned by PSO, *Turkish Journal of Electrical Engineering and Computer Sciences*, **23**, 421-432.
- Yiğit, A.**, 2008. Epilepsi Sözlüğü, *Nobel Tıp Kitabevleri*, İstanbul.
- Zhang, Y., Wang, Y., Wang, W. and Liu, B.**, 2001. Doppler Ultrasound Signal Denoising Based on Wavelet Frames, *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, **48**, 709-716.
- Zucchini, W.**, 2000. An Introduction to Model Selection, *Journal of Mathematical Psychology*, **44**, 41-61.
- Zupec-Kania B.A and Spellman E.**, 2009. An Overview of The Ketogenic Diet for Pediatric Epilepsy, *Nutrition in Clinical Practice*, **23**, 589-596.
- Zweih, M.H. and Campell, G.**, 1993. Receiver-Operating Characteristic (ROC) Plots: A Fundamental Evaluation Tool in Clinical Medicine. *Clin Chem*, **39(4)**, 561-577.

EKLER

Çizelge EK 1 A veri setinin ADD katsayılarının parametre değerleri

		D1	D2	D3	D4	D5	D6	A6
	mean	0,030038	0,032839	0,033773	0,033826	0,033606	0,033004	0,023746
max	max	0,128016	0,090674	0,08653	0,087276	0,101476	0,096379	0,119239
	min	0,007943	0,013598	0,012603	0,013982	0,012058	0,010274	-0,05863
	mean	-0,02981	-0,03278	-0,03374	-0,03385	-0,03391	-0,03301	-0,02917
min	max	-0,00862	-0,01429	-0,01345	-0,0135	-0,01176	-0,00996	0,032747
	min	-0,11008	-0,0913	-0,08331	-0,07754	-0,08396	-0,10802	-0,08595
	mean	0,008544	0,008544	0,008544	0,008544	0,008544	0,008544	-0,00854
mean	max	0,105479	0,105479	0,105479	0,105479	0,105479	0,105479	0,085442
	min	-0,08544	-0,08544	-0,08544	-0,08544	-0,08544	-0,08544	-0,10548
	mean	0,032665	0,033021	0,034102	0,034333	0,034286	0,033528	0,032432
std	max	0,121481	0,087748	0,062458	0,064873	0,072484	0,0799	0,097249
	min	0,018613	0,014816	0,015071	0,016394	0,01615	0,010245	0,006284
	mean	0,030048	0,032858	0,033828	0,033907	0,033865	0,033128	0,032464
range	max	0,1195	0,091124	0,083776	0,082589	0,093075	0,101866	0,095919
	min	0,009038	0,013965	0,013464	0,014923	0,012624	0,010567	0,00556
	mean	-0,00249	-0,00093	0,002179	-0,00117	0,00099	-0,00183	-0,00859
median	max	0,212332	0,174004	0,146085	0,1044	0,123556	0,119243	0,086435
	min	-0,15192	-0,17527	-0,13022	-0,1345	-0,12455	-0,16966	-0,1084
	mean	0,008867	0,009712	0,010159	0,009283	0,010375	0,009903	0,009903
haus met	max	0,49406	0,445999	0,394283	0,44486	0,347521	0,429268	0,429268
	min	9,93E-05	0,000167	0,000169	0,000145	0,000169	0,000134	0,000134

Çizelge EK 2 B veri setinin ADD katsayılarının parametre değerleri

		D1	D2	D3	D4	D5	D6	A6
	mean	0,028985	0,033214	0,033246	0,032432	0,033535	0,033032	0,017057
max	max	0,157511	0,107904	0,074289	0,087647	0,074144	0,10395	0,117613
	min	0,004765	0,012227	0,010287	0,010985	0,010717	0,011851	-0,05644
	mean	-0,02895	-0,03328	-0,03316	-0,0324	-0,03347	-0,03288	-0,02889
min	max	-0,00529	-0,01213	-0,00834	-0,01138	-0,01104	-0,01111	0,028139
	min	-0,15612	-0,10731	-0,0777	-0,09405	-0,08581	-0,11395	-0,09337
	mean	0,013265	0,013265	0,013265	0,013265	0,013265	0,013265	-0,01326
mean	max	0,089575	0,089575	0,089575	0,089575	0,089575	0,089575	0,074691
	min	-0,07469	-0,07469	-0,07469	-0,07469	-0,07469	-0,07469	-0,08958
	mean	0,030891	0,034183	0,032726	0,032466	0,033833	0,033114	0,032482
std	max	0,10185	0,069799	0,079454	0,079197	0,079856	0,10166	0,118143
	min	0,013166	0,01501	0,00956	0,013088	0,011876	0,010588	0,006964
	mean	0,029088	0,033322	0,033262	0,032462	0,033611	0,033067	0,032498
range	max	0,157471	0,106676	0,076142	0,090967	0,071854	0,109341	0,110156
	min	0,005534	0,012238	0,009323	0,011692	0,011538	0,011619	0,006923
	mean	-0,00356	0,003278	-0,00204	0,001013	-0,00065	0,001387	-0,01338
mode	max	0,127541	0,16569	0,118835	0,152936	0,110946	0,161306	0,071766
	min	-0,19947	-0,12352	-0,17346	-0,14732	-0,16909	-0,11742	-0,08871
	mean	0,002567	0,002481	0,002781	0,00296	0,002706	0,002413	0,002413
haus met	max	0,992321	0,986596	0,979041	0,947517	0,97745	0,989171	0,989171
	min	1,32E-05	2,03E-05	2,66E-05	2,78E-05	2,41E-05	2,08E-05	2,08E-05

Çizelge EK 3 C veri setinin ADD katsayılarının parametre değerleri


		D1	D2	D3	D4	D5	D6	A6
	mean	0,027389	0,029107	0,02974	0,031737	0,032084	0,031585	0,026172
max	max	0,197524	0,176415	0,159405	0,126308	0,111207	0,116254	0,145708
	min	0,004646	0,005514	0,005698	0,007774	0,006954	0,005524	-0,04144
	mean	-0,02748	-0,02893	-0,02951	-0,03164	-0,0319	-0,03159	-0,03029
min	max	-0,00488	-0,00589	-0,00558	-0,00672	-0,00683	-0,00553	0,013606
	min	-0,17151	-0,17748	-0,16899	-0,12516	-0,11357	-0,11247	-0,10344
	mean	0,012081	0,012081	0,012081	0,012081	0,012081	0,012081	-0,01208
mean	max	0,109389	0,109389	0,109389	0,109389	0,109389	0,109389	0,080296
	min	-0,0803	-0,0803	-0,0803	-0,0803	-0,0803	-0,0803	-0,10939
	mean	0,029994	0,029153	0,02997	0,032301	0,03261	0,031841	0,031474
std	max	0,122447	0,132649	0,148109	0,113031	0,097714	0,103109	0,113103
	min	0,01121	0,008872	0,007078	0,008498	0,008002	0,006775	0,005744
	mean	0,027486	0,029058	0,029692	0,031769	0,032085	0,031687	0,03144
range	max	0,184972	0,1772	0,162109	0,113528	0,112712	0,114737	0,109552
	min	0,005057	0,005757	0,005653	0,007613	0,007076	0,005542	0,005359
	mean	0,003792	-0,00203	0,000407	0,000231	-0,00136	0,002404	-0,01241
mode	max	0,248329	0,167735	0,202302	0,132219	0,198506	0,156451	0,080182
	min	-0,16763	-0,24036	-0,18552	-0,15303	-0,1239	-0,15162	-0,12183
	mean	0,002761	0,002863	0,002263	0,002562	0,00236	0,00206	0,00206
hauss met	max	0,906866	0,92674	0,979612	0,938905	0,963656	0,984694	0,984694
	min	1,01E-05	1,39E-05	8,87E-06	1,08E-05	8,21E-06	6,05E-06	6,05E-06

Çizelge EK 4 D veri setinin ADD katsayılarının parametre değerleri


		D1	D2	D3	D4	D5	D6	A6
	mean	0,024093	0,024394	0,023082	0,025587	0,026315	0,026485	0,02078
max	max	0,261523	0,218273	0,202267	0,193109	0,186084	0,177858	0,231368
	min	0,003402	0,003902	0,003513	0,005244	0,006029	0,002811	-0,02033
	mean	-0,02427	-0,02407	-0,02286	-0,02452	-0,02484	-0,0247	-0,02463
min	max	-0,0035	-0,00433	-0,00307	-0,00435	-0,00481	-0,00301	0,011838
	min	-0,25481	-0,22264	-0,2166	-0,21617	-0,2084	-0,19488	-0,18113
	mean	0,008389	0,008389	0,008389	0,008389	0,008389	0,008389	-0,00839
mean	max	0,121447	0,121447	0,121447	0,121447	0,121447	0,121447	0,141286
	min	-0,14129	-0,14129	-0,14129	-0,14129	-0,14129	-0,14129	-0,12145
	mean	0,029352	0,028442	0,027337	0,028052	0,026706	0,025522	0,022964
std	max	0,193714	0,171783	0,182039	0,195172	0,196687	0,196785	0,234273
	min	0,011289	0,007691	0,006589	0,007074	0,00715	0,002652	0,001721
	mean	0,024249	0,024279	0,023038	0,025162	0,025643	0,025676	0,023898
range	max	0,258913	0,220958	0,210056	0,205923	0,19848	0,173881	0,208706
	min	0,003489	0,004251	0,003349	0,00509	0,005529	0,002995	0,001862
	mean	0,000775	-0,00193	-0,00195	-0,0045	-0,00555	0,001508	-0,00946
mode	max	0,125299	0,17577	0,163303	0,22922	0,080359	0,244987	0,106288
	min	-0,19229	-0,20226	-0,1817	-0,12061	-0,27496	-0,25902	-0,20953
	mean	0,006733	0,007273	0,006807	0,00659	0,005298	0,007088	0,007088
hauss met	max	0,830312	0,737833	0,678009	0,674351	0,865252	0,709017	0,709017
	min	0,000103	0,000188	0,000186	0,000194	0,000146	0,000112	0,000112

Çizelge EK 5 E veri setinin ADD katsayılarının parametre değerleri


		D1	D2	D3	D4	D5	D6	A6
	mean	0,025819	0,028315	0,029039	0,031251	0,030826	0,0288	0,025071
max	max	0,184526	0,108802	0,093355	0,092999	0,102391	0,129745	0,199252
	min	0,001396	0,003014	0,004144	0,003712	0,004985	0,003481	-0,01186
min	mean	-0,02589	-0,02876	-0,02896	-0,03155	-0,03076	-0,02891	-0,02887
	max	-0,00128	-0,00383	-0,00429	-0,00454	-0,00494	-0,0034	0,007747
	min	-0,16398	-0,10779	-0,10035	-0,09279	-0,09347	-0,11598	-0,13523
	mean	0,005629	0,005629	0,005629	0,005629	0,005629	0,005629	-0,00563
mean	max	0,116259	0,116259	0,116259	0,116259	0,116259	0,116259	0,094473
	min	-0,09447	-0,09447	-0,09447	-0,09447	-0,09447	-0,09447	-0,11626
	mean	0,028473	0,028352	0,028833	0,030794	0,030282	0,028309	0,028235
	max	0,120893	0,113159	0,094841	0,089492	0,092316	0,138856	0,149646
std	min	0,003772	0,003085	0,003358	0,002769	0,004546	0,003195	0,00444
	mean	0,02596	0,028609	0,029051	0,031512	0,030845	0,028926	0,028175
range	max	0,175012	0,108602	0,096244	0,093227	0,092919	0,117955	0,149497
	min	0,001346	0,003419	0,004388	0,004566	0,00497	0,003484	0,004369
	mean	0,004428	-0,00593	-0,00358	0,001322	-0,00188	0,001904	-0,00608
	max	0,168055	0,141687	0,128122	0,148819	0,183988	0,187566	0,121072
mode	min	-0,13297	-0,29502	-0,14532	-0,15505	-0,17423	-0,18981	-0,15649
	mean	0,003329	0,002585	0,002832	0,003038	0,003017	0,002252	0,002252
hauss met	max	0,604328	0,730913	0,813666	0,871674	0,842678	0,933817	0,933817
	min	6,67E-06	9,51E-06	1,79E-05	1,6E-05	1,94E-05	6,87E-06	6,87E-06




Şekil EK 1 A sınıfındaki sinyallerin parçalanması




Şekil EK 2 B sınıfındaki sinyallerin parçalanması



Şekil EK 3 C sınıfındaki sinyallerin parçalanması



Şekil EK 4 D sınıfındaki sinyallerin parçalanması



Şekil EK 5 E sınıfındaki sinyallerin parçalanması

ÖZGEÇMİŞ

Adı Soyadı :Ezgi Özer

Doğum Yeri :Balıkesir

Doğum Tarihi :11.10.1987

Medeni Hali :Bekar

Lisans :Gazi Üniversitesi

Yabancı Dil :İngilizce

İş Tecrübesi :Okan Üniversitesi Uygulamalı Bilimler Yüksek Okulu Turizm ve Otelcilik Bölümü Araştırma Görevlisi (2016-...)

Tel: : (216) 677 16 30 – 2757

E-mail :ezgi.ozer@okan.edu.tr