

**EEG İŞARETLERİNDEN EPİLEPSİ HASTALIĞININ TEŞHİSİ İÇİN
YENİ YAKLAŞIMLAR**

Umut ORHAN

**Zonguldak Karaelmas Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**


ZONGULDAK

Eylül 2011


KABUL:

Umut ORHAN tarafından hazırlanan “EEG İŞARETLERİNDEN EPİLEPSİ HASTALIĞININ TEŞHİSİ İÇİN YENİ YAKLAŞIMLAR” başlıklı bu çalışma jürimiz tarafından değerlendirilerek, Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında Doktora Tezi olarak oybirliğiyle kabul edilmiştir. 29/09/2011

Başkan : Prof. Dr. Mahmut ÖZER (ZKÜ)



Üye : Prof. Dr. Etem KÖKLÜKAYA (SAÜ)



Üye : Prof. Dr. Yaşar BECERİKLİ (KOÜ)



Üye : Doç. Dr. Ertan ÖZTÜRK (ZKÜ)



Üye : Doç. Dr. Ahmet ALTIN (ZKÜ)


ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım./....../2011



Prof. Dr. Özden ÖZEL GÜVEN
Fen Bilimleri Enstitüsü Müdür V.

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”



Umut ORHAN

ÖZET

Doktora Tezi

EEG İŞARETLERİNDEN EPİLEPSİ HASTALIĞININ TEŞHİSİ İÇİN YENİ YAKLAŞIMLAR

Umut ORHAN

Zonguldak Karaelmas Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanları:

Prof. Dr. Mahmut ÖZER

Yrd. Doç. Dr. Mahmut HEKİM

Eylül 2011, 83 sayfa

Epilepsi, beyinde meydana gelen geçici elektrik boşalmaları yüzünden vücutta kontrol edilemeyen istem dışı hareketlere yol açan bir sinir hastalığıdır ve dünyanın ciddi bir bölümünü etkilemektedir. Epilepsi teşhisi EEG işaretlerinin uzmanlar tarafından izlenmesine dayanmaktadır. Uzmanlar tarafından yapılan bu izlemenin zorluğu yüzünden epilepsi teşhisi üzerine yapay zeka temelli birçok çalışma bulunmaktadır. EEG kayıtlarına dayanan bu çalışmaların çoğu iki aşama içermektedir: özellik çıkartma ve sınıflandırma. Genellikle özellik çıkartma aşaması için istatistiksel parametreler, sınıflandırma için de yapay sinir ağı kullanılmaktadır. Özellik çıkartma aşaması için istatistiksel parametreleri kullanmak yerine ilk defa bu çalışmada önerilen ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımı kullanılmıştır. EEG işaretleri hem zaman hem de zaman-frekans boyutunda üç yöntem kullanılarak ayırıklaştırılmıştır: eşit genişlikli ayırıklaştırma, eşit frekanslı ayırıklaştırma ve K-

ÖZET (devam ediyor)

means. Her ayırık bölgenin yoğunluğu hesaplanmış ve bu yoğunluk çok katmanlı algılayıcı sinir ağı modeline giriş olarak uygulanmıştır. Ayrıca, eşit frekanslı ayırıklaştırma yöntemine dayalı elde edilen yoğunluklara eğri uydurma uygulanarak EEG segmentlerinin olasılık yoğunluk fonksiyonları belirlenmiş ve sinir ağı yerine ortalama karesel hata ölçütü kullanarak epileptik aktiviteler sınıflandırılmıştır. Son olarak, önerilen özellik çıkartma yaklaşımının ve literatürde aynı EEG işaretlerini kullanan bazı çalışmaların başarıları tüm sonuçlar karşılaştırılarak gösterilmiştir.

Anahtar Sözcükler: EEG, Epilepsi, Yapay sinir ağı, Özellik çıkartma, Olasılık yoğunluğu, Eşit genişlikli ayırıklaştırma, Eşit frekanslı ayırıklaştırma, K-means.

Bilim Kodu: 609.01.04.

ABSTRACT

PhD. Thesis

NOVEL APPROACHES FOR DIAGNOSIS OF EPILEPSY DISEASE FROM EEG SIGNALS

Umut ORHAN

**Zonguldak Karaelmas University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Thesis Advisors:

Prof. Mahmut ÖZER

Asst. Prof. Mahmut HEKİM

September 2011, 83 pages

Epilepsy is a neurological disease which leads to uncontrollably unconscious movements occurring as a result of electrical discharges in the brain and affects a considerable part of the world population. Epilepsy diagnosis is based on the monitoring of electroencephalogram (EEG) signals by physicians. Because of the difficulty of monitoring by physicians, there are many researches based on artificial intelligence on epilepsy diagnosis. The most of these researches based on the EEG signals includes two stages: the feature extraction and the classification. In general, statistical parameters and artificial neural networks are used for the feature extraction and the classification, respectively. Instead of using statistical parameters in the feature extraction stage, probability density approach based on discretization proposed first time in this study was used. EEG signals were discretized in both time and time-frequency domains by using three methods: equal width discretization, equal frequency and

ABSTRACT (continued)

K-means. The density of each discrete interval was calculated and this density was applied to multilayer perceptron artificial neural network model as the inputs. In addition, the probability density functions of EEG segments were determined by applying the curve fitting to the obtained densities based on equal frequency discretization method, and the epileptic activities were classified by using the mean squared error criterion instead of neural network. Finally, the successes of proposed feature extraction approach and several the studies used the same EEG signals in the literature were shown by comparing all results.

Key Words: EEG, Epilepsy, Artificial neural network, Feature extraction, Probability density, Equal width discretization, Equal frequency discretization, K-means.

Science Code: 609.01.04.

TEŞEKKÜR

Tezimle ilgili yaptığımız çalışmalardaki katkısı, çıkmaza girdiğimi sandığım anlardaki desteği ve samimi yaklaşımından dolayı tez danışmanım Sayın Prof. Dr. Mahmut ÖZER'e (ZKÜ),

Tezimde büyük katkısı olan, titiz çalışmasını örnek aldığım ve bilgilerinden her an yararlandığım ikinci danışmanım Sayın Yrd. Doç. Dr. Mahmut HEKİM'e (GOÜ),

Tez çalışmasının takibi sırasında değerli önerileriyle yardımcı olan tez izleme komitesi üyelerinden Sayın Doç. Dr. Ertan ÖZTÜRK (ZKÜ) ve Sayın Doç. Dr. Ahmet ALTIN'a (ZKÜ),

Tezimin düzenlenmesi sırasında zaman ayırarak önemli katkılarda bulunan jüri üyelerinden Sayın Prof. Dr. Yaşar BECERİKLİ'ye (KOÜ) ve önerilerinden dolayı jüri üyelerinden Sayın Prof. Dr. Etem KÖKLÜKAYA (SAÜ) ve ayrıca Sayın Yrd. Doç. Dr. Yalçın İŞLER'e (ZKÜ),

Yoğun çalışmalarım süresince gösterdiği sabır ve manevi desteği dolayısıyla eşime, kendine ayırmam gereken zamandan feragat ettiği için oğluma ve benliğimi borçlu olduğum anne ve babama teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xv
BÖLÜM 1 GİRİŞ	1
BÖLÜM 2 EPİLEPSİNİN BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ	5
2.1 EPİLEPSİ HASTALIĞI	5
2.2 ELEKTROANSEFALOGRAF (EEG) İŞARETLERİ	7
2.3 EEG İŞARETLERİNDEN EPİLEPSİ TEŞHİSİ	9
2.4 EPİLEPSİNİN BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ	11
2.4.1 Zaman Boyutu Analizi	12
2.4.2 Frekans Boyutu Analizi	13
2.4.2.1 Fourier Dönüşümü	13
2.4.3 Zaman-Frekans Boyutu Analizi	15
2.4.3.1 Kısa Zaman Fourier Dönüşümü	16
2.4.3.2 Dalgacık Dönüşümü	17
BÖLÜM 3 AYRIKLAŞTIRMAYA DAYALI OLASILIK YOĞUNLUĞU	25
3.1 AYRIKLAŞTIRMA YÖNTEMLERİ	26
3.1.1 Eşit Genişlikli ve Eşit Frekanslı Ayrıklaştırma	26

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.1.2 Kümeleme ile Ayırıklaştırma.....	27
3.1.3 Entropi Azaltmalı Ayırıklaştırma.....	27
3.1.4 Ertelemeli Ayırıklaştırma	28
3.1.5 Oransal Ayırıklaştırma	28
3.1.6 Sabit Frekanslı Ayırıklaştırma	29
3.2 AYRIKLAŞTIRMAYA DAYALI OLASILIK YOĞUNLUĞU YAKLAŞIMI	30
3.2.1 Eşit Genişlikli Ayırıklaştırma ile Olasılık Yoğunluk Analizi	30
3.2.2 Eşit Frekanslı Ayırıklaştırma ile Olasılık Yoğunluk Analizi	32
3.2.3 K-means Kümeleme Yöntemi ile Olasılık Yoğunluk Analizi.....	33
3.3 SINIFLANDIRMA	35
 BÖLÜM 4 DENEYLER VE ANALİZ SONUÇLARI.....	 39
 4.1 DENEYLERDE KULLANILAN EEG VERİSİ.....	 39
4.2 YAPILAN DENEYLER.....	41
4.2.1 Epileptik Atak Tespiti	41
4.2.1.1 ABCD-E Deneyi	42
4.2.1.2 A-E Deneyi	49
4.2.2 Epilepsi Hastalığının Teşhisi	51
4.2.2.1 AB-CD Deneyi.....	51
4.2.2.2 A-D Deneyi.....	57
4.3 KARŞILAŞTIRMALI SONUÇLAR	58
 BÖLÜM 5 SONUÇ VE ÖNERİLER	 61
 KAYNAKLAR	 63
EK AÇIKLAMALAR A YAPAY SİNİR AĞLARI.....	71
A.1 ÇOK KATMANLI ALGILAYICI AĞLARI	74
A.2 ÇAPSAL TABANLI FONKSİYON AĞLARI	76
A.3 ÖĞRENEN VEKTÖR PARÇALAMA AĞLARI.....	78
A.4 DESTEK VEKTÖR MAKİNELERİ.....	79
ÖZGEÇMİŞ	83

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
2.1 10–20 sistemine göre elektrotların düzeni.	8
2.2 EEG dalga biçimleri (Fisch 1998).	9
2.3 Bilgisayar destekli karar sistemlerinde süreç.	11
2.4 ADD tekniğiyle bir işaretin altbantlarına ayrıştırılması.	20
2.5 Db2 dalgacık ve ölçek fonksiyonlarının genel görünümü.	22
3.1 Önerilen yöntem ile gerçekleştirilen otomatik teşhis sisteminde süreç.	25
3.2 Bir EEG segmentinin $K=3$ ve $K=9$ için EGA ile ayrıklaştırılması.	31
3.3 Bir EEG segmentinin $K=3$ ve $K=9$ için EFA ile ayrıklaştırılması.	32
3.4 EEG verisinin olasılık yoğunlukları şeklinde ÇKA sinir ağına uygulanışı.	35
4.1 A, B, C, D ve E veri setlerinden örnek olarak seçilen beş EEG segmenti.	40
4.2 ABCD-E deneyi için zaman boyutunda EGA ve EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.	43
4.3 ABCD-E deneyi için zaman-frekans boyutunda EGA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.	45
4.4 ABCD-E deneyi için zaman-frekans boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.	46
4.5 ABCD-E deneyi için iki EEG segmentinin P^* , P_1 ve P_2 grafikleri.	48
4.6 A-E deneyi için zaman boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.	50
4.7 AB-CD deneyi için zaman boyutunda EGA ve EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.	52
4.8 AB-CD deneyi için zaman-frekans boyutunda EGA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.	54
4.9 AB-CD deneyi için zaman-frekans boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.	56
A.1 ÇKA ağlarında kullanılan bir nöronun genel yapısı.	74

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
A.2 ÇKA ağlarında en sık kullanılan üç aktivasyon fonksiyonu.	75
A.3 Bir ÇKA ağının genel görünümü.	75
A.4 ÇTF ağlarının gizli ve çıkış katmanlarında kullanılan nöron modelleri.	77
A.5 En sık kullanılan çapsal tabanlı aktivasyon fonksiyonu.	77
A.6 Üç girişi, tek çıkışı ve tek gizli katmanında 5 nöronu olan bir ÇTF ağı.	78
A.7 Kohonen katmanında her sınıf için iki nörona sahip iki sınıflı bir ÖVP ağı.	78
A.8 Doğrusal olarak ayrılabilen bir veri için DVM çözümü.	80
A.9 Doğrusal olarak ayrılamayan bir veri için en uygun DVM çözümü.	80
A.10 Doğrusal olmayan üç farklı haritalama fonksiyonuyla DVM çözümleri.	81

ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
2.1 EEG örüntülerinin frekanslarına göre gruplandırması.....	9
2.2 EEG verisinin altıncı seviye ADD ayrıştırması sonucu elde edilen altbantlarının frekans aralıkları.	22
4.1 Deneylerde kullanılan yöntemler ve kısaltmaları.	39
4.2 Çalışmada yapılan deneylerin sınıf ve küme sayıları.	41
4.3 Olasılık yoğunluk fonksiyonlarındaki α , λ ve β parametrelerinin sınıflara göre ortalama değerleri.....	48
4.4 Ortalama karesel hataların sınıflara göre ortalama değerleri.	49
4.5 Önerilen üç yöntemin ABCD-E deneyindeki başarı oranları.....	49
4.6 Önerilen üç yöntemin A-E deneyindeki başarı oranları.	50
4.7 Önerilen üç yöntemin AB-CD deneyindeki başarı oranları.	57
4.8 Önerilen üç yöntemin A-D deneyindeki başarı oranları.	58
4.9 Önerilen yöntemlerin zaman boyutundaki karşılaştırmalı sonuçları.	58
4.10 Önerilen yöntemlerin zaman-frekans boyutundaki karşılaştırmalı sonuçları.	58
4.11 Aynı veriyi kullanan farklı çalışma sonuçları.	59
4.12 Deneylerin içerdiği örnek ve küme sayıları ile yöntemlerin bulduğu K değerleri.	60

SİMGELER VE KISALTMALAR DİZİNİ

A_n	:	Dalgacık dönüşümünün n . seviye yaklaşıklık katsayısı
B_{ROC}	:	ROC analizine dayalı başarı ölçütü
c_i	:	i . küme merkezinin konumu
D_n	:	Dalgacık dönüşümünün n . seviye detay katsayısı
f	:	Frekans değeri
F	:	Tekrar eden işaretin frekansı
J	:	Maliyet fonksiyonu
K	:	Ayrıklaştırma katsayısı
$P^*(i)$	:	Ayrık i . bölgenin olasılık değeri
T	:	Tekrar eden işaretin periyodik zamanı
t	:	Zaman değeri
U	:	Üyelik matrisi
$X(w)$	:	İşaretin frekans boyutundaki bileşenleri
$x(t)$	:	İşaretin zaman boyutundaki genlik değerleri
φ	:	Ölçek fonksiyonu
ψ	:	Dalgacık fonksiyonu

KISALTMALAR

ADD	:	Ayrık Dalgacık Dönüşümü
AFD	:	Ayrık Fourier Dönüşümü
b	:	Belirlilik
BTG	:	Bilgisayar Destekli Tomografik Görüntüleme
ÇKA	:	Çok Katmanlı Algılayıcı
ÇTF	:	Çapsal Tabanlı Fonksiyon
d	:	Duyarlılık
Db	:	Daubechies
DD	:	Dalgacık Dönüşümü
DN	:	Doğru Negatif

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

DP	:	Doğru Pozitif
DVM	:	Destek Vektör Makinesi
EEG	:	Elektroensefalografi (Electroencephalography)
EFA	:	Eşit Frekanslı Ayırıklaştırma
EGA	:	Eşit Genişlikli Ayırıklaştırma
EKG	:	Elektrokardiyografi (Electrocardiography - ECG)
EMG	:	Elektromiyografi (Electromyography)
HFD	:	Hızlı Fourier Dönüşümü
KZFD	:	Kısa Zaman Fourier Dönüşümü
MRG	:	Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging – MRI)
ÖVP	:	Öğrenen Vektör Parçalama
ROC	:	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SBÇ	:	Sinirsel Bulanık Çıkarım
SDD	:	Sürekli Dalgacık Dönüşümü
YN	:	Yanlış Negatif
YP	:	Yanlış Pozitif
YSA	:	Yapay Sinir Ağı

BÖLÜM 1

GİRİŞ

Epilepsi, beyinde meydana gelen ve atak adı verilen geçici elektrik boşalmaları yüzünden vücutta kontrol edilemeyen istem dışı hareketlere yol açan bir sinir hastalığıdır. Epilepsi teşhisinde kullanılan yöntemlerin çoğu beyindeki elektriksel aktivitelerin Elektroensefalogram (EEG) cihazıyla incelenmesine dayanmaktadır. Yapılan bu incelemenin zorluğu yüzünden epilepsinin bilgisayar destekli otomatik teşhisi üzerine yapılmış birçok çalışma bulunmaktadır. EEG işaretlerinden epileptik aktivitelerin tespiti, özellik çıkartma ve sınıflandırma olmak üzere iki aşamayı içermektedir. Genellikle zaman, frekans veya zaman-frekans boyutunda işaretlerden istatistiksel parametrelerin elde edilmesiyle yapılan özellik çıkartma aşaması için ilk defa bu çalışmada önerilen ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımı kullanılmıştır.

Hans Berger tarafından 1929 yılında geliştirilen EEG tekniğiyle elde edilen işaretlere frekans boyutu uygulaması ilk kez Grass ve Gibbs tarafından 1938 yılında hızlı Fourier dönüşümü (HFD) kullanılarak yapılmıştır. Bu tarihten sonra birçok araştırmacı tarafından farklı çalışmalar yapılmış ve özellikle de doksanlı yıllara kadar EEG işaretlerinin analizinde otoregresif (Auto-Regressive: AR) yöntemi kullanılmıştır. EEG işaretlerine AR yöntemini ilk uygulayan çalışmalar Fenwick et al. (1969), Gersch (1970) ve Zetterberg (1969) olmuştur. Bu tarihten sonra EEG üzerine AR uygulaması yapan sayısız çalışma olmuştur. Yetmişli yıllarda özellikle AR yöntemine dayalı EEG simülasyonları üzerinde çok durulmuştur. Bu simülasyon çalışmalarından birisinde Zetterberg (1969) AR modelini EEG işaretlerinin klasik bant yapısına karşılık olarak gösterilen birinci ve ikinci dereceden spektral faktörleri için kullanmıştır. Zamana bağlı değişimi üretebilmek için güç, bant genişliği ve ortalama frekans gibi faktörlerin zamanda değişimine izin verilmiştir. Ancak araştırmacı, EEG işaretlerinin zamanla değişim karakteristiği ve faktörlerin zamanla değişiminin nasıl yapıldığı üzerine bir açıklama yapmamıştır. Buna ek olarak EEG işaretlerinin kısmen de olsa kaotik özellikler sergilediği durumlarda EEG klasik bant yapısının her zaman geçerli olmadığı ortaya çıkmıştır. Benzer şekilde bir simülasyon çalışması yapan Wennberg ve Isaksson (1976) AR yöntemi

sayesinde Kalman filtresinin EEG işaretlerinin izlenmesindeki başarısını test etmiştir. Çalışmada EEG işaretlerinin klasik bant yapısını yaklaşık olarak veren simülasyonlar ile zamanda değişen EEG işaretlerinin tahmininde Kalman filtresinin uygulanabilirliği değerlendirilmiştir. Çok kanallı EEG cihazı ile yapılan bir çalışmada ise EEG işaretleri, sıkıştırılmış spektral seri ve AR modelleriyle incelenmiş ve AR modelinin işlem yükü, depolama kapasitesi ve bilgi transferi açısından daha avantajlı olduğu gösterilmiştir (Pradhan and Dutt 1994). Tseng et al. (1995) oldukça geniş bir EEG veritabanı üzerinde ters filtreleme, beyaz gürültü testleri ve bir saniyelik EEG kesimleri gibi farklı parametrik modeller uygulamış ve 2–32 derece aralığındaki AR modellerinin en iyi tahminleri verdiğini bulmuştur.

Son yılların başarılı bu yüzden de popüler olan sınıflandırma yöntemi yapay sinir ağı (YSA) ise EEG işaretlerine 90’lardan itibaren uygulanmıştır. Psikiyatrik bozukluğu olan hastalar ile normal bireylerin EEG işaretlerinin sınıflandırılmasında yaşanan bir sorunu aşmak için Tsoi et al. (1994) YSA ile yapılan sınıflandırmada bir ön işleme aşaması olarak AR yöntemini kullanmıştır. Epileptik atak aktivitelerinin sınıflandırılması üzerine yapılan bir çalışmada öğrenen vektör parçalama (ÖVP) temelli bir YSA kullanılmış ve EEG işaretlerinde ilk kez gözlenen bir örüntüde bile başarılı sonuçlar alınabileceği öngörülmüştür (Pradhan et al. 1996).

EEG işaretlerindeki aktivitelerin sınıflandırılmasında yalnız YSA modellerinin yeterli olmadığını ve bu yüzden de işaretlerdeki detayların zaman-frekans boyutunda incelenmesinin daha yararlı olacağı öngörülmüştür. Bu yüzden de birçok çalışmada zaman-frekans boyutu analizinde en iyi yöntem olarak bilinen dalgacık dönüşümü (DD) kullanılmıştır. YSA ve DD tekniklerini beraber kullanan bir çalışmada Hazarika et al. (1997) normal, şizofren ve obsesif kompulsif bozukluğu olmak üzere üç ayrı sınıfa sahip EEG işaretleri üzerine çalışmıştır. Şizofren ve normal sınıflarına ait ayrı deneylerde yöntemleri başarıyla uygulamışlardır. EEG işaretlerini iki adımda işleyen bir başka çalışmada önce EEG işaretleri DD yardımıyla spektral bileşenlerine ayrılmış ve ardından bu bileşenler YSA modeline giriş olarak kullanılarak yüksek bir sınıflandırma başarısı sağlanmıştır (Szilagyi et al. 2002). Yeni doğan EEG’leri üzerinde epileptik atak tespiti üzerine yapılan bir çalışmada iki gün ile on dört gün arasında değişen yaş aralığındaki beş yeni doğandan EEG işaretleri alınmış ve özel bir algoritma yardımıyla EEG işaretlerinden en uygun özellik alt kümesi seçilmiştir (Zarjam et al. 2003). Bu özellikler bir YSA modeline uygulanarak sonuçların başarısı incelenmiştir. Uyanıklık seviyesinin ayırt edilmesi üzerine yapılan bir çalışmada uyanık, uykulu ve uyumakta olmak üzere üç sınıf etiketi kullanılmış ve EEG işaretleri DD ile ayrıştırıldıktan sonra bir YSA

modeliyle sınıflandırılmıştır. Tüm sınıf etiketleri çok yüksek doğruluk oranlarıyla tespit edilmiş olsa da başarı sıralaması uyanık, uykulu ve uyumakta şeklinde olmuştur (Subaşı 2005a). EEG işaretlerinin özniteliklerinin elde edilmesi için DD kullanan bir başka çalışmada sınıflandırma aşaması için uyarlamalı sinirsel bulanık çıkarım (SBC) ağı başarıyla kullanılmıştır (Güler and Übeyli 2005). Epileptik atak tespiti üzerine odaklanılan bir çalışmada EEG işaretleri frekans boyutundaki kadar iyi bir şekilde zaman boyutunda karakterize edilerek Elman tipi bir YSA modelinde tek giriş vektörüyle sınıflandırılmıştır. Bu model ile daha fazla giriş vektörü kullanan diğer tipteki YSA modellerinden daha başarılı sonuçlar elde edilmiştir (Srinivasan et al. 2005). Epileptik EEG işaretlerinin tespiti üzerine yapılan bir başka çalışmada ayırık dalgacık dönüşümü (ADD) arkasından uygulanan bir grup sinir ağı modelinin bir sinir ağının yalnız kullanılmasına göre daha yüksek başarıya sahip olacağı gösterilmiştir (Subaşı 2007b).

Araştırmacılar farklı sınıflandırma ve zaman-frekans analiz yöntemleri kullanarak daha yüksek başarılar yakalamaya çalışmışlardır. Atakları tanımlayabilmek için Lyapunov üssü kullanılan bir çalışmada normal ve epileptik EEG işaretleri arasındaki farklılıklar başarılı bir şekilde ortaya çıkarılmıştır (Swiderski et al. 2005). Epilepsi hastalarının atak geçirmediği (interiktal) dönemlerin belirlenmesi için yapılan bir çalışmada beyindeki epileptik bölgenin korelasyon boyutu değerinin diğer bölgelere oranla daha düşük çıktığı gözlenmiştir (Bai and Li Qiu 2007). Epileptik atak tespiti için yapılan kısa zaman Fourier dönüşümü (KZFD) ve sürekli dalgacık dönüşümü (SDD) karşılaştırmasında SDD yönteminin yüksek detay özelliği sayesinde klinik uygulamalarda, KZFD yönteminin ise düşük hesaplama süresi sayesinde gerçek zamanlı uygulamalarda kullanıma uygun olduğu belirlenmiştir (Kıymık et al. 2005). Epileptik aktivite örüntülerini sağlıklı örüntülerden ayırt edebilmek için yapılan bir çalışmada farklı entropi denklemleri sinirsel bulanık ağlar ile birlikte kullanılarak karşılaştırılmış ve sonuçta yüksek başarılar elde edilmiştir (Kannathal et al. 2005).

Son yıllarda yapılan EEG işaretlerinin sınıflandırılması çalışmalarında otoregresif model (Alkan et al. 2005, Subaşı and Erçelebi 2005), yaklaşıklık entropisi (Ocak 2009) ve doğrusal tahmin hata enerjisi (Altunay et al. 2010) gibi farklı modeller kullanılmış olsa da biyomedikal işaretlerin sınıflandırılmasında en çok YSA modelleri tercih edilmiştir (Acır 2005, Güler and Übeyli 2005, Subaşı 2007a, 2007b, Übeyli 2009). EEG işaretlerinin sınıflandırılmasında YSA modeline dayalı çok katmanlı algılayıcı (ÇKA) sinir ağı (Alkan et al. 2005, Subaşı 2005a, 2005b, 2007b, Subaşı and Erçelebi 2005, Übeyli 2009), uyarlamalı sinirsel bulanık çıkarım

ağı (Güler and Übeyli 2005, Subaşı 2007a), radyal tabanlı fonksiyon sinir ağı (Aslan et al. 2008), yinelemeli sinir ağı (Petrosian et al. 2000, Srinivasan et al. 2005, Pravin Kumar et al. 2010), öğrenen vektör parçalama (Pradhan et al. 1996), destek vektör makinesi (Übeyli 2008), uzman sistem modeli (Subaşı 2007b) ve otoregresif spektral analize sahip periyodogramlı sinir ağı modeli (Kıymık et al. 2004) gibi birçok farklı yaklaşım önerilmiştir. Bu yaklaşımlar genellikle EEG işaretlerini ‘epileptik’ veya ‘normal’ olarak sınıflandırmayı amaçlamaktadır. YSA modelleri, bir eğitim kümesinden elde edilen özellikleri kullanarak EEG işaretleri arasındaki farklılıkları saptamakta ve işaretleri sınıflandırmaktadır. Bu yüzden kullanılan özellik çıkartma sürecinin sınıflandırma başarısı üzerinde çok önemli bir etkisi bulunmaktadır.

Sınıflandırma performansında etkili bir diğer konu ise hesaplama karmaşıklığıdır. EEG işaretlerinden epileptik atak tespitinde kullanılan zaman-frekans boyutuna dayalı YSA modelleri her ne kadar daha yüksek başarı sağlasalar da gerçek zamanlı bir uygulamada hesaplama karmaşıklığının yüksek olması yüzünden sınıflandırma süresinin uzun olabileceği düşünülerek genellikle ya zaman ya da frekans boyutunda çalışan modeller tercih edilmektedir (Kıymık et al. 2005).

Bu çalışmada, daha önce epileptik aktivitelerin tespitinde uygulanmamış olan ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımı ile EEG işaretlerinin düşük hesaplama karmaşıklığı hedefiyle zaman boyutunda ve yüksek sınıflandırma başarısı hedefiyle zaman-frekans boyutunda ayırık bölge yoğunlukları hesaplanmış ve bir ÇKA sinir ağı modeline giriş olarak uygulanmıştır.

Çalışmanın takibi açısından genel akış şu şekilde özetlenebilir. İkinci bölümünde epilepsi hastalığı ve EEG işaretleri hakkında genel bilgiler verilerek EEG işaretlerinden epilepsi hastalığının otomatik teşhisi üzerine yapılan çalışmalarda kullanılan işaret analizi ve sınıflandırma tekniklerinden bahsedilmiştir. Üçüncü bölümde bu çalışmanın temelini oluşturan ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımı kullanılarak EEG işaretlerinin nasıl sınıflandırıldığı anlatılmıştır. Dördüncü bölümde, önerilen yöntemler genel kullanıma açık bir EEG verisi üzerinde hazırlanan dört deneye uygulanarak sonuçları literatürdeki farklı çalışmalarla karşılaştırılmıştır. Son olarak beşinci bölümde sonuçlar yorumlanarak öneriler sunulmuştur.

BÖLÜM 2

EPİLEPSİNİN BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ

Çalışmanın detaylarına geçmeden önce üzerine odaklanılan ve tüm insanlığı etkileyen epilepsi hastalığından, bu hastalığın teşhisinde tıbbi uzmanların ilk başvurduğu deneysel elektroansefalogram (EEG) kayıtlarından ve EEG işaretlerinin epilepsi hastalığı için yorumlanması üzerine genel tanımlardan bahsetmek yararlı olacaktır.

2.1 EPİLEPSİ HASTALIĞI

Dünya nüfusunun yaklaşık %1'inin epilepsi hastası olduğu düşünüldüğünde modern tıp biliminin bu hastalığa gösterdiği özen ve eğilimin yerinde olduğu söylenebilir. Hastalık için geliştirilen birçok tedavi yolu olmasına rağmen, dünya genelindeki epilepsi hastalarının %80–90 civarının henüz hiçbir tedaviyi almamış olması, bireylerin hastalığa bakışının aynı ciddiyeti taşımadığını gösterir. Doğuştan veya çocuk yaşlarda epilepsi olan bireyler hariç, dolaylı şekilde sonradan epilepsi olan bireyler bu istatistiklere dahil edilmemiştir. Epileptik atakların üçte ikisinden fazlası çocukluk döneminde başlar ve farklı atak şekilleriyle ortaya çıkar (Ropper and Brown 2006).

Halk arasında “sara” olarak da bilinen epilepsi hastalığı yaklaşık 150 yıl önce “sinir sisteminde ara sıra oluşan düzensizlikler ve beyin sinir dokusunun kaslar üzerindeki güçlü ve hastalıklı etkileri” olarak tanımlanmıştır. Beyindeki elektriksel boşalmalar yüzünden ani şuur kaybı, algıda değişim, psişik fonksiyon ve duyu bozuklukları ve kaslarda gerilme gibi etkiler gözlenebilir. Hastalık belirtilerinin çeşitli olması ve her hastada farklı birleşimlerle kendini göstermesi yüzünden hastalığın tanımlanmasında terminolojik bir sorun ortaya çıkar. Bazı terimlerin hastalığın sadece bazı belirtilerini kapsamaması nedeniyle genel olarak “atak” veya “nöbet” terimi kullanılır. Kaslardaki kasılmaları temsilen “konvülsif”, algı ve duyuşal değişikliği temsilen “duyuşal” veya “psişik nöbet” ve hastada atakların devamlı

tekrarlandığını anlatmak için de “epileptik nöbet” ifadelerinden bahsedilir (Ropper and Brown 2006). Epilepsi hastalığı etiyolojisi, kaynaklandığı yer, klinik şekli, sıklığı veya elektro-fizyolojik karşılığına göre sınıflara ayrılmıştır. Örneğin hastalık etiyolojisine göre birincil (idyopatik) ve ikincil (semptomatik) olmak üzere iki gruba ayrılırken klinik şekilleri itibariyle jeneralize ve fokal olarak sınıflandırılmıştır. Ancak, en çok kullanılan ve uluslararası kabul görmüş sınıflama şekli atakların klinik tipi ve elektro-fizyolojik karşılıklarına göre oluşturulmuştur. Bu sınıflandırmanın genel başlıkları aşağıda verilmektedir:

1. Jeneralize ataklar

- a. Tonik, klonik veya tonik-klonik
- b. Absans (petit mal)
 - i. Sadece bilinç kaybı
 - ii. Kompleks kısa tonik, klonik veya otomatik hareketlerle
- c. Lennox-Gastaut sendromu
- d. Jüvenil miyoklonik epilepsi
- e. İnfantil spazmlar
- f. Atonik ataklar

2. Parsiyel veya fokal ataklar

- a. Basit
 - i. Motor-frontal lob kökenli
 - ii. Somatosensoryal veya özel duyuşal
 - iii. Otonomik
 - iv. Pür psişik
- b. Kompleks
 - i. Başlangıçta basit parsiyel sonra ek olarak bilinç kaybı
 - ii. Baştan itibaren bilinç kaybı

3. Özel bazı epileptik tepkiler

- a. Miyoklonus ve miyoklonik ataklar
- b. Refleks epilepsi
- c. Edinsel afazi ve konvülsif hastalık
- d. Ateşli ve diğer infantil çocukluk atakları
- e. Histerik ataklar

Temel olarak jeneralize ve parsiyel-fokal olmak üzere iki ana başlıkta incelenen epilepsi hastalığında sınıflandırma, atağın başlangıç şekline göre belirlenir. Başlangıçtan itibaren tüm beyni etkileyen ataklar jeneralize olarak adlandırılırken belirli bir bölge veya beyin yarı küresinde başlayan ataklara parsiyel veya fokal adı verilir. Hastalığın doğru sınıflandırılması doğru ilaç tedavisi için önemlidir.

Bir epilepsi hastasına kesin teşhisin konulabilmesi için EEG, MRG (manyetik rezonans görüntüleme) ve BTG (bilgisayar destekli tomografik görüntüleme) gibi tıbbi görüntüleme cihazlarıyla hastanın izlenmesi gerekir. Genel maliyeti, süresi ve kolaylığı açısından EEG halen en çok tercih edilen yöntemdir. Bu yüzden, bu çalışmada EEG işaretleri üzerine odaklanılmıştır.


2.2 ELEKTROANSEFALOGRAF (EEG) İŞARETLERİ

MRG ve BTG yöntemlerinin geliştirilmesine kadar EEG işaretleri birçok hastalık için tek inceleme yolu olmuştur. EEG işaretleri kullanılarak inceleme yapılan hastalıklardan en önemlisi şüphesiz epilepsi hastalığıdır. Ayrıca uyku analizlerinde, bazı hastalıklarda ve ameliyathanede anestezi altındaki hastaların beyinsel aktivitelerinin incelenmesinde de kullanılır (Ropper and Brown 2006).

Beyinde bulunan sinir hücreleri, aksiyon potansiyeli denilen elektriksel işaretler üretirler. Sanılanın aksine aksiyon potansiyelleri EEG kayıtlarını önemli derecede etkiler. EEG cihazı beyin sinir hücrelerinde üretilen postsinaptik potansiyellerin beyin zarı üzerindeki bileşkesini kaydeder. Bu aktiviteleri kaydedebilmek için yüzeysel (ekstrakranial) ve dahili (intrakranial) olmak üzere iki yöntem mevcuttur. İçsel kayıtlar klinik ortamında cerrahi müdahale yardımıyla kafatası ve beyin zarı arasına yerleştirilen elektrotlar yardımıyla ölçülür. Yüzeysel kayıtlar ise 0,5 mm çapındaki lehim veya gümüş/gümüş-klorür disklerden üretilmiş elektrotlar yardımıyla saçlı deriden alınır. Her elektrot EEG cihazında bir kanal olarak isimlendirilir. En sık tercih edilen elektrot yerleşim tekniği uluslararası kabul görmüş olan 10–20 sistemidir. Bu sistemde 21 adet elektrot kafatasındaki kemiklerin işaret noktalarına yerleştirilir. Değiştirilmiş 10–20 sisteminde ise daha fazla kanal kaydı yapmak için 10–20 yerleşimi bozulmadan ek elektrot bölgeleri oluşturulur. Elektrotlardan gelen genlik işaretleri bir yükselteç yardımıyla yükseltilir ve yazıcı ünitesi aracılığıyla kağıt üzerinde frekans aralığı

0,5–30 Hz olan beyin aktivite dalgaları olarak gösterilir. Bu dalgalar aynı zamanda sayısal olarak işlenerek bir bilgisayar ekranına da aktarılır. Bu şekilde bakıldığında EEG işaretlerinin zamana karşı gerilim grafiği olduğu kolayca anlaşılır. Ölçülen işaretler çok kanallı -diğer bir deyişle paralel dalgalı- birçok çizgi olarak kaydedilir. Ortak bir elektrot veya toprak elektrotu, tek bir kayıt noktası olarak kullanılabilir.

Kanallar genellikle beyin zarının bir bölgesinden gelen aktiviteyi karşı yarımkürenin aynı bölgesinden gelen aktiviteyle karşılaştıracak şekilde gösterir. Tıbbi uzmanların grafikleri yorumlama kolaylığı EEG cihazındaki kanalların sayısı ile doğrudan ilgilidir (Ropper and Brown 2006, Fisch 1998). Aşağıdaki Şekil 2.1’de 10–20 sistemine göre elektrotların yerleştirilme düzeni gösterilmektedir.




Şekil 2.1 10–20 sistemine göre elektrotların düzeni.

Yüzeysel EEG kaydı sırasında hastadan alınan ve beyinsel (serebral) olmayan işaretler hastalığın karakteristiğini inceleme aşamasında istenmeyen işaretlerdir. Artefakt adı verilen bu işaretler, kaynağı itibarıyla iki sınıfa ayrılır. Fizyolojik artefaktlar vücut aktivitelerinden, fizyolojik olmayan artefaktlar ise elektriksel sebeplerden kaynaklanır. Elektrik şebekesindeki gerilim değişimleri veya EEG cihazındaki herhangi bir elektriksel arıza fizyolojik olmayan artefaktlara yol açar. Fizyolojik artefaktların ise kas hareketleri, ter bezleri aktiviteleri veya biyoelektriksel potansiyeller olmak üzere üç nedeni vardır. Nedeni ne olursa olsun epileptik aktivitelerin incelenmesi sırasında artefaktsız bir EEG kaydı üzerinde izleme yapılmalıdır (Fisch 1998). Bu konuda en büyük görev EEG cihazının başında duran tıbbi uzmana düşer.

2.3 EEG İŞARETLERİNDEN EPİLEPSİ TEŞHİSİ

En sık karşılaşılan EEG dalga biçimleri düzenli-ritmik, sinüzoidal, iğcik, keskin, diken ve polispike olarak adlandırılmıştır. Bu dalga biçimleri yalnız başına veya farklı iki dalganın birleşimi şeklinde karşımıza çıkabilir. Şekil 2.2’de en çok karşılaşılan EEG dalga biçimleri gösterilmiştir (Fisch 1998).



Şekil 2.2 EEG dalga biçimleri (Fisch 1998).

Diken, 20–70 ms, keskin dalgalar ise 70–200 ms sürmektedir. Diken dalgalar bazen yavaş bir dalga tarafından izlenebilir ve böylece düzenli şekilde tekrarlanan diken-dalga kompleksleri meydana gelebilir. Eğer bu tekrarlama frekansı 3 Hz’den düşük ise yavaş diken ve dalga kompleksleri denir. Keskin bir dalgayı izleyen yavaş dalga kompleksleri en fazla 3 Hz frekansındadır. Bazen de polispike kompleksi olarak isimlendirilen iki ve daha çok diken formu arka arkaya tekrar eder. Bu kompleksler de yine yavaş bir dalga tarafından izlenebilir. EEG işaretleri üzerinde gözlenen bu örüntüler uzmanlar tarafından frekanslarına göre dört gruba (δ , θ , α , β) ayrılmıştır. Bunlar Çizelge 2.1’de gösterilmiştir.

Çizelge 2.1 EEG örüntülerinin frekanslarına göre gruplandırması.

Adı	Frekans Aralığı
δ (Delta)	0.5 Hz – 4 Hz
θ (Theta)	4 Hz – 8 Hz
α (Alpha)	8 Hz – 13 Hz
β (Beta)	13 Hz – 30 Hz

Çizelge 2.1’de de görüldüğü gibi EEG işaretleri için anlamlı olan 0.5Hz – 30Hz frekans bandı gruplara ayrılmıştır. Ancak çoğu zaman 20Hz’den yukarı ölçüm yapılamaz. Dolayısıyla uygulamada β bandı sınırlarının daha dar olduğu söylenebilir.

Epileptik atak sürecindeki aktiviteler iktal epileptiform aktivite olarak ve iki atak arasındaki aktiviteler de interiktal epileptiform aktivite olarak adlandırılır. Hem jeneralize hem de lokalize epilepsi için yavaş dalgalarla birlikte gözlenen diken veya keskin dalga örüntülere epileptiform aktivite denir. Ancak, jeneralize interiktal epileptiform aktiviteler lokal interiktal aktivitelere göre daha sık, kısa tekrarlı ve ritmiktir. Bu örüntüler genellikle düzenli periyotlarla tekrarlanan diken ve dalga birleşimleri şeklindedir. Bu farklılıktan dolayı EEG işaretleri öncelikle jeneralize veya lokal epileptiform olarak sınıflandırılmalıdır (Fisch 1998). Interiktal epileptiform aktiviteler ile iktal aktiviteler olarak adlandırılan ataklar arasında her zaman doğrusal bir ilişki yoktur. Nadiren jeneralize ataklarına sahip epilepsi hastalarının EEG ölçümlerinde hiçbir epileptiform aktiviteye rastlanmazken, hiç atak geçirmeyen bazı kişilerin de EEG işaretlerinde jeneralize epileptiform aktivite gözlenebilir. Benzer durum parsiyel ataklara sahip hastalar için de geçerlidir. Her ne kadar yüksek güvenilirliğe sahip olsa da bahsedilen bu sebepten dolayı EEG işaretlerinde tespit edilen her epileptiform aktivite epilepsi hastalığının kesin teşhisi için mutlak sonucu gösteremez. Dolayısıyla EEG işaretlerinden hastalık örüntülerinin mümkün olsa bile tam doğrulukla tespitinin beklenmediği rahatlıkla söylenebilir.


Epilepsi hastalığının kaynağına cerrahi müdahalenin zorunlu olduğu durumlarda beyinde hastalığa sebep olan bozukluğun kesin yerini belirlemek gerekir. Bunun için tahmin edilen bölgeye öncü bir cerrahi müdahale yapılır ve kafatası açılarak beyin zarı yüzeyine mikro elektrotlar yerleştirilir. Dahili EEG ölçümü ile fizyolojik artefakt içermeyen ölçümler yapılabilir. Bu elektrotlar beyin zarına yakın olan nöronlar tarafından üretilen ve yüzey elektrotları tarafından ölçülemeyen yaklaşık 1ms süreli aksiyon potansiyelini de görüntüleyebilir. Dahili EEG ölçümlerinin yorumlanma mantığı da yüzeyseldeki gibidir. Kısa süreli olarak gözlenen diken ve keskin dalga içeren kompleksleri interiktal epileptiform aktivite olarak yorumlanırken daha uzun süren aktivilteler iktal aktivite olarak değerlendirilir (Fisch 1998).

Her ne kadar günümüzde üretilen EEG cihazlarının çoğu üzerinde bir bilgisayar destekli karar sistemi içeriyor olsa da yüksek güvenilirliğe sahip olmayışı sebebiyle epilepsi teşhisi halen

EEG işaretlerinin kağıt veya ekran üzerinde görüntülenmesi ve uzmanlar tarafından yukarıda bahsedilen tekniklerle yorumlanmasına dayanır. Ancak, birçok alanda olduğu gibi epilepsi teşhisi alanında da bilgisayar destekli karar sistemleri üzerine birçok çalışma yapılmakta ve farklı teknikler ile güvenilirliği yüksek sistemler üretilmeye çalışılmaktadır. Bu çalışmada da bilgisayar destekli teşhis sistemlerinde kullanılabilecek bir teknik üzerine odaklanılmıştır.

2.4 EPİLEPSİNİN BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ

Bilgisayar destekli otomatik karar sistemlerinin gittikçe daha güvenilir sonuçlar üretmesi sayesinde EEG işaretlerinin de otomatik olarak yorumlanması üzerine birçok uygulama geliştirilmiştir (Acır 2005, Alkan et al. 2005, Altunay et al. 2010, Güler and Übeyli 2005, Kıymık et al. 2004, Ocak 2009, Petrosian et al. 2000, Pradhan et al. 1996, Pravin Kumar et al. 2010, Srinivasan et al. 2005, Subaşı 2005a, 2005b, 2006, 2007a, 2007b, Subaşı and Erçelebi 2005, Übeyli 2008, 2009). Bilgisayar destekli karar sistemlerinde bahsedilen veriyi işleme süreci Şekil 2.3'deki blok diyagramıyla özetlenebilir.



Şekil 2.3 Bilgisayar destekli karar sistemlerinde süreç.

Şekil 2.3'de gösterilen bu süreç sağlıklı bireyler ile epilepsi hastalarından alınan EEG işaretlerinin bir bilgisayar sistemine sınıf bilgisi ile girilmesi, bu EEG işaretlerinin doğru belirlenmiş özniteliklere dönüştürülmesi ve son olarak bu vektörlerin bir makine öğrenmesi yöntemiyle sınıflandırılması adımlarından oluşur. Makine öğrenmesi üzerine bilinen ve yüksek başarılı birçok teknik geliştirilmiş olmasına rağmen bu tekniklerin başarısı bu yöntemlere giriş olarak verilen özellik vektörlerine bağlıdır. Dolayısıyla sınıflandırıcı yöntem kadar özellikleri elde eden yöntemin de doğru seçilmesi gereklidir. EEG işaretlerinden özelliklerin elde edilmesi iki aşamalı olarak ele alınabilir. Birinci aşamada EEG işaretleri zaman, frekans veya zaman-frekans boyutunda analiz edilir ve işaretin içerisindeki ilgili

örüntüler açık bir şekilde görülecek şekilde ayrıştırılmaya çalışılır. Diğer aşamada ise işaretlerin ayrıştırılmış katsayıları üzerinde tercih edilen tekniğe dayalı olarak anlamlı özellikler çıkartılır. Zaman boyutunda ham işaretin, frekans boyutunda genellikle güç spektrumunun ve zaman-frekans boyutunda ise ayrıştırılmış katsayıların üzerinde maksimum, minimum, entropi, standart sapma, ortalama, ortalama güç gibi istatistiksel parametreler uygulanarak öznitelikler elde edilir. Bu sayede bir EEG işareti, zamana bağlı bir vektörden zamandan bağımsız birkaç skalere dönüştürülmüş olur. Bazen elde edilen öznitelikler veriyi o kadar iyi temsil eder ki kompleks bir sınıflandırma yöntemi yerine basit bir eşik değeri belirlemek bile sınıfları ayırt edebilmek için yeterlidir. Bu şekilde basit bir sınıflandırma yöntemi kullanarak yakalanan yüksek başarı, genellikle güçlü bir özellik çıkartma aşamasının ürünü olarak yorumlanır.

2.4.1 Zaman Boyutu Analizi

EEG işaretlerinin zamana karşı gerilim grafiği olduğu düşünülürse herhangi bir işlem yapmadan ham EEG işaretleri üzerinde yapılacak her analizin en temel ve en ucuz yöntem olacağı söylenebilir. İşaretlerin yorumlanmasında en basit yöntem, analiz edilecek işaretlerin karakteristiklerine uygun istatistiksel işlemlerin uygulanarak işareten birkaç parametre elde edilmesi ve bu parametrelerin incelenmesidir. Önerilmiş birçok istatistiksel parametre olsa da EEG işaretleri için en sık kullanılan istatistiksel parametreler maksimum, minimum, ortalama, standart sapma, entropi ve ortalama güç değerleridir. EEG işaretlerindeki epileptik aktivitelerin değişim hızları ve belirginliğine bağlı olarak zaman boyutunda yapılan analizlerde de çok yüksek sonuçlar alınabilir. Epileptik atak aktiviteleri gibi zaman boyutunda bile kendini belirgin bir şekilde gösteren işaret değişimleri sayesinde böyle problemlerin gerçek zamanlı uygulamasının yapılması için daha fazla donanım maliyeti harcamadan zaman boyutu analizi yapılması daha uygundur. Fakat tüm epilepsi hastalarının sağlıklı kişilerden ayırt edilmesi gibi zor sınıflandırmalar için zaman boyutunda analiz yeterli olmaz ve bu yüzden frekans veya zaman-frekans boyut analizleri tercih edilir. Bununla beraber, zaman boyutunda analizin günümüzde halen birçok işaretin karakteristiği incelenirken kullanılan başarılı yöntemlerden biri olduğu bilinmektedir. Bu çalışmada da yapılan farklı deneylerden birisi olan epileptik atak aktivitelerinin tespitinde zaman boyutu analizi kullanılmış ve yüksek sınıflandırma başarıları elde edilmiştir.

2.4.2 Frekans Boyutu Analizi

Frekans analizi temelde bir işareti sinüzoidal işaretlerin birleşimi olarak kabul eden bir yaklaşımdır. Dolayısıyla frekans analizi sırasında incelenen işaret farklı sinüs işaretlerine ayrıştırılır. Gerçek uygulamalarda elde edilen birçok işaret sinüzoidal işaretlerin toplamı şeklinde gösterilebilir. Periyodik bir işaret için yapılan bu ayrıştırmaya Fourier serisi açılımı denir. Pratik uygulamalarda karşılaşılan işaretlerin sonlu-enerjiye sahip olduğu düşünülürse bu ayrıştırma Fourier dönüşümü olarak adlandırılır (Proakis and Manolakis 2007). Gün ışığı olarak da bilinen beyaz ışığın bir prizma yardımıyla gökkuşağındaki renklere dönüştüğü, Newton'un 1672'de yazdığı bir makalesinde ortaya atılmıştır. Newton, iki adet prizma kullanarak yaptığı bu deneyde üretilen renk demetine spektrum adını vermiştir. Prizmaları birbirine ters bir şekilde yerleştirmiş ve bu sayede birinci prizmaya gelen beyaz ışığın ikinci prizmanın çıkışında yeniden oluştuğunu ispatlamıştır. Deneyin devamında prizmalar arasında oluşan renk spektrumundaki bazı renklerin ikinci prizmaya ulaşmasını engelleyerek elde edilen nihai rengin beyaz olmadığını göstermiştir. Böylece ilk prizmadan geçen ışığın değişikliğe uğramaksızın sadece renk bileşenlerine ayrıştırıldığını ve ancak bütün renk bileşenleri birleştirilirse beyaz ışığın tekrar elde edilebileceğini ortaya koymuştur (Proakis and Manolakis 2007). Renk spektrumunun her bir rengi, beyaz ışığın belirli bir frekans bileşenidir ve prizmanın yaptığı işin benzerini matematiksel olarak her işarete uygulamak mümkündür.

Newton'un ışığın bileşen renkleri için söylediği spektrum terimi, bir işaretin frekans bileşenleri için de kullanılır. Zaman fonksiyonları şeklinde modellenen işaretler, prizma görevi gören Fourier dönüşüm araçlarıyla frekans bileşenlerine ayrıştırılabilir, ters yerleştirilen ikinci prizma görevini üstlenen ters Fourier dönüşüm araçları da frekans bileşenlerinden işareti yeniden sentezleyebilir. Her ne kadar bir işaretin bileşenlerini sadece sinüs olarak kabul etmesi Fourier dönüşümü için büyük bir eksiklik olsa da işaretlerin spektrum analizlerinde en çok bilinen ve kabul gören frekans dönüşümü Fourier dönüşümünü daha detaylı inceleyelim.

2.4.2.1 Fourier Dönüşümü

Periyodik işaretlerin temel matematiksel gösteriminde kullanılan Fourier serileri ilk kez cisimler üzerindeki ısı iletimi ve sıcaklık tanımlamalarını modellemek için Jean Baptiste Joseph Fourier tarafından 1807'de ortaya atılmıştır. Fakat o tarihin bilim çevreleri tarafından

beğenilmeyen ve günümüzde optik, mekanik titreşimler ve elektromanyetik gibi alanlarda da kullanılan bu kuram ancak 1822’de yayımlanmıştır. Fourier’in kuramında modellenen dalga, şeklini oluşturduğu düşünülen sinüzoidaller veya karmaşık üsteller gibi harmoniklerin doğrusal ağırlıklı toplamıyla hesaplanmaktadır (Proakis and Manolakis 2007). Bu doğrusal bileşim (2.1)’deki gibi temel periyodu T olan periyodik bir işarettir.

$$x(t) = \sum_{k=-\infty}^{\infty} c_k e^{j2\pi \frac{k}{T}t} \quad (2.1)$$

(2.1)’deki exponansiyel ifade harmonikleri, c_k terimi bu harmoniklerin ağırlıklarını ve $x(t)$ terimi de ağırlıklı harmoniklerin toplamıyla elde edilen işareti temsil etmektedir. Gerçek uygulamalarda her zaman periyodik örüntülere sahip işaretlerle karşılaşılmaz. T sonsuza yaklaşırken frekans aralıkları sıfıra yaklaşır ve işaret aperiodyk-sürekli olur. Aperiodyk işaretler için uygulanan Fourier dönüşümünde, doğrusal toplam işlemi sürekli işaretler için kullanılan integrale dönüşür. Bu şekilde uygulanan sürekli zamanlı Fourier (SZF) dönüşümünün ve ters dönüşümünün denklemleri sırasıyla (2.2) ve (2.3)’te verilmiştir.

$$X(\Omega) = \int_{-\infty}^{\infty} x(t) e^{-j\Omega t} dt \quad \Omega = \frac{2\pi}{T} \quad (2.2)$$

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\Omega) e^{j\Omega t} d\Omega \quad (2.3)$$

Denklemlerden anlaşılacağı gibi Fourier serisi ve dönüşümü arasındaki tek fark dönüşümde incelenen işaretin spektrumunun sürekli olmasıdır. Bu yüzden de doğrusal toplam yerine integral kullanılır. Sürekli zamanlı işaretlerin frekans eksenini $(-\infty, \infty)$ aralığında olduğu için işaretlerin sonsuz sayıda frekans bileşenine sahip olması mümkündür. Ayırık zamanlı işaretlerde ise frekans aralığı $(-\pi, \pi)$ veya $(0, 2\pi)$ ile tanımlanır. N periyotlu bir işaretin frekans bileşenlerinin eksen gösteriminde aralarındaki mesafe $f = 1/N$ veya $2\pi/N$ radyan olarak hesaplanır. Ayırık zamanlı periyodik bir işaretin Fourier serisiyle yazılması sırasında N ’den fazla frekans bileşeni kullanılamaz.

Bir işaretin frekans spektrumunun ayırık zamanlı Fourier dönüşümüyle bilgisayar gibi sayısal hesaplayıcılarda hesaplanmasını engelleyen bazı durumlar vardır. Bunlar, Fourier dönüşümünün sonsuz adet toplama bileşeni içermesi ve bu yüzden de sürekli bir fonksiyon

üretmesidir. Bu yüzden toplama bileşeni sayısı sonlu bir sayıya indirgenerek üretilen fonksiyonun ayrık hale getirilmesi gerekir. Pratik uygulamalarda işaretlerin tanım aralıklarının sınırlı sayıda örnek içermesi ile sonsuz toplama bileşeni sorunu ortadan kalkar (Proakis and Manolakis 2007). Bu durumda uygulanan ayrık Fourier dönüşümünün (AFD) ve ters dönüşümünün denklemleri sırasıyla (2.4) ve (2.5)'deki gibi olmaktadır.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi \frac{k}{N}n} \quad k = 0, 1, \dots, N-1 \quad (2.4)$$

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j2\pi \frac{k}{N}n} \quad n = 0, 1, \dots, N-1 \quad (2.5)$$

Burada N değeri sınırlı sayıda örnek içeren x işaretinin uzunluğunu gösterir. Fourier dönüşümü ardından elde edilen öznitelikler genellikle güç spektrum yoğunluğu üzerinde hesaplanmaktadır. Güç spektrum yoğunluğu, Fourier dönüşümüyle belirlenen $X(k)$ işaretinin eşleniğiyle çarpımı alınarak hesaplanır. Böylece istatistiksel parametreler, kompleks $X(k)$ işareti üzerinde değil gerçel sayılardan oluşan güç spektrumu üzerinde hesaplanır.

2.4.3 Zaman-Frekans Boyutu Analizi

İşaretlerin frekans detaylarını analiz etmede oldukça etkin bir yöntem olan Fourier dönüşümünün bazı işaretlerin karakteristik detaylarını ortaya çıkaramadığı gözlenmiştir. Deterministik ve durağan rasgele işaretlerde sabit frekans bileşenlerini başarıyla tespit eden Fourier dönüşümünün durağan olmayan rasgele işaretlerde zaman bilgisini yok etmesi sebebiyle işarettaki tüm değişimleri iyi karakterize edemediği bilinmektedir. Pratik uygulamalarda en sık karşılaşılan işaretlerin, durağan olmayan rasgele karakteristiğe sahip olması yüzünden işaret analizine sadece frekans boyutundan yaklaşmanın doğru olmadığı söylenebilir. Durağan olmayan rasgele işaretlerde değişimlerin zamanın hangi anında olduğunu yakalamak ve bununla beraber bir frekans analizi yapabilmek için birçok araştırmacı tarafından farklı yaklaşımlar önerilmiştir.

Aşağıda 1946 yılında Gabor tarafından önerilen kısa zaman Fourier dönüşümü (KZFD) yöntemi ile adı ilk kez 1909'da duyulmasına rağmen pratik uygulamalara 80'lerde giren ve bu çalışmada da deneylerde kullanılan dalgacık dönüşümü (DD) yöntemi ele alınmıştır.

2.4.3.1 Kısa Zaman Fourier Dönüşümü

Zaman-frekans boyutu analizi için ilk önerilen yöntemlerden birisi olan KZFD yöntemi, ilgilenilen işaretin belirli sayıda parçaya ayrılarak her bir parça üzerinde standart Fourier dönüşümü uygulanmasına dayanır. Buna göre durağan kabul edilen birim dalga şekillerinin birleşiminden oluşan işaretler bu birim dalgalara ayrılarak analiz edilmelidir. Frekans dönüşümü uygulanmadan önce ayrılmış her birim dalganın bir pencereleme fonksiyonuyla orijinal işaretten tam olarak yalıtılması sağlanmalıdır. Pencereleme işlemi için genellikle “dikdörtgen”, “üçgen”, “bartlett”, “blackman-harris”, “hamming”, “gauss”, “hann” ve “kaiser” fonksiyonları kullanılır. Frekans dönüşümünün tüm işaret yerine işaretin kısa parçalarına uygulanması sebebiyle KZFD yöntemi spektrogram adıyla da bilinir. Sürekli zamandaki spektrogramın temel matematiksel ifadesi (2.6)’daki gibi ifade edilebilir (Semmlow 2009).

$$X(\tau, \Omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\Omega t} dt \quad (2.6)$$

Burada t zamanı, $x(t)$ orijinal işareti, τ orijinal işaret üzerinde pencere öteleme değerini, $w(t-\tau)$ pencere fonksiyonunu, Ω frekansı ve $e^{-j\Omega t}$ frekans boyutundaki işareti araştıran karmaşık sinüzoidal terimi temsil eder. Orijinal işaretin kısa zamanlı parçalarının seçilmesi yüzünden pencereleme fonksiyonu uzunluğunun seçimi kritik olabilir. Bu seçim, işaretin durağan olduğu kabul edilen miktarına göre yapılmalıdır. (2.6)’nın ayrık zaman şekli (2.7)’deki gibi düzenlenmiştir.

$$X(m, \Omega) = \sum_{n=-\infty}^{\infty} x(n)w(n - m)e^{-j\Omega n} \quad (2.7)$$

(2.6)’da zamanı temsil eden t ifadesi, (2.7)’de örneklerin sırasını gösteren n ifadesiyle ve τ öteleme ifadesi de m ifadesiyle yer değiştirir. KZFD yöntemiyle zaman boyutunda kullanılan pencere uzunluğu esnek olarak seçilebilir ve işarettaki her değişimin zaman ve frekans konumu bulunabilir. Ancak, pratik uygulamalarda karşılaşılan birçok işaret için frekans boyutunda kullanılan pencere uzunluğunun da esnek seçilebilmesi gerekir. Hem zaman hem de frekans boyutunda pencere uzunluğunun ayarlanabildiği birkaç yöntem öne çıkmış olsa da uygulamada en başarılı yöntem dalgacık dönüşümü (DD) olmuştur (Ocak 2009).

2.4.3.2 Dalgacık Dönüşümü

Dalgacık terimini ilk olarak 1909 yılında Alfred Haar kendi tezinde ertesı yıl da başka bir çalışmasında kullanmıştır (Hernandez and Weiss 1996). Daha sonraları dalgacık teorisinde Haar ismi bir modelin adı olarak kullanılmıştır. Haar'dan sonra birçok araştırmacı dalgacık teorisi üzerine yoğun bir şekilde çalışmış ve bugün adları ile anılan teori ve terimlere imza atmıştır. Bunlardan başlıcaları Haar dalgacığı, Franklin normalizasyon sistemi, Hardy-Littlewood maksimal fonksiyonu, Littlewood-Paley teorisi ve Calderon-Zygmund kuramı olarak sayılabilir. Dalgacık teorisinin gerçek uygulama alanlarında kullanılarak yaygınlaşması ise ancak seksenli yıllarda olmuştur. Dalgacık teorisi ilk olarak sismik işaretlerin analizinde uygulanmıştır (Morlet et al. 1982). Daha sonra bunu Daubechies'in (1988) yaptığı teorik çalışma takip etmiştir. Dalgacık dönüşümü (DD) için kullanılan fonksiyonlar içerisinde en düzenli olanı ve bu yüzden de en çok kullanılanı Daubechies dalgacığı olmuştur. Aslında Haar fonksiyonunun aynısı gibi görünse de Daubechies'in birçok çeşidi türetildiği için Haar fonksiyonunun genişletilmiş şekli olduğu söylenebilir. İşaret analizine dayalı yapılmış sayısız çalışmada gösterdiği yüksek başarı dolayısıyla Daubechies en çok bilinen dalgacık fonksiyonudur.

DD temel olarak işarettteki aykırı değer ve gürültülerin temizlenmesi, işaretin sıkıştırılması ve işaretlerde meydana gelen beklentisiz değişimlerin olduğu zaman ve frekansların belirlenmesi için kullanılır. Son dönemlerde tıbbi alanlarda da sıklıkla kullanılan DD özellikle EEG, EKG, EMG ve MRG gibi medikal işaretlerin sınıflandırılmasında uygulama alanına sahiptir (Acır 2005, Adeli et al. 2003, Alkan et al. 2005, Altunay et al. 2010, Aslan et al. 2008, Bai and Li Qiu 2007, Güler and Übeyli 2005, Kannathal et al. 2005, Kıymık et al. 2005, Ocak 2009, Petrosian et al. 2000, Pradhan et al. 1996, Pravin Kumar et al. 2010, Subaşı 2005a, 2005b, 2006, 2007a, 2007b, Subaşı and Erçelebi 2005, Swiderski et al. 2005, Übeyli 2008, 2009, Zarjam et al. 2003).

Hem zaman hem de frekans boyutunda pencere boyutlarını esnekleştiren DD sayesinde düşük frekans bilgilerine ulaşmak için uzun zaman pencereleri ve yüksek frekans bilgilerine ulaşmak için de kısa zaman pencereleri seçilir. İşaret analizinde kullanılan “zaman-frekans” kavramı DD yöntemi sayesinde genişletilerek “farklı frekans seviyeleri için incelenen zaman-frekans” kavramına dönüşmüş ve ölçek adını alması sağlanmıştır. Özellikle bölgesel analizi kolaylaştırmasıyla işaretin karakteristiğı hakkında detaylı bilgi elde etmeyi mümkün kılar.

Dalgacık analizinde giriş işaretine bir alçak geçiren bir de yüksek geçiren olmak üzere iki filtre uygulanır. Alçak geçiren filtre çıkışında elde edilen bileşenlere “yaklaşıklık”, yüksek geçiren filtre çıkışında elde edilen bileşenlere de “detay” katsayıları denir. İşaretin boyutunun değişmemesi için filtre çıkışlarında örnek sayıları iki ile aşağı örnekleme yapılarak yarıya indirilir. Bu işlem, kullanıcı tarafından belirlenen altbant derinliğine kadar devam eder (Tewfik et al. 1992).

DD yönteminin dalgacık adı verilen $\psi(t)$ taban fonksiyonu, sınırlı süresi olan ve ortalaması sıfır olan bir dalga şeklindedir. Herhangi bir fonksiyonun dalgacık olabilmesi için sürekli olması, sıfır momentli olması ve fonksiyonun temel değişkeninin sonsuz değeri için fonksiyonun sıfır değerine gitmesi beklenir. Dalgacığın k . dereceden momentini (2.8)’deki şekilde tanımlanmaktadır (Daubechies 1992, Hernandez and Weiss 1996).

$$m_k = \int t^k \psi(t) dt \quad (2.8)$$

(2.8)’e göre bulunan $m_0=m_1=\dots=m_{p-1}=0$ ise $\psi(t)$ fonksiyonu p adet yok etme momentine sahiptir denir ve zaman serilerinde polinomun ihmal edilebilecek olan derecelerini tanımladığı için yüksek dereceden yok etme momentine sahip dalgacık fonksiyonları tercih edilir. Genel olarak bir dalgacık fonksiyonu genişleme (a) ve öteleme (b) adlı iki temel parametreye sahiptir. Genişleme parametresi bir fonksiyonu sıkıştırır veya yayar. Genişleme parametresinin büyük değerleri düşük frekanslara, küçük değerleri de yüksek frekanslara karşılık gelir. Öteleme parametresi ise işaretin zamanda kaymasını, diğer bir deyişle ötelenmesini sağlar. Bu iki parametre (a ve b) sürekli veya ayrık olabilir. Sürekli olmaları durumunda dalgacık fonksiyonu (2.9)’daki şekildedir (Daubechies 1992, Hernandez and Weiss 1996).

$$\psi_{a,b}(t) = a^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (2.9)$$

Ayrık olması durumunda t zaman ifadesi yerine n örnek sırası ifadesi kullanılırken genellikle $a = 2^m$ ve $b = k2^m$ olarak tanımlanır. Böylece dalgacık fonksiyonu (2.10)’daki şekli alır.

$$\psi_{m,k}(n) = 2^{-m/2} \psi(2^{-m}n - k) \quad (2.10)$$

Dalgacık analizinde birçok formül kullanılsa da her formül temel fonksiyonların genişletilmiş ve sıkıştırılmış durumlarından meydana gelir. Bir $x(t)$ işaretinin sürekli dalgacık dönüşümü (SDD) aşağıdaki (2.11) ile ifade edilmektedir:

$$X_w(a, b) = \int_{-\infty}^{\infty} x(t) a^{-1/2} \psi\left(\frac{t-b}{a}\right) dt \quad (2.11)$$

Burada, a değişkeni $\psi(t)$ fonksiyonu için zaman ölçeğini ayarlamakta, b değişkeni $\psi(t)$ fonksiyonunu $x(t)$ işareti üzerinde ötelemekte, X_w değeri ise a ve b değişkenlerine göre değişen dalgacık katsayılarını temsil etmektedir (Semmlow 2009).

Eğer $\psi(t)$ dalgacık fonksiyonu uygun seçilirse aynen Fourier dönüşümünde olduğu gibi dönüşüm sonucu elde edilen katsayılar kullanılarak orijinal işaretin tekrar elde edilmesi mümkündür. SDD, bir işareti iki değişken (a ve b) yardımıyla dalgacık katsayılarına ayırdığı için katsayıların orijinal işarete dönüştürülmesi işleminde bir çift toplam veya integral kullanır. Aşağıda verilen (2.12) ile işaret tekrar elde edilebilir (Semmlow 2009, Hernandez and Weiss 1996).


$$x(t) = \frac{1}{C} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} X_w(a, b) \psi(t) db da \quad \text{ve} \quad C = \frac{1}{2} \int_{-\infty}^{\infty} \frac{|\psi(\Omega)|}{|\Omega|} d\Omega \quad (2.12)$$

(2.12)'deki $|\psi(\Omega)|$ ifadesi $\psi(\Omega)$ dalgacık fonksiyonunun Fourier dönüşümünün mutlak değerini temsil etmektedir. Eşitliğin doğru işleyebilmesi için C değişkeninin sıfır ile sonsuz arasında bir değere sahip olması gerekir.

SDD kullanılarak orijinal işaretin yeniden elde edilmesi işlemi nadiren istenen bir durumdur. İşaretin yeniden elde edilmesini gerektiren durumlarda genellikle ayırık dalgacık dönüşümü (ADD) kullanılır (Semmlow 2009). Bununla beraber bilgisayarda bir işarete uygulanan SDD hesaplamasında sürekli işaretler ayırık hale getirilerek işlenir. Bu şekliyle SDD yöntemi ADD yöntemine benzese de a ve b parametrelerinin sürekli olması en büyük farkıdır. SDD yönteminde genişleme ve öteleme parametrelerinin sürekli olarak değişmesinden dolayı her bir birim için dalgacık katsayılarının hesaplanması zor ve zaman alıcıdır. Bu nedenle ADD daha sık kullanılır.

ADD, ayrık zamanlı işaretlerin zaman-frekans boyutundaki şeklini gösterir ve bu yüzden de çoğunlukla durağan olmayan rasgele işaretlere uygulanan bir spektral analiz tekniğidir. EEG işaretleri de durağan olmayan karakteristikler içeren ayrık zamanlı işaretler olduğu için ADD yöntemi EEG işaretlerinin analizinde yaygın olarak kullanılmaktadır (Adeli et al. 2003, Kıymık et al. 2004, Orhan et al. 2011c, 2011d, Subaşı 2005a, 2007a, 2007b, Übeyli 2009).

Hem ADD hem de SDD yönteminde işaret belli sayıda bileşene ayrıştırılır ve bu işleme çoklu çözünürlük ayrışımı denir. Bu işlemde bir $x(n)$ giriş işaretinin detay altbantları ve yaklaşıklık altbantları sırasıyla bir yüksek geçiren filtre (g) ve bir de alçak geçiren filtre (h) sayesinde elde edilir. Şekil 2.4'te bir $x(n)$ işaretinin üçüncü seviye ADD yöntemiyle altbantlarına ayrıştırılması gösterilmiştir.



Şekil 2.4 ADD tekniğiyle bir işaretin altbantlarına ayrıştırılması.

Şekil 2.4'te ilk filtreler sayesinde elde edilen işaretler birinci seviye yaklaşıklık (A_1) ve detay (D_1) katsayıları olarak adlandırılır. Sonraki seviyelerin yaklaşıklık ve detay katsayıları, önceki seviyenin yaklaşıklık katsayısı kullanılarak hesaplanır. Filtrelerin ardından uygulanan aşağı örnekleme ile işaretin ayrıştırma sonrası toplam uzunluğu da korunmuş olur.

ADD yönteminde farklı olarak bahsedilmesi gereken bir diğer kavram ise ölçek fonksiyonudur. ADD yöntemini etkin bir şekilde kullanabilmek için ilk olarak en uygun çözünürlüğün hesaplanması gerekir. En uygun çözünürlüğün hesabında orijinal dalgacık biçimi yerine bunun yumuşatılmış bir şekli kullanılır. Orijinal dalgacığın yumuşatılmış bu şekli ölçek fonksiyonu yardımıyla tespit edilir. Diğer taraftan ADD yönteminde dalgacık fonksiyonu, ölçek fonksiyonundan elde edilebilir. ADD için kullanılan ölçek $\varphi_{m,k}(n)$ ve dalgacık $\psi_{m,k}(n)$ fonksiyonları (2.13)'deki şekilde tanımlanır:

$$\begin{aligned}\varphi_{m,k}(n) &= 2^{-m/2} \varphi(2^{-m}n - k) \\ \psi_{m,k}(n) &= 2^{-m/2} \psi(2^{-m}n - k) \quad n = 0, 1, \dots, M-1\end{aligned}\tag{2.13}$$


Burada genişleme parametresi m ($0, 1, \dots, J-1$) değer aralığında ve öteleme parametresi k ($0, 1, \dots, 2^m-1$) değer aralığında yer alır. $2^{-m/2}$ ifadesi çarpım normalizasyonudur ve 2^J olarak seçilen M ifadesi işaretin uzunluğu olmak üzere $J=\log_2(M)$ 'dir (Gonzalez and Woods 2002). Bir $x(n)$ işaretinin m seviyesindeki ADD analizinde detay katsayıları dalgacık fonksiyonu yardımıyla (2.14)'deki ve yaklaşıklık katsayıları da ölçek fonksiyonu yardımıyla (2.15)'deki şekilde hesaplanır.

$$D_m(k) = \frac{1}{\sqrt{M}} \sum_{n=-\infty}^{\infty} x(n) 2^{-m/2} \psi(2^{-m}n - k)\tag{2.14}$$

$$A_m(k) = \frac{1}{\sqrt{M}} \sum_{n=-\infty}^{\infty} x(n) 2^{-m/2} \varphi(2^{-m}n - k)\tag{2.15}$$

Burada D_m ve A_m ifadeleri m . dereceden detay ve yaklaşıklık katsayılarını temsil etmektedir (Gonzalez and Woods 2002).

Dalgacık dönüşümünün en önemli bileşeni dalgacık fonksiyonudur. Filtre katsayılarının belirlenmesinde kullanılan bu fonksiyonun seçimi uygulanacak işarete bağlıdır ve genellikle deneme yanılma yoluyla belirlenir. Bu çalışmada analizler farklı dalgacık fonksiyonlarıyla çok kez tekrarlanmış, elde edilen yüksek başarısından dolayı sınıflandırma deneyleri için Daubechies 2 (Db2) dalgacığı seçilmiştir. Simetrik olmayan sayılı dalgacık fonksiyonlarından olan Daubechies dalgacıkları, verilen p sayıda yok etme momentine sahiptirler ve filtre çıkışının en az $2p$ adet sıfır olmayan katsayısı bulunur. Çalışmada kullanılan Db2 dalgacığı iki adet sıfır değerli momente ($m_0=m_1=0$) ve filtre çıkışında dört adet katsayıya (0.4830, 0.8365, 0.2241, -0.1294) sahiptir. Filtre katsayıları birkaç farklı yöntemle bulunabilmektedir. Bunlardan birisi de Lagrange interpolasyon algoritmasıdır (Shensa 1992). Shensa'nın algoritması, Daubechies'in açıkladığı toplam faz doğrusalsızlığı tarafından karakterize edilen spektral çarpanların bulunması, bu çarpanları ikili kodlarla temsil edilmesi, bu kodlardan mümkün olan tüm ikili kod alternatif alt kümelerinin belirlenmesi ve minimum toplam faz doğrusalsızlığını sağlayan alt kümenin seçilerek filtre katsayılarının bulunması aşamalarından oluşmaktadır. Db2 dalgacık ve ölçek fonksiyonlarının grafiğı Şekil 2.5'te verilmiştir.



Şekil 2.5 Db2 dalgacık ve ölçek fonksiyonlarının genel görünümü.

Şekil 2.5’de görünen ölçek ve dalgacık fonksiyonları önceki paragrafta nasıl elde edildiği anlatılan Db2 dalgacığının filtre katsayılarına özel bir işlem uygulanarak elde edilir. Daubechies, kitabında bu özel işlemi “hileli anahtarlama” adıyla bahsetmektedir.

Daha önce bahsedildiği üzere EEG işaretlerinde tıbbi uzman tarafından belirlenen δ (Delta) frekansının gözlenmesi epilepsi teşhisi için önemlidir. Her ne kadar ayrıştırma seviyesinin tespitinde işaretin baskın frekansı önemli (Adeli et al. 2003, Übeyli 2009) olsa da 0.5Hz – 4Hz frekans aralığının görünebileceği seviyeye kadar ayrıştırma yapmak EEG işaretlerinden epilepsi teşhisi için bir zorunluluktur. Gerek δ frekansını gerekse diğer frekans aralıklarını net bir şekilde ortaya çıkardığından dolayı ADD ayrıştırması için altıncı seviye seçilmiştir. Bu çalışmada kullanılan 173.6Hz frekansına sahip EEG verisinin altıncı seviye ADD ayrıştırması sonucu elde edilen altbantlarının frekans aralıkları Çizelge 2.2’de verilmiştir.

Çizelge 2.2 EEG verisinin altıncı seviye ADD ayrıştırması sonucu elde edilen altbantlarının frekans aralıkları.


Altbant	Frekans Aralığı
D ₁	86.8 Hz – 173.6 Hz
D ₂	43.4 Hz – 86.8 Hz
D ₃	21.7 Hz – 43.4 Hz
D ₄	10.8 Hz – 21.7 Hz
D ₅	5.4 Hz – 10.8 Hz
D ₆	2.7 Hz – 5.4 Hz
A ₆	0 Hz – 2.7 Hz

Bu çalışmada kullanılan EEG işaretlerinin Çizelge 2.2’de verilen altbant frekans aralıklarına göre 0.5Hz - 4Hz aralığını temsil eden δ için D_6 ve A_6 altbantları, 4Hz – 8Hz aralığındaki θ için D_6 ve D_5 altbantları, 8Hz – 13Hz aralığındaki α için D_5 ve D_4 altbantları ve son olarak 13Hz – 30Hz aralığındaki β için D_4 ve D_3 altbantları kullanılmalıdır. Buna göre eldeki EEG işaretlerinden epilepsi teşhisinde D_1 ve D_2 altbantlarının diğer altbantlara göre daha az anlam taşıdığı söylenebilir.

BÖLÜM 3

AYRIKLAŞTIRMAYA DAYALI OLASILIK YOĞUNLUĞU

Epileptik aktivite tespiti çalışmalarında EEG işaretleri genellikle istatistiksel işlemlerle elde edilen maksimum, minimum, standart sapma, ortalama, entropi, ortalama güç gibi özellik vektörleriyle temsil edilir (Ocak 2009, Subaşı 2007a, 2007b, Übeyli 2008, 2009). Bu çalışmada, sözü edilen temel istatistiksel parametreleri kullanmak yerine EEG işaretleri ayrıklaştırılmış ve ayrık bölgelerdeki olasılık yoğunluğu sınıflayıcının giriş vektörleri olarak kullanılmıştır. Şekil 3.1’de bu çalışmada önerilen yöntemeye dayalı otomatik teşhis sisteminde genel sürecin nasıl işlediği gösterilmiştir.



Şekil 3.1 Önerilen yöntem ile gerçekleştirilen otomatik teşhis sisteminde süreç.

Şekil 3.1’de blok diyagramı verilen sürecin zaman boyutunda da işleyebildiği anlaşılabilir diye süreç içerisinde zorunlu olmayan zaman-frekans dönüşümü aşaması kesikli çizgilerle gösterilmiştir. Her ne kadar Şekil 2.3’te gösterilen süreç ile çok benzer olsa da özneliliklerin istatistiksel işlemlerle elde edilmesinden önce uygulanan ayrıklaştırma aşaması Şekil 3.1’deki sürece belirgin bir üstünlük katmaktadır.

Ayrıklaştırma, veri madenciliği ve makine öğrenmesi yöntemlerinde yaygın olarak kullanılan bir ön işleme yaklaşımıdır (Clarke and Bratton 2000, Fayyad and Irani 1993, Gang and Tong 2002, Hsu et al. 2003, Jiang et al. 2009, Lee 2007, Tay and Shen 2002, Xi and Ouyang 2000). Ayrıklaştırma yöntemleri herhangi bir ön bilgiye gerek duymadan sürekli işaretleri istenen

sayıda bölgede gruplar. Her bir bölge farklı isimlerle etiketlenir ve veri noktaları bu etiketlere atanır. EEG gibi zaten ayrık olan işaretlerin ayrıklaştırılmasında temel amaç ise verinin içerisinde gizlenen ve aynı özellikleri taşıyan grup halindeki örüntülerin keşfedilmesidir.

3.1 AYRIKLAŞTIRMA YÖNTEMLERİ

Sınıflandırma işlemi genellikle nicel özellikler kullanılarak yapılır da nitel özelliklerle çalışan bazı sınıflayıcılar da mevcuttur. Bu tarz parametrik yaklaşımlar veri üzerinde olasılık yoğunluk tahmini yapmayı amaçlar. Nicel özellikler sıklıkla çok büyük değer çeşitliliğine sahip olduğu için (Bluman 1992, Samuel and Witmer 1999) veri içerisinde herhangi bir özellik-sınıf değer çiftinden genellikle çok az örnekleme olur. Bu şartlar altında her özellik değeriyle ona ait sınıf etiketini ilişkilendirme olasılığı oldukça düşük olur ve dolayısıyla genelleme olasılığı düşük olan tahminler yapılır. Bu problemi aşmak için ayrıklaştırma algoritması yardımıyla nicel özellik üzerinde belirlenen değer aralıklarındaki her bir değer o aralığı temsil eden etikete dönüştürülür. Bu sayede veri içerisindeki nicel özellikler nitelleştirilerek özellik-sınıf değer çifti çeşitliliği azaltılır. Ayrıklaştırma işlemi nicel veride düşük yoğunlukta olan sürekli olasılık yoğunluğunu yüksek yoğunluklu kesikli olasılık yoğunluğuna dönüştürerek genelleme olasılığı yüksek tahminlere imkan tanır.

Ayrıklaştırmanın en önemli dezavantajı ise ayrıklaştırma sırasında yaşanan bilgi kayıplarıdır. Nitel veri, nicel veriye göre daha az detay içerir. Nicel bir özelliğin ayrıklaştırılarak nitel hale getirilmesi sırasında veriden bazı detaylar yok olur (Samuels and Witmer 1999). Ayrıklaştırma yapılması da denilen bu yok olan detayların hassasiyeti, ayrıklaştırma katsayısıyla doğru orantılıdır. Diğer bir deyişle ayrıklaştırma katsayısı büyüdükçe kayıplar da büyür. Ayrıklaştırmada yaşanan bu bilgi kaybı, veride hassasiyetin gerektiği durumlarda rahatsızlık yaratabilir. Genel olarak bahsedilen ayrıklaştırma işleminde verinin dönüşüm karakteristiği tamamen ayrıklaştırma algoritmasına bağlıdır. Ayrıklaştırma için önerilmiş temel algoritmalar altı başlık altında toplanarak anlatılmıştır.

3.1.1 Eşit Genişlikli ve Eşit Frekanslı Ayrıklaştırma

Eşit genişlikli ayrıklaştırma (EGA) sayı doğrusunu k adet eş genişlikli parçaya bölmeye çalışırken eşit frekanslı ayrıklaştırma (EFA) ise her bir aralığın yaklaşık olarak aynı sayıda

nokta içermesini amaçlar (Catlett 1991, Kerber 1992, Dougherty et al. 1995). Hem EGA hem de EFA yöntemleri basit olmaları ve çok iyi performanslarından dolayı sınıflayıcılar için sıklıkla kullanılır (Hsu et. al. 2000, 2003). Bununla beraber, k parametresi için en uygun değerin seçilmesi zorunluluğu yöntemlerin dezavantajıdır. Eğitim verisi çok küçük olduğunda parçalanma aralıkları küçük frekanslı, eğitim verisi çok büyük olduğunda ise büyük frekanslı olur. Ayrık bölgelerin düşük frekanslı seçilmesi yüksek ayırıklaştırma varyansına, yüksek frekanslı seçilmesi ise yüksek ayırıklaştırma yanılmasına sebep olur. Bu çalışmada kullanılan EGA ve EFA yöntemlerinin algoritmalarından ileri bölümlerde bahsedilecektir.

3.1.2 Kümeleme ile Ayırıklaştırma

Kümeleme, verinin içerisindeki benzerlikleri belirleyerek en çok benzer noktaları birarada toplayan bir gruplama yöntemidir. Benzerlik ölçütünün genellikle noktaların birbirlerine olan uzaklıklarıyla ters orantılı olduğu düşünülür ve bu yüzden birbirlerine en yakın olan noktalar aynı kümede gösterilir. Veri uzayı, kümeler yardımıyla parçalara ayrılır ve bu sayede her veri noktasını sadece ait olduğu küme ile ifade etmek mümkün olur. Çok boyutlu veri uzayında yapılan kümeleme işlemi tek boyutta uygulanan ayırıklaştırma işleminin aslında genelleştirilmiş bir şeklidir. Bu çalışmada kullanılan kümeleme ile ayırıklaştırma yönteminin algoritmasından ileri bölümlerde bahsedilecektir.

3.1.3 Entropi Azaltmalı Ayırıklaştırma

Sınıf bilgisini hesaba katmayan EGA ve EFA gibi denetimsiz ayırıklaştırma tekniklerinin aksine entropi azaltmalı ayırıklaştırma denetimli bir ayırıklaştırma tekniği olarak bilinir (Fayyad and Irani 1993). Entropi azaltmalı ayırıklaştırma yöntemi sıralanmış değerlerin her bir sıralı çift arasındaki orta noktayı bir aday kesme noktası olarak değerlendirir. Her aday kesme noktasını değerlendirmek için önce veri iki aralığa ayırıklaştırılır ve daha sonra sınıf bilgisi entropisi hesaplanır. Bu ikili ayırıklaştırma işlemi minimum entropiye sahip kesme noktası seçilerek yapılır. Özyinelemeli bir algoritma olan ikili ayırıklaştırma işlemi her zaman en iyi kesme noktasını seçer. Minimum tanımlama uzunluğu kriteri sağlandığında algoritma durdurulur.

Güçlü bir performansa sahip olan entropi azaltmalı ayırıklaştırma yönteminin bir çeşit karar ağacı olduğu söylenebilir (Dougherty et al. 1995, Perner and Trautzsch 1998, An and Cercone

1999). Ayrıca az çeşitliliğe sahip nitel özellikler ile çalışması sayesinde karar ağaçlarında klasik bir sorun olan parçalama probleminin üstesinden de gelmiştir. Birden fazla nicel özellik arasındaki ilişkinin ayırıklaştırma sonrası korunması mümkün olmayabilir. Bu yüzden kategorik sınıflayıcılar tek özellikten yararlanır. Entropi azaltmalı ayırıklaştırma yöntemi her nicel özelliğin sınıf bilgisi entropisini hesaplayarak ayırıklaştırma yaptığı için yalnızca tek özellik içeriği kullanılarak yapılan sınıflandırmalarda etkili olabilir.

3.1.4 Ertelemeli Ayırıklaştırma

Ertelemeli ayırıklaştırma yöntemi, adını ayırıklaştırma işlemini sınıflandırma zamanına kadar geciktirmesinden alır (Hsu et al. 2000, 2003). Denetimli bir yöntem olması dolayısıyla veriyi eğitim ve test verisi olarak bölmeyi gerektirir. Yöntem, her iterasyonda bir nicel özelliğin bir değeri için iki adet kesme noktası belirler ve belirlenen kesme noktaları ile sınırlandırılan aralık dışındaki veri noktalarıyla ilgilenmez. Yöntemin bir avantajı test verisinin belirlenen aralığa dahil olan veri noktalarını içermesi durumunda kolayca atama yapmasıdır.

Bununla beraber yöntem, sınıflandırma süresince kullanmak üzere tüm eğitim noktalarını saklamak zorunda olduğu için yüksek hafıza ve hesaplama kapasitesi gerektirir. Çok sayıda veri noktası sınıflandırıldığında, her noktaya ayrı işlem uyguladığı için çok daha büyük hesaplama maliyetlerine yol açabilir. Ertelemeli ayırıklaştırma yöntemi, kategorik sınıflayıcılarla kullanıldığında EGA ve entropi azaltmalı ayırıklaştırma ile karşılaştırılabilir bir başarıya sahip olsa da (Hsu et al. 2000, 2003) yüksek hafıza ve hesaplama maliyeti yüzünden genellikle sınıflayıcıların performansını düşürür.

3.1.5 Oransal Ayırıklaştırma

Birçok çalışmada ayırıklaştırma yöntemleri tarafından belirlenen aralık frekansı ve sayısının, ayırıklaştırma yanılmasını ve varyansını etkileyebileceği hipotez olarak ileri sürülmüştür (Gama et al. 1998, Hsu et al. 2000, 2003, Hussain et al. 1999, Mora et al. 2000, Pazzani 1995, Torgo and Gama 1997, Yang and Webb 2009). İyi bir öğrenme sisteminin hem düşük yanılmaya hem de düşük varyansa sahip olması gerekir. Bu yüzden her ikisinin de eşit şekilde azaltılması önerilir (Moore and McCabe 2003). Düşük varyans için yüksek aralık frekansı ve düşük yanılma için de büyük aralık sayısına ihtiyaç vardır. Bunu başarmak için oransal ayırıklaştırma yöntemi aralık frekansı ve sayısını eğitim verisi ile orantılı olarak ayarlayan bir

yöntemdir. Oransal ayırıklaştırma yönteminde, istenen aralık frekansı m ve istenen aralık sayısı K değerleri (3.1) kullanılarak hesaplanır.

$$\begin{aligned} m \cdot K &= n \\ m &= K = \sqrt{n} \end{aligned} \quad , m=K \text{ olursa} \quad (3.1)$$

Burada n ifadesi eğitim verisi içerisindeki nokta sayısıdır. Bu yöntemde, nicel değerler azalan sırada sıralandıktan sonra m frekans aralıklarına ayırıklaştırılır. Bu yüzden her aralığın yaklaşık m adet bitişik değerlere sahip eğitim noktası içermesi beklenir. Hem aralık sayısının hem de aralık frekansının eşit ayarlanması sayesinde ($m=K$) yanılma ve varyans beraber ayarlanır. Aralık sayısı arttığı zaman yanılma ve aralık frekansı arttığı zaman da varyans azalacağı için seçilen sınıflayıcının tahminleri daha güvenilir olur. Bu şekliyle EFA yönteminden tek farkı aralık sayısının esnek olmayışıdır. En uygun aralık sayısının (3.1) ile belirlendiği durumlarda bile farklı veri ve sınıflayıcılar için yüksek sınıflandırma performansı garanti edilemez.

3.1.6 Sabit Frekanslı Ayırıklaştırma

Ayırıklaştırma yanılması ve varyansını yönetmeye alternatif bir başka yaklaşım da sabit frekanslı ayırıklaştırma yöntemidir. Bir nicel özelliği ayırıklaştırmak için sabit frekanslı ayırıklaştırma yöntemi yeterli büyüklükteki bir aralık frekansını m değerine ayarlar. Sonra artan sıralı değerleri aralıklar m frekanslı olacak şekilde ayırıklaştırır. Böylece her aralık bitişik değerli yaklaşık aynı sayıda (m) eğitim noktasına sahip olur. Her aralıkta yeterli sayıda eğitim noktası olması sağlanarak ve ayırıklaştırma varyansının çok yüksek olması önlenerek sınıflayıcıların güvenilir tahminler üretmesi sağlanır. EFA ile sabit frekanslı ayırıklaştırma yöntemlerinin farklılıklarını bilmek önemlidir. Her ikisi de eşit frekans aralıkları düzenlese de aralık frekansını kontrol etmediği için EFA, ayırıklaştırma yanılması ve varyansını yönetmede iyi değildir. Aksine sabit frekanslı ayırıklaştırma yöntemi aralık frekansını sabitler. Sınıflayıcıların güvenilir tahminler üretebilmesi için yeterli olan bir m aralık frekansı bulur ve her bir aralık m sayıda eğitim noktası içersin diye kesme noktalarını tespit eder (Catlett 1991, Kerber 1992, Dougherty et al. 1995). Ancak, en uygun aralık frekansının belirlenmesi kolay değildir. Veriye göre değişen en uygun m değerini belirlemek için genellikle minimum örnek boyutunu tutabilen bir frekans seçilir (Weiss 2002). Kategorik sınıflayıcılarla başarılı sınıflandırma sonuçları alınsa da seçilen m değerinin bu çalışmadaki gibi nicel sınıflayıcılarda

başarılı bir sonuç üretmesi garanti edilemez. Çünkü ayırıklaştırma yapılması ve varyansı gruplama temelli sınıflandırmalarda hedef alınacak kadar önemsenmez. Hatta varyans ve kayıpların bazı hesaplamalar sırasında ihmal edilmesi, sınıflandırma işleminin doğasından kaynaklanır.

3.2 AYRIKLAŞTIRMAYA DAYALI OLASILIK YOĞUNLUĞU YAKLAŞIMI

Bu çalışmada önerilen ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımının amacı, işaretin genlik ekseninin hangi bölgesinde ne kadar veri yoğunluğuna sahip olduğunu belirlemektir. Bu amaç için, EEG işaretleri seçilen ayırıklaştırma algoritması yardımıyla ayırıklaştırıldıktan sonra EEG segmentlerinin her aralığının olasılığı (3.2)'deki gibi hesaplanır.

$$P_j^*(i) = \frac{S_{ij}}{S_j} \quad i = 1, 2, \dots, K \quad j = 1, 2, \dots, n \quad (3.2)$$

(3.2)'de bulunan S_{ij} ifadesi j nci EEG segmentinin i nci aralığındaki genlik değeri sayısını, S_j ifadesi j nci EEG segmentindeki toplam genlik değeri sayısını, n ifadesi tüm EEG segmentlerinin sayısını ve K ifadesi de istenilen ayırıklaştırma seviyesini gösterir. Ayırıklaştırmaya dayalı olasılık yoğunluğu yaklaşımının başarısı seçilen ayırıklaştırma algoritmasına, verinin dağılımına ve kullanılan sınıflandırma modeline bağlıdır. Bu çalışmada, EEG işaretleri üzerinde üç farklı ayırıklaştırma yöntemi uygulanmıştır: eşit genişlikli ayırıklaştırma (EGA), eşit frekanslı ayırıklaştırma (EFA) ve K-means kümelemeye dayalı ayırıklaştırma. Bu yöntemler kullanılarak her bir EEG segmentinin aralıklara ait olasılık yoğunluğu hesaplanmış, daha sonra bu değerler, ortalama karesel hata temelli eğri uyurma yöntemiyle ve ayrıca ÇKA sinir ağıyla sınıflandırılmıştır. Seçilen ayırıklaştırma yöntemleri 3.1 başlığı altında anlatılan en basit algoritmalar ve bu üç yöntem de aralık sayısını dışarıdan istemektedir. Bu sayede en yüksek sınıflandırma başarısını sağlayan aralık sayısı değerinin bir denklemle tahmin edilip edilemeyeceği de incelenebilecektir.

3.2.1 Eşit Genişlikli Ayırıklaştırma ile Olasılık Yoğunluk Analizi

Eşit genişlikli ayırıklaştırma (EGA) yöntemi, işaretleri genlik ekseninde en büyük ve en küçük değerler arasında K adet eşit aralığa böler. Her aralığın genişliği W (3.3)'deki gibi hesaplanır:

$$W = (v_{\max} - v_{\min}) / K \quad (3.3)$$


(3.3)'deki $v_{\min}$ minimum genlik değerini ve $v_{\max}$ maksimum genlik değerini gösterir. Ayırıştırılacak işaret için kesme noktaları (3.4)'teki gibidir:

$$v_{\min} + W, v_{\min} + 2W, \dots, v_{\min} + (K - 1)W \quad (3.4)$$

Bu çalışmada, verideki tüm EEG segmentleri (3.4) ile belirlenen kesme noktalarına göre ayırıştırılmış ve her aralığa düşen veri noktası (genlik değeri) yoğunluğu hesaplanmıştır. EEG işaretlerinin EGA temelli olasılık yoğunluklarını elde etmek için kullanılan algoritma aşağıdaki adımları içermektedir (Orhan vd. 2010a, 2011b):

1. Tüm EEG segmentlerine ait genlik değerlerini birleştir.
2. Genlik değerlerinden oluşan birleştirilmiş veriyi (3.4)'e göre $K-1$ adet sınır noktası belirleyerek K adet aralığa böl.
3. Belirlenen bu sınır noktalarına göre her bir EEG segmentinin hangi aralıkta kaç genlik değeri içerdiğini hesaplayarak olasılık yoğunluğunu (3.2)'ye göre bul.

K 'nın büyük değerleri için ayırıştırılan işaretler K 'nın küçük değerleri için ayırıştırılan işaretlere göre gerçek işarete daha çok benzerlik gösterir. Şekil 3.2, $K=3$ ve $K=9$ değerleri için EGA yöntemi kullanılarak ayırıştırılmış bir EEG segmentini göstermektedir.



Şekil 3.2 Bir EEG segmentinin $K=3$ ve $K=9$ için EGA ile ayırıştırılması.


Şekil 3.2’den görüldüğü üzere K değerinin büyük değeri için ayrıklaştırılan işaret gerçek EEG işaretine daha çok benzerdir.

3.2.2 Eşit Frekanslı Ayrıklaştırma ile Olasılık Yoğunluk Analizi

Eşit frekanslı ayrıklaştırma (EFA) yöntemi her aralığın eşit sayıda veri noktası içermesini sağlayacak şekilde genlik eksenini böler. Diğer bir deyişle n adet nokta içeren sürekli bir öznitelik eksenini EFA yöntemi yardımıyla K adet aralığa bölünmek istendiğinde her bir aralıkta n/K adet veri noktası olacaktır. EEG işaretlerinin EFA temelli olasılık yoğunluklarını hesaplamakta kullanılan algoritma aşağıdaki gibidir (Orhan et al. 2011a, 2011d):

1. Tüm EEG segmentlerine ait genlik değerlerini sıralayarak birleştir.
2. Sıralanmış genlik değerlerinden oluşan birleştirilmiş veriyi her aralıkta eşit sayıda genlik değeri olacak şekilde K adet aralığa böl.
3. Komşu olan her iki aralıkta birbirlerine en yakın iki genlik değerinin ortasını bu aralıklar için sınır olarak belirle.
4. Belirlenen bu sınır noktalarına göre her bir EEG segmentinin hangi aralıkta kaç genlik değeri içerdiğini hesaplayarak olasılık yoğunluğunu (3.2)’ye göre bul.

Şekil 3.3, $K=3$ ve $K=9$ değerleri için EFA yöntemi kullanılarak ayrıklaştırılmış bir EEG segmentini göstermektedir.



Şekil 3.3 Bir EEG segmentinin $K=3$ ve $K=9$ için EFA ile ayrıklaştırılması.

Şekil 3.2 ve 3.3'ten görüldüğü gibi hem EGA hem de EFA yöntemlerinde K değerinin büyük değerleriyle ayrıklaştırılan işaretler küçük değerlerinkine göre gerçek işarete daha çok benzerdir. Ayrıklaştırma yapılması açısından bakıldığında daha fazla aralığa bölünen işaretlerde daha az kayıplar olmasına rağmen aralık sayısının fazlalığı yüzünden daha çok işlem sayısı oluşacak ve dolayısıyla yüksek hesaplama karmaşıklığı yüzünden algoritmanın performansı düşecektir.

3.2.3 K-means Kümeleme Yöntemi ile Olasılık Yoğunluk Analizi

Terim ve işlev olarak ayrıklaştırmaya benzeyen bir diğer kavram kümelemedir. Bir kümeleme yöntemi veri noktaları arasındaki benzerlik veya benzersizlik ölçütüne göre veriyi gruplara böler. En çok bilinen ve kullanılan kümeleme algoritması olan K-means yöntemi iterasyon bir yaklaşıma sahiptir (Hekim and Orhan 2007, 2011, Orhan et al. 2008, 2011c). Algoritmayı iterasyon sayısı veya maliyet için eşik değeri belirleyerek durdurmak gerekir. Bu özelliği ile çalışma süresi uzun sürebilen bir algoritmadır. Ayrıca küme merkezlerinin başlangıç konumlarını rasgele noktalardan seçerek başlaması, en iyi sonuca rastsal bir zamanda ulaşmasına neden olur.

K-means algoritması karesel hata temelli maliyet fonksiyonunu minimize etmeye dayalı olarak küme merkezlerini saptar. Algoritmanın amacı, küme merkezlerini birbirinden olabildiğince uzak konumlandırmak ve her bir veri noktasını en yakın küme merkezine ilişkilendirmektir. K-means kümeleme algoritmasında benzersizlik ölçütü olarak genellikle Öklit uzaklığı kullanılır. Öklit uzaklığına dayalı maliyet fonksiyonu J (3.5) denklemindeki gibi tanımlanır:

$$J = \sum_{i=1}^K \left(\sum_k \|x_k - c_i\|^2 \right) \quad (3.5)$$

Burada, K küme sayısını, c_i kümelerin merkezlerini ve x_k ise i nci kümede bulunan k ncı örüntüyü gösterir. Bir örüntü kendisine en yakın olan küme merkezine üyedir ve buna göre ikili üyelik matrisinin (U) elemanları (3.6)'daki gibi tanımlanır:

$$u_{ij} = \begin{cases} 1 & , \|x_j - c_i\|^2 \leq \|x_j - c_t\|^2, \forall t \neq i \\ 0 & , \text{diğer} \end{cases} \quad (3.6)$$

Burada u_{ij} jnci örüntünün i nci kümeye ait olup olmadığını gösterir. Maliyet fonksiyonunu minimize eden her bir küme merkezi c_i (3.7)'deki gibi tanımlanır:

$$c_i = \frac{\sum_{j=1}^N u_{ij} x_j}{\sum_{j=1}^N u_{ij}} \quad (3.7)$$

(3.7)'de N örüntü sayısıdır. EEG işaretlerinin K-means temelli olasılık yoğunluklarını elde etmek için kullanılan algoritma aşağıdaki adımlardan oluşmaktadır (Orhan et al. 2008, 2011c, Orhan vd. 2010b):


1. Tüm EEG segmentlerine ait genlik değerlerini birleştir.
2. Genlik değerlerinden oluşan birleştirilmiş veriden küme merkezlerinin başlangıç konumu olarak K adet genlik seç.
3. (3.6)'ya göre U üyelik matrisini hesapla.
4. (3.5)'e göre J maliyet fonksiyonunu hesapla.
5. (3.7)'ye göre c_i küme merkezi konumlarını güncelle.
6. Küme merkezlerinin konumları değişmeyene veya iterasyon sayısı belirlenen değere ulaşıncaya kadar adım 2'ye git.
7. Belirlenen bu küme merkezlerine göre her bir EEG segmentinin hangi kümede kaç genlik değeri içerdiğini hesaplayarak olasılık yoğunluğunu (3.2)'ye göre bul.

Önceki iki yöntemde olduğu gibi, bu yöntemde de EEG işaretleri gruplara ayrıldıktan sonra olasılık yoğunlukları hesaplanır. Üç yöntemde de gruplara ayırma işlemi birleştirilmiş veri üzerinde yapılırken olasılık yoğunluklarının hesaplanması ise ana veri üzerindeki her bir segment için ayrı yapılır. Diğer önemli bir nokta da K-means yönteminin rastlantısal değerlerle başlamasıdır. Bu yüzden K-means yönteminin kullanıldığı deneylerde ayrıklaştırma işlemi sınıflandırmayla beraber 50 defa tekrarlanmıştır.

3.3 SINIFLANDIRMA

Çalışmada önerilen ayırıklaştırmaya dayalı olasılık yoğunluğu yöntemlerinin sınıflandırma başarısını ölçebilmek için iki ayrı model kullanılmıştır. Bunlardan ilki çalışmanın temelini de oluşturan ve en sık tercih edilen yapay sinir ağı modeli olan ÇKA sinir ağıdır. Diğeri ise tespit edilen olasılık yoğunluğunun eğri uydurmayla belirlenmiş olan iki fonksiyondan hangisine daha çok benzediğinin ortalama karesel hata ile belirlenmesine dayanmaktadır. Kullanılan ÇKA sinir ağına ilişkin detaylar aşağıda anlatılmıştır. ÇKA ve diğer yapay sinir ağı modellerine ilişkin detaylar “Ek Açıklamalar A” bölümünde verilmiştir.

Önerilen yöntem, üç ayırıklaştırma algoritması için de aynı özelliklere sahip bir ÇKA sinir ağıyla eğitilmiştir. Yüksek çalışma performansı sağlaması ve sınıflandırma yönteminin sonuca katkısının sınırlandırılması amacıyla tek gizli katman ve bu katman içerisinde sadece 5 nöron bulunur. Deneyler MATLAB programlama ortamında gerçekleştirilmiş ve kodlamanın bazı kısımlarında MATLAB ortamının hazır komutlarından yararlanılmıştır (Demuth et al. 2006). YSA modellerinin ağırlıkları başlangıçta rastgele olarak seçildiği için çalışmada kullanılan ÇKA sinir ağı her deney için 500 defa yeniden oluşturularak eğitilmiştir. ÇKA sinir ağına Levenberg-Marquardt eğitim algoritması ve hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Maksimum iterasyon sayısı, hedef hata değeri, öğrenme oranı ve momentum katsayısı değişkenleri MATLAB’ın varsayılan değerlerinde bırakılmıştır. Önerilen sistemin blok diyagramı ve özniteliklerin ÇKA sinir ağına verilmesi Şekil 3.4’te gösterilmiştir.



Şekil 3.4 EEG verisinin olasılık yoğunlukları şeklinde ÇKA sinir ağına uygulanışı.

Şekil 3.4’ten görüldüğü gibi EEG verisi istenirse ADD ile zaman-frekans veya yalın halde kalarak zaman boyutunda önerilen modele uygulanır. Önerilen model EEG işaretlerinin her birini (eğer zaman-frekans boyutu seçilmişse her altbant için) K adet olasılık değerine ($x_1, x_2, \dots, x_K$) dönüştürür. Bu değerler ÇKA sinir ağının girişi olarak uygulanarak sınıflandırma yapılır ve y çıkışında elde edilen sınıf değeri elde edilir. Burada y sınıfı ideal olarak epilepsi hastaları için 0 ve sağlıklı bireyler için 1 değerlerini almaktadır.

YSA modellerinde elde edilen başarının genelleştirilebilmesi için kullanılan tüm çapraz geçerlik yöntemlerinde verinin eğitim, geçerlik ve test olmak üzere üç parçaya ayrılması önerilir. Bu çalışmada sonuçları karşılaştırmak için 10-parça geçerlik yöntemi kullanılmıştır. 10-parça yaklaşımında her bir sınıfın veri parçalarındaki dağılımları eşit olacak şekilde veri 10 eşit parçaya ayrılır. Bunlardan dokuz parçası birleştirilerek eğitim için ve son parça ise test için kullanılır. Eğitimde kullanılan veri parçası diğer parçalarla değiştirilerek bu işlem 10 kez tekrar edilir. Test verisinden elde edilen on adet başarının ortalaması modelin genelleştirilmiş başarısını yansıtır. Eğitim için ayrılan ve tüm verinin 9/10'unu temsil eden veri kümesi ayrıca bir kez daha parçalanır: eğitim kümesi ve geçerlik kümesi. Bu çalışmada parçalanma oranı 1/2 olarak seçilmiştir. Bu parçalanma ile elde edilen geçerlik kümesi sayesinde YSA modelinin eğitiminin ne zaman bitirileceği kestirilir. YSA modelinin nihai tahmin başarısı aşağıdaki istatistiksel ölçütlerle hesaplanır:

Doğru Pozitif (DP): Doğru sınıflandırılan pozitif sınıfa ait nokta sayısı

Doğru Negatif (DN): Doğru sınıflandırılan negatif sınıfa ait nokta sayısı

Yanlış Pozitif (YP): Pozitif olarak sınıflandırılan negatif sınıfa ait nokta sayısı

Yanlış Negatif (YN): Negatif olarak sınıflandırılan pozitif sınıfa ait nokta sayısı

Belirlilik (b): Doğru negatif sayısının (DN) gerçek negatif durum sayısına (DN+YP) oranı

Duyarlılık (d): Doğru pozitif sayısının (DP) gerçek pozitif durum sayısına (DP+YN) oranı.

Sınıflandırma yöntemlerinde modelin başarısı için genelde kullanılan geçerlik ölçütü toplam sınıflandırma doğruluğudur ve doğru sınıflandırılan örnek sayısının tüm örnek sayısına oranıyla hesaplanır. Ancak, örnek sayılarının sınıflara dağılımı çok farklı olan bir veride genel başarının yüksek olması durumunda, bu ölçüt az örneğe sahip sınıfın da yüksek başarıya sahip olduğu şeklinde yanlış bir kanıya yol açabilir. Bu nedenle bir başarı değerlendirmesinde her sınıfın kendi içindeki doğruluk oranlarını gösteren belirlilik (b) ve duyarlılık (d) parametreleri birlikte kullanılmalıdır. Bu sayede genel başarı ölçütünün tüm sınıfların başarı oranlarını temsil edebilmesi sağlanır. Birçok çalışmada başarı ölçütü olarak kullanılan ROC (Receiver Operating Characteric) analizinde de b ve d parametreleri birlikte kullanılır. İki sınıflı sistemlerde kullanılan ROC analizinde başarı, sınıfları ayıran eşiğin değiştiği durumlarda duyarlılığın belirliliğe oranıyla elde edilen eğrinin alanıyla ilgilidir. Elde edilen başarının tek değere sahip olması durumunda ROC analizinde başarı eğrisinin altında kalan alan (3.8) denklemiyle hesaplanır.

$$B_{ROC} = \frac{b+d}{2} \quad (3.8)$$

Çalışmada yapılan deneylerde başarı ölçütü olarak (3.8) denklemi kullanılmıştır. Aynı deney için yapılan tekrarlar içerisinde en yüksek B_{ROC} başarısına sahip sonuç, deneyin başarı sonucu olarak verilmiştir.

Çalışmada kullanılan diğer sınıflandırma yöntemi de eğri uydurmaya ve ortalama karesel hataya dayanmaktadır. Bir tahminleme yöntemi olan eğri uydurmada amaç bir x değişkeninin bilinen birçok değerine karşı bir y sınıf değişkeninin aldığı değerlere göre bir fonksiyon oluşturmaktır. Bu sayede yeni bir x değeri için bilinmeyen y sınıf değişkeni tahmin edilebilmektedir. Eğer sınıf değişkeninin aldığı değerler, bilinen bir olasılık yoğunluğu ile ifade edilebilirse (x, y) değer çiftleri için eğri uydurma işi kolaylaşır. Bunun için (x, y) değer çiftlerinin öncelikle Gauss dağılımına sahip olduğu varsayımı ile bir f Gauss fonksiyonunun x giriş değişkenine karşı ürettiği y^* değerinin gerçek sınıf değişkeni y değerine yaklaşık eşit olduğu varsayılır. Buna göre $f(x, y^*)$ fonksiyonu ile (x, y) değerleri arasındaki benzersizliği azaltmak üzere bir β hassasiyet parametresi tanımlanır (Bishop 2007). Bu ilişki (3.8) ile gösterilir.

$$f(x, y^*, \beta) \Rightarrow (x, y) \quad , \beta \in R \quad (3.8)$$

Verilen x değerlerine karşı y değerleri ile fonksiyonun bulduğu y^* değerleri arasındaki karesel farkların ortalaması hesaplanır ve bu ortalama değeri azaltacak şekilde $f(x, y^*, \beta)$ fonksiyonundaki β değeri ayarlanır. Ortalama karesel hatayı minimum yapan β değeri için eğri uydurma işi tamamlanmış olur. Veri noktalarının dağılımına göre β hassasiyet parametresine ek olarak farklı katsayılar da kullanılabilir. Bu katsayıların sabit bir sayı veya veriye bağlı bir değişken olması çözümün geliştirilebilmesi açısından önemlidir.

Bu çalışmada, gerçekleştirilen deneylerde veri kümesindeki her sınıfı temsilen bir EEG işaretinin var olduğu varsayımı ile EGA ve EFA yöntemleriyle ayrıklaştırılan EEG işaretlerinin olasılık yoğunluklarının ortalamaları hesaplanmıştır. EEG işaretleri hem zaman boyutunda hem de zaman-frekans boyutunda altıncı seviyeden Db2 dalgacığı kullanan ADD ile analiz edilmiştir. Her sınıfı temsil ettiği varsayılan olasılık yoğunluk grafikleri incelenerek eğri uydurma sayesinde deneye uygun bir olasılık yoğunluk fonksiyonu bulunup

bulunamayacağı yorumlanmıştır. Her ne kadar K-means yöntemi hakkında genel bir karakteristiktan bahsedilse de rastgele başlangıç değerleri dolayısıyla EEG işaretlerinin bu yöntemle ayrıklaştırılması sonrası karakteristik bir olasılık yoğunluğu bulunamamış ve bu yüzden eğri uydurma çalışmalarında bu yöntem kullanılmamıştır.

Eğri uydurma tek başına bir sınıflandırma yöntemi değildir. Bu yüzden farklı bir modelle beraber kullanılması gerekmektedir. Çalışmada hesaplanan ayrıklaştırmaya dayalı olasılık yoğunluklarının her sınıfı temsilen eğri uydurmayla belirlenmiş fonksiyonlardan hangisine daha çok benzediğini belirlemek için ortalama karesel hatadan yararlanılmıştır. En küçük ortalama karesel hatanın en çok benzerlik anlamına geldiği mantığıyla sınıflandırma yapılmıştır. Bu sınıflandırma yönteminin dezavantajı ise ortalama karesel hatanın karşılaştırmadan öte ne kadar büyük veya küçük olduğunun dikkate alınmamasıdır. Bir işaretin sınıfları temsil eden fonksiyonlardan hiç birine benzememesi durumunda da sınıflandırılması yöntemin tutarsız tarafıdır.

BÖLÜM 4

DENEYLER VE ANALİZ SONUÇLARI

Çalışmada genel kullanıma açık bir EEG verisi kullanılmış ve bu veri üzerinde farklı yaklaşımlar ele alınarak deneyler gerçekleştirilmiştir. Genel kullanıma açık olması dolayısıyla veri üzerinde yapılmış birçok çalışmanın bulunması bu tezde elde edilen sınıflandırma başarılarının karşılaştırılmasında yararlı olmuştur. Bu bölümde çalışmada kullanılan veri, yapılan deneyler ve deneylere ait sonuçlar verilmiştir. Sonuçları vermeden önce her bir yöntem için temsilen kullanılan kısaltmalar Çizelge 4.1’de verilmiştir.

Çizelge 4.1 Deneylerde kullanılan yöntemler ve kısaltmaları.


Kısaltma	Açıklama
Yöntem 1	EFA ile ayırıklaştırılan işaretlerin olasılıklarını iki fonksiyona ortalama karesel hata ile benzerliğine göre sınıflandırma
Yöntem 2	EFA ile ayırıklaştırılan işaret olasılıklarını ÇKA sinir ağıyla sınıflandırma
Yöntem 3	EGA ile ayırıklaştırılan işaret olasılıklarını ÇKA sinir ağıyla sınıflandırma
Yöntem 4	K-means ile ayırıklaştırılan işaret olasılıklarını ÇKA sinir ağıyla sınıflandırma
Yöntem A	Zaman boyutunda ABCD-E sınıflandırma sonucu (Altunay et al. 2010)
Yöntem B	Zaman-frekans boyutunda ABCD-E sınıflandırma sonucu (Güler and Übeyli 2005)
Yöntem C	Zaman boyutunda A-E sınıflandırma sonucu (Pravin Kumar et al. 2010)
Yöntem D	Zaman boyutunda A-E sınıflandırma sonucu (Srinivasan et al. 2005)
Yöntem E	Zaman-frekans boyutunda A-E sınıflandırma sonucu (Subaşı 2007b)

4.1 DENEYLERDE KULLANILAN EEG VERİSİ

Bu çalışmada kullanılan EEG verisi, her biri tek-kanallı 100 EEG segmenti içeren beş veri kümesinden (A, B, C, D ve E) oluşur (Andrzejak et al. 2001). Her bir segment 23,6 saniyelik

süre boyunca 173,60Hz örnekleme frekansı ile kaydedilmiştir. Veri, göz ve kas hareketleri yüzünden meydana gelen aykırı durumlar içermeyen EEG segmentlerinden seçilmiştir. A ve B veri kümeleri yüzeysel olarak; C, D ve E veri kümeleri ise dahili olarak kaydedilmiştir. A ve B veri kümeleri gözler açık ve gözler kapalı olarak beş sağlıklı bireyden; C ve D veri kümeleri beş epilepsi hastasının epileptik olmayan ve olan beyin yarıkürelerinden atak geçirmediği zamanlarda alınmıştır. E veri kümesi ise bu beş epilepsi hastasının atak geçirdikleri zamanlarda kaydedilmiştir (Andrzejak et al. 2001). Veriyi ilk kez bilimsel bir çalışmada kullanan araştırmacılar farklı patolojik ve psikolojik beyin durumları ile beynin farklı bölgelerinden alınan elektriksel beyin aktivitelerini karşılaştırmışlardır. Fakat bu veriyi kullanarak yapılan diğer çalışmalarda araştırmacıların amacı, kabul görmüş bu veri üzerinde farklı özellik çıkartma ve sınıflandırma önerileriyle epilepsi teşhisindeki tahminleme başarısını arttırmak olmuştur.

Bu çalışmada, EEG işaretlerinden epileptik aktivite tespiti için yapılan farklı deneylerde beş kümeden oluşan veri (A, B, C, D ve E), farklı küme birleşimleri yapılarak çeşitli deneyler için kullanılmıştır. Verinin her kümesinden temsilen birer segment seçilmiş ve Şekil 4.1’de gösterilmiştir.



Şekil 4.1 A, B, C, D ve E veri setlerinden örnek olarak seçilen beş EEG segmenti.

4.2 YAPILAN DENEYLER

Beş kümeden oluşan EEG verisi, literatürde en sık rastlanan epileptik atak tespiti deneyi de dahil olmak üzere birkaç farklı deneyde kullanılmıştır. Bu deneylerde verinin kullanım şekli belirtilen beş küme adını (A, B, C, D ve E) kullanarak oluşturulan sınıf gruplarına göre adlandırılmıştır. Örneğin, epileptik atak için beş kümenin de kullanıldığı ABCD-E deneyinde ABCD sınıfı dört kümeden ve E sınıfı tek kümeden oluşan iki sınıflı bir deneyi temsil eder. Buna benzer şekilde çalışmadaki tüm deneylerin adları genel temsiliyle beraber Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2 Çalışmada yapılan deneylerin sınıf ve küme sayıları.

Deney No	Deney Adı	Sınıf Sayısı	Küme Sayısı
1	ABCD-E	2	5
2	A-E	2	2
3	AB-CD	2	4
4	A-D	2	2

Çalışmada dört adet iki sınıflı deney gerçekleştirilmiştir. Bu deneylerin ilk ikisi epileptik atak aktivitelerinin tespiti, diğer ikisi de ataksız epilepsi hastalığının tespiti üzerine yoğunlaşmıştır. Bu yüzden, deneyler epileptik atak tespiti ve ataksız epilepsi tespiti olmak üzere iki temel başlık altında incelenmiştir.

Epileptik atak aktivitelerinin genellikle gözle görünür şekilde gerçekleşmesi sebebiyle epileptik atak tespiti başlığı altında yapılan ilk iki deneyin temel amacı klinik uygulamalardan ziyade bu çalışmada önerilen yöntemin başarısının farklı çalışmalarla karşılaştırılmasıdır. Klinik bir uygulama ortamında en sık karşılaşılan durum, epilepsi hastalığından şüphelenilen bir bireyin hasta olup olmadığının tespiti. Bu yüzden ataksız epilepsi tespiti başlığı altında yapılan son iki deneyin yüksek oranda başarılması ileride yapılacak klinik uygulamalar açısından diğer deneylere göre daha önemlidir.

4.2.1 Epileptik Atak Tespiti


Literatürde aynı veriyi kullanarak yapılan çalışmalar içerisinde en sık karşılaşılan deneydir. Deney ile klinik çalışmalara katkı sağlamaktan ziyade kullanılan otomatik tespit sistemini test

etmek ve diğer tekniklerle karşılaştırmak amaçlanır. Daha önce yapılmış olan çalışmaların bazıları seçilmiş ve seçilen çalışmalarda kullanılan teknikler bu çalışmada önerilen yöntemle eşit karşılaştırma şartları sağlanarak karşılaştırılmıştır. Bu başlık altında iki farklı deney yapılmıştır.


4.2.1.1 ABCD-E Deneyi

Veriyi oluşturan beş kümenin de kullanıldığı bu deneyde, sağlıklı bireyleri temsilen A ve B kümeleri ile atak geçirmeyen epilepsi hastalarını temsilen C ve D kümeleri bir arada “ataksız” sınıfını oluşturur. Atak geçiren epilepsi hastalarının aktivitelerini içeren E kümesi ise tek başına “ataklı” sınıfını temsil eder. Bu deney, farklı araştırmacılar tarafından yapılan birçok yöntem ile tekrarlanmış ve genel olarak %90’lar seviyesinde yakalanan başarılar ile adeta bir yöntem testi haline gelmiştir. Bu yüzden, sırasıyla EGA ve EFA yöntemleri kullanılarak ayıklaştırılan EEG işaretlerinin olasılık yoğunluklarının ortalamaları hesaplanarak epileptik atak tespitinde kullanılmıştır.

Şekil 4.2’de EGA ve EFA yöntemleriyle ABCD ve E sınıflarının olasılık yoğunluklarını göstermektedir. Şekilde EGA yöntemiyle elde edilen ve farklı sınıfa ait olan olasılık yoğunlukları arasında biçimsel olarak bir farklılık görülmezken maksimum genlik değerinde yarı yarıya değişim söz konusudur. Bununla birlikte, EFA yöntemiyle belirlenen olasılık yoğunluklarında ABCD ve E sınıflarına ait olasılık yoğunlukları EFA yönteminin karakteristiği gereği birbirlerinin tümleyeni şeklindedir. Ayrıca, ABCD sınıfının olasılık yoğunluğunun genel olarak normal dağılıma benzemesi eğri uydurma çalışması için yeterli derecede ön bilgi sağlamıştır.




(a) EGA temelli olasılık yoğunluğu.




(b) EFA temelli olasılık yoğunluğu.

Şekil 4.2 ABCD-E deneyi için zaman boyutunda EGA ve EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.


Farklı bir açıdan bakıldığında EEG işaretlerinin farklı frekans aralıklarının ayrıklaştırmaya dayalı olasılık yoğunluğu sayesinde incelenmesinin de yararlı olabileceği düşünülmüştür. Bu sayede işaretlerin özel bir frekans altbandının anlamlı bilgiler taşıyıp taşımadığı incelenmiştir. Bunun için işaretler altıncı seviyeden ADD ile ayrıştırılmış, elde edilen her frekans aralığının ayrıklaştırmaya dayalı olasılık yoğunluğu hesaplanmış ve bu olasılık değerlerine eğri uydurma işlemi uygulanmıştır. Şekil 4.3 ve 4.4'te altıncı dereceden ADD ile ayrıştırılan EEG işaretlerinin 7 altbandından sırasıyla EGA ve EFA yöntemiyle elde edilen 10 ayrık bölgeye ait olasılık yoğunluğu gösterilmiştir.




(a) D₁ altbandı.




(b) D₂ altbandı.




(c) D_3 altbandı.




(d) D_4 altbandı.



(e) D_5 altbandı.




(f) D_6 altbandı.




(g) A_6 altbandı.


Şekil 4.3 ABCD-E deneyi için zaman-frekans boyutunda EGA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.




(a) D_1 altbandı.




(b) D_2 altbandı.




(c) D_3 altbandı.




(d) D_4 altbandı.



(e) D_5 altbandı.



(f) D_6 altbandı.



(g) A_6 altbandı.

Şekil 4.4 ABCD-E deneyi için zaman-frekans boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.

Şekil 4.3'te görüldüğü gibi, EGA yöntemine dayalı oluşturulan EEG işaretlerinin iki sınıfına ait olasılık yoğunluğu arasında fark oluşmamışken, Şekil 4.4'te görüldüğü gibi, EFA yöntemine dayalı oluşturulan EEG işaretlerinin iki sınıfına ait olasılık yoğunlukları bir birinin yine tümleyeni şeklindedir. Ancak, altbantlarda beklenen önemli bir değişiklik gözlenmemiştir. Buna göre, zaman boyutunda elde edilen ön bilgiler zaman-frekans boyutunda ek bir yenilik sağlamamıştır. Zaman-frekans boyutunda kullanılan dönüşüm hesaplamaları da hesaba katıldığında, ABCD-E deneyi için zaman boyutunda analiz daha az hesaplama karmaşıklığı ve daha düşük maliyete sahip olacaktır.

Zaman boyutunda olasılık yoğunlukları üzerinde yapılan eğri uydurma çalışmasında ABCD sınıfının normal dağılıma benzediği belirtilmişti. Ancak, gerçek olasılık değerlerine tam olarak uyuşmayan değerler ürettiği için fonksiyon üzerinde iyileştirmeler yapılarak (4.1)'deki eşitlik ile gösterilen şeklini almıştır:


$$P_1(i) = P_{\max}^* \exp(-\beta(i - \mu)^2) \quad (4.1)$$

(4.1)'deki $P_{\max}^*$ ifadesi olasılık değerleri arasındaki maksimum değeri ve β ifadesi de ayarlanabilir normalizasyon katsayısını temsil eder. Diğer taraftan E sınıfı için ikinci dereceden parabollerden yola çıkarak benzetilen olasılık yoğunluk fonksiyonu (4.2)'deki eşitlik ile verilmiştir:

$$P_2(i) = P_{\min}^* + \lambda |(i - \mu)^\alpha| \quad (4.2)$$

(4.2)'teki $P_{\min}^*$ ifadesi hesaplanan olasılık değerleri arasındaki minimum değeri ve α ile λ ifadeleri olasılıklar toplamı 1 olacak şekilde ayarlanan normalizasyon katsayılarını gösterir.

Eğri uydurma çalışmasında her bir EEG segmentine ait P^* değerinin uydurulan P_1 veya P_2 fonksiyonlarına benzerliğine göre sınıflandırma yapılmıştır. Ayırıklaştırmaya dayalı olarak hesaplanan olasılık yoğunluğu (P^*) ve her bir sınıfı temsilen uydurulan iki fonksiyonun (P_1 , P_2) grafiksel gösterimleri sayesinde sınıflandırmanın nasıl yapıldığı daha kolay anlaşılacaktır. Birisi ABCD sınıfından ve diğeri E sınıfından olmak üzere örnek olarak seçilen iki segment için olasılık yoğunlukları Şekil 4.5'te gösterilmiştir.



Şekil 4.5 ABCD-E deneyi için iki EEG segmentinin P^* , P_1 ve P_2 grafikleri.

Şekil 4.5 (a)'da görüldüğü gibi, ABCD sınıfından alınan EEG segmentinin olasılık yoğunluğunu gösteren P^* değerlerine en çok benzeyen, diğer bir deyişle ortalama karesel hata değeri en düşük olan eğri P_1 iken Şekil 4.5 (b)'de görünen E sınıfından seçilen EEG segmentinin olasılık yoğunluğu P_2 eğrisine daha çok benzer.

Farklı K değerleri ile yapılan ayırıklaştırma çalışmalarında en yüksek benzeme başarısı %96,75 ile $K=66$ değerinde bulunmuştur. Bu başarıyı sağlayan durum için hesaplanan ortalama karesel hataların ve uydurulan olasılık yoğunluk fonksiyonlarının ayarlanabilir parametrelerinin veri genelindeki ortalama değerleri Çizelge 4.3 ve Çizelge 4.4'te verilmiştir.

Çizelge 4.3 Olasılık yoğunluk fonksiyonlarındaki α , λ ve β parametrelerinin sınıflara göre ortalama değerleri.

Sınıflar	α	λ ($\times 10^{-6}$)	β ($\times 10^{-2}$)
ABCD	2,60	5,3	0,63
E	2,61	5,1	6,60

Çizelge 4.3'te α ve λ parametrelerinin hem ABCD hem de E sınıfı için birbirine çok yakın değerler aldığı gözlenmiştir. Bunun yanında β parametresinin her iki sınıf için aldığı değerlerin arasında büyük farkların olması bu katsayıyı kullanan P_1 fonksiyonunun P_2 'ye göre daha kararsız olduğunu gösterir.

Çizelge 4.4 Ortalama karesel hataların sınıflara göre ortalama değerleri.

Sınıflar	$P_1 (x10^{-4})$	$P_2 (x10^{-4})$
ABCD	6,000	23,000
E	6,881	1,479

Benzer şekilde Çizelge 4.4'te P_1 fonksiyonunun hata ortalama değerlerinin her iki sınıf için birbirine yakın olması yukarıdaki yorumu destekler. P_2 fonksiyonu için sınıflar arasındaki hata ortalamaları farkının büyük olması fonksiyonun kararlı bir karakteristiğe sahip olduğunu gösterir.

Eğri uydurma çalışmasına ek olarak önerilen yaklaşım, EEG segmentlerine üç ayrı ayrıklaştırma yöntemiyle uygulanarak olasılık yoğunlukları elde edilmiş, her bir EEG segmentinin olasılık yoğunluğu ÇKA sinir ağına giriş olarak kullanılarak sınıflandırılmış ve başarı oranları Çizelge 4.5'te verilmiştir.

Çizelge 4.5 Önerilen üç yöntemin ABCD-E deneyindeki başarı oranları.


Yöntemler	K	$B_{ROC}(\%)$
Yöntem 2	19	99,25
Yöntem 3	52	98,88
Yöntem 4	29	98,50

Çizelge 4.5'te gösterildiği gibi bu deneyde EFA ayrıklaştırma yöntemini kullanan Yöntem 2 ile $K=19$ değerinde %99,25 oranında bir başarı elde edilmiştir. Aynı ÇKA sinir ağının girişleri olarak EGA yöntemiyle $K=52$ için elde edilen değerler girildiğinde %98,88 ve K-means yöntemiyle $K=29$ için elde edilen değerler girildiğinde sistem %98,50 başarıya ulaşmıştır.

4.2.1.2 A-E Deneyi

Literatürde epileptik atak tespiti için belirtilen verinin küme sayısı azaltılmış bir şeklini kullanarak yapılan diğer bir deneydir. Sağlıklı bireylerden gözleri açık iken alınan işaretler (A kümesi) pozitif sınıfını ve epilepsi hastalarından atak geçirme anlarında alınan işaretler (E kümesi) ise negatif sınıfını temsil eder. Bu deney, özellikle C ve D kümelerinin aykırı değerlerini içermediği için ABCD-E deneyine göre daha kolay bir sınıflandırma problemidir.

ABCD-E deneyinde olduğu gibi öncelikle eğri uydurma analizi yapılmış ve (4.1) ve (4.2)'teki fonksiyonlar kullanılarak en düşük ortalama karesel hatayı üreten K için başarı belirlenmiştir. EFA yöntemiyle ÇKA sinir ağı kullanmadan $K=247$ için elde edilen en yüksek başarı %99 olmuştur. Bu yüksek başarı A-E deneyinin ABCD-E deneyine göre daha basit olduğunu kanıtlamıştır. Aradaki başarı farkı, epilepsi hastalarının segmentlerini içeren C ve D veri kümelerinin bazı segmentlerinin epileptik atak örüntülerine benzemesi olarak yorumlanabilir. Şekil 4.6'da A ve E sınıflarının EFA yöntemiyle ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları gösterilmektedir.



Şekil 4.6 A-E deneyi için zaman boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.

Şekilden de görüldüğü gibi muntazam şekilli iki fonksiyon birbirine göre zıt yönlüdür. Bu da sınıflandırmayı kolaylaştırmaktadır. Aynı sınıflandırma deneyi ÇKA sinir ağı kullanılarak yapıldığı zaman elde edilen başarı oranları %100 olmuştur. K değerlerine göre sonuçlar aşağıdaki Çizelge 4.6'da verilmiştir.

Çizelge 4.6 Önerilen üç yöntemin A-E deneyindeki başarı oranları.

Yöntemler	K	$B_{ROC}(\%)$
Yöntem 2	3	100,00
Yöntem 3	9	100,00
Yöntem 4	3	100,00

EFA ayrıklaştırma yöntemini kullanan Yöntem 2 ve K-means kümeleme yöntemini kullanan Yöntem 4 sınıflandırma başarısı %100 sonucuna $K=3$ değerinde, EGA ayrıklaştırma

yöntemini kullanan Yöntem 3 ise $K=9$ değerinde ulaşabilmektedir. Hem ABCD-E hem de A-E deneyinde çok yüksek başarı elde edilmesi, önerilen yöntemin epileptik atak tespitinde epileptik aktiviteleri oldukça başarılı şekilde yakaladığını ve bu sayede yüksek sınıflandırma başarısı sağlandığını göstermektedir.


4.2.2 Epilepsi Hastalığının Teşhisi

Klinik çalışmalarda epileptik atağın tespitinden ziyade bir bireyin epilepsi hastası olup olmadığı konusunda ikilemler yaşanır. Bu durumlarda sağlığından şüphe edilen bireyin EEG segmentleri uzman bir hekim tarafından incelenir ve bunun sonucunda hastalığa karar verilir. EEG segmentleri içerisinde önceden tanımlanmış olan epileptik aktivite örüntüleri gözlenemezse bireyin sağlıklı olduğu sonucuna varılır. EEG segmentlerini inceleyen hekimin bu konuda yeterli uzmanlığa sahip olmaması klinik ortamda teşhisi güçleştirir. Bu yüzden, ataksız anlara ait epileptik aktivite örüntülerinin otomatik olarak tespit edilmesi klinik ortamlar açısından en yararlı çalışmalardandır. Çalışmada bu başlık altında da yine iki deney yapılmıştır.


4.2.2.1 AB-CD Deneyi

Bu deneyde, A ve B kümeleri sağlıklı bireylerden, C ve D kümeleri ise epilepsi hastalarından alınan EEG segmentlerinden oluşturulmuştur. Her ne kadar literatürde yapılan birkaç çalışmada kullanılmış olsa da epileptik atak aktivitelerini içermesi ve epilepsi hastalığı teşhisi için yapılan klinik çalışmalarda nadiren rastlanması yüzünden E kümesine bu deneyde yer verilmemiştir. Bu yüzden, sağlıklı bireyleri temsil eden A ve B kümeleri birleştirilerek AB sınıfı ve benzer şekilde epilepsi hastalarını temsil eden C ve D kümeleri birleştirilerek CD sınıfı oluşturulmuştur. Her iki sınıfta eşit sayıda EEG segmenti bulunur.

İlk olarak ABCD-E sınıflandırma deneyinde yapılan olasılık yoğunluk fonksiyonu uydurma çalışmasının bu deney için de yapılması düşünülmüştür. Bu amaç için öncelikle EGA ve EFA ile ayrıklaştırılan EEG işaretlerinin olasılık yoğunlukları incelenerek bu analize uygun olup olmadığı kontrol edilmiştir. Şekil 4.7 EEG işaretlerinin zaman boyutunda EGA ve EFA yöntemleri kullanılarak ayrıklaştırılan segmentlerin olasılık yoğunluk ortalamalarını göstermektedir.




(a) EGA temelli olasılık yoğunluğu.




(b) EFA temelli olasılık yoğunluğu.

Şekil 4.7 AB-CD deneyi için zaman boyutunda EGA ve EFA ile ayrıklaştırılan EEG segmentlerinin olasılık yoğunluk ortalamaları.


Şekil 4.7’de görüldüğü gibi, her iki şekilde de sınıfların yoğunlukları birbirine çok yakındır ve bu yüzden sınıfların ayırt edilebilmesi zor hatta mümkün olmayacağı için zaman-frekans boyutunda da bir analiz yapılmalıdır. Bu amaç için, öncelikle EEG işaretleri altıncı dereceden Db2 dalgacığıyla ayrıştırılmış ve elde edilen altbantlar EGA ve EFA yöntemleriyle ayrıklaştırılarak her bir EEG segmentinin olasılık yoğunluğu elde edilmiştir. Şekil 4.8 ve 4.9 ayrıştırılan EEG işaretlerinin EGA ve EFA yöntemleriyle tüm veri genelinde belirlenen olasılık yoğunluk ortalamalarını göstermektedir.




(a) D₁ altbandı.




(b) D₂ altbandı.




(c) D₃ altbandı.




(d) D₄ altbandı.



(e) D₅ altbandı.




(f) D₆ altbandı.




(g) A₆ altbandı.

Şekil 4.8 AB-CD deneyi için zaman-frekans boyutunda EGA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.


Şekil 4.8’de görüldüğü üzere bazı altbantların bazı ayırık bölgelerinde AB bazen de CD sınıfı daha yüksek yoğunluğa sahiptir. Fakat belirgin bir sınıflandırma farkı ortaya çıkmamıştır. Şekil 4.9’da aynı ayrıklaştırma EFD ile tekrarlanmış ve D₁ altbandı hariç tüm altbantlarda belirgin bir fark gözlenmiştir.




(a) D₁ altbandı.




(b) D₂ altband₁.




(c) D₃ altband₁.




(d) D₄ altband₁.



(e) D₅ altband₁.



(f) D₆ altbandı.



(g) A₆ altbandı.

Şekil 4.9 AB-CD deneyi için zaman-frekans boyutunda EFA ile ayrıklaştırılan EEG segmentlerinin altıncı dereceden dalgacık katsayılarının olasılık yoğunluk ortalamaları.

Şekil 4.8 ve 4.9’da görüldüğü gibi, ADD analizinin gerekliliğini görmek için ayrıklaştırma işlemi örnek olarak $K=10$ değerinde gerçekleştirilmiştir. Elde edilen altbantlara EGA yönteminin uygulanmasıyla elde edilen olasılık yoğunluklarının amaçlanan çalışmaya yararlı olamayacağı, bununla beraber EFA yönteminin önceki deneylerde olduğu gibi bu deneyde de yararlı olabileceği gözlenmiştir. Bu ön çalışmanın ardından yapılan detaylı incelemede EEG işaretleri ADD ile seviye 1’den seviye 6’ya kadar ayrıştırılmıştır. Elde edilen her altbant üzerinde 2’den 300’e kadar her K değeri için ayrıklaştırma yapılarak olasılık yoğunlukları hesaplanmıştır. Olasılık yoğunluklarının (4.1) veya (4.2) fonksiyonlarına benzerliğinin ortalama karesel hataya göre belirlendiği sınıflandırmada elde edilen en yüksek başarı oranı %74.25 seviyesinde kalmıştır. AB-CD deneyinin başarısının ABCD-E deneyine göre düşük olması, ayrıklaştırılan işaretlerin olasılık yoğunluklarının bir fonksiyonla temsil edilebilecek kadar basit olmadığı şeklinde yorumlanabilir.

Eğri uydurma ile başarı elde edilemese bile YSA modelleri yardımıyla birçok karmaşık problemde yüksek başarı sağlanabilir. Diğer deneylerde kullanılan aynı ÇKA sinir ağı yardımıyla AB-CD deneyi tekrarlandığında yüksek sınıflandırma başarısı elde edilmiştir. Bu

deney için K değerinin 2'den 300'e kadar denenmesi hedeflenmiş olsa da önerilen üç yöntemin de ÇKA sinir ağı ile sınıflandırma başarısı küçük K değerlerinde bile %100 ölçülmüştür (Çizelge 4.7). Bu yüzden başarının %100 olduğu anda K değerinin döngüsü sonlandırılmıştır. Çizelge 4.7, AB-CD sınıflandırma deneyinin önerilen üç yöntemin ÇKA sinir ağı ile kullanıldığındaki başarı oranlarını göstermektedir.

Çizelge 4.7 Önerilen üç yöntemin AB-CD deneyindeki başarı oranları.

Yöntemler	K	B _{ROC} (%)
Yöntem 2	5	100,00
Yöntem 3	21	100,00
Yöntem 4	3	100,00

Çizelge 4.7'de gösterildiği gibi, bu deneyde tüm yöntemler %100 başarı oranına ulaşmıştır. Fakat Yöntem 2 ve Yöntem 4 bu başarıyı daha düşük K değerinde sağlamıştır.

4.2.2.2 A-D Deneyi

Epileptik atak tespitinde olduğu gibi epilepsi hastalığının teşhisinde de AB-CD deneyinin farklı bir şeklini yapmak da mümkündür. Sağlıklı bireyleri temsilen A kümesi ve epilepsi hastalarını temsilen D kümesi kullanılarak yapılan deneyde AB-CD deneyine göre sınıfının karakteristik özelliklerini daha yoğun taşıyan veri kümeleri kullanılmıştır. Bu yüzden, AB-CD deneyine göre daha yüksek bir sınıflandırma başarısına sahip olması mümkün olabilir. A-D deneyinde de her iki sınıfa ait eşit sayıda EEG segmenti bulunur.

AB-CD deneyi için yapılan ortalama karesel hata ile benzer fonksiyon tayin etme analizinde elde edilen sonuçlar ışığında bu deneyde de başarının çok yüksek çıkmayacağı aşikardır. Nitekim olasılık yoğunluklarının (4.1) veya (4.2) fonksiyonlarına benzerliğinin ortalama karesel hataya göre belirlendiği sınıflandırmada elde edilen en yüksek başarı oranı %76 olmuştur. AB-CD deneyine göre karakteristiği daha yüksek bir veri üzerinde çalışıldığı için bu deneyde başarı beklentisinin daha yüksek olduğu yukarıda da anlatılmıştı.

Aynı deney için ÇKA sinir ağıyla yapılan sınıflandırmalarda elde edilen başarı oranları ortalama karesel hata ile yapıldığına göre daha yüksek çıkmıştır. Bu sonuçlar Çizelge 4.8'de verilmiştir.

Çizelge 4.8 Önerilen üç yöntemin A-D deneyindeki başarı oranları.

Yöntemler	K	B _{ROC} (%)
Yöntem 2	3	100,00
Yöntem 3	2	100,00
Yöntem 4	3	100,00

Çizelge 4.8’de gösterildiği gibi, tüm yöntemler bu deneyde yine %100 başarı oranına ulaşmıştır. AB-CD deneyindekinin tersine EFA ayırıklaştırmayı kullanan Yöntem 2 ve K-means kümelemeyi kullanan Yöntem 4 daha yüksek *K* değerinde bu sonucu sağlamıştır. Diğer deneylerin aksine bu deneyde EGA ayırıklaştırmayı kullanan Yöntem 3 diğer iki yönteme göre daha yüksek bir başarıya sahip olmuştur. Dolayısıyla bu deneyde kullanılan A ve D sınıflarının aralarındaki farklılıkların EGA ayırıklaştırmaya daha uygun olduğu söylenebilir.

4.3 KARŞILAŞTIRMALI SONUÇLAR

Yukarıda ayrı ayrı anlatılan deneylerin sonuçları bir arada sunulursa başarı daha iyi irdelenebilir. Bu çalışmada önerilen dört yöntemin dört ayrı deney için zaman ve zaman-frekans boyutlarındaki sınıflandırma sonuçları Çizelge 4.9 ve 4.10’da verilmiştir.

Çizelge 4.9 Önerilen yöntemlerin zaman boyutundaki karşılaştırmalı sonuçları.

Yöntemler	ABCD-E (%)	A-E (%)	AB-CD (%)	A-D (%)
Yöntem 1	96,75	99,00	57,50	70,00
Yöntem 2	99,25	100,00	82,50	88,00
Yöntem 3	98,88	100,00	67,25	85,00
Yöntem 4	98,50	100,00	75,50	88,50

Çizelge 4.10 Önerilen yöntemlerin zaman-frekans boyutundaki karşılaştırmalı sonuçları.

Yöntemler	ABCD-E (%)	A-E (%)	AB-CD (%)	A-D (%)
Yöntem 1	97,63	98,00	74,25	76,00
Yöntem 2	100,00	100,00	100,00	100,00
Yöntem 3	99,75	100,00	100,00	100,00
Yöntem 4	100,00	100,00	100,00	100,00

Çizelge 4.9 ve 4.10’da da görüldüğü gibi işaretlerin sınıflandırma başarılarına zaman-frekans boyutunun önemli derecede katkısı bulunmaktadır. Yöntemlerin geçerliliği amacıyla yapılan epileptik atak tespiti deneylerinde problemin kolaylığı açısından zaman-frekans boyutunda işaret analizinin gereksiz olduğu görünse de gerçek klinik ortamlarda uygulanabilir olarak görünen epilepsi tespiti deneylerinde sınıflandırmanın kesinlikle zaman-frekans boyutunda yapılması gerektiği söylenebilir. Ayrıca, önerilen yaklaşımın YSA modeliyle beraber kullanılmasının çok yüksek başarılar sağladığı sonucu da açıkça görülmektedir. Çizelge 4.9 ve 4.10’da elde edilen sonuçların başarısının daha iyi görülmesi amacıyla literatürde aynı veriyi kullanarak yapılmış çalışma sonuçları Çizelge 4.11’de verilmiştir.

Çizelge 4.11 Aynı veriyi kullanan farklı çalışma sonuçları.

Yöntemler	ABCD-E (%)	A-E (%)	Önerilen modelin muadil başarısı (%)
Yöntem A	93.25	-	99.25
Yöntem B	99.01	-	100.00
Yöntem C	-	99.90	100.00
Yöntem D	-	99.60	100.00
Yöntem E	-	94.50	100.00

Önerilen yaklaşımın başarısının aynı veriyi kullanan literatürdeki diğer yöntemlerin başarısına karşı üstünlüğü de çizelgelerde oldukça açıktır. Çizelge 4.9’da ABCD-E deneyi için verilen en düşük başarının bile Çizelge 4.11’de zaman boyutunu kullanan Yöntem A’dan yüksek olduğu, yine zaman boyutunda çok yüksek bir başarıya sahip olan Yöntem C’nin %99.90 ile önerilen yöntemlerin Çizelge 4.11’deki %100 başarılarından geride kaldığı görülmektedir. Ayrıca zaman-frekans boyutundaki çalışmalarda da önerilen yöntemlerin daha iyi başarılarla ulaştığı gözlenmiştir.

Sonuç olarak, önerilen yaklaşımın üç ayrıklaştırma yöntemiyle de yüksek başarı göstermesi yaklaşımın başarısını perçinlemektedir. Önerilen modelin kendi içerisindeki bir değerlendirmede özellikle EFA veya K-means yöntemleriyle ayrıklaştırmanın EGA ayrıklaştırmasına göre daha iyi sonuçlar ortaya koyacağı gösterilmiştir. Bunun sebepleri arasında EFA ve K-means yöntemlerinin işaretleri gruplarken bağlı bir değerlendirme yaparak sınıflandırmaya yardımcı olması sayılabilir. Ayrıca *K* ayrıklaştırma sayısının en uygun değerinin araştırılmadan bir denklemlerle bulunmasının mümkün olup olmadığı incelendiğinde

en yüksek sınıflandırma başarılarını sağlayan K değerlerinin genel olarak bir sistematığa uymadığı gözlenmiştir. Deneylerin içerdiği örnek ve küme sayıları ile yöntemlerin en yüksek başarıya ulaştığı K değerleri Çizelge 4.12’de verilmiştir.

Çizelge 4.12 Deneylerin içerdiği örnek ve küme sayıları ile yöntemlerin bulduğu K değerleri.

Deneyler	Örnek Sayısı	Küme Sayısı	Yöntemlerin Bulduğu K Değerleri		
			Yöntem 2	Yöntem 3	Yöntem 4
ABCD-E	500	5	19	52	29
A-E	200	2	3	9	3
AB-CD	400	4	5	21	3
A-D	200	2	3	2	3

Yöntem 3 ve 4’ün buldukları K değerlerinin küme ve örnek sayıları ile tutarlı olmadığı gözlenirken Yöntem 2’nin küme sayısı ile doğru orantılı sayılabilecek bir ilişkisi gözlenmiştir. Bu ilişki (4.3) ile temsil edilebilir.

$$2^{C-1} - \delta \leq K \leq 2^{C-1} + \delta \quad (4.3)$$

Burada C ifadesi verideki küme sayısını, δ ifadesi de C değerinden küçük bir sapma değerini göstermektedir. Fakat (4.3) ile verilen ilişkinin önceki bölümlerde anlatılan bazı ayrıklaştırma algoritmalarının önerdiği en uygun K değerinin bulunması önerilerine benzemediği rahatlıkla söylenebilir. Buradan her veri ve her sınıflandırma için en uygun K değerinin belirlenmesinde farklı bir denklem bulunabileceği sonucu çıkmaktadır. O halde bir veri üzerinde ayrıklaştırmaya dayalı bir sınıflandırma yönteminin ilk kez uygulanması sırasında elde edilen en yüksek başarının güvenilirliği için en uygun K değerinin araştırılarak bulunması gerekir.

BÖLÜM 5

SONUÇ VE ÖNERİLER

Epilepsi hastalığının teşhisinin veya epileptik atak tespitinin bilgisayar destekli sistemler tarafından yapılabilmesi fikrinin insanlığa ne derece yararlı olacağı aşıkardır. Bunun için yapılmış birçok çalışma olsa da tam güvenilir bir teşhis sistemi henüz yapılamamıştır. Yapay zeka teknikleri üzerine yapılan her yeni çalışmanın gelecekte yapılacağı düşünülen tam güvenilir teşhis sistemlerine katkısı muhakkak olacaktır. Bu çalışmada EEG işaretlerinden epileptik örüntülerin tespiti üzerine üç yeni yöntem önerilmiş ve bu yöntemlerin sınıflandırma başarıları ölçülmüştür. Önerilen yöntemler bir sınıflayıcının önünde EEG işaretlerinin özelliklerini çıkartmak için kullanılmıştır.

Epilepsi hastalığı dünya üzerinde o kadar yaygındır ki epileptik örüntüler içeren EEG işaretlerini bulup üzerinde çalışmalar yapmak çok kolaydır. Fakat yeni bir yapay zeka tekniğinin başarısını daha önce çalışılmış bir veri kümesi üzerinde test etmek gerekmektedir. Bu sayede karşılaştırma yapılarak yeni önerilen yöntemin literatür için konumu netleştirilecektir. Bu yüzden bu çalışmada genel kullanıma açık bir veri kümesi seçilmiştir. Çalışmada ilk amaç epilepsinin teşhisinde tam güvenilir bir sistem fikrine bir adım yaklaşmak ve sınıflandırma başarısı yüksek bir model önermektir. Sınıflandırma işleminde yeterli derecede yüksek başarı sağlayan model olduğu düşünülerek EEG işaretlerinin özelliklerinin çıkartılması aşaması için yeni bir model önerilmiş ve bu model içerisinde üç yöntem analiz edilmiştir. EEG işaretlerinden özellik çıkartmak için önerilmiş birçok teknik bulunmaktadır. Bunların birçoğu bilinen istatistiksel parametreler kullanılarak EEG işaretlerinin özneteliklerini işlemektedir. O kadar çok önerilmiş istatistiksel parametre vardır ki bazı çalışmalar bu parametreler içerisinde en uygun özelliklerin seçimi üzerine odaklanmıştır. Örneğin yirmi parametreden beşini seçmek için bile 1,8 milyon ihtimalden bahsetmek gerekmektedir. Bu çalışmada önerilen yöntem ile EEG işaretlerindeki örüntülerin karakteristik nitelikleri çıkartılacak olan özelliklere yansıtılmakta ve bu sayede başarı sağlanmaktadır.

Önerilen özellik çıkartma yöntemi temel olarak “ayrıklaştırmaya dayalı olasılık yoğunluğu” adıyla tanıtılabilir. Bu yöntem ilk olarak EEG işaretlerini genlik ekseninde gruplamakta daha sonra da işaretler bu grupları içerdikleri oranlara göre olasılık yoğunluğuyla temsil edilmektedir. Bahsedilen ilk aşama için EGA, EFA ve K-means olmak üzere üç ayrıklaştırma yöntemi önerilmiştir. Ayrıklaştırma sonrası olasılık yoğunluğu hesaplanıp bu yoğunluk bir sınıflayıcıya verilmiştir. Bu çalışmada sınıflayıcı olarak sık kullanımı ve başarısından dolayı ÇKA ağı seçilmiştir.

Yapılan deneylerin sonuçlarına göre önerilen yöntemlerin başarı sıralaması EFA, K-means ve EGA şeklinde olmuştur. K-means temelli modelin EGA temelli olana göre daha başarılı olma sebebi rastlantı değişkeni içermesidir. EFA ve EGA yöntemleri ise kararlı yöntemlerdir. Rastlantı değişkeni içermesi sayesinde K-means yöntemi uygun başlangıç durumundan başladığı testlerde EFA yönteminin sonuçlarına yaklaşmıştır. Dolayısıyla yeterli tekrar yapıldığında K-means yönteminin EFA yöntemi gibi grupları eşit frekanslı olarak düzenlemeye çalıştığı söylenebilir. Bu zaten K-means yönteminin bilinen bir özelliğidir. Hem ÇKA ağıyla sınıflandırmada hem de ortalama karesel hata ile eğri uydurma analizinde EFA yönteminin herhangi bir sınıflayıcı ile yüksek başarılar elde edileceği anlaşılmıştır. Bu yüzden çalışmada önerilen modelin özel bir sınıflayıcıya bağımlı olduğu söylenemez. Dolayısıyla ÇKA ağı dışındaki diğer YSA modelleri kullanılarak da yüksek başarılı sınıflandırma çalışmaları yapılabilir. Ayrıca önerilen modelin başka çalışma alanlarında ölçülen zamana bağlı rasgele işaretlerde de başarıyla kullanılabileceği düşünülmektedir.

KAYNAKLAR

- Acır N** (2005) Automated system for detection of epileptiform patterns in EEG by using a modified RBFN classifier. *Expert Systems with Applications*, 29(2): 455–462.
- Adeli H, Zhou Z and Dadmehr N** (2003) Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123: 69–87.
- Alkan A, Köklükaya E and Subaşı A** (2005) Automatic seizure detection in EEG using logistic regression and artificial neural network. *Journal of Neuroscience Methods*, 148: 167–176.
- Altunay S, Telatar Z and Eroğul O** (2010) Epileptic EEG detection using the linear prediction error energy. *Expert Systems with Applications*, 37(8): 5661–5665.
- An A and Cercone N** (1999) Discretization of continuous attributes for learning classification rules. In *Proceedings of the 3rd Pacific-Asia Conference on Methodologies for Knowledge Discovery and Data Mining*, s. 509–514.
- Andrzejak R G, Lehnertz K, Mormann F, Rieke C, 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. *Physical Review E*, 64(6): 061907.
- Aslan K, Bozdemir H, Şahin S, Oğulata S N and Erol R** (2008) A radial basis function neural network model for classification of epilepsy using EEG signals. *The Journal of Medical Systems*, 32: 403–408.
- Bai D and Li Qiu T** (2007) The sample entropy and its application in EEG based epilepsy detection. *Journal of Biomedical Engineering*, 24(1): 200–205.
- Bishop C M** (2007) *Neural Networks for Pattern Recognition*, Oxford University Press.
- Bluman A G** (1992) *Elementary statistics, a step by step approach*, William C Brown Publishers, Dubuque, IA.
- Catlett J** (1991) On changing continuous attributes into ordered discrete attributes. In *Proceedings of the European Working Session on Learning*, s. 164–178.
- Clarke E J and Bratton B A** (2000) Entropy and MDL discretization of continuous variables for bayesian belief networks. *Int. Journal of Intelligence Systems*, 15: 61–92.

KAYNAKLAR (devam ediyor)

- Daubechies I** (1988) Orthonormal bases of compactly supported wavelets, *Communication on Pure and Applied Mathematics*, 41: 909-996.
- Daubechies I** (1992) *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, Philadelphia, Pennsylvania.
- Demuth H, Beale M and Hagan M** (2006) *Neural Network Toolbox for Use with Matlab*. The MathWorks Inc.
- Dougherty J, Kohavi R and Sahami M** (1995) Supervised and unsupervised discretization of continuous features. *In Proceedings of the 12th International Conference on Machine Learning*, s. 194–202.
- Fayyad U M and Irani K B** (1993) Multi-interval discretization of continuous-valued attributes for classification learning. *In Proceedings of the 13th International Joint Conference on Artificial Intelligence*, s. 1022–1027.
- Fenwick P B C, Mitchie P, Dollimore J and Fenton G W** (1969) Application of the autoregressive model to EEG analysis, *Agressologie*, 10: 553-564.
- Fisch B J** (1998) *Spehlmann'ın EEG El Kitabı*. Elsevier Science, Türkçe 6. Baskı, Turgut Yayıncılık, İstanbul.
- Gama J, Torgo L and Soares C** (1998) Dynamic discretization of continuous attributes. *In Proceedings of the 6th Ibero-American Conference on AI*, s. 160–169.
- Gang L and Tong F** (2002) An Unsupervised Discretization Algorithm Based on Mixture Probabilistic Model. *Chinese Journal of Computers*, 25(2): 158–164.
- Gersch W** (1970) Spectral analysis of EEG's by autoregressive spectral decomposition of time series, *Mathematical Bioscience*, 7: 205-222.
- Güler İ and Übeyli E D** (2005) Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *J. of Neuroscience Methods*, 148: 113–121.
- Haykin S** (2009) *Neural Networks and Learning Machines*. 3rd edition, Pearson Prentice Hall, New Jersey.
- Hazarika N, Chen J Z, Tsoi A C and Sergejew A** (1997) Classification of EEG signals using the wavelet transform, *IEEE Proceedings of 13th International Conference on Digital Signal Processing*, s. 89-92.
- Hekim M and Orhan U** (2007) A validity measure for a new hybrid data clustering, *In Proceedings of the International Symposium on Innovations in Intelligent Systems and Applications*, s. 70–74.

KAYNAKLAR (devam ediyor)

- Hekim M and Orhan U** (2011) Bulanık C-means kümeleme yöntemine çıkarımlı yaklaşım, *İTÜ-D Mühendislik Dergisi*, 10(1): 13-19.
- Hernandez E and Weiss G** (1996) *A first course on wavelets*, CRC Press, Boca Raton-New York-London-Washington.
- Hsu C N, Huang H J and Wong T T** (2000) Why discretization works for naive bayesian classifiers. *In Proceedings of the 17th International Conference on Machine Learning*, s. 309–406.
- Hsu C N, Huang H J and Wong T T** (2003) Implications of the dirichlet assumption for discretization of continuous variables in naive bayesian classifiers. *Machine Learning*, 53(3): 235–263.
- Hussain F, Liu H, Tan C L and Dash M** (1999) Discretization: an enabling technique. *Technical Report*, TRC6/99, School of Computing, National University of Singapore.
- Jiang S, Li X, Zheng Q and Wang L** (2009) Approximate equal frequency discretization method. *In Proceedings of the 2009 WRI Global Congress on Intelligent Systems*, s. 514-518.
- Kannathal N, Choo M, Acharya U R and Sadasivan P** (2005) Entropies for detection of epilepsy in EEG. *Computer Methods and Programs in Biomedicine*, 80(3): 187–194.
- Kerber R** (1992) Chimerge: discretization for numeric attributes. *In National Conference on Artificial Intelligence*, s. 123–128.
- Kıymık M K, Güler İ, Dizibüyük A and Akın M** (2005) Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Computers in Biology and Medicine*, 35(7): 603-616.
- Kıymık M K, Subaşı A and Özçalık H R** (2004) Neural networks with periodogram and autoregressive spectral analysis methods in detection of epileptic seizure. *Journal of Medical Systems*, 28(6): 511–522.
- Kohonen T** (1984) *Self-organization and associative memory*, Springer, Berlin.
- Lee C H** (2007) A hellinger-based discretization method for numeric attributes in classification learning. *Knowledge-Based Systems*, 20(4): 419–425.
- Moore D S and McCabe G P** (2003) *Introduction to the Practice of Statistics*. 4th edition, W. H. Freeman and Company, New York.

KAYNAKLAR (devam ediyor)

- Mora L, Fortes I, Morales R and Triguero F** (2000) Dynamic discretization of continuous values from time series. *In Proceedings of the 11th European Conference on Machine Learning*, s. 280–291.
- Morlet J, Arens G, Fourgeau E and Giard D** (1982) Wave propagation and sampling theory - part I: complex signal and scattering in multilayered media, *Geophysics*, 47: 203-221.
- Ocak H** (2009) Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, (36): 2027–2036.
- Orhan U, Hekim M and İbrikçi T** (2008) Gravitational fuzzy clustering. *Lecture Notes in Artificial Intelligence*, 5317: 524–531.
- Orhan U, Hekim M ve Özer M** (2010a) EEG işaretlerinin çok-katmanlı algılayıcı yapay sinir ağı modeli ile sınıflandırılmasında ayırıklaştırma yaklaşımı, *15. Biyomedikal Mühendisliği Ulusal Sempozyumu*, Antalya, 21-24 Nisan.
- Orhan U, Hekim M ve Özer M** (2010b) Kümelemeye dayalı olasılık dağılımı ve yapay sinir ağı kullanarak EEG işaretlerinden epilepsi teşhisi, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, Kayseri, 21-24 Haziran.
- Orhan U, Hekim M and Özer M** (2011a) Epileptic seizure detection using probability distribution based on equal frequency discretization, *Journal of Medical Systems*, (basım aşamasında) DOI: 10.1007/s10916-011-9689-y.
- Orhan U, Hekim M ve Özer M** (2011b) Eşit genişlikli ayırıklaştırma yöntemine dayalı yeni bir özellik çıkartma yaklaşımı ve yapay sinir ağı kullanarak epileptik atak tespiti, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 26(3): 575-580.
- Orhan U, Hekim M and Özer M** (2011c) EEG signals classification using the K-means clustering and a multilayer perceptron neural network model, *Expert Systems with Applications*, vol.38(10): 13475-13481.
- Orhan U, Hekim M, Özer M and Provaznik I** (2011d) Epilepsy diagnosis using probability density functions of EEG signals, *International Symposium on Innovations in Intelligent Systems and Applications*, İstanbul, 15-18 Haziran.
- Öztemel E** (2003) *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul.

KAYNAKLAR (devam ediyor)

- Pazzani M J** (1995) An iterative improvement approach for the discretization of numeric attributes in bayesian classifiers. *In Proceedings of the 1st International Conference on Knowledge Discovery and Data Mining*, s. 228–233.
- Perner P and Trautzsch S** (1998) Multi-interval discretization methods for decision tree learning. *In Proceedings of advances in pattern recognition, joint IAPR international workshops*, Sydney, Australia, s. 475–482.
- Petrosian A, Prokhorov D, Homan R, Dashei R and Wunsch D** (2000) Recurrent neural network based prediction of epileptic seizures in intra and extracranial EEG. *Neurocomputing*, 30: 201–218.
- Pradhan N, Dutt D N** (1994) Data compression by linear prediction for storage and transmission of EEG signals. *International Journal of Bio-Medical Computing*, 35(3): 207-217.
- Pradhan N, Sadasivan P K and Arunodaya G R** (1996) Detection of seizure activity in EEG by an artificial neural network: a preliminary study. *Computers and Biomedical Research*, 29: 303–313.
- Pravin Kumar S, Sriraam N, Benakop P G, and Jinaga B C** (2010) Entropies based detection of epileptic seizures with artificial neural network classifiers. *Expert Systems with Applications*, 37: 3284–3291.
- Proakis J G and Manolakis D** (2007) *Digital Signal Processing*, Prentice Hall, New Jersey.
- Ropper A H and Brown R H** (2006) *Adams and Victor's Principles of Neurology*. Türkçe Baskı: Güneş Kitabevi, İstanbul.
- Samuels M L and Witmer J A** (1999) *Statistics for the life sciences*. 2nd edition, Prentice-Hall, New York.
- Shensa M J** (1992) The discrete wavelet transform: wedding the a trous and Mallat algorithms. *IEEE Transactions on Signal Processing*, 40(10): 2464-2482.
- Srinivasan V, Eswaran C and Sriraam N** (2005) Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems*, 29(6): 647–660.
- Subaşı A** (2005a) Automatic recognition of alertness level from eeg by using neural network and wavelet coefficients. *Expert Systems with Applications*, 28: 701–711.
- Subaşı A** (2005b) Epileptic seizure detection using dynamic wavelet network. *Expert Systems with Applications*, 29: 343–355.

KAYNAKLAR (devam ediyor)

- Subaşı A** (2006) Automatic detection of epileptic seizure using dynamic fuzzy neural networks. *Expert Systems with Applications*, 31: 320–328.
- Subaşı A** (2007a) Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction. *Computers in Biology and Medicine*, 37(2): 227–244.
- Subaşı A** (2007b) EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, 32: 1084–1093.
- Subaşı A and Erçelebi E** (2005) Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, 78: 87–99.
- Swiderski B, Osowski S and Rysz A** (2005) Lyapunov exponent of EEG signal for epileptic seizure characterization. *In Proceedings of the 2005 European Conference on Circuit Theory and Design*, 2(28): 153–156.
- Szilagyi L, Benyo Z and Szilagyi S M** (2002) A new method for epileptic waveform recognition using wavelet decomposition and artificial neural networks, *In Proceeding of the Second Joint EMBS/BMES Conference*, 3: 2025–2026.
- Tay E H and Shen L** (2002) A modified chi2 algorithm for discretization. *IEEE Transactions on Knowledge and Data Engineering*, 14(3): 666–670.
- Tewfik A H, Sinha D and Jorgensen P** (1992) On the optimal choice of a wavelet for signal representation. *IEEE Transactions on Information Theory*, 38(2): 747–765.
- Torgo L and Gama J** (1997) Search-based class discretization. *In Proceedings of the 9th European conference on machine learning*, s. 266–273.
- Tseng S Y, Chen R C, Chong F C and Kuo T S** (1995) Evaluation of parametric methods in EEG signal analysis, *Medical Engineering & Physics*, 17(1):71–78, January 1995.
- Tsoi A C, So D S C and Sergejew A** (1994) Classification of electroencephalogram using artificial neural networks, *Advances in Neural Information Processing Systems*, 6: 1151–1158.
- Übeyli E D** (2008) Analysis of EEG signals by combining eigenvector methods and multi-class support vector machines. *Computers in Biology and Medicine*, 38(1): 14–22.
- Übeyli E D** (2009) Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 19: 297–308.
- Weiss N A** (2002) *Introductory statistics*. 6th edition, Greg Tobin.

KAYNAKLAR (devam ediyor)

- Wennberg A and Isaksson A** (1976) Simulation of nonstationary EEG signals as a means of objective clinical interpretation of EEG, *In Quantitative Analytical Studies in Epilepsy*, Raven Press.
- Xi J and Ouyang W M** (2000) Clustering based algorithm for best discretizing continuous valued attributes. *Mini-micro systems*, 21(10): 1025–1027.
- Yang Y and Webb G I** (2009) Discretization for naive-bayes learning: managing discretization bias and variance. *Machine Learning*, 74(1): 39–74.
- Zarjam P, Mesbah M and Boashash B** (2003) Detection of newborn EEG seizure using optimal features based on discrete wavelet transform. *In Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*, 2: 265-268.
- Zetterberg L** (1969) Estimation of parameters for a linear difference equation with application to EEG analysis, *Mathematical Bioscience*, 5: 227-275.

EK AÇIKLAMALAR A

YAPAY SİNİR AĞLARI

Yapay sinir ağı (YSA) modelleri üzerine yapılan çalışmalar yirminci yüzyılın ortalarında yapay bir nöron üretimiyle başlamış olmasına rağmen günümüzdeki konumunu ancak 1990'lı yıllarda başlayan gelişmelerle sağlamıştır. Artan ilgi sayesinde YSA teknolojisi matematik, fizik ve finans gibi birçok alanda başarılı şekilde uygulanırken insan beyninin çalışma mantığıyla ilgili çalışmalara da ışık tutmuştur. Genel olarak bir YSA modeli birbirlerine bağlanmış nöronlardan oluşan bir görünüme sahiptir. Her nöron kendine gelen bilgiyi bir aktivasyon fonksiyonundan geçirerek bir çıkış değeri üretir ve bu üretilen değeri başka bir nörona ağırlıklı bir bağlantı yardımıyla iletir. Bu yüzden, çıktı olarak üretilen bilgi ilgili nöronun bağlantılarına ve nöronun aktivasyon fonksiyonuna bağlıdır. Problemin karakteristiğine en uygun olan aktivasyon fonksiyonunun seçimi sayesinde ağın veriyi öğrenme süreci hızlı ve etkin olur ve bu sayede de modelin başarısı artar. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olur. İnsanlar yaşadıkları her dönemde öğrenme süreci içerisindeyler. Tecrübe edilen her olay sayesinde sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşturulur. Bu süreç, YSA için de aynı anlama sahiptir. Bir YSA'ya girdi olarak gelen bilginin işlenmesi öğrenme olarak adlandırılır. Öğrenme, özel bir eğitim algoritması yardımıyla girdi ve çıktı değerlerinden oluşan verinin işlenmesi ve nöronlar arasındaki bağlantıların ağırlıklarının tekrarlı iterasyonlar ile düzenlenmesi anlamına gelir. YSA'lar, öğrenme sayesinde değişkenler arasındaki ilişkinin ortaya çıkarılması yeteneğine sahiptirler. İnsan beyninde olduğu gibi bilgisayar ortamında da öğrenme ile her duruma uygun bir sonuç üretilebilir. YSA'lar, geleneksel işlemcilerden tamamıyla farklı bir şekilde çalışır. Bir YSA modeli geleneksel bir işlemciye göre çok daha karmaşıktır ve ayrıca doğrusal olmayan bir yapıya ve paralel işlem yapabilme yeteneğine sahiptir. Bir YSA'da bir problem ile ilgilenen çok sayıda nöron bulunur iken geleneksel işlemciler aynı problemin çözümüne bir işlemci merkezli olarak odaklanır. Bu özellikleriyle bir YSA, günümüzde üretilen en hızlı işlemciye göre çok daha hızlıdır (Haykin 2009). YSA yöntemlerinin detaylarına geçmeden önce bazı terim ve işlemlerden bahsetmekte yarar vardır.

<i>Sınıflandırma:</i>	Veride bulunan belirli sayıdaki gruplar için tanımlı bir fonksiyonun tespit edilmesi işlemidir. Bu fonksiyon tespiti için geliştirilmiş birçok algoritma vardır.
<i>Veri kümesi:</i>	M boyutlu N adet örnek ve her örneğe ait sınıf bilgisinden oluşur. Veri kümesindeki örneklerin hepsi aynı sayıda özellik içerir. Diğer bir ifadeyle örneklerin her biri M boyutlu uzayda bir noktadır.
<i>Eğitim kümesi:</i>	Veri kümesinin sınıflandırma fonksiyonunun tespit edilmesi işleminde kullanılan bir alt kümesidir.
<i>Test kümesi:</i>	Veri kümesinin eğitim kümesine göre tümleyenidir. Üretilmiş olan sınıflandırma fonksiyonunun başarısının ölçümünde kullanılır. Başarı ölçümünde, fonksiyonun daha önce karşılaşmadığı test kümesinin kullanılması çözümün genelleştirilmesi için önemlidir.
<i>Sınıflandırma başarısı:</i>	Bir sınıflandırma fonksiyonunun başarısı, test kümesindeki örneklerin sınıfları ve sınıflandırma fonksiyonunun test kümesi üzerinden ürettiği sınıflar karşılaştırılarak ölçülür.
<i>Çapraz geçerlik:</i>	Tüm veri uzayı için başarının genelleştirilmesinin sağlanmasında kullanılan bir yöntemdir. Bu amaç için veri kümesi eğitim ve test kümelerine ayrılır.
<i>Aşırı eğitim:</i>	Bir sınıflandırma fonksiyonunun eğitim kümesi üzerindeki başarısı yüksek olmasına rağmen test kümesi üzerindeki başarısı düşük ise tespit edilen sınıflandırma fonksiyonunun aşırı eğitildiği veya ezber yaptığı söylenebilir. Bu şekilde aşırı eğitilmiş bir sınıflandırma fonksiyonu genelleştirilmiş bir çözüm üretmez ve bu yüzden de güvenilir sonuçlar veremez.

Genel olarak tahmin etme, sınıflandırma, ilişkilendirme, tanıma, genelleme, teşhis etme, yorumlama ve optimizasyon gibi konularda yaygın bir şekilde kullanıldığı bilinen birçok farklı YSA modeli bulunur. Birbirlerinden farklı özelliklere sahip olsalar da ortak bir düşünceden kaynaklanması sebebiyle tüm YSA'lar paralel bilgi işleme, çözümü genelleştirme yeteneği, doğrusal olmayan fonksiyonlar üretebilme, hem yazılımsal hem de donanımsal olarak uygulanabilme gibi ortak özelliklere sahiptir. Bunun yanında tüm YSA modellerinde ortak olan birçok avantajdan bahsetmek mümkündür. En başta makine öğrenmesi sayesinde olayları öğrenmesi ve benzer olaylara uygun sonuçlar üretmesi sayılabilir. Bilgi saklama işini özel bir depolama yöntemiyle ağırlıkta tutar ve bu yüzden de öğrenilen bilgilerin tekrar

yorumlanmasını imkansız hale getirir. Ağın yapısı itibariyle bilgi ağı yayılmış halde saklanır. YSA modelleri öğrenme işini örneklerle yaptıkları için bir olayla ilgili yorum yapabilmek için gerçekleşmiş örnekler bulmak yeterlidir. Daha önce gerçekleşmemiş bir örnek için sonuç üretebildiği gibi bazı eksik bilgileri de tamamlayabilir. Öğrenme gerçekleştikten sonra giriş olarak gelen verideki eksikliğe rağmen çalışabilir. Eksik bilgiyle çalışmanın başarıyı etkilemesi, eksik olan bilginin YSA içindeki ağırlığıyla ilgilidir. Eksik bilginin ağırlığı küçükse üretilen sonuçlar gerçek sonuçlara çok yakın olabilir. Hata toleransına sahiptir, bu sayede üretilen yakın sonuçları uygun şekilde yuvarlayabilir. YSA modelleri otomatik olarak eğitilebilir ve bu sayede yeni durumlara uyum sağlayabilir (Öztemel 2003).

YSA modellerinin ortak özellikleri ve avantajlarının yanında bazı dezavantajları da mevcuttur. Örneğin sadece nümerik değerlerle çalışabilmesi kategorik veri kümeleri için sınıflandırma yapmayı zorlaştırır. Nümerik olmayan veri kümelerinin sayısal bilgilere dönüştürülmesi problemin ana hatlarını bozmadan yapılması gerektiği için sınıflandırmaya fazladan bir iş yükü getirir. Donanımına bağımlı olması ve özellikle paralel işlem gerektirdiği için paralel işlemcilerle ihtiyaç duyması da önemli bir dezavantajdır.


Kullanılacak ağın yapısına göre paralel işlemciler bile yetersiz kalabilir. Çoğu zaman geleneksel seri işlemciler üzerinde bilgisayar yazılımı ile oluşturulan sanal paralellik ile zaman kayıpları yaşanır. Bazı problemlerde doğru ağ yapısının bulunamaması verimli bir çözüme ulaşmayı güçleştirir hatta bazen imkansız kılar. En uygun ağ yapısının belirlenmesi genellikle deneme yanılma yoluyla yapılır. Deneme yanılma yöntemiyle en uygun ağ yapısının bulunması zaman kayıplarına yol açar bazen günler sürebilir.

Bir diğer sorun da probleme göre belirlenen YSA parametrelerinin tespit edilmesidir. Tamamen uzman görüşler ışığında belirlenen bu parametrelerin yanlış değerlerinin seçimi en uygun çözüme ulaşılmasını engelleyebilir. Ayrıca, eğitim sürecinin ne kadar sürdürüleceğini saptamaya ilişkin herhangi bir yöntem bulunmaz. Bu konuda önerilen yöntemlerin hepsi sadece yüksek olasılıkla genelleştirilmiş bir çözüm sunmaya çalışır. Son olarak, YSA modellerinin ürettiği çözüme yorum getirilememesinden dolayı kara kutu benzetmesi bilinir. Benzer tarzdaki bazı problemleri yüksek başarıyla çözerken bazıları için daha düşük başarı göstermesi çalışma mantığı hakkında yapılan açıklamaları haksız çıkarırken bu yüzden ağların çözümlerine olan güveni sarsar (Öztemel 2003).

Birçok araştırmacı tarafından önerilmiş ve kabul görmüş farklı YSA modelleri bulunur. Verinin özelliklerine bağlı olarak her modelin diğerlerine göre daha başarılı olduğu problemler vardır. Bu yüzden, sınıflandırma problemlerinde başarı çok hassas olarak ele alınacaksa hangi modelin başarılı olduğu bilinmeli veya tüm modeller denenmelidir.

A.1 ÇOK KATMANLI ALGILAYICI AĞLARI

Bilinen birçok YSA modeli olsa da en sık kullanılan modellerden birisi çok katmanlı algılayıcı (ÇKA) ağıdır. Bu modelde kullanılan ağın içerisindeki her nöron türevi alınabilen ve doğrusal olmayan bir aktivasyon fonksiyonu içerir. Şekil 6.1 ÇKA ağlarında kullanılan nöronların genel bir görünümünü göstermektedir.



Şekil A.1 ÇKA ağlarında kullanılan bir nöronun genel yapısı.


Şekil 6.1'deki nöronun 3 adet girişi ve tek çıkışı mevcuttur. Verinin her boyutu ayrı bir ağırlıkla (w_1 , w_2 ve w_3) çarpılarak nörona ulaşır ve girişler nöronda işlem gördükten sonra üretilen değer y_{out} olarak çıkışa verilir. Nöronun içerisinde iki adet işlem birimi bulunur. Bunlardan ilki gelen bilgileri toplayan doğrusal birimdir. Bu birim gelen ağırlıklı bilgileri topladıktan sonra sonucu ikinci birime gönderir. İkinci birime giriş olarak hazırlanan n değeri aşağıdaki eşitlikle ifade edilir (Haykin 2009).

$$n = \sum_k i_k w_k \quad (A.1)$$

İkinci birim, nöronun doğrusal olmayan aktivasyon fonksiyonunu taşıyan birimdir. Gelen toplam değeri (n) aktivasyon fonksiyonundan geçirdikten sonra elde ettiği değeri nöronun çıkışına verir. Nöron çıkışındaki değeri temsil eden y_{out} aşağıdaki eşitlikle hesaplanır.


$$y_{out} = f(n) \quad (A.2)$$

(A.2)'deki f ifadesi kullanılan aktivasyon fonksiyonunu temsil eder. En çok kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant ve basamak fonksiyonudur. Şekil A.2 en çok kullanılan aktivasyon fonksiyonlarının grafiklerini göstermektedir.



Şekil A.2 ÇKA ağlarında en sık kullanılan üç aktivasyon fonksiyonu.

Genellikle her aktivasyon fonksiyonunun diğerlerine göre daha başarılı olduğu problemler vardır. Bir ÇKA ağında giriş ve çıkış katmanlarının haricinde ara veya gizli adıyla anılan katmandan probleme göre gerektiği sayıda kullanılabilir. Katmanlar birbirlerine paralel şekilde sıralanır. Komşu katmanların tüm nöronları birbirlerine bağlıdır. Şekil 6.3 basit bir ÇKA sinir ağını göstermektedir.



Şekil A.3 Bir ÇKA ağının genel görünümü.

Şekil A.3'te görüldüğü gibi, her katman en az bir nöron içerecek şekilde düzenlenmiştir. Ağ gösteriminde nöronlar içerisinde doğrusal olmayan aktivasyon fonksiyonunu temsil eden f notasyonu kullanılmıştır. Giriş vektörleri aslında nöron olmadıkları için girişlerin aktivasyon fonksiyonları gösterilmemiştir ve ara katmana sadece bağlantılar içerir (Haykin 2009).


Eğitim algoritması yardımıyla nöronlar arasındaki bağlantıların ağırlıkları ağın çıkışını verecek şekilde ayarlanır. Veride bulunan çıkış değerleri y ve ağın çıkışı y^* olsun. Bu iki değer arasındaki cebirsel farkına yani $y^* - y$ değerine göre, ağıdaki tüm bağlantıların ağırlıkları eğitim azaltma yöntemi ile güncellenir. YSA modellerinde eğitim algoritması olarak genelde türeve dayalı olan geriye yayılım algoritması kullanılır. Aşağıdaki eşitlikler bir ÇKA ağı üzerinde geri yayılım algoritmasını kullanarak katsayıların güncellenmesini sağlar.

$$\begin{aligned} e &= y^* - y \\ \varepsilon &= \frac{1}{2} e^2 \\ \Delta w &= -\eta \frac{\partial \varepsilon}{\partial w} \end{aligned} \tag{A.3}$$

(A.3)'te üç adet birbirinin devamı niteliğinde denklem verilmiştir. Bunlardan ilki yukarıda da bahsedildiği gibi ağın hesapladığı değer verideki çıkış değerine göre ne kadar saptığını gösteren e değerinin bulunmasını sağlar. İkinci denklemde ise üzerinde hesaplama yapılan nörona ilişkin ani hata enerjisi (ε) değeri hesaplanır. Son olarak ani hata enerjisinin ilgili nörona gelen tüm bağlantı ağırlıklarına mevcut ağırlıkların (w) tersi oranında dağıtılması yardımıyla her ağırlığın güncellenme miktarı (Δw) bulunur. Her ağırlığı güncelleme miktarı bir öğrenme oranı parametresi (η) ile orantılı şekilde küçültülür. Bu işlem verinin her noktası için tekrarlanır ve η parametresi sayesinde bir anlamda bulunan çözümlerin ortalaması hesaplanır.

A.2 ÇAPSAL TABANLI FONKSİYON AĞLARI

Çapsal tabanlı fonksiyon (ÇTF) ağları bir giriş katmanı, çapsal tabanlı aktivasyon fonksiyonu kullanan nöronlara sahip gizli katmanı ve çoğunlukla doğrusal fonksiyonlu nöronlardan oluşan çıkış katmanından oluşur. ÇKA ağlarından en büyük farkı gizli katmandaki nöronların veri uzayında belirlenmiş bir noktayı (prototip) taşımasıdır. Her nöronun bir prototipe sahip olması ve veri noktalarının bu prototipe olan uzaklığının çapsal tabanlı seçilen fonksiyona giriş olarak verilmesi ÇTF ağlarının en önemli özelliğidir (Haykin 2009). Gizli ve çıkış katmanlarında kullanılan nöron modelleri Şekil A.4'te gösterilmektedir.




Şekil A.4 ÇTF ağlarının gizli ve çıkış katmanlarında kullanılan nöron modelleri.

Şekil A.4'te soldaki (a) ilk nöron modeli iki birimden oluşur. İlk birim girişten ağırlıksız olarak gelen veri noktası i ile nöronda saklı prototip c arasındaki vektörel uzaklığı hesaplar:


$$d = \|c - i\| \quad (\text{A.4})$$

(A.4)'te yapılan vektörel uzaklık hesabında genellikle Öklit (Euclidean) uzaklığı kullanılsa da Manhattan veya Chebyshev uzaklıkları da tercih edilen uzaklık hesaplarındandır. Hesaplanan d uzaklık değeri daha sonra ikinci birimde bulunan aktivasyon fonksiyonunun girişi olarak kullanılır. Gizli katmanda bulunan nöronların en sık kullandığı çapsal tabanlı aktivasyon fonksiyonu Şekil A.5'te gösterilmektedir.



Şekil A.5 En sık kullanılan çapsal tabanlı aktivasyon fonksiyonu.


Şekil A.4'te sağda bulunan çıkış katman nöron modeli ise gizli katmandaki nöronların hesapladığı f çıkış değerlerini aynen ÇKA ağındaki gibi bir w ağırlığıyla kabul eder. Her gizli katman nöronundan gelen değer ayrı bir ağırlıkla çarpıldıktan sonra çıkış katmanındaki doğrusal nöron içerisinde toplanır ve sonuç ÇTF ağına y^* çıkışı olarak ifade edilir. Ayrıca ÇTF ağlarında çıkış katmanının doğrusal olması hatanın geri-yayılım ile ağı dağıtılması işlemini hızlandırır. Genellikle çok fazla sayıda nörona sahip tek gizli katman kullanılarak eğitimin kısa sürede sonuca ulaşması sağlanır. Şekil A.6'da üç girişi, tek çıkışı ve tek gizli katmanında beş nöronu bulunan bir ÇTF ağı örneği gösterilmektedir.



Şekil A.6 Üç girişi, tek çıkışı ve tek gizli katmanında 5 nöronu olan bir ÇTF ağı.

A.3 ÖĞRENEN VEKTÖR PARÇALAMA AĞLARI

Öğrenen vektör parçalama (ÖVP) ağları ilk kez Kohonen tarafından 1984 yılında önerilmiştir (Kohonen 1984). ÇTF ağlarında olduğu gibi bu teknikte de gizli katmandaki nöronlar birer noktaya (prototip) sahiptir. Ancak, ÇTF ağından farklı olarak ÖVP ağındaki her bir prototip belirli bir sınıfa sahiptir. Şekil 6.7’de iki sınıflı bir problem için her sınıfta iki nöronu olan bir ÖVP ağı gösterilmektedir.



Şekil A.7 Kohonen katmanında her sınıf için iki nörona sahip iki sınıflı bir ÖVP ağı.

ÖVP ağlarında gizli katman yerine Kohonen katmanı ifadesi kullanılır. ÖVP her seferinde bir işlem yapan çevrimiçi bir algoritmadır. Ana amaç eğitim kümesindeki noktaların kendisine yakın olan aynı sınıflı prototipleri çekmesi ve diğer sınıflı prototipleri itmesine dayanır.

Eğitim süreci tamamlandığında prototipler kendi sınıflarına ait olan eğitim kümesi noktalarına en yakın konumda olur. Şekil A.6'daki ÖVP ağında üç boyutlu x giriş verisinin her bir değerinin dört prototipe (c_1, c_2, c_3 ve c_4) uzaklıkları hesaplanır. Eğer en küçük uzaklık değeri c_1 veya c_2 prototiplerinden birisine aitse y_1 çıkışı aktif ve y_2 çıkışı pasif olur. Eğer en küçük uzaklık değeri c_3 veya c_4 prototiplerinden birisine ait olursa o zaman da y_1 çıkışı pasif ve y_2 çıkışı aktif olur.


Eğitim, Kohonen katmanı için belirlenen nöron sayısı kadar rastgele prototip seçilerek başlar. Daha sonra eğitim kümesindeki her veri noktasının her prototipe uzaklığı hesaplanır ve bu uzaklıklar içerisinde en küçük olanı tespit edilir. Dolayısıyla veri noktasına en yakın prototip belirlenir. Belirlenen prototip ile veri noktası aynı sınıfa sahip ise o prototip belirli bir oranda veri noktasına yaklaştırılır. Aksi durumda prototip veri noktasından uzaklaştırılır (Öztemel 2003). Yaklaştırma veya uzaklaştırma miktarı aşağıdaki (6.5) ile hesaplanır.

$$\Delta c_i = \eta(x_j - c_i) \quad (A.5)$$

(A.5)'te η ifadesi öğrenme oranı, Δc_i ifadesi yaklaştırma-uzaklaştırma miktarı, c_i ifadesi i . prototipi ve x_j ifadesi ise j nci veri noktasını temsil eder. Δc_i değeri yaklaştırma yapılacak prototipe pozitif değerle, uzaklaştırma yapılacak prototipe ise negatif değerle eklenir. ÖVP tipi ağların öğrenme mantığı “destekleyici öğrenme” ve çıktı üretme şekli de “kazanan her şeyi alır” ifadesiyle isimlendirilir (Öztemel 2003).


A.4 DESTEK VEKTÖR MAKİNELERİ

Destek vektör makinesi (DVM) yüksek derece hassas özelliklere sahip iki sınıflı veri kümeleri üzerine geliştirilmiş bir YSA modelidir (Haykin 2009). Temel mantığı iki farklı sınıfa ait noktaları birbirinden ayıran en mükemmel düzlemi bulmaya dayanır. Çok boyutlu bir veri uzayında bulunacak ayırıcı düzleme hiper-düzlem denir. İlk olarak doğrusal bir hiper-düzlem ile ayrılabilen veri kümeleri için önerilmiş fakat daha sonraları doğrusal olmayan hiper-düzlemler bulan DVM'ler geliştirilmiştir. Şekil 6.8'de doğrusal şekilde ayrılabilen bir veri için DVM çözümü gösterilmektedir.



Şekil A.8 Doğrusal olarak ayrılabilen bir veri için DVM çözümü.

Şekil A.8’de gösterilen veri, “+” ve “*” olmak üzere iki ayrı sınıfa ait noktalardan oluşur. DVM yönteminin bulduğu destek vektörleri “o” ile işaretlenmiştir. Burada olduğu gibi veri kümesi doğrusal şekilde ayrılabilir durumda ise aynı sınıfa ait bütün veri noktalarını hiper-düzlemin aynı tarafında bırakmak amaçlanır. Bunun yanında verinin doğrusal olarak bölünememe ihtimali de bulunur. Şekil A.8’de bu durum gösterilmektedir.



Şekil A.9 Doğrusal olarak ayrılamayan bir veri için en uygun DVM çözümü.


Şekil A.9’da olduğu gibi veri kümesi doğrusal şekilde ayrılamıyorsa o zaman DVM ile amaçlanan aynı sınıfa veri noktalarının mümkün olan en büyük kısmını hiper-düzlemin aynı tarafında bırakmaktır. Buna göre asıl problem, en uygun hiper-düzlemin tespitidir. İki sınıflı bir veri doğrusal bir hiper-düzlem yardımıyla sınıflarına ayrılmak isteniyorsa en uygun hiper-düzlemin (A.6) ile bulunması önerilir.

$$w^T x + b = 0 \quad (\text{A.6})$$

(A.6)'daki w ifadesi ayarlanabilen ağırlık vektörlerini, x ifadesi veri giriş vektörlerini ve b ifadesi ise meyil değerini gösterir. Bu denklemin yeterli olmadığı durumlarda veri uzayının daha üst bir uzaya haritalanması gerekir. Haritalama işlemi x veri giriş vektörleri üzerinde özel tanımlı bir fonksiyon yardımıyla yapılmalıdır (Bishop 2007). (A.6)'daki denklem haritalama fonksiyonuyla genişletilirse aşağıdaki eşitlik ortaya çıkar.

$$w^T \phi(x) + b = 0 \quad (\text{A.7})$$

(A.7)'deki $\phi(x)$ ifadesi özel haritalama fonksiyonu temsil eder. Her problemi aynı başarıyla bir üst uzaya taşıyıp çözen bir fonksiyon yoktur. Her haritalama fonksiyonu probleme göre farklı başarılar gösterir (Duda et al. 2001). DVM yönteminde en sık başvurulan üç haritalama fonksiyonunu (polinomal, çapsal tabanlı, çok katmanlı) Şekil A.9'da gösterilen yapay veri kümesi üzerinde denenmiştir. Aşağıdaki Şekil A.10'da da görüldüğü gibi üç yöntemin de veriyi ele alış biçimi yüzünden farklı sonuçlar ortaya çıkmıştır.



Şekil A.10 Doğrusal olmayan üç farklı haritalama fonksiyonuyla DVM çözümleri.

Şekil A.10'da sırasıyla polinomal (a), çapsal tabanlı (b) ve çok katmanlı (c) olmak üzere üç haritalama fonksiyonuyla yapay veri kümesi noktaları bir üst uzaya taşınmış, DVM ile bir hiper-düzlem belirlenmiş ve bu hiper-düzlemin geri haritalama ile çözümü şekle yansıtılmıştır. Geri haritalama işlemi Lagrange çarpanları kullanılarak yapılır. Üst uzayda bulunan hiper-düzlemler her ne kadar doğrusal olsalar da doğrusal olmayan bir haritalama fonksiyonu kullanılması yüzünden geri dönüşümlerde de hiper-düzlemin doğrusallığı bozulur. DVM ile doğrusal olmayan çözümler bu şekilde üretilir.

ÖZGEÇMİŞ

1978 yılında Adana’da doğdu. İlk ve orta öğrenimini Adana’da tamamladıktan sonra 1995 yılında Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği bölümünü kazandı. 2000 yılında özel bir şirkette çalışmak üzere yeniden Adana’ya döndü. 2001 yılında vatani görevini yerine getirmek üzere gittiği Ankara’da program subayı olarak görev yaptı. 2003 yılında Ankara’da özel bir şirket adına tıp bilişimi, web hizmetleri ve uzaktan eğitim konularında çalıştı. 2004 yılı başında Gaziosmanpaşa Üniversitesi Tokat Meslek Yüksekokuluna öğretim görevlisi olarak atandı. 2005 yılında aynı üniversitede Matematik bölümünde yüksek lisansa başladı. 2007 yılı başında yüksek lisansını bitirerek Bilimde Uzman unvanını aldı. Halen Zonguldak Karaelmas Üniversitesi Elektrik-Elektronik Mühendisliği anabilim dalında doktora çalışmasına devam etmektedir.

ADRES BİLGİLERİ

Adres : Gaziosmanpaşa Üniversitesi
Tokat Meslek Yüksekokulu
Taşlıçiftlik, 60250, TOKAT

Telefon : (356) 252 1616 – 2609

E-posta : umutorhan@hotmail.com

Umut ORHAN