

T.C
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FARKLI ZAMAN ÖLÇEKLİ EEG İŞARETLERİNDEN EPİLEPSİNİN
TESPİTİ

Mehmet YILDIRIM

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DİYARBAKIR

Ağustos-2018

T.C. DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ
DİYARBAKIR

Mehmet YILDIRIM tarafından yapılan “FARKLI ZAMAN ÖLÇEKLİ EEG İŞARETLERİNDEN EPİLEPSİNİN TESPİTİ” konulu bu çalışma, jürimiz tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Mehmet AKIN

Üye : Doç. Dr. Necmettin SEZGİN

Üye : Dr.Öğr.Üyesi Abdulnasır YILDIZ

Tez Savunma Sınavı Tarihi: 19/09/2018

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../.../.....

Prof. Dr. Sevtap SÜMER EKER

Enstitü Müdürü

TEŞEKKÜR

Çalışmalarım boyunca değerli bilgi ve deneyimleriyle bana yol gösteren, her türlü destek ile başarıya ulaşmamı sağlayan hocam Dr.Öğr.Üyesi Abdulnasır Yıldız'a, tecrübelerinden faydalandığım Dicle Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü öğretim üyelerine, beni sabır ve özveri ile destekleyen aileme sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
TEŞEKKÜR.....	I
İÇİNDEKİLER.....	II
ÖZET.....	IV
ABSTRACT.....	V
TABLO LİSTESİ.....	VI
ŞEKİL LİSTESİ.....	VII
KISALTMA VE SİMGELER.....	IX
1. GİRİŞ.....	1
1.1. İnsan Beyni.....	2
1.2. Epilepsi.....	4
1.3. Elektroensefalografi (EEG)	8
1.3.1. EEG Dalgaları	9
1.3.2. EEG Elektrotlarının Bağlanması ve İşaretlerinin Ölçülmesi	11
2. KAYNAK ÖZETLERİ.....	15
3. MATERYAL VE METOT.....	29
3.1. Kullanılan Veri Tabanı	29
3.2. Örüntü Tanıma Sistemleri.....	30
3.2.1. Örüntü Nedir.....	30
3.2.2. Örüntü Tanıma	30
3.2.3. Örüntü Tanıma Sistemi.....	31
3.2.3.1. Algılayıcılar ve Ön İşlemler	32
3.2.3.2. Özellik Belirleme.....	32
3.2.3.3. Sınıflandırma.....	33
3.3. Özellik Belirleme Yöntemleri	34
3.3.1. Güç Spektral Yoğunluk Kestirimi (GSY).....	34
3.3.1.1. Periodogram Güç Spektral Yoğunluk Kestirim Metodu	35

3.3.1.2. Bartlett Güç Spektral Yoğunluk Kestirim Metodu.....	36
3.3.1.3. Welch Güç Spektral Yoğunluk Kestirim Metodu	36
3.3.1.4. Pencereleme İşlemi.....	38
3.3.2. Aritmetik Ortalama.....	39
3.4. Sınıflandırma Yöntemleri.....	39
3.4.1. K-En Yakın Komşuluk Algoritması (K-NN)	40
3.4.1.1. K-NN Algoritmasının Parametreleri.....	41
3.3.1.2. K-NN Algoritmasının Çalışma Aşamaları	43
3.4.2. Destek Vektör Makineleri (SVM)	44
3.4.2.1. Doğrusal Destek Vektör Makineleri	46
3.4.2.2. Doğrusal Olmayan Destek Vektör Makineleri.....	52
3.4.3. Aşırı Öğrenme Makinesi (ELM).....	55
3.4.3.1. Çekirdek Aşırı Öğrenme Makinesi (KELM).....	58
4. BULGULAR VE TARTIŞMA.....	61
4.1. Ön İşlem Süreci: EEG İşaretlerinin Bölütlere Ayrılması	62
4.2. EEG İşaret Örüntülerinden Özellik Çıkarma.....	63
4.2.1. Periodogram Güç Spektral Yoğunluk Kestirim Metodu ve Aritmetik Ortalama Kullanarak Özellik Çıkarma	64
4.2.2. Welch Güç Spektral Yoğunluk Kestirim Metodu ve Aritmetik Ortalama Kullanarak Özellik Çıkarma	72
4.3. EEG İşaret Örüntülerini Sınıflandırma.....	80
4.3.1. K-En Yakın Komşuluk Algoritması ile Sınıflandırma	83
4.3.2. Destek Vektör Makinesi ile Sınıflandırma	83
4.3.3. Aşırı Öğrenme Makinesi ile Sınıflandırma	84
4.3.4. Sınıflandırma Performanslarının Karşılaştırılması	85
5. SONUÇ VE ÖNERİLER.....	87
6. KAYNAKLAR.....	87
ÖZGEÇMİŞ.....	95

ÖZET

FARKLI ZAMAN ÖLÇEKLİ EEG İŞARETLERİNDEN EPİLEPSİNİN TESPİTİ

YÜKSEK LİSANS TEZİ

Mehmet YILDIRIM

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2018

Epilepsi dünya nüfusunun yaklaşık olarak %1’inde görülen, insanın yaşam kalitesini olumsuz etkileyen ve kendini sürekli nöbetler ile tekrarlayan yaygın bir hastalıktır. Bu hastalık insan beyninin bir bölümünde yahut tamamında meydana gelen ani, beklenmedik ve düzensiz elektriksel boşalma sonucu ortaya çıkan ciddi bir durumdur. Epilepsinin tespit ve tanısında kullanılan araçlardan biri olan Elektroensefalografi (EEG), epilepsi hakkında bilgi edinmek için önemli bir kaynaktır. Hızı, maliyeti, erişilebilirliği ve kullanım kolaylığından dolayı EEG oldukça yaygın olarak kullanılmaktadır. Bu özelliklerinden dolayı EEG birçok araştırmacının ilgilendiği bir araştırma konusu haline gelmiştir. EEG işaretleri ile epilepsinin otomatik tespiti için birçok örüntü tanıma sistemi geliştirilmiştir.

Burada yapılan çalışmada Bonn Üniversitesi veri tabanından alınan sağlıklı ve epilepsi nöbeti geçiren deneklerden alınan A ve E işaret kümeleri kullanılarak gerçekleştirilen bir otomatik örüntü tanıma sistemi sunulmuştur.

Çalışmada sunulan sistem ön işlem, özellik çıkarım ve sınıflandırma olmak üzere üç aşamadan meydana gelmiştir. Çalışmanın amacı farklı zaman ölçekli EEG işaretlerinden epilepsinin tespitini gerçekleştirmektir. Bu amaç doğrultusunda birinci aşamada, farklı zaman ölçekli EEG işaretleri elde etmek amacı ile 4096 örnek ve 23,6 saniyelik A ve E işaret kümeleri, 128, 256, 512, 1024, 2048, 4096 örnek ve bunlara karşılık gelen 0.7375, 1.475, 2.95, 5.9, 11.8, 23.6 saniyelik bölütlere ayrılmıştır. Bu bölütleme işlemi ile farklı sayılarda, sürelerde ve uzunluklarda A(128), A(256), A(512), A(1024), A(2048), A(4096), E(128), E(256), E(512), E(1024), E(2048) ve E(4096) işaret kümeleri elde edilmiştir. İkinci aşamada Peridogram ve Welch Güç Spektral Yoğunluk (Power Spectral Density (GSY)) kestirim yöntemleri kullanılarak EEG işaretlerinin spektral bilgisine ulaşılmıştır. Çalışmada farklı iki GSY kestirim yönteminin kullanılması ile EEG işaret bölütlerinin farklı spektral yöntemler ile davranış biçimleri incelenmeye çalışılmıştır. GSY kestiriminden sonra elde edilen işaretlerin özelliklerinin veri boyutunu azaltmak için tüm EEG işaretlerine ortalama uygulanmış ve her bir bölüt 16 örnek uzunluğunda özellik vektörü ile temsil edilmiştir. Üçüncü aşamada her bir EEG bölütü için elde edilen ve 16 örnek uzunluğundaki özellik vektörleri 5-katlı çapraz doğrulama yöntemi kullanılarak K-En Yakın Komşu Algoritması (K-Nearest Neighbors Algorithm (K-NN)), Destek Vektör Makinesi (Support Vector Machine (SVM)) ve Aşırı Öğrenme Makinesi (Extreme Learning Machine (ELM)) ile sınıflandırılmıştır. Tüm sınıflandırıcılar için elde edilen başarımların performansları literatürü destekler niteliktedir. Çalışmada birden fazla sınıflandırıcının kullanılması ile farklı EEG işaret bölütlerinin farklı GSY kestirimleri ile elde edilen özellik vektörlerinin farklı sınıflandırıcılardaki performansları incelenmeye çalışılmıştır.

Çalışmanın sonunda sonuçlar irdelenmiş ve gelecekte yapılabilecek çalışmalara ışık tutması açısından önerilere yer verilmiştir.

Anahtar Kelimeler: Elektroensefalogram, Peridogram, Welch, Güç Spektral Yoğunluk, Sınıflandırma, K-En Yakın Komşu Algoritması, Destek Vektör Makinesi, Aşırı Öğrenme Makinesi.

ABSTRACT

DETERMINATION OF EPILEPSY FROM DIFFERENT TIME SCALE EEG SIGNS

MsC THESIS

Mehmet YILDIRIM

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2018

Epilepsy is a common disorder in approximately 1% of the world population, which adversely affects the quality of life of people and repeats itself with continuous bouts. This disorder is a serious condition that occurs in some or all of the human brain, sudden, unexpected and irregular electrical discharge server. Electroencephalography (EEG), one of the instruments used in the detection and diagnosis of epilepsy, is an important source for information about epilepsy. EEG is widely used because of its speed, cost, accessibility and ease of use. Because of these features, EEG has become a research topic that many researchers are interested in. Many pattern recognition systems have been developed for automatic detection of epilepsy with EEG signs.

In this study, an automated pattern recognition system is presented using A and E sign sets obtained from healthy and epileptic seizure subjects taken from Bonn University database.

The pretreatment system presented in this study, has three stages, namely feature extraction and classification occurs. The aim of this study is to realize the different time-scale detection of EEG signals from epilepsy. For this purpose, in the first stage, 4096 samples and 23.6 seconds A and E sign sets, 128, 256, 512, 1024, 2048, 4096 samples and corresponding 0.7375, 1.475, 2.95, in order to obtain different time-scale EEG signals, 5.9 divided into 11.8, 23.6 second segments. A(128), A(256), A(512), A(1024), A(2048), A(4096), E(128), E(256), E(512), E(1024), E(2048) and E(4096) were obtained. In the second stage, spectral information of EEG signals have been reached by using Peridogram and Welch Power Spectral Density (PSD) estimation methods. In this study, different spectral methods and behavior patterns of EEG signaling segments were tried to be investigated. After the PSD estimation, the average of all the EEG signals was applied to reduce the data size of the marks obtained and each segment was represented by the feature vector at 16 sample lengths. The third step obtained for each EEG segments and K-using the feature vectors of 5-fold cross-validation method in 16 sample length Nearest Neighbor Algorithm (K-NN), Support Vector Machine (SVM) and Excessive Learning Machine (ELM) are classified. Performance achievements for all classifiers support the literature. Performance of different classifiers, the EEG signal segments of different feature vectors obtained by using a plurality of classifiers with different PSD estimates study were studied.

Consequently, the results are examined and some suggestions in terms of work that can be done to shed light on the future.

Keywords: Electroencephalogram, Peridogram, Welch, Power Spectral Density, Classification, K- Nearest Neighbors Algorithm, Support Vector Machine, Extreme Learning Machine

TABLO LİSTESİ

<u>Tablo No</u>		<u>Sayfa</u>
Tablo 3.1.	Yeni veri örneğinin $K=3$ için en 3 komşusu ve ait oldukları sınıflar	44
Tablo 3.2.	SVM için yaygın olarak kullanılan çekirdek fonksiyonları	54
Tablo 3.3.	ELM için yaygın olarak kullanılan çekirdek fonksiyonları	59
Tablo 4.1.	Ön işlem sonucunda elde edilen EEG işaret kümelerinin yapısı	63
Tablo 4.2.	PGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi	71
Tablo 4.3.	WGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi	79
Tablo 4.4.	36 farklı örüntü sınıflandırma yaklaşımında kullanılan işaret kümesi, özellik çıkarım yöntemi ve sınıflandırıcı yöntemine göre gösterimleri	81
Tablo 4.5.	Konfüzyon matrisi	82
Tablo 4.6.	K-NN ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları	83
Tablo 4.7.	SVM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları	84
Tablo 4.8.	ELM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları	85
Tablo 4.9.	K-NN, SVM, ELM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre doğruluk test performans sonuçlarının karşılaştırılması	85

ŞEKİL LİSTESİ

<u>Sekil No</u>	<u>Sayfa</u>
Şekil 1.1. İnsan beyni	2
Şekil 1.2. EEG dalgaları	11
Şekil 1.3. Beyin-bilgisayar arabirimi	12
Şekil 1.4. Uluslararası 10-20 sistemine göre elektrot yerleştirme	13
Şekil 3.1. A, B, C, D ve E kümelerine ait EEG işaretleri	30
Şekil 3.2. Örüntü tanıma sistemi blok diyagramı	31
Şekil 3.3. Pencere fonksiyonları	38
Şekil 3.4. $K=3$ için K-NN sınıflandırma süreci	40
Şekil 3.5. Eğitim verisinin bilinen sınıflara atanması	43
Şekil 3.6. Uzaklıkların hesaplanması	43
Şekil 3.7. Yeni veri örneğinin sınıflandırılması	44
Şekil 3.8. İki veri sınıfını ayıran hiperdüzlemler	45
Şekil 3.9. Doğrusal olarak ayrılabilen veriler için SVM	47
Şekil 3.10. Doğrusal olarak ayrılmayan veriler için SVM	51
Şekil 3.11. Giriş uzayındaki örneklerin yüksek boyutlu özellik uzayına taşınması	53
Şekil 3.12. Tek giriş katmanlı ileri beslemeli yapay sinir ağı	56
Şekil 4.1. EEG işaretlerinden epilepsi nöbetini tespit eden otomatik örüntü tanıma sistemi	62
Şekil 4.2. A(128), A(256) , A(512) , A(1024) , A(2048) , A(4096) , E(128) , E(256) , E(512) , E(1024) , E(2048) ve E(4096) işaret kümelerinden örnek bir EEG işaretinin gösterimi	63
Şekil 4.3. EEG işaretleri için PGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı	64
Şekil 4.4. A(128), E(128) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	67
Şekil 4.5. A(128), E(128) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	67

Şekil 4.6.	A(256) , E(256) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	68
Şekil 4.7.	A(256), E(256) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	68
Şekil 4.8.	A(512) , E(512) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	68
Şekil 4.9.	A(512), E(512) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	69
Şekil 4.10.	A(1024) , E(1024) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	69
Şekil 4.11.	A(1024), E(1024) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	69
Şekil 4.12.	A(2048) , E(2048) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	70
Şekil 4.13.	A(2048), E(2048) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	70
Şekil 4.14.	A(4096) , E(4096) işaret kümelerinden örnek bir EEG işareti ve PGSY'si	70
Şekil 4.15.	A(4096), E(4096) işaret kümelerinden PGSY-AO ile çıkarılan özellikler	71
Şekil 4.16.	EEG işaretleri için WGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı	72
Şekil 4.17.	A(128) , E(128) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	75
Şekil 4.18.	A(128), E(128) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	75
Şekil 4.19.	A(256) , E(256) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	76
Şekil 4.20.	A(256), E(256) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	76
Şekil 4.21.	A(512) , E(512) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	76
Şekil 4.22.	A(512), E(512) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	77
Şekil 4.23.	A(1024) , E(1024) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	77
Şekil 4.24.	A(1024), E(1024) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	77
Şekil 4.25.	A(2048) , E(2048) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	78
Şekil 4.26.	A(2048), E(2048) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	78
Şekil 4.27.	A(4096) , E(4096) işaret kümelerinden örnek bir EEG işareti ve WGSY'si	78
Şekil 4.28.	A(4096), E(4096) işaret kümelerinden WGSY-AO ile çıkarılan özellikler	79

KISALTMA VE SİMGELER

EEG	: Elektroensefalogram (Electroencephalogram)
GSY	: Güç Spektral Yoğunluk (Power Spectral Density)
K-NN	: K-En Yakın Komşu Algoritması (K-Nearest Neighbors Algorithm)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
ELM	: Aşırı Öğrenme Makinesi (Extreme Learning Machine)
MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
CTI	: Bilgisayar Destekli Tomografik Görüntüleme (Computed Tomography Imaging)
WPD	: Dalgacık Paket Ayrışımı (Wavelet Packet Decomposition)
ApEn	: Yaklaşık Entropi (Approximate Entropy)
SampEn	: Örnek Entropisi (Sample Entropy)
RE	: Reyni Entropisi (Reyni's Entropy)
NB	: Naive Bayes (Naive Bayes)
RBF	: Radyal Tabanlı Fonksiyon (Radial Basis Function)
NNGE	: Yuvalanmamış Genelleştirilmiş Örnekler (Non-Nested Generalized Exemplars)
BFDT	: En İyi İlk Karar Ağacı (Best First Decision Tree)
FAWT	: Esnek Analitik Dalgacık Dönüşümü (Flexible Analytic Wavelet Transform)
CC	: Çapraz Enteropi (Cross Correntropy)
SE	: SURE Entropisi (SURE Entropy)
LEE	: Log Enerji Entropisi (Log Energy Entropy, (LEE))
LS-SVM	: En Küçük Kareler Destek Vektör Makinesi (Least Squares Support Vector Machine)
TQWT	: Ayarlanabilir Q Dalgacık Dönüşümü (Tunable-Q Wavelet Transform)
FuzzyEn	: Bulanık Entropi (Fuzzy Entropy)
NCA	: Komşuluk Bileşen Analizi (Neighborhood Component Analysis)
RF	: Rasgele Orman (Random Forest)
AdaBoost	: Adaptif Güçlendirme (Adaptive Boosting)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
LDC	: Lineer Diskriminant Sınıflandırıcı (Linear Discriminant Classifier)
QDC	: Kuadratik Diskriminant Sınıflandırıcı (Quadratic Discriminant Classifier)
UDC	: Korelasyonlu Normal Dansite Bazlı Sınıflandırıcı (Uncorrelated Normal Density-Based Classifier)
POLYC	: Polinom Sınıflandırıcı (Polynomial Classifier)

DT	: Karar Ağacı (Decision Tree)
PARZENC	: Parzen Sınıflandırıcı (Parzen Classifier)
RDSTFT	: Rasyonel Ayırık Kısa Zamanlı Fourier Dönüşümü (Rational Discrete Short Time Fourier Transform)
LGBP	: Yerel Gabor İkili Modelleri (Local Gabor Binary Patterns)
LR	: Lojistik regresyon (Logistic Regression)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ANFIS	: Uyarlamalı Sinirsel Bulanık Çıkarım Sistemleri (Adaptive Neuro-Fuzzy Inference Systems)
EN	: Elman Ağı (Elman Network)
FBNN	: İleri Beslemeli Geri Yayılım Sinir Ağı (Feedforward Back-Propagation Neural Network)
ANFN	: Adaptif Sinirsel Bulanık Ağ (Adaptive Neural Fuzzy Network)
PNN	: Olasılıksal Sinir Ağı (Probabilistic Neural Network)
MLPNN	: Çok Katmanlı Algılayıcı Yapay Sinir Ağı (Multilayer Perceptron Neural Network)
ME	: Uzman Karışımları (Mixture of Experts)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
AIRS-FRA	: Yapay İmmun-Tanırma Sistemi (AIRS) ile Bulanık Kaynak Ayırma (Artificial Immune-Recognition System with Fuzzy Resource Allocation)
SDA	: Vekil Veri Analizi (Surrogate Data Analysis)
REN	: Tekrarlayan Elman Ağı (Recurrent Elman Network)
RBN	: Radyal Tabanlı Ağ (Radial Basis Network)
LDA	: Lineer Diskriminant Analiz (Linear Discriminant Analysis)
LC	: Lineer Sınıflandırıcı (Linear Classifier)
MLP	: Çok Katmanlı Algılayıcı (Multilayer Perceptron)
1D-LBP	: Tek Boyutlu Yerel İkili Desen (One Dimensional Local Binary Pattern)
BayesNet	: Bayes Ağı (Bayesian Network)
FT	: Fonksiyonel Ağaç (Functional Tree)
NEWFM	: Ağırlıklandırılmış Bulanık Üyelik Yapay Sinir Ağı (Neural Network with Weighted Fuzzy Membership)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
AR-MLPNN	: Özbağımlı Model-Çok Katmanlı Algılayıcı Yapay Sinir Ağı (Autoregressive Model-Multilayer Perceptron Neural Network)

FFT-QDA	: Hızlı Fourier Dönüşümü -Kuadratik Diskriminant Analizi (Fast Fourier Transform-Quadratic Discriminant Analysis)
M-ELM	: Çarpma Aşırı Öğrenme Makinesi (Multiplicative Extreme Learning Machine)
BP	: Geri Yayılım (Backpropagation)
EMD	: Ampirik Mod Ayırma (Empirical Mode Decomposition)
IMF	: İç Mod FonksiyonU (Intrinsic Mode Function)
DTCWT	: Çift-Ağaç Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transformation)
CVANN	: Karmaşık Değerli Sinir Ağı (Complex-Valued Neural Network)
LMD	: Yerel Ortalama Ayırma (Local Mean Decomposition)
BPNN	: Geri Yayılımlı Sinir Ağı (Back Propagation Neural Network)
GA	: Genetik Algoritma (Genetic Algorithm)
HE	: Hurst Üssü (Hurst Exponent)
HFD	: Higuchi Fraktal Boyutu (Higuchi Fractal Dimension)
DT-CWT	: Çift-Ağaç Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transform)
PE	: Permütasyon Entropisi (Permutation Entropy)
RFC	: Rasgele Orman Sınıflandırıcısı (Random Forest Classifier)
LNDP	: Lokal Komşu Tanımlayıcı Desen (Local Neighbor Descriptive Pattern)
1D-LGP	: Tek Boyutlu Yerel Gradyan Paterni (One-Dimensional Local Gradient Pattern)
ATFFWT	: Analitik Zaman-Frekans Esnek Dalgacık Dönüşümü (Analytic Time-Frequency Flexible Wavelet Transform)
L1-PRR	: L1-Cezalandırılmış Robust Regresyon (L1-Penalized Robust Regression)
CNN	: Konvolüsyon Nöral Ağ (Convolutional Neural Network)
fDistEn	: Bulanık Dağılım Entropisi (Fuzzy Distribution Entropy)
AR	: Özbağlımlı (Autoregressive)
MA	: Yürüyen Ortalamalı (Moving Average)
ARMA	: Özbağlımlı Yürüyen Ortalama (Autoregressive Moving Average)
MUSIC	: Çoklu Sinyal Sınıflaması (Multiple Signal Classification)
EV	: Özvektör (Eigenvektör)
AO	: Aritmetik Ortalama (Arithmetic Mean)
KELM	: Çekirdek Aşırı Öğrenme Makinesi (Kernel Extreme Learning Machine)
PGSY	: Periodogram Güç Spektral Yoğunluk (Periodogram Power Spectral Density)
WGSY	: Welch Güç Spektral Yoğunluk (Welch Power Spectral Density)
GP	: Gerçek Pozitif (True Positive)

GN	: Gerçek Negatif (True Negative)
YP	: Yanlış Pozitif (False Positive)
YN	: Yanlış Negatif (False Negative)
K	: En Yakın Komşuların Sayısı (Number of Nearest Neighbors)
C	: Düzenleme Parametresi (Regularization Parameter)
σ	: Sigma (Sigma)
w_i	: Ağırlıklar (Weights)
x_i	: Girişler (Inputs)
y_i	: Çıkışlar (Outputs)
θ	: Teta Dalgası (Theta Wave)
α	: Alfa Dalgası (Alpha Wave)
β	: Beta Dalgası (Beta Wave)
γ	: Gama Dalgası (Gamma Wave)
δ	: Delta Dalgası (Delta Wave)

1. GİRİŞ


Epilepsi, halk arasında sara veya tutarik hastalığı olarak bilinen kendini çoğunlukla ani ve tekrarlayan nöbetler ile gösteren kişinin hayat standartlarını oldukça ciddi bir şekilde olumsuz etkileyen oldukça yaygın nörolojik bir hastalıktır. Bu hastalık bio-elektriksel bir ağ yapısı ile çalışan beynin bir bölümünde yahut tamamında meydana gelen ani ve beklenmedik elektriksel aktivitenin oluşmasıyla ortaya çıkan klinik bir durumdur. Dünya nüfusunun yaklaşık olarak %1'ini etkileyen çoğunlukla çocukluk ve yaşlılık döneminde yaygın olarak görülen epilepsinin tespiti, tahmini, tanısı ve tedavisi büyük önem arz etmektedir. Epilepsi hastalığının kesin teşhisinin yapılabilmesi için Manyetik Rezonans Görüntüleme (Magnetic Resonance İmaging (MRI)), Bilgisayar Destekli Tomografik Görüntüleme (Computed Tomography Imaging (CTI)) ve Elektroensefalografi (Electroencephalography (EEG)) gibi tıbbi görüntüleme cihazlarıyla hastanın takibi yapılmaktadır. İnsan beyin hücrelerinde meydana gelen biyolojik kaynaklı elektriksel aktivitenin grafiksel bir gösterimi olan EEG maliyeti, kullanım kolaylığı, süresi ve bulunabilirliği açısından özellikle tercih edilmektedir.

Bu sebeple bu tez çalışmasında EEG işaretleri kullanılmış ve farklı zaman ölçeklerinde epilepsi nöbet tespiti yapan otomatik örüntü tanıma sistemi sunulmuştur. Sunulan tez çalışması beş bölümden oluşmaktadır. Birinci bölümde tez çalışmasının daha iyi anlaşılması ve bir bilgi altyapısı oluşması için insan beyni, epilepsi ve EEG hakkında temel bilgiler verilmiştir. İkinci bölümde literatürde yapılan çalışmalara değinilmiştir. Üçüncü bölümde tezde kullanılan veri seti ve bu çalışmada sunulan otomatik örüntü tanıma sistemlerinin anlaşılabilir hale gelmesi için bir örüntü tanıma sistemi ve bu sistemi oluşturan öğeler üzerinde durulmuştur. Bu bölümün ileriki aşamalarında bu çalışmada sunulan otomatik örüntü tanıma sistemlerinin özellik çıkarım yöntemleri olan Periodogram, Welch Güç Spektral Yoğunluk (Power Spectral Density (GSY)) kestirim metotları ve sınıflandırmada kullanılan K-En Yakın Komşuluk Algoritması (K-Nearest Neighbor Algorithm (K-NN)), Destek Vektör Makineleri (Support Vector Machine (SVM)), Aşırı Öğrenme Makinesi (Extreme Learning Machine (ELM)) sınıflandırıcıları hakkında teorik bilgiler verilmiştir. Dördüncü bölümde daha önce teorik bilgileri verilen tekniklere dayalı olarak sunulan örüntü tanıma sistemleri ve uygulamaları verilmiştir. Beşinci ve son bölümde ise uygulama

sonuçları irdelenmiş ve gelecekte yapılabilecek çalışmalara bir veri tabanı oluşturması açısından önerilere yer verilmiştir.

1.1. İnsan Beyni

İnsan beyni kafatası boşluğunda yer alan yaklaşık olarak 100 milyar sinir hücresi (nöron), trilyonlarca destek hücrelerinden (glia) oluşan ortalama 1300-1400 gram ağırlığında su, yağ, protein, şeker ve tuzdan meydana gelen yüzeyi girintili çıkıntılı olan merkezi sinir sisteminin en önemli organıdır. İnsan beyni temelde üç ana bölümden oluşmaktadır. Bu bölümler beyin sapı, beyincik (serebellum) ve beyindir (serebrum). [(Özmen 2010), (Özbeyaz 2010)].



Şekil 1.1. İnsan beyni

Beyin sapı beyinciğin önünde yar alan, omurilik ile beyin arasındaki bağlantıyı sağlayan, yaşamla ilgili bir çok fonksiyonu lokalize eden beynin aşağıya doğru uzantısıdır. Küçük bir yapıya sahip olmasına rağmen beyin ile vücut arasında bulunan tüm sinirler ve fonksiyonların üzerinde oldukça etkilidir. Beyin sapı birbirinden farklı görevleri olan üç bölümden oluşmaktadır. Bu bölümler orta beyin (mezensefalon), omurilik soğanı (medulla oblangata) ve köprüdür (pons). Beyin sapı merkezi sinir sistemini düzenlemek, bilincin oluşmasını sağlamak, uyku düzenini sağlamak, vücuttan beyne, beyinden vücuda giden sinyalleri iletmek için köprü vazifesi görmek, kalp atışı,

kan basıncı, terleme, vücut ısısının kontrol, yutma, sindirim, solunum, görme ve işitme reflekslerini sağlamak vb. önemli görevleri yerine getirmektedir (Uşaklı 2006).

Beyincik kafanın arkasında beynin arka (oksipital) lobunun altında yer alan dış kısmı gri maddeden, iç kısmı ise beyaz maddeden oluşan organdır. Bu organ hareket düzenleme ve denge merkezi olup, istemli ve istem dışı kas hareketlerinin eş güdümlü faaliyetlerinden sorumludur. Bununla beraber kas vücut beyin koordinasyonu, denge, algılama mesajlarını bütünleştirir. Salgıladığı bazı maddeler ile omurilik ve omurilik soğanının korunmasını sağlar. Beyincik tekrarlayan ince, hızlı el ve göz hareketlerinin yapılmasında önemli katkı sağlamaktadır [(Sezer 2008), (Uşaklı 2006)].

Beyin birbirine bağlı sağ ve sol olarak isimlendirilen iki ana yarım küreden (hemisfer) oluşan merkezi sinir sisteminin en önemli organıdır. Günlük hayatımızda nefes almadan yürümeye, konuşmadan duymaya, hareket etmeden, hafızaya kadar hemen hemen tüm faaliyetlerimiz beynin denetimindedir. Beyin olmadan insanın herhangi bir faaliyet gerçekleştirmesi düşünülemez. Beynin her yarım küresi yapısal olarak kendi içinde dört loba ayrılır ve bu loblar çift taraflı bulunur [(Özdemir 2012), (Özbeyaz 2010)].

a) Ön (Frontal) Lob: İstemli hareketler, zeka, hafıza, hayal, duygu, kişilik, yaratıcılık, muhakeme, bilinçli düşünmeyi sağlayan lobdur. Zarar görmesi durumunda problem çözme yeteneğinde azalma veya artma, konuşma alışkanlığında değişiklik, risk alma yeteneğinde bozulma, tat veya koku alma yeteneğinde azalma ya da hiç alamama, zihin esnekliğinin yitilmesi, dikkat dağılmasına karşı aşırı esneklik, ruh hali değişikliği olabilir (Özdemir 2012).

b) Yan (Parietal) Lob: Çeşitli duyu organlarından gelen bilgileri birleştirmede önemli rol oynar. Ayrıca nesnelerin kullanılması ve bazı mekansal görüş işlemlerinde parietal lobun bazı bölümleri önemli rol alır. Konuşma bozukluğu veya konuşulanı anlamama, nesnelerin anormal olarak algılanması, görsel dikkat bozulması olabilir (Özdemir 2012).

c) Arka (Osipital) Lob: Görsel uyarıcılardan gelen bilgilerin alınması, yorumlanması yani görme duyusu ilgili bilgilerin işlendiği lobdur. Hafif zarar görmesi durumunda halüsinasyonlara ve görme bozukluklarına sebep olabilir (Özdemir 2012).

d) Şakak (Temporal) Lob: Bu lob beynin iki tarafında kulak hizasında yer alır. Ses ve kokunun algılanması, aynı zamanda da yüzler, mekânlar gibi karmaşık

uyaranların işlenmesi bu lob tarafından sağlanır. Zarar görmesi durumunda ses ve görsel içeriği hatırlamama, kelimeleri tanıma ve hatırlama zorluğu, görsel içeriği tanıma ve seslerin tonlamasında zorluklara sebep olabilir (Özdemir 2012).

1.2. Epilepsi

Halk arasında sara veya tutarık hastalığı olarak bilinen epilepsi beyinde bir grup hücrenin ani, beklenmedik ve geçici elektriksel deşarjlara yol açması, bunun sonucunda klinik olarak bilinç, psişik, motor, duysal ve otonom tabiatta belirtilerin ortaya çıkması halidir [(Albayrak 2008), (Yeni ve Karaağaç 2005)].

Epilepsi kelimesi Yunanca epilambenein kelimesinden türetilmiş olup nöbete yakalanmak anlamına gelmektedir. Başka bir şekilde ifade etmek gerekirse nöbet veya kasılma hastalığı demektir. Bununla beraber farklı şekillerde kasılma ve nöbet hastalıkları olduğu için epilepsi olarak adlandırılması daha yerinde bir kullanım olacaktır. (Kumdereli 2012)

Epilepsi beyin kuvvetli ve ani elektriksel boşalımı sonucu oluşan kısa süreli ve geçici bir durumdur. Bayılma, morarma, sıçrama, çarpınma, anlamsız bakma, dalma vb. şekilde ortaya çıkan rahatsızlıktır. (Bingöl ve ark. 2007).

Epilepsi çeşitli özellikleri sebebiyle eskiden beri insanlığın dikkatini çekmiştir. Belirtiler bilimsel olarak açıklanamadığı için doğaüstü etkilere bağlanmış, bazen kutsal bir hastalık bazen de şeytani ve kaçınılması gereken bir durum gözüyle bakılmıştır. Bu sebeple hastalığın tedavisinde sihir, büyü, okutma, kurşun dökme gibi yöntemler uygulanmış çoğunlukla da hasta toplum dışına itilmiş, hastalık adeta tıp dışı kalmıştır. Bu anlayış biçimi ilkel topluluklarda ve gelişmekte olan ülkelerin bazı bölgelerinde de geçerliliğini sürdürmektedir (Yeni ve Karaağaç, 2005).

Epilepsiden bahseden ilk kişi M.Ö. 350’lerde Hipokrat’tır. Bu yüzden Hipokrat hastalığı olarak da bilinir. Günümüze ışık tutması anlamında epilepsi ile ilgili ilk fizyopatolojik değerlendirmeler 19. yüzyılda John Hughlings Jackson tarafından, sadece klinik gözlemlere dayanılarak ortaya atılmıştır. Jackson’ın epilepsi alanına yaptığı katkılar modern tıp bilimi tarafından hala kullanılmaktadır (Sezer, 2008).

Dünya nüfusunun %1-3, Türkiye nüfusunun %1’ni etkileyen çoğunlukla çocukluk ve yaşlılık döneminde yaygın olarak görülen epilepsi sadece nöbet anında değil, normal yaşam kalitesini etkileyen kendini spontan tekrarlayan önemli ve ciddi bir

rahatsızlıktır. İnsanların yaklaşık %9'u yaşamlarının bir döneminde en azından bir kez nöbet geçirebilmektedir (Toklu ve ark., 2012).

Tam nedeni tespit edilmemesine karşın genetik nedenler, kromozom hastalıkları, doğum sırasında veya sonrasında meydana gelen beyin zedelenmeleri, kafa yaralanmaları ve travmalar, beyine giden kan akımının kesilmesi veya azalması sonucunda beyin besinsiz ve oksijensiz kalması, beyinde oluşan tümör ve hasarlar, bazı enzim eksiklikleri, gebelikte annenin geçirdiği mikrobik hastalıklar, alkol ve ilaç kullanımı, menenjit, uzun süren ateşli hastalıklar, vitamin eksikliği, tiroit hastalıkları vb. nedenlerden dolayı epilepsi oluşabileceği bilim çevrelerince kabul edilmektedir (Sezer 2008).

Epilepsi kendini sürekli tekrarlayan nöbetler şeklinde gösterir. Bu nöbetlerin tümünde hastanın bilincini yitirdiği yaygın bir kanı olduğu halde bu doğru değildir. Bazı hastalarda beyin tamamı değil sadece belli bir bölümü etkilendiğinden hasta bilincini yitirmez fakat alışılmadık durumlar ortaya çıkar. Bu durum değişik duygulara ve davranışlara neden olur. Bazı nöbetlerde ise başlangıçtan itibaren beyin tamamı etkilendiğinden hasta bilincini yitirir. Bayılma, kasılma, morarma, sıçrama, çırpınma, ağız köpürmesi gibi durumlar ortaya çıkabilir.

Epilepsi nöbetleri, fazlaca karmaşık olmasına rağmen, genellikle nöbetin başlangıç şekline göre iki kategoriye ayrılması uluslararası düzeyde kabul görmektedir. Birinci kategori parsiyel ya da fokal (kısmi) ikinci kategori ise, jeneralize (genel, yaygın) nöbet olarak adlandırılmaktadır. Beynin belirli bir bölge veya yarı küresinde başlayan nöbetlere parsiyel veya fokal adı verilirken başlangıçtan itibaren tüm beyni etkileyen nöbetler jeneralize olarak adlandırılır. Parsiyel veya fokal nöbetler kendi içinde basit, kompleks ve sekonder jeneralize nöbetler olarak üç kategoriye ayrılmaktadır. Bu nöbet kategorileri içindeki son nöbet türü olan sekonder jeneralize nöbet türü, bir parsiyel nöbetin jeneralize nöbete geçebilmesi anlamına gelmektedir (Kumdereli 2012).

a) Basit Parsiyel Nöbetler: Bu nöbetlerde şuurlu kalmakta nöbet geçiren hasta nöbet sırasında neler yaşadığını hatırlayabilmekte fakat nöbeti durduramamaktadır. Nöbetin süresi saniyeler ile dakikalar arasında değişebilmektedir. Nöbet esnasında kol veya bacağın kontrolsüz hareketi, hoş olmayan bir koku hissetme, ağızda garip bir tat duyma veya ağız etrafında kasılma hissetme, midede yükselme

duygusu, el, kol, bacak veya ayakta karıncalanma, iğnelenme hissi, dejavu hissi, başkalarının göremediği, duymadığı şeyleri kısa süre işitme veya görme gibi belirtiler görülebilir (Albayrak 2008).

b) Kompleks Parsiyal Nöbetler: Bu nöbetlerde basit parsiyel nöbetlere nazaran beynin daha büyük bir bölümü etkilenir. Bu tip nöbetlerde bilinç tamamen veya kısmen kaybolduğundan parsiyel nöbetlere kompleks kelimesi eklenmiştir. Nöbetin süresi saniyeler ile dakikalar arasında değişebilmektedir. Fakat nöbet geçiren hasta birkaç dakika ile birkaç saat arasında bilinç bulanıklığı ve uyuşukluk his edebilir, nöbet sırasında bilinç kaybolduğundan olanları hatırlamaz. Nöbet esnasında ağızda şapırdatma, tekrarlayan garip hareketler, mırıldama, eldeki bir nesne ile oynama, kollar ve bacaklarda garip duruşlar olabilir. Bilinç kaybolduğundan soru sorarsanız size cevap veremez ve konuşamaz [(Kumdereli 2012), (Albayrak 2008)].

c) Sekonder jeneralize Nöbetler: Bu nöbetlerde nöbet basit veya kompleks parsiyel nöbet olarak başlar daha sonra nöbet yayılarak beynin her iki tarafını etkiler. Nöbet geçiren hasta bilincini kaybeder ve genellikle jeneralize nöbet çeşidi olan tonik-klonik bir nöbet geçirir.

Jeneralize nöbetler kendi içinde absans, tonik, atonik, tonik-klonik, miyoklonik nöbetler olarak beş kategoriye ayrılmaktadır (Kumdereli 2012).

a) Absans (Dalma) Nöbetleri: Absans kelimesi dalgınlık anlamına gelip genellikle çok kısa süren bilinç kaybıyla ortaya çıkan ve hafif geçen jeneralize bir epilepsi nöbetidir. Bu nöbet genellikle çocuk ve gençlerde daha yaygın görülmektedir. Bu nöbeti geçiren hasta çevresinde olup bitenlerden haberdar değildir ancak nadiren yere düşer. Gözleri bir noktaya dik dik bakar, biraz kayar ve göz kapaklarını kırıştırır. Absans nöbetleri ani başlar, birkaç saniye sürer, aniden sona erer ve genellikle etraftakiler bunun farkına bile varmadan kişi nöbetten önceki durumuna geri döner. Bu nöbetler birkaç saniye sürmesine karşın, gün içerisinde birçok defa olabilir, bu durum konsantrasyonu ve öğrenmeyi olumsuz etkiler [(Kumdereli 2012), (Albayrak 2008)].

b) Tonik Nöbetler: Tonik nöbetler kasların kaskatı olduğu jeneralize nöbetlerdir. Bu sebeple nöbet geçiren hasta ayaktaysa, oldukça şiddetli bir şekilde yere düşer. Bu düşme genellikle arkaya doğru olur. Bu düşme hastada kafa yahut vücut yaralanmasına neden olabilir. Bu nöbetler aynı zamanda uykuda ardı sıra nöbetler

halinde oluşabilir. Bu nöbet normalde çok kısa sürer ve hasta çabucak iyileşerek eski haline döner (Kumdereli 2012).

c) Atonik Nöbetler: Atonik nöbetler hastanın kaslarının aniden gevşemesine neden olan jeneralize nöbetlerdir. Bu sebeple nöbet geçiren hasta ayaktaysa, genellikle yere düşer. Bu düşme genellikle öne doğru olur. Bu düşme hastada baş veya yüz yaralanmalarına neden olabilir. Bu nöbet genellikle kısa sürer ve hasta çabucak iyileşerek eski haline döner (Kumdereli 2012).

d) Tonik-klonik (Grand Mal) Nöbetler: Tonik-klonik nöbetler epilepsi denilince çoğu kişinin aklına gelen jeneralize nöbet türüdür. Bu nöbet türü en çok bilinen nöbet olmakla beraber en çok görünen nöbet türü değildir. Bu nöbet türünde hasta bilincini tamamen kaybeder. Tonik aşama olarak adlandırılan nöbetin ilk aşaması yaklaşık olarak yarım dakika sürmektedir. Bu aşamada hasta kaskatı kesilir ve ayaktaysa, yere düşer. Hasta çığlık atabilir, yüzü morarır. Yutkunmak veya tükürmek mümkün olmadığından dolayı, ağızda tükürük birikir. Çene kasları kasıldığından dolayı hasta dilini veya yanağını ısırabilir. Klonik aşama olarak adlandırılan nöbetin ikinci aşaması ise çoğunlukla yarım ile bir buçuk dakika arası sürmektedir. Bu aşamada hastanın kaslarında gevşemeler sonra da kasılmalar meydana gelir. Sırayla oluşan bu gevşeme ve kasılmalar hastanın kol, bacak veya yüzünde çarpınma ve seğirmelere neden olur. Ağızda toplanan tükürük (bazen kanla karışık) köpük olarak dışarı çıkar [(Kumdereli 2012), (Albayrak 2008)].

e) Miyoklonik Nöbetler: Miyoklonik kelimesi kas seğirmesi anlamına gelip genellikle kaslarda kısa süreli, ani, kontrol dışı kasılmalar (seğirme) ile kendini gösteren jeneralize bir epilepsi nöbetidir. Kasılma bazen bir tek, bazen de bir dizi şeklinde olmaya çıkmakta çoğunlukla kol ve/veya bacaklarda bazen de tüm vücudu etkilemektedir. Kasılmalar o kadar kısa sürmektedir ki, bilincin kaybolduğu anlaşılmamaktadır. Kasılmalar uykuya dalarken gösterdiğimiz kasılmalara benzese de miyoklonik nöbetler çoğunlukla sabah uyanırken ortaya çıkmaktadır. Bu nöbetler kısa sürmekte ve hasta nöbetten sonra kısa bir süre içinde yine iyileşebilmektedir [(Kumdereli 2012), (Albayrak 2008)].

Epilepsi hastalığının teşhisinde en ideal yol doktorun hastayı nöbet geçirirken görmesidir. Bu durum çoğunlukla mümkün olmadığından hasta yakınlarından bilgi istenir. Ailede böyle bir hastalığın olup olmadığı araştırılır. Nörolojik muayene ve

laboratuvar tetkikleri yapılır. Bu tetkiklerin başında EEG gelir. Bunun yanı sıra CTI ve MRI gerekli olabilir. EEG işaretleri epilepsi teşhisi için kullanılan diğer teknik ve yaklaşımlara göre daha hızlı, ucuz, kolay ve erişilebilir olduğundan halen en çok tercih edilen yöntemdir. Bu yüzden, bu çalışmada EEG işaretleri üzerine odaklanılmıştır [(Sezer 2008), (Orhan 2011)].

1.3. Elektroensefalografi (EEG)

İnsan bedeninde, hücrelerde oluşan biyolojik kaynaklı elektriksel aktivitenin sonucu olarak, pek çok elektriksel işaret meydana gelmektedir. Bu işaretlerden birisi de beyinde var olan sinir hücre gruplarının elektriksel aktivitesinin kafatası derisinin yüzeyinde potansiyel değişimlere neden olduğu işaretlerdir. Bu işaretlerin grafiksel gösterimi olan EEG, Grekçe kelimelerden oluşup, “Beynin elektriksel resmi” anlamına gelmektedir. EEG terimi geçmişte beyin elektriksel aktivitelerini belirtmek için kullanılmış olsa da günümüzde beyin elektriksel aktivitelerinin kaydını, kafatasından sinyal yayılımını, çizme ya da yazmayı ifade eden anlamları içerisinde barındırmaktadır. EEG kayıtları pasta (elektro jel) denilen iletken bir madde aracılığıyla kafatasına yerleştirilen elektrotların arasındaki elektriksel potansiyel değişikliklerin ölçülmesi, filtrelenmesi ve kuvvetlendirilerek kaydedilmesi ile elde edilir. EEG işaretleri 1-400 μV genliğe ve 0.5-100 Hz’lik frekans spektrumuna sahiptirler [(Yıldız 2011), (Aydemir 2008), (Ochoa ve ark. 2002)].

EEG işaretlerine ilişkin çalışmalar yaklaşık olarak 140 yıldır devam etmektedir. 1875’te İngiliz fizikçi Richard Caton tavşan ve maymunların üzerinde yaptığı deneyler sonucunda beyinde bir takım elektriksel faaliyetlerin var olduğunu keşfetmiştir. 1920’de Alman nörolog Hans Berger ilk defa insan beyindeki elektriksel aktivitenin varlığını keşfetmiştir. 1929’da Berger kafatası yüzeyine yerleştirilen elektrotlar ve bunlara bağlı galvanometre ile beyin dalgalarını ölçmüş ve alınan işaretleri bir kâğıda grafiksel olarak dökmüştür. Ancak, bilim adamlarınca, kaydedilen bu dalgaların insan beyinden değil, kullanılan cihazlardan kaynaklandığı ortaya atılmıştır. EEG işaretlerinin varlığının bilimsel şekilde kesin olarak ortaya konması, elektronikteki gelişmeler ile birlikte Adrian ve Matthews’un 1934’te “insanın beyin dalgaları” konseptini doğrulayacak şekilde 10-12 Hz civarında düzenli “alfa ritimleri” salınımlarını tanımlaması ve elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydetmeleriyle olmuştur. Bu çalışma aynı zamanda EEG dalgaları ile ilgili giriş niteliğinde bir çalışmadır. İlk

epileptik EEG işaretleri 1934'te Fisher ve Lowenback tarafından incelenmiş ve 1936'da Massachusetts General Hospital Hastanesinde ilk EEG laboratuvarı kurulmuştur. W. G. Walter, 1950'de beyin yüzeyindeki elektriksel aktivitenin haritalandırılması için EEG topoğrafyasını geliştirerek bu konuyu 1950-1980 yılları arasında popüler bir çalışma alanı haline getirmiştir. 1980-2000 yılları arasında EEG işaretlerinden yararlanarak erken hastalık teşhisi üzerine birçok çalışma yapılmıştır. 2000 yılından bu yana beyin ve EEG işaretlerine yönelik çalışmalar büyük bir hız kazanmıştır [(Emhan 2017), (Başçıl 2015), (Yıldız 2011), (Teplan, 2002)].

İnsan beyni gibi merkezi sinir sisteminden alınan işaretlerde de çok miktarda bilgi olduğu bilinmektedir. Yalnız beynin kompleks yapısı ve kontrol ettiği karmaşık işlemlerle birlikte, alınan işaretlerin düşük genlikli olması, bu bilgilere ulaşılmasını oldukça zorlaştırmaktadır. Günümüzde birçok rahatsızlık ve zihinsel süreçlerin izlenmesinde hızlı, ucuz, kolay, erişilebilir ve hastaya acı vermeyen bir yöntem olduğundan EEG işaretleri hastalıkların teşhisinde önemli bir yer tutmaktadır. Nöroloji hastalarında beyin patolojisinin belirlenmesinde, beyin cerrahisi ameliyatlarında çıkarılacak tümör gibi anormal patolojik dokuların belirlenmesinde, anestezi altındaki hastanın anestezi seviyesinin belirlenmesinde, psikiyatride zihinsel bir bozukluğun daha kesin bir şekilde belirlenmesi amacıyla organik bir beyin hastalığının var olup olmadığının belirlenmesinde, pediatriye yeni doğmuş çocukların duyma ve görme problemlerinin belirlenmesinde, uyku ile ilgili hastalıkların tanınmasında, kafa travmalarında, komalar ve metabolik hastalıklarda ayrıca epilepsi hastalığının tespitinde EEG işaretleri yaygın bir şekilde kullanılmaktadır [(Demir 2008), (Bayram 2003)].

1.3.1. EEG Dalgaları

Kafatası üzerine yerleştirilen elektrotlar ile algılanan EEG işaretlerinin genliği tepeden tepeye (10-200) μV ve frekans bandının aralığı ise (0.5-100) Hz'dir. EEG işaretleri durağan olmayan özellikler göstermekte olup genlik, faz ve frekans bileşenleri sürekli değişkenlik göstermektedir. Bu işaretlerin frekans bileşenleri beyin fonksiyonları hakkında oldukça önemli bilgiler vermektedir. EEG ile patolojik veya fizyolojik bir durum tespiti yapmak için uzmanlar EEG işareti içerisinde bulunan baskın frekans aralığındaki dalgaları kullanılmaktadırlar. EEG işaretini oluşturan ve özel adlarla anılan bu dalgalar aşağıda geniş bir şekilde tarif edilmiş olup 1 saniyelik örnek dalgalar Şekil 1.2.'de gösterilmiştir [(Polat 2016), (Yıldız 2011)].


a) Delta Dalgaları (δ): Bu dalga yüksek genlikli olup (0.5-4) Hz aralığındaki frekans bandı ile en düşük frekanslı EEG dalgasıdır. Bu tür dalgalar süt çocuklarında ön planda olup yetişkin bireylerde derin uyku sırasında sıklıkla görülür. Uyanık yetişkinlerde istirahat halinde görülen delta dalgası her zaman anormal bir bulgu olarak kabul edilir [(Kumdereli 2012), (Yıldız 2011), (Adeli ve ark. 2003)].

b) Teta Dalgaları (θ): Teta terimini 1944'de ilk defa Walter ve Doney kullanmıştır. Teta dalgalarının frekans bandı (4-8) Hz olup normal bebeklerde, çocuklarda ve uyku halindeki yetişkinlerde bulunur. Az da olsa yetişkinlerde uyanırken görülebilen bir dalga türüdür. Fakat uyanık yetişkinlerde yüksek teta aktivitesinin varlığı, anormal ve patolojik durumları göstermektedir [(Yıldız 2011), (Adeli ve ark. 2003)].

c) Alfa Dalgaları (α): Alfa terimini 1929'da ilk defa Berger kullanmıştır. Alfa dalgalarının frekans bandı (8-13) Hz olup uyanık bireylerin fiziksel ve zihinsel olarak tam dinlendiği ve gözlerinin kapalı olduğu durumlarda daha fazla görülür. Alfa dalgaları gözlerin (görsel dikkat) ve düşünme gibi diğer zihinsel çabaların açılmasıyla yok olan bir dalga türüdür [(Yıldız 2011), (Adeli ve ark. 2003)].

d) Beta Dalgaları (β): Frekans bandı (13-30) Hz ve genlikleri alfa dalgalarından daha küçük olan dalgalardır. Alfa dalgaları beyin ön kısmında daha baskındır. Problem çözme ve hatırlama anları gibi beyindeki fiziksel ve bilişsel aktivitelerin yoğun olduğu durumlarda iyice belirginleşirler. Ayrıca kahve, enerji içecekleri gibi çeşitli uyarıcılar tüketildiğinde beta dalgalarında bir artış olur [(Polat 2016), (Yıldız 2011), (Adeli ve ark. 2003)].

e) Gama Dalgaları (γ): Frekans aralığı yaklaşık olarak (30-100) Hz olan dalgalardır. Gama dalgaları yüksek bir frekans bandına sahip olduğundan genellikle klinik ve fizyolojik çalışmalar dışında kullanılır. Bu nedenle birçok uygulamada dalgalar EEG kayıtlarından sıklıkla filtrelenir [(Polat 2016), (Yıldız 2011), (Adeli ve ark. 2003)].



Şekil 1.2. EEG dalgaları (Yıldız 2011)

1.3.2. EEG Elektrotlarının Bağlanması ve İşaretlerinin Ölçülmesi

Bilgisayarların gelişmesi ile birlikte günümüzde EEG işaretlerinin ölçülmesinde yaygın olarak beyin-bilgisayar arabirimi kullanılmaktadır. Bu arabirimlerin kullanılması ile EEG işaretini almak, alınan işaretleri analiz etmek ve çıkan sonuçları kaydetmek daha kolay hale gelmiştir. EEG işaretlerini almak, analiz etmek ve kaydetmek hasta açısından tamamen ağrısız bir yöntemidir. Şekil 1.3.'te gösterildiği gibi beyin ile bilgisayar arasına kurulan beyin-bilgisayar arabirimi ile kayıt ve analiz işlemleri kolay, hızlı ve etkin bir şekilde yapabilmektedir. Bu beyin-bilgisayar arabirimi aşağıda detaylı olarak açıklanan dört temel birimden oluşmaktadır [(Yıldız 2011), (Özer 2010)].


a) Kafatası elektrotları: Beyin-bilgisayar arabiriminin ilk birimi beynin elektriksel aktivitesini kafatası yüzeyinden ölçmeye yarayan metal elektrotlardır. EEG

işaretlerinin alınmasında elektrotların işlevini doğru bir şekilde yerine getirmesi ve kaliteli verilerin elde edilmesi oldukça önemlidir. EEG ölçümlerinde, beş tip elektrot kullanılmakla birlikte, yeniden kullanılabilen scalp disk tipi elektrotlar en yaygın kullanılan elektrotlardır. Bu elektrotlar, uygun bir iletken krem (jel) kullanılarak deriye temas ettirilirlir. Kafatası elektrotları Şekil 1.3a.'da gösterilmiştir. [(Yıldız 2011), (Demir 2008)].

b) Dönüşüm Kuvvetlendiricisi: Bu birimde elektrolara işlemsel yükselteçlerden oluşan diferansiyel kuvvetlendirici devreler bağlanır ve bu yolla elektrotlardan elde edilen işaretler güçlendirilir. Güçlendirilen analog işaretler filtrelendirir. Dönüşüm kuvvetlendiricisi Şekil 1.3b.'de gösterilmiştir (Demir 2008).

c) İşlemci Arabirimi: Dönüştürücü arabiriminin çıkışından elde edilen analog EEG işaretlerinin sayısal olarak işlenmesi ve bilgisayar portları tarafından algılanabilecek hale dönüştüren arabirimdir. İşlemci arabirimi Şekil 1.3c.'de gösterilmiştir (Yıldız 2011).

d) Bilgisayar: İşlemci arabiriminden gelen işaretlerin ekranda görüntülenmesi, depolanması, herhangi bir depolama alanına transfer edilmesi, gerekiyorsa kağıt veya başka bir yüzeye çıktı alınmasını sağlayan arabirimdir. Bilgisayar arabirimi Şekil 1.3d.'de gösterilmiştir (Yıldız 2011).



Şekil 1.3. Beyin-bilgisayar arabirimi

EEG işaretlerinin ölçülmesinde kullanılan sistemin ilk kısmını oluşturan elektrotların kafatasına yerleşiminde Uluslararası EEG Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot yerleştirme sistemi kullanılır. Bu yerleştirme sistemine göre baş; burun (nasion), başın arka kısmı (inion), sol kulak arkası ve sağ kulak arkası (preauriculars) olmak üzere dört standart noktayla işaretlenmiştir. Elektrotlar burun ve başın arka kısmı arasına % 10 - 20 - 20 - 20 - 20 - 10 olacak şekilde yerleştirilir. Şekil 1.4.'te Uluslararası 10-20

elektrot yerleştirme sistemine göre elektrotların yerleşim şekli farklı açılardan gösterilmiştir. 10-20 yerleştirme sisteminde elektrotlar beynin sağ ve sol yarımkürelerine simetrik olarak daire oluşturacak şekilde yerleştirilirler. Bu durum beynin sağ ve sol yarımküreleri arasında kıyaslamanın sağlıklı yapılabilmesi için gereklidir. Beyin yarımkürelerine yerleştirilen elektrotlar her beyin lobunun adının baş harfine göre solda tek sayı ve sağda çift sayı ile gösterilir. Örnek olarak sol arka frontal için F7 sağ ön frontal için F4 kullanılır. Sonuçta 19 elektrot kafa üzerine yerleştirilir ve kulak memesine yerleştirilen 20. elektrot ise toprak elektrotu olarak kullanılır [(Emhan 2017), (Yıldız 2011), (Gürsoy 2009)].



2. KAYNAK ÖZETLERİ

Literatür incelendiğinde, EEG işaretlerinden epilepsi tespiti için farklı veri tabanları ile çok sayıda çalışma yapıldığı görülmektedir. Bu bölümde yapılacak uygulama öncesi daha önce epilepsi tespiti için yaygın olarak kullanılan veri tabanları ve çalışmamızda kullanılan veri tabanı ile ilgili çalışmalar incelenmiş olup, yapılan örnek çalışmaların özeti aşağıda sunulmuştur.

a) Bern-Barcelona EEG Veri Tabanı: İsviçre Bern Üniversitesi Nöroloji Bölümü'nde farmakolojik dirençli temporal lob epilepsisi olan, beş hastadan elde edilen uzun süreli, kafa içi, çok kanallı EEG kayıtlarından oluşmaktadır. EEG işaretleri 512 Hz'lik bir örnekleme frekansında örneklenmiştir. Veri kümesinde kayıtlar X ve Y ile gösterilen EEG işaret çiftlerinden oluşmuştur. Veri kümesinde her bir EEG işareti 10.240 örneğe sahip 3750 çift fokal (focal) ve 3750 fokal olmayan (non-focal) EEG işaretinden oluşmaktadır. Literatürde bu işaret kümesinin kullanılması ile yapılan çalışmalardan bazılarının kısa bir özeti aşağıda verilmiştir.

Arunkumar ve ark. (2017) yaptıkları çalışmada, fokal ve fokal olmayan EEG işaretlerini sınıflandırmak için bir sınıflandırma metodolojisi önermişlerdir. Bu çalışmada, Yaklaşık Entropi (Approximate Entropy (ApEn), Örnek Entropisi (Sample Entropy (SampEn)) ve Reyni Entropisi (Reyni's Entropy (RE)) 10.240 örneğe sahip EEG işaretlerine doğrudan uygulanarak özellik çıkarımı yapılmıştır. Naive Bayes (Naive Bayes (NB)), Radyal Tabanlı Fonksiyon (Radial Basis Function (RBF)) SVM, K-NN, Yuvalanmamış Genelleştirilmiş Örnekler (Non-Nested Generalized Exemplars (NNGE)) ve En İyi İlk Karar Ağacı (Best First Decision Tree (BFD)) sınıflandırıcıları ile sınıflandırma yapılmıştır. Çalışmada maksimum doğruluk %98 olup NNGE sınıflandırıcısı ile elde edilmiştir.

Gupta ve ark. (2017) yaptıkları çalışmada, fokal EEG sinyallerinin saptanması için otomatik bir sistem önerilmişlerdir. EEG işaretlerinin 15. seviye Esnek Analitik Dalgacık Dönüşümü (Flexible Analytic Wavelet Transform (FAWT)) dalgacık dönüşümü yapılmıştır. Çapraz Entropi (Cross Correntropy (CC)) Stein'in Yansız Risk Tahmini (SURE) Entropisi (SURE Entropy (SE)) ve Log Enerji Entropisi (Log Energy Entropy (LEE)) kullanılarak orijinal ile yeniden oluşturulmuş 16 adet alt bant işaretlerinden özellik çıkarımı yapılmıştır. Kruskal-Wallis testi ile istatistiksel olarak anlamlı özellikler seçilerek K-NN ve En Küçük Kareler Destek Vektör Makinesi (Least

Squares Support Vector Machine (LS-SVM)) sınıflandırıcıları ile sınıflandırma yapılmıştır. Çalışmada maksimum doğruluk %94.41 olup LS-SVM sınıflandırıcısı ile elde edilmiştir.

Bhattacharyya ve ark. (2017) yaptıkları çalışmada, fokal ve fokal olmayan farklı frekans ölçeklerindeki çok değişkenli EEG işaretlerinin analizi ve sınıflandırması için bir yöntem önermektedirler. Önerilen sistemde Ayarlanabilir Q Dalgacık Dönüşümü (Tunable-Q Wavelet Transform (TQWT)) ve çok değişkenli alt bant Bulanık Entropi (Fuzzy Entropy (FuzzyEn)) kullanılarak özellik çıkarımı yapılmış bu özellikler LS-SVM sınıflandırıcısı ile sınıflandırılmıştır. Çalışmada maksimum %84.67 doğruluk elde edilmiştir.

Arunkumar ve ark. (2018) yaptıkları çalışmada, fokal ve fokal olmayan EEG işaretlerinden 50 çift işaret kullanarak bir sınıflandırma metodolojisi önermişlerdir. Bu çalışmada, ApEn, SampEn ve FuzzyEn 10.240 örneğe sahip EEG işaretlerine doğrudan uygulanarak özellik çıkarımı yapılmıştır. NB, RBF-SVM, K-NN, NNGE ve BFDT sınıflandırıcıları ile sınıflandırma yapılmıştır. Çalışmada maksimum doğruluk %99 olup NNGE sınıflandırıcısı ile elde edilmiştir.

Raghu ve ark. (2018) yaptıkları çalışmada, fokal epileptik nöbetlerin otomatik tespitini yapmışlardır. Çalışma için Bern-Barcelona veri kümesinden toplam 41.66 saat uzunluğunda EEG işaretleri kullanılmıştır. Zaman, frekans ve istatistiksel alandan 28 özellik çıkarılmış ve Komşuluk Bileşen Analizi (Neighborhood Component Analysis (NCA)) kullanılarak 7 önemli özellik seçilmiştir. SVM, K-NN ve Rasgele Orman (Random Forest (RF)) ve Adaptif Güçlendirme (Adaptive Boosting (AdaBoost)) sınıflandırıcıları ile sınıflandırma yapılmıştır. Çalışmada maksimum doğruluk %96.1 ile kübik çekirdek fonksiyonuna sahip SVM sınıflandırıcısı ile elde edilmiştir.

b) Physionet CHB-MIT EEG Veri Tabanı: Boston Çocuk Hastanesinde yaşları 3 ile 22 arasında değişen 5 erkek ve yaşları 1.5 ile 19 arasında değişen 17 kadın epilepsi hastasına ait EEG kayıtlarından oluşmaktadır. Dirençli nöbeti olan ve anti-nöbet özellikli ilaçlar kullanan bu hastalar ilaçlar çekildikten sonra birkaç gün takip edilmiş ve 256 Hz örnekleme frekansı ile EEG sinyalleri elde edilmiştir. Veri tabanında mevcut dosya 23 EEG kanalı içermekte ve bu kayıtlar için uluslararası 10-20 EEG elektrot pozisyonları ve isimlendirme sistemi kullanılmıştır. Mevcut EEG kayıtları toplamda 198 nöbet olayını içermekte olup süresi yaklaşık 983 saattir.

Fergus ve ark. (2017) yaptıkları çalışmada, Physionet CHB-MIT EEG veri tabanından alınan işaretler için denetimli bir makine öğrenme yaklaşımı sunmuşlardır. Öncelikle EEG'nin delta, teta, alfa ve beta bantlarını elde etmek için 543 EEG bölütüne bant geçiren bir filtre uygulamışlardır. Elde edilen EEG alt batlarından zaman domeninde örnek entropisi, çarpıklık, basıklık işaret enerjisi ve frekans domeninde ise pik frekans, ortalama frekans kullanılarak özellik vektörü çıkarılmıştır. Çıkarılmış bu özellikler Temel Bileşen Analizi (Principal Component Analysis (PCA)) kullanılarak azaltılmıştır. Veri azaltımından sonra elde edilen özellik vektörü Lineer Diskriminant Sınıflandırıcı (Linear Discriminant Classifier (LDC)), Kuadratik Diskriminant Sınıflandırıcı (Quadratic Discriminant Classifier (QDC)), Korelasyonlu Normal Dansite Bazlı Sınıflandırıcı (Uncorrelated Normal Density-Based Classifier (UDC)), Polinom Sınıflandırıcı (Polynomial Classifier (POLYC)), Lojistik Sınıflandırıcı (Logistic Classifier (LOGLC)), K-NN, Karar Ağacı (Decision Tree (DT)), Parzen Sınıflandırıcı (Parzen Classifier (PARZENC)) ve SVM ile sınıflandırılmıştır. Çalışmada maksimum doğruluk %91.00 olarak K-NN ile elde edilmiştir.

Samiee ve ark. (2017) yaptıkları çalışmada, Physionet CHB-MIT EEG veri tabanından alınan 163 saatlik EEG işaretleri üzerinde kapsamlı ve karşılaştırmalı bir çalışma gerçekleştirmişlerdir. EEG işaretlerine Rasyonel Ayrık Kısa Zamanlı Fourier Dönüşümü (Rational Discrete Short Time Fourier Transform (RDSTFT)) alt bantlar elde edilmiştir. Basis Pursuit algoritması kullanılarak kısıtlılık yaratılmış ve Yerel Gabor İkili Modelleri (Local Gabor Binary Patterns (LGBP)) kullanılarak öz nitelik vektörleri çıkarılmıştır. Çıkarılan öz nitelik vektörleri Lojistik regresyon (Logistic Regression (LR)), RF ve SVM ile sınıflandırılmıştır. Çalışmada maksimum doğruluk %83.00 olarak SVM ile elde edilmiştir.

Harpale ve ark. (2018) yaptıkları çalışmada, fokal ve fokal olmayan farklı frekans ölçeklerindeki çok değişkenli EEG işaretlerinin analizi ve sınıflandırması için bir yöntem önermektedirler. Önerilen sistemde TQWT ve çok değişkenli alt bant FuzzyEn kullanılarak özellik çıkarımı yapılarak bu özellikler LS-SVM sınıflandırıcısı ile sınıflandırılmıştır. Çalışmada maksimum %84.67 doğruluk elde edilmiştir.

Tsiouris ve ark. (2018) yaptıkları çalışmada, Uzun Kısa Süreli Bellek (Long Short-Term Memory (LSTM)) ağlarını kullanarak Physionet CHB-MIT EEG veri tabanında bulunan tüm vakaların nöbet tespitini vaka bazında ayrı ayrı yapmışlardır.

Veri tabanından alınan EEG işaretlerini beş saniyelik bölütlere ayırarak bu işaretlerden zaman domeninde varyansın karekökü, işaret değişikliği sayısı, en yüksek / en düşük genlik arasındaki fark, sinyal altındaki mutlak alan ve frekans domeninde toplam EEG işaret enerjisi özellikler, delta, teta, alfa, beta, gama1, gama2 enerji yüzdesi, yedinci altıncı seviye dalgacık dönüşümünün yaklaşım, yedinci, altıncı, beşinci, dördüncü, üçüncü, ikinci, birinci seviye detay katsayıları kullanılarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü her vaka için LSTM ile ayrı ayrı sınıflandırılarak maksimum doğruluk %98 olarak elde edilmiştir.

c) Bonn Üniversitesi EEG Veri Tabanı: Bonn Üniversitesi Epileptoloji Bölümü (Freiburg Veri Analizi ve Modelleme Merkezi) veri tabanı A, B, C, D ve E olmak üzere 5 veri kümesinden oluşmaktadır. Her bir veri kümesi 23.6 saniyelik, 100 tek-kanallı ölçümlerle kaydedilmiş EEG işaret parçalarını içerir. Her bir kümede 5 kişiye ait 20 adet ölçüm ile alınmış toplamda 100 adet 4096 örnekten (sample) oluşan EEG işareti bulunmaktadır. Bu veri tabanı ile ilgili daha fazla bilgi tez çalışmasının materyal ve metot kısmında sunulmuştur.

Kannathal ve ark. (2005), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin kolmogorov, spektral, renyi ve yaklaşım entropisi kullanılarak özellik vektörü çıkarılmış ve (Adaptive Neuro-Fuzzy Inference Systems (ANFIS)), ile sınıflandırılmıştır. Çalışmada doğruluk A ve E işaret kümeleri için %90'nın üzerinde elde edilmiştir.

Srinivasan ve ark. (2005), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin ritmisitesi, ritmisitesitenin maksimum genlik değeri, baskın frekans, temel enerji bölgesindeki ortalama güç, normalize edilmiş spektral entropi kullanılarak özellik vektörü çıkarılmış ve Elman Ağı (Elman Network (EN)) ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.60 olarak elde edilmiştir.

Sadati ve ark. (2006), yaptıkları çalışmada mevcut işaret kümelerinden A, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin beşinci seviye dalgacık dönüşümünün yaklaşım katsayısı, beşinci, dördüncü, üçüncü, ikinci, birinci seviye dalgacık dönüşümünün detay katsayılarının enerjileri alınarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü SVM, ANFIS, İleri Beslemeli Geri Yayılım Sinir Ağı (Feedforward Back-Propagation Neural Network (FBNN)) ve Adaptif Sinirsel

Bulanık Ağ (Adaptive Neural Fuzzy Network (ANFN)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk %85.90 olarak ANFN sınıflandırıcısı ile elde edilmiştir.

Polat ve Güneş (2007), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin Welch GSY kestirimi kullanılarak özellik vektörü çıkarılmış ve DT yöntemi ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %98.72 olarak elde edilmiştir.

Güler ve Übeyli. (2007), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin dördüncü seviye dalgacık dönüşümünün yaklaşım katsayısı, dördüncü, üçüncü, ikinci, seviye dalgacık dönüşümünün detay katsayılarının maksimumu, Lyapunov üstelinin maksimumu, minimumu, Lyapunov üstelinin minimumu, ortalaması, Lyapunov üstelinin ortalaması alınarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü SVM, Olasılıksal Sinir Ağı (Probabilistic Neural Network (PNN)) ve Çok Katmanlı Algılayıcı Yapay Sinir Ağı (Multilayer Perceptron Neural Network (MLPNN)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.28 olarak SVM sınıflandırıcısı ile elde edilmiştir.

Srinivasan ve ark. (2007), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin yaklaşık entropisi alınarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü EN ve PNN sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 olarak PNN sınıflandırıcısı ile elde edilmiştir.

Subaşı (2007), yaptığı çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmıştır. EEG işaretlerinin beşinci seviye dalgacık dönüşümünün yaklaşım, beşinci, dördüncü, üçüncü seviye detay katsayılarının mutlak değerlerinin ortalaması, dalgacık katsayılarının ortalama gücü, dalgacık katsayılarının standart sapması, bitişik alt bantların mutlak ortalama değerinin oranı alınarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü MLPNN ve Uzman Karışımları (Mixture of Experts (ME)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %94.50 olarak ME sınıflandırıcısı ile elde edilmiştir.

Tzallas ve ark. (2007), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin zaman-frekans düzleminde

enerji dağılımları göz önüne alınarak bölütlere ayrılarak özellik vektörü çıkarılmış ve Yapay Sinir Ağı (Artificial Neural Network (ANN)) ile sınıflandırılmıştır. Yapılan sınıflandırma sonucunda ABCD-E işaret kümeleri için %97.73, A-D-E için %99.28, AB-E ve CD-E işaret kümeleri için %99.28, A-E işaret kümeleri için %100 doğruluk elde edilmiştir.

Polat ve Güneş (2008), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin Welch GSY alınarak özellik vektörü çıkarılmış, çıkarılmış bu özellikler PCA kullanılarak azaltılmıştır. Veri azaltımından sonra elde edilen özellik vektörü Yapay İmmün-Tanıma Sistemi ile Bulanık Kaynak Ayırma (Artificial İmmune-Recognition System with Fuzzy Resource Allocation (AIRS-FRA)) ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 olarak elde edilmiştir.

Ocak (2009), yaptığı çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmıştır. EEG işaretlerinin üçüncü, ikinci, birinci seviye dalgacık dönüşümünün yaklaşım ve detay katsayılarının yaklaşık entropisi alınarak özellik vektörü çıkarılmış ve Vekil Veri Analizi (Surrogate Data Analysis (SDA)) ile analizi yapılmıştır. Yaptığı analiz sonucunda normal ve epileptik dönemleri %97.00 doğrulukla ayırmıştır.

Kumar ve ark. (2010), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin dalgacık, örnek, spektral entropisi kullanılarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü Tekrarlayan Elman Ağı (Recurrent Elman Network (REN)) ve Radyal Tabanlı Ağ (Radial Basis Network (RBN)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.75 olarak REN sınıflandırıcısı ile elde edilmiştir.

Guo ve ark. (2010), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerine dördüncü seviye dalgacık dönüşümü uygulanmış elde edilen her alt bandın yaklaşık entropisi alınarak özellik vektörü çıkarılmış ve MLPNN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk ABCD-E işaret kümeleri için %98.27 ve A-E işaret kümeleri için %98.85 olarak elde edilmiştir.

Özer ve ark. (2011), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerine ortalama mutlak değer, yule-walker autoregressive model, kovaryans autoregressive model uygulanarak özellik vektörü oluşturulmuş, k-ortalama, bulanık c-ortalama ile kümeleme yapılarak SVM ve Lineer Diskriminant Analiz (Linear Discriminant Analysis (LDA)) ile sınıflandırma yapılarak sonuçlar karşılaştırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.50 ile doğrusal SVM sınıflandırıcısı ile elde edilmiştir.

Wang ve ark. (2011), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin en iyi baz tabanlı dalgacık paket entropisi yöntemi ile özellik vektörü çıkarılmış ve K-NN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 olarak elde edilmiştir.

Tekin ve ark. (2011), yaptıkları çalışmada mevcut işaret kümelerinden A, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin dördüncü seviye dalgacık dönüşümünün yaklaşım katsayısı ve dördüncü, üçüncü, ikinci, birinci seviye dalgacık dönüşümünün detay katsayılarının maksimumu, minimumu, standart sapması, ortalaması, dalgacık enerjisi, medyanı hesaplanmış, bu özellikler K-means algoritması ile kümelenecek özellik vektörü çıkarılmış ve ANN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A-D ve A-E işaret kümeleri için %100 olarak elde edilmiştir.

Fathima ve ark. (2011), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin dördüncü seviye dalgacık dönüşümünün yaklaşım katsayısı ve dördüncü, üçüncü, ikinci, birinci seviye dalgacık dönüşümünün detay katsayılarının maksimumu, minimumu, ortalaması, standart sapması kullanılarak özellik vektörü çıkarılmış ve Lineer Sınıflandırıcı (Linear Classifier (LC)) ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.50 olarak elde edilmiştir.

Orhan ve ark. (2011), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin altıncı seviye dalgacık dönüşümünün yaklaşım, altıncı, beşinci, dördüncü, üçüncü, ikinci, birinci seviye detay katsayıları K-means algoritması ile kümelenecek, bu kümelerin olasılık dağılımları bulunarak özellik vektörü çıkarılmış ve MLPNN ile sınıflandırılmıştır. Yapılan sınıflandırma sonucunda ABCD-E işaret kümeleri için %99.60, A-D-E işaret kümeleri için %99.67, A-E işaret kümeleri için %100 doğruluk elde edilmiştir.

Kaya ve Tekin. (2012), yaptıkları çalışmada mevcut işaret kümelerinden A, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin ayırık dalgacık dönüşümü ile elde edilen istatistiksel özellikler ile özellik vektörü çıkarılmış ve ELM ile sınıflandırılmıştır. A-E ve D-E işaret kümeleri için farklı aktivasyon fonksiyonları farklı gizli katman nöron sayıları ile %100 doğruluk elde edilmiştir. Elde edilen sonuçlar Çok Katmanlı Algılayıcı (Multilayer Perceptron (MLP)), SVM ve NB gibi farklı sınıflandırıcılar ile kıyaslanmıştır.

Nicolaou ve Georgiou. (2012), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. Permütasyon entropisi kullanılarak EEG işaretlerinden özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü doğrusal SVM ve RBF-SVM sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %93.55 olarak doğrusal SVM sınıflandırıcısı ile elde edilmiştir.

Bayram ve Acar. (2013), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin ilinti boyutu analizinden elde edilen özgün veri, dalgacık-entropi analizinden elde edilen özgün veriler ve alt bant entropileri ile özellik vektörü çıkarılmış ve SVM ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %98.00 olarak elde edilmiştir.

Kumar ve ark. (2014), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin beşinci seviye dalgacık dönüşümünün beşinci, dördüncü, üçüncü, ikinci, birinci seviye yaklaşım ve detay katsayılarının bulanık yaklaşık entropileri kullanılarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü doğrusal SVM ve RBF-SVM sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A-E ve B-E işaret kümeleri için %100 ile RBF-SVM sınıflandırıcısı ile elde edilmiştir.

Nergiz ve ark. (2014), yaptıkları çalışmada mevcut veri kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin dördüncü seviye dalgacık dönüşümünün yaklaşım katsayılarının varyansı kullanılarak özellik vektörü çıkarılmış ve SVM ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %98.50 olarak elde edilmiştir.

Polat ve Özerdem (2014), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin beşinci seviye dalgacık

dönüşümünün yaklaşım katsayısı ve beşinci, dördüncü, üçüncü seviye dalgacık dönüşümünün detay katsayılarının mutlak değerinin ortalaması, mutlak değerinin maksimumu, ortalama gücü, standart sapması kullanılarak özellik vektörü çıkarılmış ve ANN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.00 olarak elde edilmiştir.

Kumar ve ark. (2014), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin ayrık dalgacık dönüşümü alınmış yaklaşım ve detay katsayıları bulunmuştur. Bulunan bu katsayıların yaklaşık entropisi alınarak özellik vektörü çıkarılmış ve FBNN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 olarak elde edilmiştir.

Kaya ve ark. (2014), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Tek Boyutlu Yerel İkili Desen (One Dimensional Local Binary Pattern, (1D-LBP)) metodu kullanılarak EEG işaretlerinden özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü Bayes Ağı (Bayesian Network (BayesNet)), ANN, LR, Fonksiyonel Ağaç (Functional Tree (FT)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.50 ile FT sınıflandırıcısı ile elde edilmiştir.

Lee ve ark. (2014), yaptıkları çalışmada mevcut veri kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin beşinci seviye dalgacık dönüşümünün yaklaşım, beşinci, dördüncü, üçüncü, ikinci, birinci derece detay katsayıları elde edilmiştir. Bu katsayılar Faz Uzayı Rekonstrüksiyonu (Phase-Space Reconstruction) kullanılarak iki boyutlu faz uzayı diyagramında çizilmiş ve bu çizimdeki dalgacık katsayıları ile orijin arasındaki Euclidean mesafesi hesaplanarak özellik vektörü çıkarılmış ve Ağırlıklandırılmış Bulanık Üyelik Yapay Sinir Ağı (Neural Network with Weighted Fuzzy Membership (NEWFM)) ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %98.17 olarak elde edilmiştir.

Zhu ve ark. (2014), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerine Hızlı Ağırlıklı Yatay Görünürlük Grafiği Oluşturma Algoritması (Fast Weighted Horizontal Visibility Algorithm) uygulanmış bu algoritma sonucu ortalama derece, ortalama mukavemet elde edilerek özellik vektörü çıkarılmış, çıkarılan özellik vektörü SampEn ve Hızlı Fourier Dönüşümü (Fast Fourier Transform (FFT)) ile çıkarılan özellik vektörü ile

karşılaştırılarak K-NN ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 olarak elde edilmiştir.

Fu ve ark. (2014), yaptıkları çalışmada mevcut işaret kümelerinden A ve E işaret kümelerini kullanmışlardır. EEG işaretlerine Hilbert–Huang dönüşümü uygulanmış elde edilen histogramda piksel yoğunluğunun ortalaması, varyansı, çarpıklığı ve basıklığı gibi istatistiksel özellikler hesaplanarak özellik vektörü çıkarılmış ve RBF-SVM ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.125 olarak elde edilmiştir.

Kang ve ark. (2015), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin Hjorth's'un hareketliliğine dayanan zaman uzayı ayırımı ve FFT kullanılarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü Özbağlaşımlı Model-Çok Katmanlı Algılayıcı Yapay Sinir Ağı (Autoregressive Model-Multilayer Perceptron Neural Network (AR-MLPNN)) ve Hızlı Fourier Dönüşümü -Kuadratik Diskriminant Analizi (Fast Fourier Transform-Quadratic Discriminant Analysis (FFT-QDA)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %99.97 ile AR-MLPNN sınıflandırıcısı ile elde edilmiştir.

Li ve ark. (2016), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerinin beşinci seviye dalgacık dönüşümünün yaklaşım katsayısı ve beşinci, dördüncü, üçüncü, ikinci, birinci seviye dalgacık dönüşümünün detay katsayılarının faz uzayını yapılandırma ve tek değerli kovaryans matrisinin hesaplanması ile özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü Çarpma Aşırı Öğrenme Makinesi (Multiplicative Extreme Learning Machine (M-ELM)), ELM, Geri Yayılım (Backpropagation (BP)) Sigmoid-SVM, RBF-SVM sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A ve E işaret kümeleri için %100 ile M-ELM sınıflandırıcısı ile elde edilmiştir.

Riaz ve ark. (2016), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerine Ampirik Mod Ayırma (Empirical Mode Decomposition (EMD)) algoritması uygulanarak EEG işaretlerinin İç Mod Fonksiyonları (Intrinsic Mode Functions (IMF)) tespit edilmiştir. EMD sonucunda elde edilen IMF, frekans bileşenlerine göre bir işaretin ayrışmasını sağlamaktadır. Elde edilen ilk üç IMF'nin zaman ve frekans uzayında istatistiksel

özellikleri hesaplanarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü SVM ile sınıflandırılmıştır. Sınıflandırma yapılırken veri kümeleri arasında altı ayrı kombinasyon uygulanmış ve maksimum doğruluk A-E işaret kümeleri için %99.00 olarak elde edilmiştir.

Peker ve ark. (2016), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerine üçüncü seviye Çift-Ağaç Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transformation (DTCWT)) uygulanarak 4096 örnekten oluşan EEG işaret kümelerinden her biri için 2048 karmaşık değerli örnek elde edilmiştir. Elde edilen bu karmaşık değerli 2048 örnekten oluşan işaretlerin aritmetik ortalama, medyan, standart sapma, minimum ve maksimum değerler ayrı ayrı hesaplanarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü Karmaşık-Değerli Sinir Ağı (Complex-Valued Neural Network (CVANN)) ile sınıflandırılmıştır. Sınıflandırma yapılırken veri kümeleri arasında dört ayrı kombinasyon uygulanmış ve maksimum doğruluk A-D-E işaret kümeleri için %99.30 olarak elde edilmiştir.

Zhang ve Chen (2016), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerine Yerel Ortalama Ayırma (Local Mean Decomposition (LMD)) algoritması uygulanarak EEG işaretleri alt bantlarına ayrılmıştır. Elde edilen ilk beş alt bandın zaman uzayında maksimum, minimum genliği, ortalama mutlak değeri, dalgalanma aralığı ve enerjisi, Welch GSY ile hesaplanan frekans uzayında maksimumu, çarpıklık, basıklık gibi istatistik özellikleri, Higuchi Fraktal Boyutu (Higuchi Fractal Dimension (HFD)), Hurst Üssü (Hurst Exponent (HE)), RE uygulanarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü K-NN, LDA, Geri Yayılımlı Sinir Ağı (Back Propagation Neural Network (BPNN)), SVM ve Genetik Algoritma (Genetic Algorithm (GA)) ile optimize edilmiş GA-SVM sınıflandırıcıları ile sınıflandırılmıştır. Sınıflandırma yapılırken veri kümeleri arasında dört ayrı kombinasyon uygulanmış ve maksimum doğruluk A ve E işaret kümeleri için %100 ile GA-SVM sınıflandırıcısı ile elde edilmiştir.

Wang ve ark. (2017), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerine dördüncü seviye dalgacık dönüşümü uygulanarak işaretler delta (0–4 Hz), teta (4–8 Hz), alfa (8–16 Hz), beta (16–32 Hz) ve gama (32–64 Hz) alt bantlarına ayrılmıştır. Elde edilen alt

bantların zaman uzayında ortalama, varyans, varyasyon katsayısı, toplam varyasyon, dalgacık dönüşüm katsayılarının maksimum, minimum, ortalama, toplam varyasyon gibi istatistik özellikleri ve FFT katsayıları tarafından tahmin edilen nispi GSY'si hesaplanarak özellik vektörü çıkarılmıştır. Çıkarılmış bu özellikler PCA kullanılarak azaltılmıştır. Veri azaltımından sonra elde edilen özellik vektörü RBF-SVM, K-NN, NB, LDA ve LR ile sınıflandırılmıştır. Çalışmada maksimum doğruluk ABCD-E işaret kümeleri için %99.25 ile RBF-SVM sınıflandırıcısı ile elde edilmiştir.

Li ve ark. (2017), yaptıkları çalışmada mevcut işaret kümelerinden A, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretleri 0.53-40 Hz kesim frekanslarına sahip bir bant geçiren filtre ile ön-işlemden geçirilmiştir. Ön işlemden geçirilen EEG işaretlerine Çift-Ağaç Karmaşık Dalgacık Dönüşümü (Dual-Tree Complex Wavelet Transform (DT-CWT)) uygulanarak işaretler delta (0-4 Hz), teta (4-8 Hz), alfa (8-15 Hz), beta (15-30 Hz) ve gama alt bantlarına ayrılmıştır. Elde edilen alt bantlara HE, HFD ve Permütasyon Entropisi (Permutation Entropy (PE)) uygulanarak özellik vektörü çıkarılmıştır. Elde edilen özellik vektörü K-NN, SVM, DT ve Rasgele Orman Sınıflandırıcısı (Random Forest Classifier (RFC)) sınıflandırıcıları ile sınıflandırılmıştır. Çalışmada maksimum doğruluk A-D-E işaret kümeleri için %98.87 ile SVM sınıflandırıcısı ile elde edilmiştir.

Jaiswal ve Banka (2017), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. EEG işaretlerine Lokal Komşu Tanımlayıcı Desen (Local Neighbor Descriptive Pattern (LNDP)) ve Tek Boyutlu Yerel Gradyan Paterni (One-Dimensional Local Gradient Pattern (1D-LGP)) gibi iki etkili özellik çıkarım yöntemi uygulanarak iki farklı özellik vektörü çıkarılmıştır. Bu iki özellik vektörü ayrı ayrı K-NN, SVM, ANN ve DT sınıflandırıcıları ile sınıflandırılmıştır. Sınıflandırma yapılırken veri kümeleri arasında sekiz ayrı kombinasyon uygulanmış ve maksimum doğruluk A ve E işaret kümeleri için %99.82 ile ANN sınıflandırıcısı ile elde edilmiştir.

Sharma ve ark. (2017), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerindeki gürültü, özellikle güç hattı gürültüsünü ve artefaktları ayıklamak için EEG işaretleri 0.53-40 Hz kesim frekanslarına sahip bir bant geçiren filtre ile ön-işlemden geçirilmiştir. Ön işlemden geçirilen EEG işaretlerinin on altıncı seviye Analitik Zaman-Frekans Esnek

Dalgacık Dönüşümü (Analytic Time-Frequency Flexible Wavelet Transform (ATFFWT)) uygulanarak bir yaklaşım ve on altı adet detay alt bantları elde edilmiştir. Elde edilen alt bantların HFD hesaplanarak özellik vektörü çıkarılmış bu özellikler student's *t*-test kullanılarak azaltılmıştır. Veri azaltımından sonra elde edilen özellik vektörü RBF LS-SVM ile sınıflandırılmıştır. Sınıflandırma yapılırken veri kümeleri arasında sekiz ayrı kombinasyon uygulanmış ve maksimum doğruluk A-E ve B-E işaret kümeleri için %100 olarak elde edilmiştir.

Hussein ve ark. (2018), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada, EEG işaretlerinin frekans spektrumuna robust özellik çıkarım yöntemi olan L1-Cezalandırılmış Robust Regresyon (L1-Penalized Robust Regression (L1-PRR)) modeli uygulanarak özellik vektörü çıkarılmıştır. Önerilen özellik çıkarım yönteminin kas aktivitelerinden, göz kırpmalarından kaynaklanan beyaz gürültü veya yüksek gürültü seviyeleri nedeniyle bozulmuş EEG işaretlerine uygulandığında çok sağlam bir yöntem olduğu kanıtlanmaya çalışılmıştır. Çalışmada RFC kullanılarak ikili, üçlü ve beşli sınıflandırmalar yapılmıştır. Sonuçta maksimum doğruluk A ve E işaret kümeleri için %100 olarak elde edilmiştir.

Acharya ve ark. (2018), yaptıkları çalışmada mevcut işaret kümelerinden B, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada öncelikle EEG işaretlerine Z-skor normalizasyonu, sıfır ortalaması ve standart sapma uygulanarak normalleştirme yapılmıştır. Bu işlemlerden sonra normal, ön-nöbet ve nöbet sınıflarını tespit etmek için on üç katmanlı derin Konvolüsyon Nöral Ağ (Convolutional Neural Network (CNN)) algoritması uygulanmıştır. Çalışmada B-D-E işaret kümeleri için %88.70 doğruluk elde edilmiştir.

Zhang ve ark. (2018), yaptıkları çalışmada mevcut işaret kümelerinden A, B, C, D ve E işaret kümelerini kullanmışlardır. Bu çalışmada EEG işaretlerine WPD uygulanarak işaretler alt bantlarına ayrılmış, her bir alt bandın Bulanık Dağılım Entropisi (Fuzzy Distribution Entropy (fDistEn)) hesaplanarak özellik vektörü çıkarılmış, çıkarılmış bu özellikler Kruskal-Wallis testi kullanılarak azaltılmıştır. Veri azaltımından sonra elde edilen özellik vektörü K-NN ile sınıflandırılmıştır. Çalışmada A ve E işaret kümeleri için maksimum doğruluk %100 olarak elde edilmiştir.



3. MATERYAL VE METOT

3.1. Kullanılan Veri Tabanı


Bu tez çalışmasında veri kümesi olarak kullanılan EEG işaretleri Bonn Üniversitesi Epileptoloji Bölümü (Freiburg Veri Analizi ve Modelleme Merkezi) veri tabanından alınmıştır. Tüm veri tabanı A, B, C, D ve E olmak üzere 5 veri kümesinden oluşmaktadır. Her bir veri kümesi 23.6 saniyelik, 100 tek-kanallı ölçümlerle kaydedilmiş, EEG işaret parçalarını içerir. Her bir kümede 5 kişiye ait 20 adet ölçüm ile alınmış toplamda 100 adet 4096 örnekten (sample) oluşan EEG işareti bulunmaktadır.

A ve B işaret kümeleri, standart 10-20 sistemine göre yerleştirilen yüzeysel elektrotlar yardımıyla ölçülen EEG işaretlerini içerirler. A kümesi, sağlıklı deneklerden uyanık durumda gözleri açıkken ve B kümesi yine aynı deneklerden uyanık durumda gözleri kapalıyken alınan EEG işaretlerini içerir. C ve D işaret kümeleri ise derin elektrotlar kullanılarak kontrol altındaki epilepsi hastası olan deneklerden alınan ve nöbet olmayan durumda kaydedilen EEG işaretlerine sahiptirler. D işaret kümesi epileptojenik bölgeden alınarak kaydedilmiştir ve C işaret kümesi, hasta olan deneklerden nöbet öncesinde hipokampal oluşumlu karşı yarım küreden alınan ölçümlerle kaydedilmiştir. E işaret kümesi ise epilepsi hastası olan deneklerden alınan ve nöbet sırasında kaydedilen EEG işaretlerini içerir.

Tüm EEG kayıtları için aynı 128-kanallı yükseltici sistem ve ortalama ortak bir referans kullanılarak gerçekleştirilmiştir. Daha sonra ölçülen işaretler, 12 bitlik analog-sayısal dönüştürücüden geçirilerek, 173.61 Hz frekansında örneklenerek bilgisayara kaydedilmiştir. Epileptik özellikler kendini (30-40) Hz altındaki frekans bantlarında gösterdiğinden spektral aralığı (0.5-85) Hz olan sinyallere (0.53-40) Hz bant geçiren filtre uygulanmıştır. EEG işaretleri alınırken, işlenirken ve veri tabanına aktarılırken konunun uzmanları tarafından ayarlar kontrolünden geçirilmiştir (Andrzejak ve ark 2001).

A,B,C,D ve E işaret kümeleri için tipik bir EEG işareti Şekil 3.1.'de gösterilmiştir.

Bu çalışmanın amacı EEG işaretlerinden epilepsi hastalığını teşhis etmek için otomatik örüntü tanıma sistemi tasarlamak olduğundan sadece sağlıklı deneklere ait işaretler (A kümesi) ile epilepsi hastası olan deneklerden alınan ve nöbet sırasında kaydedilen epileptik işaretler (E kümesi) kullanılmıştır.



Şekil 3.1. A, B, C, D ve E kümelerine ait EEG işaretleri

3.2. Örüntü Tanıma Sistemleri

3.2.1. Örüntü Nedir

Örüntü, ilgilenilen varlıklar ile ilgili ölçülebilen, gözlenebilen olay veya nesnelerin düzenli bir biçimde birbirini birbirlerini takip ederek oluşturdukları düzenli yapıdır. Ses, insan yüzü, retina, iris, parmak izi, bir metin içerisindeki karakterler, tıbbi cihazlardan alınan görüntüler, Tıbbi cihazlar ile yapılan analiz sonuçları örüntüye dair bazı örneklerdir (Yıldız 2011).

3.2.2. Örüntü Tanıma

Örüntü tanıma, ortak özellikleri olan, aralarında bir ilişki kurulabilen karmaşık olayları ya da nesneleri tespit edilmiş çeşitli yöntemler vasıtası ile tanımlama, kategoriye ayırma veya sınıflandırma işlemidir (Türkoğlu 2002).

Örüntü tanıma ile ilgili aşağıda ifade edildiği gibi farklı kaynaklarda farklı tanımlamalar bulunmaktadır. Fiziksel nesneleri veya meydana gelen olayları önceden belirlenmiş bir veya daha fazla kategoriye ayrılma işlemidir. Çok boyutlu uzayda yoğunluk fonksiyonunu tahmini etmek, bu uzayı kategorilere ya da sınıflara ayırma problemidir. Örüntü tanıma “Bu nedir” sorusuna verilebilecek cevaplarla ilgilenen bilimdir [(Duda ve ark. 2000),(Fukunaga 1990)].

İnsanoğlu sahip olduğu duyu organları yardımı ile çevresindeki örüntüleri belli oranda tanıma yeteneğine sahiptir. Bu yetenekler aldıkları eğitim, edindikleri tecrübe ile artmakta ve seçicilik arz etmektedir. Hava değişiminin algılanması, binlerce çiçeğin algılanıp tanınması, bitki ve hayvan cinslerini tanımlama, konuşma algılama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip etkinliklerde insanlar örüntüleri tanıdıkları halde insan duyularının yeterli olmadığı durumlarda örüntü tanıma işlemini otomatik hale getirmek, işlemleri daha ucuz, iyi ve hızlı hale getirmek için makine ortamında örüntü tanıma yapılmasını arzulamaktadırlar (Yıldız 2011).

Günümüzde optik karakter tanıma, junk e-posta filtreleme, ses, yüz, iris, parmak izi, imza tanıma, otomatik hedef tanıma, baskılı devre denetimi, meyve sınıflandırma, ürün kar tahmini, trafik denetimi, uydu resim yorumlanması, biyomedikal görüntülerin ve işaretlerin sınıflandırılması gibi örüntü tanıma uygulamaları birçok alanda yaygın olarak kullanılmaktadır. Yaklaşık yarım asırdır üzerinde araştırma ve çalışmalar yapılan bu bilim kolu gün be gün ortaya çıkan yeni uygulamalar ile giderek cazibesini artırmaktadır (Günel 2008).

3.2.3. Örüntü Tanıma Sistemi

Yaygın bir örüntü tanıma sistemi, Şekil 3.2.'de gösterildiği gibi üç aşamadan oluşmaktadır. Bunlar sırasıyla algılayıcılar ve ön işlemler, özellik belirleme (öznitelik belirleme) ve sınıflandırma aşamalarıdır.



Şekil 3.2. Örüntü tanıma sistemi blok diyagramı.

Algılayıcılar ve ön işlemler aşaması, fiziksel ortamdan herhangi bir anda algılayıcılarla toplanmış olan sinyallerin çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine, bölütlerine ayırdığı veya modellendiği süreçtir. Özellik belirleme aşaması ham örüntüyü karakterize eden özelliklerinin elde edilebilmesi için çeşitli dönüşüm tekniklerinin uygulandığı, anahtar özelliklerin tespit edildiği gerekiyorsa normalizasyon işleminin gerçekleştirildiği süreçtir. Sınıflandırma aşaması ise özellik belirleme aşamasından sonra örüntüden elde edilen özellikleri kullanarak bir

karar verme mekanizması (sınıflandırıcı) yardımıyla örüntüyü özelliklerine göre kategorize ederek uygun sınıflara ayırma sürecidir [(Yıldız 2011), (Türkoğlu 2002)].

3.2.3.1. Algılayıcılar ve Ön İşlemler

Otomatik örüntü tanıma sisteminin duyu organları olarak adlandırılan algılayıcılar, herhangi bir anda mümkün fiziksel büyüklükleri fiziksel ortalamalardan ölçerek elektronik ekipmanların anlayabileceği veri haline getiren cihazlardır. Fiziksel ortam ile elektronik cihazları birbirine bağlayan bir köprü görevi görürler. Mekanik, termal, elektriksel, manyetik, nem, konum, ışıma, kimyasal vb. birçok fiziksel büyüklüğü ve durumu ölçerek elektronik ortama aktaran algılayıcı bulunmaktadır (Türkoğlu 2002).

Otomatik örüntü tanıma sistemlerinde örüntünün algılandığı gerektiğinde filtrelendiği, bölütlere ayrıldığı çeşitli dönüşüm ve gösterim teknikleri ile işlendiği veya modellendiği kısımdır. Birçok otomatik örüntü tanıma sisteminde bu bölüm örüntü tanıma sisteminin ilk aşaması olarak kabul edilir (Yıldız 2011).

3.2.3.2. Özellik Belirleme

Otomatik örüntü tanıma sistemlerinde özellik belirleme aşamasında amaç, algılayıcılar ve ön işlemler aşamasından alınan, yüksek boyutlu örüntüyü temsil eden, kararlı, gözlenebilen ve ölçülebilen en küçük boyutlu veri ile temsil edebilmektir. Başka bir ifade ile bu bölüm ham örüntünün veri boyutunun indirgendiği ve veri için tanımlayıcı anahtar özelliklerin tespit edildiği bölümdür (Yıldız 2011).

Özellik belirleme aşamasından sonra bir örüntü birden fazla özellik ile temsil ediliyorsa, tek bir özellik yerine bir “özellik kümesi” söz konusudur. Burada d adet özelliğe sahip özellik kümesi d -boyutlu “özellik vektörü” ile temsil edilir. Özelliklerin içinde bulunduğu d –boyutlu R^d uzayı ise “özellik uzayı” olarak adlandırılır (Günel 2008).

Özellik belirleme aşamasında, ham örüntüyü temsil eden bu özellik kümesi elde edilirken aslında birbiriyle ilişkili iki bölümden oluşan ve aşağıda açıklanan yol izlenir (Yıldız 2011).

a) Özellik Çıkarma: Özellik çıkarma otomatik örüntü tanıma sistemlerinin en önemli bölümü olup en temel anlamda algılayıcılar ile kaydedilmiş ve ön işlem aşamasında düzenlenmiş örüntünün boyut indirgeme işlemlerinin gerçekleştirildiği bölümdür. Otomatik örüntü tanıma sistemlerinde sınıflandırma işleminde giriş

vektörlerinin seçimi gerçekten çok hassas ve önemli bir konudur. Girişler kötü ve gereksiz bilgi içerdiğinde bilinen en iyi sınıflandırıcı kullanılsa bile başarımların performansı kötü olacağı gibi gereksiz zaman ve kaynak israfına da neden olacaktır. Bu olumsuzlukları gidermek için örüntüye ait fazla ve gereksiz bilginin elenip sadece örüntüyü temsil eden az sayıdaki karakteristik bilginin elde edildiği dönüşüme özellik çıkarma adı verilir (Yıldız 2011).

b) Özellik Seçme: Otomatik örüntü tanıma sistemlerinde özellik çıkarma işlemleri sonucu örüntünün boyutu büyük oranda azaltılır. Buna karşın elde edilen bu özellik kümesi içindeki bazı özellikler örüntü ile ilişkisiz (irrelevant) olabileceği gibi bazı özellikler de örüntüyü temsil etmede fazlalık (redundant) teşkil edebilir. Örüntüde bulunan ilgisiz veya gereksiz özellikleri uzaklaştırmak, veri dağılımının daha uygun ve ayrıştırılabilir bir hale getirmek sınıflandırıcıların daha etkin kullanılmasında faydalı bir durumdur. Özellik seçme ile sınıflandırıcıların performansı ve çalışma süresi arttığı gibi, donanım maliyeti de azalır. Özellik seçme bölümünde özellik çıkarma bölümünden elde edilen örüntüden istenmeyen bazı özellikler belli yöntemler ile çıkarılır ve örüntüyü temsil eden en iyi özellik alt kümesi elde edilir. [(Yıldız 2011), (Güler ve Übeyli 2005)].

3.2.3.3. Sınıflandırma

Otomatik örüntü tanıma sistemlerinde bilinmeyen bir örüntüyü tanımlayabilmek için özellik belirleme bölümünden sonra sınıflandırma işlemi yapılır. Sınıflandırma işlemi iki veya daha fazla türü, sınıfı, nesneyi, olayı veya örüntüyü tanıma, tanımlama, kategorize etme veya birbirinden ayırt etme işlemidir. Daha genel bir ifade ile sınıflandırma kavramı bilinmeyen bir veri nesnesi üzerinde tanımlı olan çeşitli sınıflar arasında veriyi belli bir kurala göre dağıtmaktır [(Yıldız 2011), (Aydilek 2013)].

Sınıflandırma işlemi, verilerin veya örüntülerin davranışları hakkında bilgi vermekle kalmaz aynı zamanda araştırmacılar açısından, konunun daha açık ve net bir şekilde anlaşılmasına yardımcı olur (Özkan 2008).

Sınıflandırma işlemi kullanılan öğrenme yöntemlerine göre genel olarak güdümlü ve güdümsüz öğrenme olmak üzere iki grupta incelenir. Güdümlü öğrenmede, ilgilenilen örüntüler ve bu örüntülerin ait olduğu sınıflar önceden bilindiğinden özellik vektörünün oluşturduğu veri kümeleri ile sınıflandırıcı bir eğitim sürecinden geçirilir. Bu eğitim sonucunda, bilinmeyen örüntüyü uygun sınıfa atamakta

kullanılan bir model oluşturulur. GÜDÜMSÜZ ÖĞRENMEDE ise sınıflandırıcıya eğitim esnasında sadece ilgilenilen örüntülerin belirlenmiş özellikleri gösterilerek bunlar arasındaki benzerlik, uzaklık, boyut, renk vb. önsel olasılıklar ve bilgiler verilerek bir model oluşturulur [(Yıldız 2011), (Günel 2008)].

3.3. Özellik Belirleme Yöntemleri

Otomatik örüntü tanıma sistemlerinde EEG gibi durağan olmayan biyolojik işaretlerden fizyolojik veya patolojik bir durumun tespit edilmesi oldukça zordur. Çünkü işaret durağan olmadığından örüntüyü karakterize eden asıl bilgi işaret içerisinde zamana yayılmış ve gömülü durumdadır. Aynı zamanda bu işaretler sürekli değişen formda olduklarından kısa süreli değişiklikler ve karmaşık dalga formları büyük önem arz etmektedir. Genelde boyutu yüksek ve yapısı karmaşık olan EEG işaretleri kullanılarak tasarlanan bir örüntü tanıma sisteminde özellik belirleme örüntü tanıma sisteminin en önemli bölümlerinden biridir. Yanlış seçilecek bir özellik belirleme yöntemi örüntüyü karakterize eden önemli bilgilerin yok olmasına neden olabileceği gibi sınıflandırma aşamasında da gereksiz zaman ve donanım israfına neden olabilir. Bu sebeple özellik belirleme aşamasında ham örüntü gereksiz ve ilişkisiz bilgilerden arındırılmalı ve mümkün olan en küçük boyutlu veri ile temsil edilmelidir.

Bu tez çalışmasında EEG işaret örüntülerine ait özellikleri belirlemek amacı ile güç spektral yoğunluk kestirimine dayalı yöntemler ve ortalama kullanılmıştır. Tez çalışmasında kullanılan bu özellik belirleme yöntemleri aşağıda sunulmuştur.

3.3.1. Güç Spektral Yoğunluk Kestirimi (GSY)

Güç spektral yoğunluğu (GSY), bir işaretin frekans bandı üzerindeki spektral bilgilerini ve güç dağılımını bulmak olarak ifade edilebilir. GSY kestirim yöntemleri genelde parametrik olmayan yöntemler ve parametrik yöntemler olarak iki sınıfa ayrılır. Fakat bazı kaynaklarda bu iki sınıfa ek olarak alt uzay yöntemleri de ayrı bir sınıf olarak değerlendirilmektedir. Parametrik olmayan GSY yöntemlerinde işaretin kendisi direk olarak değerlendirilmektedir. İşaretin nasıl üretildiği konusunda ortaya herhangi bir varsayım konulmamaktadır. Parametrik GSY yöntemlerinde ise işaret, beyaz gürültü işareti uygulanmış doğrusal ayırık zamanlı bir filtrenin çıkışı olarak kabul edilmektedir. GSY hesaplanırken de oluşturulan bu modelin parametreleri kullanılmaktadır (Yıldız 2011).

Parametrik olmayan GSY kestirim yöntemlerine örnek olarak, Fourier Dönüşümü, Periodogram, Bartlett and Welch metotları verilebilir. Parametrik olmayan GSY yöntemleri nispeten basit algoritmalar kullandıklarından parametrik yöntemlere göre daha az işlem yükü gerektirirler. Bu sebeple hızlı çalışmakla birlikte oluşan kaçaklardan dolayı spektrum bozulmakta ve zayıf sinyaller maskelenmektedir. Bu sebeple kısa süreli işaretlerde frekans çözünürlüğü iyi olmamaktadır (Albayrak 2008).

Parametrik GSY yöntemlerinde elde edilen kestirim performansı iyi olmasına rağmen, işlem yükü fazla olduğundan, daha fazla zaman ve daha güçlü donanım gerekmektedir. Yule-Walker, Burg ve Kovaryans gibi yöntemler parametrik GSY kestirim yöntemlerine örnek olarak verilebilir (Özbeyaz 2010).

3.3.1.1. Periodogram Güç Spektral Yoğunluk Kestirim Metodu

Periodogram GSY kestirim metodu Ayrık Fourier Dönüşümü temeline dayanan klasik bir GSY yöntemi olup 1898 yılında İngiliz fizikçi Sir Arthur Schuster tarafından geliştirilmiş ve güneş lekelerinin sayısının periyodikliği üzerine yapmış olduğu çalışmada kullanılmıştır. GSY temel olarak otokorelasyon fonksiyonunun Fourier Dönüşümü olarak da tanımlanabilmektedir. Sonlu enerjisi olmayan ve dolayısıyla Fourier Dönüşümü alınamayan istikrarlı rasgele sinyaller bir ortalama güce sahiptir ve GSY ile karakterize edilirler (Bozdağ 2002).

$x(t)$ durağan rastgele bir sinyali göstermektedir ve (3.1)'deki gibi tanımlanabilir.

$$x(t) = [x_K] = [x_0, x_1, x_2, \dots, x_{N-1}] \quad (3.1)$$

N örnekten oluşan $[x_K]$ işaretinin Periodogramı ($P_{xx}(f)$), (3.2)'de ifade edildiği üzere $[x_K]$ işaretinin AFD'sinin karesine karşılık gelmektedir.

$$P_{xx}(f) = |F(jw)|^2 \quad (3.2)$$

Periodogramı alınan işaretin N adet veri noktası olduğundan en az N noktada AFD hesaplanır ve $f_k = k/N$ frekansında (3.3)'teki gibi ifade edilir (Dursun 2009).

$$P_{xx}\left(\frac{k}{N}\right) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \right|^2 \quad k = 0, 1, 2, \dots, N-1 \quad (3.3)$$

3.3.1.2. Bartlett Güç Spektral Yoğunluk Kestirim Metodu

Periyodogramların ortalaması olarak ta adlandırılan Bartlett GSY kestirim metodu periyodogramdaki varyansı indirmek için 1948 yılında İngiliz istatistikçi Maurice Stevenson Bartlett tarafından ortaya atılmıştır. Bartlett metodu üç aşamadan meydana gelmektedir. Birinci aşamada, N örnek uzunluğundaki veri dizisi örtüşmeyen K adet bölüte ayrılır. Her bölütün uzunluğu M olan K adet veri bölümü için veri yapısı:

$$X_i(n) = x(n + iM) \quad i = 0, 1, \dots, K-1 \quad n = 0, 1, \dots, M-1 \quad (3.4)$$

(3.4)'teki gibi ifade edilir ve her bir bölüm için ayrı ayrı Periodogram hesabı yapılır.

$$P_{xx}^{(i)}(f) = \frac{1}{M} \left| \sum_{n=0}^{M-1} x_i(n) e^{-j2\pi fn} \right|^2 \quad i = 0, 1, \dots, K-1 \quad (3.5)$$

Son aşamada Bartlett GSY kestirimini hesaplamak için ise K adet bölüm için hesaplanmış Periodogramlarının ortalaması alınır (Dursun 2009).

$$P_{xx}^{(B)}(f) = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx}^{(i)}(f) \quad (3.6)$$

3.3.1.3. Welch Güç Spektral Yoğunluk Kestirim Metodu

İyileştirilmiş periyodogramların ortalaması olarak da adlandırılan Welch GSY kestirim metodu 1967 yılında Amerikalı bilim adamı Peter D. Welch tarafından ortaya atılmış ve Bartlett GSY kestirim metoduna göre iki yenilik eklenmiştir. İlk olarak, Welch GSY kestirim metodunda veri bölütlerinin örtüşmesine izin verilmektedir. İkinci olarak, her veri bölütüne pencereleme işlemi uygulanmaktadır. Welch GSY metodu ile kestirim yapılırken kestirim işlemleri üç aşamada gerçekleştirilir.

Öncelikle N örnek uzunluğundaki veri dizisi bir biri ile örtüşen L adet bölüte ayrılır. Her bir bölütünün örnek uzunluğu M olan L adet veri bölütü için veri yapısı:

$$X_i(n) = x(n + iD) \quad n = 0, 1, \dots, M - 1 \quad i = 0, 1, \dots, L - 1 \quad (3.7)$$

(3.7)'deki gibi ifade edilir. Burada iD i . veri dizisinin başlangıç noktasını ifade etmektedir. $D=M$ olması halinde bölütlerde örtüşme yoktur. Buradaki veri bölütlerinin L sayısı Bartlett GSY'deki K sayısı ile aynıdır. Örtüşmenin olması için $M > D$ olmalıdır. $D=M/2$ olması halinde ise ardışık veri bölütleri arasında %50 örtüşme vardır ve $L=2K$ olarak bulunur (Proakis 1992).

Burada işareti örtüşecek şekilde bölütlemenin amacı sonraki aşamalarda kullanılan pencere fonksiyonunun neden olduğu bilgi kaybını gidermektir. Genelde bölütler arasında örtüşmenin %50 ile %75 arasında olması tavsiye edilmektedir (Yıldız 2011).

İkinci aşamada örtüştürülmüş her bir veri bölütü uygun bir $w(n)$ pencere fonksiyonu ile pencerelenerek Periodogramı alınır. Böylece (3.8)'de ifade edildiği üzere her veri bölütünün iyileştirilmiş Periodogramı alınmış olur.

$$P_{xx}^{(i)}(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n) w(n) e^{-j2\pi fn} \right|^2 \quad i = 0, 1, \dots, L - 1 \quad (3.8)$$

(3.8)'de kullanılan U pencere fonksiyondaki güç normalizasyon faktörü olup (3.9)'da ifade edilmiştir.


$$U = \frac{1}{M} \sum_{n=0}^{M-1} w(n)^2 \quad (3.9)$$

Son aşamada L adet veri bölütüne ait iyileştirilmiş Periodogramların ortalaması alınarak N örnek uzunluğundaki işaretin Welch GSY kestirimi bulunmuş olur.

$$P_{xx}^W = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}^i(f) \quad (3.10)$$

3.3.1.4. Pencereleme İşlemi

GSY yaklaşımlarında pencereleme işleminin amacı spektral sızıntı etkilerini bir pencere fonksiyonu yardımı ile azaltmaktır. Bir işaret ister zaman isterse spektral bölgede analiz edilsin bu işaretin ne şekilde bölütlere ayrılacağı önemlidir. En basit hali ile bir işaretin sadece belli bir bölümü sınırlı donanımına sahip bir bilgisayar ile işlenebilir. Bu durum işarete dikdörtgen bir pencere uygulanması anlamına gelmektedir. Pencereleme işlemi zaman yahut frekans bölgesinde uygulanabilmektedir. GSY kestiriminde pencere seçimi önemli bir faktördür. Çünkü seçilen pencerenin karakteristiği GSY kestirim sunucunu etkilemektedir. Bu sebeple bir kestirim yapılırken farklı yapıdaki pencere fonksiyonları ile denemeler yapılması ve en uygun pencere fonksiyonunun seçilmesi gerekmektedir. Literatürde en sık kullanılan pencere fonksiyonları grafiksel gösterimleri Şekil 3.3'te verilmiştir.



Şekil 3.3. Pencere fonksiyonları.

3.3.2. Aritmetik Ortalama (AO)

Aritmetik Ortalama (AO), bir sayı dizisindeki elemanların toplamının dizinin eleman sayısına bölünmesi sonucu elde edilen değerdir.

$$\text{Aritmetik Ortalama} = \frac{\sum_{i=1}^n x_i}{n} \quad (3.11)$$

3.4. Sınıflandırma Yöntemleri

Sınıflandırma basit bir anlatım ile bilinmeyen bir örüntünün yahut bir veri nesnesinin üzerinde tanımlı bulunan çeşitli sınıflar arasında veriyi belli bir kurala göre dağıtmaktır. Burada bir problemi çözmek için elde bulunan verilerin kullanılması ile problemin çözümüne giden yolun öğrenilmesi, deneyimlerin elde edilmesi ve öğrenilen bu yolun yeni verilerin ayrıştırılması veya yeni problemlerin çözülmesi için kullanımı amaçlanmaktadır. Bir otomatik örüntü tanıma sisteminde sistemin başarısı örüntüyü tanımlayan özellik seçme yöntemlerine bağlı olmakla birlikte kullanılacak sınıflandırma yöntemleri ile de çok yakından ilintilidir. Örüntünün yapısı, özellik seçme yöntemleri uygulandıktan sonra elde edilen özelliklerin yapısı, boyutu, birbirleri ile ilişki durumları, karmaşıklığı vb. durumlara göre seçilecek sınıflandırma yöntemleri farklılık gösterebilmektedir. Yaygın olarak kullanılan sınıflandırma yöntemlerinden bazıları aşağıda verilmiştir.


- a) Karar Ağaçları
- b) Yapay Sinir Ağları
- c) Bayes Sınıflandırıcılar
- d) Genetik Algoritmalar
- e) Örnek Tabanlı Yöntemler
- f) Saklı Markov Modeller
- g) K- En Yakın Komşu Algoritması
- h) Destek Vektör Makineleri
- ı) Aşırı Öğrenme Makineleri

Bu tez çalışmasında, EEG işaretlerinden epilepsi hastalığının tespitini yapan otomatik örüntü tanıma sisteminin sınıflandırmasında K-NN, SVM ve ELM sınıflandırma yöntemleri kullanılmıştır. Tez çalışmasında kullanılan bu sınıflandırma yöntemleri aşağıda sunulmuştur.

3.4.1. K-En Yakın Komşuluk Algoritması (K-NN)

K-NN 1967 yılında T.M. Cover ve P. E. Hart tarafından ortaya atılmış, sıkça kullanılan, basit, yorumlaması kolay, güdümlü ve örnek tabanlı bir öğrenme algoritmasıdır (Cover 1967). K-NN parametrik olmayan basit bir öğrenme algoritması olduğundan temel veri dağılımında herhangi bir varsayım yapmaz. Bu durum, pratik verilerin yapılan teorik varsayımlara uymaması sürecinde K-NN için bir avantaj sağlar. Ayrıca, K-NN genelleme yapmak için eğitim verilerini kullanmadığından eğitim süreci oldukça hızlıdır. K-NN örnek tabanlı öğrenme algoritması olduğundan, karar işlemi eğitim setinde tutulan verilere dayalı olarak gerçekleştirilmektedir (Anchalia 2014).

K-NN uzaklığa bağlı olarak değerlendirme yapan bir öğrenme algoritmasıdır. K-NN’de eğitim verisinde yer alan her bir örnek bir noktayı temsil edecek biçimde n boyutlu bir özellik uzayında sayısal nitelikler ile belirtilir. Algoritma yeni bir veri örneği ile karşılaştığında yeni örneğin eğitim verisinde yer alan her bir örneğe olan uzaklığı hesaplanır. Hesaplama sonrası sınıf etiketleri önceden bilinen veri örneklerinden K adet en yakın komşusu bulunur. Yeni veri örneği K en yakın komşusunun çoğunluk teşkil ettiği ilgili sınıfa atanır. Şayet $K=1$ ise, sınıfı tespit edilmeye çalışılan yeni veri örneği en yakın komşusunun ait olduğu sınıfa atanır. Şayet $K=3$ ise, sınıfı tespit edilmeye çalışılan yeni veri örneğinin en yakın üç komşusu dikkate alınarak ilgili sınıfa atanır. Şekil 3.4.’te iki sınıfa ait veri örneklerinin bulunduğu uzayda, sınıfı bilinmeyen yeni bir veri örneğinin K-NN algoritmasıyla sınıflandırma süreci gösterilmiştir. Şekil 3.4.’te görüldüğü gibi $K=3$ için sınıfı bilinmeyen yeni bir veri örneğine uzaklıkları $d1$, $d2$ ve $d3$ olan iki sınıfa ait en yakın 3 komşu belirlenmiştir. Bu süreç sonucunda en yakın üç komşunun ikisi Sınıf 2’de olduğundan yeni veri örneği Sınıf 2’ye atanmıştır (Polat 2016).



Şekil 3.4. $K=3$ için K-NN sınıflandırma süreci

3.4.1.1. K-NN Algoritmasının Parametreleri

a) K Parametresi: K verilen bir veri örneğine en yakın komşuların sayısını gösteren bir parametredir. K-NN algoritmasında K parametresi algoritmanın başarısını etkileyen önemli faktörlerden biri olduğu için K parametresinin uygun seçilmesi çok önemlidir. Şayet K parametresinin değeri çok büyük seçilirse farklı sınıflara veri örnekleri aynı sınıfa atanabilir. K parametresi çok küçük seçildiği durumda ise tam tersi şekilde aynı sınıfta atanması gereken örnekler farklı sınıflara atanabilir. K parametresini seçmek için birçok yöntem geliştirilmesine rağmen en yaygın kullanım veri setini çeşitli K değerleri ile deneyerek en uygun değerin tespit edilmesidir. Bu işlem zaman ve iş gücü kaybına neden olmaktadır (Mitchell 1997).

b) Uzaklık Ölçütleri: K-NN algoritmasında sınıflandırma, seçilen K parametresine göre K tane en yakın komşunun tespit edilmesi ile gerçekleştirilir. En yakın komşuların tespit edilmesi için sınıflandırılmaya çalışılan veri örneğinin eğitim kümesinde yer alan her veriye olan uzaklığının ayrı ayrı bulunması gerekir. İki veri arasındaki uzaklığın büyük olması benzerliğin az, uzaklığın küçük olması ise benzerliğin çok olduğu şeklinde değerlendirilir. Bu uzaklığın bulunmasında Minkowski, Euclidean, Manhattan, Chebyshev, Mahalanobis, Cosine, Hamming, Canberra, Bray-Curtis, Relative Deivation, Square Chord gibi farklı yöntemler kullanılır. Bu uzaklıklardan en sık kullanılanların hesaplanması için eşitlikler (3.12), (3.13), (3.14) ve (3.15)'te verilmiştir (Polat 2016).

b1) Minkowski Uzaklığı: Öklid uzayında tanımlı, sınıflandırma, kümeleme ve veri madenciliği uygulamalarında sıklıkla kullanılan Eculidean uzaklığı, Manhattan uzaklığı gibi uzaklık ölçütlerinin genelleştirilmiş halidir. Herhangi iki P ve Q noktası arasındaki Minkowski uzaklığı $P=(x_1, x_2, \dots, x_n)$ ve $Q=(y_1, y_2, \dots, y_n)$ olmak üzere, (3.12)'deki eşitlik ile hesaplanır (Taşçı 2016).

$$D = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (3.12)$$

b2) Eculidean uzaklığı: Sınıflandırma, kümeleme ve veri madenciliği uygulamalarında sıklıkla kullanılan Eculidean uzaklığı, Minkowski uzaklık ölçütünün özel bir durumu olup $p=2$ olarak atanması ile elde edilir. K-NN algoritmalarında

uzaklığın tespit edilmesi için kullanılan temel uzaklık ölçütüdür. $P=(x_1, x_2, \dots, x_n)$ ve $Q=(y_1, y_2, \dots, y_n)$ olmak üzere, (3.13)'teki eşitlik ile hesaplanır (Taşçı 2016).

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.13)$$

b3) Manhattan uzaklığı: n boyutlu iki nokta arasındaki farkların mutlak değerlerinin toplamıdır. Minkowski uzaklık ölçütünün özel bir durumu olup $p=1$ olarak atanması ile elde edilir. $P=(x_1, x_2, \dots, x_n)$ ve $Q=(y_1, y_2, \dots, y_n)$ olmak üzere, (3.14)'teki eşitlik ile hesaplanır (Taşçı 2016).

$$D = \sum_{i=1}^n (|x_i - y_i|) \quad (3.14)$$


b4) Chebyshev uzaklığı (Maksimum Değer Uzaklığı): Minkowski uzaklığının, $n \rightarrow \infty$ olduğu özel durum olup, iki nokta arasındaki farkların mutlak değerlerinin maksimumu olarak ifade edilmektedir. $P=(x_1, x_2, \dots, x_n)$ ve $Q=(y_1, y_2, \dots, y_n)$ olmak üzere, (3.15)'teki eşitlik ile hesaplanır (Taşçı 2016).

$$D = \lim_{p \rightarrow \infty} \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} = \max(|x_i - y_i|) \quad (3.15)$$

Sayısal olarak ifade edilen iki veri örneğinin birbirine olan uzaklıklarının tespit edilmesinde yukarıda verilen yöntemlerin kullanılması oldukça uygundur. Bununla beraber sayısal olarak belirtilemeyen cinsiyet, renk ve ırk gibi kategorik özelliklerin birbirine olan uzaklıklarını hesaplamak için Hamming uzaklık ölçütü geliştirilmiştir. Hamming uzaklık ölçütünde aynı niteliklerle verilen özellikler arasındaki uzaklık 0, farklı niteliklerle verilen özellikler arasındaki uzaklık ise 1 olarak kabul edilir (Polat 2016).


3.4.1.2. K-NN Algoritmasının Çalışma Aşamaları

K-NN algoritması dört aşamadan oluşur. Birinci aşamada, öncelikle K değeri belirlenir ve eğitim verileri bilinen sınıflara atanır. Bu işlem Şekil 3.5.'te gösterilmiştir.



Şekil 3.5. Eğitim verisinin bilinen sınıflara atanması

İkinci aşamada sınıfı bilinmeyen yeni veri örneği yüklenir ve bu yeni veri örneğinin farklı sınıflardaki bütün verilere olan uzaklığı ayrı ayrı hesaplanır. Bu işlem Şekil 3.6.'da gösterilmiştir.



Şekil 3.6. Uzaklıkların hesaplanması


Üçüncü aşamada sınıfı bilinmeyen yeni veri örneğinin eğitim verisinde yer alan verilere olan uzaklığı sıralanır ve seçilen K parametresine göre minimum uzaklığa bağlı

olarak en yakın K adet komşu tespit edilir. Tablo 3.1.'de yeni veri örneğinin $K=3$ için en yakın 3 komşusu sırasıyla gösterilmiştir.

Tablo 3.1. Yeni veri örneğinin $K=3$ için en yakın 3 komşusu ve ait oldukları sınıflar

En Yakın Komşular	Ait Oldukları Sınıflar
y	Sınıf 2
w	Sınıf 2
e	Sınıf 1

Dördüncü ve son aşamada sınıfı tespit edilmek istenen yeni veri örneği K-NN algoritması tarafından tespit edilen K adet en yakın komşunun ait oldukları sınıflar dikkate alınarak, en fazla komşunun ait olduğu sınıfa atanır. Tablo 3.1.'de görüldüğü gibi tespit edilen yakın 3 komşudan 2'si Sınıf 2'ye, 1'i ise Sınıf 1'e aittir. Bu durumda yeni veri örneği, K-NN algoritması tarafından Sınıf 2'ye atanır. Şekil 3.7.'de yeni veri örneği ait olduğu sınıfa atandığı gösterilmiştir (Polat 2016).




Şekil 3.7. Yeni veri örneğinin sınıflandırılması

3.4.2. Destek Vektör Makineleri (SVM)

SVM ilk olarak 1992 yılında Vapnik tarafından önerilmiş, bilim adamlarınca zaman içerisinde geliştirilmiş, sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinde oldukça başarılı ve yaygın olarak kullanılan bir yöntemdir. Günümüzde SVM ses, yüz, nesne, yazı vb. örüntü tanıma, fonksiyon tahmini, mühendislik, genetik, bilgi güvenliği, zaman serilerinin tahmini, biyoenformatik vb. birçok alanda başarı ile

uygulanan bir yöntemdir. SVM başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için ortaya atılmasına rağmen zaman içerisinde matematiksel alt yapısı geliştirilerek doğrusal olmayan ve çok sınıflı verilerin sınıflandırılması için genelleştirilmiştir. SVM temelde üç ana bileşenden meydana gelmiştir. Bu bileşenler istatistiksel öğrenme teorisi, optimizasyon algoritması ve çekirdek fonksiyonlarıdır [(Yıldız ve ark. 2011), (Burges 1998)].

SVM, ikili sınıflandırma problemlerinde oldukça önemli başarılar elde etmektedir. Şekil 3.8.'de gösterildiği gibi iki farklı veri sınıfını ayırmak için birden fazla doğrunun çizilme ihtimali vardır. En uygun ayırıştırıcı doğru belirlenirken veri sınıflarına eşit ve maksimum mesafede olanı tespit edilmelidir. Sınır (Margin) olarak isimlendirilen bu maksimum mesafe belirlenirken, veri sınıflarına ait örnekler arasında ayırıştırıcı doğruya en yakın örnekler kullanılır. Bu örnekler destek vektörler olarak isimlendirilir. Yapay sinir ağlarında en iyi genellemeyi elde etmek için ağırlıkların güncellenmesi ne kadar önemliyse, SVM ile yapılan sınıflandırmada en uygun doğru ve sınırın belirlenmesi o derecede önemlidir. Çok boyutlu uzayda doğruların yerini hiperdüzlemler almaktadır [(Emhan 2017), (Yıldız 2011), (Aydemir 2008)].



Şekil 3.8. İki veri sınıfını ayıran hiperdüzlemler

SVM, sınıflandırılacak verinin durumuna göre iki ayrı bölümde incelenebilir. Bunlar; doğrusal destek vektör makineleri ve doğrusal olmayan destek vektör makineleridir.

3.4.2.1. Doğrusal Destek Vektör Makineleri

Günümüzde pratik uygulamalarda yaygın olarak kullanılmamakla birlikte SVM algoritmasının temelini inşa ettiğinden oldukça önemlidir. Doğrusal destek vektör makineleri kendi içinde verilerin doğrusal olarak ayrılabilme ve doğrusal olarak ayrılama durumu olmak üzere iki başlıkta incelenmektedir.

a) Doğrusal Olarak Ayrılabilme Durumu

SVM'nin eğitim için kullanılacak iki sınıflı n sayıda örnekten oluşan bir eğitim veri kümesi $\{x_i, y_i\}$ $i=1, \dots, n$ ve $y_i \in \{-1, +1\}$, şeklinde kabul edilsin. Burada $y_i \in \{-1, +1\}$ sınıflara ait etiket değerlerini $x_i \in R^d$ olup d -boyutlu özellik vektörünü göstermektedir. Bu iki sınıfın eğitim verileri doğrusal olarak ayrılabilme durumunda bir hiperdüzlem ile ayrılacaktır. Ancak daha öncede ifade edildiği gibi bu iki veri sınıfını ayırabilecek sonsuz sayıda hiperdüzlem bulunmaktadır. Ancak SVM'nin amacı veri sınıflarını birbirinden ayıracak, veri sınıflarına eşit ve maksimum mesafede optimal hiperdüzlemi tespit etmektir. Doğrusal olarak ayrılabilme durumunda hiperdüzlem (3.16)'daki ifade ile tanımlanır.

$$f(x) = w^T \cdot x + b = \sum_{i=1}^n w_i x_i + b \quad (3.16)$$


(3.16)'daki ifade de w herhangi bir x noktası için hiperdüzlemin normalini, $|b|/\|w\|$ hiperdüzlemin orijin noktasına olan dik uzaklığını, b sapma değerini göstermektedir. Doğrusal ayrılabilme durumu için hiperdüzlem Şekil 3.9.'da gösterilmiştir. Hiperdüzlem üzerindeki herhangi bir x noktası (3.17)'de verilen koşulu sağlamaktadır.

$$f(x) = w^T \cdot x + b = 0 \quad (3.17)$$

SVM eğitim veri kümesini doğrusal olarak ayırabiliyorsa $y_i = +1$ ve $y_i = -1$ şeklinde tanımlı veri örneklerine uygun optimum hiperdüzlem bulunabilir. Bunun için eğitim veri kümesinin (3.18) ve (3.19)'da belirtilen bağıntıları sağlaması gerekmektedir:

$$w^T \cdot x_i + b \geq +1, \quad y_i = +1 \text{ için} \quad (3.18)$$

$$w^T \cdot x_i + b \leq -1, \quad y_i = -1 \text{ için} \quad (3.19)$$



Şekil 3.9. Doğrusal olarak ayrılabilen veriler için SVM

(3.18) ve (3.19)'da verilen iki eşitsizlik tek eşitsizlik ile ifade edildiğinde (3.20)'deki eşitsizlik elde edilir.

$$y_i(w^T \cdot x_i + b) - 1 \geq 0 \quad (3.20)$$

SVM'ye verilen eğitim veri kümesi için olası tüm hiperdüzlemler (3.20)'deki eşitsizlik ile temsil edilebilir. Burada optimum hiperdüzlemin belirlenmesi için bu hiperdüzlemi karşılayacak uygun w ve b değerleri bulunmalıdır. (3.18)'deki bağıntının eşitlik durumu $w^T x_i + b = +1$, Şekil 3.9.'daki C2 sınıfını ayıran D2 hiperdüzleme, (3.19)'daki bağıntının eşitlik durumu $w^T x_i + b = -1$, Şekil 3.9.'daki C1 sınıfını ayıran D1 hiperdüzleme, karşılık geldiği kabul edilirse; D1 ve D2 hiperdüzlemlerinin orijine olan dik uzaklıkları sırasıyla $|1 - b|/\|w\|$ ve $|-1 - b|/\|w\|$ olacaktır. Her iki hiperdüzlemin optimum hiperdüzleme D0 ($w^T x_i + b = 0$) olan uzaklıkları da $1/\|w\|$ olacaktır. Bu iki hiperdüzlem veya başka bir deyişle eğitim kümesine ait iki veri kümesi arasındaki uzaklık $2/\|w\|$ olur. Burada D1 ve D2 hiperdüzlemlerin aynı normale sahip oldukları yani paralel oldukları görülmektedir. Burada hiperdüzlemlerin arasında eğitim veri kümesine ait hiçbir veri örneğinin olmamasına dikkat edilmelidir. D1 ve D2 hiperdüzlem arasındaki uzaklık ($2/\|w\|$) olup sınır (margin) olarak isimlendirilir. SVM ile yapılmaya çalışılan D1 ve D2 hiperdüzlemin arasındaki sınırı maksimize etmektir.

Dolayısıyla iki hiperdüzlem arasındaki maksimum sınır Euclid normunun yani ($\|w\|$ değerinin) minimize edilmesiyle bulunur. Aralarındaki sınır değeri maksimum olan iki hiperdüzlem üzerindeki veri örnekleri *Destek Vektörleri* olarak adlandırılır[(Acar 2012), (Yıldız 2011)].

Maksimum sınırı bulunma işlemi için, $\|w\| = \sqrt{w^T \cdot w}$ ifadesi eşitlik (3.21)'de yerine konularak;

$$f = \|w\|^2 = \frac{w^T \cdot w}{2} \quad (3.21)$$

$$y_i(w^T \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, 3, \dots, n \quad (3.22)$$

sırasıyla minimizasyon için (3.21) eşitliği ve kısıtlama için (3.22) eşitsizliği elde edilir. Burada; (3.21)'deki eşitlik çözülecek problemi, (3.22)'deki eşitsizlik ise bu problemin çözümünde kullanılacak kısıtlamayı (koşulu) göstermektedir. Yukardaki ifadeler incelendiğinde problemin ikinci dereceden bir optimizasyon problemi olduğu görülmektedir. Mevcut optimizasyon problemi, ikinci dereceden programlama tekniğinin kullanılmasıyla çözülebilmektedir. Bununla beraber, yüksek boyutlu uzaylar için problemin şu anki formda çözülebilmesi çok pratik değildir. Bu nedenle problem pratik olarak çözülebileceği ikincil (dual) forma dönüştürülerek çözülür. İkincil forma dönüştürülerek çözülen problemin çözümü problemin orijinal çözümüne eşdeğerdir. Problemin ikincil forma dönüştürülmesi iki basamakta gerçekleştirilir.

Birinci aşamada; problemin çözümünü kolaylaştırmak amacı ile Lagrange çarpanları yöntemi kullanılarak, (3.21)'deki eşitlikle gösterilen kısıtlamalı optimizasyon problemi, (3.23) eşitlikle gösterilen kısıtlamasız optimizasyon problemi biçiminde tekrar yazılır.

$$\begin{aligned} L_{primal}(w, b, \alpha) &= \frac{w^T \cdot w}{2} - \sum_{i=1}^n \alpha_i [y_i(w^T \cdot x_i + b) - 1] \\ &= \frac{w^T \cdot w}{2} - \sum_{i=1}^n \alpha_i y_i w^T \cdot x_i - \sum_{i=1}^n \alpha_i y_i b + \sum_{i=1}^n \alpha_i \end{aligned} \quad (3.23)$$

Buradaki $\alpha_i = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n) \geq 0$ değerleri Lagrange çarpanları olarak isimlendirilir.

İkinci aşamada ise (3.23) eşitliği $\alpha_i = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n) \geq 0$ Lagrange çarpanlarına bağlı olarak optimize edilebilecek ikincil (dual) problem formuna dönüştürmek için Karush-Kuhn-Tucker koşulları kullanılır. Karush Kuhn-Tucker teoremine göre (3.23) eşitliğinin (3.24) ve (3.25)'te belirtilen şartları sağlaması gerekmektedir.

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^n \alpha_i x_i y_i \quad (3.24)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^n x_i y_i = 0 \quad (3.25)$$

(3.24) ve (3.25)'te belirtilen koşullar (3.23)'teki eşitlikte yerine yazılırsa sırasıyla minimizasyon için (3.26) ve kısıtlama için (3.27) eşitliği elde edilir. Bu şekilde optimizasyon problemi ikincil problem formuna dönüşmüş olur.

$$L_{dual}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (3.26)$$

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad \alpha_i \geq 0, \quad i = 1, 2, 3, \dots, n \quad (3.27)$$

İkincil problem formuna dönüşmüş olan optimizasyon problemi verilen kısıtlamalar altında karesel (ikinci dereceden) programlama yöntemleri ile çözülerek $\alpha_i = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n) \geq 0$ değerleri bulunur. w , Karush Kuhn-Tucker koşullarından Gradyen koşulu eşitliği (3.28) ve b ise Karush Kuhn-Tucker koşullarından Orthogonality koşulu eşitlik (3.29) ile elde edilir.

$$\frac{\partial L_{primal}}{\partial w} = w^T - \sum_{i=1}^n \alpha_i x_i y_i = 0, \quad (3.28)$$

$$\frac{\partial L_{primal}}{\partial w} = \frac{\partial L_{primal}}{\partial w_1}, \frac{\partial L_{primal}}{\partial w_2}, \frac{\partial L_{primal}}{\partial w_3}, \dots, \frac{\partial L_{primal}}{\partial w_n}$$

$$(y_i(w^T \cdot x_i + b) - 1)\alpha_i = 0, \quad i = 1, 2, 3, \dots, n \quad (3.29)$$

Burada dikkat edilirse, eğitim kümesinin her örneği için bir tane Lagrange çarpanı (α_i) bulunmaktadır ve bu çarpanların büyük bir kısmının değeri sıfır olmaktadır. Lagrange çarpanı pozitif olan eğitim kümesi örnekleri (x_i) *Destek Vektörleri* olarak isimlendirilir. Bu eğitim kümesi örneklerinde kısıtlamalar aktif halde olup D1 veya D2 hiperdüzlemlerin üzerinde yer alırlar. Lagrange çarpanı sıfır olan diğer eğitim kümesi örnekleri ise D1 ve D2 hiperdüzlemlerinin üzerinde yer almayıp arka tarafında kalan örneklerdir [(Acar 2012), (Yıldız 2011), (Çomak 2008)].

b) Doğrusal Olarak Ayrılamama Durumu

Eğitim kümesine ait verilerin doğrusal olarak ayrılmadığı durumlarda verileri minimum sayıda hata ile ayırabilecek bir çözüm algoritması kullanılır. Zira bu verileri doğrusal olarak ayırma işlemi SVM'nin kötü bir genelleme yapmasına neden olur. Bunu engellemek için bir önceki alt başlık altında verilmiş olan doğrusal olarak ayrılabilir verilerin sınıflandırması probleminin çözümü için kullanılan algoritma geliştirilerek kullanılır [(Acar 2012), (Yıldız 2011)].


Eğitim kümesine ait verilerin doğrusal olarak tamamen ayrılmadığı durumlarda verilerin sınıflandırılması problemi Şekil 3.10.'da da görüleceği üzere pozitif değerler alan ve sınıflandırma hatalarını ifade eden gevşek (serbestlik) değişkenlerin (ξ_i) tanımlanması ve optimizasyon modeline eklenmesi ile çözülür. Tanımlanan $\xi_i \geq 0$ gevşek değişkeni, eğitim kümesine ait herhangi bir veri örneğinin ait olması gereken sınıfın sınırına olan uzaklığı miktarıdır. Dolayısıyla eğitim kümesine ait herhangi bir veri örneğinin doğru veya yanlış sınıflandırılmış olması, o örneğin ξ_i gevşek değeri ile doğrudan ilişkilidir. Şayet eğitim kümesine ait herhangi bir veri örneğinin ξ_i değeri, 0 ise bu veri örneği doğru sınıflandırılmış, 0-1 aralığında ise bu veri örneği doğru sınıflandırılmış ancak belirlenmiş olan maksimum sınır aralığında yer alıyor, 1 ve 1'den büyük ise yanlış sınıflandırılmıştır demektir.

Yukarıda ifade edilen bilgiler doğrultusunda (3.18), (3.19) eşitsizlikleri ile tanımlanan optimizasyon problemi ξ_i gevşek değişkenleri dikkate alınarak yeniden yazılacak olursa (3.30) ve (3.31) eşitsizlikleri elde edilir.

$$w^T \cdot x_i + b \geq +1 - \xi_i, \quad y_i = +1 \text{ için}, \quad \xi_i \geq 0 \quad (3.30)$$

$$w^T \cdot x_i + b \leq -1 + \xi_i, \quad y_i = -1 \text{ için}, \quad \xi_i \geq 0 \quad (3.31)$$

(3.30) ve (3.31)'de verilen iki eşitsizlik tek eşitsizlik ile ifade edildiğinde (3.32)'deki eşitsizlik elde edilir.



Şekil 3.10. Doğrusal olarak ayrılmayan veriler için SVM

$$y_i(w^T \cdot x_i + b) - 1 + \xi_i \geq 0 \quad (3.32)$$

Maksimum sınırı bulunma işlemi için gerekli işlemler yapılırsa;

$$f = \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (3.33)$$

$$y_i(w^T \cdot x_i + b) - 1 + \xi_i \geq 0, \quad \xi_i \geq 0, \quad i = 1, 2, 3, \dots, n \quad (3.34)$$

sırasıyla minimizasyon için (3.33) eşitliği ve kısıtlama için (3.34) eşitsizliği elde edilir. Burada; (3.33)'teki eşitlik çözülecek problemi, (3.34)'teki eşitsizlik ise bu problemin çözümünde kullanılacak kısıtlamayı (koşulu) göstermektedir. Yukarıda yapılan işlemler ile doğrusal olarak ayrılmayan veriler için optimizasyon problemi ve kısıtlamaları tanımlanmış olur. Eşitlik (3.33)'te var olan ikinci çarpan ($\sum_{i=1}^n \xi_i$) yanlış sınıflandırma hata sayısının üst sınırını belirtir. (3.33) eşitliğinde var olan C çarpanı ise sınırın maksimum ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki dengenin sağlanması işlevini gören sabit bir parametredir. Bu parametre

Lagrange çarpanlarının alabileceği maksimum değeri ifade edip çarpanların $0 < \alpha_i < C$ değer aralığında kalmasını sağlar. C parametresi düzenleme parametresi olarak adlandırılır ve değeri kullanıcı tarafından belirlenir. Bu çalışma sonucunda elde edilen optimizasyon problemi yüksek boyutlu uzayda çözülüyorsa ikincil problem formuna dönüştürülmelidir. Bu dönüştürme aşamasında yapılması gereken işlemler bir önceki alt başlık altında verilen doğrusal ayrılabilme durumundaki veriler üzerinde yapılan işlemlerle aynıdır. Gerekli işlemler yapıldıktan sonra sırasıyla minimizasyon için (3.35) ve kısıtlama için (3.36) eşitliği elde edilir. Bu şekilde optimizasyon problemi ikincil problem formuna dönüşmüş olur.


$$L_{dual}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (3.35)$$

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, n \quad (3.36)$$

İkincil problem formuna dönüşmüş olan optimizasyon problemi karesel (ikinci dereceden) programlama yöntemleri kullanılarak doğrusal olarak ayrılamayan veriler için en uygun SVM sınıflandırıcı parametreleri belirlenir. Burada, $0 < \alpha_i < C$ değer aralığındaki Lagrange çarpanlarına karşılık gelen x_i veri örnekleri SVM sınıflandırıcısının destek vektörlerini temsil eder [(Acar 2012), (Yıldız 2011), (Aydemir 2008)].

3.4.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Gerçek dünyada karşılaşılan problemlerin çoğu farklı bileşenlerden oluştuğundan bu problemlerin çözümleri için doğrusal SVM'lerin kullanılması oldukça kısıtlı kalmaktadır. Bu sebeple birçok problemin çözümünde doğrusal olmayan destek vektör makineleri kullanılmaktadır. Şekil 3.11.'de görüleceği üzere gerçekte karşılaşılan eğitim veri kümelerinin giriş uzayındaki dağılımı doğrusal olmadığından, bu verileri bulundukları giriş uzayında doğrusal bir hiperdüzlem ile ayırtırmak pek mümkün olmamaktadır.



Şekil 3.11. Giriş uzayındaki örneklerin yüksek boyutlu özellik uzayına taşınması

Bulundukları giriş uzayında doğrusal olarak ayrıştırılamayan bu veriler bir çekirdek fonksiyonu yardımıyla yüksek boyutlu bir özellik uzayına taşınarak, bu yeni özellik uzayında doğrusal olarak ayrıştırılabilirler. Böylece yüksek boyutlu özellik uzayındaki çok boyutlu hiperdüzlem, asıl uzayda doğrusal olmayan bir işleve karşılık gelir [(Acar 2012), (Yıldız 2011), (Vapnik 1995)].

Yüksek boyutlu özellik uzayına taşıma işlemi için ilk olarak eğitim kümesine ait d boyutlu veri örnekleri bulundukları giriş uzayından φ fonksiyonu kullanılarak daha yüksek boyutlu H özellik uzayına dönüştürülür. Burada; yüksek boyutlu uzay H sonsuz boyutlu Hilbert uzayıdır. Sonlu boyutlu durumda H uzayı Euclid uzayı olarak düşünülür.

$$\varphi: R^d \rightarrow H, x \rightarrow \varphi \quad (3.37)$$

Bu işlemde SVM'nin eğitim algoritması H uzayındaki verilerin $(x_i) \cdot (x_j)$ iç çarpımına bağlı olacaktır. Yüksek boyutlu H özellik uzayında bu iç çarpımın hesaplanması oldukça zor olacağından bunun yerine düşük boyutlu giriş uzayında, çekirdek (kernel) fonksiyonları kullanılarak bu işlem gerçekleştirilir. K çekirdek fonksiyonunun genel ifadesi (3.38)'de verilmiştir.

$$K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j) \quad (3.38)$$

Verinin yüksek boyutlu uzaya dönüşümü ve problemin çözümü için kullanılan bu çekirdek fonksiyonları seçilirken Mercer teoreminde belirtilen koşulları karşılaması gerekmektedir. Mercer teoremine göre bir $K(x_i, x_j)$ fonksiyonunun çekirdek olabilmesi için sürekli, simetrik ve $x_1, x_2, x_3, \dots, x_n$ değerleri için pozitif tanımlı olmalıdır. SVM için literatürde yaygın olarak kullanılan çekirdek fonksiyonlarından bazıları Tablo 3.2.'de verilmiştir. Doğru çekirdek fonksiyonunun seçimi diğer sınıflandırıcılarda olduğu gibi SVM için de sınıflandırma başarımını etkileyen önemli unsurlardan biridir. Yapılan çalışmalarda SVM için en yaygın kullanılan çekirdek fonksiyonunun radyal tabanlı çekirdek fonksiyonu olduğu görülmekte ve sınıflandırma başarımının yüksek olduğu ifade edilmektedir.

Eşitlik (3.35)'te x_i, x_j iç çarpan yerine yüksek boyutlu özellik uzaydaki karşılığı $K(x_i, x_j)$ çekirdek fonksiyonu ile yer değiştirirse minimizasyon için (3.39) ve kısıtlama için (3.40) eşitliği elde edilir.

$$L_{dual}(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.39)$$

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, n \quad (3.40)$$

Doğrusal olmayan verileri yüksek boyutlu özellik uzayında ayırabilen optimum hiperdüzlemin belirlenmesi için ikincil problem formunda olan optimizasyon problemi karesel (ikinci dereceden) programlama yöntemleri kullanılarak çözülür [(Yıldız 2011), (Özbeyaz 2010), (Gürsoy 2009)].


Tablo 3.2. SVM için yaygın olarak kullanılan çekirdek fonksiyonları

Çekirdek Fonksiyonu	Matematiksel İfade	Parametreler
Doğrusal	$K(x_i, x_j) = x_i \cdot x_j$	–
Polinomal	$K(x_i, x_j) = (x_i \cdot x_j + 1)^d$	d , Fonksiyonun Derecesi
Radyal Tabanlı	$K(x_i, x_j) = \exp(- x_i - x_j ^2 / 2\sigma^2)$	σ , Fonksiyonun Genişlik Parametresi

3.4.3. Aşırı Öğrenme Makinesi (ELM)

Öğrenme algoritmalarının başlangıcından bu yana, geri yayılma (BP) öğrenme algoritması ileriye dönük sinir ağlarını eğitmede baskın rol oynamaktadır. BP öğrenme algoritmasının yerel minimum, insan müdahalesi ve öğrenmede zaman kaybı gibi zorlu sorunlarla karşı karşıya olduğu iyi bilinmektedir. Dünyada hemen hemen tüm üniversitelerden binlerce araştırmacı yaklaşık yirmi yıl ileriye dönük sinir ağlarını incelemeye zaman harcamış olsa da ileriye dönük sinir ağları için verimli öğrenme algoritmaları bulmada çok fazla ilerleme kaydedilmemiştir. BP algoritmaları ve çeşitleri için ileriye dönük sinir ağlarındaki ana araştırma akışı, bir şekilde BP algoritmasının yaptığı gibi yerel minimum da sıkışmıştı. İleriye dönük sinir ağlarını eğitmek için alternatif bir çözüm olan SVM, 1995 yılında önerilmiş ve bazı araştırmacıların yapay sinir ağlarına olan güvenlerini kaybetmeye başlamış olduğu bir süreçte bu alan yeniden popüler olmuştur. ELM başlangıçta biyolojik öğrenimden ilham alan bir yapı olup BP öğrenme algoritmalarının karşılaştığı zorlu sorunların üstesinden gelmeyi önermiştir. Zira beynin öğrenimi karmaşık olup genellikle özellik belirleme, kümeleme, regresyon, sınıflandırma için evrensel olarak çalışır ve aynı zamanda sıfır insan müdahalesi gerektirir. Pek çok durumda belirli örnekler verildiğinde neredeyse sıfıra yakın zaman harcanır. Burada ifade edilen biyolojik öğrenme özelliklerinden esinlenerek, beyin sistemlerinin bir kısmının tüm parametrelerini ortamdan bağımsız olarak rastgele nöronlara sahip olması gerektiği fikri ELM'ye esin kaynağı olmuştur (Huang 2014).

2006 yılında Huang ve arkadaşları tarafından önerilen ELM tek gizli katmanlı olan ileri beslemeli yapay sinir ağlarına benzeyen bir öğrenme algoritması olup çalışma prensipleri belli bir noktaya kadar yapay sinir ağları ile aynıdır. Ancak yapay sinir ağlarının aksine ELM'de giriş katmanı ile gizli katman arasındaki ağırlıklar rastgele atanmakta ve bu değerler eğitimin ileriki aşamalarında güncellenmeyerek aynı kalmaktadır. Buna karşın gizli katman ile çıkış katmanı arasındaki ağırlıklar tek seferde doğrusal bir model yardımı ile analitik bir şekilde hesaplanmaktadır. Bu durum öğrenme sürecini hızlandırmış ve genelleme başarısını artırmış olur (Alçin ve ark. 2015).



Şekil 3.12. Tek giriş katmanlı ileri beslemeli yapay sinir ağı

Şekil 3.12.'de görüleceği gibi tek giriş katmanlı olan ileri beslemeli yapay sinir ağı için girişler $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in R^N$ ve çıkışlar $y_i = [y_{i1}, y_{i2}, \dots, y_{iM}]^T \in R^M$ vektörleri ile gösterilmiştir. Gizli katman nöron sayısı P ve aktivasyon fonksiyonu $g(\cdot)$ olan ileri beslemeli yapay sinir ağının temel matematiksel gösterimi (3.41)'deki eşitlik ile ifade edilebilir (Huang ve ark. 2006).

$$\sum_{i=1}^P \beta_i g(w_i \cdot x_j + b_i) = o_j \quad j = 1, 2, 3, \dots, N \quad (3.41)$$

(3.41)'deki eşitlikte $w_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$ giriş katmanını ile i 'inci gizli katman sinir hücresi arasındaki ağırlık değerlerini, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iM}]^T$ i 'inci gizli katman sinir hücresi ile çıkış katmanını arasındaki ağırlık değerlerini, b_i i 'inci gizli katman sinir hücresine eklenen eşik değerini göstermektedir. $o_i = [o_1, o_2, \dots, o_j]^T$ ELM'nin beklenen yahut olması istenen çıkışıdır. M adet çıkış hücresi ve $g(\cdot)$ aktivasyon fonksiyonu ile bir ileri beslemeli yapay sinir ağı N adet örnek β_i , w_i ve b_i değerleri ile sıfır hata değerine yakınsayabilir bu durumda istenen çıkış ile verilen çıkış

ilişkisi $\sum_j^P \|o_j - y_j\| = 0$ şeklinde ifade edilebilir. Bu durumda (3.41)'deki eşitlik yeniden yorumlanarak (3.42)'deki gibi yazılabilir (Huang ve ark. 2006).

$$\sum_{i=1}^P \beta_i g(w_i \cdot x_j + b_i) = y_j \quad j = 1, 2, 3, \dots, N \quad (3.42)$$

Yukarıdaki N adet denklem kompakt olarak (3.43)'teki eşitlik ile yazılabilir.

$$H\beta = Y \quad (3.43)$$

(3.43) eşitliğinde yer alan H matrisi β_i , w_i ve b_i değerlerine göre hesaplanan sinir ağının gizli katman çıkış matrisini ifade etmektedir (Huang ve ark. 2006).

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_P \cdot x_1 + b_P) \\ \vdots & \cdots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_P \cdot x_N + b_P) \end{bmatrix}_{N \times P} \quad (3.44)$$

β gizli katman ile çıkış katmanı arasındaki ağırlık değerleri ile Y örneklerin etiketleri (3.45)'te gösterilmektedir (Huang ve ark. 2006).

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_P^T \end{bmatrix}_{P \times M} \quad ve \quad Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times M} \quad (3.45)$$

ELM (3.43)'teki eşitliği çözerek sonuç üretir. Geleneksel yöntemlerde sinir ağı öğrenme işleminde iteratif işlemler gerçekleştirirken ELM sadece doğrusal bir denklemi iterasyona gerek duymadan çözerek eğitimini tamamlamış olur. (3.43)'teki β değerlerini hesaplamak için Moore-Penrose yöntemi kullanılır. Moore-Penrose genelleştirilmiş matris tersi alma yöntemine göre $H\beta = Y$ olan bir denklem sisteminde $N \times M$ boyutlarında kare olmayan bir matrisin en küçük norm ve kareler çözümünü sağlayan gösterimi (3.46)'daki gibidir [(Huang ve ark. 2006), (Ergül ve Bilgin 2017)].

$$\text{Min: } \|H\beta - Y\|^2 \text{ ve } \|\beta\|^2 \text{ olmak üzere } \beta' = H^\dagger Y \quad (3.46)$$

Moore-Penrose genelleştirilmiş matris tersi alınabilmesi için farklı yollar kullanılabilir. Bu yollardan biri ortogonal projeksiyon yöntemidir ki bu yöntem iki farklı şekilde kullanılmaktadır. $H^T H$ tekil ise $H^\dagger = (H^T H)^{-1} H^T$ ve HH^T tekil ise $H^\dagger = H^T (HH^T)^{-1}$ dir. Ridge regresyon teorisine göre HH^T veya $H^T H$ matrislerinin diyagonaline pozitif bir değer eklemek sistemin daha kararlı sonuçlar üretmesini ve daha genel başarıma sahip olmasını sağlamaktadır. ρ sabit bir değeri, I ise birim matrisi olmak üzere (3.46)'daki ifade (3.47)'de gibi genişletilerek yazılabilir (Ergül ve Bilgin 2017).

$$\beta' = H^T \left(\frac{I}{\rho} + HH^T \right)^{-1} Y \quad (3.47)$$

Gizli katman ile çıkış katmanı arasındaki ağırlık değerleri olan β' bulunduğundan sonra test verisi X_t için gizli katman çıkış sonuçları (3.48)'deki hesaplama ile bulunur.

$$h(x_t) = g(w^T x_t + b) \quad (3.48)$$

Sınıflandırma işlemi (3.49)'daki ifade kullanılarak tamamlanır. Bu arada eğitim kümesi kullanılarak hesaplanmış β' 'dan faydalanılır.

$$f(x_t) = h(x_t) \beta' = h(x_t) H^T \left(\frac{I}{\rho} + HH^T \right)^{-1} Y \quad (3.49)$$

3.4.3.1. Çekirdek Aşırı Öğrenme Makinesi (KELM)

Tüm örüntü tanıma teorilerinde, düşük boyutlu uzayda verilerin ayrışabilirliğinin yüksek boyutlu uzaylara oranla az olduğu kabul edilmektedir. Ayrışabilirliği artırmak amacı ile veriler $K: R^d \rightarrow F; x_n \rightarrow K(x_n)$ şeklinde bir K fonksiyonu ile daha yüksek boyutlu bir uzaya transfer edilir. Sınırlandırma amacı ile daha yüksek boyutlu uzaya taşımak maliyetli bir iştir. Hesaplama için gerekli zaman, dananım, saklama alanı gibi unsurları artıran bir iştir. Bu maliyeti azaltmak için çekirdek oyunu adı verilen bir yöntem kullanılır. Bu yöntemde nokta çarpımı halinde bulunan verilerin transfer fonksiyonu veriler üzerinden değil verilerin nokta çarpımı üzerinden elde edilir.

ELM'de karar aşamasında iki adet nokta çarpımı içerdiğinden bu sınıflandırıcıya çekirdek yöntemi uygulanabilmektedir (Ergül ve Bilgin 2017).

ELM hesaplama sürecinde $h(x_t)H^T$ ve HH^T nokta çarpımları (3.50)'de ifade edildiği şekilde çekirdek transferi gerçekleştirilebilir.

$$K(x_t, x^T) = \begin{bmatrix} K(x_t, x_1^T) \\ \dots \\ K(x_t, x_N^T) \end{bmatrix} \text{ ve } \Omega_{ELM} = K(x_i, x_j^T) \quad (3.50)$$

Yapılan bu dönüşümden sonra çekirdek tabanlı ELM (3.51)'deki eşitlik ile ifade edilmektedir.

$$f(x_t) = K(x_t, x^T) \left(\frac{I}{\rho} + \Omega_{ELM} \right)^{-1} Y \quad (3.51)$$

ELM için literatürde yaygın olarak kullanılan çekirdek fonksiyonlarından bazıları Tablo 3.3.'te verilmiştir. Doğru çekirdek fonksiyonunun seçimi diğer sınıflandırıcılarda olduğu gibi ELM içinde sınıflandırma başarımını etkileyen önemli unsurlardan biridir. Yapılan çalışmalarda ELM için en yaygın kullanılan çekirdek fonksiyonunun radyal tabanlı çekirdek fonksiyonu olduğu görülmekte ve sınıflandırma başarımının yüksek olduğu ifade edilmektedir.

Tablo 3.3. ELM için yaygın olarak kullanılan çekirdek fonksiyonları

Çekirdek Fonksiyonu	Matematiksel İfade	Parametreler
Doğrusal	$K(x_i, x_j) = x_i \cdot x_j$	–
Polinomal	$K(x_i, x_j) = (x_i \cdot x_j + 1)^d$	d , Fonksiyonun Derecesi
Radyal Tabanlı	$K(x_i, x_j) = \exp(-\ x_i - x_j\ ^2 / 2\sigma^2)$	σ , Fonksiyonun Genişlik Parametresi



4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında, Bonn Üniversitesi veri tabanından alınan 23.6 saniye ve 4096 örnek (sample) uzunluğunda sağlıklı deneklere ait işaretler (A kümesi) ile epilepsi hastası olan deneklerden alınan ve nöbet sırasında kaydedilen (E kümesi) EEG işaretleri kullanılarak farklı zaman ölçeklerinde epilepsi nöbet tespiti yapan otomatik örüntü tanıma sistemi sunulmuştur. Sunulan otomatik örüntü tanıma sistemi ön işlem, özellik çıkarma ve sınıflandırma olmak üzere üç aşamadan meydana gelmektedir.


Birinci aşamada veri tabanından alınan A ve E işaret kümeleri bir ön işlem sürecinden geçirilerek 128, 256, 512, 1024, 2048 ve 4096 örnek uzunluğunda bölütlere ayrılmıştır. Bölütleme işlemi ile EEG işaretleri farklı zaman ölçeklerinde temsil edilmiştir. Bu işlem sonucunda 100 adet olan A ve E işaret kümelerinden farklı zaman ölçeklerinde toplamda 12 adet işaret kümesi türetilmiştir.

İkinci aşama olan özellik çıkarma aşamasında ise bölütlere ayrılmış her bir EEG işaretinin Periodogram ve Welch GSY kestirimi yapılarak işaretlerin spektrum bilgisine ulaşılmıştır. GSY kestirimi sonucu elde edilen spektrum verilerinin sıralı ortalamaları alınarak her bir veri 16 adet örnek ile temsil edilmiştir. Bu çalışma ile EEG işaretleri için özellik çıkarımı yapılmış, işaretler kararlı ve daha küçük boyutlu bir bilgi ile temsil edilmiştir. Bu aşamada toplamda 12 adet işaret kümesi için 16 örnek uzunluğunda 12 adet özellik kümesi elde edilmiştir.

Sunulan örüntü tanıma sisteminin özellik çıkarma aşamasından sonra gerçekleşen üçüncü aşamada ise özellik çıkarma aşamasında kullanılan yöntemlerle elde edilen EEG işaret özellikleri, giriş olarak kullanılıp K-NN, SVM ve ELM ile sınıflandırma yapılmıştır. Sınıflandırma yapılırken tüm uygulamalar 5 katlı çapraz doğrulama yöntemi kullanılarak gerçekleştirilmiş ve sınıflandırma performansları karşılaştırılmıştır.

Kaba hatları ile sunulan otomatik örüntü tanıma sisteminin yapısı Şekil 4.1.'de gösterilmiştir. Sistemin her aşamasında yapılan işlemlerin detayları ve uygulamaları çalışmanın ilerleyen bölümlerinde verilmiştir.

Bu çalışmada sunulan otomatik örüntü tanıma sistemi için tüm analizler Intel® i5 mikro işlemcili GIGABYTE Ultra Durable 5 Anakart ve 16 GB RAM belleğe sahip bir bilgisayarda çalışan MATLAB programı ile yapılmıştır.




Şekil 4.1. EEG işaretlerinden epilepsi nöbetini tespit eden otomatik örüntü tanıma sistemi

4.1. Ön İşlem Süreci: EEG İşaretlerinin Bölütlere Ayrılması

Kullanılan veri tabanı bölümünde detaylı olarak ifade edildiği üzere her biri 100 adet EEG işareti içeren A ve E işaret kümelerinde bulunan, her bir işaretin uzunluğu 4096 örnek ve 23.6 saniyedir. EEG işaretleri kullanılarak farklı zaman ölçeklerinde epilepsi nöbetini tespit eden otomatik örüntü tanıma sistemi tasarlamak için A ve E işaret kümelerindeki her bir EEG işareti 128, 256, 512, 1024, 2048, 4096 örnek ve 0.7375, 1.475, 2.95, 5.9, 11.8, 23.6 saniyelik bölütlere ayrılmıştır. Bu bölütleme işlemi ile farklı sayılarda, sürelerde ve uzunluklarda A(128), A(256), A(512), A(1024), A(2048), A(4096), E(128), E(256), E(512), E(1024), E(2048) ve E(4096) işaret kümeleri elde edilmiştir. Ön işlem süreci sonucunda elde edilen EEG işaret kümelerinin detaylı gösterimi Tablo 4.1.'de verilmiştir. Aynı zamanda mevcut veri kümelerinden seçilen örnek bir EEG işareti Şekil 4.2.'de gösterilmiştir.

Tablo 4.1. Ön işlem sonucunda elde edilen EEG işaret kümelerinin yapısı

EEG İşaret Kümesi	İşaret Kümesindeki İşaret Sayısı	İşaret Kümesindeki İşaretlerin Örnek Sayısı	İşaret Kümesindeki İşaretlerin Süresi (Sn)
A(128)	3200	128	0.7375
A(256)	1600	256	1.475
A(512)	800	512	2.95
A(1024)	400	1024	5.9
A(2048)	200	2048	11.8
A(4096)	100	4096	23.6
E(128)	3200	128	0.7375
E(256)	1600	256	1.475
E(512)	800	512	2.95
E(1024)	400	1024	5.9
E(2048)	200	2048	11.8
E(4096)	100	4096	23.6

**Şekil 4.2.** A(128), A(256) , A(512) , A(1024) , A(2048) , A(4096) , E(128) , E(256) , E(512) , E(1024) , E(2048) ve E(4096) işaret kümelerinden örnek bir EEG işaretinin gösterimi

4.2. EEG İşaret Örüntülerinden Özellik Çıkarma


Özellik çıkarma otomatik örüntü tanıma sistemlerinin en önemli bölümü olup bir takım matematiksel dönüşümlerin veya veri hesaplama tekniklerinin uygulanması ile

örüntünün boyut indirgeme işlemlerinin gerçekleştirildiği bölümdür. Otomatik örüntü tanıma sistemlerinde sınıflandırma işleminde giriş vektörlerinin seçimi gerçekten çok hassas ve önemli bir konudur. Girişler kötü ve gereksiz bilgi içerdiğinde bilinen en iyi sınıflandırıcı kullanılsa bile başarımlar performansı kötü olacağı gibi gereksiz zaman ve kaynak israfına da neden olacaktır.

Bu çalışmada ön işlem sürecinde bölütlere ayrılmış sağlıklı ve nöbet geçiren hasta deneklere ait EEG işaret örüntülerini bir birinden ayırt edecek otomatik örüntü tanıma sisteminin özellik çıkarma aşamasında iki farklı yöntem kullanılmıştır. Kullanılan özellik çıkarma yöntemlerinden birincisi Periodogram GSY kestirim metodu ve aritmetik ortalama kullanarak özellik çıkarma yöntemidir. Bu yöntemin detayları ve EEG işaretlerine uygulanması 4.2.1. alt başlığı altında verilmiştir. İkinci özellik çıkarma yöntemi ise Welch GSY kestirim metodu ve aritmetik ortalama kullanarak özellik çıkarma yöntemidir. Bu yöntemin detayları ve EEG işaretlerine uygulanması 4.2.2. alt başlığı altında verilmiştir. Özellik çıkarma bölümünde kullanılan yöntemlerin teorik matematiksel alt yapısı materyal ve metot bölümünde detaylı olarak verilmiştir.

4.2.1. Periodogram Güç Spektral Yoğunluk Kestirim Metodu ve Aritmetik Ortalama Kullanarak Özellik Çıkarma

EEG işaret örüntülerinden Periodogram güç spektral yoğunluk (PGSY) kestirim metodu ve aritmetik ortalama (AO) kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı Şekil 4.3.'te gösterilmiştir. Blok diyagramın her bölümünde gerçekleştirilen işlemlerin detayları aşağıda verilmiştir.



Şekil 4.3. EEG işaretleri için PGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı

a) A(128) ve E(128) işaret Kümesi için Özellik Çıkarımı: A(128) ve E(128) işaret kümelerindeki her bir EEG işareti 128 örnek ve 0.7375 saniye uzunluğundadır. A(128) ve E(128) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(128), E(128) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.4.'te gösterilmiştir. PGSY kestirimi sonucunda 128 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 64 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 4 örneğin AO'su hesaplanarak 4 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 128 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(128) ve E(128) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.5.'te gösterilmiştir.

b) A(256) ve E(256) işaret Kümesi için Özellik Çıkarımı: A(256) ve E(256) işaret kümelerindeki her bir EEG işareti 256 örnek ve 1.4750 saniye uzunluğundadır. A(256) ve E(256) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(256), E(256) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.6.'da gösterilmiştir. PGSY kestirimi sonucunda 256 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 128 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 8 örneğin AO'su hesaplanarak 8 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 256 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(256) ve E(256) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.7.'de gösterilmiştir.

c) A(512) ve E(512) işaret Kümesi için Özellik Çıkarımı: A(512) ve E(512) işaret kümelerindeki her bir EEG işareti 512 örnek ve 2.95 saniye uzunluğundadır. A(512) ve E(512) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(512), E(512) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.8.'de gösterilmiştir. PGSY kestirimi sonucunda 512 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 256 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 16 örneğin AO'su


hesaplanarak 16 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 512 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(512) ve E(512) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.9.'da gösterilmiştir.

d) A(1024) ve E(1024) işaret Kümesi için Özellik Çıkarımı: A(1024) ve E(1024) işaret kümelerindeki her bir EEG işareti 1024 örnek ve 5.9 saniye uzunluğundadır. A(1024) ve E(1024) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(1024), E(1024) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.10.'da gösterilmiştir. PGSY kestirimi sonucunda 1024 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 512 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 32 örneğin AO'su hesaplanarak 32 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 1024 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(1024) ve E(1024) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.11.'de gösterilmiştir.


e) A(2048) ve E(2048) işaret Kümesi için Özellik Çıkarımı: A(2048) ve E(2048) işaret kümelerindeki her bir EEG işareti 2048 örnek ve 11.8 saniye uzunluğundadır. A(2048) ve E(2048) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(2048), E(2048) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.12.'de gösterilmiştir. PGSY kestirimi sonucunda 2048 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 1024 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 64 örneğin AO'su hesaplanarak 64 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 2048 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(2048) ve E(2048) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.13.'te gösterilmiştir.

f) A(4096) ve E(4096) işaret Kümesi için Özellik Çıkarımı: A(4096) ve E(4096) işaret kümelerindeki her bir EEG işareti 4096 örnek ve 23.6 saniye uzunluğundadır. A(4096) ve E(4096) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle PGSY kestirim metodu kullanılarak bu işaretlerin frekans


domeni bilgilerine ulaşılmıştır. A(4096), E(4096) işaret kümelerinin örnek bir EEG işareti ve PGSY'si Şekil 4.14.'te gösterilmiştir. PGSY kestirimi sonucunda 4096 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 2048 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işareti sıralı 128 örneğin AO'su hesaplanarak 128 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 4096 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(4096) ve E(4096) işaret kümelerinden PGSY-AO ile çıkarılan özellikler Şekil 4.15.'te gösterilmiştir.




Şekil 4.4. A(128), E(128) işaret kümelerinden örnek bir EEG işareti ve PGSY'si




Şekil 4.5. A(128), E(128) işaret kümelerinden PGSY-AO ile çıkarılan özellikler




Şekil 4.6. A(256) , E(256) işaret kümelerinden örnek bir EEG işareti ve PGSY'si




Şekil 4.7. A(256), E(256) işaret kümelerinden PGSY-AO ile çıkarılan özellikler




Şekil 4.8. A(512) , E(512) işaret kümelerinden örnek bir EEG işareti ve PGSY'si




Şekil 4.9. A(512), E(512) işaret kümelerinden PGSY-AO ile çıkarılan özellikler




Şekil 4.10. A(1024), E(1024) işaret kümelerinden örnek bir EEG işareti ve PGSY'si




Şekil 4.11. A(1024), E(1024) işaret kümelerinden PGSY-AO ile çıkarılan özellikler




Şekil 4.12. A(2048) , E(2048) işaret kümelerinden örnek bir EEG işareti ve PGSY'si



Şekil 4.13. A(2048), E(2048) işaret kümelerinden PGSY-AO ile çıkarılan özellikler



Şekil 4.14. A(4096) , E(4096) işaret kümelerinden örnek bir EEG işareti ve PGSY'si



Şekil 4.15. A(4096), E(4096) işaret kümelerinden PGSY-AO ile çıkarılan özellikler


g) Periodogram Güç Spektral Yoğunluk Kestirim Metodu ve Aritmetik Ortalama Kullanılarak Gerçekleştirilen Özellik Çıkarımının Detaylı Gösterimi: A(128), A(256), A(512), A(1024), A(2048), A(4096), E(128), E(256), E(512), E(1024), E(2048) ve E(4096) işaret kümelerinin PGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi Tablo 4.2.'de verilmiştir.

Tablo 4.2. PGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi

EEG İşaret Kümesi	İşaret Kümesindeki İşaret Sayısı	İşaret Kümesindeki İşaretlerin Süresi	İşaret Kümesindeki İşaretlerin Örnek Sayısı	PGSY Kestirimi Sonucu İşaretlerin Örnek Sayısı	Aritmetik Ortalaması Alınan Örnek Sayısı	Özellik Vektörünün Örnek Sayısı
A(128)	3200	0.7375	128	64	4	16
A(256)	1600	1.475	256	128	8	16
A(512)	800	2.95	512	256	16	16
A(1024)	400	5.9	1024	512	32	16
A(2048)	200	11.8	2048	1024	64	16
A(4096)	100	23.6	4096	2048	128	16
E(128)	3200	0.7375	128	64	4	16
E(256)	1600	1.475	256	128	8	16
E(512)	800	2.95	512	256	16	16
E(1024)	400	5.9	1024	512	32	16
E(2048)	200	11.8	2048	1024	64	16
E(4096)	100	23.6	4096	2048	128	16

4.2.2. Welch Güç Spektral Yoğunluk Kestirim Metodu ve Aritmetik Ortalama Kullanarak Özellik Çıkarma

EEG işaret örüntülerinden Welch güç spektral yoğunluk (WGSY) kestirim metodu ve aritmetik ortalama (AO) kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı Şekil 4.16.'da gösterilmiştir. Blok diyagramının her bölümünde gerçekleştirilen işlemlerin detayları aşağıda verilmiştir. WGSY kestirimi yapılırken Bartlett, Blackman, Hanning ve Hamming pencere fonksiyonları denenmiş en iyi performans Hamming pencere fonksiyonu ile elde edildiğinden, çalışmada bu fonksiyon seçilmiştir. İşaret bölütlerinin örtüşme miktarı %25, %50 ve %75 oranlarında denenmiş iyi performans %50 ile elde edildiğinden, çalışmada bu oran seçilmiştir.



Şekil 4.16. EEG işaretleri için WGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının blok diyagramı

a) A(128) ve E(128) işaret Kümesi için Özellik Çıkarmı: A(128) ve E(128) işaret kümelerindeki her bir EEG işareti 128 örnek ve 0.7375 saniye uzunluğundadır. A(128) ve E(128) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(128), E(128) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.17.'de gösterilmiştir. WGSY kestirimi hesaplanırken 32 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 16 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 128 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 16 örnek olarak elde edilmiştir. WGSY

kestirimi sonucu elde edilen özellik vektörü 16 örnek uzunluğunda olduğundan veri azaltımı için herhangi bir işlem yapılmayarak sonuç özellik vektörü olarak kabul edilmiştir. A(128) ve E(128) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.18.'de gösterilmiştir.

b) A(256) ve E(256) işaret Kümesi için Özellik Çıkarımı: A(256) ve E(256) işaret kümelerindeki her bir EEG işareti 256 örnek ve 1.4750 saniye uzunluğundadır. A(256) ve E(256) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(256), E(256) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.19.'da gösterilmiştir. WGSY kestirimi hesaplanırken 64 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 32 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 256 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 32 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 2 örneğin AO'su hesaplanarak 2 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 256 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(256) ve E(256) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.20.'de gösterilmiştir.


c) A(512) ve E(512) işaret Kümesi için Özellik Çıkarımı: A(512) ve E(512) işaret kümelerindeki her bir EEG işareti 512 örnek ve 2.95 saniye uzunluğundadır. A(512) ve E(512) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(512), E(512) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.21.'de gösterilmiştir. WGSY kestirimi hesaplanırken 128 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 64 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 512 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 64 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 4 örneğin AO'su hesaplanarak 4 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 512 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(512) ve E(512) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.22.'de gösterilmiştir.

d) A(1024) ve E(1024) işaret Kümesi için Özellik Çıkarımı: A(1024) ve E(1024) işaret kümelerindeki her bir EEG işareti 1024 örnek ve 5.9 saniye uzunluğundadır. A(1024) ve E(1024) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(1024), E(1024) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.23.'te gösterilmiştir. WGSY kestirimi hesaplanırken 256 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 128 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 1024 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 128 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 8 örneğin AO'su hesaplanarak 8 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 1024 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(1024) ve E(1024) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.24.'te gösterilmiştir.


e) A(2048) ve E(2048) işaret Kümesi için Özellik Çıkarımı: A(2048) ve E(2048) işaret kümelerindeki her bir EEG işareti 2048 örnek ve 11.8 saniye uzunluğundadır. A(2048) ve E(2048) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans domeni bilgilerine ulaşılmıştır. A(2048), E(2048) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.25.'te gösterilmiştir. WGSY kestirimi hesaplanırken 512 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 256 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 2048 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 256 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 16 örneğin AO'su hesaplanarak 16 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 2048 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(2048) ve E(2048) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.26.'da gösterilmiştir.

f) A(4096) ve E(4096) işaret Kümesi için Özellik Çıkarımı: A(4096) ve E(4096) işaret kümelerindeki her bir EEG işareti 4096 örnek ve 23.6 saniye uzunluğundadır. A(4096) ve E(4096) işaret kümelerindeki işaretlerin özelliklerini çıkarmak için öncelikle WGSY kestirim metodu kullanılarak bu işaretlerin frekans


domeni bilgilerine ulaşılmıştır. A(4096), E(4096) işaret kümelerinin örnek bir EEG işareti ve WGSY'si Şekil 4.27.'de gösterilmiştir. WGSY kestirimi hesaplanırken 1024 noktalı Hamming pencere fonksiyonu kullanılmış ve bölütlerin örtüşme miktarı 512 örnek (%50) olarak seçilmiştir. WGSY kestirimi sonucunda 4096 örnek uzunluğundaki zaman domeni EEG işaretlerinin uzunluğu frekans domeninde 512 örnek olarak elde edilmiştir. Veri azaltımı yapmak amacı ile her bir EEG işaretinde sıralı 32 örneğin AO'su hesaplanarak 32 örnek tek bir örnek ile temsil edilmiştir. Yapılan tüm işlemler sonucunda 4096 örnek uzunluğundaki EEG işaretleri 16 örnek uzunluğundaki özellik vektörü ile temsil edilmiştir. A(4096) ve E(4096) işaret kümelerinden WGSY-AO ile çıkarılan özellikler Şekil 4.28.'de gösterilmiştir.




Şekil 4.17. A(128), E(128) işaret kümelerinden örnek bir EEG işareti ve WGSY'si




Şekil 4.18. A(128), E(128) işaret kümelerinden WGSY-AO ile çıkarılan özellikler




Şekil 4.19. A(256) , E(256) işaret kümelerinden örnek bir EEG işareti ve WGSY'si




Şekil 4.20. A(256), E(256) işaret kümelerinden WGSY-AO ile çıkarılan özellikler




Şekil 4.21. A(512) , E(512) işaret kümelerinden örnek bir EEG işareti ve WGSY'si




Şekil 4.22. A(512), E(512) işaret kümelerinden WGSY-AO ile çıkarılan özellikler




Şekil 4.23. A(1024) , E(1024) işaret kümelerinden örnek bir EEG işareti ve WGSY'si




Şekil 4.24. A(1024), E(1024) işaret kümelerinden WGSY-AO ile çıkarılan özellikler




Şekil 4.25. A(2048) , E(2048) işaret kümelerinden örnek bir EEG işareti ve WGSY'si



Şekil 4.26. A(2048), E(2048) işaret kümelerinden WGSY-AO ile çıkarılan özellikler



Şekil 4.27. A(4096) , E(4096) işaret kümelerinden örnek bir EEG işareti ve WGSY'si



Şekil 4.28. A(4096), E(4096) işaret kümelerinden WGSY-AO ile çıkarılan özellikler

g) **Welch Güç Spektral Yoğunluk Kestirim Metodu Kullanarak ve Aritmetik Ortalama Özellik Çıkarımının Detaylı Gösterimi:** A(128), A(256), A(512), A(1024), A(2048), A(4096), E(128), E(256), E(512), E(1024), E(2048) ve E(4096) işaret kümelerinin WGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi Tablo 4.3.'te verilmiştir.

Tablo 4.3. WGSY kestirim metodu ve AO kullanılarak gerçekleştirilen özellik çıkarımının detaylı gösterimi

EEG İşaret Kümesi	İşaret Kümesindeki İşaret Sayısı	İşaret Kümesindeki İşaretlerin Süresi	Veri Kümesindeki İşaretlerin Örnek Sayısı	WGSY Kestirimi Sonucu İşaretlerin Örnek Sayısı	Aritmetik Ortalaması Alınan Örnek Sayısı	Özellik Vektörünün Örnek Sayısı
A(128)	3200	0.7375	128	16	1	16
A(256)	1600	1.475	256	32	2	16
A(512)	800	2.95	512	64	4	16
A(1024)	400	5.9	1024	128	8	16
A(2048)	200	11.8	2048	256	16	16
A(4096)	100	23.6	4096	512	32	16
E(128)	3200	0.7375	128	16	1	16
E(256)	1600	1.475	256	32	2	16
E(512)	800	2.95	512	64	4	16
E(1024)	400	5.9	1024	128	8	16
E(2048)	200	11.8	2048	256	16	16
E(4096)	100	23.6	4096	512	32	16

4.3. EEG İşaret Örüntülerini Sınıflandırma

Sınıflandırma basit bir anlatım ile bilinmeyen bir örüntünün yahut bir verinin nesnesinin üzerinde tanımlı bulunan çeşitli sınıflar arasında veriyi belli bir kurala göre dağıtmaktır. Burada bir problemi çözmek için eldeki verilerin kullanılması ile problemin çözümüne giden yolun öğrenilmesi, deneyimlerin elde edilmesi ve öğrenilen bu yolun yeni verilerin ayrıştırılması veya yeni problemlerin çözülmesi için kullanımı amaçlanmaktadır.

Bu çalışmada özellik çıkarma sürecinde elde edilen özellik vektörlerinden sağlıklı ve nöbet geçiren hasta denekleri bir birinden ayırt edecek otomatik örüntü tanıma sistemi için K-NN, SVM ve ELM sınıflandırıcıları kullanılarak sınıflandırma yapılmıştır. Tüm çalışmada EEG kaydından sağlıklı ve nöbet geçiren hasta denekleri bir birinden ayırt edecek 36 farklı örüntü sınıflandırma yaklaşımı yapılmıştır. Bu yaklaşımların her birinde kullanılan EEG kaydına ilişkin işaret türü, özellik çıkarım yöntemi ve sınıflandırma yöntemi Tablo 4.4.'te verilmiştir.

Tablo 4.4.'te verilen her örüntü sınıflandırmasında sınıflandırıcının güvenilirlik testi için k katlı çapraz doğrulama (k fold cross validation) testi kullanılmıştır. k katlı çapraz doğrulama testinde teste tabi tutulacak veri kümesi, k adet alt veri bölümüne ayrılır. Daha sonra bu alt veri bölümlerinin $k-1$ tanesi sınıflandırıcının eğitiminde, geriye kalan diğer alt veri bölümleri ise sınıflandırıcının testinde kullanılır. Belirtilen bu işlem tüm olası alt veri bölümlerinin sınıflandırıcı testinde kullanılıncaya kadar k defa tekrarlanır. Böylelikle sınıflandırılacak veri kümesinin hepsi test edilerek verinin tamamı hakkında sonuca varılır.

Bu çalışmada Tablo 4.4.'te verilen sınıflandırma yaklaşımlarının her birinin testi için 5 katlı çapraz doğrulama yöntemi kullanılmıştır. Çalışmada her veri kümesi beş bölüme ayrılmış dört bölüm sınıflandırıcının eğitimi için, bir bölüm ise sınıflandırıcının test edilmesi için kullanılmıştır. Bu işlem beş defa tekrarlanarak tüm veriler hem eğitim hem de test için kullanılarak sınıflandırma işlemi tamamlanmıştır.

Tablo 4.4. 36 farklı örüntü sınıflandırma yaklaşımında kullanılan işaret kümesi, özellik çıkarım yöntemi ve sınıflandırıcı yöntemine göre gösterimleri.

EEG İşaret Kümesi	Özellik Çıkarım Yöntemi	Sınıflandırma Yöntemi
A(128)/E(128)	PGSY-AO	K-NN
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		
A(128)/E(128)	WGSY-AO	K-NN
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		
A(128)/E(128)	PGSY-AO	SVM
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		
A(128)/E(128)	WGSY-AO	SVM
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		
A(128)/E(128)	PGSY-AO	ELM
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		
A(128)/E(128)	WGSY-AO	ELM
A(256) /E(256)		
A(512) /E(512)		
A(1024) /E(1024)		
A(2048) /E(2048)		
A(4096) /E(4096)		

Sınıflandırıcıların performansının değerlendirilmesinde literatürde sıkça kullanılan test performansının istatistiksel parametrelerinin hesaplanması ile değerlendirilmiştir. Bu istatistiksel parametreler (4.1)-(4.3) arasında verilmiştir.

$$\text{Doğruluk (Accuracy)} = \frac{GP + GN}{GP + YP + DN + YN} (\%) \quad (4.1)$$

$$\text{Kesinlik (Specificity)} = \frac{GN}{YP + GN} (\%) \quad (4.2)$$

$$\text{Duyarlılık (Sensitivity)} = \frac{GP}{GP + YN} (\%) \quad (4.3)$$

Buradaki GP, GN, YP ve YN istatistiksel parametreler olup bu çalışma açısından aşağıda verildiği şekilde tanımlanırlar:

Gerçek Pozitif (GP): Sağlıklı olan deneğin sınıflandırıcı tarafından da sağlıklı olarak belirlenmesi.

Gerçek Negatif (GN): Nöbet geçiren hasta deneğin sınıflandırıcı tarafından da nöbet geçiren hasta denek olarak belirlenmesi.

Yanlış Pozitif (YP): Nöbet geçiren hasta deneğin sınıflandırıcı tarafından sağlıklı olarak belirlenmesi.

Yanlış Negatif (YN): Sağlıklı olan deneğin sınıflandırıcı tarafından nöbet geçiren hasta denek olarak belirlenmesi.

Bu çalışmada tanımlanan bu istatistiksel parametreler konfüzyon matrisi olarak adlandırılan bir tablo ile gösterilirler. Konfüzyon matrisinin bu çalışmaya uyarlanmış biçiminin örneği Tablo 4.5.'te verilmiştir.

Tablo 4.5. Konfüzyon matrisi.

Sınıflandırma Test Sonuçları	Gerçek Sonuçlar	
	Sağlıklı Denek	Nöbet Geçiren Hasta Denek
Sağlıklı Denek	GP	YP
Nöbet Geçiren Hasta Denek	YN	GN

4.3.1. K-En Yakın Komşuluk Algoritması ile Sınıflandırma

Bölüm 4.2.'de özellikleri çıkarılan, Tablo 4.2. ve Tablo 4.3.'te detayları verilen EEG işaret kümelerinin özellik vektörleri bu bölümde K-NN sınıflandırıcısı kullanılarak sınıflandırılmıştır. K-NN ile yapılan sınıflandırmada uzaklık ölçütü olarak Öklid uzaklık ölçütü kullanılmıştır. K-NN algoritmasında K komşuluk parametresi 1'den 100'e kadar denenmiş (4.1)-(4.3) arasında ifade edilen istatistiksel parametreler hesabına göre maksimum test performansı sonuçları detaylı olarak Tablo 4.6.'da verilmiştir.

Tablo 4.6. K-NN ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları.

EEG İşaret Kümesi	Özellik Çıkarma Yöntemi	Komşu Sayısı (K)	Doğruluk (Accuracy) (%)	Keskinlik (Specificity) (%)	Duyarlılık (Sensitivity) (%)
A(128)/E(128)	PGSY-AO	5	99.30	98.91	99.69
A(256) /E(256)	PGSY-AO	3	99.66	99.38	99.94
A(512) /E(512)	PGSY-AO	3	99.81	99.75	99.88
A(1024) /E(1024)	PGSY-AO	1	99.75	99.50	100
A(2048) /E(2048)	PGSY-AO	1	100	100	100
A(4096) /E(4096)	PGSY-AO	1	100	100	100
A(128)/E(128)	WGSY-AO	9	99.30	98.97	99.63
A(256) /E(256)	WGSY-AO	3	99.72	99.44	100
A(512) /E(512)	WGSY-AO	1	99.75	99.50	100
A(1024) /E(1024)	WGSY-AO	1	99.88	99.75	100
A(2048) /E(2048)	WGSY-AO	1	100	100	100
A(4096) /E(4096)	WGSY-AO	1	100	100	100

4.3.2. Destek Vektör Makinesi ile Sınıflandırma

Bölüm 4.2.'de özellikleri çıkarılan, Tablo 4.2. ve Tablo 4.3.'te detayları verilen EEG işaret kümelerinin özellik vektörleri bu bölümde SVM sınıflandırıcısı kullanılarak sınıflandırılmıştır. SVM için çekirdek fonksiyonu olarak radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Kullanılan çekirdek fonksiyonun genişlik parametresi olan σ 0.01'den başlanarak 0.01'lik artışlar ile 10'a kadar, düzenleme parametresi olan C 1'den başlanarak 1'lik artışlar ile 100'e kadar denenmiş (4.1)-(4.3) arasında ifade edilen istatistiksel parametreler hesabına göre maksimum test performansı sonuçları detaylı olarak Tablo 4.7.'de verilmiştir. σ ve C parametrelerinin aldığı değerlere göre SVM sınıflandırıcısının sınıflandırma başarımı değişebilmektedir.

Tablo 4.7. SVM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları

EEG İşaret Kümesi	Özellik Çıkarım Yöntemi	C Katsayısı	σ Değeri	Doğruluk (Accuracy) (%)	Kesinlik (Specificity) (%)	Duyarlılık (Sensitivity) (%)
A(128)/E(128)	PGSY-AO	2	0.01	99.41	98.97	99.84
A(256)/E(256)	PGSY-AO	1	0.01	99.72	99.50	99.94
A(512)/E(512)	PGSY-AO	1	0.01	99.88	99.75	100
A(1024)/E(1024)	PGSY-AO	1	0.01	100	100	100
A(2048)/E(2048)	PGSY-AO	1	0.01	100	100	100
A(4096)/E(4096)	PGSY-AO	1	0.01	100	100	100
A(128)/E(128)	WGSY-AO	8	0.01	99.24	99.00	99.47
A(256)/E(256)	WGSY-AO	4	0.01	99.75	99.50	100
A(512)/E(512)	WGSY-AO	8	0.01	99.88	99.75	100
A(1024)/E(1024)	WGSY-AO	1	0.01	100	100	100
A(2048)/E(2048)	WGSY-AO	1	0.01	100	100	100
A(4096)/E(4096)	WGSY-AO	1	0.01	100	100	100

4.3.3. Aşırı Öğrenme Makinesi ile Sınıflandırma

Bölüm 4.2.'de özellikleri çıkarılan, Tablo 4.2. ve Tablo 4.3.'te detayları verilen EEG işaret kümelerinin özellik vektörleri bu bölümde ELM sınıflandırıcısı kullanılarak sınıflandırılmıştır. ELM için çekirdek fonksiyonu olarak radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Kullanılan çekirdek fonksiyonun genişlik parametresi olan sigma (σ) 0.001'den başlanarak 0.001'lik artışlar ile 10'a kadar, düzenleme parametresi olan (C) 1'den başlanarak 1'lik artışlar ile 100'e kadar denenmiş (4.1)-(4.3) arasında ifade edilen istatistiksel parametreler hesabına göre maksimum test performansı sonuçları detaylı olarak Tablo 4.8.'de verilmiştir. σ ve C parametrelerinin aldığı değerlere göre ELM sınıflandırıcısının sınıflandırma başarımı değişebilmektedir.

Tablo 4.8. ELM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre test performansı sonuçları.

EEG İşaret Kümesi	Özellik Çıkarım Yöntemi	C Katsayısı	σ Değeri	Doğruluk (Accuracy) (%)	Kesinlik (Specificity) (%)	Duyarlılık (Sensitivity) (%)
A(128)/E(128)	PGSY-AO	1	0.001	99.33	98.78	99,88
A(256) /E(256)	PGSY-AO	4	0.001	99.72	99.50	99,94
A(512) /E(512)	PGSY-AO	1	0.001	99.75	99.50	100
A(1024) /E(1024)	PGSY-AO	32	0.001	99.88	99.75	100
A(2048) /E(2048)	PGSY-AO	1	0.001	100	100	100
A(4096) /E(4096)	PGSY-AO	1	0.001	100	100	100
A(128)/E(128)	WGSY-AO	1	0.001	99.18	98.72	99.63
A(256) /E(256)	WGSY-AO	4	0.001	99.72	99.44	100
A(512) /E(512)	WGSY-AO	8	0.001	99.75	99.50	100
A(1024) /E(1024)	WGSY-AO	12	0.001	99.88	99.75	100
A(2048) /E(2048)	WGSY-AO	1	0.001	100	100	100
A(4096) /E(4096)	WGSY-AO	1	0.001	100	100	100

4.3.4. Sınıflandırma Performanslarının Karşılaştırılması

Tablo 4.6., Tablo 4.7. ve Tablo 4.8.'de detayları verilen K-NN, SVM ve ELM sınıflandırıcıların sınıflandırma sonuçlarından elde edilen doğruluk test performans sonuçları Tablo 4.9.'da karşılaştırılmıştır.

Tablo 4.9. K-NN, SVM, ELM ile EEG işaretlerinin sınıflandırılması sonucunda istatistiksel parametreler hesabına göre doğruluk test performans sonuçlarının karşılaştırılması.

EEG İşaret Kümesi	Özellik Çıkarım Yöntemi	K-NN Doğruluk (Accuracy) (%)	SVM Doğruluk (Accuracy) (%)	ELM Doğruluk (Accuracy) (%)
A(128)/E(128)	PGSY-AO	99.30	99.41	99.33
A(256) /E(256)	PGSY-AO	99.66	99.72	99.72
A(512) /E(512)	PGSY-AO	99.81	99.88	99.75
A(1024) /E(1024)	PGSY-AO	99.75	100	99.88
A(2048) /E(2048)	PGSY-AO	100	100	100
A(4096) /E(4096)	PGSY-AO	100	100	100
A(128)/E(128)	WGSY-AO	99.30	99.24	99.18
A(256) /E(256)	WGSY-AO	99.72	99.75	99.72
A(512) /E(512)	WGSY-AO	99.75	99.88	99.75
A(1024) /E(1024)	WGSY-AO	99.88	100	99.88
A(2048) /E(2048)	WGSY-AO	100	100	100
A(4096) /E(4096)	WGSY-AO	100	100	100



5. SONUÇ VE ÖNERİLER

Epilepsi dünya nüfusunun yaklaşık olarak %1'ini tehdit eden, kendini ani ve tekrarlayan nöbetler ile gösteren, insan yaşam kalitesini olumsuz etkileyen ciddi bir rahatsızlıktır. Beynin elektriksel resmi anlamına gelen EEG, insan beyin hücrelerinde meydana gelen biyolojik kaynaklı elektriksel aktivitenin grafiksel gösterimidir. EEG işaretleri epilepsi hastalığının tespit edilmesinde önemli bilgiler içermektedir.

Bu sebeple bu tez çalışmasında, Bonn Üniversitesi Epileptoloji Bölümü veri tabanından (A,B,C,D,E) alınan EEG işaret kümlelerinden sağlıklı deneklere ait işaretler (A kümesi) ile epilepsi hastası olan deneklerden nöbet sırasında kaydedilen (E kümesi) işaretler kullanılarak farklı zaman ölçeklerinde epilepsi nöbet tespiti yapan otomatik örüntü tanıma sistemi sunulmuştur.

Bu tez çalışmasında sunulan otomatik örüntü tanıma sistemi ile elde edilen sonuçların genel değerlendirilmesi aşağıda detaylı olarak sunulmuştur.

- Yapılan çalışmada 4096 örnek, 23.6 saniye uzunluğundaki EEG işaretleri 128, 256, 512, 1024, 2048, 4096 örnek ve 0.7375, 1.475, 2.95, 5.9, 11.8, 23.6 saniyelik bölütlere ayrılarak tasarlanan otomatik örüntü tanıma sisteminde K-NN, SVM, ELM sınıflandırıcıları ve PGSY-AO, WGSY-AO özellik çıkarım yöntemleri ile yapılan bütün çalışmalar sonucunda elde edilen doğruluk performanslarının %99.18 ile %100 arasında olması tüm çalışma açısından tatmin edici bir sonuç olarak değerlendirilmiştir. Gerek otomatik örüntü tanıma sistemlerinde gerekse klinik uygulamalarda biyolojik işaretin kısa olması tespiti oldukça güçleştirmektedir. Bu sebeple yapılan bu çalışmada kısa işaretler içinde iyi başarımlı performansının yakalanması bu çalışmanın gelecekte yapılması düşünülen çalışmalara önemli katkılar sağlayacağını düşündürmektedir.

- Bu çalışmada kullanılan EEG işaretleri ile farklı özellik çıkarım ve sınıflandırma teknikleri ile çok sayıda örüntü tanıma sistemi sunulduğu bilinmektedir. Literatürde sunulan örüntü tanıma sistemleri ile elde edilen sonuçlar yaptığımız çalışmanın sonuçları ile karşılaştırıldığında sonuçların örtüştüğü görülmüştür. Bu durum çalışma açısından umut verici bir durum olarak değerlendirilmiştir.

- Sistemin başarımlı performansı kullanılan EEG işaretlerinin veri uzunlukları açısından değerlendirildiğinde işaretin veri uzunluğu arttıkça başarımlı performansının arttığı görülmüştür. Bu durum kullanılan tüm özellik çıkarma ve sınıflandırma yöntemlerinde gözlemlenmiştir. PGSY ve WGSY gibi parametrik olmayan GSY yöntemlerini kullanan tüm çalışmalarda işaretin uzunluğunun artması başarımlı performansını artırdığı ifade edilmektedir. Bu sebeple elde edilen sonuçlar literatür ile örtüşmektedir.

- PGSY-AO özellik çıkarma yöntemi açısından değerlendirme yapıldığında en düşük doğruluk performansı A(128)/E(128) işaret kümelerinin K-NN ile sınıflandırılması sonucu %99.30 olarak elde edilmiştir. En yüksek doğruluk performansı A(2048)/E(2048), A(4096)/E(4096) işaret kümelerinin K-NN, SVM ve ELM sınıflandırılması sonucu %100 olarak elde edilmiştir.

- WGSY-AO özellik çıkarma yöntemi açısından değerlendirme yapıldığında en düşük doğruluk performansı A-128/E-128 işaret kümelerinin ELM ile sınıflandırılması sonucu %99.18 olarak elde edilmiştir. En yüksek doğruluk performansı A(2048)/E(2048), A(4096)/E(4096) işaret kümelerinin K-NN, SVM ve ELM sınıflandırılması sonucu %100 olarak elde edilmiştir.

- PGSY-AO ve WGSY-AO özellik çıkarma yöntemleri açısından değerlendirme yapıldığında WGSY-AO özellik çıkarma yönteminin PGSY-AO özellik çıkarma yöntemine göre daha iyi sonuç verdiği görülmüştür. Literatürde WGSY ve PGSY özellik çıkarma yöntemleri ile yapılan çalışmalar incelendiğinde WGSY özellik çıkarma yönteminin PGSY özellik çıkarma yöntemine göre daha iyi sonuçlar verdiği görülmektedir. Bu yönü ile yapılan çalışmanın literatürü desteklediği görülmüştür.

- K-NN sınıflandırıcısı açısından değerlendirme yapıldığında en düşük doğruluk performansı A(128)/E(128) işaret kümelerinin PGSY-AO ve WGSY-AO özellik çıkarma yöntemleri sonucu elde edilen özelliklerin sınıflandırılması %99.30 olarak elde edilmiştir. En yüksek doğruluk performansı A(2048)/E(2048), A(4096)/E(4096) işaret kümelerinin PGSY-AO ve WGSY-AO özellik çıkarma yöntemleri sonucu elde edilen özelliklerin sınıflandırılması %100 olarak elde edilmiştir

- SVM sınıflandırıcısı açısından değerlendirme yapıldığında en düşük doğruluk performansı A(128)/E(128) işaret kümelerinin WGSY-AO özellik çıkarım yöntemi sonucu elde edilen özelliklerin sınıflandırılması %99.24 olarak elde edilmiştir. En yüksek doğruluk performansı A(1024)/E(1024), A(2048)/E(2048), A(4096)/E(4096) işaret kümelerinin PGSY-AO ve WGSY-AO özellik çıkarım yöntemleri sonucu elde edilen özelliklerin sınıflandırılması %100 olarak elde edilmiştir

- ELM sınıflandırıcısı açısından değerlendirme yapıldığında en düşük doğruluk performansı A(128)/E(128) işaret kümelerinin WGSY-AO özellik çıkarım yöntemi sonucu elde edilen özelliklerin sınıflandırılması %99.18 olarak elde edilmiştir. En yüksek doğruluk performansı A(2048)/E(2048), A(4096)/E(4096) işaret kümelerinin PGSY-AO ve WGSY-AO özellik çıkarım yöntemleri sonucu elde edilen özelliklerin sınıflandırılması %100 olarak elde edilmiştir.

- K-NN, SVM, ELM sınıflandırıcısı açışında değerlendirme yapıldığında SVM sınıflandırıcısının tüm özellik çıkarma yöntemlerinde genelde en iyi sonuçları verdiği, K-NN ve ELM sınıflandırıcılarının başarımlarının birbirine yakın olduğu görülmüştür. Tüm sınıflandırıcılar için işaretin uzunluğun artması başarımlarını artırdığı gibi WGSY özellik çıkarım yöntemi ile elde edilen özelliklerin başarımları PGSY özellik çıkarım yöntemi ile elde edilen özelliklerin sınıflandırılması sonucu elde edilen başarımlarından yüksek çıkmıştır.

Bu tez çalışmasında sunulan otomatik örüntü tanıma sistemi ile elde edilen sonuçların genel değerlendirilmesi sonucunda gelecekteki çalışmalara ışık tutması açısından aşağıda ifade edilmeye çalışılan önerilerin sunulması uygun görülmüştür.

- Yapılan çalışmada Bonn Üniversitesi Epileptoloji Bölümü veri tabanından (A,B,C,D,E) alınan A ve E işaret kümeleri kullanılmıştır. Çalışmada kullanılan özellik çıkarım yöntemleri ve sınıflandırıcılar kullanılarak B, C, D işaret kümelerini de için alan bir çalışma yapılarak tüm işaret kümeleri için sonuçlar değerlendirilebilir.

- Bu çalışmada kullanılan A ve E işaret kümeleri için parametrik Özbağlımlı (Autoregressive (AR)) Yürüyen Ortalamalı (Moving Average (MA)) Özbağlımlı Yürüyen Ortalamalı (Autoregressive Moving Average (ARMA)) veya altuzay Çoklu

Sinyal Sınıflaması (Multiple Signal Classification (MUSIC)) Özvektör (Eigenvektör (EV)) GSY yöntemleri kullanılarak özellik çıkarımı yapılabilir ve bu çalışmada kullanılan sınıflandırıcılar ile sınıflandırma yapılarak sonuçlar karşılaştırılabilir.

- Bu çalışmada kullanılan A ve E işaret kümeleri için mevcut özellik çıkarım yöntemleri ile özellik çıkarılarak sınıflandırmada kullanılan sınıflandırıcılardan farklı sınıflandırıcılar ile sınıflandırma yapılarak sonuçlar incelenebilir.

- Farklı veri tabanlarından alınan EEG işaret kümeleri için bu çalışmada kullanılan özellik çıkarım yöntemleri ve sınıflandırıcılar kullanılarak bu çalışma genellenebilir.

- Burada yapılan çalışma temel alınarak bir online otomatik örüntü tanıma sistemi gerçekleştirilebilir. Gerçekleştirilen bu online sistem özellikle uzman hekimler için klinik kullanımda büyük yararlar sağlayabilir ve aynı zamanda gelecekte yapılacak çalışmalar için de faydalı bir veri tabanı oluşturabilir.

6. KAYNAKLAR

- Acar, E. 2012. Yapay Zeka Yöntemleriyle Bitki Yaprak İmgelerinde Pas Hastalıklarının Tespiti. Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır.
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adeli, H. 2018. Deep Convolutional Neural Network for the Automated Detection and Diagnosis of Seizure Using EEG Signals. *Computers in Biology and Medicine*, Vol. 100, Pages: 270–278
- Adeli, H., Zhou, Z., Dadmehr, N. 2003. Analysis of EEG Records in an Epileptic Patient Using Wavelet Transform. *Journal of Neuroscience Methods*, 123 (1), Pages:69-87.
- Anchalia, P., Roy, K. 2014. The K-Nearest Neighbor Algorithm Using MapReduce Paradigm. 2014 Fifth International Conference on Intelligent Systems, Modelling and Simulation, Pages 513-518.
- Andrzejak R.G., Lehnertz K., Mormann F., Rieke C., David P., Elger C. E. 2001. Indications of Nonlinear Deterministic and Finite-Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State. *Physical Review E*, Vol. 64, Pages:1-8.
- Alçın, Ö. F., Şengür, A., İnce, M. C. 2015. İleri-Geri Takip Algoritması Tabanlı Seyrek Aşırı Öğrenme Makinesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, Cilt 30, No 1, Sayfalar: 111-117.
- Albayrak, M. 2008. EEG Sinyallerindeki Epileptiform Aktivitenin Veri Madenciliği Süreci İle Tespiti. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Albayrak, Ü. C. 2012. Tıp Bilişimi Ve Veri Madenciliği Uygulamaları: EEG Sinyallerindeki Epileptiform Aktiviteye Veri Madenciliği Yöntemlerinin Uygulanması. Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne.
- Aydemir, Ö. 2008. Beyin Bilgisayar Arayüzü Uygulamalarına Yönelik EEG İşaretleri İçin Öznitelik Çıkarma. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- Aydilek, İ. B. 2013. Veri Kümelerindeki Eksik Değerlerin Yeni Yaklaşımlar Kullanılarak Hesaplanması. Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

- Başçıl, M. S. 2015. Beyinde Üretilen Yöne Bağlı EEG Sinyallerinin Öznitelik Çıkarımı Yardımıyla Sınıflandırılması. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Bayram, M., Acar, H. 2013 . EEG Sınıflandırma Amaçlı Bir Kompozit Sistem. **Dicle Üniversitesi Mühendislik Fakültesi Dergisi**, Cilt 4, Sayı 1, Sayfalar: 5-12.
- Bayram, M. 2003. EEG Sinyalleriyle Uyuklama Seviyesinin Modern Yöntemlerle Kestirimi. Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır.
- Bingöl, C. A., Aktekin, B., Ağan, K., Arman, F., Aslan, K., Aykutlu, E., Baklan, B., Baykan, B., Bebek, N., Bilir, E., Bora, İ., Bozdemir, H., Gürses, C., Kayrak, N., Özkara, Ç., Saygı, S., Velioglu, S. 2007. **Epilepsi Rehberi. Epilepsi Dergisi**, Sayfalar: 26-38.
- Bozdağ, H. E. 2002. Yeşilyurt ve Avcılar’ da Deprem Yer Tepkisinin Çok Kanallı Mikrotremor Kayıtlarının Analizi ile Belirlenmesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Burges, C. J. C. 1998. A Tutorial on Support Vector Machines for Pattern Recognition. **Knowledge Discovery Data Mining**, Vol.2, Issue 2, Pages: 121-167.
- Cover, T. M., Hart, P. E. 1967. Nearest Neighbor Pattern Classification. **IEEE Transactions on Information Theory**, IT, Vol. 13, Issue 1, Pages 21–27.
- Çomak, E. 2008. Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar. Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Demir, Ö. 2008. EEG Dalgalarının Wavelet (Dalgacık) Dönüşümü İle Değerlendirilmesi, Yüksek Lisans Tezi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü, Kütahya.
- Duda, R. O., Hart, P.E., Stork, D. G. 2000. Pattern Classification, 2nd edition, John Wiley & Sons, Inc.
- Dursun, M. 2009. EEG Sinyallerinde Uyku İçciklerinin Zaman Ve Frekans Domeni Özellikleri kullanılarak Analizi. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Emhan, Ö. 2017. Yukarı-Aşağı İmleç Hareketine İlişkin EEG Kayıtlarının Ayırık Dalgacık, KNN ve DVM ile Sınıflandırılması. Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır.
- Ergül U., Bilgin, G. 2017. Hiperspektral Görüntülerin Melez Çekirdek Aşırı Öğrenme Makinesi ile Sınıflanması; Hyperspectral Image Classification with Hybrid Kernel Extreme Learning

- Machine. SIU'17, IEEE 25th Conf. on Signal Processing and Communications Applications, Antalya, Türkiye, 15-18 Mayıs 2017, Pages: 1-4.
- Fathima, T., Bedeuzzaman, M., Farooq, O., Khan, Y. U. 2011. Wavelet Based Features for Epileptic Seizure Detection. *MES Journal of Technology and Management*, Pages: 108 -112.
- Fu, K., Qu, J., Chai, Y., Dong, Y. 2014. Classification of Seizure Based on the Time-Frequency Image of EEG Signals Using HHT and SVM. *Biomedical Signal Processing and Control*, Vol. 13, Pages: 15–22.
- Fukunaga, K. 1990. Introduction to Statistical Pattern Recognition. Academic Press.
- Guo, L., Rivero, D., Alejandro, P. (2010). Epileptic Seizure Detection Using Multiwavelet Transform Based Approximate Entropy and Artificial Neural Networks, *Journal of Neuroscience Methods*, Volume 193, Issue 1, Pages: 156–163
- Güler, İ., Übeyli, E.D. 2005. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of Neuroscience Methods*, (148), Pages:113-121.
- Güler, İ., Übeyli E. D. (2007). Multiclass Support Vector Machines for EEG-Signals Classification. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 11, Pages 117–126.
- Günel, S. 2008. Örüntü Tanıma Uygulamalarında Altuzay Analiziyle Öznitelik Seçimi ve Sınıflandırma. Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- Gürsoy, M. İ. 2009. Destek Vektör Makineleri İle EEG İşaretlerinin Sınıflandırılmasında TBA, BBA ve DAA'nın Performansının Karşılaştırılması. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Huang, G. 2014. An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels. *Cognitive Computation*, Vol. 6, Issue 3, Pages: 376–390.
- Huang, G., Zhu, Q., Siew, C. 2006. Extreme learning machine. *Theory and applications, Neurocomputing*, Vol. 70, Issue 1-3, Pages: 489–501.
- Hussein, R., Elgendi, M., Wang, Z. J., Ward, R. K. 2018. Robust Detection of Epileptic Seizures Based on L1-Penalized Robust Regression of EEG Signals. *Expert Systems with Applications*, Vol. 104, Pages: 153–167

- Jaiswal, A. K., Banka, H. 2017. Local Pattern Transformation Based Feature Extraction Techniques for Classification of Epileptic EEG Signals. *Biomedical Signal Processing and Control*, Vol. 34, Pages: 81-92
- Kang, J., Chunga, Y. G., Kimb, S. P. 2014. An Efficient Detection of Epileptic Seizure by Differentiation and Spectral Analysis of Electroencephalograms. *Computers in Biology and Medicine*, Vol. 66, Pages: 352–356.
- Kannathala, N., Choo, M. L., Acharyab, U. R., Sadasivan, P. K. 2005. Entropies for Detection of Epilepsy in EEG. *Computer Methods and Programs in Biomedicine*, Vol. 80, Issue 3, Pages 187–194.
- Kaya, Y., Uyar, M., Tekin, R., Yildirim, S. 2014. 1D-Local Binary Pattern Based Feature Extraction For Classification of Epileptic EEG Signals. *Applied Mathematics and Computation*, Vol. 243, Pages: 209-219.
- Kaya, Y., Tekin, R. 2012. Epileptik Nöbetlerin Tespiti için Aşırı Öğrenme Makinesi Tabanlı Uzman Bir Sistem. *Bilişim Teknolojileri Dergisi*, Cilt 5, Sayı 2, Sayfalar: 33-39.
- Kumar, Y., Dewal, M. L., Anand, R. S. 2014. Epileptic Seizures Detection in EEG Using DWT-Based Apen and Artificial Neural Network. *Signal, Image and Video Processing*, Vol. 8, Issue 7, Pages: 1323–1334.
- Kumar, Y., Dewal, M. L., Anand, R.S. 2014. Epileptic Seizure Detection Using DWT Based Fuzzy Approximate Entropy and Support Vector Machine. *Neurocomputing*, Vol. 133, Pages 271–279.
- Kumar, S. P., Sriraam, N., Benakop, P. G., Jinaga, B. C. 2010. Entropies Based Detection of Epileptic Seizures with Artificial Neural Network Classifiers. *Expert Systems with Applications*, Volume 37, Pages: 3284–3291.
- Lee, S. H., Lim, J.S., Kim, J. K., Yang, J., Lee, Y. 2014. Classification of Normal and Epileptic Seizure EEG Signals Using Wavelet Transform, Phase-Space Reconstruction, and Euclidean Distance. *Computer Methods and Programs in Biomedicine*, Vol. 116, Issue 1, Pages: 10–25.
- Li, M., Chen, W., Zhang, T. 2017. Automatic Epileptic EEG Detection Using DT-CWT-Based Non-Linear Features. *Biomedical Signal Processing and Control*, Vol. 34, Pages: 114-125
- Li, D., Xie, Q., Jin, Q., Hirasawa K. 2016. A Sequential Method Using Multiplicative Extreme Learning Machine for Epileptic Seizure Detection. *Neurocomputing*, Vol. 214, Pages: 692–707.
- Mitchell, T. 1997. Machine Learning, McGraw Hill.

- Nergiz, M., Özerdem, M. S., Akın, M. 2014. Dalgacık Dönüşümü Kullanılarak EEG İşaretlerinde Epileptik Nöbet Tespiti, Tıp Teknolojileri Ulusal Kongresi, 25-27 Eylül 2014, Kapadokya, Türkiye. Sayfalar: 70-73.
- Nicolaou, N., Georgiou, J. 2012. Detection of Epileptic Electroencephalogram Based on Permutation Entropy and Support Vector Machines. *Expert Systems with Applications*, Vol. 39, Issue 1, Pages 202–209.
- Nigam, V., Graupe, D. 2004. A Neural-Network-Based Detection of Epilepsy. *Neurological Research*, Vol. 26, Pages:55-60.
- Ocak, H. 2009. Automatic Detection of Epileptic Seizures in EEG Using Discrete Wavelet Transform and Approximate Entropy. *Expert Systems with Applications*. Volume 36, Issue 2, Pages: 2027–2036.
- Ochoa J. B., Molina G. G., Ebrahimi T., 2002. EEG Signal Classification for Brain Computer Interface Applications, *Ecole Polytechnique Federale De Lausanne*, 11.
- Orhan, U., Hekim, M., Ozer, M. 2011. EEG Signals Classification Using the K-Means Clustering and a Multilayer Perceptron Neural Network Model. *Expert Systems with Applications*, Vol. 38, Pages 13475–13481.
- Orhan, U., 2011. EEG İşaretlerinden Epilepsi Hastalığının Teşhisi İçin Yeni Yaklaşımlar. Doktora Tezi, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Zonguldak.
- Özer, O., Günay, M., Alkan, A. 2011. EEG İşaretlerinin Sınıflandırma Ve Kümeleme Teknikleri İle Analizi. *e-Journal of New World Sciences Academy*, Vol. 39, Number 1, Pages 477–485.
- Özer, O., 2010. EEG İşaretlerinin Diskriminant Analizi İle Sınıflandırılması. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Özbeyaz, A. 2010. EMG ve EEG İşaretlerinin Sınıflandırılmasında EKK-DVM Hiper Parametrelerinin PSO'ya Dayalı Seçimi. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Özdemir, N. 2011. EEG İşaretlerinden Hilbert-Huang Transform (HHT) Yöntemi ile Nöbet Algılama ve Tahmini. Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Hatay.
- Özkan, Y., 2008. Veri madenciliği Yöntemleri, Papatya Yayıncılık Eğitim, İstanbul.

- Özmen, N. G. 2010. Beyin Bilgisayar Arayüzü Tasarımı için Farklı Zihinsel Aktiviteler Esnasında Oluşan EEG İşaretlerinin Analiz Edilmesi Ve Sınıflandırılması. Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- Peker, M., Sen, B., Delen, D. 2016. A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers. *IEEE Journal of Biomedical and Health Informatics*, Vol. 20, Issue:1 Pages: 108-118
- Polat, H. 2016. Görsel – İşitsel Uyarılar Kaynaklı Oluşan Duyguların EEG İşaretleri İle Sınıflandırılması. Yüksek Lisans Tezi, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır.
- Polat, H., Özerdem, M. S. 2014. Dalgacık Katsayıları ve Yapay Sinir Ağları Kullanılarak EEG İşaretlerinin Sınıflandırılması. Tıp Teknolojileri Ulusal Kongresi, 25-27 Eylül 2014, Kapadokya, Sayfalar: 62-65
- Polat, K., Güneş, S. 2008. Artificial Immune Recognition System with Fuzzy Resource Allocation Mechanism Classifier, Principal Component Analysis and FFT Method Based New Hybrid Automated Identification System for Classification of EEG Signals. *Expert Systems with Applications*. Volume 34, Issue 3, Pages: 2039–2048.
- Polat, K., Güneş, S. 2007. Classification of Epileptiform EEG Using a Hybrid System Based on Decision Tree Classifier and Fast Fourier Transform. *Applied Mathematics and Computation*, Vol. 187, Issue 2, Pages 1017–102.
- Proakis J.G., Manolakis D.G. 1996. Digital Signal Processing: Principles, Algorithms and Applications, Prentice Hall Inc. New Jersey.
- Riaz, F., Hassan, A., Rehman, S., Niazi, I. K., Dremstrup, K. 2016. EMD-Based Temporal and Spectral Features for The Classification Of EEG Signals Using Supervised Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 24, Issue:1 Pages: 28-35.
- Sanei, S., Chambers, J. A., 2007. EEG Signal Processing. Center of Digital signal processing, United Kingdom.
- Sadati, N., Mohseni, H. R., Maghsoudi, A. 2006. Epileptic Seizure Detection Using Neural Fuzzy Networks. IEEE International Conference on Fuzzy Systems, 16-21 July 2006, Vancouver, BC, Canada. Pages 596–600.
- Sezer, E. 2008. Epilepsi Teşhisi İçin EEG Sinyal Analizi. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

- Sharma, M., Pachori, R. B., Acharya, U. R. 2017. A New Approach to Characterize Epileptic Seizures Using Analytic Time-Frequency Flexible Wavelet Transform and Fractal Dimension. *Pattern Recognition Letters*, Vol. 94, Pages: 172–179
- Srinivasan, V., Eswaran, C., Sriraam, S. 2007. Approximate Entropy-Based Epileptic EEG Detection Using Artificial Neural Networks, *IEEE Transactions on Information Technology in Biomedicine*, Vol. 11, Pages 288–295.
- Srinivasan, V., Eswaran, C., Sriraam, N. 2005. Artificial Neural Network Based Epileptic Detection Using Time-Domain and Frequency-Domain Features. *Journal of Medical Systems*, Vol.29, Issue 6, Pages: 647–660.
- Subasi, A. 2007. EEG Signal Classification Using Wavelet Feature Extraction and a Mixture of Expert Model. *Expert Systems with Applications*, Volume 32, Issue 4, May 2007, Pages 1084–1093.
- Taşçı, E., Onan, A. 2016. K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. XVIII. Akademik Bilişim Konferansı, 3-5 Şubat 2016. Aydın.
- Tekin, R., Kaya, Y., Tağluk, M. E. 2011. K-means ve YSA temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması. Fırat Üniversitesi Elektrik-Elektronik ve Bilgisayar Sempozyumu, Elazığ. Sayfalar: 277-283.
- Teplan, M. 2002. Fundamentals of EEG Measurement. *Measurement Science Review*, Vol. 2, Pages: 1–11.
- Toklu, Z., Kutlu, G., Demirbaş, H., Koyuncu, G., İnan, E. L. 2012. Ankara Eğitim ve Araştırma Hastanesi Epilepsi Polikliniğine Başvuran Epilepsi Hastalarının Demografik ve Klinik Bulguları. *Epilepsi Dergisi*, Sayfalar: 13-18.
- Türkoğlu, İ. 2002. Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma. Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- Tzallas, A. T., Tsipouras, M. G., Fotiadis, D. I.(2007). Automatic Seizure Detection Based on Time-Frequency Analysis and Artificial Neural Networks, *Computational Intelligence and Neuroscience*, Volume 2007, Pages: 1–13.
- Uşaklı, A. B. 2006. Elektriksel Kaynak Görüntüleme Amaçlı 256 Kanallı Elektroensefalografik Veri Toplama Sistemi. Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Vapnik, V.N. 1995. The Nature of Statistical Learning Theory, Springer-Verlag, New York.

- Wang, L., Xue, W., Li, Y., Luo, M., Huang, J., Cui, W., Huang, C. 2017. Automatic Epileptic Seizure Detection in EEG Signals Using Multi-Domain Feature Extraction and Nonlinear Analysis. *Entropy*, Vol. 19, Issue:6 Pages: 222
- Wang, D., Miao, D., Xie, C. 2011. Best Basis-Based Wavelet Packet Entropy Feature Extraction and Hierarchical EEG Classification for Epileptic Detection. *Expert Systems with Applications*, Vol. 38, Issue 11, Pages: 14314–14320.
- Yıldız, A., Akın, M., Poyraz, M. 2011. An Expert System for Automated Recognition of Patients with Obstructive Sleep. *Expert Systems with Applications*, Vol. 38, Issue 10, Pages: 12880–12890.
- Yıldız, A. 2011. EEG ve EKG İşaretlerinden Örüntü Tanıma Uygulamaları ve Karşılaştırılması. Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- Yeni, S. N., Karaağaç, N. 2005. Epilepsiler Nörolog Olmayanlar İçin Nöroloji Sempozyum Dizisi, Ocak 2005, İstanbul. Sayfalar: 159-175.
- Zhang, T., Chen, W., Li, M. 2018. Fuzzy Distribution Entropy and Its Application in Automated Seizure Detection Technique. *Biomedical Signal Processing and Control*, Vol. 39, Pages: 360–377.
- Zhang, T., Chen, W. 2016. LMD Based Features for the Automatic Seizure Detection of EEG Signals Using SVM. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 25, Issue:8 Pages: 1100-1108
- Zhu, G., Li, Y., Wen, P. 2014. Epileptic Seizure Detection in EEGs Signals Using a Fast Weighted Horizontal Visibility Algorithm. *Computer Methods and Programs in Biomedicine*, Vol. 115, Issue 2, Pages: 64–75.

ÖZGEÇMİŞ

Kişisel Bilgiler:

Adı – Soyadı: Mehmet YILDIRIM

Doğum Yeri: Hani

Doğum Tarihi: 25/09/1975

Yabancı Dil: İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise: Ziya Gökalp Lisesi / Diyarbakır, 1993

Lisans: İstanbul Üniversitesi, Elektronik Mühendisliği / İstanbul, 1999

Çalıştığı Kurumlar, Pozisyon ve Süre:

Diyarbakır Devlet Hastanesi: Teknik Servis Mühendisi, 2003 – 2005

Digitek Bilgisayar, Medikal Tic. Ltd. Şti: Müdür Yardımcısı, 2005 – 2006

Aneltech A.Ş: Transmisyon Birim Yöneticisi, 2007 – 2010

Asur İletişim Tic. Ltd. Şti: Transmisyon Network Grup Yöneticisi, 2010 – 2011

Dicle Üniversitesi Sivil Havacılık Yüksekokulu: Öğretim Görevlisi, 2011- Devam

Yayınlar:

Yıldırım, M., Yıldız, N. 2017 Farklı Zaman Ölçekli EEG İşaretlerinden Epilepsi Nöbetinin Otomatik Tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, Cilt: 8, Sayı:4 Sayfa:745-757

Yıldırım, M., Yıldız, N. 2017. Automated recognition of epilepsy from EEG signals. International Artificial Intelligence and Data Processing Symposium (IDAP). Malatya, Turkey.



T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI İNTİHAL RAPORU FORMU

ÖĞRENCİ BİLGİLERİ

ADI VE SOYADI	Mehmet YILDIRIM
ÖĞRENCİ NO	12805008
EĞİTİM - ÖĞRETİM YILI	2017-2018
YARIYIL	☐ Güz ☒ Bahar
ANABİLİM DALI	Elektrik-Elektronik Mühendisliği
PROGRAM	Yüksek Lisans
TEZ KONUSU	Farklı Zaman Ölçekli EEG İşaretlerinden Epilepsinin Tespiti

İNTİHAL RAPORU BİLGİLERİ

RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	99
BENZERLİK ORANI	%22
RAPORLAMA TARİHİ	18/10/ 2018

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 99 sayfalık kısmına ilişkin, 18/10/2018 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 22 'dir.

Uygulanan filtrelemeler:

- ☐ Kabul/Onay sayfaları hariç,
- ☐ Kaynakça hariç
- ☐ Alıntılar hariç/dâhil
- ☐ Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

1974

Mehmet YILDIRIM

18/10/2018

Dr. Öğr. Üyesi Abdülnasır YILDIZ
Tez Danışmanı

18/10/2018

Prof. Dr. İbrahim KAYA
Anabilim Dalı Başkanı