

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



EPİLEPTİK EEG SİNYALLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI

Andaç İMAK

Yüksek Lisans Tezi

Anabilim Dalı: Elektrik Elektronik Mühendisliği Teknolojileri

Danışman: Doç. Dr. Melih Cevdet İNCE

ELAZIĞ-2019

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EPİLEPTİK EEG SİNYALLERİNİN MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ
Andaç İMAK
(161138102)

Tezin Enstitüye Verildiği Tarih : 04.12.2018

Tezin Savunulduğu Tarih : 22.03.2019

Tez Danışmanı : Doç. Dr. Melih Cevdet İNCE (F.Ü.)

Diğer Jüri Üyeleri : Prof. Dr. Abdulkadir ŞENGÜR (F.Ü.)
Dr. Öğr. Üyesi Ömer Faruk ALÇİN (B.Ü.)

Mart-2019

ÖNSÖZ

Yüksek lisans tez çalışmam boyunca güven ve desteğini her zaman hissettiğim kıymetli danışman hocam Doç. Dr. Melih Cevdet İNCE'ye bana öğrettiği her şey için teşekkür ederim.

Tezimin yürütülmesinde büyük bir titizlik, sabır ve özveriyle bana destek olan, beni araştırmaya yöneltten ve hiçbir yardımını benden esirgemeyen kıymetli hocam Dr. Öğr. Üyesi Ömer Faruk ALÇİN'e teşekkürü bir borç biliyor ve şükranlarımı sunuyorum.

Lisansüstü eğitimim boyunca bilgi ve deneyimlerinden yararlanarak fikir alışverişinde bulunduğum kıymetli hocam Prof. Dr. Abdulkadir ŞENGÜR'e teşekkür ederim.

Hayatımın tüm aşamasında maddi ve manevi her zaman yanımda olan, aldığım kararlarda arkamda durup bana cesaret veren, benliğimi borçlu olduğum aileme en içten ve en samimi minnet borcu duygularım ile iyi ki varsınız.

Bu yüksek lisans tezinin ülkemizde medikal tanı sistemleri üzerine çalışma yapacak olanlara katkıda bulunmasını dilerim.

Andaç İMAK
ELAZIĞ- 2019

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	IX
KISALTMALAR LİSTESİ	X
SİMGELER LİSTESİ	XI
1. GİRİŞ	1
1.1. Genel Bilgi ve Literatür	1
1.2. Tezin Amaç ve Organizasyonu	5
2. TEORİK ALT YAPI	7
2.1. Beyin	7
2.1.1. Beyinde Elektriksel Sinyal Oluşumu	9
2.2. EEG Sinyalleri	11
2.2.1. EEG Dalgaları	12
2.2.2. Elektrot Yerleşim Sistemi	15
2.2.3. EEG Sinyallerindeki Bozucu Faktörler	17
2.2.4. Beyin Bilgisayar Arayüz (BBA) Sistemlerinde Sinyal Ön İşleme	19
2.3. Epilepsi	23
2.4. Öznitelik Çıkarma	26
2.4.1. Ortalama	26
2.4.2. Standart Sapma	26
2.4.3. Yerel Maksimum Sayısı	27
2.4.4. Ortalama Eğri Genişliği	27
2.4.5. Hijort Parametreleri	28
2.4.6. Tekrarlılık Ölçüm Analizi	28
2.4.7. Çok Boyutlu Dalgacık Dönüşümü	30
2.5. Aşırı Öğrenme Makinesi	32
2.5.1. Moore-Penrose Genelleştirilmiş Tersİ	32

2.5.2. Genel Doğrusal Sistemin En Küçük Norm En Küçük Kareler Çözümü	33
2.5.3. Tek Gizli Katmanlı İleri Beslemeli Ağlar	34
2.5.4. Eğim-Temelli Öğrenme Algoritması	36
2.5.5. Tek Gizli Katmanlı İleri Beslemeli Ağlar En Küçük Kareler Çözümü.....	37
2.5.6. Tek Gizli Katmanlı İleri Beslemeli Ağlar için Öğrenme Algoritması.....	39
2.6. Destek Vektör Makineleri.....	40
2.6.1. Doğrusal Ayrılabilen Veriler İçin DVM.....	41
2.6.2. Doğrusal Ayrılamayan Veriler İçin DVM.....	43
2.7. En Yakın K-Komşu Algoritması	44
2.8. Karar Ağaçları	45
2.9. Performans Değerlendirme Kriteri	46
2.9.1. Alıcı İşlem Karakteristikleri (ROC) Eğrileri:	50
2.10. Deneysel Çalışmada Kullanılan EEG Veri Seti.....	52
3. YEREL MAKSİMUM SAYISI, HİJORT MOBİLİTE, HİJORT KARMAŞIKLIK, ORTALAMA EĞRİ GENİŞLİĞİ, STANDART SAPMA VE ORTALAMA ÖZNİTELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI.....	54
3.1. Deneysel Çalışma ve Sonuçları	54
4. TEKRARLILIK ÖLÇÜM ANALİZİ ÖZNİTELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI.....	59
4.1. Deneysel Çalışma ve Sonuçları	59
5. ÇOK BOYUTLU DALGACIK DÖNÜŞÜMÜ VE TEKRARLILIK ÖLÇÜM ANALİZİ ÖZNİTELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI.....	64
5.1. Deneysel çalışma ve sonuçları.....	64
6. SONUÇLAR VE ÖNERİLER.....	69
KAYNAKLAR	71
ÖZGEÇMİŞ	81

ÖZET

Dünya Sağlık Örgütü'nün (WHO) analizlerine göre epilepsi dünyada en yaygın görülen bir nörolojik hastalıktır. Her yaşta insanı etkileyebilen bu hastalık bilinç kaybı, hareket bozukluğu ve diğer bilişsel işlevler gibi geçici istemsiz durumlar oluşturmaktadır. Halk arasında sara olarak da adlandırılan bu hastalığın teşhisinde noninvaziv veya intrakraniyal EEG yöntemleri ile beyindeki elektriksel sinyal kayıt altına alınır. Epileptik EEG sinyallerinin çok çeşitli morfolojilere sahip olmasından dolayı nörofizyologların değerlendirmesi hem zaman alıcı hem de yanıltıcı olabilmektedir. Bundan dolayı epilepsi tespitinde yerel sağlık sistemlerine entegre modeller geliştirmeyi amaçlayan çalışmalar yapılmaktadır. Literatürde de EEG sinyallerinden epilepsi tespiti için uzmanlara yardımcı olmak amacıyla makine öğrenmesi temelli yaklaşımlar mevcuttur.

Bu tez çalışmasında da nöbet tespitinde medikal tanı sistemlerine fayda sağlayacak, işlem maliyetini azaltacak bir yöntem amaçlanmıştır. Kaliforniya Bonn Üniversitesi Epileptoloji Bölümü tarafından gerçekleştirilen erişime açık EEG epileptik veri seti kullanılarak 3 ayrı çalışma yapılmıştır. Çalışmalarda farklı yöntemlerle elde edilen öznitelikler Aşırı Öğrenme Makineleri (AÖM), Destek Vektör Makineleri (DVM), En Yakın K-Komşu (KNN) ve Karar Ağaçları (KA) ile sınıflandırılmıştır. Ayrıca en iyi başarımlar elde edilen sistem için tıpta tanı testlerinde sınıflandırma değerlendirmesinde yaygın olarak kullanılan ROC (Alıcı İşlem Karakteristikleri) eğrisi ile analizleri yapılarak sınıflandırıcının performans değerlendirilmesi yapılmıştır. Son olarak da literatürdeki aynı veri seti kullanılarak yapılan çalışmalar ile karşılaştırılmıştır.

Anahtar Kelimeler: Epilepsi, Elektroensefalogram, Aşırı Öğrenme Makineleri, En Yakın K-Komşu, Destek Vektör Makineleri, Karar Ağaçları.

SUMMARY

Classification of Epileptic EEG Signals Based on Machine Learning Methods

According to World Health Organization (WHO) analyses, epilepsy is the most common neurological disorder in the world. This disorder, that can affect people of all ages, leads to loss of consciousness, movement disorder, and like other cognitive functions causes temporary involuntary situations. In order to make a diagnosis of Epilepsy, which is also called as sara, the electrical signal in the brain is recorded by non-invasive or intracranial EEG methods. Due to the wide variety of morphologies of epileptic EEG signals, the evaluation them by neurophysiologists could be both time-consuming and misleading. Therefore, studies have been carried out to develop integrated models of diagnosis of epilepsy for local health systems. There are machine learning-based approaches in the literature to assist specialists in diagnosing epilepsy from EEG signals.

In this thesis, the aim is to develop a method which will be beneficial to medical diagnostic systems and reduce the transaction cost in seizure detections. Three separate studies were performed using the open-access EEG epileptic dataset that have carried out by the University of Bonn University Epileptology Department. In the studies, features that obtained by different methods have classified based on Extreme Learning Machines, Support Vector Machines, K-Nearest Neighbour, and Decision Trees. In addition, for the system which the highest performance results was obtained by, ROC curve (Receiver Operation Characteristics), that commonly used in classification assessment in diagnostic test, was used to analyse classifier's performance evaluation. Finally, obtained results compared with the studies in the literature that have been used.

Keywords: Epilepsy, Electroencephalogram, Extreme Learning Machines, K-Nearest Neighbour, Support Vector Machines, Decision Trees.

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 1.1. Önerilen sistemin genel aşamaları	2
Şekil 2.1. Beyindeki sağ ve sol yarım küre	7
Şekil 2.2. Anatomik beyin bölgeleri.....	8
Şekil 2.3. Örnek bir nöron yapısı	9
Şekil 2.4. Kimyasal Hareket.....	10
Şekil 2.5. Aksiyon Potansiyeli	10
Şekil 2.6. Örnek bir EEG sinyali.....	12
Şekil 2.7. Delta dalgası.....	13
Şekil 2.8. Teta dalgası	13
Şekil 2.9. Alfa dalgası	14
Şekil 2.10. Beta dalgası	14
Şekil 2.11. Gama dalgası.....	15
Şekil 2.12. 10/20 sistemine göre elektrot yerleşimi ve örnek bir EEG dalga şekli	16
Şekil 2.13. (A) Bipolar, (B) Monopolar Elektrot Bağlantı Şekli	17
Şekil 2.14. Göz ve göz kapağının etkisi ile oluşan artifaktlar	17
Şekil 2.15. Terlemeye bağlı oluşan artifaktlar	18
Şekil 2.16. Kas kasılmalarına bağlı artifaktlar]	18
Şekil 2.17. Elektrotların etkisine bağlı artifaktlar	19
Şekil 2.18. Şebeke etkisine bağlı artifaktlar	19
Şekil 2.19. EEG sinyallerinin elde edilme aşamaları	20
Şekil 2.20. EEG kep ve elektrotu	20
Şekil 2.21. Yüksek geçiren filtre	21
Şekil 2.22. Alçak geçiren filtre	22
Şekil 2.23. A / D dönüştürücü	22
Şekil 2.24. EEG dalga formları	24
Şekil 2.25. Normal olmayan EEG sinyalleri	25
Şekil 2.26. Epileptik nöbet tespit sistemi	25
Şekil 2.27. Bir EEG sinyali için yerel maksimum noktaları	27
Şekil 2.28. Epileptik ve Normal EEG Sinyalindeki Tekrarlılık Nokta Grafiği.....	29
Şekil 2.29. $j=3$ için alt uzaylara ayırma şeması	32

Şekil 2.30. TKGİB ağ yapısı	34
Şekil 2.31. İki sınıflı problemler için muhtemel hiper-düzlemler	40
Şekil 2.32. Optimum hiper-düzlem ve destek vektörleri.....	41
Şekil 2.33. Doğrusal olarak ayrılabilen veri kümesi için optimum hiper düzlemin belirlenmesi.....	42
Şekil 2.34. Kernel fonksiyonu ile hiper-düzlemin belirlenmesi.....	44
Şekil 2.35. Doğrusal olarak ayrılabilen veri kümesi için optimum hiper düzlemin belirlenmesi.....	44
Şekil 2.36. Yeni bir örneğin en yakın $k=5$ için komşu belirlenmesi	45
Şekil 2.37. Karar ağacı örneği	46
Şekil 2.38. Teşhis sistemindeki genel dağılım	50
Şekil 2.39. ROC uzay grafiği	51
Şekil 2.40. ROC analizi.....	51

TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1. AÖM yönteminde kullanılan başlıca aktivasyon fonksiyonları	39
Tablo 2.2. Tespit sisteminde karşılaşılabilecek durumlar.....	47
Tablo 2.3. EEG veri seti.....	52
Tablo 3.1. Deneysel çalışmada kullanılan 7 durum.....	54
Tablo 3.2. Önerilen özneliklerin AÖM üzerindeki başarımları	55
Tablo 3.3. 7 durum için ROC eğrisi.....	55
Tablo 3.4. Önerilen özneliklerin KA, DVM, KNN ve AÖM üzerindeki başarımları sonuçları.....	57
Tablo 3.5. Bonn Üniversitesinden elde edilen veri setleri ile yapılan çalışmalar ve doğruluk yüzdesi.....	58
Tablo 4.1. Önerilen özneliklerin AÖM üzerindeki başarımları	59
Tablo 4.2. Önerilen yöntemin 7 durum için ROC eğrisi	60
Tablo 4.3. Önerilen özneliklerin KA, DVM, KNN ve AÖM üzerindeki başarımları sonuçları.....	62
Tablo 4.4. Epileptik EEG sinyalleri üzerine yapılan çalışmalar	63
Tablo 4.5. Aynı veri seti ve öznelik çıkarma yöntemi kullanılarak yapılan çalışmalar ...	63
Tablo 5.1. CDD özneliklerinin başarımları	64
Tablo 5.2. TÖA özneliklerinin başarımları	65
Tablo 5.3. CDD + TÖA özneliklerinin başarımları	65
Tablo 5.4. Önerilen (CDD+TÖA) özneliklerin AÖM üzerindeki başarımları.....	66
Tablo 5.5. Önerilen yöntemin 7 durum için ROC eğrisi	66
Tablo 5.6. Aynı veri seti ile literatürde yapılan çalışmalar.....	68

KISALTMALAR LİSTESİ

AÖM	: Aşırı Öğrenme Makinası
A / D	: Analog-Dijital Dönüştürücü
BBA	: Beyin Arayüz Sistemleri
CDD	: Çok Boyutlu Dalgacık Dönüşümü
DET	: Belirlilik
DVM	: Destek Vektör Makineleri
EEG	: Elektroensefalogram
ENTR	: Entropi
GSY	: Güç Spektrum Yoğunluğu
HK	: Hijort Karmaşıklık
HM	: Hijort Mobilite
KA	: Karar Ağaçları
KNN	: En Yakın K-Komşu
L	: Ortalama Köşegen Uzunluğu
LAM	: Tabakalanma
O	: Ortalama
OEG	: Ortalama Eğri Genişliği
ROC	: Alıcı İşlem Karakteristikleri
RR	: Tekrarlılık Oranı
SS	: Standart Sapma
TDA	: Tekil Değer Ayrışımı
TGKİB	: Tek Gizli Katmanlı İleri Beslemeli
TÖA	: Tekrarlılık Ölçüm Analizi
TT	: Yakalama Zamanı
YMS	: Yerel Maksimum Sayısı
WHO	: Dünya Sağlık Örgütü

SİMGELER LİSTESİ

$\hat{w}_i$	: w 'nin en küçük kareler çözümü
$\hat{\beta}_i$	: β 'nin en küçük kareler çözümü
$\hat{b}_i$	: b 'nin en küçük kareler çözümü
$\hat{x}$	: x 'in en küçük kareler çözümü
$(.)^T$	: Transpoz operatörü
$(.)^\dagger$	: Moore-Penrose Genelleştirilmiş Ters operatörü
$\ \cdot\ $	: Öklid uzayında norm operatörü
2^j	: Ölçeklendirme parametresi
(w_i, x_j)	: w_i ve x_j içsel çarpımını ifade
$\min[.]$	: Minimizasyon operatörü
(x_i, y_i)	: Veri çifti
a_i	: Lagrange katsayısı
b_i	: Gizli katman eşik değeri
C	: Düzenleme parametresi
$f_{(s)}$	: Örnekleme frekansı
f_c	: Kesim frekansı
G	: H Moore-Penrose Genelleştirilmiş Ters
$g(\cdot)$	: Gizli katman aktivasyon fonksiyonu
H	: Gizli katman çıkış matrisi
j	: Ölçeklendirme katmanı
K	: alt bant endeksi
k	: son örnek
l_{min}	: Minimum köşegen uzunluğu
M	: Gizli katman nöron sayısı
N	: Örnek sayısı
N	: AÖM'nde nöron sayısı
$P_{(l)}$	: l uzunluklu köşegen çizgilerin histogramı
$P_{(v)}$	: v uzunluklu dikey çizgilerin histogramı
$t_{(s)}$	: örnekleme periyodu

v_{min}	: Minimum dikey çizgi uzunluğu
W	: (w_i, β_i) ve b_i 'yi temsil eden vektör
w_i	: Giriş katman ağırlıkları
Y_j	: TGKİB ağ çıkışı
X_j	: TGKİB ağ girişi
$x_{[m]}$	: EEG zaman serisi
$x_{[n]}$	: EEG zaman serisi
Q_j	: TGKİB ağının çıkışı
β_i	: Çıkış katmanı ağırlıkları
θ	: Yoğunluk fonksiyonu
$\Phi_{j,k}(t)$	: Yaklaşım uzayında ölçeklendirme fonksiyonu
$\psi_{j,k}(t)$	: Ayrıntı uzayında ölçeklendirme fonksiyonu
η	: Eğim-Temelli öğrenme algoritması öğrenme oranı
ε	: Kesme mesafesi
φ	: Kernel fonksiyonu
λ_i	: Lagrange katsayısı
σ_0	: Sinyalin varyansı veya ortalama gücüdür
σ_1	: Birinci türevin varyansı
σ_2	: İkinci türevin varyansı
$\Omega_{0,0}$	: Ağacın kök kısmı
ξ_i	: Yapay pozitif değişken

1. GİRİŞ

1.1. Genel Bilgi ve Literatür


Epilepsi her yaştan insanı etkileyen beyindeki bir grup hücrenin aşırı elektrik boşalması sonucu oluşan nörolojik bir bozukluktur. Beyindeki bu bozukluğun ilk nerede başladığına ve ne kadar yayıldığına göre nöbetlerin özellikleri değişmektedir. Kişide belirli bir süre içerisinde bilinç, davranış, duygu, hareket veya algılama fonksiyonlarına ilişkin bozukluğa yol açıp erken teşhis ve tespiti önem arz etmektedir. Epilepsi dünyada tahminen her yıl 2.4 milyon kişide görülen en yaygın nörolojik rahatsızlıktır. Dünya Sağlık Örgütü'nün (WHO) son raporuna göre dünya nüfusunda yaklaşık 50 milyon kişi epilepsi hastası olup bunun %80'ine yakın kısmı düşük ve orta gelirli ülkelerde yaşamaktadır [1].

Epilepsi teşhisi ve tespiti Elektroensefalogram (EEG) ile mümkündür. Beyindeki nöronların binlerce ve milyonlarcasının hareketliliği sonucu aksiyon potansiyelleri olarak adlandırılan elektrik işaretleri üretirler. EEG beyindeki bu elektriksel dalgalanmaları kafatası üzerine Uluslararası EEG Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot yerleştirme yöntemi kullanılarak yerleştirilen elektrotlar yardımıyla kaydeden bir tanı aracıdır. Kaydedilen bu sinyallerin tespiti için deneyimli nörofizyologlar tarafından görsel analiz edilmektedir. Epileptik EEG sinyalleri çok çeşitli morfolojilere sahip olduğundan dolayı nöbetler her zaman kolay tespit edilemez [2]. Bu anormalliklerde çoğu zaman uzmanların değerlendirmesini yanıltıcı ve nihayetinde zaman alıcı etkisiz bir sürece yol açmaktadır [3]. Bundan dolayı epilepsi tespitinde uzmanlara yardımcı otomatik tanı tespit sistemlerine ihtiyaç duyulmuştur.

19. yüzyıldan itibaren biyomedikal alanında bilimsel çalışmalar sayesinde çok büyük yenilikler yapılmıştır. Bu çalışmaların bir kısmı yalnızca beyindeki nöral aktiviteye dayanan Beyin Arayüz Sistemleri (BBA) sayesinde direkt iletişim ve kontrol metotları geliştirmek üzerine yoğunlaşmaktadır. İlk olarak 1960-1970 yıllarında Fetz ve arkadaşları tarafından bireyler üzerinde yapılan deneylerde beyindeki nöronal aktivitenin tanımlanabileceğini göstermişlerdir [4]. Aynı yıllar içerisinde bireyin bir uyarıcıya odaklandığında uyarı geldikten sonra beyin yan lobunda 300-500 ms aralığında EEG sinyalinde bir pozitif sapma gözlemlenmiştir. Bu gözlem üzerine 1980-1990 yılları arasında felçli insanlar tarafından "evet-hayır" şeklinde niyetlenen ifadeleri ortaya

ıkarılabilmesi zerine bir yntem nerilmiřtir [5, 6]. BBA sistemlerinde noninvaziv gerekleřtirilen tekniklerinin arasında oėunlukla EEG sinyalleri kullanılmaktadır. Mcfarland ve arkadaşları kiřinin saė ve sol el hareketi dřncelerini kullanarak iki boyutlu bir hareket kontrol saėlanan BBA sistemi gstermiřlerdir. Bu hareket kontrol alıřmasında EEG sinyallerinin alt bantları olarak adlandırılan alfa ve beta dalga ritimleri kullanılarak hareket dřncelerini tahmin etmiřlerdir [7, 8]. Ayrıca bilimsel arařtırmalar 1970 yılının bařlarında EEG-BBA sistemleri ile insanın yařam kalitesini etkileyen epilepsi hastalıėının tespiti zerine de alıřmalar bařlamıřtır.

Gnmzde de epilepsi tespiti iin yerel saėlık sistemlerine entegre modeller geliřtirmeyi amalayan projeler birok lkede devam etmektedir. alıřmalarda epileptik nbetlerin saptanması iin birok algoritma ve sinyal iřleme yntemleri kullanılarak nerilmiřtir. nerilen tm sinyal iřleme yntemleri EEG kayıtlarındaki epileptik sinyallerin eřitli karakterize zelliklerini tespit etmeyi amalamaktadır. nk epileptik nbetler genellikle EEG kayıtlarında ritmik deřarjlar veya oklu titremeler řeklinde grlmektedir. Bilgisayar destekli EEG analiz iřlemlerinde, bireyden alınmıř ham EEG sinyali eřitli grltlerden arındırmak iin bir n iřleme tabi tutulmaktadır. Elde edilen EEG sinyallerinin iřlem basamakları řekil 1.1’de gsterilmiřtir.



řekil 1.1. nerilen sistemin genel ařamaları

řekil 1.1’de de grleceėi zere otomatik epileptik nbet tespiti iin geliřtirilen yntemlerin tm genel olarak znitelik ıkarımı ve sınıflandırma řeklinde iki ana ařamadan oluřmaktadır. Sistemin ilk ařaması zaman, frekans ve zaman-frekans uzayı znitelik ıkarma yntemi kullanılarak bir EEG sinyalinin ayırt edilmesini saėlayacak en iyi parametrenin bulunması aısından en nemli adımlardan birisidir. Sinyalin elde edilmesinde oluřacak hatalar ve uygun zniteliklerin belirlenememesi durumu tespit sistemlerini olumsuz etkilemektedir. Sistemin ikinci ařamasında ise elde edilen bu znitelikler uygun bir makine ėrenmesi yntemi ile sınıflandırılmaktadır [9].

Literatrde karmařık, duraėan ve doėrusal olmayan EEG sinyallerinin analizi iin sinyal iřleme ve makine ėrenme temelli birok alıřma mevcuttur. Acharya ve arkadaşları

epileptik EEG sinyallerini karakterize etmek için korelasyon boyutu, hurst üssü ve yaklaşık entropi yöntemlerini kullanmışlardır. Çıkarılan bu öznitelikler gauss karma modeli ve DVM ile sınıflandırılarak yaklaşık olarak %95 doğruluğa sahip bir sonuç elde etmişlerdir [10]. Tzallas ve arkadaşları durağan olmayan EEG sinyalleri için zaman-frekans analizine dayalı bir yöntem önermişlerdir. Zaman-frekans düzlemindeki enerji dağılımını temsil eden her bölüm için bazı özellikler çıkarılarak yapay sinir ağına giriş parametreleri olarak kullanmışlardır [11]. Kumar ve arkadaşları epileptik EEG sinyallerinin ayrık dalgacık dönüşümü ile yaklaşım ve detay katsayıları elde edilerek yaklaşık entropi değerleri hesaplanmıştır. Elde edilen bu öznitelikler yapay sinir ağına girdi olarak kullanılmıştır [12]. Orhan ve arkadaşları EEG sinyallerini ayrık dalgacık dönüşümü kullanılarak frekans alt-bantlarına ayırmışlardır. Daha iyi sonuçlar elde etmek için dalgacık katsayıları her frekans alt-bandı için KNN algoritması kullanılarak kümelendirilmiştir. Elde edilen öznitelikleri sınıflandırmak için çok katmanlı sinir ağı modelini kullanmışlardır [13]. Liang ve arkadaşları spektral güç ve entropi analizi ile epileptik EEG sinyallerinden elde edilen özniteliklerin seçiminde temel bileşen analizi ile genetik algoritma kullanmışlardır. Elde edilen sonuçlara göre temel bileşen analizinin daha iyi sonuç verdiği gözlemlenmiştir [14]. Alam ve arkadaşları epilepsi ve nöbeti saptamak için ampirik mod ayrışma yöntemi ile elde edilen varyans, kurtozis ve çarpıklığı içeren yüksek dereceden momentler EEG sinyallerinin sınıflandırılması için bir yapay sinir ağı modeline öznitelik olarak uygulanmıştır. Yapılan çalışmalar sonucunda yöntemin umut verici olduğu gözlemlenmiştir [15]. Das ve arkadaşları çift-ağaçlı karmaşık dalgacık dönüşümü kullanılarak öznitelikler yapay sinir ağı ve DVM ile sınıflandırılmıştır. Deneysel çalışmalar DVM'nin daha iyi başarıma sahip olduğu görülmüştür [16]. Tzamourta ve arkadaşları EEG sinyallerini alt bantlara bölmek için ayrık dalgacık dönüşümü kullanarak dalgacık tabanlı bir yöntem sunmuşlardır. Elde edilen öznitelikler DVM yardımıyla 5 farklı sınıflandırma probleminde analiz etmişlerdir [3]. Sharma ve arkadaşları epileptik nöbetleri saptamaya yönelik yeni bir yaklaşım sunmuşlardır. Önerilen çalışmada analitik zaman-frekanslı esnek dalgacık dönüşümü kullanmışlardır. Dönüşüm sonrası oluşan her alt bant fraktal boyut kullanılarak hesaplanarak en küçük kareler DVM ile analiz edilmiştir [17]. Samiee ve arkadaşları ayrık kısa süreli fourier dönüşümü ve sınıflandırıcı olarak çok katmanlı algılayıcı ile epileptik nöbet tespiti için bir yöntem sunmuşlardır [18]. Peker ve arkadaşları EEG verilerinde çift-ağaçlı karmaşık dalgacık dönüşümü kullanılarak boyut indirgemesi gerçekleştirmiştir. Daha sonraki aşamada özellik vektörleri kullanılarak beş öznitelik

(maksimum değer, minimum değer, aritmetik ortalama, standart sapma, medyan) istatistiksel ölçümlere dayalı olarak hesaplanmıştır. Bulunan öznitelikler karmaşık-değerli sinir ağı tarafından öğrenmeye tabi tutulup analiz edilmiştir [19]. Sharmila ve arkadaşının çalışmaları ayırık dalgacık dönüşümü analizine dayanmaktadır. Epileptik EEG sinyallerinden elde edilen istatistiksel özellikler naive bayes ve KNN algoritması kullanılarak incelenmiştir. Yapılan çalışmanın sonucunda naive bayes sınıflandırıcı kısa sürede daha iyi başarımlar verdiği gözlemlenmiştir [20]. Nicolaou ve arkadaşları çalışmalarında permütasyon entropisini DVM ile bütünleştirerek epileptik nöbet tespiti için bir yöntem ileri sürmüşlerdir [21]. Alçin ve arkadaşları epileptik EEG sinyallerinin analizi için frekans tabanlı öznitelikler ve en küçük kareler DVM kullanılan bir yöntem sunmuşlardır [22]. Acharya ve arkadaşları tekrarlılık ölçüm analiz yönteminin sinyal hakkında doğru bilgi edinileceği üzerine dikkat çekmiştir. Bu yöntem ile epileptik EEG sinyallerinden elde edilen öznitelik parametrelerini DVM, gauss karma modeli, bulanık mantık sınıflandırıcı, KNN, naive bayes sınıflandırıcı, KA ve radyal tabanlı olasılıksal sinir ağı olmak üzere 7 sınıflandırıcı ile çalışmalar yapılmıştır. Bu denemeler sonucunda DVM ile %95.6'lık doğruluk sunduğu bulunmuştur [23]. Ouyang ve arkadaşları sıçanlardan elde edilen EEG kayıtlarından epileptik nöbet tespiti üzerine bir çalışma yapmışlardır. Çalışma sonucunda tekrarlılık ölçüm analizinin EEG verisinin gizli dinamiklerini ortaya koyduğunu belirlemişlerdir [24]. Onay ve arkadaşları epileptik EEG sinyallerinin tespitinde Hilbert-Huang dönüşümü ile elde edilen fonksiyonlarının tekrarlılık grafiğinden faydalanmıştır. Elde edilen öznitelikler DVM ile sınıflandırılmasında %96.67'lik bir başarımlar elde etmişlerdir [25]. Thomasson ve arkadaşları EEG sinyallerinde epileptik nöbet öncesi analizinde tekrarlılık özniteliklerine dikkat çekmiştir [26]. Iscan ve arkadaşları zaman ve frekans özelliklerinin EEG hakkında doğru bilgi edinildiği düşünülmüş zaman domeninde çapraz korelasyon, frekans domeninde ise Güç Spektrum Yoğunluğu (GSY) metoduna dikkat çekmiştir [27]. Subası EEG sinyalini ayırık dalgacık dönüşümü kullanarak çıkarılmış olan öznitelikleri uzman hibrit olarak isimlendirdiği sistem ile sınıflandırmıştır [28]. Guo ve arkadaşları çoklu boyutlu dalgacık dönüşümü kullanarak nöbet tespiti üzerine çalışma yapmışlardır. Bu çalışmada yaklaşık entropi özelliklerini öznitelik sınıflandırıcı olarak da yapay sinir ağları kullanmışlardır [29]. Kananathal ve arkadaşları EEG sinyallerinin analizinde entropi özniteliklerinin katkısı üzerine çalışmışlardır [30]. Srinivasan ve arkadaşları yaptıkları çalışmada sınıflandırıcı olarak yapay sinir ağlarını kullanıp EEG sinyallerinin analizini gerçekleştirmiş ve zaman-frekans domeni özniteliklerini

kullanmışlardır [31]. Nigam ve Graupe sinir ağıları kullanarak EEG tespiti için bir metot geliştirmiştir [32]. Polat ve Güneş KA ve hızlı fourier dönüşümü kullanılarak hibrit bir sistem üzerine çalışmışlardır [33]. Chen ve arkadaşları dalgacık dönüşümü kullanarak elde edilen öznitelikleri sınıflandırmak için KNN ve DVM kullanarak analiz etmişlerdir [34].

1.2. Tezin Amaç ve Organizasyonu

Epilepsi hastalığının tespitinde kişiden alınan EEG sinyalleri nörofizyologlar tarafından gözlemlenip yorumlanmaktadır. Fakat EEG sinyallerinin çeşitli morfolojilere sahip olmasından dolayı epilepsi tespiti uzun süreli takip ve gözleme dayanmaktadır. Nihayetinde zaman alıcı ve bazen değerlendirmede yanıltıcı sonuçlar oluşabilmektedir. Bu incelemelerin zorluğundan dolayı hastalık teşhisi için bilgisayar destekli sistemlere ihtiyaç duyulmuş ve bunun üzerine bilimsel araştırmalar nöbetlerin saptanması üzerine yoğunlaşmıştır. Yapılan bu tez çalışmasının temel amacı epilepsi tespitinde karar verme aşamasında, sinyalin karakteristiğinin belirlenmesi için en uygun öznitelikler elde edilerek makine öğrenmesi temelli medikal tanı sistemlerine fayda sağlayan bir araç oluşturabilmektir.

Bu tez çalışmasında Kaliforniya Bonn Üniversitesi Epileptoloji Bölümünde erişime açık EEG epileptik veri seti kullanılmıştır. Zaman, frekans veya zaman-frekans uzayında öznitelik çıkarma yöntemleri detaylı analiz edilerek sinyale ait farklı öznitelikler elde edilmiştir. Çıkarılan bu öznitelikler AÖM, DVM, KNN ve KA ile sınıflandırılarak medikal tanı sistemlerinde iş maliyeti az ve iyi başarımlı sonuçları elde edilmeye çalışılmıştır. Ayrıca tıpta tanı testlerinde sınıflandırma değerlendirmesinde yaygın olarak kullanılan ROC eğrisi ile yapılan çalışmalarda en iyi başarımlı sonuçları elde edilen sistemin sınıflandırma performansı gösterilmiştir.

Bu yüksek lisans tez çalışması 6 bölümden oluşmaktadır.

Birinci bölüm tez hakkında genel bilgi, literatürdeki yapılan çalışmalar ve tezin amacı anlatılmıştır. Ardından gelen ikinci bölümde ise beyin anatomisi, EEG ve epilepsiden bahsedilmiştir. Çalışmanın temelini oluşturan iki ana aşamanın daha iyi anlaşılabilmesi için öznitelik çıkarımı ve makine öğrenmesi yöntemleri bu bölümde bulunmaktadır. Ayrıca performans değerlendirme kriteri ve deneysel çalışmada kullanılan veri seti de bu bölümde yer almaktadır.

Üçüncü bölümde epileptik EEG sinyallerinin tespiti için EEG epileptik veri setinde öznitelik çıkarma yöntemleri kullanılarak her bir sinyale ait 6 adet öznitelik elde edilmiştir. Elde edilen bu öznitelikler AÖM, DVM, KNN, KA ile sınıflandırılarak ROC analizi yapılmıştır. Sonuçlar literatürde yapılan çalışmalar ile karşılaştırılmıştır. Bu bölümdeki uygulama ile hazırlanan çalışma aşağıda belirtilen uluslararası sempozyumda yayımlanmak üzere kabul edilmiştir.

• İmak, A., Alçin, Ö. F., İnce M. C., 2017. Epileptik EEG sinyallerinin aşırı öğrenme makineleri kullanılarak tespiti, IMESET International Conference (IMESET'17), Bitlis, October 27-29, pp. 403-410.

Dördüncü bölümde epileptik EEG sinyallerinin tespiti için EEG epileptik veri setinde öznitelik çıkarma yöntemleri kullanılarak her bir sinyale ait 6 adet öznitelik elde edilmiştir. 7 durum düşünülerek elde edilen bu öznitelikler AÖM, DVM, KNN, KA ile sınıflandırılarak ROC analizi yapılmıştır. Sonuçlar hem literatürde farklı sinyal işleme ve makine öğrenmesi yöntemi kullanılarak yapılan çalışmalarla hem de aynı öznitelik çıkarma yöntemi kullanılarak yapılan çalışmalar ile karşılaştırılmıştır. Bu bölümdeki uygulama ile hazırlanan çalışma aşağıda belirtilen uluslararası sempozyumda yayımlanmak üzere kabul edilmiştir.

• İmak, A., Alçin, Ö. F., İnce M. C., 2018. Tekrarlılık Ölçüm Analizi ve Aşırı Öğrenme Makinesi Tabanlı Epileptik EEG Sinyallerinin Sınıflandırılması, IETS International Conference , Batman, May 3-5, pp. 622-627.

Beşinci bölümde epileptik EEG sinyallerinin tespiti için EEG epileptik veri setinde öznitelik çıkarma yöntemi kullanılarak her bir sinyale ait 67 adet öznitelik elde edilmiştir. 7 durum için bu öznitelikler AÖM, DVM, KNN, KA ile sınıflandırılarak ROC analizi yapılmıştır. Sonuçlar literatürde yapılan çalışmalar ile karşılaştırılmıştır.

Altıncı bölümde ise son olarak tez çalışmasındaki önerilen yöntem sonuçları değerlendirilmiştir.


2. TEORİK ALT YAPI

2.1. Beyin

Merkezi sinir sisteminin en önemli kısmı olan beyin vücudun yönetme işlevini görmektedir. Nefes alma, hareket etme, duyu organlarıyla hissetme gibi motor aktiviteleri ve bilişsel faaliyetleri denetleyen merkezi kontrol organıdır [35]. Beyin temel olarak Şekil 2.1’de görüleceği üzere sağ ve sol olmak üzere iki yarım küreden meydana gelmektedir.

Sol yarım küre: Akılcı, mantıksal sıralama, analitik ve sözel işlemlerle ilgilidir. Bu yarım küre mantıksal ve tümevarımsal olarak sözel ve sayısal bilgi işleme süreciyle özelleşmiştir. Bu ise, sol yarım kürenin bilgiyi ve bütünü parçalarını teker teker analiz etme, ayırıştırma yoluyla parçalayıp incelediği anlamına gelmektedir. Dolayısıyla sol yarım küre, bilgiyi doğrusal ve düzenli bir şekilde, sırayla işlemektedir [36]. Vücudun sağ bölgesini yönetme gibi işlevleri kontrol etmektedir.


Sağ yarım küre: Sezgisel, duygusal, bütüncül, sentezci, sözel olmayan, görsel işleme yapan yaratıcı ve tüm dengelimsel düşünce yoluyla çıkarım yaptığı belirtilmiştir [36]. Vücudun sol bölgesini yönetme gibi işlevleri kontrol etmektedir.



Şekil 2.1. Beyindeki sağ ve sol yarım küre [36]

İnsan beyni temel olarak sağ ve sol yarım küreden oluşması ile birlikte daha ayrıntılı olarak anlaşılabilmesi açısından lob olarak adlandırılan bölümlere ayrılmaktadır. Her bir

lob farklı farklı işlevler üstlenirler de birbirlerinden haberdardır ve koordineli olarak çalışırlar. EEG ölçümleri de bu parçalara göre yapılmaktadır [37]. Her bir yarım küre, Şekil 2.2’de de gösterildiği gibi frontal (ön), parietal (yan), oksipital (arka), temporal (şakak) ve serebellum (beyincik) olmak üzere beş loba ayrılmaktadır.



Şekil 2.2. Anatomik beyin bölgeleri [4]

Frontal (Ön) Lob: Beynin ön kısmında bulunan bu lob insan beyninin en geniş alanına sahiptir. Akıl yürütme, motor beceriler, yüksek seviyeli bilişsel yetenekler ve ifade edici bir dil ile ilişkilidir. Mutluluk, üzüntü gibi duyguları hissetmek ve canlandırma frontal lob içerisinde yer almaktadır. Kısacası bu lobun en büyük özelliği bilinçli düşünme merkezini oluşturmasıdır. Zarar görmesi halinde ruh hali, hissiyat değişiklikleri, problem çözme becerisinde düşüş gibi sorunlar ortaya çıkabilmektedir [38].

Parietal (Yan) Lob: Beynin sağında ve solunda yer alan parietal lob aritmetik yetenekleri, algılanan nesnenin yerini ve yönünü saptamak gibi işlevler ile ilişkilidir. En önemli özelliği duyu organlarından gelen bilgileri birleştirmede etkin olmasıdır. Zarar görmesi halinde oluşacak sinir kaybı ile Alzheimer hastalığına sebep olmaktadır [38].

Oksipital (Arka) Lob: Beyindeki sağ ve sol yarı kürenin en arka kısmında yer almaktadır. Görsel bilginin alınması ve işlenmesi bu lobda gerçekleşir. Zarar görmesi başta görme bozukluğunu tetiklediği gibi halüsinasyonlara da sebep olmaktadır [38].


Temporal (Şakak) Lob: Beyindeki sağ ve sol yarı kürenin kulak hizasında bulunurlar. Yüz ve mekân gibi karmaşık uyaranların işlenmesi ve anlamlandırılması bu bölümde gerçekleşir. Aynı zamanda ses ve kokunun algılanması, dengede katkıda bulunma gibi işlevlere sahiptir [38].

Serebellum (Beyincik) : Beynin ikinci büyük parçasını oluşturan serebellum vücudun denge organlarından birisidir. Kasların birbiriyle uyumlu çalışmasını sağlayarak aktif hareketin düzenliliğini oluşturmaktadır [38].

Uyku bozukluğu, odaklanma sorunu, epilepsi ve ruhsal durum gibi sorunların tespit ve takibi için EEG sinyalleri gözlemlenmektedir. Beyindeki bu temel kısımların görev ve işleyişini bilmek kafatası üzerinde hangi bölümden EEG kayıtlarının alınması gerektiğine yardımcı olmaktadır.

2.1.1. Beyinde Elektriksel Sinyal Oluşumu


Beyin kıvrımlı bir yapıya sahiptir. Bu kıvrımlarda bilgi iletimini sağlayan sinir sisteminin en temel yapı taşı olan milyarlarca nöron bulunmaktadır. Her bir nöron binlerce veya milyonlarca nöron ile bağlantı kurabilmektedir. Nöron dentrit, soma (hücre gövdesi) ve akson olmak üzere 3 temel kısımdan oluşmaktadır. Nöronun temel yapısı Şekil 2.3'te gösterilmiştir [39].




Şekil 2.3. Örnek bir nöron yapısı [39]

Şekil 2.3'te de görüleceği üzere sinir hücreleri (nöronlar), geniş bir hücre gövdesi ve bu gövdeden çıkan kısa ve uzun uzantılardan oluşur. Dentrit yardımı ile getirilen uyarı, yönetimi sağlayan soma tarafından aksona aktarma işlemi gerçekleşir. Akson ise işlenen bu kimyasal hareketliliği diğer hücelere aktarmayı sağlamaktadır. Elektriksel kökenli bu biyolojik sinyallerinin temelini hücre zarındaki iyonların hareketi ile ortaya çıkan aksiyon potansiyeli oluşturur [40]. Aksiyon potansiyelinin oluşabilmesi için belirli bir eşik seviyesine ulaşması gerekmektedir.

Hücre uyarılmadığı zamanlarda -90 mV seviyelerindedir. Dentritler uyarı alınca (aktif durumda) Na^+ iyonları geçişi iç potansiyeli -90 mV seviyesinden -60 mV seviyesine çıkarılabilecek olursa eşik değeri aşılmış olup işlem devam etmektedir. Eşik değeri aşılmamış durumda ise denge değerine tekrar geri dönmektedir. Bu olaya ya hep ya hiç yasası denir. Eşik değeri aşılmış durumda hücre içerisindeki Na^+ iyonlarının geçişi artarak iç potansiyeli yükseltmeye devam eder ve tam olarak +20 mV değerine ulaştığı zaman inaktif duruma geçilir. Hücre zarı kapanır ve ikinci bir uyarı alınıp iyon dengesi değişimi gerçekleşene kadar dinlenme durumunda kalmaktadır [35, 42, 43]. Şekil 2.4'te kimyasal hareketlilikte söz konusu olan aktif, inaktif ve dinlenme durumları gösterilmiştir. Ayrıca Şekil 2.5'te ise bir aksiyon potansiyeli için eşik değerinin aşılması ve oluşturmuş olduğu sinyal karakterizasyonu gösterilmiştir.



Şekil 2.4. Kimyasal Hareket [35, 41]




Şekil 2.5. Aksiyon Potansiyeli [35,41]

2.2. EEG Sinyalleri

Beyindeki elektriksel sinyallerin varlığı yüz yüze aşkın süredir bilinmektedir. 1875 yılında İngiliz fizikçi Richard Caton'un maymun ve tavşan beyinleri üzerinde yaptığı deneyler sonucu elektriksel aktivitenin varlığını ortaya koymuştur. Deneylerinde hayvanların gözüne uyguladığı ışık yardımı ile beyindeki elektriksel sinyallerde negatif bir sapma olduğunu göstererek, uyarılma potansiyellerinin temellerini atmıştır. 1929 yılında Alman bilim adamı Hans Berger ise kafatası yaralanması olan insanlarda beyin içerisine yerleştirilen elektrotlar ve bu elektrotlara bağlı galvanometre düzeneği sayesinde beyindeki elektriksel sinyallerin tespit edileceğini göstermiştir. Geliştirilen elektrotlar ile birlikte ilerleyen yıllarda saçlı deri üzerinde ölçüm yapmış ve grafiksel olarak kâğıt üzerine dökmek mümkün olmuştur [44]. Gözlemlediği bu sinyallerin anestezi, uyku, oksijen eksikliği ve epilepsi gibi nöronal hastalıklarda değişim olduğunu fark etmiştir. İnsan beynindeki elektriksel aktivite kaydında, kendi adıyla anılan alfa ritmini (Berger ritmi) ve beta ritminin oluştuğunu gösteren ilk kişidir. Berger'in yaptığı bu çalışmalar ile nörofizyoloji alanında çok önemli bir adım olmuştur. Bununla birlikte 1934'te Adrian ve Matthews beyin biyoelektrik aktivitelerinden alfa ritminin 10-12 Hz civarında düzenli salınımlar belirleyerek EEG alt bantlarının morfolojik özelliklerinin belirlenmesi niteliğinde bir çalışma yapmışlardır [45]. EEG laboratuvarı ise ilk olarak 1936'da Massachusetts General Hospital'da kuruldu. 1980-2000 yılları arasında EEG kayıtlarından faydalanarak hastalık teşhisi üzerine birçok çalışma yapılmış ve 2000 yılından günümüze beyin bilgisayar arayüzü sistemlerine yönelik çalışmalar hız kazanmıştır [37].

Beyin, organların çalışmalarıyla ilişkili birçok bilgiler içermekle birlikte sinir sisteminin yapı taşı olan milyarlarca nöronu da bünyesinde bulundurmaktadır. Beyindeki bu nöronların binlerce ve milyonlarcasının hareketliliği sonucu aksiyon potansiyelleri olarak adlandırılan elektrik işaretleri üretirler. Elektroensefalogram (EEG) olarak isimlendirilen cihaz beyindeki elektriksel faaliyeti alır, kuvvetlendirerek kâğıt üzerine kaydetmektedir. Bu kayıt edilme yöntemi noninvaziv (saçlı deri) EEG ve intrakraniyal EEG olmak üzere ikiye ayrılmaktadır. Saçlı deri EEG metal elektrotların krem veya jel yardımı ile kafa derisi üzerine sabitlenmesi sonucu kayıt işlemi ile gerçekleşmektedir. İntrakraniyal EEG ise kas ve hareket etkisinin olmaması ve düşük genlikli hızlı aktivitelerin gözlemlenmesi için kullanılır. İntrakraniyal EEG genel anestezi altında beyin yüzeyine yerleştirilen ızgara biçiminde veya kafatasına açılmış küçük deliklerden

yerleştirilen derin elektrotlar yardımı ile kaydedilir [46]. Beyindeki aktivite düzeyi yükseldikçe EEG dalgalarının frekansı yükselir, genliği ise azalmaktadır. Ayrıca baskın frekanslar yaşı ilerlemesi ile de yükselmektedir. EEG cihazı yardımıyla kaydedilen örnek bir sinyal Şekil 2.6’da gösterilmiştir.



Şekil 2.6. Örnek bir EEG sinyali


Yöntemler sonucunda elde edilen bu sinyaller hekimler tarafından değerlendirilerek, hastalık teşhisi ve tedavi amaçlı olarak kullanılırlar. EEG’nin zamansal çözümlemesinin hızlı olması avantajlarından biridir. Uyku bozukluğu, tümör, beyin ölümünün gerçekleşmesi ve epilepsi gibi klinik uygulamalarının yanı sıra erişkin ve çocuklarda algılama, dikkat ve duygu gibi bilişsel süreçlerin değerlendirilmesinde de yaygın olarak kullanılmaktadır.

2.2.1. EEG Dalgaları

EEG sinyalleri durağan ve periyodik olmayan dinamik sinyallerdir. Sinyaller serebral korteksin geniş bir bölümünden gelen birçok aksiyon potansiyelin birleşiminden oluşmaktadır. EEG sinyallerinin frekans bandı 0.5 Hz ile 100 Hz, genliği ise $5\mu\text{V}$ ile $400\mu\text{V}$ arasında değişim göstermektedir [43]. Beyindeki aktivite EEG kayıtlarında belirli frekans aralığındaki dalgaların baskınlık göstermesini sağlar. Fizyolojik ve psikolojik


durumların değerlendirilmesinde EEG sinyallerindeki belirgin frekans aralığında baskınlık gösteren bu dalgalara göre durum tespiti yapılabilmektedir. Çeşitli karakteristiklere sahip önemli 5 tane beyin dalgası bulunmaktadır. Bu dalgalar;

- Delta Dalgası: 1936 yılında Walter tarafından bulununan delta dalgası derin uykuda, anestezi gibi beynini düşük aktivite gösterdiği anda belirginleşmektedir. Yetişkinlerde frontal bölgede, çocuklarda ise oksipital bölgede daha belirgindir. 0.5 – 3.5Hz frekans aralığında bulunan delta dalgası genliği en yüksek ve frekansı en düşük dalgalardır [47]. Kaydedilen örnek bir delta dalgası Şekil 2.7’de gösterilmiştir.



Şekil 2.7. Delta dalgası [48]


- Teta dalgası: Teta terimi ilk defa 1944’te Walter ve Doney tarafından kullanılmıştır. 4-7 Hz frekans aralığına sahip teta dalgası temporal lob epilepsisinde ve yetişkinlerde üzüntü, duygusal gerginlik, sevinç, uykuya geçiş dönemi gibi anlarda belirginleşmektedir [47]. Kaydedilen örnek bir teta dalgası Şekil 2.8’de gösterilmiştir.



Şekil 2.8. Teta dalgası [48]


- Alfa dalgası: Berger ritmi olarak da adlandırılan alfa dalgası ilk defa Berger tarafından 1929 yılında bulunmuştur. 8-13 Hz frekans aralığına sahip olan alfa dalgası

gözlerin kapandığı kasların gevşek olduğu anda başın arka kısmında belirginleşmektedir [47]. Kaydedilen örnek bir alfa dalgası Şekil 2.9’da gösterilmiştir.




Şekil 2.9. Alfa dalgası [48]

• Beta dalgası: 1929 yılında Berger tarafından bulunan beta dalgası zihinsel çaba içerisinde ve sinir sistemi duygusal bir bilgiyi işlerken belirginleşmektedir. 15-30 Hz frekans aralığına sahip beta dalgası frekans aralığı ve genlik olarak alfa dalgalarından daha küçük olan dalgalardır [47]. Kaydedilen örnek bir beta dalgası Şekil 2.10’da gösterilmiştir.



Şekil 2.10. Beta dalgası [48]


• Gama dalgası: 1938 yılında Jasper ve Adrew tarafından bulunan gama dalgası kişinin odaklanma anında ortaya çıkmaktadır. Ayrıca uyku analizinde de uykunun karakteristiğinin belirlenmesine de yardımcı olmaktadır. Frekans aralığı yaklaşık olarak 30-100 Hz olan dalgalardır. En anlamlı yanıt gama ritmi olarak adlandırılan 40 Hz frekansında meydana çıkar [47, 49]. Örnek bir gama dalgası Şekil 2.11’de gösterilmiştir.



Şekil 2.11. Gama dalgası [48]

2.2.2. Elektrot Yerleşim Sistemi


EEG ölçümlerinde saçlı deri üzerinde elektrotların yerini belirlemek için Uluslararası EEG Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot yerleştirme yöntemi kullanılmaktadır [50]. 21 elektrotla sahip olan bu sistemde her elektrot, beyin altında yatan alanı veya lobu temsil eden bir harf ve beyindeki yarım kürelerin konumunu belirlemek için bir bir numara kullanılır [51]. Elektrotların yerleştirilmesinde kafa anatomisine göre 4 temel nokta tanımlanmıştır. Bu noktalar burun ile göz arasındaki girinti (nasion), başın arka kısmı (inion) ve sağ ile sol kulak girintileri (preauricular) olarak işaretlenmiş koronal orta hatları temsil etmektedir. Elektrotlar, çizgilerin kesim noktası (C_z) referans alınarak temel noktalara olan mesafelerin %10-20-20 olacak şekilde aralıklara bölünerek yerleştirilmesi gerçekleştirilir. Şekil 2.12’de uluslararası 10-20 elektrot sistemine göre temel noktalarda elektrot yerleştirme, yarım kürelere göre numaralandırma sistemi ve iki elektrot arasında bir EEG dalga şekli gösterilmiştir.



Şekil 2.12. 10/20 sistemine göre elektrot yerleşimi ve örnek bir EEG dalga şekli [17, 18]

Şekil 2.12’de gösterilen F: frontal (ön) lob, C: merkez (kesim) noktası, T: temporal (şakak) lob, P: parietal (yan) lob, O: oksipital (arka) lob, A: kulak memesi elektrotu olarak isimlendirilmiştir [52]. Elektrotların numaralandırılması işlemi ise beyin sol yarım küresi tek sayı, sağ yarım küresi çift sayı ile ifade edilmektedir [46]. Ayrıca orta hat üzerinde bulunan elektrotlar ise (z) harfi ile belirtilmektedir [52]. Beyin anatomisinden bilindiği üzere, beyinde bulunan her bir bölge beyin farklı işlevleri ile ilişkili olabilir. Kafa derisi üzerine yerleştirilen elektrotlar belirli merkezlerin yakınındadır. Örneğin F_z konumu kasıtlı ve motivasyon fonksiyonları ile, C_z ve C_3 konumları çevresindeki korteks, duyuşal ve motor fonksiyonları ile, P_z ve P_4 konumları ise yakınındaki yerler, algı ve farklılaşma faaliyetlerine katkıda bulunur [45, 53].

Elektrotların bağlantı şekilleri monopolar ve bipolar olmak üzere 2’ye ayrılmaktadır. Bipolar bağlantı şeklinde sinyal birbirine komşu iki elektrodun potansiyel farkından oluşmaktadır. Yani bir elektrot diğerinin referansı konumundadır. Monopolar bağlantıda ise bütün elektrotlar için bir referans noktası belirlenir ve bu noktaya göre potansiyel fark alınmaktadır. Bipolar ve monopolar bağlantı ile elde edilen sinyaller Şekil 2.13’te gösterilmiştir [47].




Şekil 2.13. (A) Bipolar, (B) Monopolar Elektrot Bağlantı Şekli [13]

2.2.3. EEG Sinyallerindeki Bozucu Faktörler


EEG kayıtları sırasında doğru bir ölçüm yapılmasını engelleyecek bozucu faktörler (artifaktlar-parazitler) bulunmaktadır. Ölçümlerin doğruluk derecesini arttırmak için sinyalin ön işlemlere tabi tutularak bu artifaktlardan ayıklanması gerekmektedir. Artifaktlar kimi zaman ölçüm yapılan kişiden, cihazdan veya elektrik şebekesine bağlı olarak gelişebilir [37]. Oluşan artifaktlardan bazıları şunlardır:

Göz ve göz kapağının etkisi: En sık görülen artifaktlardan birisidir. Göz kırpma sırasında kas hareketlerinden dolayı oluşmaktadır. Bu artifaktın etkisi beyinde frontal ve parietal lobda görülmektedir [37]. Göz ve göz kapağının etkisi ile oluşan artifaktlar Şekil 2.14'te gösterilmiştir.




Şekil 2.14. Göz ve göz kapağının etkisi ile oluşan artifaktlar [37]

Terleme etkisi: Ter bezlerinin hareketi sonucu oluşan artifaktlardır. 1/4 Hz'lik yavaş salınımlı bir etki yaratmaktadır [37]. Terlemeye bağlı oluşan artifaktlar Şekil 2.15'te gösterilmiştir.




Şekil 2.15. Terlemeye bağlı oluşan artifaktlar [37]

Kas kasılmalarının etkisi: Frekansı 100 Hz'e kadar ulaşabilen hızlı ve ritmik elektriksel deşarjlardan oluşmaktadır. En çok frontal ve temporal lobda görülmesiyle birlikte boyun kaslarının kasılması sonucu oksipital lobda da etkisini göstermektedir [37]. Çeşitli kas kasılmaları sonucu oluşan artifaktlar Şekil 2.16'da gösterilmiştir.




Şekil 2.16. Kas kasılmalarına bağlı artifaktlar [37]

Elektrotların etkisi: Elektrotların bozulmasından, yerleştirmede oluşan hatalardan, birbirleriyle olan etkileşimlerinden dolayı oluşan artifaktlardır [37]. Elektrotların etkisinden dolayı oluşan artifaktlar Şekil 2.17'de gösterilmiştir.



Şekil 2.17. Elektrotların etkisine bağlı artifaktlar [37]


Şebeke etkisi: Şehir şebekesinin 50 Hz’lik salınımlarının EEG kayıt cihazına etkisinden oluşan artifaktlardır. Elektrotların yerleştirildiği kişinin veya cihazın kötü bir şekilde topraklanması sonucunda da oluşabilmektedir. Elektrostatik bir materyalin elektrotlara yakın bir mesafede hareketi sonucu oluşacak artifaktlarda bu gruba dahil olmaktadır [37]. Şebekenin etkisinden oluşan artifaktlar Şekil 2.18’de gösterilmiştir.



Şekil 2.18. Şebeke etkisine bağlı artifaktlar [37]

2.2.4. Beyin Bilgisayar Arayüz (BBA) Sistemlerinde Sinyal Ön İşleme

EEG sinyalleri, bilgisayarın gelişimi ile birlikte günümüzde kayıt altına alınması, analiz edilmesi ve istenilen sonuçların saklanması daha kolay bir hale gelmektedir. Şekil 2.19’da da görüleceği üzere beyin ve bilgisayar arasındaki süreç 4 temel aşamadan oluşmaktadır.



Şekil 2.19. EEG sinyallerinin elde edilme aşamaları

1. Aşama: Sistemdeki ilk aşama beyindeki aksiyon potansiyelleri ölçmek için kullanılan elektrotlardır. Yüksek kaliteli verim elde etmek için kritik bir öneme sahip bu elektrotların farklı özelliklere sahip birçok çeşidi bulunmaktadır. Temel olarak birkaç elektrot çeşitleri şunlardır:

- Tek kullanımlık (jelsiz veya önceden jel konulmuş tipler)
- Yeniden kullanılabilir disk elektrotları (altın, gümüş veya paslanmaz çelikten)
- İğne elektrotlar

Çok kanallı montajlar için genellikle silikon veya kumaş türü malzemeden yapılmış, elektrot yerleştirme yuvasına sahip EEG kepleri kullanılmaktadır. Bu keplerde yaygın olarak kullanılan elektrotlar 1 ile 3 mm çapında gümüş - gümüş klorür disklerden ve kuvvetlendiriciye takılabilen esnek kablolardan oluşmuştur. Ayrıca gümüş klorür elektrotları çok yavaş potansiyelleri de algılayabilme özellikleri bulunmaktadır [45, 54, 55]. Şekil 2.20’de örnek bir EEG kepi ve elektrotu gösterilmiştir.




Şekil 2.20. EEG kepi ve elektrotu

2. Aşama: Elektrotlardan alınan sinyaller mikro volt (μV) seviyesinde ve analog işlenmektedir. Sinyalin analiz edilebilmesi için yeterli bir gerilim seviyesine yükseltilmesi

gerekmektedir. Hem uygun gerilimi seviyesini sağlamak hem de sinyal gürültü oranını koruyabilmek amacıyla kazancın 100 ile 100,000 arasında seçilmesi uygun olacaktır. Ayrıca elektriksel gürültülerin etkisini azaltmak için yükselteçlerin, ortak mod ayrışma oranı (CMRR) en az 100dB ve en az 100M Ω 'luk yüksek giriş empedansına sahip olmalıdır [45, 56].


3. Aşama: Doğru bir ölçümün gerçekleşmesi için sinyalin bozucu faktörlerden (DC bileşen, artifaktlar) temizlenmesi için çeşitli filtre yapıları kullanılmaktadır. Analog filtreler yükseltici bölümüne entegre edilmesi gerekmektedir. Filtreler, doğru sinyal özelliklerini minimum düzeyde etkileyecek şekilde tasarlanmalıdır.

Yüksek geçiren filtre devreleri belirli bir kesim frekansının yalnız üzerindeki frekansları geçiren, altındaki frekansları ise zayıflatan filtre devresidir. Solunum ve kan akışı gibi düşük frekanslı bileşenlerin etkisinin azaltılması için bu filtre yapısı kullanılmaktadır. Klinik EEG bilgileri genellikle 0.5- 40 Hz arasında olduğundan dolayı filtre kesim frekansı (f_c) ise genellikle 0.1- 0.7 Hz aralıklarında seçilmektedir [37, 45]. Şekil 2.21'de basit bir yüksek geçiren filtre yapısı ve karakteristiği gösterilmiştir.



Şekil 2.21. Yüksek geçiren filtre [37, 58]


Alçak geçiren filtre devreleri ise belirli bir kesim frekansının yalnız altındaki frekansları geçiren, üstündeki frekansları ise zayıflatan filtre devresidir. Yüksek frekanslı bozucu etkilerin azaltılması için bu filtre yapısı kullanılmaktadır. Kesim frekansı (f_c) 40Hz olarak belirlenmektedir [37, 45]. Şekil 2.22'de basit bir alçak geçiren filtre yapısı ve karakteristiği gösterilmiştir.



Şekil 2.22. Alçak geçiren filtre [37, 58]

Analog filtreleme işlemleri sonrasında Dc bileşenlerin etkisini daha iyi bir şekilde azaltılması için sayısal filtreler kullanılabilir. Bu filtreleme işlemi ise doğrusal (FIR, IIR) filtreleme veya doğrusal olmayan filtreleme yöntemleri arasından seçim yapmak mümkündür [45].

4. Aşama: Sürekli sinyaller olarak da bilinen analog sinyaller sabit bir zaman aralığında tekrar tekrar örneklenir ve her bir örnek bir analog-dijital (A / D) dönüştürücü ile istenilen dijital gösterime dönüştürülür. Bir saniyede sayısala çevrilen toplam örnek sayısı A / D dönüştürücü örnekleme frekansı (f_s) olarak bilinir [57]. Şekil 2.23'te analog bir sinyalin dijital olarak gösterimi verilmiştir.



Şekil 2.23. A/D dönüştürücü [57]

EEG sinyallerinin dijitale dönüştürülmesi için genellikle çözünürlük mertebesi en az 12 bit seçilmelidir [45]. Nyquist örnekleme teoremine göre bir işarete ait bütün bilginin kaybedilmeden geri alınabilmesi için örnekleme frekansı dijitale dönüştürülecek sinyalin frekansının minimum 2 katı olmalıdır [57]. A/D dönüştürücü ile dijitale çevrilen sinyallerin saklanması ve ekranda görüntülenmesi için bilgisayarın belleğine kaydedilmektedir.

2.3. Epilepsi

Eski çağlardan beri bilinen epilepsinin tanrıların verdiği inanan, tehlikesi büyük bir hastalık olarak tanımlanmıştı. Epilepsi (Yunanca "Epilepsia") anlam olarak yakalamak, tutmak anlamına gelen "epilambanein" kelimesinden türetilmiştir. Dini inançlardan dolayı epilepside 1800'lü yıllara kadar sistematik, bilimsel araştırmalardan kaçınılmıştır [59]. Yunan doktoru Hipokrat, epilepsinin beynin bir hastalığı olduğunu fark eden ilk kişi olup ilaçlar ile tedavi edilebileceğini açıklamıştır. Epileptik EEG sinyalleri ilk olarak 1934'te Fisher ve Lowenback tarafından incelenmiştir. İlk kez İbn-i Sina tarafından "Epileptik nöbet beyinden kaynaklanır, duyuların kaybı düşme olur." şeklinde tıp terminolojisinde ifade edilmiştir [60]. Epilepsi şu anda beynin anatomisi ve fonksiyonu için bir pencere olarak düşünülmekte ve bu nedenle giderek aktif, disiplinler arası bir araştırma alanı olmaktadır [61].

Küresel hastalık yükünün %0.6'sını oluşturan epilepsi beyindeki binlerce veya milyonlarca nöronun ani elektrik boşalması sonucu oluşan nörolojik bir bozukluktur. Epilepsi hastalığı dünya çapında yaklaşık 50 milyon insanda görülmekle birlikte her yaştan insanı etkilemektedir [1]. Dünya Sağlık Örgütü'nün (WHO) yaptığı analizlere göre düşük ve orta gelirli ülkelerde her 1000 kişide 7 ile 14 arasında epilepsi hastası olduğu görülmektedir. Bu oranlar göz önünde bulundurulduğunda epilepsili insanların %80'ine yakını düşük ve orta gelirli ülkelerde yaşamaktadır. Yüksek gelirli ülkelerde epilepsi hastalığının görülme sıklığı ise her 100 000 kişide 30 ile 50 arasında olmaktadır. Beyindeki bu bozukluğun ilk nerede başladığına ve ne kadar yayıldığına göre nöbetlerin özellikleri değişmektedir. Epilepsi tekrarlayan nöbetler ile karakterizedir. Bu nöbetler sonucunda bilinç kaybı, hareket bozuklukları ve diğer bilişsel işlevler gibi geçici istemsiz durumlar oluşmaktadır. Epilepsi hastalığı bulaşıcı bir hastalık değildir. Bu hastalığa sahip her 10 kişiden 6'sı idiyopatik epilepsi olarak adlandırılan, tanımlanabilir bir nedeni olmayan epilepsi hastasıdır. Fakat zamanla idiyopatik epilepsi altta yatan genetik sebeplerden dolayı kaynaklan bir epilepsi hastalığı olduğu benimsenmiştir ve bu kategorideki vakaların çoğu genetik yatkınlıktan etkilenmesi muhtemeldir. Belirli bir nedeni olan epilepsiye ise sekonder epilepsi veya diğer bir adıyla semptomatik epilepsi denilmektedir [1]. Sekonder veya semptomatik epilepsinin nedenleri şunlardır:

- Doğum öncesi veya sonrasındaki enfeksiyonlar, doğum travmaları
- Doğum sonrası şiddetli titreşimlere maruz kalınması

- Beynin oksijensiz kalması
- Beyin tümörleri
- Beyin zarı iltihabı, beyin iltihabı
- Beyin kanaması veya damar tıkanıklığı (serebrovasküler hastalıklar)
- Uzun süren ateşli havaleler
- Kaza sonrası oluşan kafa ve beyin hasarları
- Yoğun stres

İnsanlık tarihi kadar eski olan epilepsi hastalığı düşük ve orta gelirli ülkelerdeki son çalışmalar, epilepsili çocukların ve yetişkinlerin %70'ine yakını ilaç tedavisi ile düzeltilmektedir. 2 ile 5 yıllık başarılı bir tedavi ile çocukların yaklaşık %70'inde ve erişkinlerin %60'ında ilaç tedavisi bırakılarak bir daha nöbet riski yaşanmayan başarılı sonuçlar elde edilmiştir [1].


Elektroensefalogram (EEG) sayesinde beyin aktivitesinin izlenmesi epilepsinin tespit ve teşhisinde önemli bir hale gelmiştir. Epileptik EEG sinyallerinde en sık karşılaşılan dalga biçimleri keskin, polispik, diken, iğnecik, düzenli ritmik ve düzensiz aritmik şeklinde dalga modellerine göre adlandırılmıştır. Epileptik EEG sinyallerinde bu dalga biçimleri yalnız başına veya farklı dalga biçimlerinin birleşmesiyle birlikte bir sinyal oluşturabilmektedir [62, 63]. Şekil 2.24'te karşılaşılan EEG dalga formları gösterilmiştir.



Şekil 2.24. EEG dalga formları [62, 63]


Epilepsi hastası olan insanların EEG kayıtlarında normal olmayan sinyaller interiktal ve iktal olmak üzere iki bölümden oluşmaktadır. İnteriktal bölge iki nöbet arasında elde edilen EEG sinyalleridir. Bu bölgedeki sinyallerin genel özellikleri zaman zaman ortaya çıkan ani yükselmeler, keskin dalgalar gibi geçici durumlar şeklindedir. İktal bölge ise

nöbet sırasında elde edilen EEG sinyalleridir. İktal bölgedeki sinyallerin özellikleri interiktal bölgeye göre dalga formlarındaki genlik ve frekans üzerinde anormal değişiklikler daha uzun bir süre gerçekleşmektedir [64]. İktal bölgedeki kayıtlar nadiren elde edildiği için EEG analizi genellikle interiktal bulgulara dayanmaktadır [64]. İnteriktal ve iktal bölgedeki EEG sinyallerinin görünümleri Şekil 2.25'te gösterilmiştir.



Şekil 2.25. Normal olmayan EEG sinyalleri [9]

Epilepsi tespitinde yardımcı olmak için EEG kayıtlarının otomatik analizi 1970'lerin başlarında başlamıştır [9]. Gelişen bilgisayar destekli karar sistemlerinin otomatik nöbet tespiti üzerinde gün geçtikçe daha güvenilir sonuçlar verdiği yapılan çalışmalarla gözlemlenmektedir. Şekil 2.26'da otomatik olarak epileptik nöbet tespiti üzerine genel yapı gösterilmiştir.



Şekil 2.26. Epileptik nöbet tespit sistemi [32]

Önerilen tüm sinyal işleme yöntemleri EEG kayıtlarındaki epileptik sinyallerin çeşitli karakterize özelliklerini tespit etmeyi amaçlamaktadır. Otomatik epileptik nöbet tespiti yöntemlerinin çoğu öznitelik çıkarma ve sınıflandırma olmak üzere iki ana aşamadan oluşmaktadır. Bir hareketli pencere analizi vasıtasıyla, çok kanallı EEG kayıtlarını karakterize etmek için tasarlanan öznitelikler bulunur. Sınıflandırma aşaması ile bulunan öznitelikler, analiz edilen EEG'nin epileptik bir nöbet olup olmadığına karar vermek için kullanılmaktadır [9].

2.4. Öznitelik Çıkarma

Öznitelik çıkarımı bir sinyalin karakteristiğinin en iyi şekilde temsil edilmesi bakımından en önemli adımdır. Uygun özniteliklerin çıkarılması EEG analizinde oldukça önemlidir. Bu kısımda tez çalışmasında kullanılan öznitelik çıkarma yöntemleri anlatılmıştır.

2.4.1. Ortalama

İstatiksel temelli olan Ortalama (O) parametresi genellikle bütün dağılımlarda ayırt edici bilgi sağlamaktadır. Epilepsi hastası olan insanlarda nöbet öncesi beyindeki nöronların ani elektrik boşalması sonucu EEG sinyallerinde farklılıklar oluşmaktadır. Buna bağlı olarak kişiden elde edilen EEG sinyallerindeki ortalama güçleri de farklılık gösterecektir. Ortalama parametresi Denklem (2.1)'de verilmiştir [65].

$$O = \frac{1}{N} \sum_{n=1}^N x_n \quad (2.1)$$

Burada $x_{[n]}$ bir zaman serisi, N veri noktaları sayısıdır.


2.4.2. Standart Sapma

Standart Sapma (SS) bir dağılımdaki gözlemlerin tipik bir değer etrafında nasıl dağıldığı hakkında bilgi vermektedir. Sinyaldeki her değerın ortalama değere olan uzaklıklarının karesinin toplamının aritmetik ortalaması olarak formüle edilebilir [37]. SS parametresi Denklem (2.2)'deki gibi hesaplanmaktadır [65].

$$SS = \sqrt{\frac{\sum_{n=1}^N (x_n - O)^2}{N-1}} \quad (2.2)$$

2.4.3. Yerel Maksimum Sayısı

Bir sinyalin belli bir örneği iki (önceki ve sonraki) komşusundan büyükse o örnek yerel maksimum noktası olarak tanımlanabilir. Bu çalışmada bir EEG sinyalinin Yerel Maksimum Sayısı (YMS) öznitelik olarak kullanılmıştır. Şekil 2.27’de bir EEG sinyali ve yerel maksimum noktaları gösterilmiştir.



Şekil 2.27. Bir EEG sinyali için yerel maksimum noktaları

2.4.4. Ortalama Eğri Genişliği

Katz fraktal boyutuna bir tahmin sağlamak için Esteller ve ark. [66] tarafından Ortalama Eğri Genişliği (OEG) önerildi [67]. Genellikle EEG sinyallerindeki hareketliliğin belirlenmesinde kullanılır. Denklem (2.3) kullanılarak hesaplanmaktadır.

$$OEG = \frac{1}{N} \sum_{m=k-N+1}^k x_{[m]} - x_{[m-1]} \quad (2.3)$$

Burada $x_{[m]}$ bir EEG zaman serisidir, N pencerenin uzunluğu ve k son örnektir.

2.4.5. Hijort Parametreleri

Hijort parametresi (aktivite, mobilite ve karmaşıklık) EEG sinyallerinin analizinde sıklıkla kullanılan özelliklerdir [68]. Hijort parametreleri hesaplanırken sinyallerin birinci ve ikinci türevleri kullanılmaktadır. Bu tez çalışmasında sırasıyla Denklem (2.4) ve (2.5) verilen Hijort Mobilite (HM) ve Hijort Karmaşıklık (HK) kullanılmıştır.

$$HM = \sigma_1 / \sigma_0 \quad (2.4)$$

$$HK = \sqrt{\left(\frac{\sigma_2}{\sigma_1}\right)^2 - \left(\frac{\sigma_1}{\sigma_0}\right)^2} \quad (2.5)$$


Burada σ_0 sinyalin varyansı veya ortalama gücüdür, σ_1 birinci türevin varyansı ve σ_2 sinyalin ikinci türevinin varyansıdır [68].

2.4.6. Tekrarlılık Ölçüm Analizi

Eckmann ve arkadaşları zaman serisinde durağan olmayan sistemlerde tekrarlı durumları göstermek için bir grafik yöntemi sunmuşlardır [69]. Bir faz uzayında X_i yörüngelerinin zamana bağlı davranışı görselleştirme olarak da ifade edilebilir. Denklem (2.6)'da gösterilen Tekrarlılık Noktalarının (TN) temel basamağı şu şekildedir;

$$R_{i,j} = \theta(\varepsilon - (||X_i - X_j||)) \quad i,j=1,\dots,N \quad (2.6)$$

ε önceden tanımlanmış bir kesme mesafesi, $|| \cdot ||$ öklid formu, N nokta sayısı, θ bir yoğunluk fonksiyonudur. X_i 'ninci nokta X_j 'ninci noktaya olan uzaklığı ε eşik değerinin altına düşerse $R_{i,j}=1$ olan X_i merkezli bir küre tanımlanır. Aksi takdirde $R_{i,j}=0$ olur. $R_{i,j}$ 'nin ikili değerleri basit bir ifade ile siyah (1) ve beyaz (0) ile görselleştirilebilir. TN'nin ek avantajı kısa ve durağan olmayan verileri analiz etmek için uygundur. Kısacası TN, dinamik sistemin geniş ve küçük ölçekli modellerinin özelliklerini aynı anda tanımlayabilmektedir [70]. Epileptik EEG sinyali ve normal EEG sinyalinin TN grafiği Şekil 2.28'de gösterilmiştir.



Şekil 2.28. Epileptik ve Normal EEG Sinyalindeki Tekrarlılık Nokta Grafiği

Şekil 2.28’de de görüleceği üzere epileptik ve normal EEG sinyalinin yoğunluğuna bakıldığında TN grafiğinin ayırt edici bilgi sağladığı görülmektedir. TN’lerden niceliksel bilgi çıkarmak için Tekrarlılık Ölçüm Analizi (TÖA) tekniği uygulanır. TÖA kavramlarının elektro-fizyolojik verilere uygulanması bu sorunun çözüm yollarından biri olmaktadır [70].

TÖA’ndeki elde edilen parametreler şu şekildedir;

i) Tekrarlılık Oranı (RR): Tekrarlılık grafiğinde tekrarlama noktalarının yoğunluğunu gösterir [69]. Denklem (2.7)’de gösterilen RR şu şekilde ifade edilir;

$$RR = \frac{1}{N^2} \sum_{i,j=0}^N R_{i,j} \quad (2.7)$$

ii) Belirlilik (DET): Köşegen çizgiler oluşturan ve tekrar noktalarının oranıdır. Bu çizgiler, sistemin durumlarının benzer evrim zamanlarını temsil eder. Dolayısıyla DET sistemin öngörülebilirliğini belirtir [69]. Denklem (2.8)’de gösterilen DET şu şekilde ifade edilir;

$$DET = \frac{\sum_{i=l_{min}}^N lP(l)}{\sum_{i,j}^N R_{i,j}} \quad (2.8)$$

Burada l_{min} minimum köşegen çizgi uzunluğudur, $P(l)$ l uzunluklu köşegen çizgilerin histogramıdır.

iii) Ortalama köşegen çizgi uzunluğu (L) : Bu parametre, sistemin farklılaşmasının ortalama öngörme süresini veya tersini belirtir [69]. Denklem (2.9)'da gösterilen L şu şekilde ifade edilir;

$$L = \frac{\sum_{i=l_{min}}^N lP(l)}{\sum_{i,j}^N Pl} \quad (2.9)$$

iv) Entropi (ENTR): Tekrarlama yapısının karmaşıklığını ölçer [69]. Denklem (2.10)'da gösterilen ENTR şu şekilde ifade edilir;

$$ENTR = - \sum_{l=l_{min}}^N P(l) \ln P(l) \quad (2.10)$$

v) Tabakalanma (LAM): Dikey çizgilerde oluşturan tekrarlılık noktalarının oranıdır [71]. Denklem (2.11)'de gösterilen LAM şu şekilde ifade edilir;

$$LAM = \frac{\sum_{l=v_{min}}^N lP(v)}{\sum_{i,j}^N R_{i,j}} \quad (2.11)$$

v_{min} minimum dikey çizgi uzunluğu, $P(v)$ v uzunluklu dikey çizgilerin histogramıdır.

vi) Yakalama Zamanı (TT): Dikey yapıların ortalama uzunluğunu belirtir. TT, ortalama zaman sisteminin belirli bir durumda olacağını bildirerek, TN'deki dik yapıların miktarı ve aralığı hakkında bilgi içerir [71]. Denklem (2.12)'de gösterilen TT şu şekilde ifade edilir;

$$TT = \frac{\sum_{l=v_{min}}^N vP(l)}{\sum_{l=v_{min}}^N P(l)} \quad (2.12)$$

2.4.7. Çok Boyutlu Dalgacık Dönüşümü

Biyomedikal sinyaller genellikle durağan olmayan, zaman içinde yakın aralıklarla yerleştirilmiş kısa yüksek frekanslı bileşenlerden oluşmaktadır. Dalgacık dönüşümü,


ayarlanabilir pencere yapısından dolayı düşük ve yüksek frekanslı bileşenler açısından iyi bir frekans çözünürlük sağlandığı için durağan olmayan sinyallerde çoğunlukla tercih edilmektedir [72]. Coifman ve arkadaşları çoğullaştırma yaklaşımları ve dalgacık arasındaki bağlantıyı genelleştirerek Çok Boyutlu Dalgacık Dönüşümü (CDD) olarak adlandırılan bir yöntem önermişlerdir [73]. CDD, 1-D dalgacık ayrışmasının genelleştirilmesini temsil etmektedir. Orijinal sinyal uzayı $\Omega_{0,0}$ yani ağacın kökünü temsil ettiğini varsayarsak, CDD bir alt uzay dalı olarak düşünülebilir. Genel bir gösterimde düğüm $\Omega_{j,k}$ olarak ifade edildiğinde buradaki j ölçeği ve k ölçek içindeki alt bant endeksini ifade etmektedir. Dalgacık dönüşümü ile yaklaşım uzayı $\Omega_{j,k} \rightarrow \Omega_{j+1,2k}$, $\{\Phi_{j+1}(t - 2^{j+1}k)\}_{k \in \mathbb{Z}}$ ve ayrıntı uzayı $\Omega_{j,k} \rightarrow \Omega_{j+1,2k+1}$, $\{\psi_{j+1}(t - 2^{j+1}k)\}_{k \in \mathbb{Z}}$ olmak üzere iki ortogonal alt uzayı olarak ayrıştırılır [74]. Denklem (2.13)'de yaklaşım uzayı, Denklem (2.14)'de de ayrıntı uzayı matematiksel olarak şu şekilde ifade edilmektedir:

$$\Phi_{j,k}(t) = \frac{1}{\sqrt{|2^j|}} \Phi\left(\frac{t-2^j k}{2^j}\right) \quad (2.13)$$

$$\psi_{j,k}(t) = \frac{1}{\sqrt{|2^j|}} \psi\left(\frac{t-2^j k}{2^j}\right) \quad (2.14)$$

Burada $\Phi_{j,k}(t)$, $\psi_{j,k}(t)$ dalgacık ve ölçeklendirme fonksiyonları, j ölçeği, k alt bant endeksini ve 2^j ise ölçekleme parametresi olarak bilinmektedir [75].

CDD'nün, dalgacık dönüşümü arasındaki fark sonraki ayırıklaştırma seviyeleri için CDD sadece yakınsama katsayılarını değil, aynı zamanda detay katsayılarını da ayırıştırılmaktadır. Bu işlem J kere tekrarlanmaktadır. Bu tekrarlanma N adet orijinal sinyaldeki örnek sayısında $J \leq \log_2 N$ olacak şekilde şartı sağlaması gerekmektedir. Tekrarlama işleminin sonucunda $J \times N$ boyutunda bir katsayı matrisi elde edilir. Böylece $j = 1, 2, \dots, J$ çözünürlük seviyesinde N adet örnek sayısına sahip bir sinyalden katsayılar 2^j 'lik bir ölçeklendirme ile bloklara bölünmüştür. Bu tekrarlamalı süreç, bir ikili dalgacık paket dönüşümü benzeri bir yapı oluşturmaktadır. Ağacın düğümleri farklı frekans özelliklerine sahip alt uzayları temsil etmektedir [75]. CDD'ne örnek Şekil 2.29'da üç ayrışma seviyesi ile şematik olarak gösterilmiştir.



Şekil 2.29. $j=3$ için alt uzaylara ayrışma şeması

2.5. Aşırı Öğrenme Makinesi

Huang ve arkadaşları tarafından önerilen aşırı öğrenme makinesi (AÖM), sınıflandırmada ve regresyonda kullanılan tek gizli katmanlı ileri beslemeli (TGKİB) sinir ağları için bir öğrenme algoritmasıdır [76]. Kullanımı kolay ve etkili bir öğrenme yöntemidir. Tek gizli katmanlı ileri beslemeli sinir ağı eğitimi için kullanılan AÖM, uygulama sürecinde rastgele oluşturulmuş girdi ağırlıklarını kullanarak çıktı ağırlıklarını en küçük kareler yöntemi ile hesaplanabilmektedir. Bu sayede hızlı öğrenme hızı ve genelleme performansı avantajlarıyla benzersiz bir optimal çözüm üretir [77]. Bu tez çalışmasında yapılan uygulamalarda diğer sınıflandırıcılara kıyasla AÖM ile daha iyi başarımlar sağlandığı için ayrıntılı bir şekilde ele alınmıştır. AÖM'nin çıkış üretmek için doğrusal bir denklemi tek seferde çözümleyip eğitimi tamamlamasını kolaylaştıran Moore-Penrose Genelleştirilmiş Ters ve genel bir doğrusal sistemin en küçük norm en küçük kareler çözümü konuları bu bölümde anlatılacaktır. Daha sonrasında TGKİB ağların matematiksel modeli detaylandırılarak yaygın olarak kullanılan Eğimli Düşüş öğrenme algoritması anlatılacaktır.

2.5.1. Moore-Penrose Genelleştirilmiş Ters

$Hx = y$ şeklinde bir doğrusal sistemin çözümü Moore-Penrose Genelleştirilmiş Ters ile daha kolay bir hale getirilebilmektedir. Hatta H tekil ve $n \times n$ 'lik bir kare matris

olmayabilir [78, 79, 80]. H $n \times m$ boyutlu bir matris olsun, $m \times n$ boyutlu bir reel G matrisi Denklem (2.15) ifadesindeki koşulları sağlıyorsa G matrisine H matrisinin genelleştirilmiş tersi denir [38].

$$HGH = H, GHG = G, (HG)^T = HG, (GH)^T = GH \quad (2.15)$$

Bu ifadedeki $(.)^T$ operatörü matrisdeki transpoz işlemini göstermektedir. H matrisinin Moore-Penrose Genelleştirilmiş Ters H^+ ile gösterilecektir [79, 80].

2.5.2. Genel Doğrusal Sistemin En Küçük Norm En Küçük Kareler Çözümü

En küçük kareler çözümü regresyon analizlerinde en çok kullanılan yöntemlerden birisidir. Gauss'un 1795'te geliştirdiği bu yöntem, ilk kez 1801 yılında Cres astroidinin yörüngesinin belirlenmesinde kullanılmıştır. En küçük kareler yöntemi mühendislik, finans, tıp, ziraat ve biyoloji gibi bilim dallarında çeşitli değişkenlerin belirlenmesinde önerilen önemli yöntemlerden birisidir [82].

$Hx = y$ şeklindeki genel bir doğrusal sistem için Denklem (2.16)'da $\hat{x}$ en küçük kareler çözümü;

$$\|H\hat{x} - y\| = \min_x \|Hx - y\| \quad (2.16)$$

Şeklinde ifade edilmektedir [78, 79, 80, 83]. Bu ifadedeki $\|\cdot\|$ Öklid uzayında normu göstermektedir. Herhangi bir $y \in R^m$ için $Hx = y$ şeklindeki doğrusal bir sistemin en küçük norm en küçük kareler çözümü x_0 olduğu söylenebilir [80, 83]. Bu tanım Denklem (2.17)'de ifade edilmiştir.


$$\|x_0\| \leq \|x\|, \forall x \in \{x: \|Hx - y\| \leq \|Hz - y\|, \forall z \in R^n\} \quad (2.17)$$

Denklemdeki $x_0 \in R^n$ 'dir.

$Hx = y$ doğrusal bir sistemin minimum normlu en küçük kareler çözümü G matrisi olsun. Bu çözümdeki gerekli olan şart ($G = H^+$) Moore-Penrose tersidir [79, 80].

2.5.3. Tek Gizli Katmanlı İleri Beslemeli Ağlar

Sinir ağı yapıları arasında basit bir mimariye sahip bir model olan TGKİB, uygulamalarda oldukça iyi genelleme performansı göstermektedir [80]. İleri beslemeli ağlarda nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir. Bir katmandan sadece kendinden sonraki katmanlar ile bağ bulunmaktadır. Yapay sinir ağına gelen bilgiler giriş katmanına daha sonra sırasıyla gizli katmanlardan ve çıkış katmanından işlenerek geçer ve eğitimi tamamlamış olur. 3 ana katmandan oluşan TGKİB mimarisi Şekil 2.30'da gösterilmiştir.



Şekil 2.30. TGKİB ağ yapısı [80, 84]

Şekil 2.30'da gösterilen TGKİB ağ yapısına örnek olarak girişler $X_i = [X_1, X_2, \dots, X_N]^T \in R^N$ vektörü ve karşılık gelen istenen çıkışlar ise $Y_i = [Y_1, Y_2, \dots, Y_N]^T \in R^N$ vektörü ile gösterilmiştir. Gizli katmanda M adet nörona ve $g_{(x)}$ aktivasyon fonksiyonuna sahip TGKİB ağ için matematiksel gösterimi Denklem (2.18)'deki gibi ifade edilmektedir.

$$\sum_{i=1}^M \beta_i g(W_i X_j + b_i) = Q_j, j=1,2,\dots,N \quad (2.18)$$

N adet nöron sayısına sahip TGKİB ağ yapısında $w_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ gizli nöron ile giriş nöronları birbirine bağlayan giriş ağırlık vektörü, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$

gizli nöron ile çıkış nöronlarını birbirine bağlayan çıkış ağırlık vektörü, b_i eklenen eşik değerini ve $Q_j = [Q_1, Q_2, \dots, Q_j]^T$ ise beklenen çıkışı ifade etmektedir. TGKİB ağ yapısında Q_j ve Y_j arasındaki hatayı en aza indirmeyi hedeflemektedir. Denklem (2.19)'da beklenen çıkış ile olması istenilen çıkış ilişkisi arasında;

$$\sum_{j=1}^N Q_j - Y_j = 0 \quad (2.19)$$

Şeklinde matematiksel olarak ifade edilmektedir. Hatanın sıfıra yaklaştığı varsayılırsa TGKİB ağ yapısı için matematiksel gösterim de olması istenilen çıkış eşitliği ile mevcut β_i , w_i ve b_i için kullanılan Denklem (2.18) düzenlenerek;

$$\sum_{i=1}^M \beta_i g(W_i X_j + b_i) = Y_j, j=1,2,\dots,N \quad (2.20)$$

Şeklinde yazılabilir [78, 79, 80, 85]. Denklem (2.20)'deki matematiksel ifadeden yola çıkılarak Denklem (2.21)'de N adet denklemin daha sade bir halde gösterimi;

$$H\beta = Y \quad (2.21)$$

şeklinde tanımlanabilir. Burada

$$H = \begin{bmatrix} g(W_1 X_1 + b_1) & \cdots & g(W_M X_1 + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \cdots & g(W_M X_N + b_M) \end{bmatrix}_{N \times M} \quad (2.22)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times 1} \quad \text{ve} \quad Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times 1} \quad (2.23)$$

olarak ifade edilir. H gizli katman çıkış matrisi olarak adlandırılmaktadır [80, 84].

2.5.4. Eđim-Temelli Öğrenme Algoritması

$Y = H\beta$ şeklindeki doğrusal bir sistemin çözümünde H $n \times n$ 'lik bir kare matris ise tersi alınabilir ve $H^+ = H^{-1}$ eşitliđi yazılabilmektedir [81]. Yapılan çalışmalarda [86, 87] gizli katman sayısı eğitim örneklerine eşit ise TGKİB ađlar bu eğitim örneklerini sıfır hata ile yakınsayabilir [80, 88, 89]. Fakat genellikle gizli nöron sayısı farklı eğitimdeki nöron sayısından çok küçük olduğundan dolayı H matrisi kare matris olamaz. Bu durumdabir TGKİB ađ yapısını eğitmek için Denklem (2.24)'deki eşitliđi sađlayan w_i , β_i ve b_i bulunmalıdır.

$$\left| \left| H(\hat{w}_i, \dots, \hat{w}_M, \hat{b}_i, \dots, \hat{b}_m) \hat{\beta} - Y \right| \right| = \min_{w_i, b_i, \beta_i} \left| \left| H(w_i, \dots, w_M, b_i, \dots, b_M) \beta - Y \right| \right| \quad (2.24)$$

Burada bir optimizasyon probleminin çözümünde, çözümün iyiliđine ilişkin Denklem (2.25)'de ifade edilen sayısal deđer veren fonksiyon E , minimize edilmelidir.

$$E = \sum_{j=1}^N \left(\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) - y_j \right)^2 \quad (2.25)$$

Gizli katman çıkış matrisi H bilinmediğinden eğitim-temelli öğrenme algoritmaları genellikle $\left| \left| H\beta - Y \right| \right|$ ifadesinin minimumunu bulduran algoritmalar kullanılır. Eğitim-temelli öğrenme algoritmalarındaki minimizasyon işleminde ađrılık (w_i , β_i) ve eşik (b_i) parametrelerinden oluşan W vektörü, tekrarlı bir şekilde Denklem (2.26)'da belirtildiđi gibi ayarlanmaktadır [80, 88, 89].

$$W_k = W_{k-1} - \eta \frac{\partial E(W)}{\partial W} \quad (2.26)$$

Buradaki η bir öğrenme oranıdır. Geriye-yayılım algoritması ileri beslemeli sinir ađlarında kullanılan popüler bir öğrenme algoritmasıdır [89]. Geriye-yayılım algoritmasında eğitimler yayılım işlemi ile çıkıştan girişe doğru verimli bir şekilde hesaplanabilir [80, 88]. Bu öğrenme algoritmasının aşağıda belirtildiđi gibi bazı olumsuzlukları bulunmaktadır;

- Öğrenme oranı η değeri çok küçük olduğunda öğrenme algoritması çok yavaş bir şekilde yakınsar. Ayrıca η çok büyük olduğunda ise algoritma kararsızlaşmaktadır.
- Geriye-yayılım algoritmasını etkileyen bir diğer faktör ise yerel minimum noktasıdır. Eğer öğrenme algoritması yerel minimum noktasının çok üzerinde konumlanmışsa, bu noktalarda durmak istemez.
- Sinir ağlarında aşırı eğitilmiş olabilir ve daha kötü genelleme performansı elde edilebilir. Bu yüzden optimizasyon problem çözüm fonksiyonda geçerleme ve uygun durdurma yöntemleri gerekli olmaktadır.
- Geriye-yayılım algoritma tabanlı öğrenme uygulamada çok zaman alıcıdır.

AÖM bu sorunları çözmek ve ileri beslemeli sinir ağları için verimli bir öğrenme algoritmasıdır [79, 80].

2.5.5. Tek Gizli Katmanlı İleri Beslemeli Ağlar En Küçük Kareler Çözümü

TGKİB ağlarda girdi ağırlıklarını ve gizli katman eşik değerinin ayarlamasını gerektiren geleneksel teorik işlevlerden farklı olarak girdi ağırlıkları ve gizli katman eşik değeri rasgele seçilebilir. Bu rastgele seçiminin gerçekleştirilmesi için sadece aktivasyon fonksiyonu sınırsız olarak ayırt edilebilmesi gerekmektedir. TGKİB tüm parametrelerinin ayarlanması gerektiğine dair geleneksel sinir ağı yapılarından farklı olarak öğrenme aşamasında giriş ağırlıkları ve gizli katman eşik değeri rastgele seçilerek H gizli katman çıkış matrisi elde edilmektedir. Ayrıca geleneksel öğrenme algoritmalarından farklı olarak, önerilen öğrenme algoritması sadece en küçük eğitim hatasını değil, aynı zamanda en küçük ağırlık seviyesine ulaşma eğilimindedir. Çünkü ağırlıklar ne kadar küçük olursa ağırlığın genel performansı da doğru orantılı olarak iyi olmaktadır [79].

Literatürde bu konu ile ilgili çalışmalarda türevlenebilir bir aktivasyon fonksiyonu ile giriş ağırlıkları rastgele seçilmiş TGKİB ağına, farklı örnekler ile yapılan uygulamalarda çok küçük hata değeri ile öğrenimini tamamlayacağını göstermiştir [90]. Benzetim çalışmaları ve pratik uygulamalarda giriş ağırlığının yanı sıra gizli katman eşik değerinin de ek olarak rastgele seçilebileceği ispatlanmıştır [80]. Huang ve Babri, M gizli nöronların çoğunda ve hemen hemen tüm doğrusal olmayan aktivasyon fonksiyonlarıyla TGKİB ağına tam olarak N gözlemlerini öğrenebildiğini göstermiştir [79, 91].

Denklem (2.24)'de görüleceği üzere giriş ağırlıkları w_i ve gizli katman eşik değeri b_i sabit olursa, TGKİB ağıının $H\beta = Y$ doğrusal bir denklemi tek seferde çözerek eğitilmesi için Denklem (2.27)'de verilen çıkış ağırlıkları $\hat{\beta}$ en küçük kareler yöntemi ile bulunmaktadır [80, 88, 89].

$$\left| \left| H(\hat{w}_i, \dots, \hat{w}_M, \hat{b}_i, \dots, \hat{b}_m) \hat{\beta} - Y \right| \right| = \min_{\beta_i} \left| \left| H(w_i, \dots, w_M, b_i, \dots, b_M) \beta - Y \right| \right| \quad (2.27)$$

Denklem (2.15)'e göre yukarıda verilen doğrusal sistemin en küçük kareler çözümü Denklem (2.28)'deki gibi şöyle ifade edilebilir;

$$\hat{\beta} = H^+ Y \quad (2.28)$$

Genellikle gizli nöron sayısı M , farklı eğitim örnek sayısı N 'den ($M \ll N$) çok daha azdır. Bu yüzden H matrisi kare matris olmayabilir. $\hat{\beta}$ değerini elde etmek için H matrisinin Moore-Penrose Genelleştirilmiş Tersi yöntemi kullanılmaktadır [79, 80].

TGKİB ağ yapısında vurgulandığı gibi önemli durumlar söz konusudur. Bu durumlardan ilk olarak minimum eğitim hatasına ulaşmak söylenebilir. $Y = H\beta$ doğrusal bir sistemde en küçük kareler yöntemlerinden biri kullanılarak $\beta = H^+ Y$ çözümü ile minimum eğitim hatasına Denklem (2.29)'da gösterilen özel çözüm ile ulaşılabilir.

$$\left| \left| H\hat{\beta} - Y \right| \right| = \left| \left| HH^+ Y - Y \right| \right| = \min_{\beta} \left| \left| H\beta - Y \right| \right| \quad (2.29)$$

Bütün öğrenme algoritmaları her ne kadar minimum eğitim hatasına ulaşmayı amaçlasa da birçoğu yerel minimum ve sınırlı eğitim iterasyonundan dolayı ulaşamamaktadır. İkinci önemli durum ise en küçük ağırlık seviyesine ulaşma eğilimidir. Ayrıca $Y = H\beta$ doğrusal bir sistemde Denklem (2.30)'da ifade edilen $\hat{\beta} = H^+ Y$ özel çözümü en küçük norma sahiptir.

$$\left| \left| \hat{\beta} \right| \right| = \left| \left| H^+ Y \right| \right| = \left| \left| \beta \right| \right|, \forall \beta \in \{ \beta : \left| \left| H\beta - Y \right| \right| \leq \left| \left| H\hat{\beta} - Y \right| \right|, \forall \hat{\beta} \in R^{M \times N} \} \quad (2.30)$$

H matrisinin Moore-Penrose Genelleme Tersini hesaplamak için çeşitli yöntemler kullanılabilir. Bu yöntemler orthogonal projection, orthogonalization metodu, iteratif metot ve tekil değer ayrışımı (TDA) içerebilir, ancak bunlarla da sınırlı değildir [36, 49]. Orthogonalization yöntemi ve iteratif metot AÖM’nde kaçınmak istediğimiz iterasyonlarda kullanılır. AÖM’nde genellikle H ’nin Moore-Penrose genelleme tersini hesaplamak için TDA yöntemi kullanılmaktadır [79].

Son olarak $Y = H\beta$ doğrusal sisteminin en küçük normlu en küçük kareler çözümünün ($\hat{\beta} = H^+Y$) tek olduğu söylenebilir [80, 88, 89].

2.5.6. Tek Gizli Katmanlı İleri Beslemeli Ağlar için Öğrenme Algoritması

Aşırı öğrenme makinesi (AÖM) olarak isimlendirilen giriş ağırlıkları, gizli katman eşik değerini rastgele seçen ve çıkış ağırlıklarını analitik olarak belirleyen TGKİB ağ yapısı için basit bir öğrenme yöntemi bulunmaktadır [79].

TGKİB ağ mimarisinde olduğu gibi AÖM yapısında da modelin çıktısını şekillendirmek için çeşitli $g(x)$ aktivasyon fonksiyonuna sahiptir. Bu aktivasyon fonksiyonlarından bir kaç formülleri ile birlikte Tablo 2.1’de bir araya getirilmiştir [93].

Tablo 2.1. AÖM yönteminde kullanılan başlıca aktivasyon fonksiyonları [93, 94]

Aktivasyon Fonksiyonu	Denklemleri
1) Sigmoid	$g(w, b, x) = \frac{1}{1 + \exp(-(wx + b))}$
2) Sinüs	$g(w, b, x) = \sin(wx + b)$
3) Hard Limit	$g(w, b, x) = \begin{cases} 1, & wx + b \geq 0 \\ 0, & wx + b < 0 \end{cases}$
4) Radyal bazlı	$g(w, b, x) = \exp(-(wx + b)^2)$
5) Elliot Sigmoid	$g(w, b, x) = \frac{0.5 * wx + b}{1 + \exp(wx + b)} + 0.5$
6) Gauss	$g(w, b, x) = \exp(-b x - w ^2)$
7) Multiquadric	$g(w, b, x) = (x - w ^2 + b^2)^{1/2}$

AÖM’nin öğrenme hızı, daha iyi genelleme performansı gerçekleştirebilmesi, az sayıda parametrenin belirlenmesi ve kullanım kolaylığı önemli avantajları arasında bulunmaktadır. Bunun ile birlikte hangi aktivasyonun seçileceği ve gizli katman nöron sayısının ampirik yollarla karar verilmesi bir dezavantaj olarak düşünülebilir.


Girişler $X_i = [X_1, X_2, \dots, X_N]^T \in R^N$ vektörü, karşılık gelen istenen çıkışlar ise $Y_i = [Y_1, Y_2, \dots, Y_N]^T \in R^N$ vektörü olan veri çifti, gizli katmanda M adet nöron sayısına ve $g(x)$ aktivasyon fonksiyonuna sahip AÖM algoritmasının öğrenme yöntemi şu şekilde özetlenebilir;

- Eğitim ve test verilerini ayır
- w_i giriş ağırlıklarını ve b_i gizli katman eşik ağırlıklarını belirle
- Denklem (2.22) kullanılarak gizli katman çıkış matrisini hesapla
- Denklem (2.20) kullanılarak β değeri hesapla

şeklinde özetlenebilir [80, 88, 89].

2.6. Destek Vektör Makineleri


Destek vektör makineleri (DVM) ilk olarak 1995'te Cortes ve Vapnik tarafından sınıflandırma ve regresyon için kullanılan, danışmanlı öğrenme yaklaşımıyla çalışan bir öğrenme algoritması olarak önerilmiştir [95]. Genel olarak DVM'nin çalışma prensibi sınıf etiketleri bilinen iki sınıfa ait örneklerin, eğitim ve test verileri olmak üzere iki gruba ayrılıp; eğitim verisi sonucu elde edilen bir karar fonksiyonu sayesinde test verilerinin sınıflandırılması işlemidir. Şekil 2.31'de bakıldığında ayrılması istenen iki sınıfı ayırtırmak için birden fazla hiper-düzlem çizilebilme ihtimali vardır.



Şekil 2.31. İki sınıflı problemler için muhtemel hiper-düzlemler [96]

Hatanın minimize edilerek sınıflandırma işleminde çizilebilecek doğrular arasında her iki sınıfa en uzak mesafede olacak şekilde çizilen doğru bulunmalıdır [50]. Şekil 2.32'de gösterilen sınıflara olan uzaklığı maksimuma çıkaran düzlem optimum hiper-

düzlem ve sınır genişliğini belirleyen noktalara ise destek vektörleri olarak adlandırılmaktadır [96].



Şekil 2.32. Optimum hiper-düzlem ve destek vektörleri [96]

DVM hem doğrusal hemde doğrusal olmayan veri kümelerini uygun bir dönüşüm ile her zaman iki sınıfa ayırabilmektedir.

2.6.1. Doğrusal Ayrılabilen Veriler İçin DVM

Destek vektör makineleri genellikle $\{-1, +1\}$ şeklinde sınıf etiketleri ile tanımlanan iki sınıfa ait veri kümesini bir karar fonksiyonu yardımıyla en uygun şekilde ayırabilecek bir hiper-düzlem bulunur.


Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde N sayıda örnekten oluşan bir sistemde $i=1, \dots, N$ olacak şekilde $\{x_1, y_1\}, \{x_2, y_2\}, \dots, \{x_i, y_i\}$ eğitim verilerinin olduğu kabul edilirse, optimum hiper-düzleme ait eşitsizlikler şu şekilde yazılabilir:

$$w \cdot x_i + b \geq +1 \text{ her } y = +1 \text{ için} \quad (2.31)$$

$$w \cdot x_i + b \leq -1 \text{ her } y = -1 \text{ için} \quad (2.32)$$

$$y_i * (w \cdot x_i + b) \leq -1 \quad 1 \leq i \leq N \quad (2.33)$$

Eğer tüm eğitim verileri için Denklem (2.31), (2.32) ve (2.33)'teki eşitsizlikleri doğrulayacak bir w ağırlık vektörü ve b eğilim değerine sahip ise eğitim verileri doğrusal olarak ayrılabilir olarak kabul edilmektedir. Şekil 2.33'teki gösterilen optimum hiper-düzlemi belirleyen destek vektör noktalarının oluşturduğu düzlem $w \cdot x_i + b = \pm 1$ şeklinde ifade edilmektedir [97].



Şekil 2.33. Doğrusal olarak ayrılabilen veri kümesi için optimum hiper düzlemin belirlenmesi [96]

Optimum hiper-düzlemin belirlenmesi için $\|w\|$ ağırlık vektörünün minimum hale getirilmesi gerekmektedir. En uygun hiper-düzlem belirlenmesinde Denklem (2.34)'teki sınırlı optimizasyon probleminin çözümünü gerektirir [98].

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (2.34)$$

Değer Denklem (2.33)'teki sınır şartlarını sağlaması gerekmektedir. Lagrange Denklemi (2.35) kullanılarak bu optimizasyon problemi çözümlenebilmektedir [99].

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N a_i y_i (w \cdot x_i + b) + \sum_{i=1}^N a_i \quad (2.35)$$

a_i değişkenleri Lagrange katsayılarını göstermektedir. Elde edilen bu eşitlikten sonuç olarak iki sınıflandırma problemin ayrılabilmesi için karar fonksiyonu Denklem (2.36)'da şu şekilde yazılabilir:

$$f(x) = \text{sign}[\sum_{i=1}^N \lambda_i y_i (w \cdot x_i + b)] \quad (2.36)$$

λ_i değişkenleri Lagrange katsayılarını göstermektedir [99].

2.6.2. Doğrusal Ayrılamayan Veriler İçin DVM

Şekil 2.34'te görüleceği üzere veri kümesi doğrusal olarak ayrılamadığında veriyi orijinal girdi uzayından bir kernel fonksiyonu (φ) sayesinde daha yüksek boyutta özellik uzayına aktarır. Bu yeni boyutta iki sınıflandırma problemini ayıracak çoklu düzlemi araştırır. Sınıflandırma problemlerinin birçoğunun doğrusal olarak ayrılması mümkün değildir. Eğitim verilerinin bir kısmının hiper-düzlemin karşı tarafında bulunmasından dolayı oluşan problemin çözülmesi için bir yapay pozitif değişken (ξ_i) tanımlanması ile çözümlenebilmektedir. Hata toleransının minimuma indirilerek optimum hiper-düzlemin elde edilmesi için Denklem (2.37)'de C ile ifade edilen bir düzenleme parametresi eklenmesi ile optimizasyon problemi çözümlenebilmektedir [96].


$$\min \left[\frac{1}{2} ||w||^2 + C * \sum_{i=1}^N \xi_i \right] \quad (2.37)$$

Şeklini alır ve buna bağlı sınırlamalar ise;


$$y_i(w \cdot \varphi(x_i) + b) - 1 \geq 1 - \xi_i \quad (2.38)$$

$$\xi_i \geq 0 \text{ ve } i=1, \dots, N \quad (2.39)$$

Şeklinde ifade edilir. Şekil 2.35 ise doğrusal olarak ayrılamayan veri kümesi için optimum hiper-düzlemi belirleyen destek vektör noktalarının oluşturduğu düzlem gösterilmiştir [99].



Şekil 2.34. Kernel fonksiyonu ile hiper-düzlemin belirlenmesi [96]



Şekil 2.35. Doğrusal olarak ayrılabilen veri kümesi için optimum hiper düzlemin belirlenmesi [96]

Destek vektör makineleri doğrusal olarak ayrılamayan sınıflandırma problemlerinde matematiksel olarak $K(x_i, x_j) = \phi(x) \cdot \phi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu sayesinde yüksek boyutta bir özellik uzayına aktararak doğrusal olarak ayrılmasına imkân sağlamaktadır [99].


2.7. En Yakın K-Komşu Algoritması

En Yakın K-Komşu (KNN) algoritması literatürdeki çalışmalarda da yaygın olarak kullanılan sınıflandırma yöntemlerinden birisidir. Sınıf etiketleri belirli olan bir eğitim örneği kümesine dahil edilecek yeni bir örneğin hangi sınıfa ait olacağını mesafeye dayalı olarak sınıflandırma yapan denetimli bir öğrenme algoritmasıdır. Söz konusu bu yöntemin çalışma prensibi dahil edilecek örneğin, eğitim örnekleri arasındaki uzaklıkları hesaplanmaktadır. En düşüktən en yüksek uzaklık değerleri sıralanarak belirlenen k değerinde genelleme gösteren sınıfa atanması gerçekleştirilmektedir. Denetimli bir öğrenme olduğundan dolayı gürültü parametrelerin varlığında sorun yaratabilmektedir [100].

Algoritmada genel olarak i ve j noktaları arasındaki uzaklıkların hesaplanmasında yaygın olarak Denklem (2.40)'taki Öklid uzaklık yöntemi kullanılmaktadır [101].

$$d(i, j) = \sqrt{\sum_{k=1}^N (x_{ik} - x_{jk})^2} \quad (2.40)$$

Üç ayrı sınıfın (w_1 , w_2 , w_3) bulunduğu bir veri kümesinde bilinmeyen bir x örneğinin $k=5$ için sınıflandırılması Şekil 2.36'da gösterilmiştir [101].




Şekil 2.36. Yeni bir örneğin en yakın $k=5$ için komşu belirlenmesi [101].

En yakın mesafedeki 5 eğitim örneğinden 1 tanesi w_3 'te, 4 tanesi ise w_1 'de bulunmaktadır. Genel olarak baskın sınıf w_1 olduğu için x örneği w_1 sınıfına dahil olmaktadır. KNN algoritmasını, örnekleri en iyi temsil eden özneliliklerin elde edilmesi ve k parametresinin belirlenmesi performansını etkileyecek iki temel unsurdur.

2.8. Karar Ağaçları

1973 yılında Karar Ağaçları (KA), Bierman ve Friedman tarafından bir şartın kendisinden başka bir şarta bağlı olduğu sezgisel bir yöntem olarak önermişlerdir [102]. Tümevarım yöntemi ile benzer örüntüleri bulmak için kullanılabilecek bir denetimli öğrenme algoritmasıdır. KA eğitim örneklerine dayalı kurallar çıkartarak test edilecek örneğin hangi sınıfa ait olduğuna karar vermektedir. Öğrenme aşamasında başlangıç kısmına kök, son kısmına yaprak ve kök-yaprak arasındaki kısma ise dal olarak adlandırılmaktadır [101].

KA doğru tahmin elde etmek için pek çok if-then yapısına tabi tutarak en iyi sırayı bulmaya çalışır [103]. Şekil 2.37’de kök düğüm, iç düğüm ve yaprak düğümünden oluşan örnek bir karar ağacı gösterilmiştir.



Şekil 2.37. Karar ağacı örneği [101]

Şekil 2.37’de de görüleceği üzere soru sorma aşamasına kök düğümü ile başlangıç vererek alınan cevaba göre bir yaprak düğümü ile sonlandığı gibi, iç düğüm ile soru-cevap adımı devam etmektedir. Sonuç olarak yaprak düğümü ile dallanma bitmiş ise sınıfı temsil eden en iyi karar aşamasına (yaprağa) ulaşılmıştır. Algoritma kendi içerisinde bölme, budama ve durdurma işlevlerinde bulunmaktadır. Her bölünme işleminde değişkenler analiz edilerek en iyi bölüm seçilmektedir. Dallanma sırasında gereksiz alt iç düğümler oluşabilmektedir budama sayesinde bu dallanmalar ayıklanır. Son olarak durdurma kriteri ile çeşitli şartlara göre öğrenme algoritmasını sonlandırmaktadır [103]. Denetimli bu öğrenme modelinde sınıflandırma performansının iyi bir genelleme sonucuna sahip olabilmesi için eğitim veri kümesinin yeteri büyüklük ve değişkenlere sahip olması gerekmektedir [102].

2.9. Performans Değerlendirme Kriteri

Otomatik tespit sistemi için geliştirilen yöntemlerin tümü genel olarak öznetelik çıkarımı ve sınıflandırma şeklinde iki ana aşamadan oluşmaktadır. Kullanılan sınıflandırıcıların yeterliliğinin değerlendirilmesinde de çeşitli yöntemler geliştirilmiştir. Sınıflandırıcı performansında kullanılan ölçütlerin hesaplanışını detaylandırmak amacıyla karşılaşılabilecek durumlar Tablo 2.2’de gösterilmiştir.

Tablo 2.2. Tespit sisteminde karşılaşılabilecek durumlar

Teşhis	Gerçek Durum			
		Epileptik EEG (Hasta Birey)	Normal EEG (Sağlam Birey)	Toplam
	Epileptik EEG (Hasta Birey)	DE	YE	DE+YE
	Normal EEG (Sağlam Birey)	YN	DN	YN+DN
	Toplam	DE+YN	YE+DN	DE+YE+DN+YN

Tez çalışmasındaki konu ile bağlantılı olarak düzenlenen Tablo 2.2’de bulunan ifadelerin açıklaması şu şekildedir;

DE: Gerçekte epileptik EEG sinyali olup sınıflandırıcı sonucuna göre de epileptik EEG sinyali olarak belirlenen doğru olgulardır.

YE: Gerçekte epileptik EEG sinyali olduğu halde sınıflandırıcı sonucuna göre normal EEG sinyali olarak belirlenen yanlış olgulardır.

DN: Gerçekte normal EEG sinyali olup sınıflandırıcı sonucuna göre de normal EEG sinyali olarak belirlenen doğru olgulardır.

YN: Gerçekte normal EEG sinyali olduğu halde sınıflandırıcı sonucuna göre epileptik EEG sinyali olarak belirlenen yanlış olgulardır.

Tespit sistemlerinde sınıflandırmanın sonucunda elde edilen veriler ile sistemin doğruluğu ve hata oranı Denklem (2.41) ve (2.42)’de belirtildiği gibi hesaplanmaktadır [104].

$$Doğruluk = \frac{DE+DN}{DE+YE+DN+YN} \quad (2.41)$$

$$Hata Oranı = 1 - Doğruluk \quad (2.42)$$

Sınıflandırıcının duyarlılığı hastalığı taşıyanları hangi oranla tespit edebildiği anlamına gelir. Duyarlılık doğru sınıflandırılan epileptik EEG sinyallerinin toplamda elde edilen tüm epileptik EEG sinyalleri sayısına oranıdır [104, 105]. Denklem (2.43)’de belirtildiği gibi hesaplanmaktadır.

$$Duyarlılık = \frac{DE}{DE+YE} \quad (2.43)$$

Sınıflandırıcının normal EEG sınıf etiketlerini tahmin etmedeki etkinliği belirleyicilik veya özgüllük olarak isimlendirilmektedir. Denklem (2.44)'de gösterilen belirleyicilik doğru sınıflandırılan normal EEG sinyallerinin toplamda elde edilen tüm normal EEG sinyalleri sayısına oranıdır [105].

$$Belirleyicilik = \frac{DN}{DN+YN} \quad (2.44)$$

Duyarlılık ve belirleyicilik ölçütlerin tersi olan, sınıflandırıcının hatalı durumları da hesaplanabilmektedir. Gerçekte normal EEG sinyali olan ancak epileptik EEG sinyali olarak sınıflandırılmış örneklerin, tüm normal EEG sinyalleri sayısına oranı yanlış pozitif oranı olarak adlandırılmaktadır. Kısacası gerçekte sağlam bireyler içerisinde sınıflandırıcının hasta olarak hatalı belirlediği örnek sayısıdır [105, 106]. Yanlış pozitif oran sayısı Denklem (2.45)'te belirtildiği gibi hesaplanmaktadır.

$$Yanlış Pozitif Oran Sayısı = 1 - (Belirleyicilik) = \frac{YE}{DN+YE} \quad (2.45)$$

Gerçekte epileptik EEG sinyali olan ancak normal EEG sinyali olarak sınıflandırılmış örneklerin, tüm epileptik EEG sinyalleri sayısına oranı da yanlış negatif oranı olarak isimlendirilen ölçütü vermektedir. Kısacası gerçekte hasta bireyler içerisinde sınıflandırıcının sağlam olarak hatalı belirlediği örnek sayısıdır [105, 106]. Yanlış negatif oran sayısı Denklem (2.46)'da belirtildiği gibi hesaplanmaktadır.

$$Yanlış Negatif Oran Sayısı = 1 - (Duyarlılık) = \frac{YN}{DE+YN} \quad (2.46)$$

Sınıflandırma sonucunda belirlenen epileptik EEG sinyalleri içerisindeki doğru olarak bulunan örnek sayısının, tüm epileptik EEG sinyal sayısına oranı pozitif tahmin değeri olarak Denklem (2.47)'de belirtildiği gibi hesaplanmaktadır [107].

$$Pozitif Tahmin Değeri = \frac{DE}{DE+YE} \quad (2.47)$$

Sınıflandırma sonucunda belirlenen normal EEG sinyalleri içerisinde ki doğru olarak bulunan örnek sayısının, tüm normal EEG sinyal sayısına oranı negatif tahmin değeri olarak adlandırılmaktadır [106]. Negatif tahmin değeri Denklem (2.48)'den yararlanılarak hesaplanmaktadır.

$$\text{Negatif Tahmin Değeri} = \frac{DN}{DN+YN} \quad (2.48)$$

Tahminler sonucunda gerçekte epileptik EEG sinyal etiketinin varlığında doğru çıkma olasılığının, normal EEG sinyal etiketi varlığında doğru çıkma olasılığına oranı pozitif olabilirlik oranını vermektedir. Kısacası sınıflandırıcının hasta olarak ayırdığı sinyali bildirmesindeki doğruluğun yanlışmasına oranıdır [104, 105, 106]. Pozitif olabilirlik oranı Denklem (2.49)'da belirtildiği gibi hesaplanmaktadır.

$$\text{Pozitif Olabilirlik Oranı (L +)} = \frac{\text{Duyarlılık}}{\text{Yanlış Pozitif Oran Sayısı}} = \frac{DE(DN+YE)}{YE(DE+YN)} \quad (2.49)$$


L + oranı ne kadar yüksek olursa, epileptik EEG sinyallerini sınıflandırma performansı o derece iyi olmaktadır [104, 105, 106].

Tahminler sonucunda gerçekte epileptik EEG sinyal etiketinin varlığında yanlış çıkma olasılığının, normal EEG sinyal etiketi varlığında yanlış çıkma olasılığına oranı negatif olabilirlik oranını vermektedir [105]. Negatif olabilirlik oranı Denklem (2.50)'de belirtildiği gibi hesaplanmaktadır.

$$\text{Negatif Olabilirlik Oranı (L -)} = \frac{\text{Yanlış Negatif Oran Sayısı}}{\text{Belirleyicilik}} = \frac{YN(YE+DN)}{DN(DE+YN)} \quad (2.50)$$

L – oranı ne kadar düşük olursa, normal EEG sinyallerini sınıflandırma performansı o derece iyi olmaktadır [105, 106].

Hasta ve sağlam bireylerden oluşan iki popülasyon karşılaştırılırken hatasız bir ayrım çok nadir görülmektedir. Teşhis sistemlerindeki sınıflandırma performans dağılımı Şekil 2.38'dekine benzer olmaktadır [106].



Şekil 2.38. Teşhis sistemindeki genel dağılım [106]


Tanı testleri ile ilgili yapılan çalışmaların birçoğu sistemin güvenilirliğini araştırılmasına ayrılmıştır. İyi bir tanı sistemi için sınıflandırmanın yüksek doğruluk, belirleyicilik, duyarlılık ve pozitif olabilirlik oranına sahip olması beklenir [105, 106].

2.9.1. Alıcı İşlem Karakteristikleri (ROC) Eğrileri:

Alıcı işlem karakteristiği eğrisi (ROC) analizi ilk olarak II. Dünya savaşı sırasında Britanya'daki radar sisteminin ayırt ediciliğini belirlemek amacıyla kullanılmıştır. 1967 yılında Lusted, bir testin doğruluğunu değerlendirmek için ROC eğrisinin nasıl kullanılabileceğini tanımlamıştır. Bununla birlikte Lusted, 1969 yılında tıpta tanı ve tespit sistemlerinde kullanımını sağlamıştır [105]. 1989 yılında Spackman çalışmasında makine öğrenme tekniklerinin değerlendirilmesi için çok yararlı olduğunu kanıtlamıştır [107]. Tespit sistemlerinin bilimsel araştırma alanında önemli bir hale gelmesinden dolayı performans değerlendirmesinde ROC analizinin kullanımı giderek yaygınlaşmaktadır [106].


Duyarlılık ve özgüllük bir tespit sisteminde doğruluğunun temel ölçüleridir. ROC eğrisi, ikili sınıflandırma sistemlerinde ayırım eşik değerinin farklılık gösterdiği durumlarda, hassasiyetin kesinliğe olan oranıyla ortaya çıkmaktadır. Daha basit anlamda ise doğru pozitiflerin yanlış pozitiflere olan kesri olarak da ifade edilebilir. Bir ROC eğrisi, farklı eşik değerleri için dikey eksen üzerinde doğru pozitifler (duyarlılık) ve yatay eksen üzerinde yanlış pozitiflerin (1-özgüllük) oranlarının yer aldığı bir eğridir. ROC eğrisi üzerindeki her nokta, farklı eşik değerlerine karşılık gelen doğru pozitif ve yanlış pozitif

oranını ortaya koymaktadır. Bu noktaların birleştirilmesi ile ROC eğrisi çizilmektedir [105, 107]. ROC uzayı grafiği Şekil 2.39’da gösterilmiştir.



Şekil 2.39. ROC uzay grafiği [104]

ROC eğrisi altında kalan alan ise sistemin doğruluğunu belirtmektedir. ROC uzayı grafiğinde iyi bir performansta sırasıyla (0.0), (0.1) ve (1.1) noktalarından geçen bir eğri oluşturmaktadır. Ayrım yapamayan kötü bir sınıflandırıcının performansında ise ROC, (0.0) noktasından 45 derecelik açı yapacak şekilde (1.1) noktasından geçen doğrusal bir grafik oluşturmaktadır [106]. Farklı başarımlarına sahip bir sınıflandırıcının ROC analizi Şekil 2.40’da gösterilmiştir.




Şekil 2.40. ROC analizi

2.10. Deneysel Çalışmada Kullanılan EEG Veri Seti




Kaliforniya Bonn Üniversitesi Epileptoloji Bölümü'nün erişime açık EEG epileptik veri tabanı bulunmaktadır. Tüm veri tabanındaki EEG sinyalleri 23.6 sn'lik her biri 100 tek kanallı A, B, C, D ve E olmak üzere 5 ayrı sınıftan oluşmaktadır. Kaydedilen veriler, 12 bitlik çözünürlük kullanılarak saniyede 173.61 örnekle sayısallaştırılmıştır. Bant geçiren filtre ayarları 0.53-40 Hz (12dB /oct)'dır [108, 109].

A ve B setleri, sırasıyla beş sağlıklı gönüllüden alınan, gözleri açık ve gözleri kapalı olan yüzey EEG kayıtlarından toplandı. C, D ve E setleri, beş epileptik hastanın cerrahi öncesi tanısının EEG kayıtlarından oluşturuldu. Set C ve D'deki sinyaller sırasıyla epileptojenik bölge içinde ve beyindeki zıt hemisferin hipokampal oluşumundan gelen beş epileptik hastadan nöbetsiz aralıklarla kaydedilmiştir. Set E, nöbet sırasında beş epileptik hastanın EEG kayıtlarını içermektedir [108, 109]. EEG epileptik veri tabanı Tablo 2.3'te gösterilmiştir.

Tablo 2.3. EEG veri seti



Tablo 2.3. EEG veri seti (devamı)

Set C:	Hasta nöbet öncesinde hipokampal oluşumlu karşı yarım küreden elde edilen veriler	
Set D:	Hasta epileptojenik bölgeden elde edilmiştir	
Set E:	Hasta kriz anında	

3. YEREL MAKSİMUM SAYISI, HİJORT MOBİLİTE, HİJORT KARMAŞIKLIK, ORTALAMA EĞRİ GENİŞLİĞİ, STANDART SAPMA VE ORTALAMA ÖZNİTELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI

3.1. Deneysel Çalışma ve Sonuçları

Deneysel çalışmada 5 ayrı bölümden oluşan EEG veri seti iki sınıf (kriz yok/epilepsi kriz var) olacak şekilde 7 durum düşünülmüştür. Bu düşünülen 7 durum Tablo 3.1’de detaylandırılmıştır.

Tablo 3.1. Deneysel çalışmada kullanılan 7 durum

Durum	Veri Seti	Tanımlama
1	A - E	A verileri ve E verilerinin sınıflandırması;
2	AB - E	A,B verileri ve E veri setinin sınıflandırması;
3	CD - E	C,D verileri ve E veri setinin sınıflandırması;
4	A - CDE	A verileri ve C,D,E verilerinin sınıflandırması;
5	ACD - E	A,C,D verileri ve E verilerinin sınıflandırması;
6	AB - CDE	A,B verileri ve C,D,E verilerinin sınıflandırması;
7	ABCD - E	A,B,C,D verileri ve E verilerinin sınıflandırması;


Bu çalışmada her bir EEG sinyali için zaman domeni özniteliklerinden YMS, HM ve HK, doğrusal olmayan özniteliklerden OEG, istatistiksel tabanlı özniteliklerden SS ve O değeri parametreleri kullanılarak 6 adet öznitelik elde edilmiştir. Bu öznitelikleri sınıflandırılması için AÖM kullanılmıştır. Ayrıca sınıflandırıcının ROC eğrisi ile sınıflandırma performansı da analiz edilmiştir.

EEG sinyallerinden elde edilen özniteliklerin sınıflandırılmasında özniteliklerden oluşan veri setinin rastgele seçilmiş üçte ikisi eğitim için ve kalanı test için kullanılmak üzere iki parçaya ayrılmıştır. AÖM sınıflandırıcı gizli katman nöron sayısı 1500 ve gizli katman aktivasyon fonksiyonu sigmoid ampirik yolla seçilmiştir. Önerilen yaklaşım başarımları Tablo 3.2’de verilmiştir.


Tablo 3.2. Önerilen özniteliklerin AÖM üzerindeki başarımları

Durum	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
A - E	100	100	100
AB - E	100	100	100
CD - E	99	98.48	100
A - CDE	98.50	96.43	99.05
ACD - E	99.25	100	97.37
AB - CDE	99.40	100	99.10
ABCD - E	100	100	100


Sınıflandırıcı |A|-|E|, |AB|-|E| ve |ABCD|-|E| durumları için %100 başarımları üretmiştir. Yapılan deneysel çalışmada en düşük başarımları ise %98.5 olarak |A|-|CDE| olarak elde edilmiştir. Önerilen yöntemin 7 durum için sınıflandırma performansını gösteren ROC eğrileri sırasıyla Tablo 3.3'te verilmiştir.

Tablo 3.3. 7 durum için ROC eğrisi

Tablo 3.3. 7 durum için ROC eğrisi (devamı)



Tablo 3.3. 7 durum için ROC eğrisi (devamı)



Tablo 3.3'te de görüleceği gibi önerilen yöntem ile $|A|-|E|$, $|AB|-|E|$ ve $|ABCD|-|E|$ durumlarını %100 başarıyla sınıflandırmıştır. $|CD|-|E|$, $|A|-|CDE|$, $|ACD|-|E|$ ve $|AB|-|CDE|$ durumları için ise epilepsiyi ayırt etmede önerilen yöntemin başarılı olduğu ROC eğrisine bakılarak söylenebilir.

AÖM dışında literatürde epileptik EEG sinyallerinin sınıflandırılmasında yaygın olarak kullanılan DVM, KNN ve KA ile de elde edilen özneliliklerin sınıflandırıcılar üzerindeki etkisi analiz edilerek Tablo 3.4'de detaylandırılmıştır.

Tablo 3.4. Önerilen özneliliklerin KA, DVM, KNN ve AÖM üzerindeki başarımlar

Sınıflandırıcı	Doğruluk (%)						
	A-E	AB-E	CD-E	A-CDE	ACD-E	AB-CDE	ABCD-E
KA	100	99	96	96	97.80	96	98.40
DVM	100	99.70	97.70	98	98.50	98.80	99.40
KNN	100	99.70	97.70	97.50	98.30	98	99.20
AÖM	100	100	99	98.50	99.25	99.40	100

Tablo 3.4’e bakıldığında AÖM diğer sınıflandırıcılara kıyasla genel olarak bakıldığında daha iyi bir performansı gösterdiği görülmüştür. AÖM’nden sonra ise ikinci olarak en iyi başarımlar sonuçları DVM ile yapılan sınıflandırmada kaydedilmiştir.

Önerilen öznitelik çıkarımı ve AÖM kullanılarak yapılan deneysel çalışmadan elde edilen sonuçlar literatürde aynı veri setini ve aynı durumları dikkate alan çalışmalar ile karşılaştırılmıştır. Karşılaştırmalı sonuçlar Tablo 3.5’te verilmiştir.

Tablo 3.5. Bonn Üniversitesinden elde edilen veri setleri ile yapılan çalışmalar ve doğruluk yüzdesi

Öznitelikler Çıkarma + Sınıflandırma	Sınıflandırılan Durum	Doğruluk (%)
Çapraz korelasyon, güç spektrum yoğunluğu+DVM[27]	A - E	100
ADD+ expert sistem[28]	A - E	95
Çoklu dalgacık dönüşümü, entropi+ YSA[29]	A - E	99.85
Zaman-Frekans yöntemleri+YSA[11]	A - E	100
Entropi+ANFIS[30]	A - E	92.22
Zaman-Frekans yöntemleri+tekrarlayan sinir ağı[31]	A - E	99.6
Doğrusal olmayan ön işleme+YSA[32]	A - E	97.20
Fourier dönüşümü+karar ağaçları[33]	A - E	98.72
ADD+Hibrit Sistem(K-means+MLPNN)[13]	A - E	100
Dalgacık dönüşümü+K-means/DVM[34]	A - E	100/78
Önerilen yöntem+AÖM	A - E	100
Zaman-Frekans yöntemleri+YSA[11]	ABCD - E	97.73
Çoklu dalgacık dönüşümü,entropi+ YSA[29]	ABCD - E	98.27
ADD+Hibrit Sistem(K-means+MLPNN)[13]	ABCD - E	100
Zaman-Frekans yöntemleri + doğrusal olmayan sistemler[110]	ABCD - E	100
Dalgacık dönüşümü+K-means/DVM[34]	ABCD - E	100/93.6
Önerilen yöntem+AÖM	ABCD - E	100

Tablo 3.5’ten görüldüğü gibi |A|-|E| durumu için [11], [13], [27], [34] ve önerilen yöntem %100 başarıma sahiptir. |ABCD|-|E| durumu için [13], [34], [110] ve önerilen yöntem %100 başarıma sahiptir. Literatürdeki çalışmalar ile karşılaştırıldığında önerilen yöntemin geçerliliğini göstermektedir.

4. TEKRARLILIK ÖLÇÜM ANALİZİ ÖZNİTELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI

4.1. Deneysel Çalışma ve Sonuçları

Önerilen yöntemde Kaliforniya Bonn Üniversitesi Epileptoloji Bölümü tarafından gerçekleştirilen erişime açık EEG epileptik veri seti kullanılarak epilepsi tespiti üzerine bir deneysel çalışma yapılmıştır. Bu çalışmada epilepsi tespitinde kriz var veya yok olacak şekilde 7 durum düşünülerek TÖA ile RR, DET, L, ENTR, LAM ve TT olmak üzere 6 adet öznitelik çıkarılmıştır. Önerilen bu öznitelik çıkarma yönteminin etkisini 7 farklı durumda test edilmesi için AÖM kullanılmıştır. Son olarak da yapılan çalışmanın ROC performans analizi elde edilmiştir.




Sınıflandırma bölümünde EEG sinyallerinden elde edilen öznitelikler ile oluşturulan durumlarda rastgele seçilmiş üçte ikisi eğitim ve kalan bölümü ise test olarak ayrılmıştır. AÖM’de gizli katman nöron sayısı 1000 ve gizli katmanda tribas aktivasyon fonksiyonu ampirik yöntemlerle seçilmiştir. Önerilen yöntemin oluşturulan 7 durumdaki başarımları Tablo 4.1’de gösterilmiştir.

Tabla 4.1. Önerilen özniteliklerin AÖM üzerindeki başarımları


Durum	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
A - E	100	100	100
AB - E	99.33	99.50	99
CD - E	99.67	100	99
A - CDE	95.50	97	95
ACD - E	99.75	100	99
AB - CDE	96.20	98	95
ABCD - E	99.40	100	97

Tablo 4.1’e bakıldığında en yüksek başarımları |A|-|E| durumu için %100 ve en düşük başarımları ise % 95.50 olarak |A|-|CDE| durumunda elde edilmiştir. |A|-|E|, |AB|-|E|, |CD|-|E|, |A|-|CDE|, |ACD|-|E|, |AB|-|CDE| ve |ABCD|-|E| durumları için ROC eğrileri sırasıyla Tablo 4.2’de verilmiştir.


Tablo 4.2. Önerilen yöntemin 7 durum için ROC eğrisi

Durum	ROC eğrisi
$ A - E $	
$ AB - E $	
$ CD - E $	

Tablo 4.2. Önerilen yöntemin 7 durum için ROC eğrisi (devamı)



Tablo 4.2. Önerilen yöntemin 7 durum için ROC eğrisi (devamı)



AÖM dışında önerilen öznitelik çıkarma yöntemi oluşturulan 7 durum için DVM, KNN ve KA sınıflandırıcıları üzerindeki etkisi de analiz edilerek Tablo 4.3’de detaylandırılmıştır.

Tablo 4.3. Önerilen özniteliklerin KA, DVM, KNN ve AÖM üzerindeki başarımları

Sınıflandırıcı	Doğruluk (%)						
	A-E	AB-E	CD-E	A-CDE	ACD-E	AB-CDE	ABCD-E
KA	100	97.70	91.70	93.80	93.50	95	94.60
DVM	100	99.30	97.70	94.30	98.80	95.80	99
KNN	100	99	98	95	98.80	95.20	99
AÖM	100	99.33	99.67	95.50	99.75	96.20	99.40

Tablo 4.3’e bakıldığında AÖM diğer sınıflandırıcılara kıyasla daha iyi bir genelleme performansı gösterdiği görülmüştür. AÖM’nden sonra ise ikinci olarak en iyi başarımları DVM ve KNN ile yapılan sınıflandırmada kaydedilmiştir. Önerilen öznitelik çıkarımı ve AÖM kullanılarak yapılan deneysel çalışmadan elde edilen sonuçlar literatürde aynı veri setini ve aynı durumları dikkate alan çalışmalar ile karşılaştırılmıştır. Karşılaştırmalı sonuçlar Tablo 4.4’te verilmiştir.

Tablo 4.4. Epileptik EEG sinyalleri üzerine yapılan çalışmalar

Durum	Yazarlar	Doğruluk (%)	Durum	Yazarlar	Doğruluk (%)
A - E	Kumar ve ark. [12]	100	ABCD - E	Tzallas ve ark. [11]	97.73
	Orhan ve ark. [13]	100		Kumar ve ark. [12]	94
	Alam ve ark. [15]	100		Orhan ve ark. [13]	99.6
	Das ve ark. [16]	100		Liang ve ark. [14]	98.51
	Tzimourta ve ark. [3]	99.50		Alam ve ark. [15]	100
	Sharma ve ark. [17]	100		Das ve ark. [16]	100
	Samiee ve ark. [18]	99.80		Tzimourta ve ark. [3]	99.20
	Peker ve ark. [19]	100		Sharma ve ark. [17]	99.20
	Sharmila ve ark. [20]	100		Samiee ve ark. [18]	98.10
	Nicolaou ve ark. [21]	93.55		Peker ve ark. [19]	99.33
	Alçin ve ark. [22]	100		Sharmila ve ark. [20]	97.10
	Önerilen Yöntem	100		Önerilen Yöntem	99.40

Ayrıca deneysel çalışmadan elde edilen sonuçlar aynı veri seti ve TÖA kullanılarak elde edilen öznelitliklerin bazıları kullanılarak yapılan literatürde çalışmalar ile karşılaştırılmıştır. Karşılaştırmalı sonuçlar Tablo 4.5’te verilmiştir.

Tablo 4.5. Aynı veri seti ve öznelitlik çıkarma yöntemi kullanılarak yapılan çalışmalar

Durum	Yazarlar	Öznelitlik Çıkarma + Sınıflandırıcı	Doğruluk (%)
A - E	Acharya ve arkadaşları [23]	TÖA + DVM	95.60
	Onay ve arkadaşları [25]	Hilbert Huang-TÖA + DVM	96.67
	Önerilen Yöntem	TÖA + AÖM, DVM, KNN, KA	100

Sonuçlar hem literatürde farklı sinyal işleme ve makine öğrenmesi yöntemi kullanılarak yapılan çalışmalarla hem de TÖA yöntemi kullanılarak yapılan çalışmalarla karşılaştırılmıştır. Yapılan bu karşılaştırmalar sonucunda önerilen TÖA ve AÖM tabanlı epileptik EEG sinyallerinin sınıflandırılması yöntemi karar verme aşamasında medikal tanı sistemlerinde fayda sağlayacak bir araç olabileceği düşünülmektedir.

5. ÇOK BOYUTLU DALGACIK DÖNÜŞÜMÜ VE TEKRARLILIK ÖLÇÜM ANALİZİ ÖZNETELİKLERİ KULLANILARAK EPİLEPTİK EEG SİNYALLERİNİN SINIFLANDIRILMASI

5.1. Deneysel çalışma ve sonuçları

Deneysel çalışma EEG veri seti epilepsi krizi var veya yok olacak şekilde Tablo 3.1’de ifade edilen 7 farklı durumun sınıflandırma problemine yönelik yapılmıştır. Önerilen yöntemde, CDD ve TÖA yöntemi kullanılarak öznitelikler çıkarılmış ve sınıflandırma üzerindeki etkileri makine öğrenmesi yöntemleri ile analizi elde edilmiştir.

Çalışmada ilk olarak CDD’nde $j=5$ alınarak her bir sinyale ait 5x63 lük bir öznitelik matrisi elde edildi. Her bir özelliğe ait 5 adet parametrenin ortalaması alınarak bir sinyale ait 1x63 adet öznitelik çıkarılmıştır. Elde edilen öznitelikler KA, DVM, KNN ve AÖM (gizli katman nöron sayısı 2000 ve aktivasyon fonksiyonu sigmoid) ile sınıflandırılmıştır. Önerilen özniteliklerinin sınıflandırıcılar üzerindeki başarımları Tablo 5.1’de verilmiştir.

Tablo 5.1. CDD özniteliklerinin başarımları

Sınıflandırıcı	Doğruluk (%)						
	A-E	AB-E	CD-E	A-CDE	ACD-E	AB-CDE	ABCD-E
KA	99.50	99.30	96	98	97.30	97	98
DVM	99.50	100	98	99.30	99	99.20	98.60
KNN	99.50	99.70	98	99.30	98.80	98.80	99
AÖM	100	99.67	99	99.75	99.25	99.80	99.40

Çalışmada ikinci olarak TÖA ile elde edilen özniteliklerden RR, DET, L ve ENTR’den oluşan 4 adet öznitelik kullanılmıştır. Her bir sinyale ait elde edilen bu 4 adet öznitelik KA, DVM, KNN ve AÖM (gizli katman nöron sayısı 1000 ve aktivasyon fonksiyonu tribas) ile sınıflandırılmıştır. Önerilen özniteliklerinin sınıflandırıcılar üzerindeki başarımları Tablo 5.2’de verilmiştir.

Tablo 5.2. TÖA özniteliklerinin başarımları sonuçları

Sınıflandırıcı	Doğruluk (%)						
	A-E	AB-E	CD-E	A-CDE	ACD-E	AB-CDE	ABCD-E
KA	95	96.30	81	95.30	86.80	93.80	87.80
DVM	97.50	96.70	87	95.80	91	96.20	89.40
KNN	98	96.70	85.30	95.30	89	94.40	99
AÖM	99	98.33	87	97.25	89.25	97.40	90.20

Deneyisel çalışmada son olarak da önerilen yöntem, CDD ve TÖA ile elde edilen öznitelikler birleştirilerek 67 adet öznitelik elde edilmiştir. Bu öznitelikler KA, DVM, KNN ve AÖM ile sınıflandırılmıştır. Önerilen yaklaşım başarımları sonuçları Tablo 5.3'te verilmiştir.

Tablo 5.3. CDD + TÖA özniteliklerinin başarımları sonuçları

Sınıflandırıcı	Doğruluk (%)						
	A-E	AB-E	CD-E	A-CDE	ACD-E	AB-CDE	ABCD-E
KA	100	99.30	95	97.80	97	98	97.80
DVM	100	99.70	98	99.30	98.80	99.60	98.40
KNN	100	99.70	98	100	98.50	99.60	98.40
AÖM	100	100	99.33	100	99.50	99.80	99.40


Öznitelik çıkarma yöntemlerinin ayrı ayrı ve birlikte kullanılarak elde edilen başarımları oranları karşılaştırma yapıldığında, CDD ve TÖA birlikte kullanılması ile daha iyi sonuçlar elde edilmiştir. Ayrıca CDD ve TÖA yöntemleri birlikte kullanılarak elde edilen özniteliklerin Tablo 5.3'e bakıldığında AÖM diğer sınıflandırıcılara kıyasla daha iyi bir performans yakaladığı kaydedilen başarımları sonuçlarından gözlemlenmektedir.

Önerilen yaklaşımda CDD ve TÖA tabanlı EEG sinyallerinin AÖM ile sınıflandırılmasında, sınıflandırıcının gizli katman nöron sayısı 2000 ve gizli katmanda sigmoid aktivasyon fonksiyonu ampirik yöntemlerle seçilmiştir. Oluşturulan 7 durumda da 10 kat çaprazlama kullanılarak doğruluk, duyarlılık ve özgüllük oranı Tablo 5.4'te gösterilmiştir.


Tablo 5.4. Önerilen (CDD+TÖA) özniteliklerin AÖM üzerindeki başarımları

Durum	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
A - E	100	100	100
AB - E	100	100	100
CD - E	99.33	99.05	100
A - CDE	100	100	100
ACD - E	99.50	99.34	100
AB - CDE	99.80	99.51	100
ABCD - E	99.40	99.26	100


Tablo 5.4'e bakıldığında en yüksek başarımları |A|-|E|, |AB|-|E|, |A|-|CDE| durumları için %100 ve en düşük başarımları ise %99.33 olarak |CD|-|E| durumunda elde edilmiştir. AÖM'nin |A|-|E|, |AB|-|E|, |CD|-|E|, |A|-|CDE|, |ACD|-|E|, |AB|-|CDE| ve |ABCD|-|E| durumları için ROC eğrileri sırasıyla Tablo 5.5'te verilmiştir.

Tablo 5.5. Önerilen yöntemin 7 durum için ROC eğrisi

Tablo 5.5. Önerilen yöntemin 7 durum için ROC eğrisi (devamı)



Tablo 5.5. Önerilen yöntemin 7 durum için ROC eğrisi (devamı)



Deneysel çalışmadan elde edilen sonuçlar literatürde aynı veri setini ve aynı durumları dikkate alan çalışmalar ile karşılaştırılmıştır. Karşılaştırmalı sonuçlar Tablo 5.6’da verilmiştir.

Tablo 5.6. Aynı veri seti ile literatürde yapılan çalışmalar

Yazarlar	Doğruluk (%)	
	A - E	ABCD - E
Tzimourta ve ark. [3]	99.50	99.20
Tzallas ve ark. [11]	100	97.73
Orhan ve ark. [13]	100	99.60
Sharmila ve ark. [20]	100	97.10
Guo ve ark. [29]	99.85	98.27
Önerilen Yöntem	100	99.40

Literatürde aynı veri seti, farklı sinyal işleme ve makine öğrenmesi yöntemi kullanılarak önerilen çalışmalarla birlikte Guo ve ark. [29] önerdiği CDD ve yaklaşık entropi özniteliklerinin çok katmanlı bir sinir ağı yapısı kullanılarak yapılan sınıflandırma çalışması ile karşılaştırma yapılmıştır. Yapılan bu karşılaştırma sonucunda önerilen yöntemin geçerliliğini göstermektedir.

6. SONUÇLAR VE ÖNERİLER

Epilepsi dünya nüfusunun yaklaşık %1'ini kapsayan insanın yaşam kalitesini etkileyen nörolojik bir rahatsızlıktır. Bu oranlar epilepsi hastalığının dünyadaki en yaygın nörolojik hastalıklarından biri olmasını sağlamaktadır. Düşük gelirli ve orta gelirli ülkelerde yapılan son çalışmalarda epilepsi tespiti ile birlikte ilaç tedavisinde çocuk ve yetişkinlerin yaklaşık %70'ine kadar nöbetlerin tamamen kontrol altına alınmasının mümkün olduğunu göstermiştir [1]. Gelişen teknolojiyle birlikte her alanda olduğu gibi biyomedikal alanda da önemli gelişmeler gerçekleştirilmiştir. Yaygın olarak görülen epilepsi hastalığının tespitindeki zorluklardan dolayı bu alandaki bilimsel araştırmalar nöbetlerin saptanması üzerine yoğunlaşmıştır. Böylece nöbet tespitinde nörofizyologlara yardımcı olmakla birlikte hastanın yaşam kalitesini yükseltmeyi hedefleyen bir tanı aracı amaçlanmıştır.

Bu tez çalışmasında Kaliforniya Bonn Üniversitesi Epileptoloji Bölümü tarafından gerçekleştirilen erişime açık EEG epileptik veri seti kullanılarak epilepsi tespiti üzerine 3 farklı deneysel çalışma yapılmıştır. Bu çalışmalardan;

Bölüm 3'te EEG sinyallerinden YMS, HM, HK, OEG, O ve SS yöntemleri kullanılarak 6 adet öznitelik elde edilmiştir. Yöntem 7 farklı sınıflandırma durumu için elde edilen öznitelikler KA, DVM, KNN ve AÖM ile sınıflandırılmıştır. Yapılan deneysel çalışma sonuçlarında en iyi başarımlar oranları AÖM ile kaydedilmiştir. Önerilen öznitelik yöntemleri ve AÖM tabanlı çalışmada sonuçlar en yüksek başarımlar oranı %100, en düşük başarımlar oranı ise %98.50 olarak kaydedilmiştir.

Bölüm 4'te EEG sinyallerinden TÖA ile RR, DET, L, ENTR, LAM ve TT olmak üzere 6 adet öznitelik çıkarılmıştır. Daha sonrasında elde edilen bu öznitelikler KA, DVM, KNN ve AÖM ile sınıflandırılmıştır. Yöntem 7 farklı sınıflandırma probleminde test edilmiştir. Yapılan deneysel çalışma sonuçlarında en iyi başarımlar oranları AÖM ile kaydedilmiştir. Önerilen öznitelik yöntemleri ve AÖM tabanlı deneysel çalışmada sonuçlarda en yüksek başarımlar %100, en düşük başarımlar ise %95.50 olarak kaydedilmiştir.

Bölüm 5'te EEG sinyallerinden CDD ve TÖA'nin birlikte kullanıldığı bir yöntem önerilmiştir. Çalışmada ilk olarak CDD kullanılarak her bir sinyale ait 63 adet öznitelik çıkarılmıştır. Elde edilen öznitelikler 7 farklı sınıflandırma durumu AÖM ile sınıflandırılmıştır. İkinci olarak ise TÖA'nde RR, DET, L ve ENTR'den oluşan 4 adet

öznitelik kullanılarak 7 farklı durum için KA, SVM, KNN ve AÖM ile sınıflandırılmıştır. Son olarak önerilen yöntemde iki farklı öznitelik çıkarma yöntemlerinden elde edilen öznitelikler birleştirilerek 67 adet öznitelik KA, SVM, KNN ve AÖM ile sınıflandırılmıştır. CDD ve TÖA yönteminin bir arada kullanılmasıyla daha iyi bir başarıml oranı elde ettiği gözlemlenmiştir. Önerilen öznitelik çıkarma yöntemi ve AÖM kullanılarak yapılan deneysel çalışmada en yüksek başarıml %100 ve en düşük başarıml ise %99.33 olarak elde edilmiştir.

Ayrıca yapılan deneysel çalışmalarda önerilen yöntemdeki sınıflandırıcının ROC analizi ile performansları değerlendirilerek, literatürde aynı veri seti kullanılarak yapılan çalışmalar ile karşılaştırılmıştır. Önerilen yöntemlerin hem ROC analizlerine hem de literatürdeki yapılan çalışmalar ile karşılaştırma sonucuna bakıldığında önerilen yöntemlerin geçerliliğini desteklemektedir.

Bu tez çalışmasında otomatik tespit sistemlerinde iyi bir başarıml ve kısa sürede sonuçlanması amaçlanmıştır. Önerilen öznitelik çıkarma yöntemleri ve ikinci aşamasında KA, SVM, KNN ve AÖM ile sınıflandırılarak başarıml oranları karşılaştırılmıştır. Genel olarak en iyi sonuçlar AÖM ile kaydedilmiştir. Kullanılan öznitelik çıkarma yöntemleri ve AÖM ile tanı kararının çok kısa sürede, iyi başarıml oranı vermesi sağlanmıştır. TGKİB ağ mimarisine sahip AÖM' nin medikal tanı sistemlerinde iyi bir genelleme performansı elde etmek için öğrenme algoritması olarak kullanılabileceğini göstermiştir.

Epilepsi tespiti üzerine yapılan bu tez çalışmasındaki iki aşamalı önerilen yöntemler farklı tıbbi teşhis ve sinyal işleme problemleri için uyarlanabilir. İlerdeki klinik uygulamalarında daha hızlı ve başarıml talebini ne ölçüde karşılayabileceği araştırılabilir.

KAYNAKLAR

- [1] <http://www.who.int/mediacentre/factsheets/fs999/en/> Dünya Sağlık Örgütü (Epilepsi). Şubat 2018.
- [2] **Gotman, J.**, 1999. Automatic detection of seizures and spikes, *Journal of Clinical Neurophysiology*, **16(2)**, 130-140.
- [3] **Tzimourta, K.D., Astrakas, L.G., Tsipouras, M.G., Giannakeas, N., Tzallas, A.T. and Konitsiotis, S.**, 2017. Wavelet based classification of epileptic seizures in EEG signals, *Computer-Based Medical Systems (CBMS)*, IEEE 30th International Symposium on, pp. 35-39.
- [4] **Fetz, E.E.**, 1969. Operant conditioning of cortical unit activity, *Science*, **163(3870)**, 955-958.
- [5] **Sutton, S., Braren, M., Zubin, J. and John, E.R.**, 1965. Evoked-potential correlates of stimulus uncertainty, *Science*, **150(3700)**, 1187-1188.
- [6] **Donchin, E., Spencer, K.M. and Wijesinghe, R.**, 2000. The mental prosthesis: assessing the speed of a P300-based brain-computer interface, *IEEE transactions on rehabilitation engineering*, **8(2)**, 174-179.
- [7] **McFarland, D.J., Sarnacki, W.A. and Wolpaw, J.R.**, 2010. Electroencephalographic (EEG) control of three-dimensional movement, *Journal of neural engineering*, **7(3)**, 036007.
- [8] **Mishchenko, Y., Kaya, M. ve CÖMERT, M.**, 2017. Beyin bilgisayar arayüzü için DVM makine öğrenme yöntemi kullanılarak EEG verilerinden sağ ve sol el hareket düşüncelerinin tespiti, *TÜBAV Bilim Dergisi*, **10(3)**, 1-20.
- [9] **Tzallas, A.T., Tsipouras, M.G., Tsalikakis, D.G., Karvounis, E.C., Astrakas, L., Konitsiotis, S. and Tzaphlidou, M.**, 2012. Automated epileptic seizure detection methods: a review study, In Epilepsy-histological, electroencephalographic and psychological aspects, InTech, pp. 75-98.
- [10] **Acharya, U.R., Chua, C.K., Lim, T.C., Dorothy and Suri, J.S.**, 2009. Automatic identification of epileptic EEG signals using nonlinear parameters, *Journal of Mechanics in Medicine and Biology*, **9(04)**, 539-553.

- [11] **Tzallas, A.T., Tsipouras, M.G. and Fotiadis, D.I.**, 2007. Automatic seizure detection based on time-frequency analysis and artificial neural networks, *Computational Intelligence and Neuroscience*, 2007, pp. 1-13.
- [12] **Kumar, Y., Dewal, M.L. and Anand, R.S.**, 2014. Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network, *Signal Image and Video Processing*, **8(7)**, 1323-1334.
- [13] **Orhan, U., Hekim, M. and Ozer, M.**, 2011. EEG signals classification using the K-means clustering and a multilayer perceptron neural network model, *Expert Systems with Applications*, **38(10)**, 13475-13481.
- [14] **Liang, S.F., Wang, H.C. and Chang, W.L.**, 2010. Combination of EEG complexity and spectral analysis for epilepsy diagnosis and seizure detection, *EURASIP Journal on Advances in Signal Processing*, **2010(1)**, 853434.
- [15] **Alam, S.S. and Bhuiyan, M.I.H.**, 2013. Detection of seizure and epilepsy using higher order statistics in the EMD domain, *IEEE journal of biomedical and health informatics*, **17(2)**, 312-318.
- [16] **Das, A.B., Bhuiyan, M.I.H. and Alam, S.S.**, 2014. A statistical method for automatic detection of seizure and epilepsy in the dual tree complex wavelet transform domain, *Informatics, Electronics & Vision (ICIEV)*, 2014 International Conference on. IEEE, pp. 1-6.
- [17] **Sharma, M., Pachori, R.B. and Acharya, U.R.**, 2017. A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension, *Pattern Recognition Letters*, **94**, 172-179.
- [18] **Samiee, K., Kovacs, P. and Gabbouj, M.**, 2015. Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform, *IEEE transactions on Biomedical Engineering*, **62(2)**, 541-552.
- [19] **Peker, M., Sen, B. and Delen, D.**, 2016. A novel method for automated diagnosis of epilepsy using complex-valued classifiers, *IEEE journal of biomedical and health informatics*, **20(1)**, 108-118.
- [20] **Sharmila, A. and Geethanjali, P.**, 2016. DWT based epileptic seizure detection from EEG signals using naive bayes/K-NN classifiers, *IEEE Access*, **4**, 7716-7727.

- [21] **Nicolaou, N. and Georgiou, J.,** 2012. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines, *Expert Systems with Applications*, **39(1)**, 202-209.
- [22] **Alçin, Ö.F., Güner, A. ve Üstündağ, M.,** 2016. Frekans tabanlı öznelilikler kullanılarak epileptik EEG sinyallerinin sınıflandırılması, *TÜRK DOĞA VE FEN DERGİSİ*, **5**, 32.
- [23] **Acharya, U.R., Sree, S.V., Chattopadhyay, S., Yu, W. and Ang, P.C.A.,** 2011. Application of recurrence quantification analysis for the automated identification of epileptic EEG signals, *International journal of neural systems*, **21(03)**, 199-211.
- [24] **Ouyang, G., Xie, L., Chen, H., Li, X., Guan, X. and Wu, H.,** 2005. Automated prediction of epileptic seizures in rats with recurrence quantification analysis, Engineering in Medicine and Biology Society, 27th Annual International Conference of the. IEEE, 2006, pp. 153-156.
- [25] **Onay, F.K. ve Cemal, K.,** 2014. İçsel mod fonksiyonlarının tekrarlılık grafiği kullanılarak EEG sinyallerinde epileptik nöbetin algılanması, *Eleco 2014 Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, pp. 613-617.
- [26] **Thomasson, N., Hoepfner, T.J., Webber Jr, C.L. and Zbilut, J.P.,** 2001. Recurrence quantification in epileptic EEGs, *Physics Letters A*, **279(1-2)**, 94-101.
- [27] **Iscan Z., Dokur Z. and Tamer D.,** 2011. Classification of electroencephalogram signals with combined time and frequency features, *Expert Systems with Applications*, **38**, 10499–10505.
- [28] **Subasi A.,** 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Systems with Applications*, *Expert Systems with Applications*, **32(4)**, 1084-1093.
- [29] **Guo L., Rivero D. and Pazos A.,** 2010. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks, *Journal of Neuroscience Methods*, **193(1)**, 156-163.
- [30] **Kannathal N., Choo M. L., Acharya U. R. and Sadasivan P. K.,** 2005. Entropies for detection of epilepsy in EEG, *Computer Methods and Programs in Biomedicine*, **80(3)**, 187-194.

- [31] **Srinivasan V., Eswaran C. and Sriraam A. N.,** 2005. Artificial neural network based epileptic detection using time-domain and frequency domain features, *Journal of Medical Systems*, **29(6)**, 647–660.
- [32] **Nigam V.P. and Graupe D.,** 2004. A Neural-Network-Based detection of epilepsy, *Neurological Research*, **26(1)**, 55-60.
- [33] **Polat K. and Güneş S.,** 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast fourier transform, *Applied Mathematics and Computation*, **187(2)**, 1017-1026.
- [34] **Chen G., Xie W., Bui T. D. and Krzyzak A.,** 2017. Automatic epileptic seizure detection in EEG using nonsubsamped wavelet–fourier features, *Journal of Medical and Biological Engineering*, **37(1)**, 123-131.
- [35] **Şahin, E.M.,** 2015. EEG sinyali almak için sistem tasarımı, *Yüksek Lisans Tezi*, Bozok Üniversitesi Fen Bilimleri Enstitüsü, Yozgat.
- [36] <https://tedmem.org/mem-notlari/sol-beyin-sag-beyin-miti> Sağ ve Sol Beyin. 22 Haziran 2015.
- [37] **Başçıl, M.S.,** 2015. Beyinde üretilen yöne bağlı EEG sinyallerinin öznitelik çıkarımı yardımıyla sınıflandırılması, *Doktora Tezi*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- [38] <http://www.beyin.gen.tr/beyin-loblari.html> Beyin Lobları ve Özellikleri. 8 Temmuz 2015
- [39] **Kutlu, F.,** 2014. Melez sınıflandırma yaklaşımı ile EEG işaretlerinden epileptik dönemlerin algılanması, Yüksek Lisans Tezi, K.T.Ü. Fen Bilimleri Enstitüsü, Trabzon.
- [40] **MEGEP,** 2007. Mesleki eğitim ve öğretim sisteminin güçlendirilmesi projesi, biyomedikal cihaz teknolojileri-elektrotlar, Ankara.
- [41] **Senior, C., Russell, T. and Gazzaniga, M.S.,** 2006. Methods in Mind, The MIT Press, USA.
- [42] **Yazgan, E. ve Korürek, M.,** 1996. Tıp Elektroniği, İ.T.Ü. Matbaası, İstanbul.
- [43] **Türkoğlu, M.Y.,** 2010. EEG sinyallerinin analizinde performansı yüksek olan dalgacık tipinin belirlenmesi, *Yüksek Lisans Tezi*, T.O.B.B. Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [44] **Iasemidis, L.D.,** 2003. Epileptic seizure prediction and control, *IEEE Transactions on Biomedical Engineering*, **50(5)**, 549-558.

- [45] **Teplan, M.**, 2002. Fundamentals of EEG measurement, *Measurement science review*, **2**, 1-11.
- [46] **Akdeniz, G.**, 2013. Cerrahi adayı epilepsi hastalarında epileptojenik bölgenin yüzeyel EEG kaynak yerelleştirimi ile belirlenmesi, *Doktora Tezi*, İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü, İstanbul.
- [47] **Tülay, E.E.**, 2009. Beyin elektriksel aktivitesinin ölçümü ve sinyal analizi, *Yüksek Lisans Tezi*, İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [48] **Yıldırım, E.**, 2017. Sağlıklı bireylerde transkutanöz elektriksel sinir stimülasyonunun EEG üzerindeki etkisi, *Yüksek Lisans Tezi*, İstanbul Medipol Üniversitesi Sağlık Bilimleri Enstitüsü, İstanbul.
- [49] **Başar, E., Başar-Eroğlu, C., Karakaş, S. and Schürmann, M.**, 2000. Brain oscillations in perception and memory, *International journal of psychophysiology*, **35**, 95-124.
- [50] **Emhan, Ö.**, 2017. Yukarı- aşağı imleç hareketine ilişkin EEG kayıtlarının ayırık dalgacık, KNN ve DVM ile sınıflandırılması, *Yüksek Lisans Tezi*, Dicle Üniversitesi Fen Bilimleri Enstitüsü, Diyarbakır.
- [51] **Kuru, B.**, 2015. Classification of epilepsy and psychogenic patients with analysis of EEG signals, *MSc Thesis*, Fatih University Institute of Science and Technology, İstanbul.
- [52] <https://neupsykey.com/clinical-electroencephalography-and-nocturnal-epilepsy/> Elektrot bağlantısı. 24 Aralık 2017.
- [53] **Nunez, P.L.**, 1995. Neocortical Dynamics and Human EEG Rhythms, *Oxford University Press*, New York.
- [54] **Bronzino, J.D.**, 1995. Principles of Electroencephalography, *The Biomedical Engineering Handbook*, pp. 201-212, CRC Press, Florida.
- [55] **Picton, T.W., Bentin, S., Berg, P., Donchin, E., Hillyard, S.A., Johnson, R. and Taylor, M.J.**, 2000. Guidelines for using event-related potentials to study cognition: Recording standards and publication criteria, *Psychophysiology*, **37**, 127-152.
- [56] **Nagel, H.N.**, 1995. Biopotential amplifiers, *The Biomedical Engineering Handbook*, pp. 1185-1195, CRC Press, Florida.

- [57] <http://web.itu.edu.tr/~bdogan/dersler/tetu1314/TETU-SayisalFiltreler.pdf> Tıbbi Enstrümantasyon Tasarım ve Uygulamaları. 11 Nisan 2012.
- [58] <http://www.elektrikport.com/teknik-kutuphane/elektronik-filtreler-1-bolum-elektrikport-akademi/17069#ad-image-0>, Elektronik Filtreler. 24 Şubat 2016.
- [59] **Lasemidis, L.D.**, 2003. Epileptic seizure prediction and control, *IEEE Transactions on Biomedical Engineering*, **50**, 549-558.
- [60] **Naderi, S., Acar, F., Mertol, T. and Arda, M.N.**, 2003. Functional anatomy of the spine by Avicenna in his eleventh century treatise “Al-Qanun fial-Tibb” (The Canons of Medicine), *Neurosurgery*, **52**, 1449–53.
- [61] **Lockard, J.S. and Ward, A.A.**, 1992. Epilepsy: A Window to Brain Mechanisms, New York: Raven.
- [62] **Fisch, B.J.**, 1998. Spehlmann’ın EEG El Kitabı, Elsevier Science, Türkçe 6. Baskı, Turgut Yayıncılık, İstanbul.
- [63] **Orhan, U.**, 2011. EEG işaretlerinden epilepsi hastalığının teşhisi için yeni yaklaşımlar, *Doktora Tezi*, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Zonguldak.
- [64] **McGrogan, N.**, 1999. Neural network detection of epileptic seizures in the electroencephalogram.
- [65] **Şen, B., Peker, M., Çavuşoğlu, A. and Çelebi F. V.**, 2014. A Comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms, *Journal of Medical Systems*, **38(3)**, 18.
- [66] **Esteller, R., Echauz, J., Tchong, T., Litt B. and Pless B.**, 2001. Line Length: an efficient feature for seizure onset detection, In Engineering in Medicine and Biology Society, Proceedings of the 23rd Annual International Conference of the IEEE, **2**, 1707-1710.
- [67] **Katz, M.J.**, 1988. Fractals and the analysis of waveforms, *Comput Biol Med*, **18**, 145–156.
- [68] **Hjorth, B.**, 1975. Time domain descriptors and their relation to a particular model for generation of EEG activity, *CEAN-Computerized EEG Analysis*, pp. 3-8.
- [69] **Eckmann, J. P., Kamphorst, S.O. and Ruelle, D.**, 1987. Recurrence plots of dynamical systems, *EPL (Europhysics Letters)*, **4(9)**, 973.

- [70] **Stangalini, M., Ermolli, I., Consolini, G. and Giorgi, F.,** 2017. Recurrence quantification analysis of two solar cycle indices, *Journal of Space Weather and Space Climate*, 7:A5.
- [71] **A Desai, U., Martis, R.J., Acharya, U.R., Nayak, C.G., Seshikala, G. and SHETTY K.R.,** 2016. Diagnosis of multiclass tachycardia beats using recurrence quantification analysis and ensemble classifiers, *Journal of Mechanics in Medicine and Biology*, **16(01)**, 1640005.
- [72] **M. Akay,** 1997. Wavelet applications in medicine, *IEEE Spectrum*, **34(5)**, 50-56.
- [73] **Coifman, R.R., Meyer, Y., Quake, S. and Wickerhauser, V.,** 1992. Wavelet analysis and signal processing, In: *Wavelets and Their Applications*, Jones and Barlett, pp. 153-178.
- [74] **Englehart, K.,** 1998. Signal representation for classification of the transient myoelectric signal, *PhD Thesis*, Department of Electrical and Computer Engineering University of New Brunswick, Canada.
- [75] **Mallat, S.,** 2008. A wavelet tour of signal processing: The sparse way, third edition, Academic Press, pp. 386-387.
- [76] **Ding, S., Zhao, H., Zhang, Y., Xu, X., and Nie, R.,** 2015. Extreme learning machine: algorithm, theory and applications, *Artificial Intelligence Review*, **44(1)**, 103-115.
- [77] **Alcin, O. F., Sengur, A., Ghofrani, S. and Ince, M.C.,** 2014. GA-SELM: Greedy algorithms for sparse extreme learning machine, *Measurement*, **55**, 126-132.
- [78] **Huang, G. B., Zhu, Q. Y., and Siew, C. K.,** 2004, Extreme learning machine: a new learning scheme of feedforward neural networks, *IEEE International Joint Conference on Neural Networks*, Budapest, 25-29 July, **2**, 985-990.
- [79] **Huang, G. B., Zhu, Q. Y. and Siew, C. K.,** 2006, Extreme learning machine: theory and applications, *Neurocomputing*, **70(1)**, 489-501.
- [80] **Alçin, Ö.F.,** 2015. Aşırı öğrenme makinalarının seyrek geri çatma algoritmaları ile optimizasyonu, *Doktora Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

- [81] **Özdemir, F.**, 2008. Genelleştirilmiş inverslerin aşikar ifadeleri ve işaretli genelleştirilmiş inversli matrisler, *Yüksek Lisans Tezi*, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- [82] **Golayoğlu, A.**, 2013. En küçük kareler yöntemi üzerine ders notları, <http://www.kocaelimakine.com>, Nisan 2013.
- [83] **Serre, D.**, 2002, *Matrices: Theory and Applications*, Springer New York Inc., New York.
- [84] **Alçin, Ö.F., Şengür, A., ve İnce, M.C.**, 2015. İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, **30(1)**, 111-117.
- [85] **Bartlett, P. L.**, 1998, The sample complexity of pattern classification with neural networks: the size of the weights is more important than the size of the network, *IEEE Transactions on Information Theory*, **44(2)**, 525-536.
- [86] **Huang, G. B. and Babri, H.**, 1998, Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions, *IEEE Transactions on Neural Networks*, **9(1)**, 224-229.
- [87] **Huang, G. B.**, 2003, Learning capability and storage capacity of two-hidden-layer feedforward networks, *IEEE Transactions on Neural Networks*, **14(2)**, 274-281.
- [88] **Alcin O. F., Sengur A. and Ince M. C.**, 2013, Iterative hard thresholding based extreme learning machine and its application to predictions in medical datasets, *Brain and Health Informatics*, Maebashi, October 29-31.
- [89] **Alçin, Ö. F., Arı, A., Şengür, A. and İnce, M. C.**, Yinelemeli Sert Eşikleme Tabanlı Aşırı Öğrenme Makinası, 23. *Sinyal İşleme ve İletişim Uygulamaları, İnönü Üniversitesi*, Malatya, 16-19 May 2015, pp. 271-274.
- [90] **Alataş, B.**, 2007. Kaotik haritalı parçacık sürü optimizasyonu algoritmaları geliştirme, *Doktora Tezi*, F. Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [91] **Huang, G. B., and Babri, H.A.**, 1998. Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions, *IEEE Transactions on Neural Networks*, **9(1)**, 224-229.
- [92] **Ortega, J.M.**, 1987. *Matrix Theory*, Plenum Press, New York, London.

- [93] **Özçalıcı, M.**, 2017. Aşırı öğrenme makineleri ile hisse senedi fiyat tahmini, *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **35(1)**, 67-88.
- [94] **Varol, G.**, 2015. Efficient action and event recognition in videos using extreme learning machines, *MSc Thesis*, Bogaziçi University, İstanbul.
- [95] **Varady, P., Micsik, T., Benedek, S. and Benyo, Z.**, 2002. A novel method for the detection of apnea and hypopnea events in respiration signals, *IEEE Trans. Biomed. Eng.*, **49**, 936-942.
- [96] **Kavzoğlu, T., ve Çölkesen, I.**, 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, **144(7)**, 73-82.
- [97] **Osuna, E.E., Freund, R. and Girosi, F.**, 1997. Support Vector Machines: Training and Applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, A.I. Memo No. 1602, C.B.C.L. Paper No. 144, pp. 1-41.
- [98] **Vapnik, V.N.**, 1995, The Nature of Statistical Learning Theory, Springer-Verlag, New York.
- [99] **Tunjaku, T.R.**, 2014. PNN ve SVM kullanılarak DWT tabanlı yüz tanıma, *Yüksek Lisans Tezi*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- [100] **Han, J., Kamber, M.**, 2001. Data Mining Concepts and Techniques, Morgan Kaufmann Publishers, Massachusetts, USA,
- [101] **Köktürk, F.**, 2012. K-En Yakın Komşuluk, yapay sinir ağları ve karar ağaçları yöntemlerinin sınıflandırma başarılarının karşılaştırılması, *Doktora Tezi*, Bülent Ecevit Üniversitesi Sağlık Bilimleri Enstitüsü, Zonguldak.
- [102] **Ulusoy, G.**, 2013. Karar ağacı analizi ile AB genişleme kriterlerinin değerlendirilmesi, *Yüksek Lisans Tezi*, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- [103] **Emel, G.G. ve Taşkın, Ç.**, 2005. Veri madenciliğinde karar ağaçları ve bir satış analizi uygulaması, *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, **6(2)**, 221-239.
- [104] **Kartal, E.**, 2015. Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama, *Doktora Tezi*, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

- [105] **Ertorsun, A.D., Bağ, B., Uzar, G. ve Turanoğlu, M.A.**, ROC (Receiver Operating Characteristic) eğrisi yöntemi ile tanı testlerinin performanslarının değerlendirilmesi.
- [106] **Spackman, K.A.**, 1989. Signal detection theory: Valuable tools for evaluating inductive learning, *In Proceedings of the sixth international workshop on Machine learning*, pp. 160-163.
- [107] <http://portal.netcad.com.tr/display/HELP/ROC+Analizi>, ROC analizinin temel mantığı, 2015.
- [108] **Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P. and Elger, C. E.**, 2001. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, *Physical Review E*, **64(6)**, 061907.
- [109] **Siuly, Li, Y. and Wen, P.**, 2011. EEG signal classification based on simple random sampling technique with least square support vector machine, *International journal of Biomedical Engineering and Technology*, **7(4)**, 390-409.
- [110] **Xie, S. and Krishnan, S.**, 2013. Wavelet-Based sparse functional linear model with applications to EEGs seizure detection and epilepsy diagnosis, *Medical and biological engineering and computing*, **51(1-2)**, 49-60.

ÖZGEÇMİŞ

Andaç İMAK, 16.06.1992 tarihinde Elazığ'da doğdu. İlk orta ve liseyi burada tamamladı. 2010 yılında Atatürk Lisesi'nden mezun oldu. 2011 yılında başladığı Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nü 2015 yılında bitirdi. 2016 yılında Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Teknolojileri Programı'nda yüksek lisans eğitimine başladı.

