

T.C.
KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İleri Teknolojiler Anabilim Dalı

Yüksek Lisans Tezi

**MULTİFRAKTAL, SPEKTRAL ANALİZ VE UZUN-KISA SÜRELİ
HAFIZA DERİN ÖĞRENME MODELİ KULLANILARAK EEG
SİNYALLERİNDEN KANAL BAZINDA EPİLEPTİK NÖBET
TESPİTİ**

Danışman:
Doç. Dr. Ömer KASIM

Hazırlayan:
Karim MUSTAFAYEV

Kütahya – 2023

Kabul ve Onay

İleri Teknolojiler Ana bilim dalında, 202085121031 öğrenci numaralı, Karim MUSTAFAYEV'nın hazırlamış olduğu "MULTİFRAKTAL, SPEKTRAL ANALİZ VE UZUN-KISA SÜRELİ HAFIZA DERİN ÖĞRENME MODELİ KULLANILARAK EEG SİNYALLERİNDEN KANAL BAZINDA EPİLEPTİK NÖBET TESPİTİ" başlıklı yüksek lisans tez çalışması ile ilgili tez savunma sınavı jüri tarafından yapılmış ve adayın tezinin OY BİRLİĞİ ile kabul edilmesine karar verilmiştir.

30/01/2023

Tez Jürisi	İmza	
	Kabul	Red
Doç. Dr. Ömer KASIM (Danışman)		
Prof. Dr. Ayhan İSTANBULLU		
Doç. Dr. Mustafa TOSUN		

Doç. Dr. Arif KOLAY

Enstitü Müdürü

Bilimsel Etik Bildirimi

Yüksek Lisans tezi olarak hazırladığım “*Multifraktal, Spektral Analiz Ve Uzun-Kısa Süreli Hafıza Derin Öğrenme Modeli Kullanılarak EEG Sinyallerinden Kanal Bazında Epileptik Nöbet Tespiti*” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

30/01/2023

İmza

Karim MUSTAFAYEV

Özgeçmiş

İlk ve orta öğrenimini Kah'ta aldıktan sonra 2020 yılında Bakü Azerbaycan Teknik Üniversitesi Bilgisayar Mühendisliği bölümünü tamamladım. Üniversite eğitimini tamamladıktan hemen sonra Yüksek Lisans eğitimi için Kütahya Dumlupınar Üniversitesi Simav Teknoloji Fakültesi İleri Teknolojiler Anabilim Dalı Elektrik-Elektronik Mühendisliği bölümüne kabul edildim. Uzmanlık alanlarım sinyal işleme, biyomedikal sinyal analizi ve yapay zekâdır.



ÖZET

MULTİFRAKTAL, SPEKTRAL ANALİZ VE UZUN-KISA SÜRELİ HAFIZA DERİN ÖĞRENME MODELİ KULLANILARAK EEG SİNYALLERİNDEN KANAL BAZINDA EPİLEPTİK NÖBET TESPİTİ

MUSTAFAYEV, Karim

Yüksek Lisans Tezi, İleri Teknolojiler Anabilim Dalı

Tez Danışmanı: Doç. Dr. Ömer KASIM

Ocak, 2023, 110 sayfa

Beyindeki elektriksel aktivitesinin düzensiz seviyede boşalması önemli bir rahatsızlıktır. Epilepsi olarak bilinen bu rahatsızlık uzmanlarca Elektroensefalografi sinyalleri incelenerek teşhis edilir. Uzmanların yoğun çalışması ve uzun Elektroensefalografi çekimlerinde nöbetlerin tespitinin yapay zekâ ile desteklenmesi önemlidir. Bu amaç doğrultusunda, bu çalışmada önerilen yapay zekâ modeli ile CHB-MIT Scalp veri setindeki elektroensefalografi sinyalleri analiz edilerek normal ve epileptik veriler olarak sınıflandırılmıştır. Analiz için 22 kanaldan kaydedilen ve 10 saniyelik segmentlere ayrılan elektroensefalografi sinyallerine Multifraktal Analiz, Anlık Frekans ve Spektral Entropi yöntemleri uygulanmıştır. Analiz yöntemleri ile 162 bileşenden oluşan özellik vektörü elde edilmiştir. 175 adet normal etiketli ve 172 adet epileptik nöbet elektroensefalografi kayıtlarına ait özellik vektörleri çalışmanın veri seti oluşturulmuştur. Sonrasında çalışmadaki yapay zekâ yönteminin eğitimi için veri seti, %80 eğitim ve %20 doğrulama olarak ikiye ayrılmıştır. Eğitim için ayrılan 278 veri ile Çift Yönlü Uzun-Kısa Süreli Hafıza Derin Öğrenme Modeli eğitilmiştir. Kalan 69 veri ile de derin öğrenme modeli doğrulanmıştır. Doğrulama sonucu kanal bazında en yüksek başarı metrikleri Fp1-F7 ve CZ-PZ kanallarından elde edilmiştir. Bu kanallardaki başarı metrikleri sırası ile Doğruluk %85,29, Özgüllük %87,88, Hassasiyet %87,88, Yanlış Pozitif Oranı %12,12, Duyarlılık %82,86, Negatif Tahmin Değeri %82,86, F1-puanı %85,29, Mathews Korelasyon Katsayısı %70,74, Yanlış Negatif Oranı %17,14 ve Yanlış Keşif Oranı %12,12 hesaplanmıştır. Bu sonuç önerilen yöntemin kanal bazında epileptik nöbetleri tespit edebildiğini gösterir. Sonuç olarak, geliştirilen yapay zekâ yöntemi bu alanda çalışan uzmanları asiste edebilecek niteliktedir.

Anahtar Kelimeler: Epileptik Nöbet Tespiti, EEG Sinyal İşleme, Multifraktal Analiz, Spektral Analiz, Uzun-Kısa Süreli Hafıza Derin Öğrenme Modeliyle Sınıflandırma.

ABSTRACT

EPILEPTIC SEIZURE DETECTION FROM EEG SIGNALS ON THE BASIS OF CHANNELS USING MULTIFRACTAL, SPECTRAL ANALYSIS AND LONG-SHORT-TERM MEMORY DEEP LEARNING MODEL

MUSTAFAYEV, Karim

Master Thesis, Department of Advantages Technologies

Thesis Advisor: Assoc. Dr. Ömer KASIM

January, 2023, 110 pages

Irregular discharge of electrical activity in the brain is an important disorder. This disorder, known as epilepsy, is diagnosed by experts by examining electroencephalography signals. It is important to support the detection of seizures with artificial intelligence in the intensive work of experts and long electroencephalography shots. For this purpose, the artificial intelligence model proposed in this study and the electroencephalography signals in the CHB-MIT Scalp data set were analyzed and normal and epileptic data were classified. Multifractal, Instantaneous frequency and Spectral entropy methods were applied to electroencephalography signals recorded from 22 channels and divided into 10-second segments for analysis. With the analysis methods, a feature vector consisting of 162 components was obtained. The feature vectors of 175 normal labeled and 172 epileptic seizure electroencephalography recordings were created for the study. Afterwards, the dataset of the study was divided into two as 80% for training and 20% for validation. Long-short-term memory deep learning model was trained with 278 data allocated for training. The deep learning model was validated with the remaining 69 data. As a result of the validation, the highest success metrics on channel basis were obtained in the Fp1-F7 and CZ-PZ channels. The success metrics in these channels are Accuracy 85.29%, Originality 87.88%, Sensitivity 82.86%, False Positive Rate 12.12%, Sensitivity 82.86%, Negative Prediction Value 82.86%, F1-score 85%, respectively. .29, Matthews Correlation Coefficient 70.74%, False Negative Rate 17.14% and False Discovery Rate 12.12%. These results show that the proposed method can detect epileptic seizures on a channel basis. As a result, the developed artificial intelligence method is capable of assisting experts working in this field.

Keywords: Epileptic Seizure Detection, EEG Signal Processing, Multifractal Analysis, Spectral Analysis, Long-Short-Term Memory Classification with Deep Learning Model.

Önsöz

Bu çalışmayı hazırlarken geçirdiğim süreçte benden yardımlarını esirgemeyen aileme, akrabalarım ve arkadaşlarıma, bana bu Yüksek Lisans Tez Çalışması sırasında kendimi daha da geliştirmeme katkı sağlayan değerli danışman hocam Doç. Dr. Ömer KASIM'a, Doç. Dr. Mustafa TOSUN'a, Öğr. Gör. Mustafa ERGİNLİ'ye, Halil İbrahim ÖZDEMİR'e ve Osman ÇETİN'e teşekkürü bir borç bilirim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	v
ABSTRACT	vi
TABLolar LİSTESİ.....	x
ŞEKİLLER LİSTESİ.....	xii
SİMGELER VE KISALTMALAR LİSTESİ	xiv
GİRİŞ	1

BİRİNCİ BÖLÜM

LİTERATÜR ÇALIŞMASI

1.1. LİTERATÜR.....	4
---------------------	---

İKİNCİ BÖLÜM

GENEL KISIMLAR

2.1. EPİLEPSİ HASTALIĞI.....	18
2.1.1. Epilepsi Hastalığının Tanımı.....	18
2.1.2. Epilepsi Hastalığının Türleri	18
2.1.2.1. Fokal Nöbet.....	19
2.1.2.2. Jeneralize Nöbet.....	19
2.2. ELEKTROENSEFALOGRAFİ SİNYALLERİ.....	19
2.2.1. Elektroensefalografinin Ölçümü	23

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

3.1. ELEKTROENSEFALOGRAFİ VERİLERİ	26
3.2. ELEKTROENSEFALOGRAFİ SİNYALLERİNİN BÖLÜTLEMESİ.....	31

İÇİNDEKİLER

Sayfa

3.3. ELEKTROENSEFALOGRAFİ ANALİZ YÖNTEMLERİ	33
3.3.1. Dalgacık Multifraktal Analiz	33
3.3.2. Spektral Analiz.....	41
3.3.2.1. Anlık Frekans Analizi	42
3.3.2.2. Spektral Entropi Analizi.....	44
3.4. UZUN KISA SÜRELİ HAFIZA DERİN ÖĞRENME MODELİ	47
3.5. DENEYLERİN DOĞRULANMASI.....	50

DÖRDÜNCÜ BÖLÜM BULGULAR VE DENEYSEL ÇALIŞMALAR

4.1. YAPILAN DENEYLER.....	55
-----------------------------------	-----------

BEŞİNCİ BÖLÜM

TARTIŞMA

5.1. TARTIŞMA	93
SONUÇLAR VE ÖNERİLER	96
KAYNAKÇA.....	97
DİZİN	110

TABLOLAR LİSTESİ

	<u>Sayfa</u>
Tablo 3.1: Elektrotlar Ve Onun Açıklamaları	26
Tablo 3.2: Kanallar	28
Tablo 3.3: EEG Veri Seti Bilgisi	29
Tablo 4.1: Birinci Deneydeki Karışıklık Matrisi	55
Tablo 4.2: Birinci Deneyin Metrikleri	55
Tablo 4.3: İkinci Deneydeki Karışıklık Matrisi	57
Tablo 4.4: İkinci Deneyin Metrikleri	57
Tablo 4.5: Üçüncü Deneydeki Karışıklık Matrisi	58
Tablo 4.6: Üçüncü Deneyin Metrikleri	59
Tablo 4.7: Dördüncü Deneydeki Karışıklık Matrisi	60
Tablo 4.8: Dördüncü Deneyin Metrikleri	60
Tablo 4.9: Beşinci Deneydeki Karışıklık Matrisi	61
Tablo 4.10: Beşinci Deneyin Metrikleri	62
Tablo 4.11: Altıncı Deneydeki Karışıklık Matrisi	63
Tablo 4.12: Altıncı Deneyin Metrikleri	63
Tablo 4.13: Yedinci Deneydeki Karışıklık Matrisi	65
Tablo 4.14: Yedinci Deneyin Metrikleri	65
Tablo 4.15: Sekizinci Deneydeki Karışıklık Matrisi	66
Tablo 4.16: Sekizinci Deneyin Metrikleri	67
Tablo 4.17: Dokuzuncu Deneydeki Karışıklık Matrisi	68
Tablo 4.18: Dokuzuncu Deneyin Metrikleri	68
Tablo 4.19: Onuncu Deneydeki Karışıklık Matrisi	69
Tablo 4.20: Onuncu Deneyin Metrikleri	70
Tablo 4.21: On Birinci Deneydeki Karışıklık Matrisi	71
Tablo 4.22: On Birinci Deneyin Metrikleri	71
Tablo 4.23: On İkinci Deneydeki Karışıklık Matrisi	73
Tablo 4.24: On İkinci Deneyin Metrikleri	73
Tablo 4.25: On Üçüncü Deneydeki Karışıklık Matrisi	74
Tablo 4.26: On Üçüncü Deneyin Metrikleri	75
Tablo 4.27: On Dördüncü Deneydeki Karışıklık Matrisi	76
Tablo 4.28: On Dördüncü Deneyin Metrikleri	76

TABLOLAR LİSTESİ

Sayfa

Tablo 4.29: On Beşinci Deneydeki Karışıklık Matrisi	77
Tablo 4.30: On Beşinci Deneyin Metrikleri	78
Tablo 4.31: On Altıncı Deneydeki Karışıklık Matrisi	79
Tablo 4.32: On Altıncı Deneyin Metrikleri	79
Tablo 4.33: On Yedinci Deneydeki Karışıklık Matrisi	81
Tablo 4.34: On Yedinci Deneyin Metrikleri	81
Tablo 4.35: On Sekizinci Deneydeki Karışıklık Matrisi	82
Tablo 4.36: On Sekizinci Deneyin Metrikleri	83
Tablo 4.37: On Dokuzuncu Deneydeki Karışıklık Matrisi.....	84
Tablo 4.38: On Dokuzuncu Deneyin Metrikleri.....	84
Tablo 4.39: Yirminci Deneydeki Karışıklık Matrisi	85
Tablo 4.40: Yirminci Deneyin Metrikleri.....	86
Tablo 4.41: Yirmi Birinci Deneydeki Karışıklık Matrisi	87
Tablo 4.42: Yirmi Birinci Deneyin Metrikleri	87
Tablo 4.43: Yirmi İkinci Deneydeki Karışıklık Matrisi	89
Tablo 4.44: Yirmi İkinci Deneyin Metrikleri	89
Tablo 5.1: Literatürdeki Çalışmaların Kullandıkları Yöntemlere Göre Başarı Oranları (%)	93

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: EEG Sinyalinin Gama (γ) Bandı	20
Şekil 2.2: EEG Sinyalinin Beta (β) Bandı	21
Şekil 2.3: EEG Sinyalinin Alfa (α) Bandı.....	21
Şekil 2.4: EEG Sinyalinin Teta (θ) Bandı	22
Şekil 2.5: EEG Sinyalinin Delta (δ) Bandı	22
Şekil 2.6: Epilepsi Paterni (Kalıbı).....	23
Şekil 3.1: Bu Çalışmaya Ait Akış Diyagramı	25
Şekil 3.2: Uluslararası 10-20 Elektrot Sistemi	26
Şekil 3.3: Chb01_04 Veri Setinin EEG Sinyali	31
Şekil 3.4: Chb01_04 EEG Veri Setinin Bölütlenmiş Hali	32
Şekil 3.5: Örnek Dalgacık MA Çalışma Adım 1	34
Şekil 3.6: Örnek Dalgacık MA Çalışma Adım 2	34
Şekil 3.7: Örnek Dalgacık MA çalışma adım 3	35
Şekil 3.8: Normal Kişiden Alınan Chb01_01 Veri Setinin Tekillik Spektrumu (dh) Grafiği	35
Şekil 3.9: Epileptik Kişiden Alınan chb05_13 Veri Setinin Tekillik Spektrumu (dh) Grafiği	36
Şekil 3.10: Normal Kişiden Alınan chb01_01 Veri Setinin Tutucu Üs Tahminleri (h) Grafiği	37
Şekil 3.11: Epileptik Kişiden Alınan chb05_13 Veri Setinin Tutucu Üs Tahminleri (h) Grafiği	38
Şekil 3.12: Normal Kişiden Alınan chb01_01 Veri Setinin Kümülantları (cp) Grafiği..	39
Şekil 3.13: Epileptik Kişiden Alınan chb05_13 Veri Setinin Kümülantları (cp) Grafiği.	39
Şekil 3.14: Normal Kişiden Alınan chb01_01 Veri Setinin Ölçeklendirme Üsleri (tauq) Grafiği	40
Şekil 3.15: Epileptik Kişiden Alınan chb05_13 Veri Setinin Ölçeklendirme Üsleri (tauq) Grafiği	41
Şekil 3.16: Normal Kişiden Alınan chb01_01 Veri Setinin AF Grafiği	43
Şekil 3.17: Epileptik Kişiden Alınan chb05_13 Veri Setinin AF Grafiği	43
Şekil 3.18: Normal Kişiden Alınan chb01_01 Veri Setinin SE (pa) Grafiği	46
Şekil 3.19: Epileptik Kişiden Alınan chb05_13 Veri Setinin SE (pa) Grafiği.....	47
Şekil 3.20: ÇYUKSHDÖM iç yapısı.....	48
Şekil 4.1: Normal chb01_01 EEG Sinyali.....	54

ŞEKİLLER LİSTESİ**Sayfa**

Şekil 4.2: Epileptik chb05_13 EEG Sinyali	54
Şekil 4.3: Yapılan Deneylerin Başarı Yüzdeleri	90



SİMGELER VE KISALTMALAR LİSTESİ

<u>Simgeler</u>	<u>Açıklama</u>
Hz	Hertz
μV	Mikrovolt
%	Yüzde
δ	Delta
θ	Teta
α	Alfa
β	Beta
γ	Gama
ψ	Psi
λ	Lambda
φ	Fi
π	Pi
log	Logaritma
σ	Sigma
sn	Saniye

<u>Kısaltmalar</u>	<u>Açıklama</u>
1B-ESA	Tek Boyutlu Evrişimli Sinir Ağları
ADD	Ayrık Dalgacık Dönüşümü
AF	Anlık Frekans
AÖM	Aşırı Öğrenme Makinesi
CWD	Choi–Williams Dağılımı
ÇÇA	Çoklu-Çözünürlük Analizi
ÇYKTB	Çift Yönlü Kapılı Tekrarlayan Birim
ÇYUKSHDÖM	Çift Yönlü Uzun-Kısa Süreli Hafıza Derin Öğrenme Modeli
DÖ	Derin Öğrenme
DSWVD	Düzleştirilmiş Sözde Wigner–Ville Dağılımı
DVM	Destek Vektör Makinesi
EAAD	Eğri Altındaki Alan Değeri

<u>Kısaltmalar</u>	<u>Açıklama</u>
EEG	Elektroensefalografi
ESA	Evrişimli Sinir Ağları
FBSE-AMDD	Fourier-Bessel Serisi Genişleme Tabanlı Ampirik Dalgacık Dönüşümü
GD	Görüntü Dönüşümü
GDA	Grafik Dikkat Ağları
iEEG	İntrakraniyal Elektroensefalografi
KEYK	k-En Yakın Komşu
KSFD	Kısa Süreli Fourier Dönüşümü
LGEA	Lineer Grafik Evrişim Ağı
MA	Multifraktal Analiz
MKK	Mathews Korelasyon Katsayısı
NMTKOEYK	Nötrozofik Mantık Tabanlı K-Ortalama En Yakın Komşu
NTD	Negatif Tahmin Değeri
OKM	Odak Kayıp Modeli
RS-VA	Rastgele Seçim ve Veri Artırma
SE	Spektral Entropi
sEEG	Stereo Elektroensefalografi
SGE	Sigmoid Entropi
TBS	Tek Bileşenli Sinyaller
TEÇ	Tek Evrişimli Çekirdekler
VSS	Vagal Sınır Stimulus
YKO	Yanlış Keşif Oranı
YNO	Yanlış Negatif Oranı
YPO	Yanlış Pozitif Oranı
ZF	Zaman-Frekans



TEZ METNİ

GİRİŞ

Epilepsi, beyinde düzensiz seviyede elektriksel aktivitesinin boşalmasına verilen kronik geçici olmayan bir hastalıktır (Sisodiya, vd., 2022). Yapılan araştırmalarda Epilepsi, beyin hastalıkları arasında dünyada en fazla rastlanan üçüncü hastalıktır (Thijs, vd., 2019). Şu anda dünya çapında yaklaşık 50 milyon insanda epilepsi rahatsızlığı bulunmaktadır (Pale, vd., 2022). Yapılan araştırmalar, 15 yaşın altındaki çocuklar ve 65 yaşın üzerindeki kişilerin epilepsi rahatsızlığını geçirmelerinin daha riskli olduğunu ortaya koymuştur (Taquet, vd., 2022).

Uzmanlar, epilepsi rahatsızlığını belirlemek için elektroensefalografi (EEG) tekniğini kullanırlar (Alkhachroum, vd., 2022). EEG kullanılarak uzmanlar hastalığın 3 aşamasını sinyaller üzerinden etiketlerler (Lillo, Mora ve Lucero, 2022). Bunlar sırası ile nöbet öncesi, nöbet anında ve nöbet sonrasıdır (Schüssler, vd., 2022). Ham sinyallerden nöbet anının gözlemlenmesi zordur (Xiong, vd., 2021). Farklı bozucu etmenler ve uzmanların analiz anında yoğun olması gibi durumlar nöbet anının belirlenmesini etkiler (Saedi, vd., 2022). Ayrıca EEG sinyal kalitesi, vücut hareketi, elektrot hareketleri, normal kas aktivitesi, elektromanyetik girişim gibi artefaktlar beyin elektriksel aktivitesinin daha düşük uzaysal ayrıklığı açısından problemler bulunmaktadır (Mercier, vd., 2022). Bu nedenle, günlük hasta izleme ve nöbet uyarısı oluşturma için kafa derisi EEG kayıtları, intrakraniyal elektrotlara kıyasla uygulanabilirlik ve kullanım kolaylığı açısından daha yüksek potansiyele sahiptir (Biondi, vd., 2022).

Yapay zekâ yöntemleri, yüksek karmaşıklığa sahip EEG sinyallerindeki nöbet anının belirlenmesine yenilik getirdi (Comanducci, vd., 2020). Ayrıca, EEG sinyallerindeki gizli özellikleri elde etmede ve spektral özelliklerin sunulmasına katkı sağlar (Yiu, vd., 2022). Son birkaç yıla kadar, geleneksel makine öğrenme teknikleri EEG analizinde tek geçerli seçenektir (Fouad, 2022). Ancak Derin Öğrenme (DÖ) yöntemlerinin kullanılmaya başlaması ile efektif ve gürbüz çözümleri mümkün hale getirdi (Baduge, vd., 2022). Nöbet tahmininde, Evrişimli Sinir Ağları (ESA) ve Uzun-Kısa Süreli Hafıza Derin Öğrenme Modeli (UKSHDÖM) ağırlıklı olarak araştırmacıların ilgisini çekmiştir (Tuncer ve Bolat, 2022). UKSHDÖM, kaybolan gradyan problemini ele almak ve algoritmanın hangi bilgilerin hafızasında tutulması gerektiğini ve nelerin kaldırılması gerektiğini daha kesin olarak kontrol etmesine izin vermek için kapılar dahil edilmiştir (Rath, vd., 2022). EEG sinyalleri esasen oldukça dinamik, doğrusal olmayan zaman serisi verileri olduğu göz önüne alındığında UKSHDÖM tasarım gereği, duygu

tanıma, karışıklık tahmini ve karar verme gibi çeşitli uygulamalarda bildirildiği gibi farklı durumlar sırasında beyin aktivitesinin zamansal özelliklerini izole etmede ESA'ya göre avantaja sahiptir (Khademi, Ebrahimi ve Kordy, 2022).

Her ne kadar epilepsi teşhisi EEG sinyalleri kullanarak yapılsa da farklı elektrotların doğruluğa etkisi araştırılmamıştır. Bu çalışmanın hipotezi EEG çekimlerindeki farklı kanallardan hangisinin epilepsi teşhisine ne kadarlık katkı sağladığıdır. Dahası DÖ yöntemlerinden UKSHDÖM ile yapılan akademik çalışmalarda yüksek başarıların elde edilmesi bizi motive etti. Bu çalışmanın amacı DÖ yöntemleri ile uygun özellik setinin oluşturulması yardımı ile 22 kanallı EEG cihazı ile kaydedilen epilepsi hastalarına ait verilerden hangi kanalın teşhiste önemli olduğunun belirlenmesidir. Bu çalışmanın hedefleri ise CHB-MIT Scalp veri setindeki EEG verileri 10 saniyelik dilimler halinde organize ederek epilepsi nöbet anı ve normal durumdaki etiketlenen şeklinde organize edilir. Sonrasında Multifraktal Analiz (MA), Anlık Frekans (AF), Spektral Entropi (SE) yöntemleri ile özellik seti oluşturulur. ÇYUKSHDÖM ile sınıflandırmadan sonra Doğruluk, Özgüllük, Hassasiyet, Duyarlılık, Yanlış Pozitif Oranı (YPO), Negatif Tahmin Değeri (NTD), F1-puanı, Mathews Korelasyon Katsayısı (MKK), Yanlış Negatif Oranı (YNO) ve Yanlış Keşif Oranı (YKO) istatistiksel yöntemleri ile doğrulanır. Bu çalışmanın katkıları şöyle sıralanabilir.

1. Epilepsi teşhisinde 22 kanalın etkisi gözlemlenmiştir. En yüksek doğruluk başarı metriği ön lobdaki Fp1-F7 ve CZ-PZ kanallarından elde edilmiştir.
2. Spektral Analiz (SA) ile frekans uzayındaki durağan olmayan sinyallerin özelliklerinin analizi ile EEG sinyalindeki düzensizlikler ölçülebilir hale gelmektedir. Bu çoğunlukla ölçeklendirme üslerini ölçmekten oluşan MA, çoğu ampirik veri analizinde pratik olarak etkilidir ve sonlu uzunluğa sahip tek bir veri gözlemine bu çalışmada uygulanmıştır.
3. Önerilen yöntemde kaybolan gradyanlar etkilenmeyen ÇYUKSHDÖM kullanılması kaybolan gradyanlar probleminin çözümüne katkı sağlamıştır.



BİRİNCİ BÖLÜM
LİTERATÜR ÇALIŞMALARI

1.1. LİTERATÜR

Literatüre bakıldığında epileptik nöbetleri EEG sinyallerinden tespit etmek için farklı yöntemler kullanılmıştır. Bu yöntemler genelde özellik çıkarımı, sınıflandırma ve sinyal işleme üzerinde yoğunlaşmıştır. Bizde bu çalışmamızda MA, SA yöntemleri ile özellik çıkarılmıştır. Ayrıca UKSHDÖM ile sınıflandırılmıştır.

Wang vd. (2021), epileptik EEG sinyalini nöbet öncesini ayarlamak için Rastgele Seçim ve Veri Artırma (RS-VA) stratejisi ile birleştirilmiş yığınlanmış tek boyutlu evrişimsel sinir ağı (1B-ESA) modelini kullanmışlardır. EEG sinyalleri bu çalışmada ilk önce 2 saniyelik pencere ile bölütlenmiştir. Daha sonra, 2-saniyelik EEG sinyal dilimleri interiktal ve iktal olarak 1B-ESA modeli ile sınıflandırılmıştır. RS-VA metodu kullanılarak, model eğitimi zamanında örnek dağınıklığı problemi çözülmüştür. Sonuçta, önerilen yaklaşımın performanslarını değerlendirmek için segment bazlı ve olay bazlı seviyeleri kullanılmıştır. Bu çalışma CHB-MIT Stereo Elektroensefalografi (sEEG) veri seti ve SWEC-ETHZ İntrakraniyal Elektroensefalografi (iEEG) veri setleri ile beraber test edilmiştir. CHB-MIT sEEG veri seti için Duyarlılık %88,14, Özgüllük %99,62 ve Doğruluk %99,54 elde edilmiştir. Olaya dayalı seviye açısından bakıldığında, Hassasiyet %99,31, (YPO) 0,2/saat ve ortalama 8,1 sn gecikme görülmüştür. SWEC-ETHZ iEEG veri seti için Duyarlılık %90,09, Özgüllük %99,81 ve Doğruluk %99,73 hesaplanmıştır. Olaya dayalı düzeyde ise Duyarlılık %97,52, YPO 0,07/saat ve ortalama 13,2sn gecikme elde edilmiştir. Bu sonuçlardan, epileptik nöbetleri hem sEEG hem de iEEG verilerinden tespit edilebildiği çalışmada gösterilmiştir.

Zhang ve Li (2022), CHB-MIT Scalp veri setinden faydalanmışlardır. Görüntü Dönüşümü (GD) kullanılarak özel bir nöbet tahmin modeli çalışmıştır. Öncelikle, CHB-MIT Scalp veri seti için her hastanın EEG sinyali filtrelenmiştir ve preiktal ve interiktal bölütlemeler etiketlenmiştir. Daha sonra işlenen EEG sinyali Kısa Süreli Fourier Dönüşümü (KSFD) aracılığıyla İki Boyutlu Spektrogramlara (İBS) dönüştürülmüştür. Son olarak, işlenmiş İBS, belirli epileptik EEG sinyallerinin özellik çıkarma ve sınıflandırma tahminini tamamlamak için GD modelini kullanılmıştır. Sonuçlar, GD kullanılarak epilepsi hastalarından en iyi performansa Chb21 ile etiketli hasta sahip olmuştur. Bu veri setinin metrik değerleri: Doğruluk %94,6, Duyarlılık %98,6, Özgüllük %89,8, Hassasiyet %90,5 ve Eğri Altındaki Alan Değeri (EAAD) 0,989 olarak elde edilmiştir.

Saidi, Othman ve Saoud (2021), yaptıkları çalışmada CHB-MIT Scalp veri setini kullanmışlardır. Bu veri setini ESA ve ESA-Destek Vektör Makinesi (DVM) yöntemlerine göre sınıflandırılmıştır. CHB-MIT Scalp veri setinin ESA sınıflandırma yöntemine göre birinci hastada %100, ikinci hastada %91,9, beşinci hastada %91,87, on dokuzuncu hastada %99,9, yirminci hastada %97,24, yirmi birinci hastada %93,68 ve yirmi üçüncü hastada %100 Doğruluk elde edilmiştir. CHB-MIT Scalp veri setinin ESA-DVM sınıflandırma yöntemine göre ise birinci hastada %95, ikinci hastada %94, beşinci hastada %94, on dokuzuncu hastada %99, yirminci hastada %100, yirmibirinci hastada %96 ve yirmi üçüncü hastada %100 Doğruluk elde edilmiştir. Sonuç olarak, ESA-DVM sınıflandırma yönteminin doğruluğu, ESA sınıflandırma yönteminin doğruluğundan daha iyi başarı değerine ulaşmıştır.

Salvatierra vd. (2020), yaptıkları çalışmada CHB-MIT Scalp veri setini kullanmışlardır. Yazarlar, epileptik hastalarda nöbetleri kestirmek için EEG sinyalleri üzerinde Mutlak Spektral Güç (MSG) ve Spektral Güç Oranı (SGO) ile özellik çıkarmışlardır ve Doğruluk %100 elde etmişlerdir. Sonuç olarak, bir nöbet tahmin algoritmasıyla karşılaştırılmıştır ve böylece elde edilen sonuç değerleri onu düşük bir hesaplama maliyetiyle eşleştirilmiştir.

Hasnaoui ve Djebbari (2022), yaptıkları çalışmada CHB-MIT Scalp veri setini kullanmışlardır. Bu veri setindeki çok sayıda kanal arasındaki yararlı kanalları ayırtmak için Ayırık Dalgacık Dönüşümü (ADD) ve bir k-En Yakın Komşu (KEYK) sınıflandırıcı ile bir sistem oluşturulmuştur. İktal öncesi ve normal sinyalleri 5 seviyeli bir ADD ile ayırılmıştır ve ardından bunları seçilen temel özellikleri kullanarak sınıflandırılmıştır. Bu yöntemleri kullanılabildiği metrik değerleri Doğruluk %98,27, Duyarlılık %100 ve Özgüllük %96,66 elde edilmiştir. Geliştirilen teknikte yazarlar, gelişmiş hesaplama süresi ve tatmin edici sonuçlarla EEG verilerini işleyerek epilepsiyi verimli bir şekilde tahmin edebilmişlerdir.

Fathima, Rahna ve Gaffoor (2020), yılında yaptıkları çalışmada nöbet tespiti için CHB-MIT Scalp kullanmışlardır. Nöbetlerin tespiti için Dalgacık Dönüşümü tabanlı öznelilikler kullanılmıştır. Sekiz özellik yani: Standart Sapma, Ortalama Mutlak Sapma, Kök Ortalama Kare Değeri, Minimum, Çeyrekler Arası Menzil, Çarpıklık, Entropi ve Maksimum Dalgacık Katsayıları üzerinden çıkarılmıştır. Özelliklerin sıralaması, T-Testi Sınıf Ayrılabilirlik Kriteri kullanılarak yapılmıştır. Sınıflandırma, en önemli altı özellik kullanılarak DVM sınıflandırıcısı kullanılarak yapılmıştır ve Özgüllük %100, Duyarlılık

%97,2 ve Doğruluk %98,6 elde edilmiştir. Sonuçlar, ilgili çalışmalara göre bir gelişme göstermektedir.

Yang vd. (2021), yaptıkları çalışmada çok kanallı EEG sinyallerinden elde edilen verilerin Zaman-Frekans Korelasyonunu (ZFK) keşfederek belirli hastalarda nöbetleri tahmin etmek için genel bir yöntem geliştirmeyi amaçlamışlardır. Orijinal EEG sinyalleri, EEG sinyallerine KSFD uygulayarak Zaman-Frekans (ZF) özelliklerini temsil eden spektrogramlara çevrilmiştir. İlk kez, performansı daha iyi tahmin etmek için kanal eşlemeleri arasındaki karşılıklı bağımlılığı araştıran bir kanal dikkat modülü ile yerel özellikleri küresel özelliklerle bütünleştiren bir spektrum dikkat modülünü birleştiren İkili Bir Öz-Dikkat Artık Ağı (İBÖDAA) önerilmiştir. Önerilen yaklaşım, CHB-MIT Scalp EEG veri setinden 13 hastada Hassasiyet %89,33, Özgüllük %93,02, EAAD %91,26 ve Doğruluk %92,07 elde edilmiştir. Yapılan deneyler sonucunda, farklı EEG sinyali tahmin segment uzunluklarının, tahmin performansını etkileyen önemli bir faktör olduğunu göstermiştir. Önerilen yöntem yarışmacı ve hastaya özel mühendislik olmadan iyi sağlamlık sağlamıştır.

Qin vd. (2020), yaptıkları çalışmada CHB-MIT Scalp veri setini kullanarak nöbetleri tahmin etmek için ESA ve Aşırı Öğrenme Makinesinden (AÖM) oluşan karma bir model önermişlerdir. CHB-MIT Scalp veri setini KSFD yöntemi ile özellik çıkarmışlardır ve ESA-ELM yöntemi ile de sınıflandırmışlardır. Yazarlar deneysel sonuçlarda Duyarlılık %95,85, YPO 0.045/saat elde etmişlerdir. İlk olarak, KSFD kullanarak 30 saniyelik pencerelerdeki EEG zaman serilerini 2B spektrogramlara dönüştürülmüştür. Ardından, özellikleri otomatik olarak çıkarmak için bu görüntülere ESA'ları uygulanmıştır. Son olarak, preiktal ve interiktal segmentleri sınıflandırmak için AÖM kullanılmıştır. Önerilen yöntem, CHB-MIT Scalp EEG veri setinde Hassasiyet %95,85 ve YPO 0,045/saat elde edilmiştir.

Zhao vd. (2021), ham EEG verilerinden nöbetleri tespit etmek için bir Lineer Grafik Evrişim Ağına (LGEA), fokal kayıp modeli ve LGEA dayalı yeni bir nöbet tespit modeli önermişlerdir. Grafik sınır ağının giriş grafiğini oluşturmak için ham EEG sinyallerinin Pearson Korelasyon Matrisi (PKM) hesaplanmıştır. Deneyler CHB-MIT Scalp veri setinde uygulanmıştır. CHB-MIT Scalp veri setinin LGEA ile Odak Kayıp Modeline (OKM) göre nöbet saptama doğruluğu %99,3, özgüllüğü %99,43, duyarlılığı %98,82, F1-puanı %98,73 ve EAAD %98,57 değerleri elde edilmiştir. CHB-MIT Scalp veri setinin LGEA modeline görede nöbet saptama Doğruluğu %95,89, Özgüllüğü %95,3,

Duyarlılığı %93,8, F1-puanı %89,36 ve EAAD %82,35 değerleri elde edilmiştir. Sonuç olarak, EAAD + OKM CHB-MIT Scalp veri setinde üstün performansını sağlamıştır.

Sopic, Aminifar ve Atienza (2018), EEG sinyallerinin nöbet geçiren anını tespiti için dört elektrot vasitesi ile e-Glass sistemi geliştirmişlerdir. Deneysel değerlendirmeler, sistemin tek bir pil şarjı ile 2,71 gün çalışmaya izin vererek, Hassasiyet %93,8 ve Özgüllük %93,37 elde edilmiştir. Genel olarak, e-Glass epilepsinin sosyoekonomik yükünü azaltarak hastanın yaşam kalitesinde iyileşmelere önemli ölçüde katkıda bulunmuştur.

Singh ve Malhotra (2021), EEG sinyallerinin DÖ dayalı SA yöntemini kullanarak epileptik nöbetlerin otomatik tahmini için akıllı bir sağlık izleme yaklaşımı önermişlerdir. Yazarlar, nöbet oluşumunun öngörülmesi görevini, ham EEG sinyallerinin filtrelenmesini, zaman alanı segmentasyonunu, frekans alanına dönüştürülmesini, EEG'nin spektral segmentlerinin çeşitli farklı frekans bantlarına ayrılmasını ve özelliklerin çıkarılması dahil olmak üzere farklı uygulama adımlarını uygulamışlardır. Önerilen ESA modelinin sonuçları, iki farklı spektral bant kombinasyonu için preiktal nöbet durumunda %98,3 maksimum doğruluk elde edilmiştir ve interiktal nöbet durumunda %97,4 maksimum Doğruluk elde edilmiştir. Bu nedenle, EEG sinyallerinin SA eşlik ettiği önerilen ESA mimarisi, epileptik nöbetlerin güvenilir ve gerçek zamanlı tahmini için uygun bir yöntem sağlamıştır.

Zhang vd. (2022), epilepsinin tanı ve tedavisini kolaylaştırmak için Çift Yönlü Kapılı Tekrarlayan Birim (ÇYKTB) sinir ağına dayalı otomatik bir nöbet tespit yöntemi önermişlerdir. CHB-MIT Scalp EEG veri setinde Hassasiyet %93,89, Özgüllük %98,49 ve 124 nöbetten 867,14 saatlik test verilerinde YPO metriğini saatte 0,31 olarak almıştır. Sonuç olarak, ÇYKTB ağının uzun süreli EEG'nin çekiminde güvenilir bir sonuçlara ulaşılmıştır.

Shen vd. (2022), ADD, DVM ve karar ağacı makine öğrenimi modellerini kullanan EEG tabanlı bir gerçek zamanlı epilepsi nöbet tespit yaklaşımı önermişlerdir ve performansını karşılaştırarak değerlendirmişlerdir. Farklı alt frekans bantlarındaki öznitelikleri çıkarmak için ADD ve sekiz özdeğer algoritması uygulanmıştır. Daha sonra, sağlık kontrolü, nöbetsiz ve nöbet aktif üç sınıf sınıflandırması için DVM kullanılmıştır ve son olarak, gerçek zamanlı nöbet başlangıcı tespiti için karar ağacı yöntemi uygulanmıştır. Belirlenen algoritma, UB ve CHB-MIT Scalp veri setlerinde uygulanmıştır. Sonuçlar, algoritmanın UB veri setindeki sağlık kontrolü, nöbetsiz ve

nöbet aktif gruplar üç sınıflı sınıflandırmasında Doğruluk %97 ve Duyarlılık %96,67 ve CHB-MIT Scalp Veri Kümesinde gerçek zamanlı nöbet başlangıcı tespiti için Doğruluk %96,38, Duyarlılık %96,15, YPO %3,24 elde edilmiştir.

He vd. (2022), CHB-MIT Scalp veri seti ve Temple Üniversitesi'nin TUH veri seti üzerinde deneyler yapmışlardır. Yazarlar, nöbet tespiti için Grafik Dikkat Ağları (GDA) ve ÇYUKSHDÖM tabanlı yeni bir nöbet tespit yöntemi önermişlerdir. Çalışmada yapılan deneylerde CHB-MIT Scalp veri setinin GDA ve ÇYUKSHDÖM yöntemine göre Doğruluk %98,52, Duyarlılık %97,75, Özgüllük %94,34 elde edilmiştir. TUH veri setinin GAT ve ÇYUKSHDÖM yöntemine göre de Doğruluk %98,02, Duyarlılık %97,7, Özgüllük %99,06 elde edilmiştir. CHB-MIT Scalp veri setinin GDA yöntemine göre Doğruluk %96,28, Duyarlılık %93,03, Özgüllük %92,75 elde edilmiştir. CHB-MIT Scalp veri setinin ÇYUKSHDÖM yöntemine göre Doğruluk %94,16, Duyarlılık %88,23, Özgüllük %75 elde edilmiştir. TUH veri setinin GDA yöntemine göre Doğruluk %95,5, Duyarlılık %94,95, Özgüllük %96,52 elde edilmiştir. TUH veri setinin ÇYUKSHDÖM yöntemine göre Doğruluk %84,43, Duyarlılık %90,9, Özgüllük %89,1 elde edilmiştir. Uygulanan yöntemin, özellik çıkarımı anında çekilmiş EEG sinyallerinin epileptik anını tespit etmek için kaliteli bir sonuçlara ulaşılmıştır.

Ansari, Sharma ve Tripathi (2020), frekans etki alanı özneteliklerinin ve Nötrozofik Mantık Tabanlı K-Ortalama En Yakın Komşu (NMTKOEYK) sınıflandırıcısının bir kombinasyonu olan nöbet tespiti için bir algoritma önermişlerdir. Önerilen algoritmanın performansındaki tutarlılık, Bonn Üniversitesi ve CHB-MIT Scalp EEG veri setlerine uygulanarak kontrol edilmiştir. Önerilen algoritma test edildiğinde AIIMS veri setine göre %98,16, Bonn Üniversitesi veri setine göre %100 ve CHB-MIT Scalp veri setine göre %89,06 sınıflandırma doğruluklarına ulaşmışlardır. NMTKOEYK sınıflandırıcıdan elde edilen Doğruluk değeri, Lineer Diskriminant Analizi, DVM ve KEYK sınıflandırıcılarının elde edilen sonuçlarıyla karşılaştırılmıştır. Bonn Üniversitesi ve CHB-MIT Scalp veri setlerini uygulayarak, önerilen algoritmanın performansındaki Doğruluk değeri test edilmiştir. Önerilen NMTKOEYK, mevcut üç sınıflandırıcı tabanlı yöntemden daha iyi performans göstermiştir. Sonuç olarak, EEG sinyallerinden özellik çıkarmak amacıyla NMTKOEYK sınıflandırıcısını kullanarak epilepsi teşhisinde başarılı bir sonuç elde edilebilmiştir.

Shahbazi ve Aghajan (2018), EEG sinyallerinden nöbet tahmini için DÖ dayalı yeni bir model sunmuşlardır. Bu amaçla, EEG segmentlerinden elde edilen KSFD

üzerinde bir ESA-UKSHDÖM sinir ağı eğitilmiştir. CHB-MIT Scalp veri setinde Hassasiyet %98,21 ve 0,13/saat düşük YPO ve 44,74 ortalama tahmin süresi değerleri elde edilmiştir. Önerilen yöntem, nöbet tahmini için DÖ'e dayalı son teknoloji algoritmalarından daha iyi performans gösterir.

Ansari, Sharma ve Tripathi (2020), iktal (nöbet anı), interiktal (nöbetler arası) ve preiktal (nöbet öncesi) sınıflandırması için minimum öznitelik kümesine sahip UKSHDÖM önermişlerdir. Önerilen yöntem, CHB-MIT Scalp veri tabanı kullanılarak test yapıldığında nöbet tahmininde Doğruluk %91,02 ve nöbet tespitinde Doğruluk %96,59 elde edilmiştir. CHB-MIT Scalp veri setinden alınan EEG sinyalleri 983 saatte UKSHDÖM ağı ile sınıflandırılmıştır. EEG sinyali çekilirken Preiktal (nöbet öncesi) 30 dakikalık süre ve sonra interiktal (nöbetler arası) 1 saatlik süre sürece dahil edilmediğinde Doğruluk %95,71 elde edilmiştir. Değerlendirmenin sonuçları, önerilen ağı, nöbet tespitinin yanı sıra nöbet tahmininde minimal bir dizi özellik ile kullanılmasını önermektedir.

Anuragi, Sisodia ve Pachori (2021), epileptik nöbetleri belirlemek için Fourier-Bessel Serisi Genişleme Tabanlı Ampirik Dalgacık Dönüşümü (FBSE-AMDD) yöntemini kullanan otomatik bir öğrenme çerçevesi önermişlerdir. FBSE-AMDD yöntemi ile EEG sinyallerini alt bant sinyallerine ayrıştırılmıştır. En önemli öznitelikleri seçmek için Kabartma-F Öznitelik Sıralama (KFÖS) yöntemi kullanılmıştır. Bonn ve CHB-MIT Scalp veri setlerini kullanarak EEG sinyalinin nöbet tespiti edilmiştir. 10 kat çapraz doğrulama tekniği uygulayarak modellerin eğitimi ve testi yapılmıştır. FBSE-AMDD öğrenme modeli iki veri seti için de gerçekleştirilmiştir ve diğer son teknoloji yöntemlerle kıyaslanmıştır. Deneysel sonuçlar, önerilen çerçevenin Bonn EEG veri setinde Doğruluk %100 elde edilmiştir ve CHB-MIT Scalp EEG veri setinde Doğruluk %99,84 ulaştığını göstermiştir.

Ciurea vd. (2020), hesaplama karmaşıklığının azaltılmasını sağlamak için girdi olarak bir saniye uzunluğundaki EEG kayıtlarını kullanarak, bir saniye uzunluğundaki EEG kayıtları biçiminde zaman alanı özniteliklerini çıkaran verimli bir algoritma önermişlerdir. Özellikler, algılama için basit bir sinir ağına beslenmiştir. Modeli tek tek ve küresel olarak Upenn-Mayo Clinic veri setinde ve CHB-MIT Scalp veri setinde doğrulanmıştır. Sonuç olarak, hasta bazında Doğruluk %99,17, Duyarlılık %99,44 ve Özgüllük %98,89, küresel olarak Doğruluk %92,69, Duyarlılık %91,99 ve Özgüllük %93,38 elde edilmiştir. Bununla birlikte, sonuçlar daha fazla veriye genelleştirilmelidir.

Mohan vd. (2018), yaptıkları çalışmanın temel amacı, EEG sinyallerini minimum YPO ile analiz ederek epileptik nöbetleri en erken tahmin etmişlerdir. Bu algoritma, Gizli Dirichlet Ayırımı (GDA), QDA ve KEYK sınıflandırıcıları için Physionet ATM'den alınmış EEG veri setinde test edilmiştir. Bu çalışmada farklı sınıflandırıcıların performansları değerlendirilmiş ve karşılaştırılmıştır. Elde edilen ortalama tahmin süresi, 31,6 dakikada YPO değeri 1,3 olmuştur. Sonuçların umut verici olduğu göz önüne alınmıştır.

Li vd. (2021), yaptıkları çalışmada EMD ve CSP'ye dayalı yeni bir hastaya özel nöbet başlangıcı tespit sistemi önermişlerdir. Sistem, iki veri tabanından 34 denekten alınan CHB-MIT Scalp EEG veri kayıtları üzerinde değerlendirilmiştir. Deneysel sonuçlar, önerilen algoritmanın CHB-MIT Scalp veri setinde Özgüllük %97,5, Duyarlılık %97,34 ve SH-SDU veri setinde Özgüllük %96,06, Duyarlılık %93,67 elde ettiğini göstermiştir. Daha sonra, CSP uzamsal filtresinin, nöbet başlangıçlarında yer alan EEG kanallarını tanımlamaya yardımcı olduğunu göstermiştir. 23 denek için 19 hastanın nöbet başlangıç alanları doğru tahmin edilmiştir. Bu tatmin edici sonuçlar, önerilen sistemin klinik uygulamalarda nöbet başlangıcı tespiti için bir referans sağlayabileceğini göstermektedir.

Steele vd. (2021), yaptıkları çalışmada tüm sensör alanı üzerinde bulunan bir karışık filtre ve birden çok kanal kullanarak çoklu nöbet durumu tahminleri yapmışlardır. Yazarlar, çoklu tahminler üretmek için bu işlemi tekrarlamışlardır ve bir Kalman Filtresi uygulayarak çoklu tahminlerden oluşan birleşik bir nöbet durumu tahmini elde etmişlerdir. Tüm sensör uzayından, tek bir nöbet durumu tahmini üretmek için bir sürekli ve bir ikili özellik belirlenmiştir. Sonuç olarak, CHB-MIT Scalp EEG veri seti üzerinde deneyler yapılmıştır ve önerilen tahmin yöntemini doğrulamıştır ve Doğruluk %92,7, Duyarlılık %92,8 ve Özgüllük %93,4 metrik değerlerine ulaşılmıştır. Elde edilen birleşik nöbet durumu tahmini, tek bir tahmin kullanarak elde edebileceklerinden daha yüksek Doğruluk, Duyarlılık ve Özgüllüğe sahip olmuştur.

Ahmad vd. (2020), yaptıkları çalışmada preiktal/iktal ve interiktal dönemlerdeki EEG sinyallerinden öznitelik çıkarma, sınıflandırma ve düzenleme süreci yoluyla epileptik hastalarda nöbetleri tahmin etmeye çalışmışlardır. 10 epilepsi hastasının beyninin çeşitli bölgelerinden gelen EEG sinyalleri değerlendirilmiştir. Sinyallerin Faz Açısı (FA), Genlik ve Güç Spektral Yoğunluğunu (GSY) tayin etmek için Hızlı Fourier Dönüşümü (HFD) yöntemi kullanılmıştır. Sinyalleri sınıflandırmak amacıyla DVM

kullanılmıştır. Önerilen yaklaşım CHB-MIT Scalp EEG veri seti üzerinde test edilmiştir ve epileptik nöbetleri nöbet başlangıcından ortalama 25 dakika önce Doğruluk %100 ve saatte düşük bir yanlış alarm oranı 0,46 elde edilmiştir. Tıp biliminde gelişmiş nöbet tahmin cihazlarının geliştirilmesine yardımcı olacaktır.

Wang vd. (2021), EEG sinyallerinin zaman, frekans ve kanal bilgilerini analiz etmek için yeni bir ESA önermişlerdir. Önerilen ESA modeli CHB-MIT Scalp EEG veri tabanı ile değerlendirilmiştir, deneysel sonuçlar modelimizin mevcut en son teknolojiden daha iyi performans göstermiştir ve Doğruluk %80,5, Duyarlılık %85,8 ve Özgüllük %75,1 elde edilmiştir.

Shariat vd. (2021), yaptıkları çalışmada CHB-MIT Scalp ve sEEG veri setlerini kullanmışlardır. Bu veri setlerini ön işleme için Butterworth filtre ve bölütleme kullanmışlardır, covaryans matrisi ile özellik çıkarmışlardır, Maksimum Alaka Düzeyi Minimum Fazlalık ve Sıralı İleri Özellik Seçimi ile özellik seçmişlerdir ve DVM ilede sınıflandırılmıştır. CHB-MIT Scalp veri setine göre Doğruluk %99,87, Duyarlılık %99,91 ve Özgüllük %99,82 elde edilmiştir. sEEG veri setine göre de Doğruluk %98,14, Duyarlılık %98,16 ve Özgüllük %98,12 elde edilmiştir.

Ryu vd. (2021), yaptıkları çalışmada EEG verilerini kullanarak epileptik nöbet tahmini için DenseNet ve UKSHDÖM yöntemlerini birleştirerek yeni bir model önermişlerdir. Sonrasında bu model ile önceden dönüştürülmüş görüntü eğitilmiştir. Sonuç olarak, Doğruluk %93,28, Duyarlılık %92,92, Özgüllük %93,65, saatte yanlış pozitif oranı 0,063 elde edilmiştir ve preiktal uzunluk 5 dakika olduğunda F1-puanı 0,923 elde edilmiştir. Sonuç olarak, önerilen yöntem önceki çalışmalarla karşılaştırıldığında, nöbet tahmin performansının önemli ölçüde iyileştiği doğrulanmıştır.

Zhao vd. (2020), nöbet tahmini için İkili 1-B ESA önermişlerdir. İkili 1-B ESA, tahmin performansını iyileştirmek için Tek Evrişimli Çekirdekleri (TEÇ) kullanılmıştır. İlk katman hariç, gerekli hesaplama ve depolamayı azaltmak için tüm parametreler ikili hale getirilmiştir. Amerikan Epilepsi Derneği Nöbet Tahmini Mücadelesi veri setine göre EAAD 0,915, duyarlılık %89,26 ve YPO 0,117/saat ve CHB-MIT Scalp veri setine göre de EAAD 0,97, Duyarlılık %94,69 ve YPO 0,095/saat elde edilmiştir. Son teknoloji ürünü çalışmalarla karşılaştırıldığında, önerilen İkili 1-B ESA daha iyi performans sunmuştur. Ayrıca, TEÇ'in teorik açıklaması, İkili 1-B ESA modeline kıyasla nöbet tahmininde daha iyi performans elde etmiştir.

Khalilpour vd. (2020), CHB-MIT Scalp EEG veritabanını kullanarak epileptik nöbetleri tahmin etmek için yapay bir model geliştirmişlerdir. Nöbetin başlama zamanını bulmak için EEG sinyallerini Tek Boyutlu ESA (TBESA) modeli ile incelemişlerdir. Yedi Katmanlı ESA (YKESA), önerilen modelin performansının Doğruluk %97, Özgüllük %98,47 ve Duyarlılık %98,5 elde edilmiştir. Ayrıca önerilen model, bireysel kanala göre besleme ve gruplanmış kanallara göre besleme durumunda eğitilmiştir. Toplanan sonuçların faydalı olduğu gözlemlenmiştir.

Ghembaza vd. (2022), CHB-MIT Scalp veri setinden faydalanmışlardır. Önerilen çalışmada, ZF denkleminde genişletilmiş bir Renyi Entropisi ile dinamik kanal seçim algoritması önermişlerdir. Önerdikleri algoritma ile yüksek çözünürlüklü ikinci dereceden ZF dağılımlarını kullanarak bu algoritmayı uygulamışlardır. Bu veri setini DVM ve KEYK sınıflandırıcıları ile sınıflandırmışlardır. Spektrogram, Düzleştirilmiş Sözde Wigner–Ville Dağılımı (DSWVD) karşılaştırması amacıyla Choi–Williams Dağılımı (CWD) sayesinde öznitelliklerini belirlemişlerdir. CHB-MIT Scalp veri setinin DVM sınıflandırıcısının Spektrogram öznitelik seçimine göre Doğruluk %97,69, Duyarlılık %100, Özgüllük %97,56, F1-puan %82,35 ve MKK 0,82 elde edilmiştir. CHB-MIT Scalp veri setinin DVM sınıflandırıcısının DSWVD öznitelik seçimine göre Doğruluk %98,46, Duyarlılık %100, Özgüllük %98,4, F1-puan %80 ve MKK 0,81 değerleri alınmıştır. CHB-MIT Scalp veri setinin DVM sınıflandırıcısının CWD öznitelik seçimine göre Doğruluk %96,15, Duyarlılık %100, Özgüllük %96,12, F1-puan %28,57 ve MKK 0,4 metrik değerleri alınmıştır. CHB-MIT Scalp veri setinin KEYK sınıflandırıcısının Spektrogram öznitelik seçimine göre Doğruluk %98,46, Duyarlılık %100, Özgüllük %98,36, F1-puan %88,88 ve MKK 0,88 elde edilmiştir. CHB-MIT Scalp veri setinin KEYK sınıflandırıcısının DSWVD öznitelik seçimine göre Doğruluk %99,23, Duyarlılık %100, Özgüllük %99,2, F1-puan %90,9 ve MKK 0,9 değerleri alınmıştır. CHB-MIT Scalp veri setinin KEYK sınıflandırıcısının CWD öznitelik seçimine göre Doğruluk %96,92, Duyarlılık %100, Özgüllük %96,87, F1-puanı %50 ve MKK 0,56 metrik değerleri alınmıştır. Sonuçlar, cesaret verici olmuştur. Yanı sıra, önerilen çalışmada ZF artırılmış RE tabanlı kanal seçim (RETKS) yöntemi, otomatik bir şekilde EEG dinamik boyutsallık indirgemesi için verimli bir hesaplama çözümü olmuştur.

MohanBabu vd. (2021), optimize edilmiş DÖ Ağ Modeli kullanılarak uzun-kısa süreli kayıtlardan elde edilen nöbet tahminine odaklanmışlardır. Bu yazıda, işlevsel bir

bağlantı ölçüsü olarak etkileşim grafiği modeli kullanılarak, senkronizasyon kalıpları ve preiktal ile interiktal durumları ayırt etme fizibilitesi incelenmiştir. Değerlendirme, CHB-MIT Scalp EEG veri seti üzerinde uygulanarak, nöbet tahmini için Duyarlılık %100 ve 0,1 ile 0,02 arasında düşük yanlış tahmin oranı sağlamıştır. Önerilen DÖ Ağ Modeli metodolojisi, mevcut makine öğrenimi ve ESA yöntemleriyle karşılaştırıldığında, nöbet tahmininin performans oranında kayda değer bir artış olduğunu ortaya koymaktadır.

Bilal vd. (2019), epileptik nöbet tespiti probleminde, veriye dayalı bir boyutsallık azaltma tekniği olan Çok Çözünürlüklü Dinamik Mod Ayırıştırma (ÇÇDMA) uygulamışlardır. Yazarlar, bu algoritmayı CHB-MIT Scalp ve KU Leaven veri kümeleri kullanmışlardır. Önerilen çalışmada, YPO azaltması için ve Duyarlılık ile Özgüllüğün artırması amacıyla işlem sonrası gerekli adımlar uygulanmıştır. İki veri kümesinde bu yöntem uygulanmıştır ve ayrıntılı bir analiz elde edilmiştir. Algoritma, CHB-MIT Scalp veri seti için Hassasiyet 0,937, Özgüllük 0,99, saatte YPO 0,587 ve gecikme süresi 3,12 saat elde edilmiştir. KU Leuven veri seti için Hassasiyet 0,96, Özgüllük 0,99, saatte YPO 0,413 ve gecikme süresi 2,75 saat elde edilmiştir. Bu sonuçlara göre, Çoklu-Çözünürlük Analizi (ÇÇA) ile Temel Dinamik Mod Ayırıştırması (TDMA) karşılaştırılmıştır. Bu karşılaştırılma sonucunda ÇÇA'nın Duyarlılığında daha fazla gelişme sağladığı görülmüştür.

Tang vd. (2018), CHB-MIT Scalp veri seti ile nöbet tahmini performansını artırmak amacıyla Otonom Artefakt Azaltma (OAA) yöntemi önermişlerdir. Önerilen bu yöntem ile Elektrokülografi (EOG) ve Elektromiyografi (EMG) artefaktları ile Çokdeğişkenli Ampirik Mod Ayırıştırımı-Bağımsız Bileşen Analizini (ÇAMA-BBA) birleştirmiştir. Bu yöntem iki aşamadan oluşan artefakt tanımlama sayesinde artefaktlarda ciddi bir azalma gözlenmiştir. CHB-MIT Scalp veri tabanına dayalı olarak Doğruluk %90,59 ve Hassasiyet %91,09 elde edilmiştir.

Tallón-Ballesteros vd. (2022), yaptıkları çalışmada etkili otomatik çapraz özne nöbet tespiti için ayrılabilir derinlik bazında evrişime dayalı değiştirilmiş bir ESA mimarisi önermişlerdir ve araştırmışlardır. Önerilen yöntemin performansı, CHB-MIT Scalp ve UBonn veri setleri üzerinde değerlendirilmiştir. Yöntem, CHB-MIT Scalp veri setine göre Duyarlılık %91,93 ve saatte YPO 0,005 ulaşılmıştır. UBonn veri setine görede Duyarlılık %100 ve saatte YPO 0,057 elde edilmiştir. Sınıflandırma sonuçları, derinlik bilgisine sahip evrişim katmanlarını kullanan bu çalışmanın ESA mimarisinin hem küçük

hem de oldukça büyük bir veri tabanı kullanarak epileptik nöbet tespiti için iyi performans gösterdiğini göstermektedir.

Zhang vd. (2019), yaptıkları çalışmada Ortak Uzaysal Model (OUM) ve ESA kullanılarak nöbet tahmini üzerine yeni bir çözüm önermişlerdir. Önerilen çözüm, CHB-MIT Scalp veri setinden alınan 23 hastanın verileri üzerinde, bir dışarıda bırakma çapraz doğrulaması kullanılarak değerlendirilmiştir ve Hassasiyet %92,2 ve YPO 0,12/saatlik elde edilmiştir. Deneysel sonuçlar, önerilen yaklaşımın en gelişmiş yöntemlerin çoğundan daha iyi performans gösterdiğinin farkına varılmıştır.

Tsiouris vd. (2018), yaptıkları çalışmada, EEG sinyalleri kullanılarak epileptik nöbet tahmininde UKSHDÖM kullanmışlardır. Bu çalışmada, CHB-MIT Scalp EEG veri tabanından sinyaller ile çalışılmıştır. Önerilen metodolojinin 185 nöbetin tamamını tahmin edebildiğini, yüksek nöbet tahmin Duyarlılığı oranları ve YPO 0,11 elde edilmiştir. UKSHDÖM temelli bu yöntem ile geleneksel makine öğrenmeleri ve daha önceki ESA ağlara göre nöbet tahmin performansında daha iyi sonuçlara ulaşılmıştır.

Zou vd. (2018), yaptıkları çalışmada derin yapıya sahip Kanal Kısıtlı ESA (KKESA) kullanan hastaya özel bir nöbet tespit sistemi göstermişlerdir. Bu çalışmada CHB-MIT Scalp veri seti kullanılmıştır. 23 epileptik nöbet geçiren hastanın verileri test edilmiş ve güzel başarı elde edilmiştir. YPO değeri saatte 0,12 olarak ölçülmüştür. 167 nöbetten oluşan teste 1 tanesi doğru tahmin edilememiştir. Sonuç olarak, tavsiye edilen bu yöntem ile detektör performansı en üst düzey teknoloji seviyesindedir.

Kaziha ve Bonny (2020), ham EEG sinyallerinden nöbetleri tespit etmek amacıyla yazılım tabanlı bir sinir ağı geliştirmişlerdir. Bir sinir ağı, ESA dayalı olarak tasarlanmış ve EEG ham sinyal veri seti CHB-MIT Scalp üzerinde eğitilmiştir. CHB-MIT Scalp veri seti üzerinde yazılımsal olarak tasarlanmış bir ESA ile eğitim ve çıkarım yapılmıştır ve Doğruluk %96,74, Özgüllük %100 ve Duyarlılık %82,35 elde edilmiştir. Sınıflandırıcı daha sonra edinim için gerekli çevre birimleri ile yeniden yapılandırılabilir donanım üzerinde gerçekleştirilerek taşınabilir bir çip üzerinde sisteme Güvenlik Operasyon Merkezi (GOM) dönüştürülebilir.

Xu vd. (2020), bir ESA kullanarak uçtan uca bir DÖ çözümü önermişlerdir. Bir ve iki boyutlu çekirdekler, sırasıyla erken ve geç aşama evrişim ve maksimum havuzlama katmanlarında benimsenmiştir. Önerilen ESA modeli, Kaggle kafa içi ve CHB-MIT Scalp veri setleri üzerinde değerlendirilmiştir. Kaggle kafa içi EEG veri setinde Hassasiyet

%93,5, YPO 0,063/saat ve EAAD 0,981 elde edilmiştir. CHB-MIT Scalp EEG veri setinde Hassasiyet %98,8, YPO 0,074/saat değerlerine ulaşılmıştır. Son teknoloji çalışmalarla karşılaştırma, önerilen modelin tahmin performansını aşan bir başarı elde ettiğini göstermektedir.

Raghu vd. (2019), EEG sinyallerinde epileptik nöbetlerin tespiti için Sigmoid Entropi (SGE) olarak adlandırılan yeni bir özellik önermişlerdir. SGE, her alt banttaki dalgacık katsayılarından tahmin edildi ve bir özneyi dışarıda bırak çapraz doğrulamalı doğrusal olmayan bir DVM sınıflandırıcısı kullanılarak sınıflandırılmıştır. RMCH, UBonn ve CHB-MIT Scalp veri setlerini ADD yöntemi ile özellik çıkarılmıştır. Önerilen yöntemin performansı, 115 denekten alınan 58 Saatlik EEG'den oluşan RMCH veri tabanı, Bonn Üniversitesi (UBonn) ve CHB-MIT Scalp veri tabanları ile test edilmiştir. RMCH veri tabanı için nöbet saptama oranı %96,34, YPO 0,5/saatlik ve 1,2 saniyelik bir ortalama algılama gecikmesi gözlemlenmiştir. UBonn veri setine göre Duyarlılık %100 ve CHB-MIT Scalp veri setine göre Duyarlılık %94,21 elde edilmiştir. Sonuç olarak, SGE'in, daha az hesaplama karmaşıklığı ile epileptik nöbet davranışını anlamak için beyin dinamiklerini analiz etmek için kullanılabileceği sonucuna varılmıştır.

Zheng vd. (2020), yaptıkları çalışmada optimum özellik ve minimum kanal ile CHB-MIT Scalp EEG ölçümlerini kullanarak etkili, güvenilir ve otomatik bir epileptik nöbet tahmin sistemi geliştirmişlerdir. CHB-MIT Scalp veri setinden interiktal ve preiktal dönemlerdeki EEG verileri, nöbet tahmini için kullanılır. İlk olarak, orijinal sinyaller bir ADD kullanılarak birkaç frekans bandına ayrıştırılır. Daha sonra, standart sapma (S), genlik günlüğü (L), çeyrek (Q) ve varyasyon katsayısı (CV) gibi özellikler çıkarılır. Son olarak, yukarıdaki iki durumu (preiktal ve interiktal durumlar) sınıflandırmak için farklı özellik vektör kombinasyonları sınıflandırıcılara (destek vektör makinesi (SVM) ve aşırı öğrenme makinesi (ELM)) beslenir. Performans analizi, optimal özelliğin CV, optimal alt bandın 16-31 Hz olduğunu ve optimal EEG kanalının FP1-F7, T7-P7, FP1-F3, P3-O1 veya P7-T7 olarak seçilebileceğini göstermektedir. ELM, sınıflandırma sonuçlarını karşılaştırarak daha sağlam bir ve DVM'den daha yüksek genel doğruluk ve hem ELM hem de DVM'nin en iyi ortalama doğruluğu %100'e kadar ulaşılabilmiştir. CHB-MIT Scalp veri setini ELM ve DVM yöntemleri ile sınıflandırmışlardır ve %100 doğruluk başarısı elde etmişlerdir.

Cheng vd. (2021), epileptik nöbetleri tahmin etmek için DÖ ve uyku CHB-MIT Scalp veri setine dayalı hastaya özel yeni bir yöntem önermişlerdir. ÇYUKSHDÖM,

birini dışarıda bırak çapraz doğrulama yöntemiyle birleştirilmiş sınıflandırma sonuçlarını elde etmek için en ayırt edici özellikleri ortaya çıkarmak için uygulanmıştır. Ardından, iki aşamalı bir son işleme süreci, tahmin sonuçlarını optimize edilmiştir. ÇYUKSHDÖM yönteminde Doğruluk %99,47, Duyarlılık %99,34 ve Özgüllük %99,6 elde edilmiştir. ÇYUKSHDÖM ile sınıflandırma performansı diğer sinir ağlarına göre daha yüksektir. Sonuç olarak, uyku sırasında nöbet tahmini için mevcut yöntemlerle karşılaştırıldığında, önerilen yöntem daha iyi bir tahmin performansına sahiptir.





İKİNCİ BÖLÜM
GENEL KISIMLAR

2.1. EPİLEPSİ HASTALIĞI

2.1.1. Epilepsi Hastalığının Tanımı

Epilepsi, beyindeki hücrelerin elektriksel aktivitesinin ani olarak boşalmasına ve bilinç kaybı oluşturan bir hastalıktır. Manyetik Rezonans Görüntüleme (MRG), ve EEG sinyallerinin analizi epilepsilerdeki beyin süreçlerini anlamamızı ilerletmede temel olmuştur (Sisodiya, vd., 2022). Epilepsi, özellikle çocuklarda sık görülen bir rahatsızlıktır. Sinir rahatsızlığıdır. Çocuklarda yetişkinlere göre 15 kat daha fazla görünür. Dünyada rastlanılan hastalar %80’ni ilk nöbetini 18 yaşından önce geçirmiştir. Epilepsi rahatsızlığı kişinin yaşam kalitesine önemli ölçüde azaltır. Bunun yanında ölüme kadar gidebilir. Paroksistik nörolojik bozukluklar arasında yer alır. Ölümcül olduğu için gerçek zamanlı izleme ve nöbet tespiti oldukça önemlidir.

Epilepsi doğum anındaki kafa darbelerinden, genetik geçmişten, çocukluk anında yüksek seviyede ateşli hastalıklardan, beyin kanamasından, beyin iltihaplanmasından ve alkol kullanımına bağlı durumlar temel olarak epilepsiye neden olduğu bilimsel çalışmalarla ortaya konulmuştur (Sarudiansky, vd., 2021).

Epilepsi tedavisi tam olamayan bir rahatsızlık olsa bile uzmanların önereceği farklı tedavi yöntemleriyle süreç hafifletilir (Çatalkaya, vd., 2022). Epilepsi ilaç kullanmadada doğru ilaçlardan ve doğru dozda belirlenmelidir (Yuluğ, Özşimşek ve Öktem, 2022). Doktorlar kişinin yaşına, onun sürekli nöbet geçirmesine ve başka nedenlere göre hangi ilacı kullanacağına karar verir (Doğan, 2022).

2.1.2. Epilepsi Hastalığının Türleri

Epilepsi hastalığının şu nöbet türleri bulunmaktadır: fokal ve jeneralize (Fordington ve Manford, 2020). Bundan sonra gelen alt bölümlerde bunların kısaca açıklamaları verilmiştir.

2.1.2.1. Fokal Nöbet

Fokal epilepsi, sol ya da sağ beyinde kaynaklanan nöbetlere ek olarak, tek veya çoklu olarak bozukluklar içerir (Lattanzi, vd., 2019).

2.1.2.2. Jeneralize Nöbet

Beynin her iki lobunda ortaya çıkan, tıbbi araştırmalarla veya EEG çekimi ile fark edilebilen nöbetlere jeneralize başlangıçlı nöbetler denir. Jeneralize nöbetlerin sık rastlanılan nöbetleri: Absans, jeneralize tonik-klonik, miyoklonik ve atonik nöbetlerdir (Gray, vd., 2020).

Absans epilepsi idiopatik jeneralize epilepsiler grubunda bulunmakta olup bilinç kaybıyla eşlik eden, iktal EEG' de 2,5-4 frekansında bilateral ve simetrik Diken Dalga Deşarjlarla (DDD) karakterizedir (Huguenard, 2019).

Tonik-klonik nöbetlerde ise genellikle bilincin azalması gözlemlenir, tonik fazda hastanın kasları sertleşir ve yana devrilir, klonik fazda ise şiddetli kas daralmaları tespit edilir (Elmalı, vd., 2020).

Miyoklonik nöbetler baş, gövde veya ekstremitelerde ortaya çıkan ani, kısa süreli, otonom olarak gerçekleşen kas kasılmaları ile özgülleştirilmektedir (Shakeshaft, vd., 2021).

Atonik nöbetler vücudun tonüs kaybı ile gerçekleştiği bilinmektedir. Tonüsün ani olarak kaybolması sonucunda dizler, baş ve gövde öne doğru bükülür, ani düşüşler gerçekleşir. Nöbet esnasında hasta ayakta ise genellikle olduğu yere düşer (Angione, vd., 2019).


2.2. ELEKTROENSEFALOGRAFİ SİNYALLERİ

EEG, beyin tarafından üretilen elektrik alanlarının yüksek zamansal ve uzaysal çözünürlüğe sahip tek beyin görüntüleme yöntemidir. EEG, beyinden gelen elektrik sinyallerini kaydeder, böylece beyin aktivitesiyle ilgili değerli bilgileri çıkarma yeteneği sağlar. EEG sinyalleri, nöronlar tarafından üretilen elektriksel beyin aktivitesinin izlenmesini sağlar. Şizofreni, zihinsel bozukluklar ve diğer ilgili hastalıklarda EEG'den

makine öğrenimi araçları son yıllarda önem kazanmıştır. EEG, epilepsi tespiti için ana araçlardan biridir (Stancin, Cifrek ve Jovic, 2021).


EEG sinyalleri frekansına göre Delta (δ), Teta (θ), Alfa(α), Beta (β) ve Gama (γ) olmak üzere beş alt bantta incelenir (Jayaraj ve Mohan, 2021). 0,5-4 Hz aralığında frekansa ve 20-400 μ V aralığında genliye sahip olan dalgaya Delta (δ) dalgası denir (Yildirim ve Varol, 2016). 4-8 Hz aralığında frekansa ve 5-100 μ V aralığında genliğe sahip olan dalgaya Teta (θ) dalgası denir (Uys, 2019). 8-14 Hz aralığında frekansa ve 2-10 μ V aralığında genliye sahip olan dalgaya Alfa(α) dalgası denir (Bednaya, vd., 2021). 14-30 Hz aralığında frekansa ve 1-5 μ V aralığında genliye sahip olan dalgaya Beta (β) dalgası denir (Todd, Govender ve Colebatch, 2018), 30-100 Hz aralığında frekansa sahip olan dalgaya ise Gama (γ) dalgası denir (Cavelli, vd., 2020).

Şekil 2.1: EEG Sinyalinin Gama (γ) Bandı




Şekil 2.1’de yer alan sinyal, EEG sinyalinin gama bandına ait bir örnek sinyaldir. Bu dalgalar, duyuşal ve çalışma hafızası ile ilgili süreçlerde ortaya çıkmaktadır (Reinhart ve Nguyen, 2019).

Şekil 2.2: EEG Sinyalinin Beta (β) Bandı




Şekil 2.2’de EEG sinyalinin beta bandına ait bir örnek sinyaldir. Beta sinyali erken yaş aralığında beynin orta-arka bölgelerinde bulunur, sonraki yaşlarda ise frontal bölgelere doğru kayabilmektedir (Fröhlich, vd., 2021).

Şekil 2.3: EEG Sinyalinin Alfa (α) Bandı




Şekil 2.3’te EEG sinyalinin alfa bandına ait bir örnek sinyaldir. Zihinsel aktivite ve göz açıp kapamaya yeniden etkinleştiriyor. Uyku anında görülmez amma uyanıkken görülür (O'Hara ve Guerriero, 2019).

Şekil 2.4: EEG Sinyalinin Teta (θ) Bandı



Şekil 2.4'te EEG sinyalinin teta bandına ait bir örnek sinyaldir. Yetişkenlerde uykuya girerken frontal bölgede gözlemlenebilir (Snipes, vd., 2022).

Şekil 2.5: EEG Sinyalinin Delta (Δ) Bandı




Şekil 2.5'te EEG sinyalinin delta bandına ait bir örnek sinyaldir. Delta dalgası insanların gözlerinin hareketsiz halinde ve dinlenirken ortaya çıkmaktadır (Fitriana, vd., 2021).

2.2.1. Elektroensefalografinin Ölçümü

EEG çekim öncesi elektrodların düzenli bir seviyede yerleştirilmesi önemli hazırlık faktörlerden biridir. EEG çekim anında 23 tane küçük elektroda bir tür jel kullanarak saçlı kafa derisine yerleştirilir ve sonra bir bilgisayar arayüzü ile beyinin elektriksel aktivitesi kaydedilir (Stevenson, vd., 2019).

Genel olarak EEG testinin süresi 20 dakika kadar çekilir. Bazı hallerde hastalığın teşhisine göre testin süresi uzatılabilmektedir (Lillo, Mora ve Lucero, 2022). Özellikle uykuda gerçekleşen nöbetlerin tanısında EEG çekimi uzatılmakta ve hastanın uyuması sağlanmaktadır (San-Segundo, vd., 2019).

Şekil 2.6: Epilepsi Paterni (Kalıbı)




Kaynak: Beleza, vd., 2010.

Doktorlar Şekil 2.6'daki kalıbı EEG sinyallerinde gördüklerinde epilepsi tanısı koymaktadırlar (Beleza, vd., 2010).



ÜÇÜNCÜ BÖLÜM
MATERYAL VE YÖNTEM

Şekil 3.1: Bu Çalışmaya Ait Akış Diyagramı



Şekil 3.1’de çalışmamızın akışı gösterilmiştir.


Bu EEG verileri Physionet.org veri sitesinden alınmıştır. Bu veriler 2 kısma ayrılmıştır. Bunlar sırasıyla epileptik ve normaldir. Bu veriler, veri setinde hazır bir şekilde sınıflara ayrılarak etiketlenmiştir. Veri seti incelendiğinde epileptik nöbet anında 172 veri yer almaktadır. Nöbet anında olmayan normal EEG sinyalinde ise 175 veri yer almaktadır. Bu çalışmada EEG sinyalleri kanallar bazında analiz edildi. İlk olarak her kanala ait veriler sırasıyla epileptik ve normal sinyaller, 10 saniyelik bölütlere ayrıldı. Bölütlenen verilerin her biri 1×2560 olarak ele alınmıştır. Bölütlemeden sonra 3 tane analiz yöntemi ile sinyalin özellikleri çıkarılmıştır. Bu yöntemler dalgacık temelli MA yöntemi, AF ve SE’dir. Dalgacık temelli MA yöntemi kullanılarak sinyale ait 36 özellik elde edilmiştir. Bu özelliklerden 11 tanesi tekillik spektrumu (dh) temsil eder. Bu özelliklerden diğer 11 tanesi tutucu üs tahminlerini (h) temsil eder. Diğer 11 özellik ise ölçeklendirme üsleri (tauq) verilerini ilgilendirir. Geriye kalan 3 tanesi ise kümülant (cp) parametrelerini temsil eder. AF analiz yöntemi ile sinyalin uzunluğuna göre 63 özellik hesaplanmıştır. SE analiz yöntemi ile yine aynı şekilde sinyalin uzunluğuna göre 63 tane spektral özellik hesaplanmıştır. Bu 3 yöntemle hesaplanan özellikler bir araya getirilerek EEG sinyalinin çekildiği her bir kanala ait özellik vektörleri elde edilmiştir. Her bir özellik vektöründe 162 özellik yer almaktadır. Sonrasında, her bir kanala ait özellik

vektörleri ile ÇYUKSHDÖM eğitilmiştir. Yapılan eğitim sonucunda epileptik verilerin tespitinde Fp1-F7 ve ve CZ-PZ kanallarından %85,3 başarı elde edilmiştir.

3.1. ELEKTROENSEFALOGRAFİ KAYITLARI

Yaptığımız deneylerde kullandığımız EEG verileri PhysioNet.org’da yer alan CHB-MIT Scalp EEG veri tabanından alınmıştır. Doktorlar epilepsili kişilerden çekilen EEG sinyallerini Boston Çocuk Hastanesinde 22 denekten (5 erkek, 3-22 yaş, 17 kadın, 1.5-19 yaş) aralarında kayıtlar alınmıştır. SUBJECT-INFO dosyasında EEG sinyali çekilen kişilerin yaş ve cinsiyet karakterleri, EEG sinyalleri bulunmaktadır (Shoeb, 2009).

Şekil 3.2: Uluslararası 10-20 Elektrot Sistemi



Kaynak: Tosun, vd., 2018.

Bu çalışmamızda 21 elektrot kullanılan veri setinden faydalanılmıştır. Bu kullanılan elektrotların açıklamaları Tablo 3.1’de gösterilmiştir.

Tablo 3.1: Elektrotlar Ve Onun Açıklamaları

Elektrotun adı	Açıklaması
FP1	sol en ön frontal
F7	en sol frontal
T6	sol temporal
P3	sol parietal
O1	sol osipital
FP2	Sağ en ön frontal

Tablo 3.1 (devam): Elektrotlar Ve Onun Açıklamaları

Elektrotun adı	Açıklaması
A1	Sol referans elektrotu
A2	Sağ referans elektrotu
F3	Sol frontal
Fz	Merkezi frontal
F4	Sağ frontal
F8	En sağ frontal
T3	Sol temporal
C3	Sol merkez
Cz	Merkez
C4	Sağ merkez
T4	Sağ temporal
T5	Sol arka temporal
Pz	Merkezi parietal
P4	Sağ parietal
O2	Sağ oksipital

Bu çalışmada kullandığımız veri seti 22 kanaldan oluşmaktadır. Bu kanallar Tablo 3.2’de verilmiştir.

Tablo 3.2: Kanallar

Kanal İsimleri	Açıklaması
Kanal1-FP1-F7	FP1 ve F7 arasındaki potansiyel fark
Kanal2-F7-T7	F7 ve T7 arasındaki potansiyel fark
Kanal3-T7-P7	T7 ve P7 arasındaki potansiyel fark
Kanal4-P7-O1	P7 ve O1 arasındaki potansiyel fark
Kanal5-FP1-F3	FP1 ve F3 arasındaki potansiyel fark
Kanal6-F3-C3	F3 ve C3 arasındaki potansiyel fark
Kanal7-C3-P3	C3 ve P3 arasındaki potansiyel fark
Kanal8-P3-O1	P3 ve O1 arasındaki potansiyel fark
Kanal9-FP2-F4	FP2 ve F4 arasındaki potansiyel fark
Kanal10-F4-C4	F4 ve C4 arasındaki potansiyel fark
Kanal11-C4-P4	C4 ve P4 arasındaki potansiyel fark
Kanal12-P4-O2	P4 ve O2 arasındaki potansiyel fark
Kanal13-FP2-F8	FP2 ve F8 arasındaki potansiyel fark
Kanal14-F8-T8	F8 ve T8 arasındaki potansiyel fark
Kanal15-T8-P8	T8 ve P8 arasındaki potansiyel fark
Kanal16-P8-O2	P8 ve O2 arasındaki potansiyel fark
Kanal17-FZ-CZ	FZ ve CZ arasındaki potansiyel fark
Kanal18-CZ-PZ	CZ ve PZ arasındaki potansiyel fark
Kanal19-P7-T7	P7 ve T7 arasındaki potansiyel fark

Tablo 3.2 (devam): Kanallar

Kanal İsimleri	Açıklaması
Kanal20-T7-FT9	T7 ve FT9 arasındaki potansiyel fark
Kanal21-FT9-FT10	FT9 ve FT10 arasındaki potansiyel fark
Kanal22-FT10-T8	FT10 ve T8 arasındaki potansiyel fark

Bütün sinyaller, saniyede 256 Hz örnekleme frekansı ile ve 16 bit çözünürlükte çekilmiştir. Genellikle Pysionette yer alan EEG sinyalleri 22 kanal üzerinden elektrotlar vasıtası ile çekilmiştir (Shoeb, 2009).

EEG kayıtlarını elde edebilmek için Uluslararası 10-20 EEG elektrot konumları ve isimlendirme sistemi kullanılmıştır. Bazı epileptik EEG sinyallerinin çekimlerinde farklı elektrotlar ile kaydedilmiştir. Onlar, epileptik chb04'e ait son 36 dosyadaki bir Elektrokardiyografi (EKG) sinyali ve vaka chb09'a ait son 18 dosyadaki bir Vagal Sınır Stimulus (VSS) sinyali gibi başka sinyaller de kaydedilmiştir. EEG veri seti hakkında daha ayrıntılı bilgi Tablo 3.3'te gösterilmiştir (Shoeb, 2009). Bu çalışmada VSS kayıtları kullanılmamıştır.

Tablo 3.3: EEG Veri Seti Bilgisi

Vaka	Cinsiyet	Yaş
Chb01	F	11
Chb02	M	11
Chb03	F	14
Chb04	M	22
Chb05	F	7
Chb06	F	1,5
Chb07	F	14,5

Tablo 3.3 (devam): EEG Veri Seti Bilgisi

Vaka	Cinsiyet	Yaş
Chb08	M	3,5
Chb09	F	10
Chb10	M	3
Chb11	F	12
Chb12	F	2
Chb13	F	3
Chb14	F	9
Chb15	M	16
Chb16	F	7
Chb17	F	12
Chb18	F	18
Chb19	F	19
Chb20	F	6
Chb21	F	13
Chb22	F	9
Chb23	F	6


RECORDS dosyası, bu koleksiyonda yer alan tüm verilerin bir listesini içerir. RECORDS-WITH-SEIZURES dosyası ise bir veya daha fazla nöbet içeren 129 dosyayı listeler. Toplamda, bu kayıtlar 198 nöbet (23 vakalık orijinal sette 182); her nöbetin başlangıcı (I) ve bitişi (J), nöbetli kayıtlar'da listelenen dosyaların her birine eşlik eden. seizure ek açıklama dosyalarında açıklanır. Ayrıca chb nn -summary.txt adlı dosyalar, her

kayıt için kullanılan montaj ve her “edf” dosyasının başlangıcından, içerdiği her bir epileptik anı yakalamanın başlangıcına ve sonuna kadar geçen süre hakkında saniye cinsinden bilgiler içerir (Goldberger, vd., 2000).

3.2. EEG Sinyallerinin Bölütlemesi


EEG sinyallerinin belirli zaman dilimlerine bölünmesine bölütleme denir (Siuly, vd., 2020). Veri kümesinin her bir durumu için ham EEG sinyaller, başlangıçta, bitişik bölümler arasında örtüşme olmaksızın 10 saniyelik uzun bölümlere (segmentlere) ayrılır. Her segment iktal ve normal sınıflamalara bölünmüştür.

Şekil 3.3: Chb01_04 Veri Setinin EEG Sinyali



Şekil 3.3.’de chb01_04 klasöründe yer alan bir EEG sinyali örnek olarak gösterilmiştir. Bu sinyal epilepsi anında kaydedilen bir sinyaldir. Şekil 3.3’ü incelendiğinde 10×10^5 saniye aralığında ve 0 ile ortalama $+1500 -1500 \mu V$ aralığında değiştiği görülmektedir.

Şekil 3.4: Chb01_04 EEG Veri Setinin Bölütlenmiş Hali



Şekil 3.3.b’de chb01_04 klasöründen alınan normal durumdaki sinyal olduğu için bölütleme yapılmıştır. Bu sinyal epilepsi nöbetinde bulunmayan normal sinyale ait örneği temsil etmektedir. Bölütleme 3 sınıfa ayrılmıştır: Preiktal (nöbet öncesi), iktal (nöbet anı), postiktal (nöbet sonrası) olarak ifade edilmektedir. Bölütleme yaparken nöbet anındaki sinyalleri aldık, (iktal) bölütünü Şekil 3.3 (b) gösterdik.

İktal hissesinin formüle göre nasıl alındığı aşağıda gösterilmiştir.

$$\text{datai} \{2,1\} = \text{val} (:, 375552:382464) \quad (3.1)$$

Formül (3.1) denkleminde: datai {2,1}, data verisinin iktal hissesinin 2’nci satır 1’inci sütunu anlamına gelmektedir. Denklemin sağ tarafındaki val değişkenindeki rakamlar şu şekilde ifade edilebilir: önce başlangıç saniyesi 1467 ve bitiş saniyesi 1494 alınmıştır. Bu veri setinin EEG sinyalleri 256 Hz örnekleme frekansı ile çekilmiştir.

$$T_{\text{böl}} \times F_s = \text{veri} \quad (3.2)$$

Denklem 3.2’de bölütleme işleminde ilk önce $T_{\text{baş}}$ saniyesi 10 san F_s örnekleme frekansı 256 Hz ile çarpıyoruz ve sonuçta 2560 veri elde ediyoruz.

Sonra başlangıç 1467 ve bitiş 1494 saniyeleri ile örnekleme frekansı 256 Hz ile çarpıyoruz.

İlk önce biz iktal bölütünün başlangıç saniyesini hesaplamıştık.

$$T_{\text{baş}} \times F_s = \text{segmentin başlangıç noktası} \quad (3.3)$$

Denklem 3.3'te $T_{baş.} * F_s = tsB$, $t_{baş.}$ 1467 san., F_s 256 Hz ve sonuçta iktal hissesinin 375552 başlangıç saniyesini aldık.

$$T_{bit.} \times F_s = \text{segmentin bitiş noktası} \quad (3.4)$$

Denklem 3.4'te $t_{bit.} * F_s = tsBit$, $t_{bit.}$ 1494 san., F_s 256 Hz ve sonuçta iktal hissesinin 382464 bitiş saniyesini aldık.

Böylece 375552 saniyesi ile 382464 saniye arasındaki veriler bölütlenerek elde edilmektedir.

3.3. ELEKTROENSEFALOGRAFİ ANALİZ YÖNTEMLERİ

3.3.1. Dalgacık Multifraktal Analiz

Fraktallar Öklid geometrisini tanımanın imkânsız olduğu doğal yapıların biçimlerini karakterize etmekte kullanılan düzensiz geometrik yapılardır (Andronache, Liritzis ve Jelinek, 2023).

Dalgalanma fonksiyonu, sinyalin dalgalanmasını ve güç yasası özellikleri tanımlar (Villarreal-Hernandez, vd., 2020). Farklı q değerleri ve farklı zaman ölçekleri altında zaman serilerinin değişen eğilimini daha açık bir şekilde ifade etmek için, dalga fonksiyonunun noktalarını bir doğruya sığdırmak için en küçük kareler yöntemini kullanırız (Davidson, Grabowsky ve Jayatilaka, 2022).

$$y(t) = \sum_k s_{j_{m,k}} \varphi_{j_{m,k}}(t) + \sum_{j \geq j_m} \sum_k d_{j,k} \psi_{j,k}(t) \quad (3.5)$$

Denklem 3.5'te ayrıştırma katsayıları yaklaşık $(s_{j_m,k})$ ve detay katsayıları $(d_{j,k})$ olarak adlandırılır. İkincisinin, sinyalin özelliklerini farklı ölçeklerde (çözünürlük seviyeleri) tanımladığı kabul edilir. Bu amaçla, $d_{j,k}$ 'nin standart sapmaları σ_j çözünürlük seviyesinin bir fonksiyonu olarak kullanılır. Çoklu çözünürlüklü dalgacık analizi, sırasıyla düşük geçişli filtre ve yüksek geçişli filtre olan ölçekleme fonksiyonu $\phi(t)$ ve dalgacık $\psi(t)$ 'den oluşturulan iki filtre setini kullanarak bir $y(t)$ sinyalini ayrıştırır (Pavlova, Guyo ve Pavlov, 2022).

1 boyutlu ana dalgacık şu şekilde tanımlanır:

$$L_x(j,k) = \sup_{\lambda' \in 3\lambda_{j,k}} |d_x(j,k)| \quad (3.6)$$

Denklem 3.6'ı şöyle anlatmak olur: ADD kullanarak dalgacık katsayılarını, $d \times (j,k)$ hesaplanır ve her ölçek için her katsayının mutlak değeri kaydedilir. Her daha ince ölçek, bir sonraki daha kaba ölçekten iki kat daha fazla katsayıya sahiptir. 2 j ölçeğindeki her ikili aralık, daha ince bir ölçekte iki aralığın birleşimi olarak yazılabilir. Elde edilen en iyi ölçekten bir seviye daha kaba olan ölçekte başlanır. İlk değeri tüm daha ince ikili aralıklarıyla karşılaştırılır ve maksimum değeri elde edilir. Bir sonraki değere gidilir ve değerini tüm hassas ölçek değerleriyle karşılaştırılır. Değerleri iç içe değerleri ile karşılaştırmaya devam edilir ve maksimumları elde edilir. O ölçek için elde edilen maksimum değerlerden ilk üç değeri inceleyerek bu komşuların maksimumunu elde edilir. Bu maksimum değer, o ölçek için bir dalgacıktır. Bu ölçek için diğer dalgacıkları elde etmek için maksimum değerleri karşılaştırmaya devam edilir. Bir sonraki kaba ölçeğe geçilir ve işlemi tekrarlanır (Wendt ve Abry, 2007).

Şekil 3.5: Örnek Dalgacık MA Çalışma Adım 1 (Wendt ve Abry, 2007)

6		2		7		5	
4	3	5	2	1	0	4	3


Şekil 3.5'te üst satırdaki rakamlar sinyali anlatıyor. Daha sonra o sinyallerin her biri iki sinyale ayrışıyorlar (Wendt ve Abry, 2007).

Şekil 3.6: Örnek Dalgacık MA Çalışma Adım 2 (Wendt ve Abry, 2007)

6		2		7		5	
4	3	5	2	1	0	4	3
	6		5		7		5

Şekil 3.6'da en ince ölçekten (alt sıra) sonraki en kaba düzey olan üst sıradan başlayarak, her değeri ikili aralıklarıyla karşılaştırılır ve maksimumları elde edilir.

Şekil 3.7: Örnek Dalgacık MA Çalışma Adım 3 (Wendt ve Abry, 2007)




Şekil 3.7’de üç komşu değere bakılır ve maksimumu elde edilir. Sonraki üç komşu için tekrarlanır. Bu maksimal, 7 ve 7, bu seviye için ana dalgacık sayılır (Wendt ve Abry, 2007).

Tekillik spektrum (dh), -5 ile 5 arasındaki doğrusal aralıklı momentler için belirlenen yapı fonksiyonları kullanılarak tahmin edilir. Yapı fonksiyonları, biorthogonal spline dalgacık filtresi kullanılarak elde edilen dalgacık liderlerine dayalı olarak hesaplanır. Kullanılan biorthogonal spline dalgacık filtresi, sentez dalgacığında bir kaybolma anına ve analiz dalgacığında beş kaybolma anına sahiptir. Varsayılan olarak, multifraktal tahminler, minimum 3 düzeyinde ve en az altı dalgacık liderinin olduğu maksimum düzeyde dalgacık liderlerinden türetilir (Wendt ve Abry, 2007).

Önce dh tekillik spektrumunun normal kişiden alınan sinyalden analizi yapılmıştır. Bu analiz için chb01_01 veri setini örnek olarak kullanılan veriye ait grafik Şekil 3.7.’de gösterilmiştir.


Şekil 3.8: Normal EEG Sinyaline Ait Chb01_01 Verisine Ait Tekillik Spektrumu (dh) Grafiği



Şekil 3.8.'de x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik sayısı 0,8 ile 0,9 sayıları arasında başlarken örnekleme numarasının 1 sayısına denk gelmiştir. Genlik sayısının 0,9 rakamı örnekleme numarasının 2 rakamına denk gelmiştir. Genlik sayısının 0,9 ile 1 rakamları arası örnekleme numarasının 4 rakamına denk gelmiştir. Genlik sayısının 0,9 ile 1 rakamları arası örnekleme numarasının 5 rakamına denk gelmiştir. Genlik sayısının 1 rakamı örnekleme numarasının 6 rakamına denk gelmiştir. Genlik sayısının 0,9 ile 1 rakamları arası örnekleme numarasının 7 rakamına denk gelmiştir. Genlik sayısının 0,8 ile 0,9 rakamları arası örnekleme numarasının 8 rakamına denk gelmiştir. Genlik sayısının 0,7 değeri örnekleme numarasının 9 değerine denk gelmiştir. Genlik sayısının bitiş noktası 0,2 ile 0,3 değerleri arası örnekleme numarasının 11 değerine denk gelmiştir.

Daha sonra dh tekillik spektrumunun epileptik kişiden alınan sinyalden analiz yaptık. Chb05_13 veri setini örnek olarak kullanılan veriye ait grafik Şekil 3.8'de gösterilmiştir.

Şekil 3.9: Epilepsi Anında Alınan Chb05_13 Veri Setinin Tekillik Spektrumu (dh) Grafiği



Şekil 3.9.'da x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Şekilde genlik sayısı 0,5 ile 0,6 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genlik sayısının 0,6 ile 0,7 değerleri arasında rakamı örnekleme numarasının 2 değerine denk gelmiştir. Genlik sayısının 0,8 ile 0,9 değerleri arasında rakamı örnekleme numarasının 4 değerine denk gelmiştir. Genlik sayısının 0,9 ile 1


değerleri arasında rakamı örnekleme numarasının 5 değerine denk gelmiştir. Genlik sayısının 1 değeri örnekleme numarasının 6 değerine denk gelmiştir. Genlik sayısının 0,9 ile 1 değerleri arası örnekleme numarasının 7 değerine denk gelmiştir. Genlik sayısının bitiş noktası 0,6 ile 0,7 değerleri arası örnekleme numarasının 11 değerine denk gelmiştir.

Epilepsi olmayan normal bir EEG sinyalinin analiz edilen tekillik spektrumu (dh) epileptik EEG sinyalden analiz edilen tekillik spektrumunun grafiklerinin farkına bakıldığında normal anda alınan EEG sinyalinin tekillik spektrumu daha yüksek genliğe sahiptir.

Tutucu üs tahminleri (h), 1'e 11 skaler vektörü olarak döndürülür. Tutucu üsler, sinyal düzenliliğini karakterize eder. Bir Holder üssü 1'e ne kadar yakınsa, fonksiyon türevlenebilir olmasına o kadar yakın olur. Tersine, Holder üssü sıfıra ne kadar yakınsa, fonksiyon süreksizliğe o kadar yakın olur (Jaffard, Lashermes ve Abry, 2006).

Normal kişiden alınan EEG sinyalleri analiz edilerek h tutucu üs tahminleri elde edilmiştir. Bu analizde chb01_01 veri setine ait grafik Şekil 3.9'da gösterilmiştir.


Şekil 3.10: Normal EEG Sinyaline Ait Tutucu Üs Tahminleri (h) Grafiği (Chb01_01)



Şekil 3.10.'da x eksenini örnek numarasını ve y eksenini de genlik gösterir. Grafiği bir az açıklasak genlik 0,55 ile 0,6 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genlik 0,5 ile 0,55 değerleri arasında rakamı örnekleme numarasının 4 değerine denk gelmiştir. Genlik 0,2 ile 0,25 değerleri arasında rakamı örnekleme numarasının 10 değerine denk gelmiştir. Genliğin bitiş noktası 0,15 ile 0,2 değerleri arası örnekleme numarasının 11 değerine denk gelmiştir.

Daha sonra h Tutucu üs tahminleri epileptik kişiden alınan sinyalle yapılan analiz chb05_13 veri setini örnek olarak kullanılan veriye ait Şekil 3.10'da gösterilmiştir.

Şekil 3.11: Epileptik Kişiden Alınan Chb05_13 Veri Setinin Tutucu Üs Tahminleri (h) Grafiği



Şekil 3.11.'da x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik 0,65 ile 0,7 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genlik 0,65 değerinde örnekleme numarasının 2 değerine denk gelmiştir. Genlik 0,6 ile 0,65 değerleri arasında rakamı örnekleme numarasının 3 değerine denk gelmiştir. Genlik 0,55 ile 0,6 değerleri arasında örnekleme numarasının 4 değerine denk gelmiştir. Genlik 0,35 değerinde örnekleme numarasının 7 değerine denk gelmiştir. Genlik 0,3 değerinde örnekleme numarasının 8 değerine denk gelmiştir. Genlik 0,25 ile 0,3 değerleri arasında örnekleme numarasının 9 değerine denk gelmiştir. Genlik 0,25 değerinde örnekleme numarasının 10 değerine denk gelmiştir. Genlik bitiş noktası 0,2 ile 0,25 değerleri arası örnekleme numarasının 11 değerine denk gelmiştir.


Normal EEG sinyalinden analiz edilen Tutucu üs tahminleri (h) epileptik EEG sinyalden analiz edilen Tutucu üs tahminleri (h) grafiklerinin farkı şöyledir: normal kişiden alınan EEG sinyalinin Tutucu üs tahminleri (h) grafiğinde başlangıç genlik değerinin bitiş genlik değerinden yüksek değere sahiptir ve epileptik kişiden alınan EEG sinyalinin Tutucu üs tahminleri (h)'da aynı grafiktedir, ancak farkı normal kişiden alınan EEG sinyalinin Tutucu üs tahminleri (h) genlik epileptik kişiden alınan EEG sinyalinin Tutucu üs tahminleri (h)'dan küçük değere sahiptir.

Kümülantlar (cp), 1'e 3 skaler vektörü olarak döndürülür. Vektör, ölçeklendirme üslerinin ilk üç günlük birikimlerini içerir. İlk kümülant, ölçeklendirme üslerindeki

doğrusal davranışı karakterize eder. İkinci ve üçüncü kümülanlar, doğrusallıktan ayrılmayı karakterize eder (Wendt ve Abry, 2007).

Kümülanlara bakıldığında normal anda alınan sinyalle yapılan analiz chb01_01 veri setini örnek olarak kullanılan veriye ait Şekil 3.11’de gösterilmiştir.


Şekil 3.12: Normal EEG Sinyaline Ait Kümülan Grafiği (Chb01_01)



Şekil 3.12.’de x eksenı örnek numarasını ve y eksenı de genliyi gösterir. Grafiği bir az açıklasak genlik 0,4 ile 0,5 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genlik -0,1 ile 0 değerleri arasında örnekleme numarasının 2 değerine denk gelmiştir. Genliğin bitiş noktası -0,1 ile 0 değerleri arası örnekleme numarasının 3 değerine denk gelmiştir.

Daha sonra cp kümülanları epileptik kişiden alınan sinyalle yapılan analiz chb05_13 veri setini örnek olarak kullanılan veriye ait Şekil 3.12’de gösterilmiştir.


Şekil 3.13: Epileptik Kişiden Alınan Chb05_13 Veri Setinin Kümülanları (cp) Grafiği



Şekil 3.13.'de x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik 0,4 ile 0,5 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genlik -0,1 ile 0 değerleri arasında örnekleme numarasının 2 değerine denk gelmiştir. Genliğin bitiş noktası 0 ile 0,1 değerleri arası örnekleme numarasının 3 değerine denk gelmiştir. Normal EEG sinyalinin analiz edilen Kümülanları (cp) epileptik EEG sinyalden analiz edilen Kümülanları (cp) grafiklerinin farkı şöyledir: normal kişiden alınan EEG sinyalinin Kümülanları (cp) grafiğinde bitiş genlik değeri epileptik kişiden alınan EEG sinyalinin Kümülanları (cp)'dan küçük değere sahiptir.

Ölçeklendirme üsleri (τ), sütun vektörü olarak döndürülür. Üsler, -5 ile +5 arasındaki doğrusal aralıklı momentler içermektedir (Jaffard, Lashermes ve Abry, 2006). Önce τ Ölçeklendirme üsleri normal kişiden alınan sinyalle yapılan analiz chb01_01 veri setini örnek olarak kullanılan veriye ait Şekil 3.13'te gösterilmiştir.


Şekil 3.14: Normal EEG Sinyaline Ait Ölçeklendirme Üs Grafiği (Chb01_01)



Şekil 3.14.'de x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik -3 ile -2,5 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genliğin bitiş noktası 1,5 ile 2 değerleri arası örnekleme numarasının 11 değerine denk gelmiştir.

Daha sonra τ Ölçeklendirme üsleri epileptik kişiden alınan sinyalle yapılan analiz chb05_13 veri setini örnek olarak kullanılan veriye ait Şekil 3.14'te gösterilmiştir.

Şekil 3.15: Epileptik Kişiden Alınan Chb05_13 Veri Setinin Ölçeklendirme Üsleri (τ_{uq}) Grafiği



Şekil 3.15.'de x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik -3 ile -2,5 değerleri arasında başlarken örnekleme numarasının 1 değerine denk gelmiştir. Genliğin bitiş noktası 1,5 değerinde örnekleme numarasının 11 değerine denk gelmiştir.

Normal EEG sinyalinin analiz edilen Ölçeklendirme üsleri (τ_{uq}) epileptik EEG sinyalinin analiz edilen Ölçeklendirme üsleri (τ_{uq}) grafiklerinin farkı şöyledir: normal kişiden alınan EEG sinyalinin Ölçeklendirme üsleri (τ_{uq}) grafiğinde bitiş genlik değeri epileptik kişiden alınan EEG sinyalinin Ölçeklendirme üsleri (τ_{uq})'dan azca büyük değere sahiptir.

3.3.2. Spektral Analiz

ZF sinyal işleme, doğru temsil ve durağan olmayan sinyallerin verimli analizi ve işlenmesi ihtiyacı nedeniyle ortaya çıkar (Boashash ve Ouelha, 2018). Durağan olmayan sinyaller çok yaygın doğal fenomenlerdir (Varanis, vd., 2021). Fourier dönüşümü gibi durağanlık kabul eden geleneksel yöntemlerle analiz için uygun olmamalarını sağlayan zamanla değişen frekans içerikleri ile karakterize edilirler (Galadí, vd., 2021). ZF sinyal işleme, ortak ZF alanındaki sinyalleri göstermek amacıyla Tek Bileşenli Sinyaller (TBS) kullanır. Bu sayede sinyalleri zaman bazında spektral değişimleri gözlenir (Feng, vd., 2020).

Tek bileşenli sinyaller için, TBS'in sabit zamanlı kesitlerinin tepe noktaları ve birinci dereceden momenti, sinyalin AF yasasının tahminlerini verir (Straub, vd., 2020). Çok bileşenli bir sinyal için çok AF ile çalışılmaktadır (Shi, vd., 2022). Bu tür sinyalleri karakterize etmek için, her sinyal bileşenine bir AF kuralı atanır (Bruni, Tartaglione ve Vitulano, 2020). Çok bileşenli sinyaller için çeşitli AF tahmin yaklaşımları önerilmiştir (Amin, Zhang ve Himed, 2019). Sinyal bileşenlerini ZF temsilinden lokalize etmek ve AF tahmin prosedürünü gerçekleştirmek olar (Khan ve Ali, 2020). Yöntemler, bileşenlerinin ZF alanında ayrılması dışında, analiz edilen sinyal hakkında önceden bilgi gerektirmeme avantajına sahiptir (Vranković, Lerga ve Saulig, 2020), bu durum genellikle yeni doğan EEG sinyalleri tarafından karşılanır (Alkhachroum, vd., 2022).

Bir spektrogram, frekans analizine bir zaman boyutu getirerek durağan olmayan bir sinyaldeki frekansları tahmin etmek için kullanılır. Yöntemler sinyali kısa olarak böler (Varanis, vd., 2021). Zaman dilimleri ve sinyalin her segment içinde sabit olduğunu varsayılır. Daha sonra her segment için bir periodogram hesaplanır (Castro-Tirado, vd., 2021).

3.3.2.1. AF analizi

AF, frekans içeriğinin zamanla nasıl değiştiğini açıklayan durağan olmayan bir sinyalin anahtar parametresidir (Xin, Hao ve Li, 2019). Tek bileşenli bir analitik sinyal (Zhou, vd., 2022) Denklem 3.10'da gösterilmiştir.

$$z(t) = a(t) \cdot e^{j\varphi(t)} \quad (3.10)$$


Denklem 3.10'da $z(t)$ Tek Bileşenli Analitik Sinyal (TBAS), Anlık Genlik (AG) $a(t)$ ile sinyalin eksponensial değeri üzeri $j\varphi(t)$ çarpımına eşittir ve $\varphi(t)$ sinyalin anlık fazıdır (Sengupta ve Lande, 2020). AF hesaplamak için Denklem 3.11'de gösterilmiştir:

$$f_i(t) = \frac{1}{2\pi} \cdot \frac{d\varphi(t)}{dt} \quad (3.11)$$

Denklem 3.11'de $f_i(t)$ sinyalin AF'dır. Sinyalin ters periodunun yani frekansının $\frac{1}{2\pi}$ anlık fazının zamana göre değişiminin $\frac{d\varphi(t)}{dt}$ çarpımına eşittir.

Önce normal kişiden alınan sinyalden AF analiz yapılmıştır. Bu analiz için chb01_01 veri setini örnek olarak kullanılan veriye ait grafik Şekil 3.15.'de gösterilmiştir.


Şekil 3.16: Normal EEG Sinyaline Ait AF Grafiği (Chb01_01)



Şekil 3.16'da x eksenini örnek numarasını ve y eksenini de genliyi gösterir. Grafiği bir az açıklasak genlik 0 ile 5 değerleri arasında başlarken örnekleme numarasının 0 değerine denk gelmiştir. Genliğin bitiş noktası 5 değerinde örnekleme numarasının 250 ile 300 değerine denk gelmiştir. Grafik periodiktir, amplitüdları artıp azalan yöndedir. Örnek numarası 0:50:300, genlik 0:5:45 ardıcılığıyla artar.

Daha sonra epileptik kişiden alınan sinyalden AF analiz yapılmıştır. Bu analiz için chb05_13 veri setini örnek olarak kullanılan veriye ait grafik Şekil 3.16'da gösterilmiştir.

Şekil 3.17: Epileptik Kişiden Alınan Chb05_13 Veri Setinin AF Grafiği



Şekil 3.17’de x eksenini örnek numarasını ve y eksenini de genliği gösterir. Grafiği bir az açıklasak genlik 0 ile 5 değerleri arasında başlarken örnekleme numarasının 0 değerine denk gelmiştir. Genliğin bitiş noktası 0 ile 5 değerleri arasında örnekleme numarasının 250 ile 300 değerine denk gelmiştir. Grafik periodiktir, amplitüdleri artıp azalan yöndedir. Örnekleme numarası 0:50:300, genlik 0:5:45 ardıcılığıyla artar.

Normal EEG sinyalinin analiz edilen AF epileptik EEG sinyalinin analiz edilen AF grafiklerinin farkı şöyledir: normal kişiden alınan EEG sinyalinin AF grafiğinde bitiş genlik değeri epileptik kişiden alınan EEG sinyalinin AF’den azca büyük değere sahiptir.

3.3.2.2. Spektral Entropi

Sinyallerde spektral karmaşıklığını ölçen bir sisteme güç SE’si denilir (Patel ve Annavarapu, 2021). Belirsiz bir sistem için, sistemin durumları olarak rastgele bir değişken X varsayalım, X ’in değeri Denklem 3.12’de kullanılarak hesaplanır.

$$X = \{x_1, x_2, \dots, x_n\} \quad (3.12)$$

Denklem 3.12’de X – EEG sinyalinin değişkenidir, $x_1, x_2, \dots, x_n$ - EEG sinyalinin değişkeninin değerleridir.

Karşılık gelen olasılık

$$P = \{p_1, p_2, \dots, p_n\}, 0 \leq p_i \leq 1, i = 1, 2, \dots, n \quad (3.13)$$

Denklem 3.13’te karşılık gelen olasılık P eşittir karşılık gelen olasılığın değerlerine $p_1, p_2, \dots, p_n$. p_i 0, 1 ve arasındaki değerleri alıyor. i ’de karşılık gelen olasılığın indeks değeridir, 1’den belirlenen maksimum artı değerleri almaktadır.

$$\sum_{i=1}^n p_i = 1 \quad (3.14)$$

Denklem 3.14’te toplam karşılık gelen olasılık değeri 1’den n kadar toplam sayıları alır.

Bu nedenle, sistemin bilgi entropisi şu şekilde ifade edilebilir

$$H = - \sum_{i=1}^n p_i \ln p_i \quad (3.15)$$

Denklem 3.15’te, H , sistemin bilgi entropisidir eşittir eksi toplamda kısıtlamalar altında olan olasılığa karşılık gelen ve olasılığın logaritmik değerine karşılık gelen p_i ile

çarpılır. Denklem 3.14'te gördüğümüz gibi toplam kısıtlamalar altında olan değere karşılık gelen olasılık değeri olarak bir alınır.

Shannon tarafından belirlenen düzensiz ölçüde hesaplayıp sonuca varan entropi değerine Shannon SE denir. SE, bir sinyalin frekans alanında normalleştirilmiş dağıtım gücü ile bir olasılık dağılımı olarak çalışır. Bir sinyal için SE'nin matematiksel açıklaması, güç spektrumu ve olasılık dağılım denklemlerinden türetilebilir. Bir sinyal $g(m)$ için, sinyal güç spektrumu şu şekilde ifade edilir: $P_s(m)$. Nerede, $P_s(m) = |g(m)|^2$. Olasılık dağılımı, $P_d(m)$ aşağıdaki denklemde verilmiştir.

$$P_d(m) = \frac{P_s(m)}{\sum_i P_s(i)} \quad (3.16)$$

Denklem 3.16'da m herhangi bir anlık dizi i değeridir. Olasılık dağılımı $P_d(m)$ sinyalin güç spektrumunun $P_s(m)$ toplam güç spektrumunun i değerine $\sum_i P_s(i)$ bölünmesiyle hesaplamak olur. SE, Denklem 3.17'de gösterilmiştir.

$$S_E = - \sum_{m=1}^N P_d(m) \log_2 P_d(m) \quad (3.17)$$

Denklem 3.17'de eksi toplamda herhangi bir anlık dizinin $m=1$ değerinden başlar. Frekans noktaları N sayısının değerlerine kadar toplam işlemi gider. $-\sum_{m=1}^N$ Olasılık dağılımının logaritmik değerin olasılık dağılımının çarpımına eşitliye SE formüle göre tanımıdır.

Denklem (3.17) normalleştirdikten sonra, aşağıdaki denklem (3.18) elde edilir,

$$S_{E_n} = - \frac{\sum_{m=1}^N P_d(m) \log_2 P_d(m)}{\log_2 N} \quad (3.18)$$

Denklem 3.18'de Denklem 3.17'i $\log_2 N$, frekans alanı üzerinde düzgün dağılımlı beyaz gürültünün maksimum SE'ne böldükte SE'in normalleşmiş haline gelir.


Denklem 3.18'de N frekans noktaları, $\log_2 N$, frekans alanı üzerinde düzgün dağılımlı beyaz gürültünün maksimum SE'dir. Anlık bir süre için SE aşağıdaki Denklem (3.19) gibi hesaplanır.

$$S_E(t) = - \sum_{m=1}^N P_d(t, m) \log_2 P_d(t, m) \quad (3.19)$$

Denklem 3.19’da eksi toplamda herhangi bir anlık dizinin $m=1$ değerinden başlar frekans noktaları N sayısının değerlerine kadar toplam işlemi gider $-\sum_{m=1}^N$ anlık bir sürede olasılık dağılımının logaritmik değerini anlık bir sürede olasılık dağılımının çarpımına eşitliye anlık sürede SE’in Denkleme göre tanımıdır (Patel ve Annavarapu, 2021).

SE (pa) normal kişiden alınan sinyalle yapılan analiz chb01_01 veri setini örnek olarak kullanılan veriye ait şekil 3.17’de gösterilmiştir.


Şekil 3.18. Normal EEG Sinyaline Ait Spektral Entropi Grafiği (Chb01_01)



Şekil 3.18’de x eksenini örnek numarasını ve y eksenini de genliği gösterir. Grafiği bir az açıklasak genlik 0,45 ile 0,5 değerleri arasında başlarken örnekleme numarasının 0 değerine denk gelmiştir. Genliğin bitiş noktası 0,6 ile 0,65 değerleri arasında örnekleme numarasının 250 ile 300 değerine denk gelmiştir. Grafik periodiktir, amplitüdü artıp azalan yöndedir. Örnek numarası 0:50:300, genlik sayılarda 0,45:0,05:0,9 aralığıysan artar.

SE (pa) epileptik kişiden alınan sinyalle yapılan analiz Chb05_13 veri setini örnek olarak kullanılan veriye ait şekil 3.18’de gösterilmiştir.

Şekil 3.19: Epileptik Kişiden Alınan Chb05_13 Veri Setinin SE (pa) Grafiği




Şekil 3.19’da x eksenı örnek numarasını ve y eksenı de genliyi gösterir. Grafiği bir az açıklasak genlik 0,6 ile 0,65 değeri arasında başlarken örnekleme numarasının 0 değerine denk gelmiştir. Genliğin bitiş noktası 0,5 ile 0,55 değeri arasında örnekleme numarasının 250 ile 300 değerine denk gelmiştir. Grafik periodiktir, amplitüdları artıp azalan yöndedir. Örnek numarası 0:50:300, genlik sayılarda 0,45:0,05:0,9 olarak artar.

Normal ana ait EEG sinyalinde analiz edilen SE (pa) epileptik EEG sinyalinde analiz edilen SE (pa) grafiklerinin farkı şöyledir: normal kişiden alınan EEG sinyalinin SE (pa) grafiğinde başlangıç ve bitiş genlik değeri epileptik kişiden alınan EEG sinyalinin SE (pa)’dan azca küçük değere sahiptir.

3.4. UZUN-KISA SÜRELİ HAFIZA DERİN ÖĞRENME MODELİ

UKSHDÖM verilerin yapılarının (kalıplarının) tanınmasından ve daha sonra analiz edilmesinden elde edilen bilgileri depolar. UKSHDÖM, bir DÖ algoritması olan Tekrarlayan Sinir Ağına (TSA) dayanmaktadır. TSA, aktivasyon enerjisi yerel olarak besleyen ve tekrarlayan yapılardan oluşur, bu nedenle önceki çıktıları depolamak için harici kayıtlara veya belleklere ihtiyaç yoktur. TSA’da kullanılan tekrarlayan yapılar nedeniyle UKSHDÖM’de hesaplama karmaşıklığı düşüktür. UKSHDÖM iç yapısı (Şekil 3.20’de) gösterilmiştir (Smagulova ve James, 2019).

Şekil 3.20: ÇYUKSHDÖM İç Yapısı



Kaynak: Tosun ve Çetin, 2022.

UKSHDÖM blok teorisinde, çarpma “*” gereksiz içeriğin unutulmasına, toplama “+” ise yeni bir şeyin hatırlanmasını ifade eder. Veri dizileri önemli ve yeni bir şeyle karşılaştıysa, bu uzun vadeli içeriğe (C_t) eklenmelidir.

UKSHDÖM ağı 3 kapıdan oluşur. Bunlar unutma kapısı, girdi kapısı ve çıktı kapısıdır. Unutma kapısı hücre durumundan hangi bilgilerin atılabileceğini belirlemektir. Bu kapı yalnız sigmoidal katmandan (σ) oluşur. Başlangıçta, özyinelemenin mevcut adımındaki X_t giriş değeri, bloğun önceki gizli durumu ile birleştirilir ve sinir ağının sigmoidal tam bağlı katmanının girişine beslenir. Çıktıda bu f_t değeri, C_{t-1} vektörünün boyutuna eşit boyutta oluşturulur. Ayrıca f_t , 0 ile 1 aralığındaki elemanlardan oluşur (Tiwari, vd., 2023). f_t Denklem 3.20’de ile hesaplanır.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.20)$$

Denklem 3.20’de tam bağlı bir sigmoid katmanın girişinde ilk başta böyle bir ortak vektör $[h_{t-1}, x_t]$ oluşturulduğunu görüyoruz, daha sonra W_f ağırlık katsayıları ile çarpılıyor, ardından bias ofset b_f ekleniyor, ancak tüm bunlar sigmoid işlevinden geçirilir. Çıktıda f_t vektörü alınır. Yani f_t vektörü hangi bilgileri saklanacağını ve unutulacağını gösteriyor. Bu onun eğitimi sırasında belirlenir. Yani, öğrenme sürecinde ağırlık katsayıları, ağırlık ortalaması olarak uzun vadeli içerik vektörünün gereksiz değerlerini doğru bir şekilde zayıflatması ve ihtiyaç duyulana bırakması için seçilir (Khalil, vd., 2019).

Girdi kapısı, hücrenin durumunda hangi yeni bilgilerin saklanacağına karar vermektedir. Bu kapı iki katmandan oluşmaktadır. Bunlar, sigmoidal ve tanh katmanlarıdır. Burada ayrıca, daha önce elementel ekleme işlemi de kullanılmaktadır. Çarpmadan eklemeye giden vektör, iki miktar temelinde oluşturulur, bunlar i_t ve $\tilde{C}'_{t-1}$ dir. Aşağıdaki denklemlerde i_t ve $\tilde{C}_t$ – nin hesaplama formülleri gösterilmiştir.

$$i_t = \sigma (W_p \cdot [h_{t-1}, x_t] + b_i) \quad (3.21)$$

$$\tilde{C}_t = \tanh (W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3.22)$$

Denklem 3.21 ve 3.22'ü şöyle anlatabiliriz: Sigmoid ve tanh katmanlarının denklemlerde gördüğümüz gibi böyle ortak vektörü $[h_{t-1}, x_t]$ oluşur. Sonra sigmoid katmanından W_p ve tanh katmanından W_C ağırlık katsayıları ile çarpılıyor, ardından sigmoid katmanında bias offset b_i tanh katmanında b_C ekleniyor, ancak tüm bunlar hem sigmoid hem de tanh katmanlarından geçiriliyor. Çıkışta sigmoid katmanından i_t ve tanh katmanından $\tilde{C}_t$ vektörleri alınır (Smagulova ve James, 2019).

Çıktı kapısı, çıktı olarak hangi bilgileri almak istediğimize karar vermemiz gerekiyor. Çıktı kapısı iki katmandan oluşur: Sigmoid ve tanh. Çıktı, hücre durumumuza dayalı olmaktadır ve buna bazı filtreler uygulanmaktadır. İlk olarak, hücre durumundan hangi bilgileri çıkaracağımıza karar veren bir sigmoid katman uygulanır. Hücre durum değerleri daha sonra -1 ile 1 aralığında çıktı değerleri üretmek için tanh katmanından geçirilir ve sadece gerekli bilgileri çıktılamak için sigmoid katmanının çıktı değerleri ile çarpılır.

$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o) \quad (3.23)$$

Denklem 3.23'te tam bağlı bir sigmoid katmanın girişinde ilk başta böyle bir ortak vektör $[h_{t-1}, x_t]$ oluşturulduğunu görüyoruz, daha sonra W_o ağırlık katsayıları ile çarpılıyor, ardından bias offset b_o ekleniyor, ancak tüm bunlar sigmoid işlevinden geçirilir. Çıktıda o_t vektörü alınır. Yani o_t vektörü hangi bilgileri almak istediğimizi gösteriyor.

$$h_t = o_t * \tanh (C_t) \quad (3.24)$$

Denklem 3.24'te çıktı değeri h_t sigmoid katmanının çıktı değerinin o_t tanh katmanının C_t çıktı değerinin çarpımıdır (Siarni-Namini, Tavakoli ve Namin, 2019).

3.5. DENEYLERİN DOĞRULANMASI

Tez çalışmasında, deneyler UKSHDÖM ile sınıflandırılmıştır. Bu sınıflandırma ile veri setinin yüzde (%) kaç başarı kazandığını gördük. Bundan ziyade, karşılık matrisi ile Doğruluk, Özgüllük, Hassasiyet, YPO, Duyarlılık, NTD, F1-puanı, MKK, YNO, YKO metrikleri hesaplanmıştır.

Eğitim ve testin başarısı karmaşıklık matrisi ile performansları belirlenmiştir. Analizler ne kadar düzenli şekilde yapılırsa karmaşıklık matrisi de o kadar başarılı olur.

Karmaşıklık matrisi Tablo 3.5’te gösterilmiştir.

Tablo 3.5: Karmaşıklık Matrisi Tahmini

		Tahmini sınıf	
		E	N
Gerçek sınıf	E	TP	FP
	N	FN	TN

Doğruluk: Doğru tahmin sayısının toplam veri sayısına oranıdır (Mangalathu, vd., 2020).

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FN+FP} \quad (3.25)$$

Denklem 3.25’te TP- doğru bir bilgiyi doğru kabul etmek, TN – yanlış bir bilgiyi yanlış kabul etmek, FN – yanlış bir bilgiyi doğru kabul etmek, FP – doğru bir bilgiyi yanlış kabul etmek anlamına geliyorlar.

Özgüllük: Toplam negatif sayısına bölünen doğru negatif tahminlerin sayısı olarak hesaplanır (Balaanand, vd., 2019).

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3.26)$$

Hassasiyet: Pozitif toplam tahmin sayısının doğru pozitif tahminlere oranıdır (Maragkakis, vd., 2009). Hassasiyet, Denklem 3.27 ile hesaplanır.

$$Hassasiyet = \frac{TP}{TP+FP} \quad (3.27)$$

YPO: Toplam negatif sayısına bölünen hatalı pozitif tahminlerin sayısı olarak hesaplanır (Dankers, vd., 2019). YPO, Denklem 3.28 ile hesaplanır.

$$YPO = \frac{FP}{TN+FP} \quad (3.28)$$

Duyarlılık: Pozitif toplam sayının pozitif doğru tahminlere oranıdır (Tomašev, vd., 2019). Duyarlılık, Denklem 3.29 ile hesaplanır.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.29)$$

NTD: Toplam negatif tahmin sayısına bölünen doğru negatif tahminlerin sayısına olarak hesaplanır (Guastavino, vd., 2022). NTD, Denklem 3.30 ile hesaplanır.

$$NTD = \frac{TN}{TN+FN} \quad (3.30)$$

F1-puanı: Kesinlik ve hatırlamanın harmonik bir ortalamasıdır (Miao ve Zhu, 2022). F1 puanı, Denklem 3.31 ile hesaplanır.

$$F1 - puanı = \frac{2TP}{2TP+FP+FN} \quad (3.31)$$

MKK: Karışıklık matrisindeki dört değerin tümü kullanılarak hesaplanan bir korelasyon katsayısıdır (Alotaibi, vd., 2022). MKK, Denklem 3.32 ile hesaplanır.

$$MKK = \frac{TP*TN-FP*FN}{\sqrt{(TP+FP)*(TP+FN)*(TN+FP)*(TN+FN)}} \quad (3.32)$$

YNO: Toplam negatif sayısına bölünen yanlış negatif tahminlerin sayısı olarak hesaplanır (Bhaduri, vd., 2022). YNO, Denklem 3.33 ile hesaplanır.

$$YNO = \frac{FN}{FN+TP} \quad (3.33)$$

YKO: Pozitif toplam tahmin sayısının yanlış pozitif tahmin sayısına oranıdır (Habiger ve Liang, 2022). YKO, Denklem 3.34 ile hesaplanır.

$$YKO = \frac{FP}{FP+TP} \quad (3.34)$$

Denklem 3.34’te TP- doğru bir bilgiyi doğru kabul etmek, TN – yanlış bir bilgiyi yanlış kabul etmek, FN – yanlış bir bilgiyi doğru kabul etmek, FP – doğru bir bilgiyi yanlış kabul etmek anlamına geliyorlar.






DÖRDÜNCÜ BÖLÜM
BULGULAR VE DENEYSEL ÇALIŞMALAR


Hazırladığımız bu tezde EEG sinyallerini gruplandırmak amacıyla normal ve epileptik olarak 2 çeşit gruba ayırmak için deneyler yapılmıştır. Şekil 4.1’de normal chb01_01 EEG sinyali 2’nci kanaldan alınmıştır ve Şekil 4.2’de epileptik chb05_13 EEG sinyali 7’nci kanaldan alınmıştır.

Şekil 4.1: Normal Chb01_01 EEG Sinyali



Şekil 4.1’de CHB-MIT Scalp veri setinden alınan CHB01_01 olarak etiketlenen bireyden alınan 10 saniyelik EEG sinyal bölütlemesi gösterilmiştir. Sinyal ilgili kişinin epilepsi nöbeti geçirilmediği döneme aittir. Bu tez çalışmasında yapılan deneylerde bu sinyaller “normal” olarak etiketlendi.

Şekil 4.2: Epileptik Chb05_13 EEG Sinyali



Şekil 4.2’de gösterilen epileptik EEG sinyali elektrik aktivasyonu bozulmaya uğrayarak hareket etmiştir.

4.1. YAPILAN DENEYLER

Çalıştığımız tezimizde yapılan deney sayısı 22'dir. Bu deneylerde kullanılan ÇYUKSHDÖM yapay zekâ algoritmasında hiperparametreler MaxEpochs=150, MiniBatchSize=384, InitialLearnRate=0,01, SequenceLength=1000, GradientThreshold=1 olarak ayarlanmıştır.

1. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır. Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %85,29'luk başarı sağlanmıştır.

Tablo 4.1: Birinci Deneydeki Karışıklık Matrisi

	E	N
E	29	4
N	6	29

Birinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.1'de verilmiştir. Tablodaki 4.1'deki 33 epileptik EEG sinyalinden 29'u epileptik gruba konulmuştur. 35 normal kişiden 29'u normal gruba konulabilmiştir. Karışıklık matrisinden elde edilen değerler kullanılarak sırasıyla Doğruluk, Özgüllük, Hassasiyet, YPO, Duyarlılık, NTD, F1-puanı, MKK, YNO, YKO hesaplanmıştır. Hesaplanan bu metrikler Tablo 4.2'de sunulmuştur.

Tablo 4.2: Birinci Deneyin Metrikleri

Metrikler	Değerler
Doğruluk	%85,29
Özgüllük	%87,88
Hassasiyet	%87,88
YPO	%12,12
YPO	%12,12

Tablo 4.2 (devam): Birinci Deneyin Metrikleri

Metrikler	Değerler
Duyarlılık	%82,86
NTD	%82,86
F1-puanı	%85,29
MKK	%70,74
YNO	%17,14

Tablo 4.2'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %85,29 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %12,12 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %17,14 olarak ölçüldü. Hassasiyet ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %85,29 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %70,74 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %17,14 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %12,12 olarak ölçüldü.

2. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %61,76'lık başarı sağlanmıştır.

Tablo 4.3: İkinci Deneydeki Karışıklık Matrisi

	E	N
E	16	17
N	9	26

İkinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.3'te verilmiştir. Tablodaki 4.3'teki 33 epileptik EEG sinyalinden 16'ı epileptik gruba konulmuştur. 35 normal kişiden 26'ı normal gruba konulabilmiştir. Karışıklık matrisinden elde edilen değerler kullanılarak sırasıyla Doğruluk, Özgüllük, Hassasiyet, YPO, Duyarlılık, NTD, F1-puanı, MKK, YNO, YKO hesaplanmıştır. Hesaplanan bu metrikler Tablo 4.4'te sunulmuştur.

Tablo 4.4: İkinci Deneyin Metrikleri

Metrikler	Değerler
Doğruluk	%61,76
Özgüllük	%60,47
Hassasiyet	%48,48
YPO	%39,53
Duyarlılık	%64
NTD	%36
F1-puanı	%55,17
MKK	%23,6
YNO	%36
YKO	%51,52

Tablo 4.4'teki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %61,76 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %60,47 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %48,48 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %39,53 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %64 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %36 olarak ölçüldü. Hassasiyet ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %55,17 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %23,6 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %36 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %51,52 olarak ölçüldü.

3. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %80,88'lık başarı sağlanmıştır.

Tablo 4.5: Üçüncü Deneydeki Karışıklık Matrisi

	E	N
E	25	8
N	5	30

Üçüncü deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.5'te verilmiştir. Tablodaki 4.5'teki 33 epileptik EEG sinyalinden 25'i epileptik gruba konulmuştur. 35 normal kişiden 30'u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.6'daki değerler elde edilmiştir.

Tablo 4.6: Üçüncü Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%80,88
Özgüllük	%78,95
Hassasiyet	%75,76
YPO	%21,05
Duyarlılık	%83,33
NTD	%85,71
F1-puanı	%79,37
MKK	%61,87
YNO	%16,67
YKO	%24,24

Tablo 4.6'daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %80,88 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %78,95 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %75,76 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %21,05 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %83,33 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %85,71 olarak ölçüldü. Hassasiyet ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %79,37 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %61,87 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %16,67 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %24,24 olarak ölçüldü.

4. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %75'lik başarı sağlanmıştır.

Tablo 4.7: Dördüncü Deneydeki Karışıklık Matrisi

	E	N
E	29	4
N	13	22

Dördüncü deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.7'de verilmiştir. Tablodaki 4.7'deki 33 epileptik EEG sinyalinden 29'u epileptik gruba konulmuştur. 35 normal kişiden 22'si normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.8'deki değerler elde edilmiştir.

Tablo 4.8: Dördüncü Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%75
Özgüllük	%84,62
Hassasiyet	%87,88
YPO	%15,38
Duyarlılık	%69,05
NTD	%62,86
F1-puanı	%77,33
MKK	%52,18

Tablo 4.8 (devam): Dördüncü Deneyin Metrikleri

Metrikler	Değerleri
YNO	%30,95
YKO	%12,12

Tablo 4.8'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %75 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %84,62 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %15,38 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %69,05 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %62,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %77,33 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %52,18 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %30,95 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %12,12 olarak ölçüldü.

5. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %79,41'lık başarı sağlanmıştır.

Tablo 4.9: Beşinci Deneydeki Karışıklık Matrisi

	E	N
E	25	8
N	6	29

Beşinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.9’da verilmiştir. Tablodaki 4.9’daki 33 epileptik EEG sinyalinin 25’i epileptik gruba konulmuştur. 35 normal kişiden 29’u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.10’daki değerler elde edilmiştir.

Tablo 4.10: Beşinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%79,41
Özgüllük	%78,38
Hassasiyet	%75,76
YPO	%21,62
Duyarlılık	%80,65
NTD	%82,86
F1-puanı	%78,13
MKK	%58,82
YNO	%19,35
YKO	%24,24

Tablo 4.10’daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %79,41 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %78,38 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %75,76 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %21,62 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %80,65 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-

puanı: %78,13 olarak görüldü. Karışıklık matrisindeki dört değerin tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %58,82 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %19,35 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %24,24 olarak ölçüldü.

6. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %58,82'lik başarı sağlanmıştır.

Tablo 4.11: Altıncı Deneydeki Karışıklık Matrisi

	E	N
E	22	11
N	17	18

Altıncı deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.11'de verilmiştir. Tablodaki 4.9'daki 33 epileptik EEG sinyalinden 22'si epileptik gruba konulmuştur. 35 normal kişiden 18'i normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.10'daki değerler elde edilmiştir.

Tablo 4.12: Altıncı Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%58,82
Özgüllük	%62,07
Hassasiyet	%66,67
YPO	%37,93
Duyarlılık	%56,41
NTD	%51,43

Tablo 4.12 (devam): Altıncı Deneyin Metrikleri

Metrikler	Değerleri
F1-puanı	%61,11
MKK	%18,29
YNO	%43,59
YKO	%33,33

Tablo 4.12'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %58,82 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %84,62 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %15,38 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %69,05 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %62,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %61,11 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %18,29 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %30,95 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %12,12 olarak ölçüldü.

7. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %80,88'lik başarı sağlanmıştır.

Tablo 4.13: Yedinci Deneydeki Karışıklık Matrisi

	E	N
E	26	7
N	6	29

Yedinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.13'te verilmiştir. Tablodaki 4.9'daki 33 epileptik EEG sinyalinden 26'sı epileptik gruba konulmuştur. 35 normal kişiden 29'u normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.14'teki değerler elde edilmiştir.

Tablo 4.14: Yedinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%80,88
Özgüllük	%80,56
Hassasiyet	%78,79
YPO	%19,44
Duyarlılık	%81,25
NTD	%82,86
F1-puanı	%80
MKK	%61,73
YNO	%18,75
YKO	%21,21

Tablo 4.14'teki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %80,88 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %80,56 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %78,79 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %19,44 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %81,25 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %80 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %61,73 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %18,75 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %21,21 olarak ölçüldü.

8. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %70,59'luk başarı sağlanmıştır.

Tablo 4.15: Sekizinci Deneydeki Karışıklık Matrisi

	E	N
E	24	9
N	11	24

Sekizinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.9'da verilmiştir. Tablodaki 4.15'teki 33 epileptik EEG sinyalinden 24'ü epileptik gruba konulmuştur. 35 normal kişiden 24'ü normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.16'daki değerler elde edilmiştir.

Tablo 4.16: Sekizinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%70,59
Özgüllük	%72,73
Hassasiyet	%72,73
YPO	%27,27
Duyarlılık	%68,57
NTD	%68,57
F1-puanı	%70,59
MKK	%41,30
YNO	%31,43
YKO	%27,27

Tablo 4.16'daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %70,59 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %72,73 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %72,73 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %27,27 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %68,57 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %68,57 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %70,59 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan MKK: %41,3 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %31,43 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %27,27 olarak ölçüldü.

9. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %82,35’lik başarı sağlanmıştır.

Tablo 4.17: Dokuzuncu Deneydeki Karışıklık Matrisi

	E	N
E	26	7
N	5	30

Dokuzuncu deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.17’da verilmiştir. Tablodaki 4.17’deki 33 epileptik EEG sinyalinden 26’ı epileptik gruba konulmuştur. 35 normal kişiden 30’u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.18’deki değerler elde edilmiştir.

Tablo 4.18: Dokuzuncu Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%82,35
Özgüllük	%81,08
Hassasiyet	%78,79
YPO	%18,92
Duyarlılık	%83,87
NTD	%85,71
F1-puanı	%81,25
MKK	%64,73

Tablo 4.18 (devam): Dokuzuncu Deneyin Metrikleri

Metrikler	Değerleri
YNO	%16,13
YKO	%21,21

Tablo 4.18'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %82,35 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %81,08 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %78,79 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %18,92 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %83,87 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %85,71 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %81,25 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %64,73 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %16,13 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %21,21 olarak ölçüldü.

10. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %77,94'lük başarı sağlanmıştır.

Tablo 4.19: Onuncu Deneydeki Karışıklık Matrisi

	E	N
E	27	6
N	9	26

Onuncu deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.19’da verilmiştir. Tablodaki 4.19’daki 33 epileptik EEG sinyalinden 27’i epileptik gruba konulmuştur. 35 normal kişiden 26’ı normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.20’deki değerler elde edilmiştir.

Tablo 4.20: Onuncu Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%77,94
Özgüllük	%81,25
Hassasiyet	%81,82
YPO	%18,75
Duyarlılık	%75
NTD	%74,29
F1-puanı	%78,26
MKK	%56,18
YNO	%25
YKO	%18,18

Tablo 4.20’deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %77,94 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %81,25 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %81,82 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %18,75 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %75 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer

%74,29 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %78,26 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %56,18 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %25 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %18,18 olarak ölçüldü.

11. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %64,71'lik başarı sağlanmıştır.

Tablo 4.21: On birinci Deneydeki Karışıklık Matrisi

	E	N
E	20	13
N	11	24

On birinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.21'de verilmiştir. Tablodaki 4.21'deki 33 epileptik EEG sinyalinden 20'i epileptik gruba konulmuştur. 35 normal kişiden 24'ü normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.22'deki değerler elde edilmiştir.

Tablo 4.22: On birinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%64,71
Özgüllük	%64,86
Hassasiyet	%60,61
YPO	%35,14
Duyarlılık	%64,52

Tablo 4.22 (devam): On birinci Deneyin Metrikleri

Metrikler	Değerleri
NTD	%68,57
F1-puanı	%62,50
Matthews Korelasyon Katsayısı	%29,28
YNO	%35,48
YKO	%39,39

Tablo 4.22'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %64,71 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %64,86 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %60,61 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %35,14 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %64,52 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %68,57 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %62,50 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %29,28 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %35,48 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %39,39 olarak ölçüldü.

12. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %69,12'lik başarı sağlanmıştır.

Tablo 4.23: On İkinci Deneydeki Karışıklık Matrisi

	E	N
E	31	2
N	19	16

On ikinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.9’da verilmiştir. Tablodaki 4.23’teki 33 epileptik EEG sinyalinin 31’i epileptik gruba konulmuştur. 35 normal kişiden 16’ı normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.24’teki değerler elde edilmiştir.

Tablo 4.24: On ikinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%69,12
Özgüllük	%88,89
Hassasiyet	%93,94
YPO	%11,11
Duyarlılık	%62
NTD	%45,71
F1-puanı	%74,70
Matthews Korelasyon Katsayısı	%44,92
YNO	%38
YKO	%6,06

Tablo 4.24’teki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %69,12 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif

tahminlerin oranıdır. Hesaplanan değer %88,89 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %93,94 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %11,11 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %62 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %45,71 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %74,7 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %44,92 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %38 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %6,06 olarak ölçüldü.

13. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %60,29'luk başarı sağlanmıştır.

Tablo 4.25: On üçüncü Deneydeki Karışıklık Matrisi

	E	N
E	13	20
N	7	28

On üçüncü deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.25'te verilmiştir. Tablodaki 4.9'daki 33 epileptik EEG sinyalinden 13'ü epileptik gruba konulmuştur. 35 normal kişiden 28'i normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.26'daki değerler elde edilmiştir.

Tablo 4.26: On Üçüncü Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%60,29
Özgüllük	%58,33
Hassasiyet	%39,39
YPO	%41,67
Duyarlılık	%65
NTD	%80
F1-puanı	%49,06
Matthews Korelasyon Katsayısı	%21,27
YNO	%35
YKO	%60,61

Tablo 4.26'daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %60,29 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %58,33 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %39,39 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %41,67 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %65 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %80 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %49,06 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %21,27 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %35 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %60,61 olarak ölçüldü.

14. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %66,18’lik başarı sağlanmıştır.

Tablo 4.27: On Dördüncü Deneydeki Karışıklık Matrisi

	E	N
E	16	17
N	6	29

On dördüncü deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.27’de verilmiştir. Tablodaki 4.27’deki 33 epileptik EEG sinyalinden 16’ı epileptik gruba konulmuştur. 35 normal kişiden 29’u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.28’deki değerler elde edilmiştir.

Tablo 4.28: On dördüncü Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%66,18
Özgüllük	%63,04
Hassasiyet	%48,48
YPO	%36,96
Duyarlılık	%72,73
NTD	%82,86
F1-puanı	%58,18
Matthews Korelasyon Katsayısı	%33,48

Tablo 4.28 (devam): On dördüncü Deneyin Metrikleri

Metrikler	Değerleri
YNO	%27,27
YKO	%51,52

Tablo 4.28'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %66,18 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %63,04 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %48,48 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %36,96 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %72,73 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %58,18 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %33,48 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %27,27 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %51,52 olarak ölçüldü.

15. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %76,47'lik başarı sağlanmıştır.

Tablo 4.29: On Beşinci Deneydeki Karışıklık Matrisi

	E	N
E	24	9
N	7	28

On beşinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.29’da verilmiştir. Tablodaki 4.9’daki 33 epileptik EEG sinyalinden 24’ü epileptik gruba konulmuştur. 35 normal kişiden 28’i normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.30’daki değerler elde edilmiştir.

Tablo 4.30: On Beşinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%76,47
Özgüllük	%75,68
Hassasiyet	%72,73
YPO	%24,32
Duyarlılık	%77,42
NTD	%80
F1-puanı	%75
Matthews Korelasyon Katsayısı	%52,91
YNO	%22,58
YKO	%27,27

Tablo 4.30’daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %76,47 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %75,68 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %72,73 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %24,32 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %77,42 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan

değer %80 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %75 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %52,91 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %22,58 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %27,27 olarak ölçüldü.

16. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %73,53'lük başarı sağlanmıştır.

Tablo 4.31: On altıncı Deneydeki Karışıklık Matrisi

	E	N
E	29	4
N	14	21

On altıncı deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.31'de verilmiştir. Tablodaki 4.31'daki 33 epileptik EEG sinyalinden 29'u epileptik gruba konulmuştur. 35 normal kişiden 21'i normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.32'deki değerler elde edilmiştir.

Tablo 4.32: On Altıncı Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%73,53
Özgüllük	%84
Hassasiyet	%87,88
YPO	%16
Duyarlılık	%67,44

Tablo 4.32 (devam): On Altıncı Deneyin Metrikleri

Metrikler	Değerleri
NTD	%60
F1-puanı	%76,32
Matthews Korelasyon Katsayısı	%49,63
YNO	%32,56
YKO	%12,12

Tablo 4.32'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %73,53 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %84 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %16 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %67,44 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %60 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %76,32 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %49,63 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %32,56 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %12,12 olarak ölçüldü.

17. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %70,59'luk başarı sağlanmıştır.

Tablo 4.33: On yedinci Deneydeki Karışıklık Matrisi

	E	N
E	23	10
N	10	25

On yedinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.33’te verilmiştir. Tablodaki 4.33’teki 33 epileptik EEG sinyalinden 23’ü epileptik gruba konulmuştur. 35 normal kişiden 25’i normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.34’teki değerler elde edilmiştir.

Tablo 4.34: On Yedinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%70,59
Özgüllük	%71,43
Hassasiyet	%69,7
YPO	%28,57
Duyarlılık	%69,7
NTD	%71,43
F1-puanı	%69,7
Matthews Korelasyon Katsayısı	%41,13
YNO	%30,3
YKO	%30,3

Tablo 4.34'teki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %70,59 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %71,43 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %69,7 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %28,57 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %69,7 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %71,43 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %69,7 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %41,13 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %30,3 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %30,3 olarak ölçüldü.

18. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %85,29'luk başarı sağlanmıştır.

Tablo 4.35: On sekizinci Deneydeki Karışıklık Matrisi

	E	N
E	29	4
N	6	29

On sekizinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.35'te verilmiştir. Tablodaki 4.35'teki 33 epileptik EEG sinyalinden 29'u epileptik gruba konulmuştur. 35 normal kişiden 29'u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.36'daki değerler elde edilmiştir.

Tablo 4.36: On sekizinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%85,29
Özgüllük	%87,88
Hassasiyet	%87,88
YPO	%12,12
Duyarlılık	%82,86
NTD	%82,86
F1-puanı	%85,29
Matthews Korelasyon Katsayısı	%70,74
YNO	%17,14
YKO	%12,12

Tablo 4.36'daki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %85,29 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %87,88 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %12,12 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %85,29 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %70,74 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %17,14 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %12,12 olarak ölçüldü.

19. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %82,35’lik başarı sağlanmıştır.

Tablo 4.37: On dokuzuncu Deneydeki Karışıklık Matrisi

	E	N
E	27	6
N	6	29

On dokuzuncu deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.37’de verilmiştir. Tablodaki 4.37’deki 33 epileptik EEG sinyalinden 27’i epileptik gruba konulmuştur. 35 normal kişiden 29’u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.38’deki değerler elde edilmiştir.

Tablo 4.38: On Dokuzuncu Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%82,35
Özgüllük	%82,86
Hassasiyet	%81,82
YPO	%17,14
Duyarlılık	%81,82
NTD	%82,86
F1-puanı	%81,82
Matthews Korelasyon Katsayısı	%64,68

Tablo 4.38 (devam): On Dokuzuncu Deneyin Metrikleri

Metrikler	Değerleri
YNO	%18,18
YKO	%18,18

Tablo 4.38'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %82,35 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %81,82 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %17,14 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %81,82 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %81,82 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %64,68 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %18,18 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %18,18 olarak ölçüldü.

20. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %82,35'lik başarı sağlanmıştır.

Tablo 4.39: Yirminci Deneydeki Karışıklık Matrisi

	E	N
E	28	5
N	7	28

Yirminci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.39’da verilmiştir. Tablodaki 4.39’daki 33 epileptik EEG sinyalinin 28’i epileptik gruba konulmuştur. 35 normal kişiden 28’i normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.40’taki değerler elde edilmiştir.

Tablo 4.40: Yirminci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%82,35
Özgüllük	%84,85
Hassasiyet	%84,85
YPO	%15,15
Duyarlılık	%80
NTD	%80
F1-puanı	%82,35
Matthews Korelasyon Katsayısı	%64,85
YNO	%20
YKO	%15,15

Tablo 4.40’taki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %82,35 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %84,85 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %84,85 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %15,15 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %80 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer

%80 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %82,35 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %64,85 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %20 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %15,15 olarak ölçüldü.

21. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %83,82'lik başarı sağlanmıştır.

Tablo 4.41: Yirmi birinci Deneydeki Karışıklık Matrisi

	E	N
E	28	5
N	6	29

Yirmi birinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.41'de verilmiştir. Tablodaki 4.41'deki 33 epileptik EEG sinyalinden 28'i epileptik gruba konulmuştur. 35 normal kişiden 29'u normal gruba konulabilmiştir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.42'deki değerler elde edilmiştir.

Tablo 4.42: Yirmi birinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%83,82
Özgüllük	%85,29
Hassasiyet	%84,85
YPO	%14,71
Duyarlılık	%82,35

Tablo 4.42 (devam): Yirmi birinci Deneyin Metrikleri

Metrikler	Değerleri
NTD	%82,86
F1-puanı	%83,58
Matthews Korelasyon Katsayısı	%67,68
YNO	%17,65
YKO	%15,15

Tablo 4.42'deki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %83,82 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %85,29 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %84,85 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %14,71 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %82,35 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %82,86 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %83,58 olarak görüldü. Karışıklık matrisindeki dört değer tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %67,68 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %17,65 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %15,15 olarak ölçüldü.

22. Deney: Yaptığımız deneyde EEG sinyallerinde epileptik saptanmıştır.

Bu deney verilen değerlerle denenmiştir. ÇYUKSHDÖM ile yapılan epileptik gruplandırmasında %80,88'lik başarı sağlanmıştır.

Tablo 4.43: Yirmi ikinci Deneydeki Karışıklık Matrisi

	E	N
E	27	6
N	7	28

Yirmi ikinci deneyde yapılan gruplandırmada ortaya çıkan karışıklık matrisi verileri Tablo 4.43'te verilmiştir. Tablodaki 4.43'teki 33 epileptik EEG sinyalinden 27'i epileptik gruba konulmuştur. 35 normal kişiden 28'i normal gruba konulabilmektedir. Bu sonuçlar doğrultusunda elde edilen metrikler aynı sırayla Tablo 4.44'teki değerler elde edilmiştir.


Tablo 4.44: Yirmi İkinci Deneyin Metrikleri

Metrikler	Değerleri
Doğruluk	%80,88
Özgüllük	%82,35
Hassasiyet	%81,82
YPO	%17,65
Duyarlılık	%79,45
NTD	%80
F1-puanı	%80,6
Matthews Korelasyon Katsayısı	%61,79
YNO	%20,59
YKO	%18,18

Tablo 4.44'teki Doğruluk; doğru tahmin sayısının toplam veri sayısına oranıdır. Hesaplanan değer %80,88 olarak ölçüldü. Özgüllük; toplam negatif sayının, doğru negatif tahminlerin oranıdır. Hesaplanan değer %82,35 olarak ölçüldü. Hassasiyet; Toplam pozitif tahmin sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %81,82 olarak ölçüldü. YPO; toplam negatif sayının, bölünen hatalı pozitif tahminlerin oranıdır. Hesaplanan değer %17,65 olarak ölçüldü. Duyarlılık; toplam pozitif sayının, doğru pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %79,45 olarak ölçüldü. NTD; toplam negatif sayının, doğru negatif tahminlerin sayısına oranıdır. Hesaplanan değer %80 olarak ölçüldü. Kesinlik ve hatırlamanın harmonik bir ortalaması olan F1-puanı: %80,6 olarak görüldü. Karışıklık matrisindeki dört değerın tümü kullanılarak hesaplanan bir korelasyon katsayısı olan Matthews Korelasyon Katsayısı: %61,79 olarak görüldü. YNO; toplam negatif sayının, yanlış negatif tahminlerin sayısına oranıdır. Hesaplanan değer %20,59 olarak ölçüldü. YKO; toplam pozitif sayının, yanlış pozitif tahminlerin sayısına oranıdır. Hesaplanan değer %18,18 olarak ölçüldü.

Yapmış olduğumuz deneylerin başarı yüzdeleri karışıklık matrisleri ile belirtilmiştir. Deneyimizin başarı grafiği Şekil 4.3'te gösterilmiştir.

Şekil 4.3: Yapılan Deneylerin Başarı Yüzdeleri



Şekil 4.3'te Yapılan Deneylerdeki ÇYUKSHDÖM ile % başarı oranları gösterilmiştir. En yüksek başarı değeri Deney 1'de alınmıştır (yani Fp1-F7 kanalında). Grafikte x eksenini Deneyleri (Kanalları) ve y ekseninde başarı değerlerini göstermektedir.

Şekil 4.3'de Deney 1 %85,29 başarı elde edilmiştir, Deney 2 %61,76 başarı elde edilmiştir, Deney 3 %80,88 başarı elde edilmiştir, Deney 4 %75 başarı elde edilmiştir, Deney 5 %79,41 başarı elde edilmiştir, Deney 6 %58,82 başarı elde edilmiştir, Deney 7 %80,88 başarı elde edilmiştir, Deney 8 %70,59 başarı elde edilmiştir, Deney 9 %82,35 başarı elde edilmiştir, Deney 10 %77,94 başarı elde edilmiştir, Deney 11 %64,71 başarı elde edilmiştir, Deney 12 %69,12 başarı elde edilmiştir, Deney 13 %60,29 başarı elde edilmiştir, Deney 14 %66,18 başarı elde edilmiştir, Deney 15 %76,47 başarı elde edilmiştir, Deney 16 %73,53 başarı elde edilmiştir, Deney 17 %70,59 başarı elde edilmiştir, Deney 18 %85,29 başarı elde edilmiştir, Deney 19 %82,35 başarı elde edilmiştir, Deney 20 %82,35 başarı elde edilmiştir, Deney 21 %83,82 başarı elde edilmiştir, Deney 22 %80,88 başarı elde edilmiştir.



BEŞİNCİ BÖLÜM

TARTIŞMA

5.1. TARTIŞMA

Literatüre bakıldığında CHB-MIT Scalp veri seti kullanılarak epilepsi teşhisine yönelik çokça çalışma yapıldığı görülmektedir. Bu çalışmalarda farklı analiz yöntemleri ile EEG sinyalleri analiz edilerek farklı sınıflandırma yöntemleri kullanılmıştır.

Tablo 5.1: Literatürdeki Çalışmaların Kullandıkları Yöntemlere Göre Metrik Değerleri (%)

Yazarlar	Kullanılan veri seti	Kullanılan yöntemler	Başarı oranı (%)
He vd. 2022	CHB-MIT Scalp	ÇYUKSHDÖM	Doğruluk: %94,16; Duyarlılık: %88,23; Özgüllük: %75
Ryu vd. 2021	CHB-MIT Scalp	UKSHDÖM	Doğruluk: %93,28; Duyarlılık: %92,92; Özgüllük: %93,65; YPO: 0,063; F1-puanı: 0,923
Ansari vd. 2020	CHB-MIT Scalp	UKSHDÖM	Preiktal ve interiktal bölütler dahil edildiğinde Nöbet tahmini zamanında: Doğruluk: %96,59; Preiktal ve interiktal bölütler dahil edilmediğinde: Doğruluk: %95,71.
Tsiouris vd. 2018	CHB-MIT Scalp	UKSHDÖM	YPO: 0,11
Cheng vd. 2018	CHB-MIT Scalp	ÇYUKSHDÖM	Doğruluk: %99,47; Duyarlılık: %99,34; Özgüllük: %99,6

He vd. (2022), yılında yaptıkları çalışmada CHB-MIT Scalp veri setini ÇYUKSHDÖM sınıflandırma yöntemine göre Doğruluk: %94,16; Duyarlılık: %88,23; Özgüllük: %75 elde etmişlerdir. Ryu vd. (2021), yılında yaptıkları çalışmada CHB-MIT Scalp veri setini UKSHDÖM sınıflandırma yöntemine göre Doğruluk: %93,28; Duyarlılık: %92,92; Özgüllük: %93,65; YPO: 0,063; F1-puanı: 0,923 elde etmişlerdir. Ansari vd. (2020), yılında yaptıkları çalışmada CHB-MIT Scalp veri setinin UKSHDÖM sınıflandırma yöntemine göre Preiktal ve interiktal bölütler dahil edildiğinde Nöbet tahmini zamanında Doğruluk: %91,02, Nöbet tespiti zamanında Doğruluk: %96,59 elde etmişlerdir. CHB-MIT scalp veri setinin UKSHDÖM sınıflandırma yöntemine göre Preiktal ve interiktal bölütler dahil edilmediğinde Doğruluk: %95,71 elde etmişlerdir. Tsiouris vd. (2018), yılında CHB-MIT Scalp veri setinin UKSHDÖM sınıflandırma yöntemine göre YPO: 0,11 ve Yanlış Alarm Oranı 0,02 elde etmişlerdir. Cheng vd. (2018), yılında yaptıkları çalışmada CHB-MIT Scalp veri setini ÇYUKSHDÖM sınıflandırma yöntemine göre Doğruluk: %99,47; Duyarlılık: %99,34; Özgüllük: 99,6 elde etmişlerdir.

MA, sinyal tanımlamaya yarar. Multifraktal spektrum, bir sinyal için ölçeklendirme üslerinin dağılımını etkin bir şekilde gösterir. Eşdeğer olarak, multifraktal spektrum, bir sinyalin yerel düzenliliğinin zaman içinde ne kadar değiştiğinin bir ölçüsünü sağlar (Amoura, Gaci ve Bounif, 2022). Monofraktal olan bir sinyal, zaman içinde her yerde esasen aynı düzenliliği sergiler ve bu nedenle dar destekli çok fraktal bir spektruma sahiptir (Rahmani ve Fattahi, 2022). SE – karmaşık sinyallerin düzenlilik derecesini belirleyebilir. SE, arıza tespiti ve teşhisinde özellik çıkarma için bir avantajdır (Mi, vd., 2022). AF, EEG sinyallerinde salınımlı nöbet tipinin saptanması için bir özellik olarak sıklıkla kullanılır. Durağan olmayan bir sinyalin AF'sı, sinyal geliştikçe mevcut frekansların ortalamasına ilişkin zamanla değişen bir parametredir. Bu, AF'in karmaşık değerli sinyaller için desteklediği tek yöntemdir. AF, sinyalin AF'nı ve karşılık gelen örnekleme sürelerini hesaplamak içindir (Maity, Veeraraghavan ve Sabharwal, 2022). ÇYUKSHDÖM – bilgileri uzun süre hatırlayabilir ve kaybolan gradyan sorununu çözebilir (Kadhuim ve Al-Janabi, 2023).

Önerilen yöntemlerin doğrulamalarına bakıldığında oldukça yüksek başarı metrikleri sunulmuştur. Her ne kadar başarılar elde edilse de sinyalin niteliğinin kaybedilmediği, spektral özelliklerle desteklenen, AF etkin kullanıldığı, kaybolan gradyanlar probleminden etkilenmeyen ve en önemlisi beynin hangi bölgesinin epilepsi

teşhisinde belirgin olduğu yönelik çalışmalara ihtiyaç vardır. Biz bu çalışmada DÖ temelli MA, SA içeren EEG sinyaller analiz yöntemi ile epilepsi teşhisini gerçekleştirdik. Sonuç olarak FP1-F7 ve CZ-PZ kanallarından Doğruluk %85,29, Özgüllük %87,88, Hassasiyet %87,88, YPO %12,12, Duyarlılık %82,86, NTD %82,86, F1-puanı %86,29, MKK %70,74, YNO %17,14 ve YKO %12,12 elde edilmiştir.



SONUÇLAR VE ÖNERİLER

EEG verilerinin hacmi ve karmaşıklığı arttıkça, DÖ algoritmalar, ele almadaki yeteneklerini göstermeye başlar. EEG sinyallerinin kaotik doğası ve epileptik nöbet tahmini gibi zorlu biyomedikal uygulamalarda yeni fırsatlar açar. ÇYUKSHDÖM bu çalışmada nöbet tahmininde tanıtıldı ve epileptik nöbetlerin EEG sinyallerinin analizi için ideal bir araç olduğu kanıtlandı. Literatürdeki diğer yöntemlerin aksine kanal bazında analizin yapılabileceği deneysel çalışmalarla ortaya kondu. Bu çalışma, epilepsi için etkili bir tahmin aracı olarak yararlılığının ve bireyler için zamanında müdahalesinin güçlü göstergelerini sunmaktadır. Bundan sonraki çalışmalarda uzmanların da desteklediği bir veri seti oluşturularak sahadaki epilepsi hastalığının kanal bazında tespitini sağlayacak bir model ortaya konulacaktır.

Bu yazılım sayesinde nöroloji doktorlarının EEG sinyallerini daha kolay yorumlayacaklardır. Bu sayede hata payı en aza enektir. Hastanedeki kalite artacaktır. Epilepsi hastaları için bu yazılım rahatsızlık verilerini anlamada yardımcı olacaktır. Bu yazdığımız tezde 22 adet kanal bazında deneyler gerçekleştirilmiştir. UKSHDÖM yöntem ile sınıflandırırken 22 deneye bakıldığında en yüksek başarı değeri birinci deneyde alınmıştır. Sonuç olarak yaptığımız sınıflandırma ve analiz yöntemleri gelecekte diğer veri setlerine görede iyi bir sonuç elde etmede katkıda bulunacaktır.

KAYNAKÇA

- Ahmad, S. R. R., Sayeed, S. M., Ahmed, Z., Siddique, N. M., & Parvez, M. Z. (2020, June). Prediction of epileptic seizures using support vector machine and regularization. In *2020 IEEE Region 10 Symposium (TENSYP)* (pp. 1217-1220). IEEE.
- Alkhachroum, A., vd. (2022). Quantitative EEG-Based Seizure Estimation in Super-Refractory Status Epilepticus. *Neurocritical Care*, 36(3), 897-904.
- Alotaibi, G., vd. (2022). Artificial intelligence (AI) diagnostic tools: utilizing a convolutional neural network (CNN) to assess periodontal bone level radiographically—a retrospective study. *BMC Oral Health*, 22(399), 1-7.
- Amin, V. S., Zhang, Y. D., & Himed, B. (2019, April). Improved instantaneous frequency estimation of multi-component FM signals. In *2019 IEEE Radar Conference (RadarConf)* (pp. 1-6). IEEE.
- Amoura, S., Gaci, S., & Bounif, M. A. (2022, October). Wavelet leader-based multifractal analysis for characterizing subsurface heterogeneities using velocity logs. In *2022 2nd International Conference on Advanced Electrical Engineering (ICAEE)* (pp. 1-5). IEEE.
- Andronache, I., Liritzis, I. & Jelinek, H. F. (2023). Fractal algorithms and RGB image processing in scribal and ink identification on an 1819 secret initiation manuscript to the “Philike Hetaereia”. *Scientific Reports*, 13(1735), 1-22.
- Angione, K., vd. (2019). Genetic testing in a cohort of patients with potential epilepsy with myoclonic-atonic seizures. *Epilepsy research*, 150, 70-77.
- Ansari, A. Q., Sharma, P. ve Tripathi, M. (2020). Automatic seizure detection using neurosophic classifier. *Physical and Engineering Sciences in Medicine*, 43(3), 1019-1028.
- Ansari, A. Q., Sharma, P., & Tripathi, M. (2020, December). A deep learning network with minimal set of features for classification of ictal, interictal, and preictal EEG states. In *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)* (pp. 259-263). IEEE.
- Anuragi, A., Sisodia, D. S. ve Pachori, R. B. (2021). Automated FBSE-EWT based learning framework for detection of epileptic seizures using time-segmented EEG signals. *Computers in Biology and Medicine*, 136(104708), 1-16.
- Baduge, S. K., vd. (2022). Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. *Automation in Construction*, 141(104440), 1-26.
- Balaanand, M., vd. (2019). An enhanced graph-based semi-supervised learning algorithm to detect fake users on Twitter. *The Journal of Supercomputing*, 75, 6085-6105.

- Bednaya, E., vd. (2021). Oscillatory signatures of Repetition Suppression and Novelty Detection reveal altered induced visual responses in early deafness. *Cortex*, 142, 138-153.
- Beleza, P., vd. (2010). Epidural and foramen-ovale electrodes in the diagnostic evaluation of patients considered for epilepsy surgery. *Epileptic disorders*, 12, 48-53.
- Benbadis, S. R., vd. (2020). The role of EEG in patients with suspected epilepsy. *Epileptic Disorders*, 22(2), 143-155.
- Beniczky, S., vd. (2022). Seizure semiology: ILAE glossary of terms and their significance. *Epileptic Disorders*, 24(3), 447-495.
- Bhaduri, R., vd. (2022). Extending the susceptible-exposed-infected-removed (SEIR) model to handle the false negative rate and symptom-based administration of COVID-19 diagnostic tests: SEIR-fansy. *Statistics in Medicine*, 41(13), 2317-2337.
- Bilal, M., vd. (2019). Automatic seizure detection using multi-resolution dynamic mode decomposition. *IEEE Access*, 7, 61180-61194.
- Biondi, A., vd. (2022). Noninvasive mobile EEG as a tool for seizure monitoring and management: A systematic review. *Epilepsia*, 63(5), 1041-1063.
- Boashash, B., & Ouelha, S. (2018). Designing high-resolution time–frequency and time–scale distributions for the analysis and classification of non-stationary signals: a tutorial review with a comparison of features performance. *Digital Signal Processing*, 77, 120-152.
- Brandt, C., vd. (2020). Adjunctive perampanel and myoclonic and absence seizures: post hoc analysis of data from study 332 in patients with idiopathic generalized epilepsy. *Seizure*, 80, 115-123.
- Bruni, V., Tartaglione, M. ve Vitulano, D. (2020). A signal complexity-based approach for am–fm signal modes counting. *Mathematics*, 8(2170), 1-33.
- Carneiro, M. R., de Almeida, A. T. & Tavakoli, M. (2020). Wearable and comfortable e-textile headband for long-term acquisition of forehead EEG signals. *IEEE Sensors Journal*, 20(24), 15107-15116.
- Cartailler, J., vd. (2019). Alpha rhythm collapse predicts iso-electric suppressions during anesthesia. *Communications biology*, 2(327), 1-10.
- Castro-Tirado, A. J., vd. (2021). Very-high-frequency oscillations in the main peak of a magnetar giant flare. *Nature*, 600(7890), 621-624.
- Cavelli, M., vd. (2020). Nasal respiration entrains neocortical long-range gamma coherence during wakefulness. *European Journal of Neuroscience*, 51(6), 1463-1477.

- Cheng, C., vd. (2021). Patient-specific method of sleep electroencephalography using wavelet packet transform and Bi-LSTM for epileptic seizure prediction. *Biomedical Signal Processing and Control*, 70(102963), 1-13.
- Ciurea, A., Manoilă, C. P., Tautan, A. M., & Ionescu, B. (2020, October). Low latency automated epileptic seizure detection: Individualized vs. Global approaches. In *2020 International Conference on e-Health and Bioengineering (EHB)* (pp. 1-4). IEEE.
- Comanducci, A., vd. (2020). Clinical and advanced neurophysiology in the prognostic and diagnostic evaluation of disorders of consciousness: review of an IFCN-endorsed expert group. *Clinical Neurophysiology*, 131(11), 2736-2765.
- Çağlayan, H. Z. B., Ataoğlu, E. E. ve Kibaroglu, S. (2018). The Assessment of Efficacy of Traditional and Complementary Medicine Practices in Neurology. *Türk Noroloji Dergisi*, 24(2), 111-116.
- Çatalkaya, O., vd. (2022). Epilepsi Tespitinde Gürbüz Yerel Ortalama Ayırışım ve Ampirik Kip Ayırışım Yöntemlerinin Performans Analizi. *Avrupa Bilim ve Teknoloji Dergisi*, (39), 132-137.
- Dankers, F. J., vd. (2019). Prediction modeling methodology. *Fundamentals of clinical data science*, 10(1007), 101-120.
- Darra, F., vd. (2023). CDKL5-associated developmental and epileptic encephalopathy: a long-term, longitudinal electroclinical study of 22 cases. *Epilepsy Research*, 190(107098), 1-11.
- Davidson, M. L., Grabowsky, S. & Jayatilaka, D. (2022). X-ray constrained wavefunctions based on Hirshfeld atoms. I. Method and review. *Acta Crystallographica Section B: Structural Science, Crystal Engineering and Materials*, 78(3), 312-332.
- DeGiorgio, C. M., vd. (2019). Sudden unexpected death in epilepsy: Risk factors, biomarkers, and prevention. *Acta Neurologica Scandinavica*, 139(3), 220-230.
- Doudou, M., Bouabdallah, A. & Berge-Cherfaoui, V. (2020). Driver drowsiness measurement technologies: Current research, market solutions, and challenges. *International Journal of Intelligent Transportation Systems Research*, 18, 297-319.
- Doğan, S. (2022). *Otizm spektrum bozukluğu olan bireylere sunulan sağlık becerileri öğretim paketinin etkileri* (Yayımlanmış Doktora Tezi). Anadolu Üniversitesi, Eğitim Bilimleri Enstitüsü, Eskişehir.
- Elmalı, A. D., vd. (2020). How to diagnose and classify idiopathic (genetic) generalized epilepsies. *Epileptic Disorders*, 22(4), 399-420.
- Fan, H. C., vd. (2021). Clinical Characteristics of Mitochondrial Encephalomyopathy, Lactic Acidosis, and Stroke-Like Episodes. *Life*, 11(11), 1-24.

- Fareri, D. S., vd. (2015). Normative development of ventral striatal resting state connectivity in humans. *Neuroimage*, 118, 422-437.
- Fathima, T., Rahna, P., & Gaffoor, T. (2020, September). Wavelet based detection of epileptic seizures using scalp EEG. In *2020 International Conference on Futuristic Technologies in Control Systems & Renewable Energy (ICFCR)* (pp. 1-5). IEEE.
- Feng, Z., vd. (2020). Generalized adaptive mode decomposition for nonstationary signal analysis of rotating machinery: Principle and applications. *Mechanical Systems and Signal Processing*, 136(106530), 1-23.
- Fitriana, L. A., vd. (2021). Differences of electroencephalography wave with eyes-closed between older women with dementia and without dementia. *Journal of Engineering Research*, 10(36909), 1-10.
- Fordington, S., & Manford, M. (2020). A review of seizures and epilepsy following traumatic brain injury. *Journal of neurology*, 267, 3105-3111.
- Fouad, I. A. (2022). A robust and efficient EEG-based drowsiness detection system using different machine learning algorithms. *Ain Shams Engineering Journal*, 14(3), 1-18.
- Fröhlich, S., vd. (2021). Characteristics of resting state EEG power in 80+-year-olds of different cognitive status. *Frontiers in Aging Neuroscience*, 13(675689), 1-14.
- Galadí, J. A., vd. (2021). Capturing the non-stationarity of whole-brain dynamics underlying human brain states. *Neuroimage*, 244(118551), 1-17.
- Ghembaza, F., & Djebbari, A. (2022, May). A Robust Dynamic EEG Channel Selection using Time–Frequency Extended Renyi Entropy. In *2022 7th International Conference on Image and Signal Processing and their Applications (ISPA)* (pp. 1-8). IEEE.
- Goldberger, A. L., vd. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *circulation*, 101(23), e215-e220.
- Gray, R. A., vd. (2020). Anticonvulsive properties of cannabidiol in a model of generalized seizure are transient receptor potential vanilloid 1 dependent. *Cannabis and Cannabinoid Research*, 5(2), 145-149.
- Guastavino, S., vd. (2022). Prediction of severe thunderstorm events with ensemble deep learning and radar data. *Scientific Reports*, 12(20049), 1-14.
- Habiger, J., & Liang, Y. (2022). Publication Policies for Replicable Research and the Community-Wide False Discovery Rate. *The American Statistician*, 76(2), 131-141.

- Hasnaoui, L. H., & Djebbari, A. (2022, May). Epileptic Activity Prediction Within Pre-ictal Epochs: Application on Selected Channels. In *2022 7th International Conference on Image and Signal Processing and their Applications (ISPA)* (pp. 1-6). IEEE.
- He, J., vd. (2022). Spatial-temporal seizure detection with graph attention network and bi-directional LSTM architecture. *Biomedical Signal Processing and Control*, 78(103908), 1746-8094.
- Hirsch, E., vd. (2022). ILAE definition of the idiopathic generalized epilepsy syndromes: position statement by the ILAE task force on nosology and definitions. *Epilepsia*, 63(6), 1475-1499.
- Huguenard, J. (2019). Current controversy: spikes, bursts, and synchrony in generalized absence epilepsy: unresolved questions regarding thalamocortical synchrony in absence epilepsy. *Epilepsy Currents*, 19(2), 105-111.
- Jaffard, S., Lashermes, B. & Abry, P. (2006). Wavelet leaders in multifractal analysis. *Wavelet analysis and applications*, 1, 219-264.
- Jayaraj, R., & Mohan, J. (2021). Classification of sleep apnea based on sub-band decomposition of EEG signals. *Diagnostics*, 11(1571), 1-14.
- Kadhuim, Z. A., & Al-Janabi, S. (2023). Codon-mRNA prediction using deep optimal neurocomputing technique (DLSTM-DSN-WOA) and multivariate analysis. *Results in Engineering*, 17(100847), 1-18.
- Kaminiów, K., Ryguła, I. & Paprocka, J. (2022). Ataxia in Neurometabolic Disorders. *Metabolites*, 13(1), 1-18.
- Kaziha, O., & Bonny, T. (2020, February). A convolutional neural network for seizure detection. In *2020 Advances in Science and Engineering Technology International Conferences (ASET)* (pp. 1-5). IEEE.
- Khademi, Z., Ebrahimi, F. ve Kordy, H. M. (2022). A transfer learning-based CNN and LSTM hybrid deep learning model to classify motor imagery EEG signals. *Computers in Biology and Medicine*, 143(105288), 0010-4825.
- Khalil, K., vd. (2019). Economic LSTM approach for recurrent neural networks. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 66(11), 1885-1889.
- Khalilpour, S., vd. (2020, April). Application of 1-D CNN to predict epileptic seizures using EEG records. In *2020 6th International Conference on Web Research (ICWR)* (pp. 314-318). IEEE.
- Khan, N. A., & Ali, S. (2020). A robust and efficient instantaneous frequency estimator of multi-component signals with intersecting time-frequency signatures. *Signal Processing*, 177(107728), 1-6.

- Lattanzi, S., vd. (2019). Antiepileptic monotherapy in newly diagnosed focal epilepsy. A network meta-analysis. *Acta Neurologica Scandinavica*, 139(1), 33-41.
- Lee, E., vd. (2022). Entrapment of Binaural Auditory Beats in Subjects with Symptoms of Insomnia. *Brain Sciences*, 12(339), 1-11.
- Li, C., vd. (2021). Seizure onset detection using empirical mode decomposition and common spatial pattern. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 458-467.
- Li, H., & Wang, J. (2022, December). *Based on Wavelet Threshold Denoising-LDA and Bilstm Aircraft Engine Life Prediction*. In Journal of Physics: Conference Series. IOP Publishing. Sweden.
- Lillo, E., Mora, M. ve Lucero, B. (2022). Automated diagnosis of schizophrenia using EEG microstates and Deep Convolutional Neural Network. *Expert Systems with Applications*, 209(118236), 1-10.
- Luján, M. Á., vd. (2021). A survey on eeg signal processing techniques and machine learning: Applications to the neurofeedback of autobiographical memory deficits in schizophrenia. *Electronics*, 10(23), 1-19.
- Lundqvist, M., vd. (2016). Gamma and beta bursts underlie working memory. *Neuron*, 90(1), 152-164.
- Maity, A. K., Veeraraghavan, A. ve Sabharwal, A. (2022). PPGMotion: Model-based detection of motion artifacts in photoplethysmography signals. *Biomedical Signal Processing and Control*, 75(103632), 1-12.
- Mangalathu, S., vd. (2020). Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls. *Engineering Structures*, 208(110331), 1-10.
- Maragkakis, M., vd. (2009). Accurate microRNA target prediction correlates with protein repression levels. *BMC bioinformatics*, 10, 1-10.
- Mercier, M. R., vd. (2022). Advances in human intracranial electroencephalography research, guidelines and good practices. *NeuroImage*, 260(119438), 1-63.
- Mi, Y., vd. (2022). Bubble transfer spectral entropy and its application in epilepsy EEG analysis. *Communications in Nonlinear Science and Numerical Simulation*, 110(106294), 1-20.
- Miao, J., & Zhu, W. (2022). Precision–recall curve (PRC) classification trees. *Evolutionary intelligence*, 15(3), 1545-1569.
- Mohan, N., PP, M. S., Sulthan, N., Sofiya, S., & Khan, K. A. (2018, April). Automatic epileptic seizure prediction in scalp EEG. In *2018 International Conference on Intelligent Circuits and Systems (ICICS)* (pp. 275-280). IEEE.

- MohanBabu, G., Anupallavi, S. & Ashokkumar, S. R. (2021). An optimized deep learning network model for eeg based seizure classification using synchronization and functional connectivity measures. *Journal of Ambient Intelligence and Humanized Computing*, 12(7), 7139-7151.
- Mutlu-Bayraktar, D., vd. (2022). Split-attention effects in multimedia learning environments: eye-tracking and EEG analysis. *Multimedia Tools and Applications*, 81(6), 8259-8282.
- Ng, C. R., vd. (2022). Multi-Center Evaluation of Gel-Based and Dry Multipin EEG Caps. *Sensors*, 22(8079), 1-16.
- Nobili, L., vd. (2021). Standard procedures for the diagnostic pathway of sleep-related epilepsies and comorbid sleep disorders: An EAN, ESRS and ILAE-Europe consensus review. *European journal of neurology*, 28(1), 15-32.
- O'Hara, B., & Guerriero, L. (2019). Meditation, sleep, and performance. *OBM Integrative and Complementary Medicine*, 4(2), 1-18.
- Önder, Ü., & Ayaz, F. (2022). Epilepsy disease and treatment approaches. *Advanced Engineering Days (AED)*, 5, 117-119.
- Pale, S., vd. (2022). Anticonvulsant effects of Cymbopogon giganteus extracts with possible effects on fully kindled seizures and anxiety in experimental rodent model of mesio-temporal epilepsy induced by pilocarpine. *Journal of Ethnopharmacology*, 286(114863), 1-9.
- Patel, P., & Annavarapu, R. N. (2021). EEG-based human emotion recognition using entropy as a feature extraction measure. *Brain informatics*, 8(20), 1-13.
- Patel, S., vd. (2021). The long-term efficacy of cannabidiol in the treatment of refractory epilepsy. *Epilepsia*, 62(7), 1594-1603.
- Pavlova, O. N., Guyo, G. A. ve Pavlov, A. N. (2022). Multifractal formalism combined with multiresolution wavelet analysis of physiological signals. *The European Physical Journal Special Topics*, 1-5.
- Pourmotabbed, H., Wheless, J. W. & Babajani-Feremi, A. (2020). Lateralization of epilepsy using intra-hemispheric brain networks based on resting-state MEG data. *Human Brain Mapping*, 41(11), 2964-2979.
- Qin, Y., vd. (2020, July). Patient-specific seizure prediction with scalp EEG using convolutional neural network and extreme learning machine. In *2020 39th Chinese Control Conference (CCC)* (pp. 7622-7625). IEEE.
- Raghu, S., vd. (2019). Performance evaluation of DWT based sigmoid entropy in time and frequency domains for automated detection of epileptic seizures using SVM classifier. *Computers in biology and medicine*, 110, 127-143.

- Rahmani, F., & Fattahi, M. H. (2022). Exploring the association between anomalies and multifractality variations in river flow time series. *Hydrological Sciences Journal*, 67(7), 1084-1095.
- Rath, P., vd. (2022). A Tuned Whale Optimization-Based Stacked-LSTM Network for Digital Image Segmentation. *Arabian Journal for Science and Engineering*, 48, 1735-1756.
- Reinhart, R. M., & Nguyen, J. A. (2019). Working memory revived in older adults by synchronizing rhythmic brain circuits. *Nature neuroscience*, 22(5), 820-827.
- Rupom, A. I., & Patwary, A. B. (2019, February). P300 speller based ALS detection using daubechies wavelet transform in electroencephalograph. In *2019 International Conference on Electrical, Computer and Communication Engineering (ECCE)* (pp. 1-5). IEEE.
- Ryu, S., & Joe, I. (2021). A Hybrid DenseNet-LSTM model for epileptic seizure prediction. *Applied Sciences*, 11(16), 1-13.
- Saedi, S., vd. (2022). Applications of electroencephalography in construction. *Automation in Construction*, 133(103985), 1-15.
- Saidi, A., Othman, S. B. & Saoud, S. B. (2021, July). A novel epileptic seizure detection system using scalp EEG signals based on hybrid CNN-SVM classifier. In *2021 IEEE Symposium on Industrial Electronics & Applications (ISIEA)* (pp. 1-6). IEEE.
- Salpekar, J. A., & Mula, M. (2019). Common psychiatric comorbidities in epilepsy: How big of a problem is it?. *Epilepsy & behavior*, 98, 293-297.
- Salvatierra, N., Sakanishi, R. & Flores, C. (2020, October). Epileptic Seizure prediction from scalp EEG using ratios of spectral power. In *2020 IEEE Engineering International Research Conference (EIRCON)* (pp. 1-4). IEEE.
- San-Segundo, R., vd. (2019). Classification of epileptic EEG recordings using signal transforms and convolutional neural networks. *Computers in biology and medicine*, 109, 148-158.
- Sarudiansky, M., vd. (2021). Patients' Explanatory Models about drug-resistant epilepsy in Argentina. A thematic analysis. *Seizure*, 91, 409-416.
- Schüssler, S. C., vd. (2022). Long-term outcomes of very-low-birth-weight and low-birth-weight preterm newborns with neonatal seizures: A single-center perspective. *European Journal of Paediatric Neurology*, 36, 137-142.
- Sengupta, S., & Lande, B. K. (2020). An approach to PAPR reduction in OFDM using Goppa codes. *Procedia Computer Science*, 167, 1268-1280.

- Shahbazi, M., & Aghajan, H. (2018, November). A generalizable model for seizure prediction based on deep learning using CNN-LSTM architecture. In *2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)* (pp. 469-473). IEEE.
- Shakeshaft, A., vd. (2021). Trait impulsivity in juvenile myoclonic epilepsy. *Annals of clinical and translational neurology*, 8(1), 138-152.
- Shariat, A., vd. (2021). Automatic detection of epileptic seizures using Riemannian geometry from scalp EEG recordings. *Medical & Biological Engineering & Computing*, 59, 1431-1445.
- Shen, M., vd. (2022). An EEG based real-time epilepsy seizure detection approach using discrete wavelet transform and machine learning methods. *Biomedical Signal Processing and Control*, 77(103820), 1-8.
- Shi, J., vd. (2022). Instantaneous frequency synchronized generalized stepwise demodulation transform for bearing fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-15.
- Shoeb, A. H. (2009). *Application of machine learning to epileptic seizure onset detection and treatment* (Published PhD Thesis). MIT University, Massachusetts Institute Of Technology, Cambridge.
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019, December). The performance of LSTM and BiLSTM in forecasting time series. In *2019 IEEE International Conference on Big Data (Big Data)* (pp. 3285-3292). IEEE.
- Singh, K., & Malhotra, J. (2021). Deep learning based smart health monitoring for automated prediction of epileptic seizures using spectral analysis of scalp EEG. *Physical and Engineering Sciences in Medicine*, 44(4), 1161-1173.
- Sisodiya, S. M., vd. (2022). The ENIGMA-Epilepsy working group: Mapping disease from large data sets. *Human brain mapping*, 43(1), 113-128.
- Siuly, S., vd. (2020). A new framework for automatic detection of patients with mild cognitive impairment using resting-state EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(9), 1966-1976.
- Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.
- Snipes, S., vd. (2022). The theta paradox: 4-8 Hz EEG oscillations reflect both sleep pressure and cognitive control. *Journal of Neuroscience*, 42(45), 8569-8586.
- Sopic, D., Aminifar, A., & Atienza, D. (2018, May). e-glass: A wearable system for real-time detection of epileptic seizures. In *2018 IEEE International Symposium on Circuits and Systems (ISCAS)* (pp. 1-5). IEEE.

- Specchio, N., vd. (2022). International League Against Epilepsy classification and definition of epilepsy syndromes with onset in childhood: Position paper by the ILAE Task Force on Nosology and Definitions. *Epilepsia*, 63(6), 1398-1442.
- Stancin, I., Cifrek, M. & Jovic, A. (2021). A review of EEG signal features and their application in driver drowsiness detection systems. *Sensors*, 21(3786), 1-29.
- Steele, A. G., vd. (2021). A Mixed Filtering Approach for Real-Time Seizure State Tracking Using Multi-Channel Electroencephalography Data. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 2037-2045.
- Stevenson, N. J., vd. (2019). A dataset of neonatal EEG recordings with seizure annotations. *Scientific data*, 6(1), 1-8.
- Straub, K. M., vd. (2020). Buffered, incomplete, and shredded: The challenges of reading an imperfect stratigraphic record. *Journal of Geophysical Research: Earth Surface*, 125(3), 1-44.
- Tallón-Ballesteros, A. J. (2022, January). *An Effective Deep Neural Network Architecture for Cross-Subject Epileptic Seizure Detection in EEG Data*. In Proceedings of CECNet 2021: The 11th International Conference on Electronics, Communications and Networks (CECNet), November 18-21, 2021. IOS Press. Canada.
- Tang, L., vd. (2018, October). Automatic Artifact Reduction Based on MEMD-for Seizure Prediction. In *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)* (pp. 1-4). IEEE.
- Taquet, M., vd. (2022). Neurological and psychiatric risk trajectories after SARS-CoV-2 infection: an analysis of 2-year retrospective cohort studies including 1 284 437 patients. *The Lancet Psychiatry*, 9(10), 815-827.
- Thijs, R. D., vd. (2019). Epilepsy in adults. *The Lancet*, 393(10172), 689-701.
- Tiwari, S., vd. (2023). A smart decision support system to diagnose arrhythmia using ensembled ConvNet and ConvNet-LSTM model. *Expert Systems with Applications*, 213(118933), 1-13.
- Todd, N. P., Govender, S. ve Colebatch, J. G. (2018). The human electrocerebellogram (ECeG) recorded non-invasively using scalp electrodes. *Neuroscience letters*, 682, 124-131.
- Tomašev, N., vd. (2019). A clinically applicable approach to continuous prediction of future acute kidney injury. *Nature*, 572(7767), 116-119.
- Tosun, M., & Çetin, O. (2022). A new phase-based feature extraction method for four-class motor imagery classification. *Signal, Image and Video Processing*, 16, 283-290.

- Tosun, M., vd. (2018). EEG verileri kullanılarak fiziksel el hareketleri ve bu hareketlerin hayalinin yapay sinir ağı ile sınıflandırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(2), 1-9.
- Tsiouris, K. M., vd. (2018). A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in biology and medicine*, 99, 24-37.
- Tuncer, E., & Bolat, E. D. (2022). Classification of epileptic seizures from electroencephalogram (EEG) data using bidirectional short-term memory (Bi-LSTM) network architecture. *Biomedical Signal Processing and Control*, 73(103462), 1-10.
- Uys, P. J. (2019). *Image classification from EEG Brain Signals using machine learning and deep learning techniques* (Yayımlanmış Doktora Tezi). Stellenbosch Üniversitesi, Mühendislik Fakültesi, Stellenbosch.
- Varanis, M., vd. (2021). A tutorial review on time-frequency analysis of non-stationary vibration signals with nonlinear dynamics applications. *Brazilian Journal of Physics*, 51, 859-877.
- Villarreal-Hernandez, C. A., vd. (2020). Discrete-time modeling and control of double dual boost converters with implicit current ripple cancellation over a wide operating range. *IEEE Transactions on Industrial Electronics*, 68(7), 5966-5977.
- Vranković, A., Lerga, J. & Saulig, N. (2020). A novel approach to extracting useful information from noisy TFDs using 2D local entropy measures. *EURASIP Journal on Advances in Signal Processing*, 2020, 1-19.
- Wang, X., vd. (2021). One dimensional convolutional neural networks for seizure onset detection using long-term scalp and intracranial EEG. *Neurocomputing*, 459, 212-222.
- Wang, Z., Yang, J. & Sawan, M. (2021, June). A novel multi-scale dilated 3D CNN for epileptic seizure prediction. In *2021 IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems (AICAS)* (pp. 1-4). IEEE.
- Wendt, H., & Abry, P. (2007). Multifractality tests using bootstrapped wavelet leaders. *IEEE Transactions on Signal Processing*, 55(10), 4811-4820.
- Xin, Y., Hao, H. ve Li, J. (2019). Time-varying system identification by enhanced empirical wavelet transform based on synchroextracting transform. *Engineering Structures*, 196(109313), 1-13.
- Xiong, Z., vd. (2021). A study on seizure detection of EEG signals represented in 2D. *Sensors*, 21(15), 1-22.

- Xu, Y., Yang, J., Zhao, S., Wu, H., & Sawan, M. (2020, August). An end-to-end deep learning approach for epileptic seizure prediction. In *2020 2nd IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)* (pp. 266-270). IEEE.
- Yaakub, S. N., vd. (2020). Heritability of alpha and sensorimotor network changes in temporal lobe epilepsy. *Annals of clinical and translational neurology*, 7(5), 667-676.
- Yang, X., vd. (2021). An effective dual self-attention residual network for seizure prediction. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 1604-1613.
- Yildirim, N., & Varol, A. (2016). Warning System for Drivers according to Attention and Meditation Status Using Brain Computer Interface. *International Journal of Advances in Electronics and Computer Science*, 3(9), 49-53.
- Yiu, C. Y., vd. (2022). Towards safe and collaborative aerodrome operations: assessing shared situational awareness for adverse weather detection with EEG-enabled Bayesian neural networks. *Advanced Engineering Informatics*, 53(101698), 1-19.
- Yuluğ, B., Özşimşek, A. & Öktem, E. Ö. (2022). Investigation of the Antiepileptics on Levels of Vitamin D and Calcium. *Acta Medica Alanya*, 6(2), 167-172.
- Zhang, X., & Li, H. (2022, March). Patient-specific seizure prediction from scalp EEG using vision transformer. In *2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC)* (Vol. 6, pp. 1663-1667). IEEE.
- Zhang, Y., vd. (2019). Epilepsy seizure prediction on EEG using common spatial pattern and convolutional neural network. *IEEE Journal of Biomedical and Health Informatics*, 24(2), 465-474.
- Zhang, Y., vd. (2022). Epileptic Seizure Detection Based on Bidirectional Gated Recurrent Unit Network. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 135-145.
- Zhao, S., vd. (2020, October). Binary single-dimensional convolutional neural network for seizure prediction. In *2020 IEEE International Symposium on Circuits and Systems (ISCAS)* (pp. 1-5). IEEE.
- Zhao, Y., vd. (2021). EEG-Based Seizure detection using linear graph convolution network with focal loss. *Computer Methods and Programs in Biomedicine*, 208(106277), 0169-2607.
- Zheng, H., vd. (2020, August). Automatic Seizure Prediction from Scalp EEG with Optimal Feature and Minimum Channels. In *2020 Chinese Control And Decision Conference (CCDC)* (pp. 4351-4355). IEEE.

- Zhou, W., vd. (2022). Empirical Fourier decomposition: An accurate signal decomposition method for nonlinear and non-stationary time series analysis. *Mechanical Systems and Signal Processing*, 163(108155), 1-22.
- Zou, L., Liu, X., Jiang, A., & Zhousp, X. (2018, November). Epileptic seizure detection using deep convolutional network. In *2018 IEEE 23rd International Conference on Digital Signal Processing (DSP)* (pp. 1-4). IEEE.



DİZİN

-A-

AF, xvi, 2, 25, 41, 42, 43, 95

-Ç-

ÇYUKSHDÖM, xv, xvi, 2, 8, 16, 26, 47,
54, 55, 57, 59, 60, 62, 64, 65, 67, 69, 71,
72, 74, 76, 77, 79, 81, 82, 84, 86, 87, 89,
91, 93, 94, 95, 96

-E-

EEG, v, vi, xi, xiv, xv, xvi, 1, 2, 4, 5, 6, 7,
8, 9, 10, 11, 12, 13, 14, 15, 18, 19, 20,
21, 22, 23, 25, 26, 29, 30, 31, 32, 35, 36,
37, 38, 39, 40, 41, 42, 43, 45, 46, 53, 54,
55, 56, 57, 59, 60, 61, 62, 64, 65, 66, 67,
68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78,
79, 80, 81, 82, 83, 84, 86, 87, 88, 89, 93,
95, 96, 97, 98, 99, 100, 101, 102, 103,
104, 105, 106, 107, 108, 109, 110, 111

Epilepsi, v, ix, xiv, 1, 2, 7, 11, 18, 19, 22,
36, 93, 96, 97, 101

-M-

MA, xiv, xvi, 2, 4, 25, 34, 95

-S-

SE, xv, xvii, 2, 25, 43, 44, 45, 46, 95