



**AYRIK DALGACIK DÖNÜŞÜM LİDERLERİ,
SPEKTRAL ANALİZ VE DERİN ÖĞRENME
MODELİ KULLANILARAK
ELEKTROENSEFALOGRAFİ (EEG)
SİNYALLERİNDEN HAFİF BİLİŞSEL
BOZUKLUĞUNUN TESPİTİ**

Yüksek Lisans Tezi

Afrah SAİD

Kütahya - 2023

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

Yüksek Lisans Tezi

**AYRIK DALGACIK DÖNÜŞÜM LİDERLERİ, SPEKTRAL
ANALİZ VE DERİN ÖĞRENME MODELİ KULLANILARAK
ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİNDEN HAFİF
BİLİŞSEL BOZUKLUĞUNUN TESPİTİ**

Danışman:
Dr. Öğr. Üyesi Hanife GÖKER

Hazırlayan:
Afrah SAİD

Kütahya – 2023

Kabul ve Onay

KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İleri Teknolojiler Ana bilim dalında, 202085121050 öğrenci numaralı, Afrah ISMAIL ABDI SAİD'nin hazırlamış olduğu "AYRIK DALGACIK DÖNÜŞÜM LİDERLERİ, SPEKTRAL ANALİZ VE DERİN ÖĞRENME MODELİ KULLANILARAK ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİNDEN HAFİF BİLİŞSEL BOZUKLUĞUNUN TESPİTİ" başlıklı yüksek lisans tez çalışması ile ilgili tez savunma sınavı jüri tarafından yapılmış ve adayın tezinin OY BİRLİĞİ ile kabul edilmesine karar verilmiştir.

19/07/2023

Tez Jürisi	İmza	
	Kabul	Red
Dr. Öğr. Üyesi Hanife GÖKER (Danışman)		
Doç. Dr. Mustafa TOSUN		
Doç. Dr. Abdullatif KABAN		

Onay

Doç. Dr. Arif KOLAY
Enstitü Müdürü

Bilimsel Etik Bildirimi

Yüksek Lisans tezi olarak hazırladığım “*AYRIK DALGACIK DÖNÜŞÜM LİDERLERİ, SPEKTRAL ANALİZ VE DERİN ÖĞRENME MODELİ KULLANILARAK ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİNDEN HAFİF BİLİŞSEL BOZUKLUĞUNUN TESPİTİ*” 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.

19/07/2023
Afrah SAİD

Özgeçmiş

Afrah SAİD, ilköğrenimini Suudi Arabistan Cidde şehrinde bulunan Duaa International School'da, ortaokulu Al-Hukamaa International School'da, lise eğitimini Hala International School'da tamamlamıştır. Lisans eğitimini Arab Open University, Cidde, fen fakültesi, Bilişim Teknolojileri ve Bilgisayar Bölümü'nde tamamlamıştır. Daha sonra Kütahya Dumlupınar Üniversitesi Lisansüstü Eğitim Enstitüsü Simav Teknoloji Fakültesi Elektrik-Elektronik Mühendisliği İleri Teknolojiler Anabilim Dalında yüksek lisansını tamamlamıştır.



ÖZET

AYRIK DALGACIK DÖNÜŞÜM LİDERLERİ, SPEKTRAL ANALİZ VE DERİN ÖĞRENME MODELİ KULLANILARAK ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİNDEN HAFİF BİLİŞSEL BOZUKLUĞUNUN TESPİTİ

SAİD, Afrah

Yüksek Lisans Tezi, İleri Teknolojiler Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi HANİFE GÖKER

Temmuz, 2023, 77 sayfa

Hafif Bilişsel Bozukluk (HBB), bilişsel bozukluklarla karakterize nöropsikolojik bir sendromdur. HBB'nin erken teşhisi, hastalığın Alzheimer hastalığına dönüşümünü yavaşlatabildiği için önemlidir. Hastalığın doğru ve erken teşhisi kapsamlı testleri ve uzun vadeli gözlemleri gerektirmektedir. Bunlar subjektif, pahalı veya eksik olabilir. EEG bulgulara dayalı olması, invazif olmaması ve daha az maliyetli olması gibi avantajlarıyla hastalıkların teşhisinde güçlü bir adaydır. Bu çalışmada derin öğrenme, makine öğrenmesi ve farklı öznitelik çıkarma yöntemleri kullanılarak, HBB'yi daha yüksek doğrulukla etkili bir şekilde tespit edebilen EEG tabanlı yeni bir model önerilmektedir. Çalışmada EEG sinyalleri Çok Ölçekli Temel Bileşen Analizi (MSPCA) kullanılarak gürültüden arındırılmıştır ve verisetinin boyutunu artırmak için Veri Büyütme (DA) gerçekleştirilmiştir. Daha sonra, EEG sinyallerinden öznitelikleri çıkarmak için Ayrık Dalgacık Dönüşümü Liderleri (DWT liderleri), Periodogram, Welch ve Multitaper öznitelik çıkarma yöntemi kullanılmıştır. Modelin doğrulanması 10-kat çapraz doğrulama yöntemi ile gerçekleştirilmiştir. Son olarak Çift Yönlü Uzun Kısa Dönem Hafıza (BiLSTM), Karar Ağacı (DT), Destek Vektör Makinesi (SVM) ve K-En Yakın Komşu (KNN) algoritmalarının performansları karşılaştırılmıştır. Multitaper spektral analizi ile BiLSTM derin öğrenme algoritmasını bütünleştiren model, deneyler sonucunda en yüksek performansı göstermiştir. Önerilen model, %98.97 doğruluk, %98.34 duyarlılık, %99.67 özgüllük, %99.70 kesinlik, %99.02 f1 skoru ve %97.94 Matthews Korelasyon Katsayısı (MCC) değerleri ile umut verici bir performans elde etmiştir.

Anahtar Kelimeler: Derin Öğrenme, DWT liderleri, Elektroensefalografi (EEG), Güç Spektral Analizi, Hafif Bilişsel Bozukluk (HBB).

ABSTRACT**DETECTION OF MILD COGNITIVE IMPAIRMENT FROM
ELECTROENCEPHALOGRAPHY (EEG) SIGNALS USING DISCRETE
WAVELET TRANSFORMATION LEADERS, SPECTRAL ANALYSIS AND
DEEP LEARNING MODEL****SAİD, Afrah****Master Thesis, Department of Advanced Technologies****Thesis Advisor: Dr. Öğr. Üyesi Hanife GÖKER****July, 2023, 77 pages**

Mild Cognitive Impairment (MCI) is a neuropsychological syndrome characterized by cognitive disorders. Early diagnosis of MCI is important as it can slow the progression of the disease to Alzheimer's disease. Accurate and early diagnosis of the disease requires extensive testing and long-term observations. These can be subjective, expensive, or incomplete. EEG is a strong candidate in the diagnosis of diseases with its advantages such as being based on findings, non-invasive, and less costly. In this study, a new EEG-based model is proposed that can effectively detect MCI with higher accuracy by using deep learning, machine learning, and different feature extraction methods. In the study, EEG signals were denoised using Multiscale Principal Component Analysis (MSPCA), and Data Augmentation (DA) was performed to increase the size of the dataset. Then, Discrete Wavelet Transform Leaders (DWT leaders), Periodogram, Welch, and Multitaper feature extraction methods were used to extract features from the EEG signals. Validation of the model was carried out with the 10-fold cross-validation method. Finally, the performances of Bi-directional Long Short-Term Memory (BiLSTM), Decision Tree (DT), Support Vector Machine (SVM), and K-Nearest Neighbor (KNN) algorithms are compared. The model, which integrates the multitaper spectral analysis and the BiLSTM deep learning algorithm, showed the highest performance as a result of the experiments. The proposed model achieved promising performance with 98.97% accuracy, 98.34% sensitivity, 99.67% specificity, 99.70% precision, 99.02% f1 score, and 97.94% Matthews Correlation Coefficient (MCC).

Keywords: Deep learning, DWT leaders, Electroencephalography (EEG), Mild Cognitive Impairment (MCI), Power Spectral Analysis.

ÖNSÖZ

Bu çalışmada bana yardımcı olan, tecrübesiyle bana ışık tutan, yüksek lisans tezimde karşılaştığım her engeli ve zorluğu aşmamda bilgi ve birikimlerini cömertçe benimle paylaşan değerli danışmanım Dr. Öğr. Üyesi Hanife GÖKER'e şükranlarımı sunarım.

Hocalarım Doç. Dr. Mustafa TOSUN'a, Doç. Dr. Ömer KASIM'a, Dr. Öğr. Üyesi Şükrü KİTİŞ'e ve bana yardımcı olan arkadaşlarıma teşekkür ederim. Hayatım boyunca maddi, manevi desteği ile hep yanımda olan, aldığım kararlarda beni sürekli destekleyen canım anneme, babama ve kardeşlerime teşekkürlerimi borç bilirim.



İÇİNDEKİLER

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

BİRİNCİ BÖLÜM

LİTERATÜR ÇALIŞMALARI

1.1. İLGİLİ LİTERATÜR ÇALIŞMALARI	5
---	---

İKİNCİ BÖLÜM

GENEL KISIMLAR

2.1. BEYİN BİLGİSAYAR ARAYÜZÜ (BCI)	10
2.1.1. Sinyal Alımı	11
2.1.2. Sinyal Ön İşleme	13
2.1.3. Öznitelik Çıkarma	13
2.1.4. Sınıflandırma	13
2.1.5. Uygulama Arayüzü	14
2.2. ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİ	14
2.2.1. EEG Sinyallerinin Kaydedilmesi	14
2.2.2. EEG Sinyallerinin Kaydedilmesine Etki Eden Faktörler	16
2.2.2.1. Dış Gürültü	16
2.2.2.2. İç Gürültü	16
2.2.3. EEG Dalga Biçimleri	17
2.2.4. EEG frekans bantları	17
2.2.4.1. Delta	17
2.2.4.2. Teta	17
2.2.4.3. Alfa	18
2.2.4.4. Beta	18
2.2.4.5. Gama	18

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOD

3.1. ÖNERİLEN DERİN ÖĞRENME MODELİ.....	20
3.2. EEG VERİSETİ	21
3.3. ÇOK ÖLÇEKLİ TEMEL BİLEŞEN ANALİZİ (MSPCA).....	22
3.4. VERİ ARTIRMA (DA)	23
3.5. ÖZNİTELİK ÇIKARIMI.....	23

3.5.1. Ayrık Dalgacık Dönüşümü Liderleri (DWT Liderleri).....	23
3.5.2. Periodogram	25
3.5.3. Welch	25
3.5.4. Multitaper	26
3.6. K-KAT ÇAPRAZ DOĞRULAMA	26
3.7. SINIFLANDIRMA ALGORİTMALARI.....	26
3.7.1. Karar Ağacı (DT).....	26
3.7.2. Destek Vektör Makinesi (SVM)	27
3.7.3. K-En Yakın Komşu (KNN)	27
3.7.4. BiLSTM.....	27
3.8. PERFORMANS DEĞERLENDİRME METRİKLERİ.....	29

DÖRDÜNCÜ BÖLÜM

DENEYSEL ÇALIŞMALAR VE BULGULAR

4.1. DWT LİDERLERİ DENEYİ	37
4.1.1. DT Algoritması ile DWT Liderleri Yöntemi	37
4.1.2. SVM Algoritması ile DWT Liderleri Yöntemi.....	39
4.1.3. KNN Algoritması ile DWT Liderleri Yöntemi.....	40
4.1.4. BiLSTM Algoritması ile DWT Liderleri Yöntemi.....	42
4.2. PERIODOGRAM DENEYİ.....	44
4.2.1. DT Algoritması ile Periodogram Yöntemi	44
4.2.2. SVM Algoritması ile Periodogram Yöntemi	45
4.2.3. KNN Algoritması ile Periodogram Yöntemi	46
4.2.4. BiLSTM Algoritması ile Periodogram Yöntemi	48
4.3. WELCH DENEYİ.....	50
4.3.1. DT Algoritması ile Welch Yöntemi	50
4.3.2. SVM Algoritması ile Welch Yöntemi.....	51
4.3.3. KNN Algoritması ile Welch Yöntemi.....	53
4.3.4. BiLSTM Algoritması ile Welch Yöntemi.....	54
4.4. MULTITAPER DENEYİ.....	56
4.4.1. DT Algoritması ile Multitaper Yöntemi	56
4.4.2. SVM Algoritması ile Multitaper Yöntemi.....	58
4.4.3. KNN Algoritması ile Multitaper Yöntemi.....	59
4.4.4. BiLSTM Algoritması ile Multitaper Yöntemi	60
4.5. TÜM MODELLERİN KARŞILAŞTIRILMASI	62
SONUÇ VE ÖNERİLER.....	68
KAYNAKÇA	69
DİZİN	76

TABLOLAR LİSTESİ

Sayfa

Tablo 4.1: DWT Liderleri+DT Algoritmasının Performans Değerlendirme Metrikleri	38
Tablo 4.2: DWT Liderleri+SVM Algoritmasının Performans Değerlendirme Metrikleri	40
Tablo 4.3: DWT Liderleri+KNN Algoritmasının Performans Değerlendirme Metrikleri	41
Tablo 4.4: DWT Liderleri+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri	43
Tablo 4.5: Periodogram+DT Algoritmasının Performans Değerlendirme Metrikleri ...	45
Tablo 4.6: Periodogram+SVM Algoritmasının Performans Değerlendirme Metrikleri	46
Tablo 4.7: Periodogram+KNN Algoritmasının Performans Değerlendirme Metrikleri	47
Tablo 4.8: Periodogram+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri	49
Tablo 4.9: Welch+DT Algoritmasının Performans Değerlendirme Metrikleri.....	51
Tablo 4.10: Welch+SVM Algoritmasının Performans Değerlendirme Metrikleri	52
Tablo 4.11: Welch+KNN Algoritmasının Performans Değerlendirme Metrikleri	54
Tablo 4.12: Welch+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri ..	55
Tablo 4.13: Multitaper+DT Algoritmasının Performans Değerlendirme Metrikleri	57
Tablo 4.14: Multitaper+SVM Algoritmasının Performans Değerlendirme Metrikleri..	58
Tablo 4.15: Multitaper+KNN Algoritmasının Performans Değerlendirme Metrikleri..	60
Tablo 4.16: Multitaper+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri	61
Tablo 4.17: Dört Modelin Sınıflandırma Algoritmalarının Karışıklık Matrisinin Karşılaştırılması	63
Tablo 4.18: Dört Modelin Sınıflandırma Algoritmalarının Performans Değerlendirme Metrikleri Sonuçları	64
Tablo 4.19: İlgili Literatürün Karşılaştırmalı Analizi	65

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: BCI sisteminin bileşenleri	10
Şekil 2.7: Bir Nöronun Yapısı	15
Şekil 2.2: Delta Ritim Dalga Formu	17
Şekil 2.3: Teta Ritim Dalga Formu.....	18
Şekil 2.4: Alfa Ritim Dalga Formu.....	18
Şekil 2.5: Beta Ritim Dalga Formu	18
Şekil 2.6: Gama Ritim Dalga Formu	18
Şekil 3.1: Önerilen Model.....	21
Şekil 3.2: Uluslararası 10-20 Sistem Elektrot Yerleştirme Sistemi.....	22
Şekil 3.3: LSTM Hücresinin Yapısı	29
Şekil 3.4: BiLSTM Yapısı	29
Şekil 4.1: Ham EEG Sinyalleri.....	32
Şekil 4.2: DWT Liderleri Yöntemiyle Öznitelik Vektör Grafiği	33
Şekil 4.3: Periodogram Yöntemiyle PSD Grafiği.....	34
Şekil 4.4: Welch Yöntemiyle PSD Grafiği.....	35
Şekil 4.5: Multitaper Yöntemiyle PSD Grafiği	36
Şekil 4.6: DWT Liderleri ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi.....	38
Şekil 4.7: DWT liderleri ile SVM sınıflandırma algoritmasının karışıklık matrisi.....	39
Şekil 4.8: DWT Liderleri ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi ..	41
Şekil 4.9: DWT Liderleri ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi	42
Şekil 4.10: DWT liderleri modelinin eğitim doğruluğu ve kayıp grafiği.....	43
Şekil 4.11: Periodogram ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi	44
Şekil 4.12: Periodogram ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi....	45
Şekil 4.13: Periodogram ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi....	47
Şekil 4.14: Periodogram ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi	48
Şekil 4.15: Periodogram modelinin eğitim doğruluğu ve kayıp grafiği	49
Şekil 4.16: Welch ile DT sınıflandırma algoritmasının karışıklık matrisi.....	50
Şekil 4.17: Welch ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi	52
Şekil 4.18: Welch ile KNN sınıflandırma algoritmasının karışıklık matrisi	53
Şekil 4.19: Welch ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi	54

Şekil 4.20: Welch Modelinin Eğitim Doğruluğu ve Kayıp Grafiği.....	56
Şekil 4.21: Multitaper ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi	57
Şekil 4.22: Multitaper ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi.....	58
Şekil 4.23: Multitaper ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi.....	59
Şekil 4.24: Multitaper ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi..	60
Şekil 4.25: Multitaper Modelinin Eğitim Doğruluğu ve Kayıp Grafiği	62
Şekil 4.26: Dört Deneyin Sınıflandırma Algoritmalarının Doğruluk Performansı	65



SİMGELER VE KISALTMALAR LİSTESİ

<u>Simgeler</u>	<u>Açıklama</u>
Hz	Hertz
μV	Mikrovolt
%	Yüzde
<u>Kisaltmalar</u>	<u>Açıklama</u>
ADNI	Alzheimer's Disease Neuroimaging Initiative (Alzheimer Hastalığı Nörogörüntüleme Girişimi)
BCI	Brain Computer Interface (Beyin Bilgisayar Arayüzü)
BiLSTM	Bi-directional LSTM (Çift Yönlü LSTM)
BOLD	Blood Oxygen Level Dependent (Kan Oksijen Düzeyine Bağlı)
C	Merkezi
CKF-SVM	Conformal Kernel-Based Fuzzy Support Vector Machine model (Konformal Çekirdek Tabanlı Bulanık Destek Vektör Makinesi modeli)
CLC-KSVD	Correlation-based Label Consistent K-SVD (Korelasyona Dayalı Label Tutarlı)
CN	Cognitively Normal (Bilişsel Olarak Normal)
CT	Computed Tomography (Bilgisayarlı Tomografi)
DA	Data Augmentation (Veri Arttırma)
DT	Decision Tree (Karar Ağacı)
DWT leaders	Discrete Wavelet Transform Leaders (Ayrık Dalgacık Dönüşümü Liderleri)
ECP	Eigen-Complexity Pattern (Öz-Karmaşıklık Örüntüsü)
EEG	Electroencephalography
ELM	Extreme Learning Machine (Aşırı Öğrenme Makinesi)
ERP	Event-Related Potential (Olay İlişkili Potansiyel)
F	Frontal
fMRI	Functional Magnetic resonance imaging (Fonksiyonel Manyetik Rezonans Görüntüleme)
FN	False Negative (Yanlış Negatif)

Fp	Frontopolar
FP	False Positive (Yanlış Pozitif)
GRU	Gated Recurrent Unit (Geçitli Yinelene Birim)
GP	Gaussian process (Gauss Süreci)
HBB	Hafif Bilişsel Bozukluk
HMM	Hidden Markov Model (Gizli Markov Modeli)
K-SVD	K-means and Singular Value Decomposition (K-ortalamları Tekil Değer Ayrışımı)
KNN	K-Nearest Neighbor (K-En Yakın Komşu)
LDA	Linear Discriminant Analysis (Doğrusal Diskriminant Analizi)
LMCI	Late Mild Cognitive Impairment (Geç Hafif Bilişsel Bozukluk)
LSTM	Long Short-Term Memory (Uzun-Kısa Dönem Hafıza)
MCC	Matthews Correlation Coefficient (Matthews Korelasyon Katsayısı)
MCI	Mild Cognitive Impairment (Hafif Bilişsel Bozukluk)
MEG	Magnetoencephalography (Manyetoensefalogram)
MMSE	Mini Mental State Examinations (Mini Mental Durum Testi)
MRI	Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
MSPCA	Multiscale Principal Component Analysis (Çok Ölçekli Temel Bileşen Analizi)
O	Oksipital
P	Parietal
PCA	Principle Component Analysis (Temel bileşenler Analizi)
PET	Positron Emission Tomography (Pozitron Emisyon Tomografisi)
PSD	Power Spectral Density (Güç Spektral Yoğunluğu)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
SVM	Support Vector Machine (Destek Vektör Makinesi)
T	Temporal
TN	True Negative (Doğru Negatif)
TP	True Positive (Doğru Pozitif)



TEZ METNİ

GİRİŞ

HBB, psikolojik yaşlanma ile alzheimer hastalığının (AD) arasında bir ara aşama olarak tanımlanmaktadır ve Dünya Sağlık Örgütü (World Health Organization, WHO) tarafından Uluslararası Hastalık Sınıflandırması kapsamında “hafif kognitif bozukluk” sınıflandırma kategorisi içinde yer almaktadır. Hastalık tedavi edilmezse Alzheimer hastalığına dönüşür, bu nedenle demansın başlamasını geciktirmek için erken müdahale çok önemlidir. Bu, hastaların kısa süreli hafızasında gerilemenin yanı sıra son olaylarla ilgili unutkanlığın olduğu, ancak günlük işlevsellikte belirgin bir bozulma olmayan bir durumdur. Düşünme becerilerinde bozulma ve hafıza kaybına yol açabilecek yüksek bir Alzheimer hastalığı geliştirme riski vardır (Kasper, vd., 2020; Lu, vd., 2021). HBB’li hastaların yılda %10 ila %15 oranında demansa ilerlediği tahmin edilmektedir. HBB, Alzheimer hastalığının erken bir aşaması olması nedeniyle HBB’nin tespitinde erken müdahale, demansa dönüşümü yavaşlatmada önemli bir rol oynar. Her yıl dünya çapında yaklaşık 9,9 milyon insan bunama geliştirmektedir, ayrıca bunamanın 2030’da 75 milyona çıkacağı tahmin edilmektedir (Lombardi, vd., 2020; WHO, 2017).

HBB’li hastalar tipik olarak motor, bilişsel ve davranışsal semptomlarla ilgili problemler yaşarlar. Normalde, yaşlanmanın normal bir sonucu olarak kabul edilen semptomlar gösterirler veya bazen hiç semptom göstermezler. Ayrıca, değişikliklere ve dış stres faktörlerine uyum sağlamada zorluklarla karşılaşır. Sonuç olarak, davranış bozuklukları bir bakıcıya ihtiyaç duymalarını gerektirebilir (Baschi, vd., 2020). Bununla birlikte, hastanın bir Alzheimer hastasına dönüşmesini önlemek için hatırlama, düşünme ve konuşma becerileri gibi bilişsel yeteneklerin belirtileri incelenebilir. Bunun nedeni, erken müdahale yapılmazsa, semptomlar yavaş gelişme eğiliminde olduğundan ve Alzheimer hastalığının geç aşamasına dönüşecek kadar şiddetli hale geldiğinden, durumun hastanın günlük yaşamını etkileyecek kadar kötüleşmeye başlamasıdır. Hasta hafıza kaybı, hareket etme ve iletişim kurma yeteneği gibi önemli bilişsel bozukluklardan muzdarip olmaya başlayacaktır (Guo ve Zhang, 2020). Bu nedenle erken teşhis, gelecek klinik deneyler için hasta seçimine yardımcı olacaktır. Ayrıca hastaları yeni bir yaşam tarzı uygulamaya motive edecektir. Ayrıca, hastanın ailesine ve hastaların gelecekteki bakım ihtiyaçları için finansal planlama yapmalarına yardımcı olabilir (Sabbagh, vd., 2020; Kashefpoor, Rabbani ve Barekatin, 2019).

Genel olarak, HBB’li hastalara klinik bakımda, geçmiş geçmişleri kontrol edilerek ve mini mental durum testi (MMSE) ve montreal bilişsel değerlendirmesi gibi

nöropsikolojik incelemeler yapılarak teşhis konur. Tipik olarak, bu incelemeler görsel uzamsal yetenekler ve hafıza, dikkat ve hesaplama yetenekleri gibi beynin yürütücü işlevleri gibi çeşitli serebral bilişsel alanları değerlendirir (Chan, vd., 2021). Beyin bölümlerinde atrofiyi saptamak için manyetik rezonans görüntüleme (MRI), bilgisayarlı tomografi taraması (CT taraması), ve pozitron emisyon tomografisi (PET) gibi laboratuvar testleri ve beyin görüntüleme incelemeleri gibi başka testler de klinik bakımda gerçekleştirilir. Ayrıca, bu testler tipik olarak sağlık uzmanları tarafından yüz yüze uygulanır ve daha yaşlı hastaların uygulama etkilerinden kaynaklanan yanlılık nedeniyle, testlerin bazen birden çok kez uygulanması gerekir. Tekrarlanan uygulamalar, uzmanlar için iş yükünü, değerlendirme için ayrılan zamanı, maliyeti ve bekleme sürelerini artırmaktadır (Kasper, vd., 2020; Chan, vd., 2021). Bu nedenle, sağlık hizmetlerinin ilerlemesi için aktif karar desteği sağlamak üzere araştırmacılar, derin öğrenme ve makine öğrenimi modelleri ile bilgisayarlı bilişsel değerlendirme kullanarak tahmine dayalı modelleme teknikleri geliştiriyor, böylece tıbbi maliyetleri azaltıyor ve yorgunluğun neden olduğu insan hatalarıyla başa çıkıyor (Battineni, vd., 2020).

Doğru ve güvenilir bir HBB teşhisi, Alzheimer hastalığının önlenmesini optimize etmede önemli bir anahtar unsur olarak kabul edilmektedir (Kashefpoor, Rabbani ve Barekatin, 2019). Tıbbi bakımdaki hastaların nörogörüntüleme teknikleri kullanılarak kontrol edilmesine yönelik normal yöntemlerin uygulanması, performansı demansın geç aşamasıyla sınırlı olduğundan, HBB'nin erken saptanmasında maliyet etkin ve daha az etkilidir. Ayrıca, bu yöntemlerden bazıları zararlı olan radyasyona maruz kalmayı içerir. Yukarıda bahsedilen pahalı yaygın teşhis tekniklerinden kaçınmak için, son zamanlarda araştırmacılar makine öğrenimi ve derin öğrenme modelleri gibi tahmine dayalı modelleme teknikleri geliştiriyorlar. Bu modeller, etkinlikleri ve EEG sinyalleri ile daha yüksek algılama performansları nedeniyle artık birçok tıbbi alanda yaygın olarak kullanılmaktadır. Bu nedenle, bu tezde HBB tespiti için derin öğrenme ve makine öğrenmesi modelleri kullanılmıştır. EEG sinyalleri hastanın beyin aktivitesi hakkında HBB tespiti için yeterli bilgi sağladığından (Alden, vd., 2021; Lu, vd., 2021), EEG tabanlı bir yaklaşım benimsenmiştir. EEG sinyallerinin yakalanması işlemi, akıl hastalıklarının teşhisinde kullanılan bir EEG cihazı kullanılarak, genellikle beyin fonksiyonlarını yakalamak için hastanın kafasına takılan bir başlık kullanılarak yapılır. Ayrıca, EEG tabanlı tekniğin, yukarıda belirtilen diğer tanı yaklaşımlarına kıyasla nöropsikolojik bozuklukların teşhisi için etkili, ucuz ve köklü bir strateji olduğu iyi bilinmektedir (Hsiao,

vd., 2021a; Rivera, vd., 2022). Bu nedenle, EEG sinyallerinin derin öğrenme ve makine öğrenme modelleriyle birlikte kullanılması tanının doğruluğunu artıracak ve HBB'nin erken saptanması için bir çözüm olacaktır.

Bu tez çalışmasında, DWT liderleri, spektral analiz ve derin öğrenme modeli kullanılarak HBB'nin daha yüksek doğrulukla ve etkili bir şekilde EEG tabanlı sınıflandırılması için çözüm önerilmektedir. Önerilen bu derin öğrenme modelinin ana hedefleri ve katkıları aşağıda özetlenmiştir:

- a) HBB'nin tanısında Multitaper spektral analizi ile çift yönlü uzun kısa dönem hafıza (BiLSTM) derin öğrenme algoritmasını bütünleştiren model, deneyler sonucunda en yüksek performansı göstermiştir. Önerilen derin öğrenme modeli %98.97 doğruluk, %98.34 duyarlılık, %99.67 özgüllük, %99.70 kesinlik, %99.02 f1 skoru ve %97.94 Matthews Korelasyon Katsayısı (MCC) değerleri ile ilgili literatürdeki diğer yöntemlere göre daha yüksek ve umut verici bir performans elde etmiştir.
- b) Çalışmada, çok ölçekli temel bileşen analizi (MSPCA) kullanılarak ham EEG sinyallerinden gürültünün temizlenmesi sınıflandırma başarısını artırmıştır.
- c) Multitaper yönteminin kullanılarak özniteliklerin çıkarılması veri kaybını önlemiş ve tahmin yanlılığını azalmıştır.
- d) Sınıflandırma performansı, 10 katlı çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir. Bu yöntem, modelin birden fazla eğitim-test grubu ile eğitilmesine izin verdiği için aşırı uyumun (overfitting) üstesinden gelir, yanlılığı ve hatayı azaltır.
- e) Veri kümesinin büyük olduğu durumlarda geleneksel makine öğrenmesi algoritmaları yetersiz kalırken, çalışmada kullanılan BiLSTM derin öğrenme algoritması kaybolan gradyanlar sorununa çözüm sunması avantajı nedeniyle yetersiz kalmamış ve yöntemin başarısını artırmıştır.



BİRİNCİ BÖLÜM
LİTERATÜR ÇALIŞMALARI

1.1. İLGİLİ LİTERATÜR ÇALIŞMALARI

Farklı modelleme teknikleri ve öznitelik çıkarma yöntemleri kullanılarak HBB'nin tespiti için çeşitli çalışmalar yapılmıştır.

Hsiao vd. (2021b) tarafından gerçekleştirilen çalışma, HBB ve normal grupları ayırt etmek için konformal çekirdek tabanlı bulanık destek vektör makinesi modeli (CKF-SVM) kullanan bir sınıflandırma modeli önermiştir. 24 HBB ve 27 sağlıklı kontrolden oluşan EEG tabanlı bir dinlenme durumu veriseti kullanmışlardır. İlk olarak, örnek entropiyi ve katz'in fraktal boyut özniteliklerini çıkarmak için bir öznitelik füzyon çerçevesi ve öznitelik çıkarma yöntemleri kullanmışlardır. Daha sonra, CKF-SVM ve doğrusal diskriminant analizi (LDA) kullanılarak sınıflandırmışlardır. HBB olmayanlardan HBB'yi tespitinde, CKF-SVM ile birleştirilmiş ECP özelliğini kullanan model %90.19 ile en yüksek doğruluk elde etmiştir.

Geng vd. (2022), 20 HBB ve 20 sağlıklı kontrol gruplarından uyku esnasında kaydedilen EEG sinyallerinin HBB'yi teşhis etmek için kullanılıp kullanılmayacağını araştırmışlardır. EEG sinyallerinden uyku içcikleri özniteliklerini (sleep spindles features) ve uyku yavaş dalgalarını çıkarmışlardır. Daha sonra spektral ve karmaşıklık öznitelikleriyle birleştirmişlerdir. Buna göre, HBB'yi tespit etmek için geçitli yinelenen birim (GRU) ağını ve destek vektör makinesi (SVM) sınıflandırıcısını kullanmışlardır. Deneysel sonuçları, GRU ağının %93.46 ile en yüksek doğruluğa ulaştığını göstermiştir. Yaptıkları deneye göre, uyku EEG sinyallerinin HBB'nin sağlıklı kontrol gruplarından ayırımı için avantajlı bilgiler sağlayabileceği sonucuna varmışlardır.

Khatun, Morshed ve Bidelman (2019), Speech-Uyarılmış beyin yanıtları aracılığıyla tek kanallı EEG tabanlı bir yaklaşım kullanarak HBB'nin tanımlanması için oldukça farklı bir model önermişlerdir. Çalışmada düzenli ev tabanlı hasta izleme için uygun ve aynı zamanda taşınabilir bir model geliştirmek amaçlanmıştır. 8 HBB ve 15 normal, beş işitsel konuşma sinyaliyle etkinleştirilen ve yaşları 52-86 arasında değişen bir EEG veriseti kullanmışlardır. Yanıtın zaman ve spektral alan özniteliklerini içeren öznitelikleri çıkarmak için olay ilişkili potansiyel (ERP) kullanmışlardır. Rastgele orman yöntemi kullanılarak, ERP kullanılarak çıkarılan 590 öznitelik arasından 25 öznitelik seçilmiştir. Daha sonra bu 25 öznitelik, HBB'li bireyleri saptamak için sınıflandırma modelleri kullanılmıştır. Sonuç olarak, birini dışarıda bırak çapraz doğrulama yöntemini

kullanarak modellerini test etmişler ve %87.9 doğruluk elde etmişlerdir.

Forouzannezhad vd. (2020), bilişsel olarak normal (CN), EMCI, geç hafif bilişsel bozukluk (LMCI) ve Alzheimer hastalığı arasındaki karşılaştırmayı içeren bir Multimodal Nörogörüntüleme veri kümesi kullanarak HBB'nin erken (EMCI) tanısına odaklanmışlardır. Çalışmalarını yürütmek için, 896 katılımcıdan oluşan Alzheimer hastalığı nörogörüntüleme girişimi (ADNI) verisetini, gauss süreci (GP) modeli ve SVM sınıflandırma algoritmasını birlikte kullanmışlardır. Daha sonra, EMCI'nin tespiti için en etkili yaklaşımı araştırmak üzere bunları karşılaştırdılar. Sonuç olarak, GP modeli %78.8 doğrulukla en yüksek sınıflandırma performansını elde etmişlerdir ve EMCI'nin CN grubundan ayrıştırılabileceğini belirtmişlerdir.

Hadiyoso ve Tati (2018), sınıflandırma için Hjorth parametrelerini ve K-NN algoritmasını kullanan bir model önermişlerdir. Hareketlilik, karmaşıklık ve aktivitenin sinyal özelliklerini elde etmek için Hjorth parametrelerini kullanmışlardır. Veriseti 5 kontrol grubundan, ve 5 HBB hastası olmak üzere toplamda 10 katılımcıdan oluşmaktadır. İlk olarak -1 ile +1 arasındaki sinyalleri almak için ham EEG sinyallerini normalleştirdiler ve 0.5 ile 40 Hz arasındaki BPF filtrelerini kullanarak gürültü artefaktını azaltmışlardır. Araştırmaları sonucunda %80 doğruluk elde etmişlerdir. Test sonuçlarına göre, normal kişiler Hjorth parametreleri için genellikle HBB'li bireylerde daha yüksek değerlere sahiptir.

Alvi, Siuly ve Wang (2022), EEG Sinyallerinden HBB'nin erken tespiti için LSTM tabanlı bir çerçeve önermişlerdir. Önerilen model gürültü giderme, sementasyon, alt örnekleme, derin gizli özniteliklerin LSTM model tabanlı keşfi ve HBB hastalarının sigmoid sınıflandırıcı tabanlı tanımlanması aşamalarını içermektedir. Model performansları hakkında bir sonuca varmak için 20 farklı LSTM modeli tasarladılar ve 5 katlı çapraz doğrulama yöntemi kullandılar. Sonuç olarak, %96.41'lik bir doğruluk elde etmişlerdir.

Hadiyoso vd. (2019), k-en yakın komşuluk (KNN) sınıflandırma algoritması ile güç spektral özelliklerine dayalı EEG sinyallerinden HBB'nin erken tanısına yönelik bir çerçeve önermişlerdir. 11 HBB ve 16 normal grupları olmak üzere toplamda 27 katılımcıdan oluşan bir veriseti kullanmışlardır. Oksipital, temporal ve parietal elektrot alanlarındaki EEG sinyallerinin 27 deneğinin elektrot alanlarını gözlemlemişlerdir ve %81.5'lik bir doğruluk elde etmişlerdir.

Alvi vd. (2022)'a, gürültüyü çıkartmak için önce EEG sinyallerini ön işleme tabi tutarak çalışmalarını gerçekleştirmişlerdir. Ayrıca araştırmalarını yürütmek için 11 HBB ve 16 kontrol olmak üzere 27 gönüllü katılımcının EEG sinyallerinden oluşan bir veriseti kullanmışlardır. Daha sonra sinyalleri bölümlere ayırdılar ve ardından bunları LSTM, GRU, SVM ve KNN olmak üzere dört farklı sınıflandırma algoritmalarını çalıştırdılar. Daha sonra, performans değerlendirme ölçütlerini kullanarak dört modeli karşılaştırdılar ve çerçevelerini 5 katlı çapraz doğrulama yöntemi kullanarak değerlendirdiler. Sonuç olarak, GRU modeli %96.91 doğrulukla en yüksek performansı elde etmiştir.

Kashefpoor, Rabbani ve Barekatin'in (2019) çalışması, korelasyona dayalı tekil değer ayrışımı (K-SVD) yöntemini kullanarak yeni bir denetimli sözlük öğrenme geliştirdiler. Modelleri, K-ortalama ve K-SVD yöntemleri kullanılarak EEG sinyallerinin analizine dayanmaktadır. İlk olarak, EEG sinyallerinden, uygulanan frekans ve zaman alanlarından spektral özellikler çıkardılar. Daha sonra, her bir EEG sinyalinin tüm kanalları için nihai bir etikete sahip olmak için etiketler arasında oylamaya başladılar. Sonuç olarak, %88.9'luk bir doğruluk elde ettiler.

Yin vd. (2019) çalışması, spektral-zamansal analize dayalı bir entegre HBB tanı sistemi önerdi. Durağan dalgacık dönüşümünü kullanarak, EEG sinyallerinden gürültüyü çıkardılar. Daha sonra spektral-zamansal analiz kullanarak öznelik vektörlerini çıkardılar ve sonunda, optimal bir öznelik alt kümesi üretmek için yeni bir 3-D algoritması geliştirdiler. Ayrıca modeli sınıflandırmak için SVM, KNN ve karar ağacı (DT) algoritmalarını kullanmışlardır. SVM sınıflandırıcı algoritması en yüksek performansla sınıflandırmış ve %96.94 doğruluk elde etmiştir.

Jamalo, Mikaeili ve Noroozian (2020), gizli durumlara sahip bir model olan gizli markov modeli'ni (HMM) kullanarak HBB ve normal gruplar arasında ayırım yapmak için EEG sinyallerinin frekans bantlarını araştırmışlardır. İlk olarak EEG sinyallerini standart frekans bantlarına göre delta (0.5–4Hz), teta (4–8Hz), alfa (8–12Hz), beta (12–25Hz) ve gama (25–35 Hz) ayırmışlardır. Daha sonra, çapraz doğrulama yöntemini kullanarak onları eğitim, test, ve doğrulama setlerine ayırdılar. Sonuç olarak alfa ve gama frekans bantlarının %95.9±0.4 alfa ve %97.2±0.5 Gamma ile en yüksek sınıflandırma doğruluğunu elde ettiğini tespit etmişlerdir.

Kashefpoor, Rabbani ve Barekatin (2016), 19 elektrot kullanılarak 11 HBB ve 16 kontrol gruplarından kaydedilen EEG sinyallerinin dinlenme durumunu kullanarak mobil ve pahalı olmayan bir teşhis yaklaşımı önermişlerdir. Korelasyon tabanlı

algoritmaların, 19 spektral öznitelik seçerek ve ardından bunları her kanal için hesaplamışlardır ve EEG sinyallerinin en iyi ayırt edici özniteliklerini seçmede etkili olup olmadığını araştırmışlardır. Daha sonra bunları KNN algoritması ve nöro bulanık sistem kombinasyonunu kullanarak sınıflandırmışlar ve %88.89 doğruluk elde etmişlerdir.

Benzer şekilde Siuly vd. (2020), dinlenme durumundaki EEG sinyallerini kullanarak HBB'li hastaların otomatik tespitini gerçekleştirdi. İlk olarak, sinyallerdeki paraziti giderdiler, daha sonra güvenilir bir analize ulaşmak için parçalı toplama yaklaşımını kullanarak sinyallerin büyük hacmini bölütlediler ve sıkıştırdılar. Ayrıca, permütasyon entropisi ve oto-regresif model özniteliklerini araştırarak, EEG sinyallerindeki alternatif değişimin HBB ve sağlıklı kontrol grupları arasında başarılı bir şekilde ayırım yapıp yapamayacağını kontrol ettiler. Modellerinin sağlamlığını kontrol etmek için 10-katlı çapraz doğrulama yöntemi kullandılar ve sonunda, HBB'yi saptamak için en iyi sınıflandırma algoritmasını bulmak üzere SVM, Aşırı Öğrenme Makinesi (ELM) ve KNN makine öğrenmesi algoritmalarını kullanmışlardır. Sonuç olarak, ELM tabanlı yöntem %98.78 ile en yüksek performanslı sınıflandırma doğruluğuna ulaşmıştır.




İKİNCİ BÖLÜM
GENEL KISIMLAR

2.1. BEYİN BİLGİSAYAR ARAYÜZÜ (BCI)

BCI beyin aktivitesini kullanan harici cihazları kontrol etmek için hem donanım hem de yazılım iletişim yöntemlerini içeren, hızla büyüyen bir teknolojidir. Beyin sinyallerini toplar, işler ve bunları gerekli görevleri yerine getirmek için çıkış cihazlarına gönderilen komutlara dönüştürürler. Felçli hastalar gibi engelli kişilere yardımcı olmak, BCI temel teknolojisinin en temel kullanım amaçlarından biridir. Ayrıca serebral palsi, amiyotrofik lateral skleroz, inme veya omurilik yaralanması gibi nöromüsküler hastalıklar nedeniyle yetersiz kalanlar için fonksiyonel işlevi değiştirmek veya eski haline getirmek için kullanılırlar. Bir BCI cihazını çalıştırmak için her türlü beyin sinyali kullanılabilir. Ancak en sık kullanılan sinyaller, voltaj veya iyon kapılı kanalların aktivasyonu sonucu nöronlardaki postsinaptik membranların polaritesindeki değişikliklerle üretilen elektrik sinyalleridir. Bir BCI sisteminin bileşenleri Şekil 2.1’de gösterilmektedir (Abhang, Gawali ve Mehrotra, 2006; Shih, Krusienski ve Wolpaw, 2012).

Şekil 2.1: BCI sisteminin bileşenleri



Kaynak: Shih, Krusienski ve Wolpaw, 2012; Houssein, Hammad ve Ali, 2022.

BCI sistemi sinyal alımı, sinyal ön işleme, öznitelik çıkarımı, sınıflandırma ve uygulama arayüzü olmak üzere temel olarak beş ana birimden oluşmaktadır.

2.1.1. Sinyal Alımı

Kafa derisine yerleştirilen bir elektrot kullanılarak EEG cihazı gibi elektriksel kayıt teknikleri kullanılarak beyinden elektrik sinyalleri toplanır ve daha sonra bu sinyaller dijitalleştirilir. BCI sistemlerinde, beyin aktivitesini izlemek için çeşitli teknikler, manyetik rezonans görüntüleme (MRI), pozitron emisyon tomografisi (PET), bilgisayarlı tomografi (CT) ve fonksiyonel manyetik rezonans görüntüleme (fMRI) gibi çeşitli teknikler bulunmaktadır. Ancak EEG sinyali alımı bunların arasında yer alır, bunun nedeni uygun zamansal çözünürlüğüdür ve hastanın herhangi bir güçlü dış manyetik veya elektrik alana maruz kalmamasıdır. Ayrıca EEG, beyin aktivitesini izlemek için en pratik, ekonomik ve invaziv olmayan yöntemdir (Shad, Molinas ve Ytterdal, 2020).

MRI, noninvaziv bir nörogörüntüleme tekniğidir. MRI sinyallerinin fonksiyonel beyin kaynağını lokalize etmek için kafadaki manyetik akıyı kaydederek kortikal aktivitenin dinamik özelliklerinin incelenmesini sağlar. MRI, beyin cerrahisi alanını ameliyat öncesi planlamada ve ayrıca beyin bölgelerinde ameliyat gerçekleştirilmede onlara yardımcı olmak için desteklemek için yararlı bir tekniktir. Ayrıca MRI, başın tamamını çevreleyen sensör dizilerini kullanarak beynin manyetik aktivitesini aynı anda kaydederek, alzheimer ve parkinson hastalarında anormal salınım aktivitesinin anormal modellerinin farklı frekans bantlarını belirlemiştir (Wheless, vd., 2004; Stam, 2010; Da Lopes Silva, 2005).

PET bir klinik görüntüleme aracıdır ve hastayı, görüş alanının dışından gelen radyasyona karşı orta kalınlıkta, kurşun uç kalkanlarla korunan silindirik bir dedektör halkasıyla çevreleyerek çalışır. PET taraması, hedef organın alınmasını ve taşınmasını sağlamak için birkaç saniye veya dakika sonra başlar. Daha sonra süreç bir radyofarmasötüğün enjeksiyonu veya inhalasyonu ile başlar, radyoaktif izotop, bozunması sırasında maddeden geçmek için pozitronlar, pozitif elektronlar yayar, kinetik enerjisini yayarak maddedeki elektronla karşılaşarak onunla etkileşime girer, onu yok eder ve geri kalanını serbest bırakır, iki foton olarak enerji (Ollinger ve Fessler, 1997; Wagner Jr, 1998). PET'in onkolojik görüntülemedeki başlıca avantajlarından biri, tüm vücut taraması ile hastalığın aktivitesini ve yayılımını doğru bir şekilde ölçebilmesidir (Anand, Singh ve Dash, 2009). PET'in kanser teşhisi ve tedavisi, nöroloji, psikiyatri, kardiyoloji

ve kalp cerrahisi gibi çeşitli klinik uygulamaları vardır (Maisey, 2005).

CT taraması, acil serviste kafa travması olan hastaların ve kafa travması geçirmiş hastaların yanı sıra felce işaret edebilecek semptomları olan hastaların ilk görüntülemesinde bir tanı aracı olarak en sık kullanılan tekniktir. Bunun nedeni, düşük edinme süreleri ve hasta hastaneye geldiğinde onu birinci basamak tanı yöntemi haline getiren geniş kullanılabilirlikleridir. Ayrıca CT, daha hızlı CT tarayıcılar ve sarmal yöntemler nedeniyle giderek daha popüler hale gelmiştir (Chilamkurthy, vd., 2018; Mettler, vd., 2000). CT tarama işlemi, hastayı, bir x-ışını kaynağının ve 180 derece ayrı yerleştirilmiş dedektörün CT taramasının deliğinden tünele kayan dar motorlu bir masaya yatırarak çalışır. Daha sonra sürekli algılama için hastanın etrafında 360 derece hareket eder ve vücuttan geçerken x-ışınlarının zayıflamasıyla ilgili verileri aktarır (Perron, 2008).

fMRI, görev sırasında beynin hangi bölümünün aktif olduğunu kontrol ederek beynin bir tür görevi yerine getirirken sorumlu olan alanını araştırmak için invaziv olmayan benzersiz bir yöntemdir. Kan oksijenasyonundaki değişiklikleri gösteren “kan oksijen düzeyine bağlı” (BOLD) adı verilen bir fenomen tarafından kontrol edilir. Normalde beyinde kan akışının arttığı bölgeye bakmak, kanın oksijen içeriğinin daha yüksek olduğunun bir göstergesidir. Genel olarak hemoglobin, yüksek seviyede oksijen taşıırken herhangi bir bozulma oluşturmadan manyetik alandan geçebilir ve oksijeni bittiğinde manyetik alandan geçemez ve içinden geçtiği herhangi bir manyetik alanı bozar. Bu nedenle, MRI görüntüsü damarların oksijeni boşaltan bölgelerini gösteren küçük siyah bir çizgi gösterir. BOLD fMRI yöntemlerinin bir uyarı sonrası nöronal aktiviteyi incelemek için kullanılan st-fMRI, ciddi ilaç sorunlarına tepki olarak phMRI ve dinlenirken rsfMRI gibi farklı türleri vardır. Günümüzde fMRI, dünyanın manyetik alanından binlerce kat daha büyük olan daha güçlü manyetik alanı nedeniyle saptamadaki etkinliği nedeniyle dünyadaki çoğu laboratuvarında kullanılmaktadır (Logothetis, 2008; Bizzi, vd., 2009; Jonckers, vd., 2015).

EEG sinyalleri epilepsi, beyin tümörleri ve beyin ölümü gibi beyin hastalıklarının saptanmasında ve tedavisinde önemli bir rol oynar. EEG sinyalleri, hastalığın teşhisini desteklemek için korteksteki kaynakların zamansal, uzaysal ve spektral özellikler gibi çeşitli katkılarını gösteren katılımcının başının farklı uzaysal konumlarına yerleştirilen bir elektrot kullanılarak toplanır (Lenartowicz ve Loo, 2014). EEG elektrotları, 10-20 uluslararası elektrot yerleştirme sistemi kullanılarak başın kafa

derisine yapıştırılır. Kişinin kafa büyüklüğüne göre burun ve kulak arasında orantılı bir mesafe kullanılarak elektrotlar birbirinden %10 veya %20 oranında ayrılır. EEG sistemi 256 kanala kadar sahip olabilir ve elektrotlar, her elektrotun baştaki konumlarını belirten bir harften oluşan bir isme sahip olduğu bitişik beyin bölgelerine göre yerleştirilir: F (frontal), Fp (frontopolar), C (merkezi), T (temporal), P (parietal), O (okspital) ve tek sayılar kullanılarak sol yarım küreyi veya çift sayılar kullanılarak sağ yarım küreyi gösteren bir sayıdır (Britton, vd., 2016; Teplan, 2002).

2.1.2. Sinyal Ön İşleme

Sinyal ön işleme aşamasında, sinyaller sonraki işleme için uygun bir formata dönüştürülür. Sinyal ön işleme aşaması, EEG cihazından kaynaklanan artifaktları, harici gürültüleri ve kafa hareketi gibi biyolojik artifaktları ortadan kaldırmayı içermektedir. Bu artefaktların nedeni, EEG sinyallerinin doğası gereği zayıf olması ve hem iç hem de dış kaynaklardan gelen gürültüden kolaylıkla etkilenebilmesidir. Sinyal ön işlemenin amacı, sinyalleri öznitelik çıkarma aşamasına hazırlamak için sinyal geliştirme ve gürültü azaltmadır. Gürültü artefaktları ortadan kaldırmak için Bağımsız Bileşen Analizi gibi analizler, yüksek veya düşük geçiş filtresi gibi çeşitli yöntemler kullanılabilir (Houssein, Hammad ve Ali, 2022).

2.1.3. Öznitelik Çıkarma

Öznitelik çıkarma aşamasında ilgili sinyal öznitelikleri çıkarılır. Bu aşama, toplanan beyin sinyallerindeki ayırt edici verileri tanımlar. Sinyal ölçüldüğünde, gözlemlenen sinyallerden faydalı ve ayırt edici özellikler içeren bir vektör üzerine çizilir. Bu, ilginç bilgilerin çıkarılmasını içerdiğinden zorlu bir süreçtir. Öznitelik çıkarma aşamasında, önemli bilgileri kaybetmeden öznitelik sistem karmaşıklığını azaltmak için daha düşük boyutlu bir öznitelik vektörü oluşturulur. Beyin sinyallerini ölçmek için birden fazla kanal kullanılabilir. Ölçülen kanalların sağladığı verilerin tümü genellikle anlamlı değildir. PCA gibi boyut küçültme teknikleri kullanılarak gereksiz ve alakasız bilgiler çıkarılarak orijinal verilerin boyutu azaltılabilir (Shih, Krusienski ve Wolpaw, 2012; Nicolas-Alonso ve Gomez-Gil, 2012).

2.1.4. Sınıflandırma

Sınıflandırma aşamasında öznitelik vektörleri kullanılarak sinyaller sınıflandırılır. BCI'de sınıflandırma adımının kullanılmasının nedeni, öznitelik adımının sağladığı beyin aktivitesini tanımlayan bir özellik vektörüne dayalı olarak kullanıcının

niyetini belirlemektir. Bu amaç, regresyon veya sınıflandırma algoritmaları SVM gibi kullanılarak gerçekleştirilebilir. Bu nedenle, etkili örüntü tanıma elde etmek ve kullanıcının niyetini anlamak için çok önemli olan kaliteli ayırt edici özneliklerin seçilmesi (Nicolas-Alonso ve Gomez-Gil, 2012).

2.1.5. Uygulama Arayüzü

Kontrol arayüzü aşaması, şifrelenmiş sinyalleri bilgisayar veya tekerlekli sandalye gibi herhangi bir bağlı cihaz için komutlara dönüştürür ve çevirir, böylece komut cihaz tarafından yapılır. Genel çerçeve, kullanıcı ve BCI sistemi iş birliği yapar. Hem kullanıcı hem de BCI eğitilir, onları eğittikten sonra, kullanıcı amacı kodlayan beyin sinyalleri üretir ve BCI sinyalleri çözerek robotik el hareketi ve çevre kontrolü gibi kullanıcının amacını gerçekleştiren bir çıkış cihazı için talimatlara dönüştürür, gerekli eylemi yaptıktan sonra cihaz, kontrolün kapatılabilmesi için kullanıcıya geri bildirimde bulunur (Shih, Krusienski ve Wolpaw, 2012).

2.2. ELEKTROENSEFALOGRAFİ (EEG) SİNYALLERİ

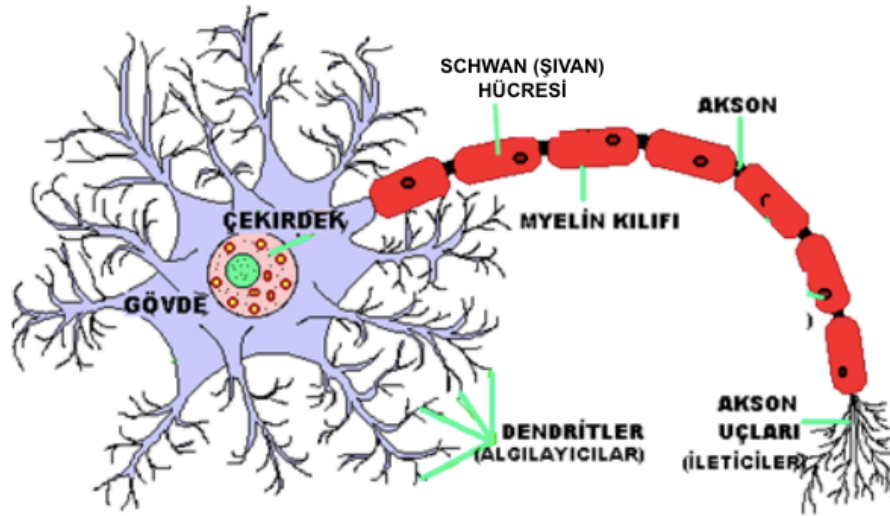
EEG, serebral korteksteki beyin hücrelerinin elektriksel aktivitesidir. EEG sinyal edinimi ise, beynin başına yerleştirilen bir dizi elektrotla sağlıklı ve sağlıklı sinir ağı aktivitesini yansıtan, beyin aktivitesinin elektriksel analizini kaydetme yöntemidir (Bourel-Ponchel, vd., 2021; Sun, vd., 2020). Son birkaç yılda nörolojik hastalıkların prevalansında bir artış oldu ve bunları tespit etmek, genişleyen teknoloji sektörü için bir zorluk haline geldi. Bununla birlikte, EEG cihazı gibi ileri teknolojilerin yardımıyla, sağlıklı bir sinir ağını sağlıklı bir sinir ağından ayırt etmek artık mümkündür (Singh, vd., 2023). Beyin aktivitesini izlemek için çeşitli teknikler, manyetik rezonans görüntüleme (MRI), pozitron emisyon tomografisi (PET), bilgisayarlı tomografi (CT) ve fonksiyonel manyetik rezonans görüntüleme (fMRI) gibi kullanılabilir. Ancak EEG sinyali alımı bunların arasında yer alır, bunun nedeni uygun zamansal çözünürlüğüdür ve hastanın herhangi bir güçlü dış manyetik veya elektrik alana maruz kalmamasıdır. Ayrıca EEG, beyin aktivitesini izlemek için en pratik, ekonomik ve invaziv olmayan yöntemdir (Shad, Molinas ve Ytterdal, 2020).

2.2.1. EEG Sinyallerinin Kaydedilmesi

EEG cihazı, elektrot adı verilen kafa derisi üzerine yerleştirilen iletken bir malzeme ile kafa derisinden geçerken beyindeki elektrik akımlarını kaydeder. Elektrik akımı Na^+ , K^+ , Ca^{++} ve Cl^- iyonlarının nöron adı verilen sinir hücrelerinden

pompalanmasıyla oluşur (Shad, Molinas ve Ytterdal, 2020). Nöronlar bilgi habercileridir, elektriksel bir dürtü kullanarak vücut ve beyin arasında bilgi iletirler (NINDS, 2002). Tipik bir Nöron, hücre gövdesi, akson ve dendrit olmak üzere üç temel parçaya sahiptir. Hücre gövdesi içinde, hücrenin genetik materyalini depolayan ve hücrenin aktivitelerini kontrol eden bir çekirdek (soma) vardır. Çekirdeği takip eden uzun bir kuyruğa benzeyen akson, hücreden gelen sinyalleri diğer nöronlara taşıyan ve 0.1 mm ile 3 m arasındaki mesafelerde sinyaller ileten ana birimdir. Bir ağacın dallarına benzeyen dendritler, diğer sinir hücrelerinden sinyaller alarak hücrenin iletişim alıcıları olarak görev yaparlar. Bu nedenle nöronlar, sinaps olarak bilinen bir bölge olan aksonları ve dendritleri arasındaki dar bir boşluk boyunca nörotransmitterler olarak bilinen kimyasalları aktararak birbirleriyle iletişim kurarlar (NINDS, 2002; Kandel, 1991). Schwann (Chivan) hücreleri, aksonun etrafını saran ve miyelin kılıfı adı verilen, izolasyon sağlayan ve böylece iletim hızını artıran bir örtü hücresi oluşturan hücrelere verilen isimdir. İki Schwann hücresi arasındaki bölgeye Ranvier düğümü denir ve işlevi, aksiyon potansiyellerinin akson boyunca hareketini hızlandırmak için saltatuar iletimi kullanmaktır (Üngüren, 2015).

Şekil 2.2: Bir Nöronun Yapısı



Kaynak: Üngüren, 2015.

Aksonları ve dendritleri arasında bir nöronun diğerine elektriksel impulsların iletilmesiyle bir aksiyon potansiyeli oluşur. Sonuç olarak, aynı yüke sahip komşu iyonları iten bir iyon havuzunu ifade eden hacim iletimi adı verilen iyonik yükün elektriksel ateşlemesi üretilir. Bu nedenle, itilen bu iyonların aynı yüke sahip diğer iyonları itmesi sonucu hücre dışı boşlukta yayılan bir yük dalgası yaratmak. Nöronal ateşleme tarafından üretilen elektrik sinyali, beyinden dura katmanları, kafatası katmanları, kafa derisi ve son

olarak başın dışındaki bir elektrotla ölçülecek elektrota gitmelidir. Hacim iletimi yoluyla iletilen sinyal hacmin kenarına ulaştığında iyonlar hacimden çıkamadığı için hacim iletimi durur. Bu nedenle, sinyalin iletiminden sorumlu olan bir kapasitans biçimi olan hacimler arasında bir kapasitif iletim olgusu meydana gelir. Sinyal kafatasına ulaştığında, kafatası sinyal ile elektrot arasında zayıf bir iletken görevi gören iyonların geçişini engellediğinden iyonlar sinyali aktaramaz. Bununla birlikte, bir elektrot jeli kullanılarak, kıllar arasındaki hava boşlukları ve elektrotun altındaki alan jöle tarafından doldurulup doyurulur, böylece iletken bir malzeme görevi görür. Yüksek düzeyde iletken elektrot jeli, kafa derisinden elektrota iletken bir kanal sağlayarak kafatasından elektrotlara sinyallerin aktarılmasını sağlar. (Jackson ve Bolger, 2014).

2.2.2. EEG Sinyallerinin Kaydedilmesine Etki Eden Faktörler

EEG sinyallerinin toplanması sırasında, çeşitli faktörler EEG sinyallerinin toplanmasını etkiler, bu faktörler dış veya iç olabilir.

2.2.2.1.Dış Gürültü

Dış gürültü, diğer elektromanyetik ekipmanların neden olduğu gürültüdür. Normalde kaynaktan ölçüme olan mesafe arttıkça, elektrik alanının gücü üstel olarak düşer. Bu nedenle beyinden gelen sinyaller, binanın elektrik şebekesi, duvarlardaki akım taşıyan teller, ışıklar, tavan, bilgisayar ekranı gibi dış etkenler tarafından üretilen sinyallerle karşılaştırıldığında, sinyaller en gürültülü gürültü kaynağıdır ve bu nedenle elektrotlardan ve elektrot uçlarından ne kadar uzakta olduklarıyla orantılı olarak ölçülen gürültüyü etkiler. Bununla birlikte, bu dış etkenlerin gürültüsü, aktif bir elektrot ve odanın veya elektrot kablolarının pasif bir şekilde korunmasıyla azaltılabilir (Cai, vd., 2018; Jackson ve Bolger, 2014).

2.2.2.2.İç Gürültü

EEG sinyallerinin toplanması sırasında, sinyali etkileyen dahili bir gürültü vardır. Bu sesler vücudun katılımcısı tarafından üretilir ve göz kırpması, baş hareketi, nefes alma kasılması, kas gerginliği, terleme ve diğer eylemler gibi vücut rahatsız olduğunda kaçınılması mümkün değildir. Ancak bu faktörler ortadan kaldırılamasa da katılımcı davranışının ve çevre koşullarının yönetimi ile hatta bir filtreleme yöntemi kullanılarak bu gürültü kaynakları bir ölçüde azaltılabilir (Cai, vd., 2018; Jackson ve Bolger, 2014).

2.2.3. EEG Dalga Biçimleri

EEG dalga biçimleri, beyin yüzeyinde meydana gelen elektriksel aktivitenin EEG makinesinin ekranında görünen temsilidir. EEG dalga biçimleri genellikle frekanslarına, genliklerine, elektrotun kafa derisi üzerindeki konumuna ve diğer özniteliklerine göre sınıflandırılır, ancak tamamen kişinin uyanıklık durumuna ve yaşına bağlıdır. Bir öznenin dalga biçiminin, EEG dalga biçimi özelliğine göre normal veya anormal olduğu söylenir. EEG dalga formu, deneğin farkındalık düzeyine, yaşına veya diğer parametrelere karşılık gelmeyen uzun veya sık nöbetler gibi beklenmedik öznitelikler gösterdiğinde anormal olduğu ve EEG kaydında olağandışı nöbetler olmadığında normal olduğu söylenir (Medithe ve Nelakuditi, 2016).

2.2.4. EEG frekans bantları

EEG sinyalinin geniş bir frekans bandı aralığı vardır, ancak klinik alaka düzeyine bağlı olarak beş frekans bandı aralığı vardır, delta (0,5–4 Hz), teta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) ve gama (>30 Hz) frekansları. EEG ritim dalga biçimleri aşağıdaki şekillerde gösterilmektedir.

2.2.4.1. Delta


Delta dalgalarının frekansı 0.5 ila 4 Hz arasında değişir ve 20 ila 400 μ V arasında büyük bir genliğe sahiptir. Delta dalgaları, kişinin derin veya rüyasız uykudayken olduğu gibi bilinçsiz bir durumda ortaya çıkar, ancak bu dalga, deneğin kaydının uyanık yetişkininde bulunmamalıdır ve bu durum bulunursa anormal kabul edilir ve bir tümörün varlığını gösterebilir (Medithe ve Nelakuditi, 2016).

Şekil 2.3: Delta Ritim Dalga Formu




2.2.4.2. Teta

Teta dalgası frekansı 4 ila 8 Hz arasında değişir ve 5 ila 100 μ V arasındaki beta dalgasından daha büyük bir genliğe sahiptir. Teta dalgaları bilinçaltı ile ilişkilendirilir ve hayal kurmada ve başlangıçtaki uyuşukluk halinde ortaya çıkar, ancak bu durum uyanık olan yetişkinlerde bulunursa anormal kabul edilir (Wang ve Wang, 2021; Medithe ve Nelakuditi, 2016).

Şekil 2.4: Teta Ritim Dalga Formu**2.2.4.3. Alfa**

Alfa aktivitesi tetadan daha fazla güce sahiptir ve dalga frekansı 8 ila 13 Hz arasındadır. Genliği genellikle $50\mu V$ 'den azdır ve kişi rahat ama bilinçli durumdayken ortaya çıkar. Bu dalga beynin ön bölgelerinde bulunursa anormalliği tahmin edecek ve kişinin kafa travması, depresyon veya dikkat sorunları yaşayabileceğini belirtecektir (Read ve Innis, 2017; Medithe ve Nelakuditi, 2016).

Şekil 2.5: Alfa Ritim Dalga Formu**2.2.4.4. Beta**

Beta dalgalarının frekansı 13 ile 30 Hz arasında değişir ve küçük bir simetrik genliğe sahiptir. Beta dalgaları, insan zihni aktif ve yoğun bir şekilde odaklandığında ortaya çıkar, ancak düşük beta seviyeleri varsa bu, konsantrasyon eksikliğine ve problem çözme sorunlarına, yüksek beta dalgaları ise hiperaktiviteye ve uyku bozukluklarına işaret eder (Medithe ve Nelakuditi, 2016).

Şekil 2.6: Beta Ritim Dalga Formu**2.2.4.5. Gama**

Gama dalgası frekans aralığı 30 ila 80 Hz arasındadır ve küçük bir genliğe sahiptir. Gama dalgaları, motor fonksiyonlar ve yüksek zihinsel aktivite sırasında aktif duyuşal işlemeyi gösterir. Ancak bu durum uzun süre görülüyorsa bir anormallik belirtisidir (Cohen, 2017; Medithe ve Nelakuditi, 2016).

Şekil 2.7: Gama Ritim Dalga Formu

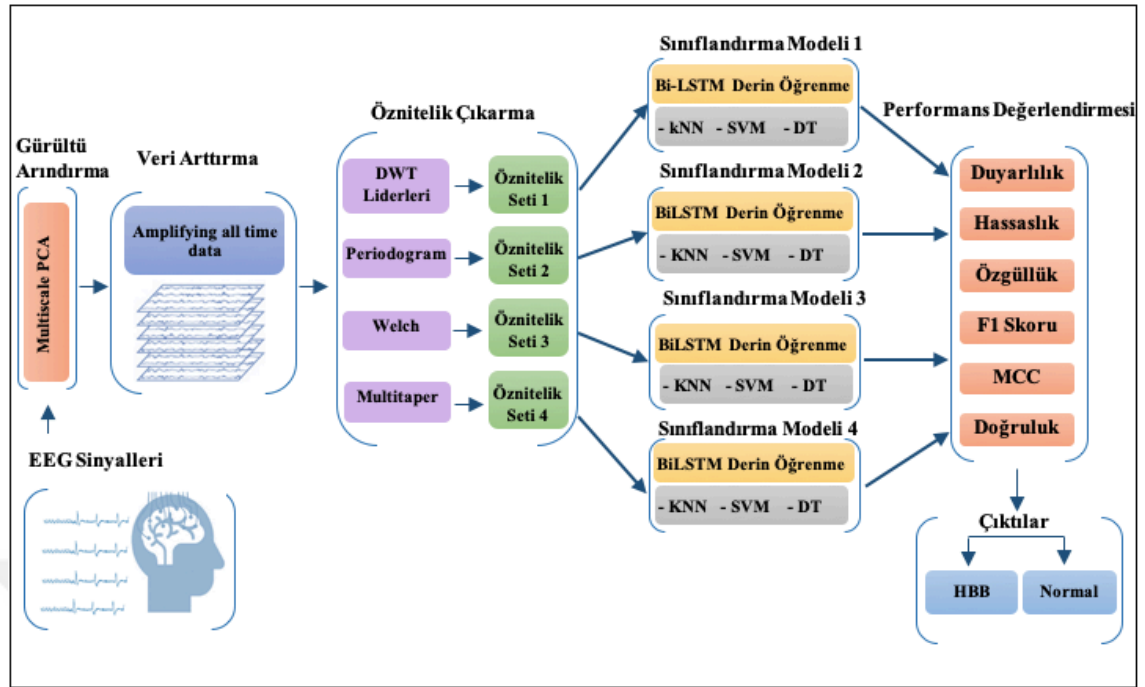


ÜÇÜNCÜ BÖLÜM
MATERYAL VE METOD

3.1. ÖNERİLEN DERİN ÖĞRENME MODELİ

Bu tez çalışmasında HBB hastalarını tespit edebilen bir model geliştirilmiştir. Önerilen derin öğrenme modeli, Şekil 3.1’de gösterildiği gibi yedi aşamadan oluşur. Kullanılan EEG verisetinde, sabah saatlerinde EEG başlığı kullanılarak katılımcıların beyin sinyalleri alınmış ve sinyal toplama sürecinde her katılımcı sessiz bir odada gözleri kapalı olarak dinlenme halinde tutulmuştur (Kashefpoor, Rabbani ve Barekatain, 2019). Daha sonra 256 Hz örnekleme frekansı kullanılarak EEG işaretlerinden artefakt gürültülerden kurtulmak ve analiz gücünü artırmak için gürültü giderme işlemi yapılmıştır. Gürültü giderme aşamasında MSPCA kullanıldı. Gürültü giderme aşamasından sonra, veri kümesi üzerinde Veri Artırma (DA) gerçekleştirilerek veri kümesinin miktarı üç katına çıkarılmıştır. Bir sonraki aşama öznitelik çıkarma yöntemidir. Dört farklı öznitelik çıkarma yöntemi, Ayrık Dalgacık Dönüşümü Liderleri (DWT liderleri), Periodogram, Welch ve Multitaper spektral analiz yöntemleri kullanılmıştır. DWT liderleri kullanılarak EEG sinyallerinin öznitelik vektörleri çıkarılmış ve Periodogram, Welch ve Multitaper olarak adlandırılan güç spektral analiz yöntemleri kullanılarak EEG sinyallerinden sinyallerin Güç Spektral Yoğunluğu (PSD) öznitelikleri çıkarılmıştır. Öznitelik çıkarma işleminden sonra, verisetini eğitim ve test setlerine ayırmak için 10-kat çapraz doğrulama yöntemi kullanıldı. Son aşamada ise, öznitelik vektörleri kullanılarak DT, SVM ve KNN algoritmalarını kullanan makine öğrenme modeli ve BiLSTM derin öğrenme algoritmasının performansları karşılaştırıldı. Bunları sınıflandırdıktan sonra, performans değerlendirme metrikleri kullanılarak modellerin performansları kontrol edildi. Önerilen modelin blok diyagramı Şekil 3.1’de gösterilmiştir.


Şekil 3.1: Önerilen Model



3.2. EEG VERİSETİ

Bu çalışmada 34 gönüllü katılımcıdan (16 normal ve 18 HBB) kaydedilen EEG sinyallerinden oluşan halka açık bir veriseti kullanılmıştır (MISPRC,2023). Katılımcıların yaşları 40 ile 77 arasında değişmektedir. EEG kayıtları, önemli demans, kafa travması, madde kötüye kullanımı, ciddi tıbbi hastalık ve psikiyatrik bozuklukları olanlar hariç, kalp kateterizasyonu için başvuran hastalardan İran, İsfahan'daki Sina ve Nour Hastanelerinin birimlerinde gerçekleştirildi. Ayrıca İsfahan Tıp Bilimleri Üniversitesi Araştırma ve Teknoloji Sorumlusu çalışma sürecini etik olarak onayladı ve katılımcılardan çalışma sürecinin açıklanmasına ilişkin yazılı onam alındı. Her katılımcının EEG'si, 5 k'dan daha düşük bir cilt elektrot empedansı ve 256 örnekleme frekansı ile 30 dakika boyunca sürekli olarak kaydedildi. EEG verileri 19 kanaldan Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 ve O2'den alınmıştır. Tüm EEG kayıtları, 10–20 Uluslararası Sisteme göre pozisyona yerleştirilmiş 19 elektrot kullanılarak alınmıştır ve bunların baş pozisyonundaki yerleşimi Şekil 3.2'de gösterilmektedir. EEG sinyalleri bireylerin uykusunu alabilecek kadar uzun süre kaydedilmesine rağmen, bunu önlemek için sürekli kontrol edildi. MMSE skoru 21 ile 26 arasında olan HBB hastası ve MMSE skoru 26'dan büyük olan ve normal kabul edilen olguların validasyonu için MMSE yapılmıştır (Kashefpoor, Rabbani ve Barekatin, 2019).

Şekil 3.2: Uluslararası 10-20 Sistem Elektrot Yerleştirme Sistemi



Bu çalışmada kullanılan EEG veriseti, 34 kişiden 19 kanaldan ve 1 dinlenme (resting) durumunda kaydedilen EEG sinyalleri olmak üzere toplamda 646 (34 x 19 x 1 dinlenme durumu=646) veri kümesinden oluşmaktadır. EEG veriseti amplifiye büyütme yaklaşımı kullanılarak üçe katlanmıştır. Bu yaklaşımın detayları 3.4.'de sunulmuştur.

3.3. ÇOK ÖLÇEKLİ TEMEL BİLEŞEN ANALİZİ (MSPCA)

EEG sinyalleri, durağan olmadıkları için gürültüye karşı hassastır ve gürültülere karşı savunmasız olduklarından, sinyallerden gelen gürültüyü ortadan kaldırmak veya azaltmak için gürültü giderme yöntemi ideal bir çözüm olacaktır. Bu, bant geçiren filtreleme ve PCA gibi gürültü giderme yöntemleri kullanılarak yapılabilir. Ancak, filtreleme tekniğinin kullanımı sinyallerin doğasına bağlıdır. Buna göre bu çalışmada sinyaller dalgacık tabanlı olduğundan MSPCA kullanılmıştır. MSPCA, potansiyel PCA ve ortonormal dalgacıkların birleşimidir. Hem temel bileşen analizinin hem de ortonormal dalgacıkların yeteneklerini birleştirir. Ortonormal dalgacıklar, stokastik süreçleri bölmekten ve PCA'yı çoklu değişkenler arasındaki ilişkiyi çıkarmaktan sorumludur. MSPCA, sınıflandırma performansını artırmak için güçlü bir gürültü giderme tekniğidir. Sinyaldeki hızlı atlamaların sayısını önemli ölçüde azaltmadan gürültüyü azaltmak için, çok ölçekli gürültü giderme yöntemleri doğrusal olmayan bir filtreleme tekniği kullanır (Kevric ve Subaşı, 2014).

3.4. VERİ ARTIRMA (DA)

Veri artırma (DA), boyutunu artırmak için mevcut veri kümesini bozmadan, değiştirerek yeni örnekler oluşturma işlemidir. Bunun nedeni, veri hacmi arttıkça derin öğrenme algoritmalarının performansının daha etkili hale gelmesidir. En azından EEG verileri için DA aşırı uydurmayı azaltma ve sınıflandırmanın doğruluğunu ve kararlılığını iyileştirme potansiyeline sahiptir (Lashgari, Liang ve Maoz, 2020). Bu araştırma çalışmasında, amplifying all-time (zamanda çarpma) veri artırma yöntemi kullanılmıştır. Verisetini artırma işlemi, verisetinin belirli bir sayı ile çarpılmasıyla gerçekleştirilir ve bu sayı, elektrot-doku empedansı gibi sorunlardan kaynaklanan beyin dalgası genliğindeki değişiklikleri ifade eder ve böylece mevcut veri miktarını gerçekçi bir şekilde artırır (Sakai, Minoda ve Morikawa, 2017). EEG veriseti, 34 kişiden 19 kanaldan dinlenme durumunda kaydedilen EEG verisetinden ($34 \times 19 \times 1$ dinlenme durumu=646) oluşmaktadır. Bu çalışmada, EEG veriseti amplifiye büyütme yaklaşımı kullanılarak üçe katlanmıştır. Sonuç olarak DA'lı veriseti toplamda 1938 veri kümesine (646×3) sahiptir.

3.5. ÖZNETELİK ÇIKARIMI

Öznitelik çıkarımı, EEG sinyallerinden bilgilendirici ve ilgili öznitelikleri seçme yöntemidir. İlişkisiz özellikleri en aza indirmek için öznitelik çıkarma yöntemleri kullanılır. Böylece, sınıflandırma modelinin performansını artırmak ve öznitelik çıkarımı yapılmadan meydana gelebilecek aşırı veri yüklemesini önlemek için EEG sinyallerinden yalnızca önemli öznitelikler çıkarılır (Al-Qerem, vd., 2020; Syed ve Muralidharan, 2022). EEG sinyalleri durağan değildir ve beyin aktivitesi sırasında frekans bilgisi elde etmek, osilatörlerin yüksek frekansı ile göz kırpmalarının ürettiği düşük frekans arasındaki elektromanyetik girişim nedeniyle zorlu bir süreçtir. Böylece ham sinyallerin sınıflandırılması sonuçta modelin doğruluğunu etkiler (Al-Qerem, vd., 2020).

PSD, enerjinin büyüklüğünü frekansın bir fonksiyonu olarak göstermek için sinyalin gücünü frekans üzerinden dağıtma kabiliyetinden dolayı kullanılmıştır. Ayrıca PSD, durağan sinyal işleme ve dar bantlı sinyaller için uygun bir araç olarak kabul edilmektedir (Ng, vd., 2019). Bu çalışmada DWT liderleri, Periodogram, Welch ve Multitaper uygulanarak toplam dört farklı öznitelik çıkarma yaklaşımı kullanılmıştır.

3.5.1. Ayırık Dalgacık Dönüşümü Liderleri (DWT Liderleri)

DWT liderleri öznitelik çıkarma yöntemi, en önemli öznitelikleri çıkarmak ve spektrumun tekilliğini tahmin etmek için kullanılır. Dalgacık dönüşümü, zaman-frekans

analizi için kullanılır. DWT ise, farklı frekans bantlarındaki yaklaşık ve ayrıntılı katsayılı sinyalleri parçalayarak farklı çözünürlüklerdeki sinyali analiz eden bir öznetelik çıkarım yöntemidir. Yüksek frekanslı bileşenleri küçük bir pencerede çözerken, DWT yöntemi düşük frekanslı bileşenleri çözmek için büyük zaman pencereleri gerektirir. Sinyal hem düşük hem de yüksek frekans bileşenlerinden oluştuğu için hem zaman hem de frekans açısından en iyi çözünürlüğü sağlamaya çalışır (Ustundag, 2021). Son zamanlarda, Jaffard ve iş arkadaşları tarafından DWT'den DWT liderleri adı verilen yeni bir form oluşturuldu. DWT liderleri, durağan olmayan ve doğrusal olmayan sinyallerle iyi çalışan bir yöntemdir (Benouioua, vd., 2017).

DWT liderleri, sinyalin dalgacık katsayısının yerel üst değeridir. Bu yöntem, olağan dalgacık yöntemlerini geliştirmek için tanıtıldı. Bu yöntem, dalgalanmaların analizi için bir araç olan multifraktal spektrumu tahmin etmek için dalgacık analizini kullanır. Bir sinyalin benzersiz davranışını tanımladığı göz önüne alındığında. DWT, etkili bir zaman-frekans analiz aracıdır ve dalgacık katsayıları, düzenliliğini incelemek için uygun ölçümlerdir. Bununla birlikte, dezavantajı, dalgalanan tekilliklere sahip sinyaller için başarısız olmasıdır. Dalgacık liderleri yöntemi bu dezavantajı düzeltti. Ayrıca, DWT liderleri düşük hesaplama karmaşıklığına sahiptir ve sağlam ve hızlı tahmin sunar. Salınlı sinyalleri yakalamada DWT'den daha iyi performans gösterir ve daha etkilidir (Serrano ve Figliola, 2009; Leonarduzzi, Schlotthauer ve Torres, 2010; Gadhomi, vd., 2018; Tan, Liu ve Chen, 2021). $X(t)$ sinyalinin DWT'si denklem 1'de gösterilmiştir ve ψ ana dalgacık. İkili küpteki dalgacık katsayılarının yerel üstünlüğü DWT liderleri olarak bilinir ve j ölçeğinde ve k konumunda dalgacık liderlerinin $L_X(j, k)$ olduğunu belirtir. DWT liderleri denklem 2'de gösterilir (Benouioua, vd., 2017).

$$d_X(j, k) = \int_R X(t) 2^{-j} \psi(2^{-j}t - k) dt \quad (1)$$

$$L_X(j, k) = \sup_{\lambda' \in \Gamma} |d_{X, \lambda'}| \quad (2)$$

λ ikili aralık ve Γ ikili küptür ve denklemleri aşağıdaki gösterilmiştir (Benouioua, vd., 2017).

$$\lambda = [k \cdot 2^j, (k + 1) 2^j] \quad (3)$$

$$\Gamma = 3\lambda = \lambda_{jk-1} \cup \lambda_{jk} \cup \lambda_{jk+1} \quad (4)$$

Bu çalışmada, Deneysel'de DWT liderleri öznitelik çıkarım yöntemi kullanılarak EEG sinyallerinden 36 adet öznitelik çıkarılmıştır.

3.5.2. Periodogram

Periodogram, bir sinyaldeki periyodiklikleri bulmak için kullanılan bir yöntemdir (Das, Subba ve Yang, 2021). Fourier analizine dayalı ilk spektrum analizi tekniğiydi ve pencereli bir zaman serisinin büyüklüğünün karesini hesaplayarak çalışır (Lan, vd., 2020; Trauth, 2021). Periodogram yönteminin denklemi denklem (5)'te gösterilmiştir.

$$P_{(w)} = \frac{1}{M} \left| \sum_{t=1}^M y(t) e^{-j\omega t} \right|^2 \quad (5)$$

Güç spektrum yoğunluğu $P(w)$, M sinyal örnek sayısını, $y(t)$ sinyalin spektrumunu ve güç spektrum yoğunluğuna sahip frekans w ile gösterilir (Güneç, vd., 2021). Deneysel'de periodogram öznitelik çıkarım yöntemi kullanılarak EEG sinyallerinden 49 adet öznitelik çıkarılmıştır.

3.5.3. Welch

Welch yöntemi, EEG işaretlerinden PSD'yi çıkarmak için kullanılan en popüler yöntemlerden biridir ve sinyali birden çok parçaya bölerek bu sinyalleri değerlendirerek çalışır. Her segment için değiştirilmiş bir Periodogram oluşturulur ve ardından PSD tahminleri için Periodogramın ortalaması alınır. Her parçanın değiştirilmiş Periodogramını hesaplamak için genellikle hamming penceresi kullanılır. Welch'in güç spektral tahmin denklemi, denklem (6)'da gösterilmektedir (Ng, vd., 2019; Xiong, vd., 2020).

$$P_{welch}(f) = \frac{1}{S} \sum_{i=1}^S P_i(f) \quad (6)$$

Burada $P_{welch}(f)$, periodogramların ortalamasıdır ve $P_i(f)$, pencereli segment başına periodogramın hesaplanmasıdır. Deneysel'de welch öznitelik çıkarım yöntemi kullanılarak EEG sinyallerinden 49 adet öznitelik çıkarılmıştır.

3.5.4. Multitaper

Multitaper yöntemi, bant genişliğini ayarlayarak yanlılık-varyans takasını yönetebilmesi ve basitliği nedeniyle diğer yöntemler arasında öne çıkmaktadır (Das ve Babadi, 2020). Her pencerenin diğer pencerelere ortogonal olduğu belirsizliği azaltmak için öz-spektral tahminlere karşılık gelen konik PSD tahminlerinin ortalaması alınarak hesaplanır (Candy, 2019). Multitaper denklemi denklem (7)'de gösterilmiştir.

$$\vartheta_{(w)} = \left| \sum_{n=1}^K h_{K-n} y(n) e^{-j\omega n} \right|^2 \quad (7)$$

Burada k , filtre sayısını, h_{K-n} ise filtre darbesini ifade eder. Deney 4'de multitaper öznitelik çıkarım yöntemi kullanılarak EEG sinyallerinden 49 adet öznitelik çıkarılmıştır.

3.6. K-KAT ÇAPRAZ DOĞRULAMA

Bu çalışmada modeli değerlendirmek için K-kat çapraz doğrulama yöntemi benimsenmiştir. Yöntem, verisetini modeli eğitmek için eğitime ve değerlendirmek için test setlerine bölerek model performansını değerlendirmek ve modelin çıktısı sonuçlarını değerlendirmek için model hatalarını azaltmak için güvenilir bir araç sunar. Eğitim setini aynı boyutta K parçaya böler. Eğitim setinin her bileşeni doğrulama seti olarak kabul edilirken, geri kalan $k-1$ bileşenleri tamamen yeni eğitim seti olarak kabul edilir. Daha sonra K modelleri geliştirilir, eğitilir ve ardından K-1 ve K doğrulama setlerinin eğitim setleri ile doğrulanır (Yan, vd., 2022). Bu araştırma çalışmasını yürütmek için, modelin performansının tarafsız bir tahminini üretmek için veriseti k ($k=10$) eşit boyutlu alt kümeyle bölünür. Sonuç olarak, her seferinde eğitim setinden bir altküme çıkarıp test seti olarak kullanarak k (10) kez model kurarak 10 uygulamanın ortalamasını temsil eder (Vu, vd., 2022; Barrow ve Crone, 2013; Wang, Zeng ve Dai, 2022).

3.7. SINIFLANDIRMA ALGORİTMALARI

3.7.1. Karar Ağacı (DT)

DT, makine öğrenimi modellerinde kullanılan popüler bir denetimli sınıflandırma yöntemidir. Karmaşık bir problemi çok sayıda basit probleme bölerek süreci yinelemeli olarak tekrarlayarak zaman ve işleme açısından verimli bir ağaç oluşturur (Bastos, vd., 2020; Ashok, vd., 2020). DT, bir düğüm ve bir yapraktan oluşur;

düğüm, giriş özniteliğiyle ilişkili kök düğümün alt ağacı olan dahili düğümdür. Yaprak, iç düğümün çıktığı değerlerine götüren her bir iç düğümün giden ucudur ve karar düğümü, çıktığı özniteliğinin sınıflarıyla uyumlu çıktığı yaprak düğümüne sahip olan düğümdür (Rabcan, vd., 2021).

3.7.2. Destek Vektör Makinesi (SVM)

SVM, çekirdek fonksiyonunu radyal tabanlı fonksiyon (RBF) veya lineer veya gauss çekirdeği olarak seçerek tahminin doğruluğunu artırmak için çekirdek parametresi ve çekirdek fonksiyon tipi adı verilen makine öğrenme teorisini kullanarak regresyon ve sınıflandırma problemlerinde kullanılan denetimli bir makine öğrenme yöntemi olarak bilinir. Ayrıca aynı zamanda verilerin aşırı uyumundan da kaçınılmaktadır (Javaid, vd., 2022; Chiang, vd., 2020). SVM sınıflandırmalarının, DT ve sinir ağı tabanlı yaklaşımlardan daha doğru olduğu söylenir çünkü ana hedefleri, sınıfları farklılaştıran doğrusal bir ayırma işlevi olan ideal ayırıcı hiperdüzlemi belirlemektir. Sınıf dağılımlarının çerperinde yer alan eğitim örneklerine odaklanır (Rahmat, vd., 2021). İlk başta ikili sınıflandırma için geliştirildiler, ancak daha sonra çok sınıflı problemleri ikili SVM ile etiketlenebilecek ikili analizlere bölerek çok sınıflı durumlar için genişletildiler (Xie, She ve Guo, 2021).

3.7.3. K-En Yakın Komşu (KNN)

KNN, sınıflandırma performansı ve basit uygulaması nedeniyle popüler bir sınıflandırma algoritmasıdır (Zhang, vd., 2017). K-NN sınıflandırıcı, test örneğini gerçekleştirmek için k-en yakın komşuyu kolayca arayabilmesi için tüm eğitim örneklerini hafızasında tuttuğu için tembel bir sınıflandırıcıdır. Aynı şekilde, k-en yakın örneği döndürmeden önce veri kümesinin eğitim örnekleri ile test örnekleri arasındaki ayrımı hesaplar. Ayrıca, dengesiz verileri sınıflandırmayı ve böylece yüksek tanıma doğruluğu elde etmeyi amaçlar (Zhang, 2020; Deng, vd., 2016).

3.7.4. BiLSTM

BiLSTM, çift yönlü uzun kısa dönem hafıza (LSTM) ağı anlamına gelir. Model çift yönlüdür ve bu, girdi verilerinin soldan sağa ve ardından sağdan sola iki kez kullanıldığını belirtmektedir (Siarni-Namini, Tavakoli ve Namin, 2019). BiLSTM, LSTM'nin bir eklentisidir ve LSTM, bir hücre bellek durumu ve üç kapıdan oluşan geleneksel bir ileri beslemeli sinir ağının bir çeşidi olan bir tekrarlayan sinir ağı (RNN) biçimidir (Liu ve Guo, 2019). Bu kapılar giriş kapısı, unutma kapısı ve çıkış kapısı olarak

bilinir ve denklemleri aşağıda gösterilmiştir. LSTM, geçmiş bilgilerini depolamak için bu kapıları kullanır. Standart RNN’de yok olan gradyan sorunları, LSTM ağının geliştirilmesiyle çözüldü. Ayrıca, sıralı veri öğrenme uygulamalarının çoğu için etkili ve esnek bir yaklaşım göstermiştir (Wang, vd., 2016; Bai, 2018). LSTM mimarisinin arkasındaki etkinlik, sahip olduğu bellek hücresidir, çünkü bu bellek hücresi, bilgilerin bir hücrenin belleğine nasıl girip çıktığını kontrol edebilen zaman içinde durumunu korur (Greff, vd., 2016).

$$\text{Giriş kapısı} \Rightarrow i_t = \sigma(w_{xi}x_t + w_{hi}h_{t-1} + b_i) \quad (8)$$

$$\text{Unutma kapısı} \Rightarrow f_t = \sigma(w_{xf}x_t + w_{hf}h_{t-1} + b_f) \quad (9)$$

$$\text{Çıkış kapısı} \Rightarrow o_t = \sigma(w_{xo}x_t + w_{ho}h_{t-1} + b_o) \quad (10)$$

$$\text{Hafıza hücresini modüle et} \Rightarrow C_t = \tanh(w_{xc}x_t + w_{hc}h_{t-1} + b_c) \quad (11)$$


$$\text{Hafıza hücresi} \Rightarrow C_t = \sigma(f_t * C_{t-1} + i_t * C_t) \quad (12)$$

$$\text{Çıktı} \Rightarrow h_t = o_t * \tanh(C_t) \quad (13)$$

W ’nin gizli katmanın kendi kendini güncelleyen ağırlıklarını gösterdiği yerde, σ sigmoid işlevidir, b yanlılık vektörüdür, \tanh hiperbolik tanjanttır ve $*$ operatörü eleman bazında çarpmadır. Ayrıca i_t anında I değerini, f_t f değerini ve o_t o ve c değerini temsil etmektedir (Liu ve Guo, 2019; Wang, vd., 2016).


BiLSTM mimarisi, ileri ve geri LSTM mimarisini içerir ve BiLSTM çift yönlü olduğundan, verileri hem ileri hem de geri yönde işleyebilir, dolayısıyla bu, BiLSTM mimarisinin, verilerin LSTM’nin yok saydığı gizli özellikleri ve örüntüleri yakalamasını sağlar. LSTM mimarisi Şekil 3.3’te ve BiLSTM mimarisi Şekil 3.4’te gösterilmektedir (Li, vd., 2020).

Şekil 3.3: LSTM Hücresinin Yapısı



Kaynak: Li, vd., 2020.

Şekil 3.4: BiLSTM Yapısı



Kaynak: Li, vd., 2020.

3.8. PERFORMANS DEĞERLENDİRME METRİKLERİ

Hastalığın pozitif mi yoksa negatif mi olduğunu tahmin ederek sınıflandırma modellerinin etkinliğini değerlendirmek için, sınıflandırıcının ölçüm metriklerini tanımlamak için dört temel parametreden (TP, FN, FP ve TN) oluşan bir karışıklık matrisi kullanıldı. Burada TP, gerçek pozitif anlamına gelir ve doğru şekilde sınıflandırılan pozitif örneklerin sayısıdır. FN, yanlış negatif anlamına gelir ve pozitif olarak yanlış sınıflandırılan negatif örneklerin sayısıdır. FP yanlış pozitif anlamına gelir ve yanlış olarak negatif olarak sınıflandırılan pozitif örnek sayısıdır ve TN gerçek negatif olup doğru sınıflandırılan negatif örneklerin sayısıdır (Bihter, 2020). TP, TN, FN ve FP değerleri bulunduktan sonra algoritmaların değerlendirme metriklerinin performansları karşılaştırılır ve değerlerine göre sistemin yüksek olup olmadığına karar verilir. Karışıklık

matrisi parametreleri kullanılarak model performans değerlendirme metrikleri hesaplanmaktadır. Model performans değerlendirme metriklerinin denklemleri aşağıda verilmiştir.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (14)$$

$$\text{Kesinlik} = TP / (TP + FP) \quad (15)$$

$$\text{Özgüllük} = TN / (TN + FP) \quad (16)$$

$$\text{F1 skoru} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (17)$$

$$\text{MCC} = \frac{(TP * TN - FN * FP)}{\sqrt{((TN + FN) * (FP + TP) * (TN + FP) * (FN + TP))}} \quad (18)$$

$$\text{Doğruluk} = (TP + TN) / (TP + FN + FP + TN) \quad (19)$$




DÖRDÜNCÜ BÖLÜM
DENEYSEL ÇALIŞMALAR VE BULGULAR

Bu tez çalışmasında, EEG sinyallerinden öznitelik vektörlerini elde etmek için dört farklı deney gerçekleştirilmiştir. Birinci deneyde DWT liderleri, ikinci deneyde Periodogram yöntemi, üçüncü deneyde Welch yöntemi ve dördüncü deneyde Multitaper yöntemi kullanılmıştır. EEG sinyallerinin öznitelik vektörleri, üç spektral analiz yöntemi kullanılarak 1-49 Hz arasında değişen PSD frekans değerleri kullanılarak hesaplandı.

Veriseti 16 normal ve 18 HBB olmak üzere toplam 34 kişiden ve 19 kanaldan kaydedilen ham EEG sinyallerinden oluşmaktadır. Örnekleme frekansı 256 Hz dir ve gönüllü katılımcıların her biri için EEG sinyallerinin kaydı 30 dakika sürmüştür. Bir numaralı kontrol grubuna ve bir numaralı HBB hastasına ait birinci kanaldan (Fp1) kaydedilen ilk 10 (1-2560 sn) saniyelik ham EEG sinyalleri Şekil 4.1’de gösterilmektedir.

Şekil 4.1: Ham EEG Sinyalleri




Şekil 4.1’deki EEG sinyallerinin ham değerleri, her iki grubun sinyallerinin birbirine yakın olduğunu ve istenmeyen gürültü olduğunu göstermektedir. Şekil 4.1’de HBB hastalarının sinyallerinin genlik değerinin normal gruplardan daha düşük olduğu görülmektedir.

EEG sinyallerinden öznitelik vektörlerini çıkarmak için DWT liderleri ve spektral analiz yöntemleri (Periodogram, Welch, Multitaper) uygulanmıştır. DWT liderleri öznitelik yöntemi kullanılarak EEG sinyallerinden 36 öznitelik çıkarılmıştır. Periodogram, Welch ve Multitaper spektral analiz yöntemleri kullanılarak ise EEG sinyallerinden 49 öznitelik vektörü çıkarılmıştır.

İlk deneyde EEG sinyallerine DWT liderleri yöntemi uygulandı. EEG sinyallerinin her iki grubu, normal grubu ve HBB grubu için öznitelik çıkarım yöntemi uygulandıktan sonra, EEG sinyallerinin çıkarılan öznitelik vektörlerinin karşılaştırılması için bir grafik çizildi. Bir numaralı kontrol grubuna ve bir numaralı HBB hastasına ait birinci kanaldan (Fp1) kaydedilen EEG sinyallerinden DWT liderleri uygulanarak çıkarılan öznitelik vektörleri Şekil 4.2’de gösterilmektedir.


Şekil 4.2: DWT Liderleri Yöntemiyle Öznitelik Vektör Grafiği



Şekil 4.2, DWT liderleri yöntemi kullanılarak EEG sinyallerinin çıkarılan öznitelik vektörlerini göstermektedir. HBB hastalarının ve normal grupların EEG sinyallerinin çıkarılan öznitelik vektörlerinin ayırt edilemez olduğu görülmektedir. Ancak grafiğin bazı kısımlarında HBB grubunun sinyal gücünün normal grupların sinyal gücüne göre daha düşük olduğu görülmektedir.

İkinci deneyde EEG sinyallerine Periodogram spektral analiz yöntemi uygulanmıştır. EEG sinyallerinin hem gruplar, normal grup hem de HBB grubu için Periodogram yönteminin spektral analizi uygulandıktan sonra, EEG sinyallerinin çıkarılan PSD'sinin karşılaştırılması için bir grafik çizildi. Bir numaralı kontrol grubuna ve bir numaralı HBB hastasına ait birinci kanaldan (Fp1) kaydedilen EEG sinyallerinden Periodogram yöntemi kullanılarak çıkarılan PSD değerleri Şekil 4.3'te gösterilmektedir.


Şekil 4.3: Periodogram Yöntemiyle PSD Grafiği



Şekil 4.3'te Periodogram yöntemi kullanılarak EEG sinyallerinin çıkarılan PSD'si gösterilmektedir ve HBB hastalarının EEG sinyallerinin çıkarılan PSD'sinin normal gruplara göre oldukça düşük olduğu görülmektedir.

Üçüncü deneyde EEG sinyallerine Welch spektral analiz yöntemi uygulandı. EEG sinyallerinin hem grupları, normal grubu hem de HBB grubu için Welch yönteminin spektral analizi uygulandıktan sonra, Welch yöntemi kullanılarak EEG sinyallerinin çıkarılan PSD'sinin karşılaştırılması için bir grafik çizildi. Bir numaralı kontrol grubuna ve bir numaralı HBB hastasına ait birinci kanaldan (Fp1) kaydedilen EEG sinyallerinden Welch yöntemi kullanılarak çıkarılan PSD değerleri Şekil 4.4'de gösterilmektedir.


Şekil 4.4: Welch Yöntemiyle PSD Grafiği



Şekil 4.4, Welch yöntemi kullanılarak EEG sinyallerinin çıkarılan PSD'sini göstermektedir. HBB hastalarının EEG işaretlerinden çıkarılan PSD'nin normal gruplara göre oldukça düşük olduğu görülmektedir. Bu yöntemde, yüksek doğruluğu başlatacak değişkene göre bazı parametreler seçilmiştir. Örneğin “non-overlap” parametresinde pencere uzunluğunun yarısı, “window length” parametresinde ise EEG sinyal uzunluğunun ¼'ü olacak şekilde seçilmiştir.

Dördüncü deneyde, EEG işaretlerine Multitaper spektral analiz yöntemi uygulanmıştır. EEG sinyallerinin hem grupları, normal grubu hem de HBB grubu için Multitaper yönteminin spektral analizi uygulandıktan sonra, Multitaper yöntemi kullanılarak EEG sinyallerinin çıkarılan PSD'sinin karşılaştırılması için bir grafik çizildi. Bir numaralı kontrol grubuna ve bir numaralı HBB hastasına ait birinci kanaldan (Fp1) kaydedilen EEG sinyallerinden Multitaper yöntemi kullanılarak çıkarılan PSD değerleri Şekil 4.5'de gösterilmektedir.

Şekil 4.5: Multitaper Yöntemiyle PSD Grafiği



Şekil 4.5, Multitaper yöntemi kullanılarak EEG sinyallerinin çıkarılan PSD'sini gösterir. Elde edilen EEG işaretlerinden normal ve HBB grubu, iki grup arasında büyük bir boşluk güç sinyali farkı olduğu görülmektedir. HBB hastalarının EEG sinyallerinin çıkarılan PSD'sinin normal gruplara göre oldukça düşük olması, EEG sinyallerinden PSD'nin çıkarılmasında Multitaper yönteminin en iyi yöntem olduğunu belirtmektedir.

DWT liderleri ve güç spektral analiz yöntemleri kullanılarak EEG sinyallerinin çıkarılan öznitelik vektörlerinin yukarıdaki grafikleri karşılaştırıldı. Karşılaştırıldıktan sonra Multitaper yönteminde elde edilen EEG sinyalinin çıkartılan PSD'si, EEG sinyallerinin PSD'si diğer yöntemlere göre daha net görüldüğü için en iyi analiz yöntemi olarak kabul edilmektedir. Bunun nedeni, Multitaper yönteminde normal grup ile HBB grubu arasında net bir güç sinyali farkı vardır ve bu da HBB grubunun normal gruptan net bir şekilde ayırt edilebildiğini gösterir. Ancak DWT liderleri yönteminde her iki grubun iki sinyali yan yana olduğundan aralarındaki ayrımı zorlaştırmaktadır. Diğer iki yöntem olan Periodogram ve Welch yöntemlerinde ise iki grup arasında fark olmasına rağmen Multitaper yöntemi kadar net olmadığı için fark net olarak ayırt edilememektedir.


HBB grupları ve normal grupları sınıflandırmak için dört deneyi gerçekleştirildi, DWT liderleri Periodogram, Welch ve Multitaper ve üç farklı makine öğrenimi sınıflandırma algoritması, DT, SVM ve KNN ve bir derin öğrenme sınıflandırma yöntemi olan BiLSTM kullanıldı. Tüm deneylerde adil sonuçlar elde etmek için hiperparametreler tüm deneylerde aynı tutulmuştur. İlk olarak tüm deneyler için SVM algoritmasının “KernelFunction” değişkeni olarak “linear”, “gaussian” ve “RBF” kullanılarak kontrol edilmiş ve “gaussian” değişkeninin deney için en uygun olduğu görülmüştür, bu nedenle deney boyunca dört modelin tümü için kullanıldı. KNN algoritmasında k değişkeni, değişken olarak “1”, “3”, “5” ve “10” kullanılarak test edilmiş ve k=1’in deney için en iyisi olduğunu göstermiştir. BiLSTM’de ise “MaxEpochs” değerleri gibi hiperparametreler, spektral analiz yöntemleri için “200” ile “500” epoch arasındaki değerler kullanılarak test edilmiş ve “220” epoch değeri modele uygun olduğu için tüm modellerde bu değer kullanılmıştır. Ancak DWT liderleri yönteminde “200” ile “2000” dönemleri arasındaki değerler kullanılarak test edilmiş ve “1890” dönemleri modele uygun olduğundan bu değer kullanılmıştır. Buna ek olarak, BiLSTM algoritması için DWT liderleri ve PSD yöntemleri, geri kalan hiperparametreleri, “MiniBatchSize” gibi, 384 değeri seçildi, “InitialLearnRate” değeri 0.001 seçildi ve “SequenceLength” değeri seçildi 1000 seçildi. “GradientThreshold” değeri olarak 1 seçilmiş ve “optimization method” parametresi olarak Adam değeri kullanılmıştır.

4.1. DWT LİDERLERİ DENEYİ

4.1.1. DT Algoritması ile DWT Liderleri Yöntemi

DWT liderleri yöntemi kullanılarak DT sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.6’da verilmiştir.

Şekil 4.6: DWT Liderleri ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi



DT algoritması ile DWT liderleri yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1624 örnek doğru sınıflandırılmış ve toplam 314 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1624 örnekten 872'si HBB ve 752'si kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.1'de gösterilmektedir.

Tablo 4.1: DWT Liderleri+DT Algoritmasının Performans Değerlendirme Metrikleri

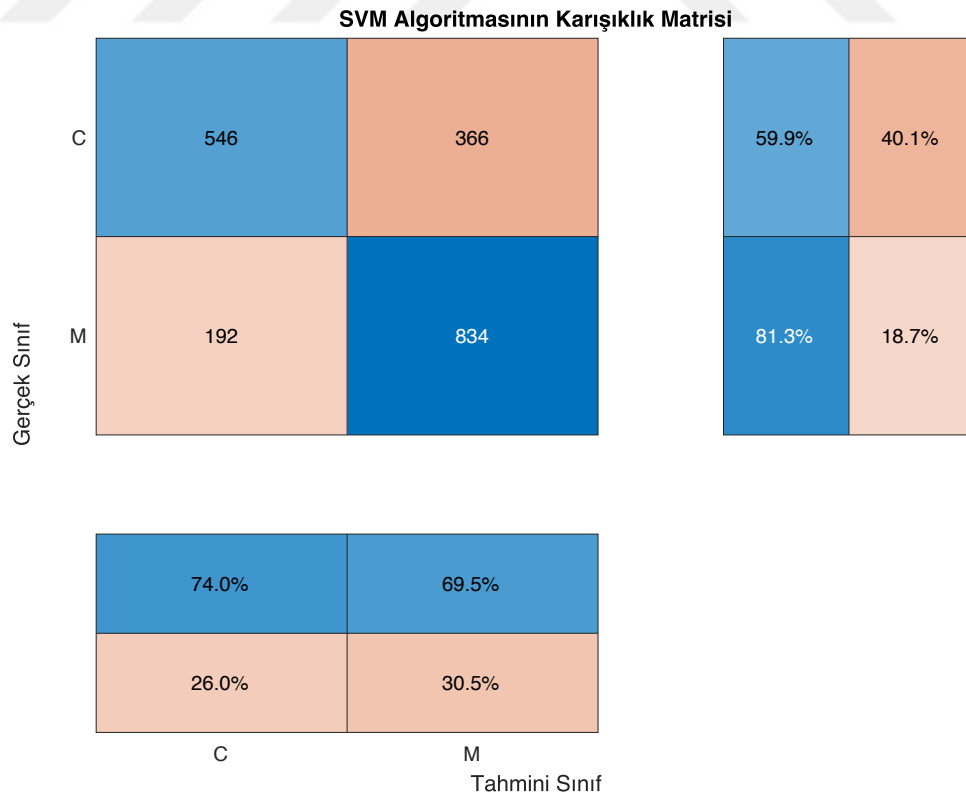
Metrikler	Başarı (%)
Duyarlılık	84.99
Özgüllük	82.46
Kesinlik	84.50
F1 skoru	84.74
MCC	67.47
Doğruluk	83.80

Tablo 4.1 incelendiğinde, DWT liderleri kullanılarak çıkarılan özneliklerin kullanıldığı DT algoritmasına ait duyarlılık değerinin %84.99, özgüllük değerinin %82.46, kesinlik değerinin %84.50, f1 skorunun %84.74, MCC değerinin %67.47 ve doğruluk değerinin %83.80 olduğu görülmektedir. Doğruluk değeri ve f1 skoru, sınıflandırma algoritmasının ne kadar doğru çalıştığını, duyarlılık değeri algoritmanın pozitif örneği ne kadar iyi tespit edebildiğini, özgüllük değeri algoritmanın gerçek negatiflerin oranını ne derecede ölçtüğünü, kesinlik değeri algoritmanın yaptığı pozitif tahminin kalitesini göstermektedir. Ayrıca MCC değeri tahmin edilen değerler ile gerçek değerler arasındaki farkı ölçen model değerlendirmesi için kullanılan istatistiksel bir araçtır.

4.1.2. SVM Algoritması ile DWT Liderleri Yöntemi

DWT liderleri yöntemi kullanılarak SVM sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.7’de verilmiştir.

Şekil 4.7: DWT liderleri ile SVM sınıflandırma algoritmasının karışıklık matrisi



SVM algoritması ile DWT liderleri yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1380 örnek doğru sınıflandırılmış ve toplam 558 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1380 örnekten 834'ü HBB ve 546'sı kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.2'de gösterilmektedir.


Tablo 4.2: DWT Liderleri+SVM Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	81.29
Özgüllük	59.87
Kesinlik	69.50
F1 skoru	74.93
MCC	42.30
Doğruluk	71.21

DWT liderleri kullanılarak çıkarılan özniteliklerin kullanıldığı SVM algoritmasına ait duyarlılık değeri %81.29, özgüllük değeri %59.87, kesinlik değeri %69.50, f1 skoru %74.93, MCC değeri %42.30 ve doğruluk değeri %71.21 olarak hesaplanmıştır.

4.1.3. KNN Algoritması ile DWT Liderleri Yöntemi

DWT liderleri yöntemi kullanılarak KNN sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.8'de verilmiştir.

Şekil 4.8: DWT Liderleri ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi

KNN algoritması ile DWT liderleri yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1618 örnek doğru sınıflandırılmış ve toplam 320 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1618 örneğin 868'i HBB ve 750'si kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.3'te gösterilmektedir.

Tablo 4.3: DWT Liderleri+KNN Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	84.60
Özgüllük	82.24
Kesinlik	84.27
F1 skoru	84.44
MCC	66.85
Doğruluk	83.49

DWT liderleri kullanılarak çıkarılan özniteliklerin kullanıldığı KNN algoritmasına ait duyarlılık değeri %84.60, özgüllük değeri %82.24, kesinlik değeri %84.27, f1 skoru %84.44, MCC değeri %66.85 ve doğruluk değeri %83.49 olarak hesaplanmıştır.

4.1.4. BiLSTM Algoritması ile DWT Liderleri Yöntemi

DWT liderleri yöntemi kullanılarak BiLSTM sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.9’da verilmiştir.

Şekil 4.9: DWT Liderleri ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi

BiLSTM Algoritmasının Karışıklık Matrisi

Gerçek Sınıf	C	778	134	85.3%	14.7%
	M	174	852	83.0%	17.0%
		81.7%	86.4%		
		18.3%	13.6%		
		C	M		
			Tahmini Sınıf		

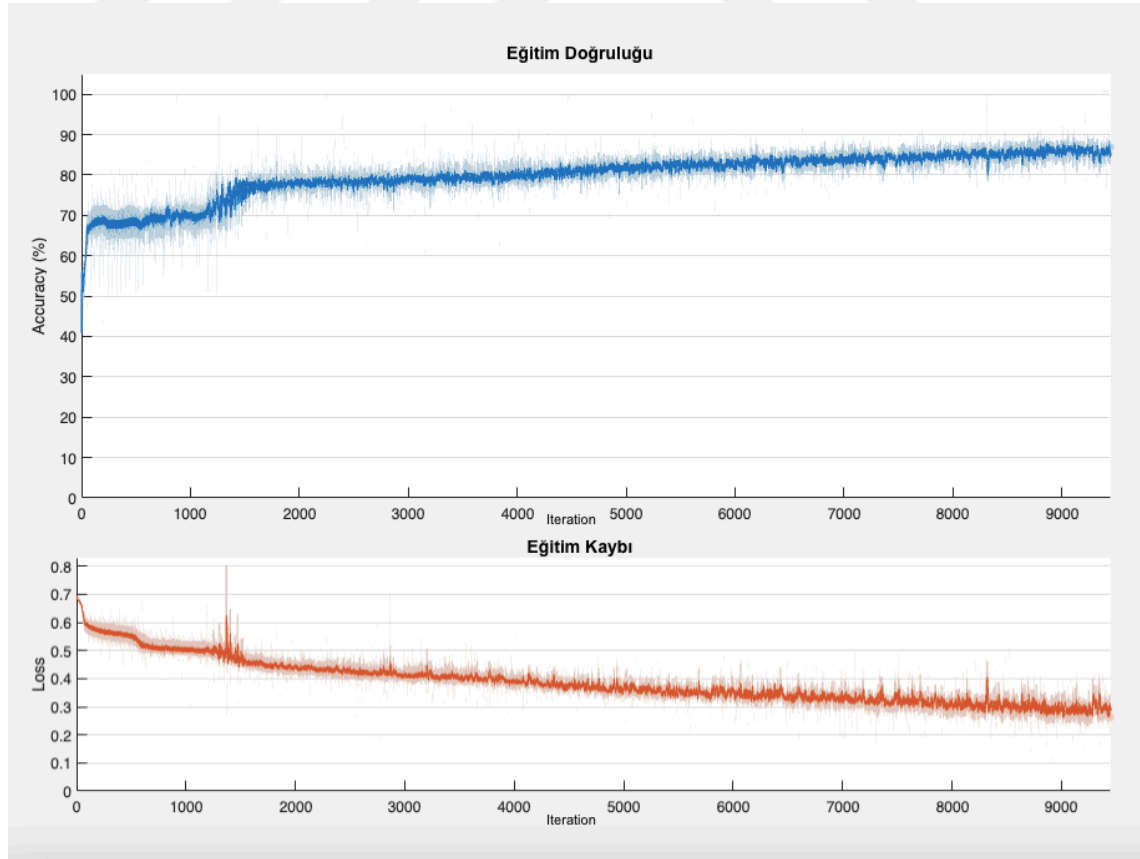
BiLSTM algoritması ile DWT liderleri yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1630 örnek doğru sınıflandırılmış ve toplam 308 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1630 örnekten 852’si HBB ve 778’i kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.4’te gösterilmektedir.

Tablo 4.4: DWT Liderleri+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	83.04
Özgüllük	85.31
Kesinlik	86.41
F1 Skoru	84.69
MCC	68.24
Doğruluk	84.11

DWT liderleri kullanılarak çıkarılan özniteliklerin kullanıldığı BiLSTM algoritmasına ait duyarlılık değeri %83.04, özgüllük değeri %85.31, kesinlik değeri %86.41, f1 skoru %84.69, MCC değeri %68.24 ve doğruluk değeri %84.11 olarak hesaplanmıştır. Modelin 1890 epochs ait eğitim ve kayıp eğrileri Şekil 4.10'da verilmiştir.

Şekil 4.10: DWT liderleri modelinin eğitim doğruluğu ve kayıp grafiği




Şekil 4.10, BiLSTM algoritması ile DWT liderleri yönteminin eğitim ve kayıp eğrileridir. Kayıp eğrisi, her girdi için istenen ve hesaplanan sonuç arasındaki hatayı gösterir. Eğriyi gözlemleyerek, epochs sayısı (iterasyon) arttıkça eğitim kaybının azaldığı ve doğruluğun arttığı görülebilir. 1500. yinelemeden itibaren, doğruluk eğrisi kademeli olarak yukarı doğru eğim yapmaya başladı ve 1890 epoch'ta %84.11'lik bir doğruluk oranına ulaştı. Ayrıca, kayıp eğrisi 1300. iterasyondan sonra aşağı doğru eğim yapmaya başlayarak yaklaşık 0.31 kayıp oranına ulaştı.

4.2. PERIODOGRAM DENEYİ

4.2.1. DT Algoritması ile Periodogram Yöntemi

DT sınıflandırma algoritmasının Periodogram yöntemi kullanılarak karışıklık matrisi hesaplanmıştır ve bu Şekil 4.11'de verilmiştir.

Şekil 4.11: Periodogram ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi



DT algoritması ile Periodogram yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1653 örnek doğru sınıflandırılmış ve toplam 285 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1653 örneğin 887'si HBB ve 766'sı kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.5'te gösterilmektedir.


Tablo 4.5: Periodogram+DT Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	86.45
Özgüllük	83.99
Kesinlik	85.87
F1 skoru	86.16
MCC	70.48
Doğruluk	85.29

Periodogram kullanılarak çıkarılan özneliklerin kullanıldığı DT algoritmasına ait duyarlılık değeri %86.45, özgüllük değeri %83.99, kesinlik değeri %85.87, f1 skoru %86.16, MCC değeri %70.48 ve doğruluk değeri %85.29 olarak hesaplanmıştır.

4.2.2. SVM Algoritması ile Periodogram Yöntemi

SVM sınıflandırma algoritmasının Periodogram yöntemi kullanılarak karışıklık matrisi hesaplanmıştır ve bu Şekil 4.12’de verilmektedir.

Şekil 4.12: Periodogram ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi

SVM algoritması ile Periodogram yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1257 örnek doğru sınıflandırılmış ve toplam 681 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1257 örneğin 952'si HBB ve 305'i kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.6'da gösterilmektedir.

Tablo 4.6: Periodogram+SVM Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	92.79
Özgüllük	33.44
Kesinlik	61.06
F1 skoru	73.66
MCC	33.01
Doğruluk	64.86

Periodogram kullanılarak çıkarılan özniteliklerin kullanıldığı SVM algoritmasına ait duyarlılık değeri %92.79, özgüllük değeri %33.44, kesinlik değeri %61.06, f1 skoru %73.66, MCC değeri %33.01 ve doğruluk değeri %64.86 olarak hesaplanmıştır.

4.2.3. KNN Algoritması ile Periodogram Yöntemi

Periodogram yöntemi kullanılarak KNN sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.13'te verilmiştir.

Şekil 4.13: Periodogram ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi



KNN algoritması ile Periodogram yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1577 örnek doğru sınıflandırılmış ve toplam 361 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1577 örnekten 834'ü HBB ve 743'ü kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.7'de gösterilmektedir.

Tablo 4.7: Periodogram+KNN Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	81.29
Özgüllük	81.47
Kesinlik	83.15
F1 skoru	82.21
MCC	62.69
Doğruluk	81.37

Periodogram kullanılarak çıkarılan özneliklerin kullanıldığı KNN algoritmasına ait duyarlılık değeri %81.29, özgüllük değeri %81.47, kesinlik değeri %83.15, f1 skoru %82.21, MCC değeri %62.69 ve doğruluk değeri %81.37 olarak hesaplanmıştır.

4.2.4. BiLSTM Algoritması ile Periodogram Yöntemi

BiLSTM sınıflandırma algoritmasının Periodogram yöntemi kullanılarak karışıklık matrisi hesaplanmıştır ve bu Şekil 4.14'te verilmektedir.

Şekil 4.14: Periodogram ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi




BiLSTM algoritması ile Periodogram yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1668 örnek doğru sınıflandırılmış ve toplam 270 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1668 örnekten 863'ü HBB ve 805'i kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.8'de gösterilmektedir.

Tablo 4.8: Periodogram+BiLSTM Algoritmasının Performans Deęerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	84.11
Özgüllük	88.27
Kesinlik	88.97
F1 skoru	86.47
MCC	72.26
Doęruluk	86.07

Periodogram kullanılarak çıkarılan özniteliklerin kullanıldığı BiLSTM algoritmasına ait duyarlılık değeri %84.11, özgüllük değeri %88.27, kesinlik değeri %88.97, f1 skoru %86.47, MCC değeri %72.26 ve doęruluk değeri %86.07 olarak hesaplanmıştır. Modelin 220 epochs eğitim ve kayıp eğrileri Şekil 4.15'te verilmektedir.

Şekil 4.15: Periodogram modelinin eğitim doęruluęu ve kayıp grafięi



Şekil 4.15, BiLSTM algoritması ile Periodogram yönteminin eğitim ve kayıp eğrileridir. Kayıp eğrisi, her girdi için istenen ve hesaplanan sonuç arasındaki hatayı gösterir. Eğriyi gözlemleyerek, epochs sayısı (iterasyon) arttıkça eğitim kaybının azaldığı ve doğruluğun arttığı görülebilir. Doğruluk oranı yaklaşık 900. iterasyondan sonra değişmedi ve 220 epoch'ta %86.07'lik bir doğruluk oranı elde edildi. Ayrıca, kayıp eğrisi 950. iterasyondan sonra sabit görünerek 0.3 kayıp oranına ulaştı.

4.3. WELCH DENEYİ

4.3.1. DT Algoritması ile Welch Yöntemi

Welch yöntemi kullanılarak DT sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.16'da verilmiştir.

Şekil 4.16: Welch ile DT sınıflandırma algoritmasının karışıklık matrisi

Karar Ağacı Algoritmasının Karışıklık Matrisi

Gerçek Sınıf	C	790	122	86.6%	13.4%
	M	102	924	90.1%	9.9%
		88.6%	88.3%		
		11.4%	11.7%		
		C	M		
			Tahmini Sınıf		

DT algoritması ile wech yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1714 örnek doğru sınıflandırılmış ve toplam 224 örnek yanlış sınıflandırılmıştır. Doğru şekilde sınıflandırılan 1714 örneğin 924'ü HBB ve 790'ı kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.9'da gösterilmektedir.

Tablo 4.9: Welch+DT Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	90.06
Özgüllük	86.62
Kesinlik	88.34
F1 skoru	89.19
MCC	76.79
Doğruluk	88.44

Welch kullanılarak çıkarılan özniteliklerin kullanıldığı DT algoritmasına ait duyarlılık değeri %90.06, özgüllük değeri %86.62, kesinlik değeri %88.34, f1 skoru %89.19, MCC değeri %76.79 ve doğruluk değeri %88.44 olarak hesaplanmıştır.

4.3.2. SVM Algoritması ile Welch Yöntemi

Welch yöntemi kullanılarak SVM sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.17’de verilmektedir.

Şekil 4.17: Welch ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi



SVM algoritması ile Welch yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1300 örnek doğru sınıflandırılmış ve toplam 638 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılmış 1300 örneğin 992'si HBB ve 308'i kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.10'da gösterilmektedir.

Tablo 4.10: Welch+SVM Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	96.69
Özgüllük	33.77
Kesinlik	62.16
F1 skoru	75.67
MCC	75.67
Doğruluk	67.08

Welch kullanılarak çıkarılan özneliklerin kullanıldığı SVM algoritmasına ait duyarlılık değeri %96.69, özgüllük değeri %33.77, kesinlik değeri %62.16, f1 skoru %75.67, MCC değeri %75.67 ve doğruluk değeri %67.08 olarak hesaplanmıştır.

4.3.3. KNN Algoritması ile Welch Yöntemi

Welch yöntemi kullanılarak KNN sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.18’de verilmiştir.

Şekil 4.18: Welch ile KNN sınıflandırma algoritmasının karışıklık matrisi



KNN algoritması ile wech yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1780 örnek doğru sınıflandırılmış ve toplam 158 örnek yanlış sınıflandırılmıştır. Doğru sınıflandırılan 1780 örneğin 918’i HBB ve 862’si kontrol grubuydu. Karışıklık matrisinin değerleri performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.11’de gösterilmektedir.


Tablo 4.11: Welch+KNN Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	96.69
Özgüllük	97.26
Kesinlik	97.54
F1 skoru	92.08
MCC	83.85
Doğruluk	91.85

Welch kullanılarak çıkarılan özniteliklerin kullanıldığı KNN algoritmasına ait duyarlılık değeri %96.69, özgüllük değeri %97.26, kesinlik değeri %97.54, f1 skoru %92.08, MCC değeri %83.85 ve doğruluk değeri %91.85 olarak hesaplanmıştır.

4.3.4. BiLSTM Algoritması ile Welch Yöntemi

Welch yöntemi kullanılarak BiLSTM sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.19'da verilmiştir.

Şekil 4.19: Welch ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi

BiLSTM algoritması ile wech yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1847 örnek doğru sınıflandırılmış ve


toplam 91 örnek yanlış sınıflandırılmıştır. Doğru şekilde sınıflandırılan 1847 örneğin 985'i HBB ve 862'si kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.12'de gösterilmektedir.

Tablo 4.12: Welch+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	96.00
Özgüllük	94.52
Kesinlik	95.17
F1 skoru	95.58
MCC	90.58
Doğruluk	95.30

Welch kullanılarak çıkarılan özniteliklerin kullanıldığı BiLSTM algoritmasına ait duyarlılık değeri %96.00, özgüllük değeri %94.52, kesinlik değeri %95.17, f1 skoru %95.58, MCC değeri %90.58 ve doğruluk değeri %95.30 olarak hesaplanmıştır. Modelin 220 epochs eğitim ve kayıp eğrileri Şekil 4.20'de verilmektedir.

Şekil 4.20: Welch Modelinin Eğitim Doğruluğu ve Kayıp Grafiği




Şekil 4.20 Welch yönteminin BiLSTM algoritması ile eğitim ve kayıp eğrileridir. Kayıp eğrisi, her girdi için istenen ve hesaplanan sonuç arasındaki hatayı gösterir. Eğriyi gözlemleyerek, epochs sayısı (iterasyon) arttıkça eğitim kaybının istikrarlı bir şekilde azaldığı ve doğruluğun arttığı görülebilir. Doğruluk, 220 epoch'ta %95.30'luk bir doğruluk oranına ulaşan yaklaşık 800. iterasyondan sonra modelini değiştirmede. Ancak kayıp eğrisi, 1100. İterasyondan sonra sonuna kadar azalmaya devam etti ve 0.1 kayba ulaştı.

4.4. MULTITAPER DENEYİ

4.4.1. DT Algoritması ile Multitaper Yöntemi

Multitaper yöntemi kullanılarak DT sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.21'de verilmiştir.

Şekil 4.21: Multitaper ile DT Sınıflandırma Algoritmasının Karışıklık Matrisi

DT algoritması ile Multitaper yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1791 örnek doğru sınıflandırılmış ve toplam 147 örnek yanlış sınıflandırılmıştır. Doğru şekilde sınıflandırılan 1791 örneğin 938'i HBB ve 853'ü kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.13'te gösterilmektedir.

Tablo 4.13: Multitaper+DT Algoritmasının Performans Değerlendirme Metrikleri

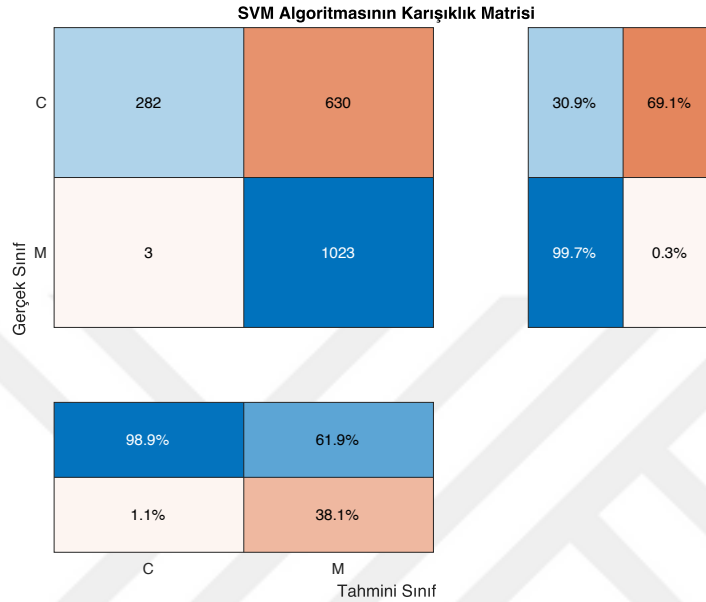
Metrikler	Başarı (%)
Duyarlılık	91.42
Özgüllük	93.53
Kesinlik	94.08
F1 skoru	92.73
MCC	84.84
Doğruluk	92.41

Multitaper kullanılarak çıkarılan özneliklerin kullanıldığı DT algoritmasına ait duyarlılık değeri %91.42, özgüllük değeri %93.53, kesinlik değeri %94.08, f1 skoru %92.73, MCC değeri %84.84 ve doğruluk değeri %92.41 olarak hesaplanmıştır.

4.4.2. SVM Algoritması ile Multitaper Yöntemi

SVM sınıflandırma algoritmasının Multitaper yöntemi kullanılarak karışıklık matrisi hesaplanmıştır ve bu Şekil 4.22’de verilmektedir.

Şekil 4.22: Multitaper ile SVM Sınıflandırma Algoritmasının Karışıklık Matrisi



SVM algoritması ile Multitaper yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1305 örnek doğru sınıflandırılmış ve toplam 633 örnek yanlış sınıflandırılmıştır. Doğru şekilde sınıflandırılan 1305 örneğin 1023’ü HBB ve 282’si kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.14’te gösterilmektedir.

Tablo 4.14: Multitaper+SVM Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	99.71
Özgüllük	30.92
Kesinlik	61.89
F1 skoru	76.37
MCC	43.17
Doğruluk	67.34

Multitaper kullanılarak çıkarılan özniteliklerin kullanıldığı SVM algoritmasına ait duyarlılık değeri %99.71, özgüllük değeri %30.92, kesinlik değeri %61.89, f1 skoru %76.37, MCC değeri %43.17 ve doğruluk değeri %67.34 olarak hesaplanmıştır.

4.4.3. KNN Algoritması ile Multitaper Yöntemi

Multitaper yöntemi kullanılarak KNN sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.23'te verilmiştir.

Şekil 4.23: Multitaper ile KNN Sınıflandırma Algoritmasının Karışıklık Matrisi



KNN algoritması ile Multitaper yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1879 örnek doğru sınıflandırılmış ve toplam 59 örnek yanlış sınıflandırılmıştır. Doğru şekilde sınıflandırılan 1879 örneğin 992'si HBB ve 887'si kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.15'te gösterilmektedir.

Tablo 4.15: Multitaper+KNN Algoritmasının Performans Değerlendirme Metrikleri


Metrikler	Başarı (%)
Duyarlılık	96.69
Özgüllük	97.26
Kesinlik	97.54
F1 skoru	97.11
MCC	93.90
Doğruluk	96.96

Multitaper kullanılarak çıkarılan özneliklerin kullanıldığı KNN algoritmasına ait duyarlılık değeri %96.69, özgüllük değeri %97.26, kesinlik değeri %97.54, f1 skoru %97.11, MCC değeri %93.90 ve doğruluk değeri %96.96 olarak hesaplanmıştır.

4.4.4. BiLSTM Algoritması ile Multitaper Yöntemi

Multitaper yöntemi kullanılarak BiLSTM sınıflandırma algoritmasının karışıklık matrisi hesaplanmıştır ve bu Şekil 4.24'te verilmiştir.

Şekil 4.24: Multitaper ile BiLSTM Sınıflandırma Algoritmasının Karışıklık Matrisi




BiLSTM algoritması ile Multitaper yöntemi kullanılarak elde edilen karışıklık matrisi değerlerinin sonucu analiz edilmiştir. Toplam 1918 örnek doğru sınıflandırıldı ve toplam 20 örnek yanlış sınıflandırıldı. Doğru sınıflandırılan 1918 örnekten 1009'u HBB ve 909'u kontrol grubuydu. Karışıklık matrisinin değerleri, performans değerlendirme metrikleri ile değerlendirilmiştir ve bu Tablo 4.16'da gösterilmektedir.

Tablo 4.16: Multitaper+BiLSTM Algoritmasının Performans Değerlendirme Metrikleri

Metrikler	Başarı (%)
Duyarlılık	98.34
Özgüllük	99.67
Kesinlik	99.70
F1 skoru	99.02
MCC	97.94
Doğruluk	98.97

Multitaper kullanılarak çıkarılan özneliklerin kullanıldığı BiLSTM algoritmasına ait duyarlılık değeri %98.34, özgüllük değeri %99.67, kesinlik değeri %99.70, f1 skoru %99.02, MCC değeri %97.94 ve doğruluk değeri %98.97 olarak hesaplanmıştır. Modelin 220 epochs eğitim ve kayıp eğrileri Şekil 4.25'te verilmektedir.

Şekil 4.25: Multitaper Modelinin Eğitim Doğruluğu ve Kayıp Grafiği



Şekil 4.25, BiLSTM algoritması ile Multitaper yönteminin eğitim ve kayıp eğrileridir. Kayıp eğrisi, her girdi için istenen ve hesaplanan sonuç arasındaki hatayı gösterir. Eğriyi gözlemleyerek, epochs sayısı (iterasyon) arttıkça eğitim kaybının düştüğü ve doğruluğun arttığı görülebilir. Doğruluk, 600. iterasyondan sonra modelini değiştirmede ve 220 epoch'ta %98.97'lik bir doğruluk oranına ulaştı. Ayrıca, aynı sayıda epoch'tan sonra, kayıp eğrisi de neredeyse sabit kaldı ve 0.1 kayıp oranının altında bir değere ulaştı.

4.5. TÜM MODELLERİN KARŞILAŞTIRILMASI

DWT liderleri ve üç farklı spektral analiz yöntemi kullanılarak EEG sinyallerinden öznitelik vektörleri ve sinyallerin PSD'si çıkarıldıktan sonra, çıkarılan öznitelik vektörleri ve spektral öznitelikler, HBB ve normal grupları sınıflandırmak için sınıflandırma algoritmalarına uygulandı. DT, SVM, KNN ve BiLSTM sınıflandırma algoritmaları kullanıldıktan sonra, dört modelin de sınıflandırma algoritmalarının karışıklık matrisinin sonuçları karşılaştırılarak doğru sınıflandırmaların yapıp yapılmadığı kontrol edildi. Daha sonra performans değerlendirme metrikleri kullanılarak değerlendirildiler. Dört modelin de karışıklık matrisinin sonuçları hesaplanmış ve değerleri Tablo 4.17'de gösterilmiştir.

Tablo 4.17: Dört Modelin Sınıflandırma Algoritmalarının Karışıklık Matrisinin Karşılaştırılması

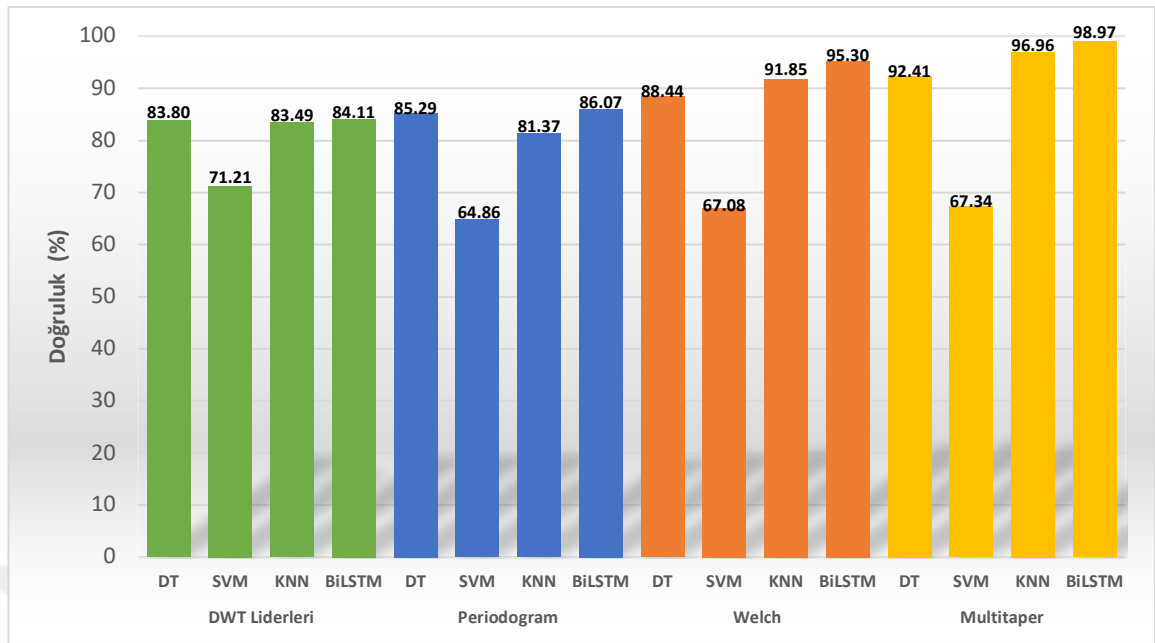
		Deney 1 (DWT Liderleri)		Deney 2 (Periodogram)		Deney 3 (Welch)		Deney 4 (Multitaper)	
		Normal	HBB	Normal	HBB	Normal	HBB	Normal	HBB
DT	Normal	752	160	766	146	790	122	853	59
	HBB	154	872	139	887	102	924	88	938
	TP+TN	1624		1653		1714		1791	
SVM	Normal	546	366	305	607	308	604	282	630
	HBB	192	834	74	952	34	992	3	1023
	TP+TN	1380		1257		1300		1305	
KNN	Normal	750	162	743	169	862	50	887	25
	HBB	158	868	192	834	108	918	34	992
	TP+TN	1618		1577		1780		1879	
BiLSTM	Normal	778	134	805	107	862	50	909	3
	HBB	174	852	163	863	41	985	17	1009
	TP+TN	1630		1668		1847		1918	

Dört deneyin tümünün karışıklık matrisinin sonuçları, en yüksek doğru sınıflandırılmış örneklere sahip modeli ve algoritmayı bulmak için karşılaştırıldı. Bunları inceledikten sonra, DWT liderleri deneyinde en fazla sayıda doğru tanımlanmış örneğe sahip algoritma, 1630 doğru sınıflandırılmış örneğe sahip BiLSTM idi. İkinci yöntem olan Periodogram yönteminde, en fazla sayıda doğru sınıflandırılmış örneği başarıyla tespit eden algoritma, 1668 doğru sınıflandırılmış örnekle BiLSTM algoritması olmuştur. Üçüncü deneyde, BiLSTM derin öğrenme algoritmasına sahip Welch yöntemi de 1847 örnekle en yüksek doğru sınıflandırılmış örneği elde etti. Dördüncü deneyde ise BiLSTM derin öğrenme algoritması ile Multitaper spektral analiz yönteminin kullanıldığı deney, 1918 doğru sınıflandırılmış örnekle en fazla sayıda doğru sınıflandırılmış örneği kazanmıştır. Dört modelde de kullanılan tüm algoritmalar arasında, BiLSTM algoritmasının HBB tanısı için diğer algoritmalar arasında en iyi şekilde sınıflandırıldığını belirten en yüksek doğrulukta sınıflandırılmış örneklere ulaştığı görülmektedir. Genel olarak, BiLSTM algoritmasına sahip Multitaper yönteminde TP olarak sınıflandırılan 1009 örnek, FP olarak 3 örnek, FN olarak 17 örnek ve TN olarak 909 örnek vardı; toplam 1918 doğru sınıflandırılmış örnek, deneyin geri kalan algoritmaları arasında en yüksek olanıydı. Ayrıca dört deneyin performansı, sınıflandırma algoritmalarının karışıklık matrisinin değerleri kullanılarak duyarlılık, özgüllük, kesinlik, f1 skoru, MCC ve doğruluk gibi performans değerlendirme metrikleri ile değerlendirildi ve karşılaştırıldı. Dört deneyin tümünün değerlendirme ölçütlerinin performansının karşılaştırması Tablo 4.18’de gösterilmektedir.

Tablo 4.18: Dört Modelin Sınıflandırma Algoritmalarının Performans Değerlendirme Metrikleri Sonuçları

Deneyler	Sınıflandırma Algoritmaları	Performans değerlendirme metrikleri (%)					
		Duyarlılık	Özgüllük	Kesinlik	F1 skoru	MCC	Doğruluk
DWT Liderleri	DT	84.99	82.46	84.50	84.74	67.47	83.80%
	SVM	81.29	59.87	69.50	74.93	42.30	71.21%
	KNN	84.60	82.24	84.27	84.44	66.85	83.49%
	BiLSTM	83.04	85.31	86.41	84.69	68.24	84.11%
Periodogram	DT	86.45	83.99	85.87	86.16	70.48	85.29%
	SVM	92.79	33.44	61.06	73.66	33.01	64.86%
	KNN	81.29	81.47	83.15	82.21	62.69	81.37%
	BiLSTM	84.11	88.27	88.97	86.47	72.26	86.07%
Welch	DT	90.06	86.62	88.34	89.19	76.79	88.44%
	SVM	96.69	33.77	62.16	75.67	39.88	67.08%
	KNN	96.69	97.26	97.54	92.08	83.85	91.85%
	BiLSTM	96.00	94.52	95.17	95.58	90.58	95.30%
Multitaper	DT	91.42	93.53	94.08	92.73	84.84	92.41%
	SVM	99.71	30.92	61.89	76.37	43.17	67.34%
	KNN	96.69	97.26	97.54	97.11	93.90	96.96%
	BiLSTM	98.34	99.67	99.70	99.02	97.94	98.97%

Karışıklık matrisi ile elde edilen değerler, sınıflandırma algoritmasının performanslarını test etmek için kullanılmış ve en iyi performansa sahip algoritma incelenmiştir. Dört deneyi de sınıflandırma algoritmaları ile inceleyip karşılaştırdıktan sonra, BiLSTM derin öğrenme algoritması ile Multitaper yönteminin aralarında en iyi performansı gösterdiği görülmektedir. Performans sonuçları %98.34 duyarlılık, %99.67 özgüllük, %99.70 kesinlik, %99.02 f1 skoru, %97.94 MCC ve %98.97 doğruluk gösterdi. Ayrıca, algoritmanın performansını net bir şekilde görselleştirmek için dört deneyin tümünün algoritmalarının doğruluk performansını karşılaştıran bir çubuk grafik çizildi ve Şekil 4.26'da gösterildi. Buna bağlı olarak, BiLSTM algoritması ile yapılan Multitaper deneyinin aralarında en yüksek doğruluğu elde ettiği açıkça gösterilmiştir.

Şekil 4.26: Dört Deneyin Sınıflandırma Algoritmalarının Doğruluk Performansı

Ayrıca, bu araştırmanın sonucu, EEG sinyalleri kullanılarak HBB tanısına dayalı diğer literatür çalışmaları ile karşılaştırıldı. Başarı oranları ve çalışmalarında kullanılan algoritma sayısı da karşılaştırıldı. Karşılaştırma Tablo 4.19’da gösterilmiş ve açıklamaları aşağıda verilmiştir.

Tablo 4.19: İlgili Literatürün Karşılaştırmalı Analizi

Yazar	Yöntem	Veriseti	En iyi sınıflandırıcı	Doğruluk
Hadiyoso ve Tati (2018)	Hjorth tanımlayıcı ve sınıflandırma için KNN	10 Kişi (5 Normal ve 5 HBB)	KNN	80.00%
Alvi, Siuly ve Wang (2022)	LSTM tabanlı mimari	27 Kişi (16 Normal ve 11HBB)	LSTM	96.41%
Hadiyoso vd. (2019)	Doğrusal kantitatif EEG tabanlı güç spektral öznitelikleri ve KNN algoritması	27 Kişi (16 Normal ve 11 HBB)	KNN	81.5%
Alvi vd. (2022)	LSTM, SVM ve KNN sınıflandırıcılı GRU modeli	27 Kişi (16 Normal ve 11 HBB)	GRU	96.91%
Kashefpoor, Rabbani ve Barekatin (2019)	CLC-KSVD kullanarak denetimli sözlük öğrenimi	61 Kişi (32 Normal ve 29 HBB)	CLC-KSVD	88.9%
Yin vd. (2019)	Spektral-zamansal analize dayalı HBB teşhis çerçevesi	27 Kişi (11 Normal ve 16 HBB)	SVM	96.94

Jamaloo, Mikaeili ve Noroozian (2020)	Sürekli HMM modeline dayalı çok metrik fonksiyonel bağlantı analizi	14 Kişi (7 Normal ve 7 HBB)	HMM	Gamma 97.2 ± 0.5 %
Kashefpoor, Rabbani ve Barekatain (2016)	Spektral öznitelikler korelasyon tabanlı algoritmalar kullanılarak HBB teşhisi	27 Kişi (16 Normal ve 11 HBB)	Nöro bulanık sistem ve KNN'nin kombinasyonu	88.89%
Siuly vd. (2020)	SVM, ELM ve KNN algoritmaları	27 Kişi (16 Normal ve 11 HBB)	ELM	98.78%
Önerilen model	Multitaper spektral analiz ve BiLSTM derin öğrenme algoritması	34 Kişi (16 Normal ve 18 HBB)	BiLSTM	98.97%

EEG sinyallerinden HBB'nin tespiti ile ilgili yapılan çalışmalar incelendiğinde, çeşitli yöntemlerin kullanıldığı, verisetleri ve bu yöntemlerin başarı oranları görülmektedir. Hadiyoso ve Tati (2018), Hadiyoso vd. (2019) ve Kashefpoor, Rabbani ve Barekatain'in (2016) çalışmasında aynı sınıflandırıcı olan KNN sınıflandırıcısı kullanılmış, ancak Kashefpoor, Rabbani ve Barekatain'in (2016) çalışmasında KNN ve nöro bulanık sistemle kullanılmıştır ve diğer iki çalışmadan daha yüksek bir doğrulukla %88.89'luk bir doğruluk elde etmek için sürdürüldü. Kashefpoor, Rabbani ve Barekatain (2019), Alvi vd. (2022) ve Jamaloo, Mikaeili ve Noroozian'ın (2020) çalışması, çalışmalarını yapmak için farklı bir yöntem kullandı. Çalışma Kashefpoor, Rabbani ve Barekatain (2019), EEG sinyallerinin k-means ve SVD yöntemi kullanılarak analizine dayanan CLC-KSVD adlı denetimli sözlük öğrenmeyi kullandı ve %88.9'luk bir doğruluk elde etti. Alvi vd. (2022) çalışmasında, LSTM, SVM ve KNN sınıflandırıcıları ile GRU modeli kullanıldı ve ardından HBB'nin tespiti için en etkili modeli bulmak için sınıflandırıcıları karşılaştırıldı. Sonuç olarak GRU modeli, sınıflandırıcıları arasında %96.91 doğrulukla en yüksek doğruluğa ulaşmıştır. Jamaloo, Mikaeili ve Noroozian (2020) çalışmasında gizli durumlara sahip bir model olan HMM modelini kullanmış ve %97.2 doğruluk elde etmiştir. Yin vd. (2019) ve Alvi, Siuly ve Wang'ın (2022) çalışmasında bu çalışmaya benzer bir yöntem kullanılmıştır. Bununla birlikte, Alvi, Siuly ve Wang'ın (2022) çalışmasında, EEG sinyallerinden spektral özellikler çıkarıldıktan sonra HBB'yi teşhis etmek için LSTM modeli kullanılırken, bu araştırma çalışmasında HBB'yi tespit etmek için BiLSTM derin öğrenme algoritması kullanılmıştır. Yin vd. 'nin (2019) çalışması, spektral-zamansal analiz kullanarak EEG sinyallerinin öznitelik vektörlerini çıkarırken ve bu araştırma çalışmasında kullanılan bazı algoritmalar olan SVM, KNN ve DT algoritmalarını modellerini test etmek için kullandı. Daha sonra modellerini karşılaştırdılar ve SVM sınıflandırıcı algoritması yüksek performansla

sınıflandırdı ve %96.94 doğruluk elde etti. Siuly vd. (2020) çalışması, yukarıda belirtilen diğer tüm çalışmalardan oldukça farklı bir yöntem kullandı. Diğer çalışmalarda olduğu gibi sinyallerdeki gürültüyü kaldırdılar. Bununla birlikte, güvenilir bir analize ulaşmak için parçalı bir toplam yaklaşımı kullanarak sinyallerin büyük hacmini sıkıştırdılar ve sıkıştırdıktan sonra, EEG sinyallerindeki alternatif değişikliğin HBB ve normal grupları arasında başarılı bir şekilde ayırım yapıp yapamayacağını görmek için Permütasyon entropi özniteliklerini ve oto-regresif tekniği incelediler. Daha sonra kişileri sınıflandırmak için SVM, KNN ve ELM makine öğrenimi algoritmalarını kullandılar. ELM tabanlı yaklaşım böylece %98.78'lik en iyi performans sınıflandırma doğruluğunu elde etti.

İlgili literatür çalışmalarında, çeşitli makine öğrenme algoritmaları ve derin öğrenme algoritmaları ile EEG sinyallerini kullanarak HBB'nin tahminine odaklanmıştır. Yukarıdaki tüm çalışmalar arasında, bu araştırma çalışması, HBB tahminini yukarıda belirtilen çalışmalardan farklı bir şekilde, dört farklı öznitelik çıkarma yöntemi modeli, DWT liderleri, Periodogram, Welch ve Multitaper, EEG sinyallerinden öznitelik vektörleri çıkarılarak gerçekleştirilmiştir. Öznitelik çıkarma işleminden sonra, makine öğrenme algoritması ve derin öğrenme algoritması kullanılarak sınıflandırıldı ve ardından en iyi performansı gösteren modeli bulmak için karşılaştırıldı. Sonuç olarak, Multitaper spektral analiz yöntemi ile BiLSTM derin öğrenme algoritmasını birleştiren modelde %98.97 doğrulukla en yüksek doğruluğa ulaşmıştır. Bu, modelin HBB hastalarını normal olanlardan ayırmada etkili bir modeli olduğunu göstermektedir.

SONUÇ VE ÖNERİLER

Teknolojik ilerleme 21. yüzyılda tıp alanında üretkenliği, etkinliği ve kolaylığı daha önce hiç olmadığı kadar artırdı. Yapay zeka, derin öğrenme ve makine öğrenimi algoritmalarına olan ilginin yaygınlaşmasıyla birlikte, hastalıkları tespit etmedeki etkinlikleri nedeniyle EEG verilerini kullanarak hastalıkları sınıflandırmak için bilimsel araştırma incelemelerinde giderek daha fazla istihdam edilmektedirler. Bu nedenle, nöropsikolojik bozuklukların teşhisinde bu modellerin kullanılması, hastalığın tedavi edilebilir bir aşamada erken saptanmasına yardımcı olabilir, böylece hastalığın ilerlemesini sınırlar ve böylece hastanın hayatını kurtarır.

Bu çalışmada HBB hastalarını etkili bir şekilde tespit edebilen derin öğrenme modeli ile spektral analiz yöntemi kullanılarak EEG sinyallerinden teşhise dayalı bir model önerilmiştir. Bu çalışmayı gerçekleştirmek için dört farklı deney yapıldı ve daha sonra HBB gönüllülerini normal gruplardan etkili bir şekilde ayırabilen en iyi performans modelini kontrol etmek için karşılaştırıldı. İlk olarak, EEG sinyallerini gürültüden arındırmak için MSPCA kullanılmış ve daha sonra amplifying all-time (zamanda çarpma) DA yöntemi kullanılarak veriseti üçe katlanmıştır. Daha sonra EEG sinyallerinden öznitelik vektörlerini ve PSD'yi çıkarmak için DWT liderleri ve üç spektral analiz öznitelik çıkarma yöntemi, Periodogram, Welch ve Multitaper yöntemleri kullanıldı. Daha sonra deneğin EEG sinyalleri, çeşitli makine öğrenme algoritmaları, DT, SVM, KNN ve BiLSTM derin öğrenme algoritması gibi kullanılarak sınıflandırıldı. Daha sonra bu algoritmaların performansı, performans değerlendirme metrikleri ile değerlendirilmiş ve sonuçları karşılaştırılarak aralarında etkili olan algoritma kontrol edilmiştir. Sonuç olarak, BiLSTM derin öğrenme algoritma modeli ile Multitaper spektral analiz yöntemi %98.97 doğruluk, %98.34 duyarlılık, %99.67 özgüllük, %99.70 kesinlik, %99.02 f1 skoru ve %97.94 MCC ile en yüksek performansı elde etmiştir.

Bu çalışmanın sonucu, BiLSTM algoritması ile Multitaper spektral analiz yöntemi kullanılarak EEG sinyallerinin PSD'sinin sınıflandırılmasının, EEG sinyallerinden HBB'yi tespit etmede başarılı olduğunu göstermektedir. Ayrıca bu tezde spektral tabanlı bu derin öğrenme modelinin daha önceki modellere ve önceki literatür çalışmalarına göre daha yüksek başarı elde ettiğini göstermektedir.

KAYNAKÇA

- Abhang, P. A., Gawali, B. W., & Mehrotra, S. C. (2016). *Introduction to EEG-and speech-based emotion recognition*. India: Academic Press.
- Alden, E. C., Pudumjee, S. B., Lundt, E. S., Albertson, S. M., Machulda, M. M., Kremers, W. K., Jack, Jr. C.R., Knopman, D.S., Petersen, R.C., Mielke, M.M., & Stricker, N. H. (2021). Diagnostic accuracy of the Cogstate Brief Battery for prevalent MCI and prodromal AD (MCI A+ T+) in a population-based sample. *Alzheimer's & Dementia*, 17(4), 584-594.
- Alvi, A. M., Siuly, S., & Wang, H. (2022). A long short-term memory based framework for early detection of mild cognitive impairment from EEG signals. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 7(2), 375-388.
- Alvi, A. M., Siuly, S., Wang, H., Wang, K., & Whittaker, F. (2022). A deep learning based framework for diagnosis of mild cognitive impairment. *Knowledge-Based Systems*, 248, 1-9.
- Al-Qerem, A., Kharbat, F., Nashwan, S., Ashraf, S., & Blaou, K. (2020). General model for best feature extraction of EEG using discrete wavelet transform wavelet family and differential evolution. *International Journal of Distributed Sensor Networks*, 16(3), 1-21.
- Anand, S. S., Singh, H., & Dash, A. K. (2009). Clinical applications of PET and PET-CT. *Medical Journal Armed Forces India*, 65(4), 353-358.
- Ashok, P., Jackermeier, M., Jagtap, P., Křetinský, J., Weininger, M., & Zamani, M. (2020, 22-24 April). *Dt Control: Decision tree learning algorithms for controller representation*. [Sözlü bildiri]. 23. International Conference on Hybrid Systems: Computation and Control, Sydney New South Wales Australia.
- Bai, X. (2018, 24-26 September). *Text classification based on LSTM and attention*. [Sözlü bildiri]. 13. In 2018 Thirteenth International Conference on Digital Information Management (ICDIM). IEEE, Berlin Germany.
- Barrow, D. K., & Crone, S. F. (2013, 4-9 August). *Crogging (cross-validation aggregation) for forecasting—A novel algorithm of neural network ensembles on time series subsamples*. [Sözlü bildiri]. 2013 International Joint Conference on Neural Networks (IJCNN), IEEE, Dallas TX USA.
- Baschi, R., Luca, A., Nicoletti, A., Caccamo, M., Cicero, C. E., D'Agate, C., Di Giorgi, L., La Bianca, G., Lo Castro, T., Zappia, M., & Monastero, R. (2020). Changes in motor, cognitive, and behavioral symptoms in Parkinson's disease and mild cognitive impairment during the COVID-19 lockdown. *Frontiers in Psychiatry*, 11, 1-10.
- Bastos, N. S., Marques, B. P., Adamatti, D. F., & Billa, C. Z. (2020). Analyzing EEG signals using decision trees: A study of modulation of amplitude. *Computational Intelligence and Neuroscience*, 2020, 1-11.
- Battineni, G., Sagaro, G. G., Chinatalapudi, N., & Amenta, F. (2020). Applications of machine learning predictive models in the chronic disease diagnosis. *Journal of Personalized Medicine*, 10(2), 1-11.
- Benouioua, D., Candusso, D., Harel, F., & Oukhellou, L. (2017). Multifractal analysis of stack voltage based on wavelet leaders: A new tool for PEMFC diagnosis. *Fuel*

Cells, 17(2), 217-224.

- Bihter, D. A. Ş. (2020). A comparative study on the performance of classification algorithms for effective diagnosis of liver diseases. *Sakarya University Journal of Computer and Information Sciences*, 3(3), 366-375.
- Bizzi, E., Hyman, S. E., Raichle, M. E., Kanwisher, N., Phelps, E. A., Morse, S. J., & Greely, H. T. (2009). Using imaging to identify deceit: Scientific and ethical questions. *Cambridge, MA: American Academy of Arts and Sciences*, 1, 3-6.
- Bourel-Ponchel, E., Gueden, S., Hasaerts, D., Héberlé, C., Malfilâtre, G., Mony, L., Vignolo-Diard, P., & Lamblin, M. D. (2021). Normal EEG during the neonatal period: maturational aspects from premature to full-term newborns. *Neurophysiologie Clinique*, 51(1), 61-88.
- Britton, J. W., Frey, L. C., Hopp, J. L., Korb, P., Koubeissi, M. Z., Lievens, W. E., Pestana-Knight, E.M., & St Louis, E. K. (2016, 19 Oct). *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. Europe PMC, American Epilepsy Society Chicago.
- Cai, H., Chen, Y., Han, J., Zhang, X., & Hu, B. (2018). Study on feature selection methods for depression detection using three-electrode EEG data. *Interdisciplinary Sciences: Computational Life Sciences*, 10, 558-565.
- Candy, J. V. (2019, 5 September). Multitaper spectral estimation: *An alternative to the welch periodogram approach (No. LLNL-TR-788954)*. Lawrence Livermore National Lab.(LLNL), Livermore CA United States.
- Chan, J. Y., Yau, S. T., Kwok, T. C., & Tsoi, K. K. (2021). Diagnostic performance of digital cognitive tests for the identification of MCI and dementia: A systematic review. *Ageing Research Reviews*, 72, 101506.
- Chiang, H. S., Sangaiah, A. K., Chen, M. Y., & Liu, J. Y. (2020). A novel artificial bee colony optimization algorithm with SVM for bio-inspired software-defined networking. *International Journal of Parallel Programming*, 48, 310-328.
- Chilamkurthy, S., Ghosh, R., Tanamala, S., Biviji, M., Campeau, N. G., Venugopal, V. K., Mahajan, V., Rao, P., & Warier, P. (2018). Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *The Lancet*, 392(10162), 2388-2396.
- Cohen, M. X. (2017). Where does EEG come from and what does it mean?. *Trends in Neurosciences*, 40(4), 208-218.
- Da Lopes Silva, F. H. (2005). What is Magnetoencephalography and why it is Relevant to Neurosurgery?. *Advances and Technical Standards in Neurosurgery*, 30, 51-67.
- Das, P., & Babadi, B. (2020). Multitaper spectral analysis of neuronal spiking activity driven by latent stationary processes. *Signal Processing*, 170, 107429.
- Das, S., Subba Rao, S., & Yang, J. (2021). Spectral methods for small sample time series: A complete periodogram approach. *Journal of Time Series Analysis*, 42(5-6), 597-621.
- Deng, Z., Zhu, X., Cheng, D., Zong, M., & Zhang, S. (2016). Efficient kNN classification algorithm for big data. *Neurocomputing*, 195, 143-148.

- Forouzannezhad, P., Abbaspour, A., Li, C., Fang, C., Williams, U., Cabrerizo, M., Barreto, A., Andrian, J., Rische, N., Curiel, R.E., Loewenstein, D., Duara, R., & Adjouadi, M. (2020). A Gaussian-based model for early detection of mild cognitive impairment using multimodal neuroimaging. *Journal of Neuroscience Methods*, 333, 1-11.
- Gadhoumi, K., Do, D., Badilini, F., Pelter, M. M., & Hu, X. (2018). Wavelet leader multifractal analysis of heart rate variability in atrial fibrillation. *Journal of Electrocardiology*, 51(6), S83-S87.
- Geng, D., Wang, C., Fu, Z., Zhang, Y., Yang, K., & An, H. (2022). Sleep EEG-Based Approach to Detect Mild Cognitive Impairment. *Frontiers in Aging Neuroscience*, 14, 1-10.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
- Guo, H., & Zhang, Y. (2020). Resting state fMRI and improved deep learning algorithm for earlier detection of Alzheimer's disease. *IEEE Access*, 8, 115383-115392.
- Güneç, K., KASIM, Ö., Tosun, M., & Büyükköroğlu, E. (2021). Estimation of pain threshold from EEG signals of subjects in physical therapy using long-short-term memory deep learning model. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 26(2), 447-460.
- Hadiyoso, S., & Tati, L. E. (2018, 05-07 December). *Mild cognitive impairment classification using hjorth descriptor based on eeg signal*. [Sözlü bildiri]. 2018. International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC). IEEE, Bandung Indonesia.
- Hadiyoso, S., Cynthia, C. L. F. A. R., ER, M. T. L., & Zakaria, H. (2019, 12-13 September). *Early detection of mild cognitive impairment using quantitative analysis of EEG signals*. [Sözlü bildiri]. 2. International Conference on Bioinformatics, Biotechnology and Biomedical Engineering (BioMIC)-Bioinformatics and Biomedical Engineering. IEEE, Yogyakarta, Indonesia.
- Houssein, E. H., Hammad, A., & Ali, A. A. (2022). Human emotion recognition from EEG-based brain-computer interface using machine learning: a comprehensive review. *Neural Computing and Applications*, 34(15), 12527-12557.
- Hsiao, Y. T., Tsai, C. F., Wu, C. T., Trinh, T. T., Lee, C. Y., & Liu, Y. H. (2021). MCI Detection Using Kernel Eigen-Relative-Power Features of EEG Signals. *In Actuators MDPI*, 10(7), 1-15.
- Hsiao, Y. T., Wu, C. T., Tsai, C. F., Liu, Y. H., Trinh, T. T., & Lee, C. Y. (2021). EEG-Based Classification Between Individuals with Mild Cognitive Impairment and Healthy Controls Using Conformal Kernel-Based Fuzzy Support Vector Machine. *International Journal of Fuzzy Systems*, 23, 2432-2448.
- Jackson, A. F., & Bolger, D. J. (2014). The neurophysiological bases of EEG and EEG measurement: A review for the rest of us. *Psychophysiology*, 51(11), 1061-1071.
- Jamaloo, F., Mikaeili, M., & Noroozian, M. (2020). Multi metric functional connectivity analysis based on continuous hidden Markov model with application in early diagnosis of Alzheimer's disease. *Biomedical Signal Processing and Control*, 61, 1-10.

- Javaid, H., Manor, R., Kumarnsit, E., & Chatpun, S. (2022). Decision Tree in Working Memory Task Effectively Characterizes EEG Signals in Healthy Aging Adults. *IRBM*, 43(6), 705-714.
- Jonckers, E., Shah, D., Hamaide, J., Verhoye, M., & Van der Linden, A. (2015). The power of using functional fMRI on small rodents to study brain pharmacology and disease. *Frontiers in Pharmacology*, 6, 1-19.
- Kandel, E. R. (1991). Nerve cells and behavior. *Principles of Neural Science*, 3, 18-32.
- Kashefpoor, M., Rabbani, H., & Barekatin, M. (2016). Automatic diagnosis of mild cognitive impairment using electroencephalogram spectral features. *Journal of Medical Signals and Sensors*, 6(1), 25-32.
- Kashefpoor, M., Rabbani, H., & Barekatin, M. (2019). Supervised dictionary learning of EEG signals for mild cognitive impairment diagnosis. *Biomedical Signal Processing and Control*, 53, 1-9.
- Kasper, S., Bancher, C., Eckert, A., Förstl, H., Frölich, L., Hort, J., Korczyn, AD., Kressig, R.W., Levin, O., & Palomo, M. S. M. (2020). Management of mild cognitive impairment (MCI): the need for national and international guidelines. *The World Journal of Biological Psychiatry*, 21(8), 579-594.
- Kevric, J., & Subasi, A. (2014). The effect of multiscale PCA de-noising in epileptic seizure detection. *Journal of Medical Systems*, 38, 1-13.
- Khatun, S., Morshed, B. I., & Bidelman, G. M. (2019). A single-channel EEG-based approach to detect mild cognitive impairment via speech-evoked brain responses. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(5), 1063-1070.
- Lan, H., White, P. R., Li, N., Li, J., & Sun, D. (2020). Coherently averaged power spectral estimate for signal detection. *Signal Processing*, 169, 107414.
- Lashgari, E., Liang, D., & Maoz, U. (2020). Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 346, 108885.
- Lenartowicz, A., & Loo, S. K. (2014). Use of EEG to diagnose ADHD. *Current Psychiatry Reports*, 16, 1-11.
- Leonarduzzi, R. F., Schlotthauer, G., & Torres, M. E. (2010, 31 August). *Wavelet leader based multifractal analysis of heart rate variability during myocardial ischaemia*. [Sözlü bildiri]. 2010. Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE, Buenos Aires Argentina.
- Li, Y. H., Harfiya, L. N., Purwandari, K., & Lin, Y. D. (2020). Real-time cuffless continuous blood pressure estimation using deep learning model. *Sensors*, 20(19), 1-19.
- Liu, G., & Guo, J. (2019). Bidirectional LSTM with attention mechanism and convolutional layer for text classification. *Neurocomputing*, 337, 325-338.
- Logothetis, N. K. (2008). What we can do and what we cannot do with fMRI. *Nature*, 453(7197), 869-878.
- Lombardi, G., Crescioli, G., Cavedo, E., Lucenteforte, E., Casazza, G., Bellatorre, A. G., Lista, C., Costantino, G., Frisoni, G., Virgili, G., & Filippini, G. (2020). Structural magnetic resonance imaging for the early diagnosis of dementia due to Alzheimer's disease in people with mild cognitive impairment. *Cochrane*

Database of Systematic Reviews, 3, 6-7.

- Lu, Y., Liu, C., Yu, D., Fawkes, S., Ma, J., Zhang, M., & Li, C. (2021). Prevalence of mild cognitive impairment in community-dwelling Chinese populations aged over 55 years: a meta-analysis and systematic review. *BMC geriatrics*, 21, 1-16.
- Maisey, M. N. (2005). Positron emission tomography in clinical medicine. *Positron Emission Tomography: Basic Sciences*, 9, 1-12.
- Medical Image and Signal Processing Research Center. (2023). *EEG Data*. Erişim adresi: <https://misp.mui.ac.ir/en/eeg-data-0>.
- Medithe, J. W. C., & Nelakuditi, U. R. (2016, 22-23 January). *Study of normal and abnormal EEG*. [Sözlü bildiri]. 3. International Conference on Advanced Computing and Communication Systems (ICACCS). IEEE, Coimbatore India.
- Mettler, F. A., Wiest, P. W., Locken, J. A., & Kelsey, C. A. (2000). CT scanning: patterns of use and dose. *Journal of radiological Protection*, 20(4), 353.
- National Institute of Neurological Disorders and Stroke. (2022, November). *Brain Basics: The Life and Death of a Neuron | National Institute of Neurological Disorders and Stroke*. Erişim adresi: <https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-life-and-death-neuron>
- Ng, W. B., Saidatul, A., Chong, Y. F., & Ibrahim, Z. (2019, June). *PSD-based features extraction for EEG signal during typing task*. [Sözlü bildiri]. In IOP Conference Series: Materials Science and Engineering. IOP Publishing, Bogor Indonesia.
- Nicolas-Alonso, L. F., & Gomez-Gil, J. (2012). Brain computer interfaces, a review. *Sensors*, 12(2), 1211-1279.
- Ollinger, J. M., & Fessler, J. A. (1997). Positron-emission tomography. *IEEE Signal Processing Magazine*, 14(1), 43-55.
- Perron, A. D. (2008). How to read a Head CT Scan. *Emergency Medicine*, 3, 753-764.
- Rabcan, J., Levashenko, V., Zaitseva, E., & Kvassay, M. (2021). EEG signal classification based on fuzzy classifiers. *IEEE Transactions on Industrial Informatics*, 18(2), 757-766.
- Rahmat, R. F., Faza, S., Adnan, S., Situmorang, D. T. E., Gunawan, D., & Lini, T. Z. (2021, 11-12 November). *News Articles Classification for Electronic Information and Transaction Law in Indonesia using Support Vector Machine*. [Sözlü bildiri]. In 2021 International Conference on Data Science, Artificial Intelligence, and Business Analytics (DATABIA). IEEE, Medan, Indonesia.
- Read, G. L., & Innis, I. J. (2017). Electroencephalography (Eeg). *The International Encyclopedia of Communication Research Methods*, 80, 1-18.
- Rivera, M. J., Teruel, M. A., Mate, A., & Trujillo, J. (2022). Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study. *Artificial Intelligence Review*, 55, 1-43.
- Sabbagh, M. N., Boada, M., Borson, S., Chilukuri, M., Doraiswamy, P. M., Dubois, B., Ingram, J., Iwata, A., Porsteinsson, A. P., Possin, K. L., Rabinovici, G. D., Vellas, B., Chao, S., Vergallo, A., & Hampel, H. (2020). Rationale for early diagnosis of mild cognitive impairment (MCI) supported by emerging digital technologies. *The Journal of Prevention of Alzheimer's Disease*, 7, 158-164.

- Sakai, A., Minoda, Y., & Morikawa, K. (2017, 31 August). *Data augmentation methods for machine-learning-based classification of bio-signals*. [Sözlü bildiri]. 10. In 2017 Biomedical Engineering International Conference (BMEiCON). IEEE, Hokkaido Japan.
- Serrano, E., & Figliola, A. (2009). Wavelet leaders: a new method to estimate the multifractal singularity spectra. *Physica A: Statistical Mechanics and its Applications*, 388(14), 2793-2805.
- Shad, E. H. T., Molinas, M., & Ytterdal, T. (2020). Impedance and noise of passive and active dry EEG electrodes: a review. *IEEE Sensors Journal*, 20(24), 14565-14577.
- Shih, J. J., Krusienski, D. J., & Wolpaw, J. R. (2012, March). Brain-computer interfaces in medicine. In *Mayo Clinic Proceedings Elsevier*, 87(3), 268-279.
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019, 09-12 December). *The performance of LSTM and BiLSTM in forecasting time series*. [Sözlü bildiri]. In 2019 IEEE International Conference on Big Data (Big Data). IEEE, Los Angeles CA USA.
- Singh, A., Ranjbarzadeh, R., Raj, K., Kumar, T., & Roy, A. M. (2023). Understanding EEG signals for subject-wise Definition of Armoni Activities. *Arxiv Preprint Arxiv*, 2301, 1-11.
- Siuly, S., Alçin, Ö. F., Kabir, E., Şengür, A., Wang, H., Zhang, Y., & Whittaker, F. (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.
- Stam, C. J. (2010). Use of magnetoencephalography (MEG) to study functional brain networks in neurodegenerative disorders. *Journal of the Neurological Sciences*, 289(1-2), 128-134.
- Sun, W., Su, Y., Wu, X., & Wu, X. (2020). A novel end-to-end 1D-ResCNN model to remove artifact from EEG signals. *Neurocomputing*, 404, 108-121.
- Syed, S. H., & Muralidharan, V. (2022). Feature extraction using Discrete Wavelet Transform for fault classification of planetary gearbox—A comparative study. *Applied Acoustics*, 188, 108572.
- Tan, Z., Liu, J., & Chen, J. (2021). Detecting stock market turning points using wavelet leaders method. *Physica A: Statistical Mechanics and its Applications*, 565, 1-13.
- Teplan, M. (2002). Fundamentals of EEG measurement. *Measurement Science Review*, 2(2), 1-11.
- Trauth, M. H. (2021). Spectral analysis in Quaternary sciences. *Quaternary Science Reviews*, 270, 1-13.
- Ustundag, M. (2021). A Novel Analog Modulation Classification: Discrete Wavelet Transform-Extreme Learning Machine (DWT-ELM). *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 10(2), 492-506.
- Üngüren, E. (2015). Beynin nöroanatomik ve nörokimyasal yapısının kişilik ve davranış üzerindeki etkisi. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(1), 195.
- Vu, H. L., Ng, K. T. W., Richter, A., & An, C. (2022). Analysis of input set characteristics

- and variances on k-fold cross validation for a Recurrent Neural Network model on waste disposal rate estimation. *Journal of Environmental Management*, 311, 114869.
- Wagner Jr, H. N. (1998, July). A brief history of positron emission tomography (PET). *In Seminars in Nuclear Medicine WB Saunders*, 28(3), 213-220.
- Wang, Y., Huang, M., Zhu, X., & Zhao, L. (2016, November). *Attention-based LSTM for aspect-level sentiment classification*. [Sözlü bildiri]. In Proceedings of the 2016 Conference on Empirical Methods In Natural Language Processing, Beijing China.
- Wang, J., & Wang, M. (2021). Review of the emotional feature extraction and classification using EEG signals. *Cognitive Robotics*, 1, 29-40.
- Wang, Q., Zeng, W., & Dai, X. (2022). Gait classification for early detection and severity rating of Parkinson's disease based on hybrid signal processing and machine learning methods. *Cognitive Neurodynamics*, 2022, 1-24.
- Wheless, J. W., Castillo, E., Maggio, V., Kim, H. L., Breier, J. I., Simos, P. G., & Papanicolaou, A. C. (2004). Magnetoencephalography (MEG) and magnetic source imaging (MSI). *The Neurologist*, 10(3), 138-153.
- World Health Organization. (2017). Global action plan on the public health response to dementia 2017–2025.
- Xie, W., She, Y., & Guo, Q. (2021). Research on multiple classification based on improved svm algorithm for balanced binary decision tree. *Scientific Programming*, 2021, 1-11.
- Xiong, Q., Zhang, X., Wang, W. F., & Gu, Y. (2020). A parallel algorithm framework for feature extraction of EEG signals on MPI. *Computational and Mathematical Methods in Medicine*, 2020,1-4.
- Yan, T., Shen, S. L., Zhou, A., & Chen, X. (2022). Prediction of geological characteristics from shield operational parameters by integrating grid search and K-fold cross validation into stacking classification algorithm. *Journal of Rock Mechanics and Geotechnical Engineering*, 14(4), 1292-1303.
- Yin, J., Cao, J., Siuly, S., & Wang, H. (2019). An integrated MCI detection framework based on spectral-temporal analysis. *International Journal of Automation and Computing*, 16, 786-799.
- Zhang, S., Li, X., Zong, M., Zhu, X., & Wang, R. (2017). Efficient KNN classification with different numbers of nearest neighbors. *IEEE Transactions On Neural Networks and Learning Systems*, 29(5), 1774-1785.
- Zhang, S. (2020). Cost-sensitive KNN classification. *Neurocomputing*, 391, 234-242.

DİZİN

-A-

ADNI, ix, 6
 Alzheimer hastalığı, 1, 6
 Alzheimer Hastalığı Nörogörüntüleme
 Girişimi, ix

-B-

BiLSTM, ii, iii, v, vi, vii, viii, ix, 3, 19,
 26, 27, 28, 36, 41, 42, 47, 48, 53, 54,
 58, 59, 60, 61, 62, 63, 64, 65, 66, 74

-C-

CT, v, ix, 2, 12, 13, 67, 69, 73

-D-

DA, ii, iii, v, ix, 3, 19, 22, 66
 Derin Öğrenme, 2, ii
 DT, ii, iii, v, vi, vii, viii, ix, 3, 7, 19, 25,
 26, 36, 37, 38, 43, 44, 49, 50, 54, 55,
 60, 61, 63, 64, 66
 DWT leaders, iii, ix
 DWT liderleri, ii, vi, vii, viii, 3, 19, 22,
 23, 24, 31, 32, 35, 36, 37, 38, 39, 40,
 41, 42, 60, 61, 65, 66

-E-

ECP, ix, 5
 Elektroensefalografi, 2, ii
 ELM, ix, 8, 63, 65, 75
 ERP, ix, 5

-F-

fMRI, v, ix, 10, 12, 13, 70, 71, 72
 Fonksiyonel Manyetik Rezonans
 Görüntüleme, v, ix, 12

-G-

Gizli Markov Modeli, ix

-H-

HBB, ii, ix, 1, 2, 3, 5, 6, 7, 8, 13, 19, 20,
 31, 32, 33, 34, 35, 36, 37, 39, 40, 41,
 43, 45, 46, 47, 49, 51, 52, 53, 55, 56,
 57, 58, 60, 61, 62, 63, 64, 65, 66

HMM, ix, 7, 63, 64

-K-

KNN, ii, iii, v, vi, vii, viii, ix, 3, 6, 7, 8,
 19, 26, 36, 39, 40, 41, 45, 46, 47, 51,
 52, 57, 58, 60, 61, 63, 64, 66, 76

-L-

LDA, ix, 5
 LSTM, viii, ix, 6, 7, 26, 27, 28, 63, 64,
 67, 70, 72, 74, 75

-M-

Makine Öğrenme, ii
 Manyetoensefalogram, ix
 MCC, ii, iii, ix, 3, 29, 37, 38, 39, 40, 41,
 42, 44, 45, 46, 47, 48, 50, 51, 52, 53,
 54, 55, 56, 57, 58, 59, 61, 62, 66
 MCI, iii, ix, 63, 67, 69, 71, 73, 76
 Mini Mental Durum Testi, ix
 MMSE, ix, 1, 20
 MRI, ix, 2, 12, 13
 MSPCA, ii, iii, v, x, 3, 19, 21, 66
 Multitaper, ii, iii, v, vi, vii, viii, 3, 19,
 22, 25, 31, 32, 34, 35, 36, 54, 55, 56,
 57, 58, 59, 60, 61, 62, 65, 66, 69

-O-

Olay İlişkili Potansiyel, ix

-P-

PCA, x, 5, 21, 71
 Periodogram, ii, iii, v, vi, vii, viii, 3, 19,
 22, 24, 31, 32, 33, 35, 36, 43, 44, 45,
 46, 47, 48, 60, 61, 65, 66
 Pozitron Emisyon Tomografisi, v, x, 11
 PSD, viii, x, 3, 19, 22, 24, 25, 31, 33,
 34, 35, 36, 60, 65, 66, 73

-S-

Sinyal İşleme, ii
 SVM, ii, iii, v, vi, vii, viii, ix, x, 3, 5, 6,
 7, 8, 19, 26, 36, 38, 39, 44, 45, 50,
 51, 56, 57, 60, 61, 63, 64, 66, 69

-T-

Temel bileşenler Analizi, x

-U-

Uzun Kısa Dönem Hafıza, ii, ix

-W-

Welch, ii, iii, v, vi, vii, viii, 3, 19, 22,
24, 31, 32, 33, 34, 35, 36, 49, 50, 51,
52, 53, 54, 60, 61, 65, 66

