

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



1D VE 2D CNN DERİN ÖĞRENME ALGORİTMALARI İLE
EEG SİNYALLERİNDEN NÖROLOJİK HASTALIK TESPİTİ

YÜKSEK LİSANS TEZİ

BAHADIR ARABACI

TEZ DANIŞMANI
PROF. DR. KEMAL POLAT
İKİNCİ TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ HAKAN ÖCAL

BOLU, TEMMUZ - 2024

KABUL VE ONAY SAYFASI

BAHADIR ARABACI tarafından hazırlanan “**1D ve 2D CNN Derin Öğrenme Algoritmaları ile EEG sinyallerinden Nörolojik Hastalık Tespiti**” adlı tez çalışması jürimiz tarafından Elektrik Elektronik Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak oy birliği ile kabul edilmiştir. 10/07/2024

Jüri Üyeleri

İmza

Danışman
Prof. Dr. Kemal Polat
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Dr. Öğr. Üyesi Fatih Kayaalp
Düzce Üniversitesi

.....

Üye
Dr. Öğr. Üyesi Ümit Şentürk
Bolu Abant İzzet Baysal Üniversitesi

.....

Lisansüstü Eğitim Enstitüsü Onayı

Prof. Dr. İbrahim KÜRTÜL
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu bildirir,

aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Teze ilişkin Turnitin adlı programında enstitü müdürlüğünce belirlenen filtrelemeler uygulanarak alınmış olan benzerlik raporuna göre, tezin benzerlik oranı %30'u geçmemektedir.

.....
BAHADIR ARABACI

ÖZET

**1D VE 2D CNN DERİN ÖĞRENME ALGORİTMALARI İLE EEG
SİNYALLERİNDEN NÖROLOJİK HASTALIK TESPİTİ
YÜKSEK LİSANS TEZİ
BAHADIR ARABACI
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**(TEZ DANIŞMANI: PROF. DR. KEMAL POLAT)
(İKİNCİ DANIŞMAN: DR. ÖĞR. ÜYESİ HAKAN ÖCAL)
BOLU, TEMMUZ - 2024
XII + 77**

Bu tez çalışmasında, Epilepsi, Alzheimer ve Parkinson hastalığının 1 Boyutlu (1D) ve 2 Boyutlu (2D) spektrograma dönüştürülmüş sinyallerden derin öğrenme yoluyla tespiti yapılmıştır. EEG sinyallerinin karmaşıklığı nedeniyle, doğru nörolojik hastalık tespiti için yenilikçi bir yaklaşım gerekmektedir. Geleneksel yöntemler genellikle EEG verilerini tek boyutlu zaman serisi olarak ele alır ve sinyallerdeki önemli frekans bilgisini göz ardı eder. Çalışmamız, 1D EEG sinyallerini 2D spektrogramlara dönüştüren ve tek boyutlu sınırlamaları ele almak için kısa zamanlı Fourier dönüşümünü kullanan bir metodoloji önermektedir. Bu dönüşüm, frekans desenlerini yakalayarak analizi geliştirir ve nöral aktivitenin daha kapsamlı bir anlayışını sağlar. Epilepsi nöbeti tespitinde, 1D CNN modeli %98,9 doğruluk, %98,9 duyarlılık, %99,2 özgüllük ve %99 F1 skoru ile nöbetleri ve nöbetsiz örnekleri doğru bir şekilde sınıflandırmıştır. 2D formatına dönüştürüldüğünde, CNN'in doğruluğu %98,5'ye bir düşüş yaşamış, ancak duyarlılığı %98,6, özgüllüğü %98,4 ve F1 skoru %98,4 olarak elde edilmiştir. Alzheimer hastalığının tespitinde, 1D EEG sinyalleri ile %72,5 doğruluk, %69,4 duyarlılık, %75,6 özgüllük ve %71,8 F1 skoru, 2D spektrogramlar ile ise %82,6 doğruluk, %76,9 duyarlılık, %87,1 özgüllük ve %79,5 F1 skoru elde edilmiştir. Parkinson hastalığının tespitinde, 1D EEG sinyalleri %74,3 doğruluk, %69,2 duyarlılık, %78,7 özgüllük ve %71,4 F1 skoru elde ederken, 2D spektrogramlar ile ise %81,2 doğruluk, %83,6 duyarlılık, %79,2 özgüllük ve %79,9 F1 skoru elde edilmiştir. Sonuç olarak, epilepsi tespitinde 1D sinyallerin daha başarılı olduğu görülürken, 2D spektrogramlar Alzheimer ve Parkinson hastalıklarının tespitinde daha yüksek doğruluk, duyarlılık, özgüllük ve F1 skorları sunmaktadır. Bu bulgular, nörolojik hastalıkların teşhisinde 2D spektrogramların kullanımının etkin olduğunu göstermektedir.

ANAHTAR KELİMELE: Biyomedikal sinyal işleme, EEG sinyalleri, Evrişimli sinir ağları, Derin öğrenme, Sınıflandırma

ABSTRACT

NEUROLOGICAL DISEASE DETECTION FROM EEG SIGNALS WITH 1D AND 2D CNN DEEP LEARNING ALGORITHMS

MSC THESIS

BAHADIR ARABACI

BOLU ABANT IZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF ELECTRICAL ELECTRONICS ENGINEERING

(SUPERVISOR: PROF. DR. KEMAL POLAT)

(CO-SUPERVISOR: DR. ÖĞR. ÜYESİ HAKAN ÖCAL)

BOLU, JULY 2024

XII + 77

In this thesis, the detection of Epilepsy, Alzheimer's, and Parkinson's diseases from 1D and 2D spectrogram-converted signals using deep learning was performed. Due to the complexity of EEG signals, an innovative approach is required for accurate neurological disease detection. Traditional methods often treat EEG data as a one-dimensional time series, overlooking significant frequency information in the signals. Our study proposes a methodology that converts 1D EEG signals into 2D spectrograms using the short-time Fourier transform (STFT) to address the limitations of one-dimensional data. This transformation captures frequency patterns, enhancing the analysis and providing a more comprehensive understanding of neural activity. In epilepsy seizure detection, the 1D CNN model accurately classified seizures and non-seizure instances with 98,9% accuracy, 98,9% sensitivity, 99,2% specificity, and an F1 score of 99,0%. When transformed into the 2D format, the CNN's accuracy slightly decreased to 98,5%, but sensitivity was 98,6%, specificity 98,4%, and the F1 score was 98,4%. For Alzheimer's disease detection, 1D EEG signals achieved 72,5% accuracy, 69,4% sensitivity, 75,6% specificity, and an F1 score of 71,8%, whereas 2D spectrograms achieved 82,6% accuracy, 76,9% sensitivity, 87,1% specificity, and an F1 score of 79,5%. In Parkinson's disease detection, 1D EEG signals achieved 74,3% accuracy, 69,2% sensitivity, 78,7% specificity, and an F1 score of 71,4%, while 2D spectrograms achieved 81,2% accuracy, 83,6% sensitivity, 79,2% specificity, and an F1 score of 79,9%. In conclusion, while 1D signals have shown greater success in epilepsy detection, 2D spectrograms provide higher accuracy, sensitivity, specificity, and F1 scores in detecting Alzheimer's and Parkinson's diseases. These findings demonstrate the increased effectiveness of using 2D spectrograms in the diagnosis of neurological diseases.

KEYWORDS: Biomedical signal processing, EEG signals, Convolutional neural networks, Deep learning, Classification

İÇİNDEKİLER

Sayfa

KABUL VE ONAY SAYFASI	iii
ETİK BEYAN.....	iv
ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ.....	ix
TABLO LİSTESİ	x
KISALTMA VE SEMBOLLER LİSTESİ	xi
TEŞEKKÜR	xii
1. GİRİŞ.....	1
2. GENEL BİLGİLER	3
2.1 Çalışmanın Amacı	3
2.2 Literatür Taraması	3
2.3 Nörolojik Hastalıklar	11
2.3.1 Beyin.....	11
2.3.2 Nöron.....	12
2.3.3 Nörolojik Hastalıkların Sıklığı ve Dağılımı	12
2.3.4 Demans	12
2.3.5 Alzheimer Hastalığı.....	13
2.3.6 Epilepsi	15
2.3.7 Parkinson Hastalığı.....	16
2.4 EEG.....	17
2.5 Yapay Zeka ve Derin Öğrenme	19
2.5.1 Yapay Sinir Ağları.....	21
2.5.2 Sinir Ağlarının Basit Mimarisi	23
2.5.3 Tek Katmanlı Sinir Ağları	23
2.5.4 Çok Katmanlı Sinir Ağları.....	24
2.5.5 Aktivasyon Katmanları.....	24
2.5.6 Evrişimli Sinir Ağları	25
2.5.7 Konvolüsyon İşlemi.....	28
2.5.8 Doğrultulmuş Doğrusal Birim Katmanı	30
2.5.9 Maksimum Havuzlama Katmanı	31
2.5.10 Küme Normalizasyonu.....	32
2.5.11 Tam Bağlı Katmanlar	32
2.5.12 SoftMax aktivasyon fonksiyonu	33
2.5.13 Seyreltme.....	33
2.5.14 Sinyal-Görüntü Dönüşüm Teknikleri.....	34
2.5.15 Kısa Zamanlı Fourier Dönüşümü.....	36
2.5.16 STFT kullanılarak 1D sinyallerin 2D spektrogram dönüşümü ...	37

3. MATERYAL VE YÖNTEM	39
3.1 Veri kümeleri	39
3.1.1 Alzheimer hastalığı veri kümesi	39
3.1.2 Epilepsi hastalığı veri kümesi.....	41
3.1.3 Parkinson hastalığı veri kümesi	44
3.2 Önerilen Derin Öğrenme Modelleri.....	46
3.2.1 Epilepsi Tespiti İçin 1D CNN Modelinin Eğitimi	46
3.2.2 Epilepsi Tespiti İçin 2D CNN Modelinin Eğitimi	47
3.2.3 Alzheimer Hastalığı ve Parkinson Hastalığı İçin Veri Ön İşleme....	48
3.2.4 Alzheimer Hastalığı Tespiti İçin 1D CNN Modelinin Eğitimi	51
3.2.5 Alzheimer Hastalığı İçin 2D CNN Modelinin Eğitimi.....	53
3.2.6 Parkinson Hastalığı için 1D CNN modelinin eğitimi.....	54
3.2.7 Parkinson Hastalığı için 2D CNN modelinin eğitimi.....	55
3.3 Performans Parametreleri	57
3.3.1 Doğruluk.....	57
3.3.2 Duyarlılık.....	58
3.3.3 Özgüllük	58
3.3.4 Hassasiyet	58
3.3.5 F1 Skoru	58
4. BULGULAR	59
5. TARTIŞMA	63
6. SONUÇ VE ÖNERİLER	68
7. KAYNAKLAR.....	70

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Tek katmanlı nöronların ileri besleme ağı şeması	23
Şekil 2.2. ReLU, Sigmoid ve Tanh aktivasyon fonksiyonları	25
Şekil 2.3. Evrişimli sinir ağlarının genel mimarisi	27
Şekil 2.4. Sinir ağlarındaki bağlantılar	28
Şekil 2.5. Örnek konvolüsyon işlemi	29
Şekil 2.6. ReLU fonksiyon grafiği	31
Şekil 2.7. Maksimum Havuzlama İşlemi	32
Şekil 2.8. (a): Standart sinir ağı, (b): Seyreltme uygulanmış sinir ağı	34
Şekil 2.9. Bir sinyalin ve spektrogramla dönüştürülmüş halinin örneği	38
Şekil 3.1. Alzheimer veri kümesi EEG sinyali örneği	41
Şekil 3.2. Epileptik ve normal EEG sinyalleri	43
Şekil 3.3. Maksimum ve minimum değerlerin gösterimi	43
Şekil 3.4. Epileptik ve normal durumların EEG sinyalindeki değerleri	44
Şekil 3.5. Parkinson Hastalığı EEG sinyal örneği	45
Şekil 3.6. Alzheimer hastalığı veri kümesi EEG sinyali ve STFT uygulanmış spektrogram görüntüsü	53
Şekil 3.7. Parkinson hastalığı veri kümesi EEG sinyali ve STFT uygulanmış sinyal görüntüsü	57
Şekil 4.1. Oluşturulan modellerin karmaşıklık matris değerleri	60
Şekil 4.2. Epilepsi tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri ..	61
Şekil 4.3. Epilepsi tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri ..	61
Şekil 4.4. AH tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri	61
Şekil 4.5. AH tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri	62
Şekil 4.6. PH tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri	62
Şekil 4.7. PH tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri	62

TABLO LİSTESİ

Sayfa

Tablo 2.1. EEG Frekans Bantları (Tatum, 2014)	19
Tablo 2.2. Yaygın olarak kullanılan sinyalden görüntü dönüşümü yöntemleri (Ch Vidyasagar ve ark., 2024)	34
Tablo 3.1. Alzheimer veri kümesinin demografik karakteristiği, ortalama ve standart sapma değerleri.....	39
Tablo 3.2. Epilepsi Tespiti İçin Önerilen 1D CNN Modeli	47
Tablo 3.3. Epilepsi Tespiti İçin Önerilen 2D CNN Modeli	48
Tablo 3.4. Alzheimer Hastalığı Tespiti İçin Önerilen 1D CNN modeli.....	52
Tablo 3.5. Alzheimer Hastalığı Tespiti İçin Önerilen 2D CNN modeli.....	54
Tablo 3.6. Parkinson Hastalığı için 1D CNN modeli.....	55
Tablo 3.7. Parkinson Hastalığı için 2D CNN modeli.....	56
Tablo 5.1. Literatürde yapılan diğer çalışmalar.....	65
Tablo 5.2. Tez çalışması bulgularımız	66

KISALTMA VE SEMBOLLER LİSTESİ

1D	: 1 Boyutlu
2D	: 2 Boyutlu
AH	: Alzheimer Hastalığı
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimli Sinir Ağları
DÖ	: Derin Öğrenme
EEG	: Elektroensefalografi
FN	: Yanlış Negatifler
FP	: Yanlış Pozitifler
FTD	: Frontotemporal Demans
HBB	: Hafif Bilişsel Bozukluk
MMSE	: Mini Mental Durum Muayenesi
MÖ	: Makine Öğrenimi
MRI	: Manyetik Rezonans Görüntüleme
PET	: Pozitron Emisyon Tomografisi
PH	: Parkinson Hastalığı
ReLU	: Doğrultulmuş Doğrusal Birim
SB	: Sağlıklı Birey
STFT	: Kısa Zamanlı Fourier Dönüşümü
TN	: Doğru Negatifler
TP	: Doğru Pozitifler

TEŞEKKÜR

Yüksek lisans eğitimim boyunca desteğini esirgemeyen, bilgi ve tecrübelerini paylaşan danışman hocam Sayın Prof. Dr. Kemal POLAT’a,

Tez çalışmam süresince desteğini esirgemeyen ve tezin yürütülmesinde değerli katkılarından dolayı Sayın Dr. Öğr. Üyesi Hakan ÖCAL’a,

Lisans ve yüksek lisans eğitimim süresince üzerimde emeği olan, kendilerinden ders aldığım ve eğitimime katkıları bulunan tüm hocalarıma,

Eğitimim süresince gösterdikleri anlayış ve destekleri için çok kıymetli aileme sonsuz sevgi, saygı ve teşekkürlerimi sunarım.

Bahadır ARABACI

1. GİRİŞ

Sağlık sektöründeki en son gelişmeler, akıllı sağlık sensörleri ve iletişim teknolojisinin etkisiyle yeni hizmetler, erişilebilirlik, doğruluk ve hızlı yanıt gibi alanlarda önemli değişimlere yol açarak büyük miktarda klinik veri toplanmasına katkı sağlamıştır.

Elektroensefalografi (EEG), beynin elektrik sinyallerini analiz etmek için kullanılan bir tekniktir ve beyin aktivite bozukluklarına dair yararlı bilgiler sunar (Abdelhameed & Bayoumi, 2021). Yüksek zamansal çözünürlüğü ve düşük maliyeti nedeniyle biyomedikal mühendislik araştırmalarında, beyin-bilgisayar arayüzleri, nöbet tespiti ve uyku analizi gibi alanlarda yaygın olarak kullanılmaktadır (Luján ve ark., 2021).

EEG sinyal analizi, insan sağlığı ve çeşitli hastalıkların teşhisinde önemli bir rol oynar. EEG kullanılarak yapılan hastalık teşhisi, uygun tıbbi veya cerrahi tedavi seçeneklerinin belirlenmesine yardımcı olur. EEG' nin vücut bütünlüğünü bozmaması, düşük maliyeti ve yüksek zaman çözünürlüğü nedeniyle geniş çapta kullanılmaktadır (Roy ve ark., 2019).

EEG, bir deneğin kafa derisine yerleştirilen elektrotlar aracılığıyla lokal nöral aktiviteden kaynaklanan voltajları tespit etmek için kullanılan bir nöro görüntüleme tekniğidir. İnvaziv olmayan teknoloji, epilepsi, uyku bozuklukları ve duysal iletim gibi hastalıkların teşhisinde uzun süredir başarıyla kullanılmaktadır (Michel & Brunet, 2019). Bu tür hastalıklarda, EEG değişiklikleri oldukça belirgindir. Uzman nörofizyologların altta yatan hastalık durumları hakkında yüksek güvenle öznel ve nispeten nitel yorumlar yapmalarını sağlar (Grant ve ark., 2014). Diğer nörolojik durumlar daha ince değişikliklerle ortaya çıkabilir ve EEG sinyallerinin karmaşıklığı, insan gözlemciler veya mevcut araçlar tarafından güvenilir bir şekilde değerlendirilmesini engelleyebilir (Smith, 2005).

Derin öğrenme (DÖ) yaklaşımları çeşitli veri türlerinden bilgi çıkarmak için geliştirilmiştir ve yaygın olarak kullanılmaktadır. EEG dalgalarıyla insan beyninin bozukluklarını ve duygusal-zihinsel durumlarını tespit etmek için farklı DÖ mimarileri kullanılmaktadır (Lecun ve ark., 2015).

Son yıllarda, yapay zeka hızla gelişerek sağlık alanında dönüşüme neden olmuştur. Yapay zeka, nöroşirürji alanında da önemli ilerlemeler sağlamıştır ve makine öğrenimi (MÖ) gibi alt alanlar, verileri kullanarak öğrenen ve kendini

geliştiren algoritmalar oluşturmayı hedeflemektedir. DÖ ise yapay sinir ağlarını kullanarak ham verilerden önemli bilgileri otomatik olarak çıkaran bir yöntemdir (Chollet, 2018). Fizyolojik veri işleme alanında, zaman alanı sinyallerini görüntü temsillerine dönüştüren çeşitli dönüştürücü teknikler, özellik mühendisliğini mümkün kılan güçlü araçlar olarak öne çıkmaktadır (Bird ve ark., 2021). Zaman ve frekans alanı analizleri gibi 1D özellik çıkarma yöntemleri, sinyal özelliklerini anlamak için gereklidir. Zaman alanı teknikleri, istatistiksel özellikleri yakalamada etkili olsa da karmaşık sinyal detaylarını temsil etmede genellikle yetersiz kalır. Bu nedenle, daha kapsamlı bir temsil sağlamak için 2D özellik çıkarma yöntemleri kritik hale gelmektedir (Wacker & Witte, 2013).

Nöroşirürji gibi cerrahi alanlar önemli riskler taşır. Yapay zeka, MÖ ve DÖ'nin birleştirilmesi, klinik tedavi tanı ve sonuçlarını iyileştirmenin yanı sıra nöroşirürjilere cerrahi müdahaleler sırasında karar vermelerinde yardımcı olabilir ve nihayetinde hasta sonuçlarını iyileştirebilir (Lecun ve ark., 2015). Ancak, bu teknolojilerin kullanımı arttıkça veri kalitesi, algoritma önyargısı, düzenleyici sorunlar ve etik konular gibi yeni zorluklar ortaya çıkar. Bu nedenle yapay zeka, MÖ ve DÖ gibi teknolojilerin nöroşirürjideki potansiyel faydalarını ve sınırlarını daha iyi anlamak için, sonuçları ve zorlukları inceleyen, ilerleme ve sınırlamaları belirleyen, etik ve düzenleyici konuları tartışan kapsamlı çalışmalara ihtiyaç vardır (Awuah ve ark., 2024).

2. GENEL BİLGİLER

2.1 Çalışmanın Amacı

Bu çalışmanın amacı, EEG sinyalleri ve bu sinyallerin iki boyutlu spektruma dönüştürülmüş veri setlerinin DÖ algoritmaları modellerinde değerlendirilmesi yoluyla Epilepsi, Alzheimer hastalığı (AH) ve Parkinson hastalığı (PH) tespitini incelemektir. Bu bağlamda, 1D EEG sinyallerini 2D spektrogramlara dönüştüren ve tek boyutlu sınırlamaları ele almak için Kısa Zamanlı Fourier Dönüşümü (STFT) kullanarak bir metodoloji önerilmektedir. Bu dönüşüm, frekans desenlerini yakalayarak analizi geliştirir ve nöral aktivitenin daha kapsamlı bir anlayışını sağlar.

2.2 Literatür Taraması

EEG, nörolojik hastalıkları tespit etmek için kullanılır. Tekrarlayan epileptik nöbetler, beynin işlevini bozarak hafıza kaybı ve zihinsel gerileme gibi ciddi sorunlara yol açabilir. Epileptik nöbetleri erken teşhis etmek ve tedavi etmek, hastanın yaşam kalitesini korumak için önemlidir (Xu ve ark., 2020).

Epilepsi, kronik bir nörolojik hastalıktır. Hastalığa sahip bireyler günlük yaşamlarında ani nöbetlere, bilinç kaybına veya olumsuz durumlara yol açan kesintilere maruz kalabilirler. EEG üzerinde epileptik ve epileptik olmayan aktivitelerin ayrıştırılması ve epileptik aktivitenin tanımlanması hastaların uygun tedavisini sağlamak için hayati bir rol oynar (Shanmugam & Dharmar, 2023). Nörologlar EEG raporlarını görsel inceleme yoluyla teşhis etmektedir. Dünya genelinde EEG verilerinin manuel olarak incelenmesi, bu verileri doğru şekilde yorumlayacak uzman eksikliğinin olması, geleneksel yöntemlerin zaman alıcı olması ve çaba gerektirmesi nedeniyle yapılan çalışmalarda araştırmacılar hastalığı tespit etmek için otomatik sistemler önermektedir (Sameer & Gupta, 2022). EEG verilerinin manuel olarak incelenmesi nörologlar için zaman ve çaba gerektiren bir işlemdir. Bu nedenle, epilepsiyi daha hızlı ve kolay bir şekilde tespit edebilen sistemler geliştirilmiştir. Bu amaçla Ullah ve arkadaşları (2018) tarafından yapılan bir çalışmada, standart CNN modellerine göre daha az parametreye sahip 1D CNN modelleri kullanılarak bir sistem önerilmiştir. Bu sayede, modelin daha iyi genelleme özelliğine sahip olması sağlanmıştır ve epilepsiyi tespit etme konusunda %99,1 doğruluğa sahiptir (Ullah ve ark., 2018).

Tjepkema-Cloostermans ve arkadaşları (2018) tarafından gerçekleştirilen bir çalışmada derin sinir ağları, EEG verilerinden Epileptiform deşarjların olasılığını hesaplamak için kullanılmıştır. Epileptiform deşarjları tespit etmek için DÖ tabanlı bir model geliştirilmiştir. Test sonuçları, modelin %47,4 hassasiyet ve %98,0 özgüllükle Epileptiform deşarjları tespit edebildiğini göstermiştir (Tjepkema-Cloostermans ve ark., 2018).

Rashed-Al-Mahfuz ve arkadaşları (2021) EEG epilepsi sınıflandırmasını doğru bir şekilde yapmak için zaman-frekans temsilini kullanan bir önerilen yöntem sunmaktadır. Bu yöntem ile, beş farklı EEG veri kümesi üzerinde yapılan testlerde başarılı bir şekilde ikili sınıflandırmada ortalama %99,21 doğruluk, %99,04 hassasiyet ve %99,38 özgüllükle sınıflandırma sonuçları elde edilmiştir. Yazarlar, geliştirilmiş sınıflandırma doğruluğunu anlamak için EEG'deki özellik frekanslarını ortaya çıkaran Shapley Eklemeli Açıklamalar analizi yaklaşımını kullanmışlardır (Rashed-Al-Mahfuz ve ark., 2021).

Geleneksel EEG tanı modelleri genellikle sınırlı bir genelleme yeteneğine sahip olup büyük ölçüde yapay deneyime dayanmaktadır. Zhao ve arkadaşları (2020) tarafından önerilen model nöbet tespiti için üç konvolüsyon bloğu ve üç tam bağlantılı katmandan oluşmaktadır. İki sınıf EEG sınıflandırma problemi için %97,63 ila %99,52 arasında, üç sınıf EEG sınıflandırma problemi için %96,73 ila %98,06 arasında ve karmaşık beş sınıf sınıflandırma problemi için %93,55 doğruluk oranlarına ulaşmışlardır (Zhao ve ark., 2020).

Xu ve arkadaşları (2020) araştırmalarında epileptik nöbetleri otomatik olarak tanımak için EEG sinyal analizi yoluyla CNN modeli önermektedir. Önerilen yöntem ikili ve beş sınıf epileptik nöbet tanı görevlerinde sırasıyla %99,39 ve %82,00 yüksek tanı doğruluklarına ulaştığını göstermektedir (Xu ve ark., 2020).

Shanmugam ve Dharmar'ın (2023) çalışmasında, etiketli EEG verilerinin sınırlılığı ve EEG örneklerinin etiketlenmesinin karmaşıklığı nedeniyle, önerilen modelin veri artırma teknikleri kullanarak AH, zihinsel bozukluklar ve PH gibi diğer beyin hastalıklarını teşhis etme ve tahmin etme amacıyla kullanılabileceği vurgulanmaktadır. Çalışmada EEG verileri üzerinde önemli bir ön işleme veya özellik çıkarma gerektirmeyen DÖ'ye dayalı otomatik nöbet tespiti yöntemi sunulmaktadır. Sağlıklı, nöbet ve nöbet öncesi EEG verilerini ayırt etmek için bir boyutlu konvolüsyonel sinir ağı-uzun kısa vadeli bellek modeli kullanılmaktadır. Model, BoU ve Nöroloji ve Uyku Merkezi verileri üzerinde değerlendirilmiştir ve

en iyi model ile BoU veri kümesi için %99-100 ve NSC veri kümesi için %100 doğruluk elde edilmiştir (Shanmugam & Dharmar, 2023).

Son yıllarda, birçok sistem el yapımı özellikler kullanarak tasarlanmıştır. Ancak, en iyi özelliklerin seçimi zor bir görevdir. DÖ ağları bu sorunu çözebilir ancak uzun süreli eğitim gerektirebilir. Bu sorunu aşmak için Sameer ve Gupta (2022) sınıflandırıcının ardından otomatik olarak özellik çıkaran yeni bir 1D-CNN önermektedir. Model, EEG sinyalinin ön işleme gereksinimi olmadığı gibi eğitim süresini yaklaşık %94 oranında azaltmaktadır. Farklı MÖ teknikleri, özelliklerin sağlamlığını değerlendirmek için kullanılmış olup sağlıklı ve nöbet geçiren hastalar arasındaki farkı tespit etmek için %99,83'e kadar maksimum doğruluk elde edilmiştir (Sameer & Gupta, 2022).

Abdallah ve arkadaşları (2023) epilepsi tespiti için dikkat mekanizması içeren DÖ tabanlı model önermişlerdir. Önerilen model, ham EEG sinyal verilerini doğrudan bir tek boyutlu konvolüsyonel sinir ağı içine besleyerek ilgili özellikleri EEG sinyallerinden çıkarmaktadır. Bu özellikler daha sonra hafıza yeteneklerinden yararlanmak ve daha iyi keşfedilmesini sağlamak amacıyla uzun kısa süreli bellek modülünden geçirilir. Model, UCI veri kümesinde ikili ve beş sınıflı epileptik nöbet tanıma görevleri için sırasıyla %97,8 ve %92,7 F1 skoru ve CHB-MIT veri kümesinde %97,9'luk bir skor elde etmiştir (Abdallah ve ark., 2023).

Cimr ve arkadaşları (2023) tarafından optimize edilmiş model ve karmaşıklığı azaltılmış bir özellik çıkarma sürecine ihtiyaç duymayan bir sistem geliştirilmiştir. Bonn EEG veri kümesinde %98 doğruluk, %98 özgüllük ve %98,5 hassasiyet; CHB-MIT EEG veri kümesinde ise %96,99 doğruluk, %96,89 özgüllük ve %97,06 hassasiyet elde edilmiştir (Cimr ve ark., 2023).

Epileptik EEG sinyallerini incelemek amacıyla San-Segundo ve arkadaşları (2019) tarafından önerilen DÖ mimarisi, 2 evrişimli ve 3 tam bağlantılı katmandan oluşmaktadır. Fourier, dalgacık ve ampirik mod ayrışımı yöntemlerini kullanmaktadır. Bern-Barcelona EEG ve Epileptik Nöbet Tanıma veri kümeleri üzerinde elde edilen sonuçlar Bern-Barcelona EEG için ampirik mod ayrışımı kullanılarak sınıflandırma doğruluğunu %92,3'ten %98,9'a yükseltmiştir. Ayrıca, nöbet ve nöbet olmayan kayıtlar arasındaki doğruluk %99,0'dan %99,5'e yükselmiştir. Sağlıklı, odaklı olmayan ve nöbet kayıtlarını ayırt etme doğruluğu %91,7'den %96,5'e yükselmiştir. Sağlıklı, odaklı ve nöbet kayıtları için ise doğruluk %89,0'dan %95,7'ye çıkmıştır (San-Segundo ve ark., 2019).

Narin (2022) tarafından gerçekleştirilen araştırmada sürekli dalga dönüşümü ve iki boyutlu evrişimli sinir ağları temel alınarak odaklı ve odaklı olmayan epileptik nöbetlerin tahmin edilmesi için yeni bir yöntem önerilmiştir. Modeller 2D skalogram görüntülerini otomatik olarak odaklı ve odaklı olmayan epileptik nöbetlere sınıflandırmak için kullanılmıştır. En yüksek sınıflandırma doğruluğu, diğer dört önceden eğitilmiş model arasından seçilen InceptionV3 modeli tarafından %92,27 olarak elde edilmiştir (Narin, 2022).

Jibon ve arkadaşları (2023) doğrusal grafik konvolüsyon sinir ağı ve DenseNet kullanılarak yeni bir hibrit çerçeve önermiştir. DenseNet, gradient kaybolma sorununu azaltarak ve özellik iletimini artırarak daha yüksek hesaplama doğruluğu ve bellek verimliliği sunar. Ham EEG sinyali Stockwell dönüşümü ile önceden işlenerek, matris zaman-frekans bloklarına gruplanır. DenseNet, doğrusal grafik konvolüsyon sinir ağı için girdi olarak kullanılmak üzere özellik seçimi ve sınıflandırma için kullanılır. Önerilen hibrit çerçeve, CHB-MIT EEG veri kümesi üzerinde gerçekleştirilen geniş deneylerde %98 doğruluk ve %98,60 özgüllük elde etmiştir (Jibon ve ark., 2023).

Literatürdeki çalışmaların çoğu tek kanallı EEG verilerinin özelliklerine odaklanmış ve farklı kanallardan gelen sinyaller arasındaki ilişkiyi göz ardı etmiştir. Bu boşluğu doldurmak için Lian ve arkadaşları (2020) bir EEG örneği eşleme temelli epilepsi sınıflandırma yaklaşımını tanıtmak üzere bir konvolüsyonel sinir ağı kullanılmasını önermiştir. İlk olarak, her EEG sinyali çifti birbirleriyle etkileşimi ortaya çıkarabilecek bir 2 boyutlu matris oluşturmak için kullanılmıştır. Daha sonra, oluşturulan matrisler giriş temsilini ayırt edecek olan önerilen CNN'ye beslenmiştir. Önerilen algoritmanın %99,3 doğruluk, %99,5 duyarlılık ve %99,6 özgüllük oranlarına ulaşabileceği gösterilmiştir (Lian ve ark., 2020).

Wang ve arkadaşları (2021) epileptik nöbetlerin doğru bir şekilde tahmin edilmesi için birçok ölçekli genişletilmiş CNN modeli incelemiştir. Model, EEG sinyallerini analiz etmek için üç boyutlu çekirdekler kullanarak zaman, frekans ve kanal bilgilerini çıkarmakta ve genişletilmiş konvolüsyon ile daha soyut bilgiler elde etmektedir. Bu çalışma CHB-MIT EEG veritabanında yapılan değerlendirmeler sonucunda önerilen modelin %80,5 doğruluk, %85,8 duyarlılık ve %75,1 özgüllük elde ettiğini göstermiştir (Wang ve ark., 2021).

Skalp EEG sinyallerinde interiktal epileptiform deşarjların görsel incelemesi yoluyla epilepsi teşhisi zorlu bir problemdir. Prasanth ve arkadaşları

(2020) deşarjları EEG'lerden otomatik olarak tespit etmek için CNN tabanlı yeni bir yaklaşım sunmuştur. Deşarj algılayıcıları değerlendirmek için beş katlı çapraz doğrulama yapılmıştır. Bu çalışmada çoklu alt bantlara sahip 1D CNN, %23 yanlış pozitif oranı ve %90 hassasiyet ile %79 kesinlik elde etmiştir (Prasanth ve ark., 2020).

Epilepsi hastalarının EEG'sinde sıklıkla gözlenen ve nöbetler arasında ortaya çıkan keskin dalga formlarını tespit etmek önemlidir. Bu amaçla, Ein Shoka (2023) ve arkadaşları çalışmalarında EEG sinyallerinden nöbet tespiti için şifrelenmiş spektrogram ve CNN tabanlı yöntem kullanmıştır. Her 10 saniyelik EEG veri segmenti için spektrogram görüntüleri üretilmiştir. Üretilen spektrogram görüntülerini şifrelemek için Arnold ve Kaotik şifreleme yöntemleri kullanılmıştır. Önerilen yapının doğruluğu Arnold ve kaotik yöntemlerle sırasıyla %86,11 ve %84,72 olarak tahmin edilmiştir (Ein Shoka ve ark., 2023).

Abdelhameed ve Bayoumi (2021) araştırmalarında birbirine bağlı şekilde eğitilen iki boyutlu konvolüsyon otomatik kodlayıcı ve sinir ağı tabanlı sınıflandırıcı kullanarak en iyi sınıflandırma doğruluğunu elde etmek üzere denetimli bir şekilde eğitilen bir birleşik sistem oluşturmuştur. Boston Çocuk Hastanesi ve Massachusetts Teknoloji Enstitüsü'nden toplanan kamu veri kümesini kullanarak, model sırasıyla %98,79 doğruluk, %98,72 duyarlılık, %98,86 özgüllük, %98,86 hassasiyet ve %98,79 F1 puanı elde etmiştir (Abdelhameed & Bayoumi, 2021).

Bahr ve arkadaşlarının (2021) çalışmasında kapalı devre implant edilebilir cihazlar aracılığıyla refrakter epilepsi tedavisi için geliştirilen bir CNN, düşük güç tüketimi ve yüksek duyarlılık göstererek önemli sonuçlar elde etmiştir. MATLAB ve GAP8 mikroişlemcide uygulanan CNN, CHB-MIT veri kümesi üzerinde eğitilmiş ve optimize edilmiştir. CNN, %90 duyarlılık, %99'un üzerinde özgüllük oranıyla öne çıkmaktadır. Mikrodenetleyici üzerinde uygulandığında ise %85 duyarlılık elde edilmiştir (Bahr ve ark., 2021).

EEG'nin heterojenliği ve yaş ile uyku aşaması gibi bağlamsal faktörlere bağımlılığı nedeniyle EEG'yi normal ve anormal olarak etiketlemek için bir algoritma eğitmek zordur. DÖ yöntemlerinin normal ve anormal EEG'leri ayırt edebileceğini öne süren önceki çalışmaları doğrulamak, yaş ve uyku aşaması bilgisinin ayırt etmeyi iyileştirip iyileştirmedikini ve hatalara yol açan faktörleri anlamak önemlidir. Van Leeuwen ve arkadaşları (2019) çalışmalarında

Massachusetts General Hospital'den alınan EEG verilerini kullanılarak heterojen bir veri kümesinde derin evrişimli sinir ağı eğitmiştir. Bağımsız bir test setinde yaş ve uyku aşamaları dahil edildiğinde marjinal bir iyileşme gözlemlenmiştir. Ancak, modelde yaş ve uyku aşaması eklenmesi, performansı anlamlı bir şekilde iyileştirmemiştir (van Leeuwen ve ark., 2019).

Abiyev ve arkadaşları (2020), çapraz doğrulama tekniği kullanarak CNN'nin eğitimi gerçekleştirmiştir. Sınıflandırma sistemi tasarımı, Bonn Üniversitesi veri setleri kullanılarak gerçekleştirilmiştir. Simülasyonun sonucunda, test için elde edilen doğruluk oranının ortalama değeri %98,67, duyarlılık %97,67 ve özgüllük %98,83 olarak belirlenmiştir (Abiyev ve ark., 2020).

Muhammad Usman ve arkadaşları (2020), nöbetlerin başlamasını tahmin etmek için DÖ yöntemlerini kullanan bir model önermektedir. Önerilen model, CHB-MIT'nin saç EEG veri kümesi kullanılarak 24 denek üzerinde uygulanmış, ortalama hassasiyet ve özgünlük oranlarını sırasıyla %92,7 ve %90,8 olduğu gösterilmiştir (Muhammad Usman ve ark., 2020).

Zhou ve arkadaşlarının (2018) çalışmasında, İntrakraniyal Freiburg ve scalp CHB-MIT veritabanlarına dayalı epileptik sinyallerin tespitinde zaman ve frekans domain sinyallerinin performansları karşılaştırılmıştır. Freiburg veritabanındaki frekans domain sinyalleri kullanılarak sırasıyla %96,7, %95,4 ve %92,3'lük ortalama doğruluk olarak elde edilmiştir. CHB-MIT veritabanındaki ortalama doğruluklar sırasıyla %95,6, %97,5 ve %93 elde edilmiştir. Freiburg veritabanındaki zaman domain sinyalleri kullanıldığında, ortalama doğruluklar sırasıyla %91,1, %83,8 ve %85,1, CHB-MIT veritabanındaki sinyal tespiti doğrulukları %59,5, %62,3 ve %47,9 olarak elde edilmiştir (Zhou ve ark., 2018).

Wei ve arkadaşları (2018) alanında ilk olan bir çalışma gerçekleştirmişlerdir. Bu çalışma, epilepsi nöbet tespiti için EEG verilerinde 3 boyutlu CNN kullanımını içermektedir ve 13 hastanın EEG verileri kullanılarak yapılmıştır. EEG verilerini CNN'de temsil etmek için öncelikle EEG verisinin her kanalının zaman serisi iki boyutlu bir görüntüye dönüştürülmüştür. Ardından, farklı elektrotlar arasındaki karşılıklı korelasyon yoğunluğuna göre tüm kanal görüntüleri birleştirilmiştir. Son olarak, farklı EEG verisi epilepsi aşamalarını tahmin etmek için bir CNN modeli oluşturulmuştur. Çoklu kanala dayalı 3D CNN, %90'dan fazla doğruluk, %88,90 duyarlılık ve %93,78 özgüllük ile 2D CNN ve geleneksel sinyal işleme yöntemlerini geride bırakmıştır (Wei ve ark., 2018).

Epilepsi nöbet tahmini, hastalara zamanında uyarı sağlayarak etkili müdahale imkanı sunar. Zhang ve arkadaşları (2020) ortak uzamsal desen ve CNN kullanılarak nöbet tahmini için yeni bir çözüm önermektedir. Denge problemini çözmek için yapay preiktal EEG sinyalleri oluşturulmuştur. Zaman ve frekans alanındaki ayırt edici özellikleri çıkarmak için dalga paketi ayrışımı ve ortak uzamsal desen kullanılmıştır. Boston Children's Hospital-MIT saç EEG veri kümesindeki 23 hastanın verileri üzerinde çapraz doğrulama ile değerlendirilmiş ve %92,2 duyarlılık oranı elde edilmiştir (Zhang ve ark., 2020).

Raghu ve arkadaşları (2020), Temple Üniversitesi Hastanesi EEG veri kümesini kullanarak evrişimli sinir ağları ve transfer öğrenme ile yedi nöbet varyantını sınıflandırmayı amaçlamışlardır. 19 kanallı EEG zaman serisi, modele giriş olarak verilmeden önce spektrogram yığınınına dönüştürülmüştür. Transfer öğrenme ile %82,85, görüntü özellikleri çıkarma yöntemi ile %88,30 oranında en yüksek sınıflandırma doğruluğuna ulaşılmıştır (Raghu ve ark., 2020).

EEG sinyalleri kullanarak beyin anormalliklerini tespit etmek oldukça zor bir görevdir. Anormal EEG sinyallerinin doğru bir şekilde tespiti, hastalara erken tedavi sağlayarak yaşam kalitesini artırabilir. Yıldırım ve arkadaşları (2020), anormal EEG sinyallerinin otomatik tespiti için geliştirilen 1D CNN tabanlı sistem ile anormal EEG sinyallerini %79,34 doğruluk oranı, %79,64 hassasiyet ve %78,71 hassasiyet ile tespit edebilmektedir (Yıldırım ve ark., 2020).

Lee ve arkadaşlarının (2021) yaptığı araştırmada, PH ve sağlıklı birey (SB) gruplarından kaydedilen dinlenme halindeki EEG'yi sınıflandırmak için CNN ve kapı yinelemeli birimlerden oluşan model önerilmiştir. Bu model, dinlenme halindeki EEG'yi sınıflandırmada %99,2 doğruluk, %98,9 hassasiyet ve %99,4 geri çağırma oranı elde etmiştir (Lee ve ark., 2021).

Quan ve arkadaşları tarafından önerilen model, 2D CNN kullanarak zaman serisi dinamik özelliklerini çıkarmakta ve zaman serileri arasındaki bağımlılıkları 1D CNN ile yakalamaktadır. Model, %92'ye kadar doğruluk elde etmiştir. Ayrıca, model tarafından üretilen özelliklerin görselleştirilmesi, PH seslerinin genel frekans aralığının azaltılmış özelliklerini başarılı bir şekilde yakaladığını göstermektedir (Quan ve ark., 2022).

Asgarzadeh-Bonab ve arkadaşlarının (2023) çalışmasında, AH'nin neden olduğu demans seviyelerini belirlemek için altı farklı CNN ve üç farklı sınıflandırıcı performansı değerlendirilmiş ve EfficientNet-B7 ile ANN sınıflandırıcı ile en

yüksek doğruluk oranını sağladığı görülmüştür. Özellik düzeyinde füzyon kullanılarak, CN-HBB, CN-AH ve HBB-AH senaryoları için sırasıyla %82,7, %89,7 ve %84,3 doğruluk oranları elde edilmiştir (Asgharzadeh-Bonab ve ark., 2023).

Si ve arkadaşlarının (2023) çalışmaları sonucunda, AH'nin SB gruplarına kıyasla daha güçlü delta-alfa çapraz bağlantıları ve daha zayıf theta-sigma çapraz bağlantıları sergilediği gözlemlenmiştir. AH daha güçlü delta-alfa ve delta-beta bağlantılarına sahip olduğu belirlenmiştir. Elde edilen temsilci ağ özellikleri kullanılarak %81,1 doğrulukla sınıflandırma gerçekleştirilmiştir (Si ve ark., 2023).

Jha ve arkadaşlarının (2023) araştırması, 88 katılımcıdan elde edilen EEG verilerinin analizi, zaman ve spektral alanlardaki nörofizyolojik süreçlere dair bilgi sağlayan 18 farklı özellik setinin çıkarılmasını içermektedir. Bu özellikler, çeşitli nörolojik bozukluklarla ilişkilendirilen ince desenlerin tanımlanmasını mümkün kılmaktadır. Değerlendirilen özellikler karmaşık EEG sinyallerinin çözülmesi yoluyla %97,62 doğrulukla erken teşhise katkıda bulunmaktadır (Jha ve ark., 2023).

Yüksek evre AH ve frontotemporal demans (FTD), benzer semptomlar göstererek tanı koymayı ve tedavi stratejileri geliştirmeyi zorlaştırmaktadır. Lal ve arkadaşları (2024) bu iki hastalığı ve SB'leri ayırt etmek için %90 örtüşmeli kayan pencereleme, Tekil Değer Ayırıştırma Entropisi ve K-En Yakın Komşu Algoritması kullanılarak %93, %91, %92,5 ve %93, %91,5 ve %91 ortalama F1 puanı ve doğruluk oranları elde etmiştir. Açıklanabilir yapay zeka ile özellik önem sıralaması, Alzheimer ve FTD biyobelirteçlerinin tanımlanmasına katkıda bulunmuştur (Lal ve ark., 2024).

Miltiadous ve arkadaşlarının (2023) çalışması, AH EEG verilerinin sınıflandırılmasında Çift Girişli Evrişimli Kodlayıcı Ağı adlı bir yöntem sunmayı amaçlamaktadır. Çalışmanın sonuçları, AH ve SB ayrımında %83,28 doğruluk oranı elde ettiğini göstermektedir (Miltiadous, Gionanidis ve ark., 2023). Literatürde yapılan çalışmalar, EEG tabanlı nörolojik hastalıkların tanı ve sınıflandırılmasında derin öğrenme yöntemlerinin başarılı bir şekilde kullanılabilirliğini göstermektedir. Derin öğrenme algoritmaları, EEG sinyallerinden elde edilen karmaşık özellikleri tanımlamak ve hastalık belirteçlerini belirlemek için etkili bir araç olarak kabul edilmektedir.

2.3 Nörolojik Hastalıklar

Nöroloji, 19. yüzyılın sonlarından 20. yüzyılın başlarına kadar olan dönemde ortaya çıkmıştır. Cajal'ın ışık mikroskopunu kullanarak sinir ağlarının ayrıntılı tanımlanması ve diğer bilim insanlarının sinir anatomisinin detaylarına getirdiği katkılar, temel nörolojik pratiğin genellikle basit gözlemlere dayanmasını sağlayan sınırlı bir nöro-anatomi bilgisinin yeterli olduğunu göstermiştir. Ancak, günümüzde nörologlar, görüntüleme, nörogenetik, nörokimya, immunoloji ve moleküler biyolojideki ilerlemelerle birlikte, sinir sisteminin organizasyonunu ve anormalliklerin açıklanmasını anlamak için kullanmaktadır (Clarke ve ark., 2009).

Nörolojik hastalıklar, karmaşık verileri analiz etmek için güçlü bir teknik olan DÖ'nin gücünden yararlanan yenilikçi çözümleri gerektirir. DÖ yöntemleri, otomatik öğrenme yetenekleriyle karmaşık veri kümelerinde istatistiksel desenleri analiz edebildiği için tıbbi teşhislere kadar nörolojik hastalıkların aşamalarını tahmin etmeye kadar birçok uygulama sunar ve insan doğruluğunu aşan sonuçlar elde eder (Lima ve ark., 2022).

Nörolojik hastalıklar, bireylerin, ailelerinin, arkadaşlarının ve toplumun yaşamları üzerinde büyük bir etki bırakır. Tüm nörolojik sağlık hizmetlerinin ana hedefi hastalığın yol açtığı acıyı hafifletmektir. Bu amaca ulaşabilmek için sağlık hizmetlerinin akılcı bir şekilde planlanması için dört temel alanda bilgi gereklidir. İlk olarak, durumun epidemiyolojisi hakkında bilgi edinmek önemlidir. İkinci olarak hastalığın bireyler, aileler, sağlık hizmetleri ve toplumlar üzerindeki geniş etkilerini ve aynı zamanda mali maliyetini anlamak önemlidir. Üçüncü olarak, tanısal, araştırma ve tedavi müdahalelerinin etkinliği hakkında verilere ihtiyaç vardır. Son olarak, mevcut sağlık hizmeti kaynakları, dağılımları ve öncelikleri hakkında bilgi gereklidir (Clarke ve ark., 2009).

Nörodejenerasyon, nöronların yapı ve fonksiyonlarının zamanla bozulması ve sonuç olarak hücrelerin ölümüyle sonuçlanabilen bir süreci ifade eder. Bu durum aynı zamanda nörodejeneratif hastalık olarak da bilinir. Epilepsi, amiotrofik lateral skleroz, multipl skleroz, PH, AH, Huntington hastalığı, multipl sistem atrofisi ve prion hastalıkları gibi çeşitli rahatsızlıkları içerir (Dugger & Dickson, 2017).

2.3.1 Beyin

İnsan sinir sistemi, bilinç, biliş, etik ve davranışın organı olarak kabul edilir. İnsan genomundaki 23.000 genin üçte birinden fazlasının sinir sisteminde olduğu ifade edilir. Her olgun beyin, 100 milyar nöron, birkaç milyon kilometre

uzunluğunda akson ve dendritleri ve sinaptik bağlantıyı içeren en karmaşık organdır (Harrison, 2013). Dış bilgiyi yorumlamak, zeka, yaratıcılık, duygu ve belleği yönetmek gibi temel işlevlere sahiptir. Karmaşık faaliyetlerin bir sonucu olarak nöronlar elektrik sinyalleri üretir. Bu da küçük voltaj dalgalanmalarına ve iyon akımlarına neden olur. Oluşan elektrik sinyalleri genellikle zamana bağlı istikrarsız, rastgele ve doğrusal olmayan özelliklere sahiptir. Dolayısıyla, beyindeki elektriksel aktivitenin ölçülmesi ve izlenmesi, beyin fizyolojisinin, fonksiyonunun ve patolojik durumunun derinlemesine anlaşılması için kritik önem taşır. Beyin ritimlerinin belirlenmesini, beyin bozukluklarının doğru bir şekilde teşhis edilmesini, beyin hasarlarının tespit edilmesini ve bu sayede belirli beyin sağlığı koşullarının düzeltilmesi veya iyileştirilmesi olasılığını içerir (Luján ve ark., 2021).

2.3.2 Nöron

Nöron, sinir sisteminin temel birimidir. Nöronların benzersizlikleri, büyüklükleri ve hücre tipleri büyük ölçüde değişiklik gösterir. Örneğin, lomber omurilik kordonundaki bir alfa motor nöronunun aksonu 1 metreden daha uzun olabilir ve bir motor birimi oluşturarak birkaç yüz ila 2000 kas lifini içerebilir. Nöron hücre gövdesinden uzanan aksonlar 1 metreye kadar uzun ve dendritler bazen birkaç milimetreden daha uzun olarak bilinir. Aksonların çoğu, defalarca dallanarak, nöronların merkezi sinir sistemi içinde birbirinden farklı birçok nöron ile sinaptik bağlantılar kurmasına olanak tanır (Clarke ve ark., 2009).

2.3.3 Nörolojik Hastalıkların Sıklığı ve Dağılımı

Nörolojik hastalıkların sıklık ölçütleri arasında insidans ve prevalans ön plandadır. İnsidans, belirli bir zaman diliminde belirli bir popülasyonda ortaya çıkan yeni vakaların oranını ifade eder ve genellikle 100,000 kişi başına hesaplanır. Prevalans ise bir popülasyondaki mevcut vakaların oranını gösterir ve genellikle 1000 kişi başına hesaplanır. Hastalıkların sıklığı yaşa, kentsel ve kırsal ortamlara, etnik kökene, yaşam tarzı ve sosyoekonomik faktörlere bağlı olarak değişebilir. Kronik hastalıkların insidans oranları düşük olabilirken, prevalans oranları yüksek olabilir. Bu durum, sağlık hizmeti planlaması için önemlidir. Çünkü insidans vakaları inceleme ve akut tedavi gerektirirken, prevalans vakaları takip, sosyal bakım, uzun vadeli tedavi ve rehabilitasyon gerektirir (Clarke ve ark., 2009).

2.3.4 Demans

Demans, birçok farklı hastalığın neden olabileceği bir sendromdur (Yogarajah, 2013). AH, serebrovasküler hastalık ve HIV enfeksiyonu gibi çeşitli

altta yatan durumların bir sonucudur. Durumlar arasında beyin dejeneratif hastalıklar, B-12 eksikliği, hipotiroidizm gibi metabolik bozukluklar yer almaktadır. Demansın nedenleri arasında en yaygın olanları dejeneratif nedenlerdir. Hastalıktan en çok etkilenen beyin bölgesine bağlı olarak değişen baskın semptomlara sahiptir. Tipik olarak duygusal kontrol, sosyal davranış veya motivasyonda bozulma bu semptomlara eşlik eder. Demanslı bireylerin çoğu, düşük ve orta gelirli ülkelerde yaşamaktadır ve yaşam beklentisi arttıkça bu yükün daha da artmasına neden olmaktadır (Howlett, 2012). Demansın klinik belirtileri arasında hafıza kaybı en yaygın olanıdır. Ayrıca dil, görsel-uzamsal yetenek, hesaplama, değerlendirme ve problem çözme gibi diğer zihinsel yetenekler de etkilenebilir (Harrison, 2013). Bilişsel bozukluklar, toplumsal ve mesleki işlevselliği ciddi şekilde etkileyebilir. Demans genellikle ilerleyici kabul edilse de etiyolojiye bağlı olarak statik veya tersine çevrilebilir olabilir. Bu nedenle hafif bilişsel bozukluk (HBB), hafıza bozulması yaşayan ancak demans kriterlerini henüz karşılamayan hastaları tanımlamak için kullanılır (Clarke ve ark., 2009). Yaşlı yetişkinlerde görülen demansın en yaygın iki nedeni AH ve vasküler demanstır. EEG kayıtları demansta nadiren spesifik değişiklikler gösterir. En sık görülen bulgu yaygın delta dalgaları ve alfa ritminin kaybı olarak görülür (Yogarajah, 2013).

2.3.5 Alzheimer Hastalığı

AH, dünya genelinde demansın en yaygın sebebidir. Temel nedeni tam olarak bilinmese de 45 yaşın altında nadir görülür ve prevalansı yaşla birlikte artarak özellikle 65 yaşından sonra belirginleşir. AH, demansla ilişkili olumlu bir aile geçmişiye sahiptir ve kadınlarda erkeklere kıyasla daha fazla görülmektedir (Howlett, 2012). AH, Bilişsel bozulmanın en yaygın nedenidir ve tüm demans vakalarının en az %50'sinin temelinde yer alır. Bu nedenle, bilişsel sorunları başvuru şikayeti olarak sunmayan yaşlı hastalarda bilişsel bozulma şüphesi için düşük bir eşik belirlemek önemlidir (Clarke ve ark., 2009). AH, global olarak giderek artan bir halk sağlığı endişesi haline gelmektedir ve yaşlılar arasında sıkça görülen, ilerleyici bir nörodejeneratif bozukluktur. Zamanla beyin nöronlarını sistemli olarak yok eder (Puri ve ark., 2023). Yaşlanan nüfusta diğer demans türlerinin prevalansı ile birlikte artması beklenmektedir (Fernández ve ark., 2010).

AH'nin semptomları genellikle kısa süreli hafıza kaybı ile başlar. Konuşma ve oryantasyon güçlükleri, ruh hali değişiklikleri, kişisel bakım eksikliği ve davranışsal değişiklikler gibi sorunlar zamanla ilerler. Sonuç olarak, vücut

sistemlerinin işlevleri bozulur ve hasta ölüme doğru ilerler. Şu anda AH'nin tedavisi bulunmamakta ve mevcut tedaviler yalnızca belirli semptomların hafifletilmesine yardımcı olmaktadır (Miltiados ve ark., 2023).

AH'yi teşhis etmek için, hasta spesifik nöropatolojik değişikliklerin postmortem doğrulaması gibi belirli klinik kriterleri karşılamalıdır. Erken tanı ve müdahale, demanslı bireylerin sayısının artmasıyla önem kazanmıştır. Yapısal Manyetik Rezonans Görüntüleme (MRI), moleküler Pozitron Emisyon Tomografisi (PET) nörogörüntüleme ve beyin omurilik sıvısı analizleri gibi güvenilir biyobelirteçler klinik uygulamada kullanılmaktadır. Yüksek maliyetleri ve sınırlı erişimleri bu yöntemlerin kullanımını kısıtlamıştır. EEG, düşük maliyeti ve geniş erişilebilirliği nedeniyle klinik uygulama ve araştırmalarda giderek artmaktadır (Wang ve ark., 2023). Beyin aktivitesini ölçmek için çeşitli yöntemler bulunmakta olup, bunlar uzay-zamansal çözünürlük ve uygulanabilirlik açısından farklılık gösterir (Miltiados ve ark., 2023).

Son yıllarda EEG, beyin hastalıklarının tespiti ve değerlendirilmesinde güvenilir bir klinik araç olarak kullanılmaya başlanmıştır ve nörogelişimsel bozukluklar ile duygusal durumların değerlendirilmesinde test edilmiştir. Özellikle AH gibi demans türlerinin tespitinde ve ayırt edilmesinde EEG'ye artan bir ilgi vardır. EEG sinyallerinin karmaşık, durağan olmayan ve doğrusal olmayan doğası nedeniyle, farklı EEG problemleri için çeşitli etkili metodolojiler önerilmiştir. EEG sinyallerini analiz etmenin yaygın bir yolu, sinyali delta, teta, alfa, beta ve gama gibi farklı frekans bantlarına ayrıştırmaktır. Her frekans bandı, beyindeki çeşitli elektriksel aktiviteleri temsil eder ve farklı bilişsel ve fizyolojik süreçlerle ilişkilendirilir. Delta bandı (0.5-4 Hz), genellikle derin uyku ve bedensel işlevlerle ilişkilendirilirken, alfa bandının (8-13 Hz) dikkat süreçleri ve gevşeme ile ilişkili olduğu düşünülmektedir (Miltiados ve ark., 2023). AH olan bireylerde EEG ritminde genel bir yavaşlama olduğunu, yavaş ritimde güç artışı ve hızlı ritimde güç azalması olduğunu göstermektedir. AH'li bireyleri SB'den ayırmada umut verici bir ölçüt olan artmış teta-alfa güç oranı bulunmuştur. Bununla birlikte, FTD olan bireylerde alfa bant gücünün arttığı ancak delta ve teta bandı gücünde artış olmadığı veya alfa gücünün sabit kalmasına rağmen teta gücünde artış olduğu gibi tartışmalı sonuçlar elde edilmiştir (Wang ve ark., 2023).

2.3.6 Epilepsi

Epilepsi, beynin nöronlarında aniden meydana gelen anormal elektriksel aktiviteler sonucu ortaya çıkan kronik bir nörolojik hastalıktır ve dünya nüfusunun yaklaşık %1'ini etkilemektedir (Wang ve ark., 2021). Epilepsi, dünya genelinde çeşitli yaş gruplarından gelen 50 milyonun üzerinde insanı etkileyen en kritik ve sürekli nörolojik bozukluklardan biridir (Abdelhameed & Bayoumi, 2021).

Tekrarlayan ve öngörülemez nöbetler, istemsiz hareketlerin kısa süreli epizodlarına ve bazen geçici bilinç kaybına neden olabilir (Fisher ve ark., 2014). Epileptik nöbetler, anormal senkronizasyon, aşırı uyarılma ve yetersiz inhibisyon içeren epileptik sinirsel aktivitenin bir sonucu olarak ortaya çıkan geçici klinik belirtilerdir (Clarke ve ark., 2009). Epilepsinin klinik özellikleri, elektrik deşarjlarının beyindeki belirli bir bölgeyi etkilemesine ve deşarjların şiddetine bağlıdır (Howlett, 2012). Epilepsi, tekrarlayan ve belirgin bir sebep olmaksızın ortaya çıkan nöbetlere yatkınlık durumudur. Nöbetler genellikle beyin korteksindeki nöronlardan kaynaklanan ani, aşırı ve anormal elektrik deşarjlarına bağlı olarak meydana gelir. Nöbetler, birkaç saniye süren duyu farkındalığından, bilinç kaybına ve istemsiz sertleşme ile sarsılmaya kadar çeşitli şekillerde olabilir (Howlett, 2012). Epilepsi hastalarının ölüm oranları diğer nörolojik hastalıklara göre 2 ila 3 kat daha yüksektir ve tanıdan sonraki ilk birkaç yılda en yüksek düzeydedir (Clarke ve ark., 2009).

Epilepsi, tekrarlayan ve kendiliğinden nöbet geçirme eğilimi olan bir durumdur. Tek bir nöbet genellikle epilepsi tanısı koymak için yeterli değildir. Epilepsi, kişinin kronik bir süreçten kaynaklanan tekrarlayan nöbetlere sahip olduğu bir durumu ifade eder. Bu tanım, düzeltilebilir veya kaçınılabılır durumlardan kaynaklanan tek bir nöbeti veya tekrarlayan nöbetleri olan bir kişinin zorunlu olarak epilepsiye sahip olmadığını gösterir. Epilepsi, birçok farklı form ve nedene sahip olabilir ve belirli epilepsi sendromları, klinik ve patolojik özelliklerine göre sınıflandırılır (Harrison, 2013).

Epileptik nöbetler, beynin korteksindeki nöronların aniden paroksizmal, senkron ve aşırı derecede boşalması sonucu ortaya çıkar ve bilinç, davranış, duyu, motor fonksiyon veya duyumda bozukluklar olarak kendini gösterir (Yogarajah, 2013). Nöbet sırasında teşhisi destekleyen klinik özellikler arasında gözbebeği genişlemesi, yüksek kan basıncı ve kalp atım hızı bulunmaktadır (Yogarajah, 2013). Epilepsi teşhisi esasen klinik bir teşhis olduğundan, EEG'nin yanlış negatif oranı

yüksek olabilir. EEG, epilepsi tanısının desteklenmesinde kullanılır ancak tek başına yeterli değildir. Epileptiform özellikler gösteren EEG sivri ve keskin dalgalar içerir. EEG'nin epilepsideki başarı oranı, uyku ve uyanıklık kayıtlarının birleştirilmesiyle artar (Clarke ve ark., 2009).

EEG, epilepsinin teşhisinde ve sınıflandırılmasında büyük ölçüde faydalıdır. Epileptik bir nöbet anında kaydedildiğinde, epileptiform aktivitenin klinik teşhisi doğruladığı durumlarda son derece etkili bir araçtır. Kanıtlanmış epilepsisi olan bireylerin yaklaşık yarısında, ilk nöbetler arası EEG'de anormallik bulunabilir. EEG, özellikle birincil veya ikincil nöbet bozukluğu şüphesi bulunan çocuklar ve genç yetişkinlerde oldukça kullanışlıdır (Howlett, 2012). Klinik kriterler, epilepsi türünün belirlenmesi konusunda tek başına yeterli veya tamamen güvenilir olmayabilir. Nöbetlerin bilişsel bozulma ve demansla ilişkilendirilebilecek bir dizi mekanizması bulunmaktadır. Özellikle gizli temporal lob nöbetlerinin tanımlanması kritik öneme sahiptir. Nöbetlerin bilişsel etkilerini temel hastalık sürecinden ayırt etmek için dikkatli bir değerlendirme yapılması önemlidir. Epilepsi sendromları, ilerleyen bilişsel bozulmaya neden olan temel hastalık süreçlerinin ayrılmaz bir parçasıdır (Clarke ve ark., 2009).

2.3.7 Parkinson Hastalığı

PH, ilk olarak 1817'de James Parkinson tarafından tanımlanmış ve "sallanma felci" olarak adlandırılmıştır. Erkeklerde kadınlara göre daha yaygın olan bu hastalık, yavaş ilerleyen bir dejeneratif hastalıktır ve akinetik-rigide bir sendroma neden olur. Genellikle istirahat titremesi ile ilişkilendirilen PH, ilerledikçe eğik duruş, artan hareketsizlik, düşmeler, bilişsel gerileme, sürüklenen bir yürüyüş ve bozulmuş denge gibi belirtiler ortaya çıkar (Yogarajah, 2013).

PH, ırk, meslek ve ülke ayrımı gözetmeksizin herkesi etkileyebilen ikinci en yaygın nörodejeneratif hastalıktır. Ortalama başlangıç yaşı yaklaşık 60 olup, daha genç hastalarda da görülebilir. Yaşla birlikte görülme sıklığı artar ve önümüzdeki yıllarda yaygınlığının artması beklenmektedir (Harrison, 2013). PH'li hastalar genellikle hafif titreme, hareketlerin yavaşlaması, yürüme ve duruş bozuklukları gibi motor semptomlar yaşarlar. Ayrıca depresyon, koku kaybı, kabızlık ve uyku sorunları gibi motor olmayan PH'nin klinik değerlendirmesini zorlaştıran semptomlar da görülebilir. Bu hastalık, dopamin, asetilkolin ve serotonin gibi önemli nörotransmitterlerin üretimini etkiler bu da motor fonksiyonları etkiler (Pan ve ark., 2012). PH genellikle beş aşamaya ayrılır. İlk

aşamada hafif titreme ve küçük hareket sorunları, ikinci aşamada artan titreme, üçüncü aşamada denge ve el becerisi sorunları, dördüncü aşamada ciddi ve kısıtlayıcı semptomlar, son aşamada ise ayakta durma veya yürüme yeteneğinin kaybı görülür. PH, genel yaşam kalitesini tehdit eder ve diğer kronik hastalıklara yakalanma riskini artırır (Wang ve ark., 2020). PH tanısı, hem motor hem de motor olmayan semptomların tespitine dayanır. Tanı doğruluğunu artırmak ve sağlık uzmanlarına yardımcı olmak için DÖ gibi bilgisayar destekli yöntemlere ihtiyaç vardır. Bu teknolojiler, PH ve ilgili durumlarda tanısal performansı iyileştirme potansiyeline sahiptir (Islam ve ark., 2024).

PH'nin önemli bir belirtisi olan bilişsel işlev bozukluğu, hastalığın ilerlemesiyle birlikte bireylerin %80'den fazlasında demansa yol açabilir. Detaylı nöropsikolojik testler bilişsel fonksiyonu değerlendirmede altın standart olarak kabul edilir. Ancak, testler uzun sürebilir ve sık tekrarlandığında öğrenme etkilerine maruz kalabilir (Anjum ve ark., 2024). Mevcut tanı prosedürleri, motor bazlı klinik kriterlere dayanır ve önemli hastalık ilerlemesiyle ilişkilendirilen tedavilere daha zayıf bir yanıtın ardından ortaya çıkar. PH'nin tamamlayıcı ve objektif biyobelirteçlerinin araştırılmasını gerektirir. Böylelikle, klinisyenlere özel klinik eğitime ihtiyaç duymadan hastalığı teşhis etmeye yardımcı olabilir (Sugden & Diamandis, 2023).

2.4 EEG

EEG uzun süredir var olan ve özellikle epilepsiye neden olan işlevsel nedenlere dayalı olarak birçok beyin bozukluğunu teşhis etmek için nörologlar arasında yaygın olarak kullanılan bir yöntemdir. EEG, bir dizi elektrodu insanın saç derisinin yüzeyine yerleştirerek ve ardından beynin içinden geçen iyon akımından kaynaklanan voltaj dalgalanmalarını kaydederek çalışır. Beynin sinirsel aktivitesine karşılık gelen bu voltaj dalgalanmaları zaman serisine dönüştürülür (Abdelhameed & Bayoumi, 2021).

EEG, beyin korteksindeki elektriksel aktiviteyi kaydederek beyindeki anormalliklerin teşhis edilmesine yardımcı olan yaygın bir ölçüm yöntemidir. Ancak, geleneksel teşhis yöntemleri bazen sınıflandırılması zor durumlarla karşılaşabilir, bu da erken teşhis için daha hızlı ve güvenilir sistemlere ihtiyaç doğurur. DÖ yöntemleri, EEG sinyallerine uygulanarak otomatik teşhis sistemlerinin geliştirilmesine katkıda bulunur (Latifoğlu ve ark., 2024). Aktif bir beyin tarafından üretilen elektrik alanlarını ölçen bir beyin haritalama ve nöro

görüntüleme tekniğidir. Bu teknik, özellikle skalpte hissedilen mikrovolt düzeyindeki onlarca elektrik potansiyel farkını algılayarak piramidal nöronlar tarafından üretilen küçük uyarıcı postsinaptik potansiyellerin birleşmesinden kaynaklanan beyin aktivitesini ölçer. Ölçülen potansiyeller, çeşitli beyin süreçlerini incelemek için sinirsel aktiviteyi yansıtarak geniş bir klinik ve klinik dışı alanlarda yaygın bir şekilde kullanılabilir (Roy ve ark., 2019).

EEG, nörolojik hastalıklar için en önemli teşhis testlerinden biri olarak kabul edilir ve genellikle beyindeki elektriksel aktiviteyi izlemek için küçük metal diskler olan elektrotlar kullanılarak 20-30 dakikalık bir süreci içerir. EEG sıklıkla klinik durumlardaki değişiklikleri belirlemek için kullanılır (Abdulbaqi ve ark., 2022). Yüksek elektrot yoğunluğuna ihtiyaç duyulan durumlarda, elektrik şapkası veya ağlar içeren sistemler tercih edilir. Uluslararası 10-20 sistemi, elektrot yerleşimlerini ve isimlerini belirlemek için çoğu klinik ve araştırma amaçlı kullanılır. Bu sistem, elektrotlar arasındaki mesafeyi belirlemek için belirli anatomik referans noktalarını kullanarak %20 ve %10 sabit bir uzaklık sağlar. Klinik ve araştırma kullanımında, daha büyük uzamsal çözünürlük gerektiren durumlarda ek elektrotlar eklenebilir (Abdulbaqi ve ark., 2022). Büyük miktardaki EEG kayıtlarının işlenmesi için objektif, hızlı ve etkili sistemlere duyulan ihtiyaç kaçınılmaz hale gelmiştir. Bu tür sistemlerin bulunabilir olması hastaların yaşam kalitesini büyük ölçüde artırabilir (Abdelhameed & Bayoumi, 2021).

EEG, nörolojik bozukluklar süresince beyin fonksiyonel anatomisini incelemek ve beyin aktivitesini toplamak amacıyla üst düzey zamansal çözünürlüğü, güvenliği ve uygun maliyeti ile en yaygın tercih edilen yöntemdir (Lima ve ark., 2022). İnvaziv teknolojiler, daha düşük duyarlılık göstermeleri, daha yüksek voltaj genlikleri sunmaları ve çözünürlük açısından avantajlı olmaları bakımından önemli avantajlar sağlamaktadır. Elde edilen bilgiler daha yüksek derecede dış etkilere, göz hareketleri, yüz hareketleri, soluk alıp verme, çiğneme, yutma gibi sanal etkilere sahip olabilir ancak ölçümler cerrahi müdahale gerektirmez. Yüzey kayıtları, altta yatan beyin yapılarının anatomisi ve fizyolojisinin tam açıklamalarını ve milisaniye düzeyinde yüksek zaman çözünürlüklerini sağlar. Elde edilen sinyallerin düşük genlik ve müdahale nedeniyle sinir aktivitesini güçlendirmek önemlidir (Luján ve ark., 2021).

Ölçülen ham EEG sinyalleri, sistem kaynaklı girişimler ve hasta ile ilişkili fizyolojik müdahaleler içerebilir. Hasta kaynaklı veya içsel girişimler, vücut

hareketleri, göz kırpma, nefes alma veya terleme gibi faktörlerden kaynaklanır. Sistem kaynaklı girişimler ise, 50/60 Hz güç kaynağı müdahalesi, elektronik ekipman ve bileşenlerden kaynaklanan elektriksel gürültü, elektrotların empedans dalgalanmaları veya kablo kusurları gibi nedenlerden ortaya çıkar. Bu nedenle, EEG sinyallerinin içerdiği önemli bilgileri işlemek ve saklamak, sonraki sınıflandırma ve teşhis aşamalarında net bilgiler elde etmek amacıyla müdahaleleri ve girişimleri ortadan kaldırmak oldukça kritiktir (Luján ve ark., 2021).

Tablo 2.1. EEG Frekans Bantları (Tatum, 2014)

Frekans Bandı	Bant Genişliği	Görevler
Delta	0.1-4 Hz	Uyku, hiperventilasyon
Teta	4-8 Hz	Uykulu olma
Alfa	8-12 Hz	Gözleri kapatmak
Beta	12-30 Hz	Uyanık olma
Gama	30-70 Hz	Öğrenme, hafıza

Tablo 2.1, insan beyninin farklı işlevleri ile ilişkili farklı frekans bantlarındaki EEG dalgalarını özetlemektedir. En düşük frekans bandı olan Delta dalgaları (0.1-4 Hz), uyku sırasında ve hiperventilasyon gibi durumlarda görülen dalgardır. Teta dalgaları (4-8 Hz) ise uykulu olma ve hafif uyku hali ile ilişkilidir. Alfa dalgaları (8-12 Hz), gözleri kapatma ve dinlenme sırasında ortaya çıkan dalgardır. Beta dalgaları (12-30 Hz), uyanıklık ve aktif zihinsel faaliyet ile ilişkilidir. En yüksek frekans bandı olan Gama dalgaları (30-70 Hz) ise öğrenme, hafıza ve bilinçli farkındalık gibi karmaşık bilişsel fonksiyonlarla ilişkilidir. Nöral aktiviteyi anlama ve beynin durumunu değerlendirme yeteneği, özel bir karakteristik olarak tanımlanabilir. EEG özellikleri, bir dizi faktöre bağlı olarak yaş, katılımcıların zihinsel durumu veya cinsiyet gibi değişiklik gösterir. Beynin içindeki temel dinamikler hem doğrusal hem de doğrusal olmayan öğeleri içerir ve söz konusu karakteristik özellikleri belirler (Luján ve ark., 2021).

2.5 Yapay Zeka ve Derin Öğrenme

Yapay zeka, verilerden öğrenebilen ve bilinçli kararlar veya tahminler yapabilen algoritmalar ve modeller geliştirmeye odaklanır. MÖ algoritmaları, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç ana kategoriye ayrılır. Denetimli öğrenme, her girdi için doğru cevabın bilindiği etiketli

bir veri kümesi kullanarak algoritmaları eğitir ve bu sayede yeni ve görülmemiş girdiler için doğru tahminler yapabilmesini sağlar. Denetimsiz öğrenme, etiketlenmemiş verilerdeki kalıpları veya yapıları tanımlamaya odaklanır. Pekiştirmeli öğrenme, bir ödül sinyalinin maksimize etmek için çevreyle etkileşimden öğrenmeyi içerir.

DÖ, insan beyninin yapısını ve işleyişini taklit eden yapay sinir ağlarının oluşturulmasını içerir. Sinir ağları, birbirine bağlı düğüm veya nöron katmanlarından oluşur ve verilerdeki karmaşık kalıpları ve ilişkileri tanımada üstündür. DÖ'nin önemli bir avantajı, kurallara dayanmadan veriye dayalı eğilimlere ve bağlantılara dayalı tahminler veya kararlar alabilmeleridir. Bu özellik, sağlık hizmetleri gibi karmaşık veri analizlerinin insanlar için zor olabileceği alanlarda onları özellikle değerli kılar (Islam ve ark., 2024).

Yapay zeka, günümüz toplumunun birçok yönünü etkilemekte olup web aramalarından sosyal medya içerik filtrelemeye, e-ticaret sitelerindeki önerilere ve hastalıkların belirlenmesine kadar birçok alanda kullanılmaktadır. Kameralardan akıllı telefonlara kadar birçok tüketici ürününde de karşımıza çıkan bu teknoloji, görüntülerde nesneleri tanımlamaktan konuşmayı metne çevirmeye, haberleri, gönderileri veya ürünleri kullanıcı ilgileriyle eşleştirmeye ve arama sonuçlarını seçmeye kadar birçok alanda işlev görmektedir. Uygulamalarda giderek artan bir şekilde DÖ tekniklerinden yararlanılmaktadır (Lecun ve ark., 2015).

MÖ, bilgisayarların programlanmadan öğrenip gelişmelerine izin veren yapay zeka alanının bir dalıdır. MÖ, veriye erişip bağımsız olarak öğrenme yeteneğine sahip programlardan oluşur. Bu yöntem, çeşitli sektörlerde büyük veri setlerindeki istatistiksel desenleri çözerek, insan doğruluğunu aşan sonuçlar elde etmekte kullanılmaktadır. Tıbbi teşhislerden nörolojik hastalıkların evre tahminine kadar geniş bir uygulama yelpazesi bulunmaktadır (Lima ve ark., 2022).

DÖ, karmaşık verileri analiz etmek için güçlü bir tekniktir ve son zamanlarda tıbbi analizlerde çok popüler hale gelmiştir. DÖ yöntemleri, doğrusal olmayan modüllerin bir araya getirilmesi yoluyla elde edilen karmaşık çok katmanlı temsil yöntemleridir. Bu yöntemler, yeterli sayıda bu tür dönüşümlerin birleştirilmesiyle öğrenilmek istenen karmaşık fonksiyonları etkili bir şekilde öğrenir. Özellikle sınıflandırma görevlerinde, temsilin daha yüksek katmanları, girişin önemli yönlerini daha güçlü bir şekilde vurgular ve ilgisiz varyasyonları baskılayarak daha keskin ve anlamlı öğrenme sonuçları elde etmeye olanak sağlar

(Lecun ve ark., 2015). DÖ, yapay zeka kapsamındaki MÖ sistemleri için daha gelişmiş bir araç olarak kabul edilir (Lima ve ark., 2022). DÖ ve MÖ yaklaşımları arasındaki farkı anlamak için önce temel işlevlerini anlamak önemlidir. MÖ, belirli bir görevi yerine getirmek için veri işleme kuralları keşfetme sürecidir. Bu kurallar, belirli bir görev için beklenen sonuç örnekleri verildiğinde keşfedilir (Chollet, 2018). Geleneksel MÖ yöntemleri, ham verileri doğrudan işleyemez. Ham veriler, MÖ modellerinin öğrenebileceği bir formata dönüştürülmeden önce genellikle özellik çıkarıcılar kullanılarak işlenir. Özellik çıkarıcılar, ham verilerden anlamlı özellikleri çıkarmak için kullanılan istatistiksel tekniklerdir (Lecun ve ark., 2015). Algoritmaların performansı, mevcut çıktı ile beklenen çıktı arasındaki farkı belirleyerek ölçülür ve algoritmanın çalışma şeklini ayarlamak için kullanılır. Algoritmaların temel hedefi, veriyi analiz etmek ve bu veriden yeni bilgiler çıkarmaktır. Verilerdeki kalıpları tespit etmek için sınıflandırma veya kümeleme gibi çeşitli teknikler kullanılabilir (Chollet, 2018).

DÖ, geleneksel yapay zeka algoritmalarının uzun süredir çözemediği problemlerde önemli ilerlemeler kaydetmektedir. Yüksek boyutlu verilerde karmaşık yapıları keşfetme konusunda başarılı olduğu için bilim, iş ve sağlık gibi birçok alanda uygulanmaktadır. Görüntü tanıma ve konuşma tanıma alanlarında rekorlar kırdığı gibi, parçacık hızlandırıcı verilerini analiz etmeden, beyin devrelerini yeniden oluşturmaya kadar birçok alanda diğer MÖ tekniklerini geride bırakmıştır (Lecun ve ark., 2015).

Nörolojik hastalıkları teşhis etmede DÖ modelleri karmaşık beyin fonksiyonlarını hassasiyetle analiz ederek önemli girdi parametrelerini öne çıkaran doğrusal olmayan katmanlardan oluşan sistemler kullanarak daha net ve anlamlı sonuçlar elde etmeyi mümkün kılar (Lecun, Bengio ve Hinton, 2015). Birçok yöntem, model öğrenimi ile ilişkili hiper parametrelere sahiptir. Model performansı, modele özgü hiper parametreler için en uygun değerlerin bulunmasına da bağlıdır. Hiper parametrelerin sayısı düşükse, ızgara veya rastgele arama yoluyla keşfedilebilirler. Bir modelin daha yüksek karmaşıklığı tahmin kapasitesini artırabilirken, belirli model mimarilerinin avantajlarını ve dezavantajlarını anlamak önemlidir (Merk ve ark., 2022).

2.5.1 Yapay Sinir Ağları

Bir yapay sinir ağı, beyindeki sinir hücrelerinin çalışma şeklini modelleyen bir hesaplama yapısıdır. Biyolojik sinir işleme şeklinden ilham alarak oluşturulan

bu mimari, paralel bir yapıya sahiptir ve yeni bilgi alındıkça ayarlamalar yapabilen veya kendi başına öğrenebilen öğrenme algoritmalarını kullanır. Doğrusal olmayan istatistiksel veri modellemesi için etkili bir araçtır (Lima ve ark., 2022). Yapay sinir ağları, özel aktivasyon fonksiyonlarına sahip birçok nöronun bir araya gelmesiyle oluşturulur. Her nöron seti, bir gizli katmana aittir ve birçok gizli katman derin sinir ağlarını oluşturur. DÖ yöntemleri, ham giriş verilerinden gereken temsili otomatik olarak bulabilen temsil öğrenme algoritmalarının bir türüdür (Lecun ve ark., 2015). Bu ağlar, insan beynindeki sinir hücrelerinin davranışını taklit eden MÖ modelleridir. Beyindeki sinir hücreleri, akson ve dendrit adı verilen uzantılarla birbirine bağlıdır. Aksonlar, bir hücreden diğerine sinyal gönderirken, dendritler gelen sinyalleri alır. Bu sinir hücreleri arasındaki bağlantılara sinaps denir. Yapay sinir ağlarında da benzer bir yapı kullanılır. Yapay sinir hücreleri birbirine bağlıdır ve bağlantıların gücü öğrenme sürecinde değişir. Bu değişiklikler, yapay sinir ağının davranışını etkiler (Aggarwal, 2018).


Yapay sinir ağları, biyolojik sinaptik bağlantılardan esinlenerek geliştirilmiş hesaplama modelleridir. Her nörona gelen her giriş, o nöron tarafından hesaplanan işlevi etkileyen bir ağırlıkla ölçeklendirilir. Yapay sinir ağları, hesaplanan değerleri giriş nöronlarından çıkış nöronlarına ileterek ve ağırlıkları ara parametre olarak kullanarak girdilerin bir fonksiyonunu hesaplar. Öğrenme süreci, nöronları birbirine bağlayan ağırlıkların ayarlanmasıyla gerçekleşir (Shalev-Shwartz, 2014). Yapay sinir ağları, öğrenme için dış uyaran gerektirir. Bu uyaran, öğrenilecek fonksiyonun giriş-çıkış çiftlerini içeren eğitim verileri tarafından sağlanır. Eğitim verileri, sinir ağına beslenir ve giriş temsillerini kullanarak çıkış etiketleri hakkında tahminler yapar. Veriler, ağırlıkların doğruluğu üzerine geri bildirim sağlayarak nöronlar arasındaki ağırlıkları tahmin hatalarına yanıt olarak ayarlar. Ağırlıkların değiştirilmesi, gelecekteki iterasyonlarda hesaplamaları daha doğru hale getirir ve sinir ağı tarafından hesaplanan fonksiyonun zaman içinde daha kesin tahminler sunmasına yol açar. Eğitim verilerinin sınırlı bir giriş-çıkış çifti kümesi üzerinde eğitilmesi, görülmeyen girdilerin fonksiyonlarını doğru bir şekilde hesaplama yeteneği olan model genelleştirmesi olarak adlandırılır. Yapay sinir ağları, temel hesaplama birimlerinin birleştirilmesi ve ağırlıkların birbirine olan bağımlılıklarının kullanılmasıyla tahmin hatasını en aza indirmeyi amaçlar. Sinir ağları, birden fazla birimi birbirine bağlayarak daha karmaşık veri işlevlerini öğrenme yeteneğini artırır (Aggarwal, 2018).

2.5.2 Sinir Ağlarının Basit Mimarisi

Tek katmanlı bir ağda, bir dizi giriş, doğrusal bir fonksiyonun genelleştirilmiş bir varyasyonunu kullanarak doğrudan bir çıktıya eşlenir. Bu basit sinir ağı örneği perceptron olarak bilinir. Çok katmanlı sinir ağlarında nöronlar ileri besleyen katmanlar halinde düzenlenir. Bir sinir ağının nöronlarının yapılandırılması, ağı eğitmek için kullanılan öğrenme algoritmasıyla yakından bağlantılıdır. Bu nedenle, sinir ağlarının tasarımında kullanılan öğrenme algoritmalarından yapılandırılmış olarak bahsedebiliriz (Haykin, 2009).

2.5.3 Tek Katmanlı Sinir Ağları

Perceptron, genellikle ikili sınıflandırma problemlerini çözmek amacıyla kullanılan tek katmanlı bir sinir ağı modelidir. Perceptron algoritması, girdi özelliklerini ağırlıklarla çarpar ve ardından bir toplamı hesaplar. Bu toplam, genellikle bir adım fonksiyonu gibi bir aktivasyon fonksiyonu tarafından işlenir ve çıktı üretilir. Eğitim sürecinde, algoritma hatalı tahminler yaparsa ağırlıkları günceller. Ancak, perceptronlar yalnızca doğrusal olarak ayrılabilen veri kümelerini doğru bir şekilde sınıflandırabilir (Aggarwal, 2018). Şekil 2.1'de, tek katmanlı ileri beslemeli bir nöron ağının örnek bir gösterimi sunulmaktadır.



Şekil 2.1. Tek katmanlı nöronların ileri besleme ağı şeması

Bir sinir ağında nöronlar katmanlar halinde düzenlenir. Katmanlı bir ağın en basit biçiminde, doğrudan nöronlardan oluşan bir çıkış katmanına yansıtan kaynak düğümlerden oluşan bir giriş katmanı vardır. Böyle bir ağ, hesaplama düğümlerinin çıkış katmanına atıfta bulunarak tek katmanlı ağ olarak adlandırılır (Haykin, 2009).

2.5.4 Çok Katmanlı Sinir Ağları


Çok katmanlı sinir ağları, birden fazla hesaplama katmanını içerir. Giriş ve çıkış arasındaki ek ara katmanlar, gerçekleştirilen hesaplamaların kullanıcı tarafından görülememesi nedeniyle gizli katmanlar olarak adlandırılır. Ardışık katmanlar, girdiden çıkışa doğru ileri yönde birbirine beslenir. İleri besleme ağlarının tipik mimarisi, bir katmandaki tüm düğümlerin bir sonraki katmandakilere bağlı olduğunu varsayar. Bu nedenle, sinir ağının mimarisi, katman sayısı ve her katmandaki düğüm sayısı/tipi belirlendikten sonra hemen hemen tamamen tanımlanmış olur. Tek kalan detay, çıkış katmanında optimize edilen kayıp fonksiyonudur. Ayrık tahminler için SoftMax çıktıları ile çapraz entropi kaybı, gerçek değerli tahminler için ise kare kayıp ile doğrusal çıktılar kullanmak son derece yaygındır (Aggarwal, 2018). Ağı giriş katmanındaki kaynak düğümleri, aktivasyon vektörü ile ilgili unsurlarını sağlar. İkinci katmandaki nöronlara uygulanan giriş sinyallerini oluşturur. İkinci katmanın çıkış sinyalleri, üçüncü katmanın girişleri olarak kullanılır ve ağı geri kalanı için de geçerlidir. Tipik olarak ağı her katmanındaki nöronların girişleri olarak yalnızca önceki katmanın çıkış sinyalleri bulunur. Ağı çıkış katmanındaki nöronların çıkış sinyallerinin kümesi ağı giriş katmanındaki kaynak düğümleri tarafından sağlanan aktivasyon desenine karşı ağı genel yanıtını oluşturur (Haykin, 2009).

2.5.5 Aktivasyon Katmanları

Aktivasyon katmanları, bir sinir ağı modelinin temel unsurlarından biridir. Katmanlar, sinir ağının girdi ve çıktıları arasındaki karmaşık ilişkileri modeller. Bir sinir ağının çıktısını hesaplarken kullanılan aktivasyon fonksiyonlarını içerir. Fonksiyonlar genellikle sinir ağının çıktısını belirli bir aralığa sınırlar ve böylelikle sinir ağının çıktısının belirli bir formatta olmasını sağlamanın yanı sıra modelin öğrenme yeteneğini artırır. Aktivasyon katmanları, bir sinir ağının karmaşıklığını ve yeteneklerini belirlemede önemli bir rol oynar. Doğrusal aktivasyon fonksiyonları, modelin doğrusal ilişkileri öğrenmesine izin verir. Doğrusal olmayan aktivasyon fonksiyonları ise modelin daha karmaşık, doğrusal olmayan ilişkileri

öğrenmesine yardımcı olur. Aktivasyon katmanları, bir sinir ağının genel performansı ve yetenekleri üzerinde büyük bir etkiye sahiptir (Aggarwal, 2018).

Rektifiye Edilmiş Doğrusal Aktivasyon (ReLU), Lojistik (Sigmoid) ve Hiperbolik Tangent (Tanh) gibi birkaç aktivasyon fonksiyonu türü vardır. Şekil 2.2'de, üç farklı aktivasyon fonksiyonunun (ReLU, Sigmoid ve Tanh) bir girdi sinyali üzerindeki etkileri gösterilmektedir.



Şekil 2.2. ReLU, Sigmoid ve Tanh aktivasyon fonksiyonları

Bilgisel ağlarda aktivasyon fonksiyonu, bir katmanın bir giriş veya bir dizi giriş verildiğinde çıktısını tanımlar. Doğrusal olmayan aktivasyon fonksiyonları, karmaşık problemler için öğrenme kapasitesini ve sistem direncini artırmak için sinir ağlarında yaygın olarak kullanılır. Her girdi, bir ağırlık ile ilişkilidir. Tüm ağırlıklı girdilerin toplamı, bir çıktıyı üreten doğrusal olmayan aktivasyon fonksiyonuna aktarılır.

2.5.6 Evrişimli Sinir Ağları


DÖ, MÖ'nin bir alt alanıdır ve çok katmanlı sinir ağlarını eğitmeyi içerir. Yapay sinir ağları, eğitim verilerinden öğrenerek ağırlıkları ayarlama yoluyla işlevlerini rafine ederek tahmin hatalarını en aza indirmeyi ve zamanla doğruluğu artırmayı amaçlar. MÖ modellerinin görülmemiş girdiler için genelleme yapma yeteneği sinir ağlarındaki birden çok birimin bağlantısı ile sağlanır (Aggarwal, 2018). Evrişimli sinir ağları (CNN), MÖ alanındaki çoğu araştırmanın odaklandığı en popüler DÖ ağlarından biridir. İlk olarak görüntü işleme uygulamaları için sunulan bu ağlar, son zamanlarda biyolojik sinyaller kullanılarak hastalıkların teşhisi ve tahmini için bir ve iki boyutlu mimarilere uyarlanmıştır (Shoeibi ve ark., 2021).

CNN, giriş katmanı, çıkış katmanı ve birden çok gizli katmandan oluşan DÖ mimarisinin bir alt kümesini temsil eder. Başlangıç gizli katmanları genellikle giriş verilerine konvolüsyon çekirdekleri uygulayarak özellik haritaları çıkaran

konvolüsyon katmanlarından oluşur (Sui ve ark., 2021). Bu konvolüsyon katmanları, aynı zamanda filtreler olarak da bilinir ve ağıın temel elemanlarını oluşturur. Veri kümesinde bir pencere kaydırarak giriş verilerine tekrarlı olarak uygulanarak bir özellik haritası oluşturur (Beeraka ve ark., 2022). Konvolüsyon katmanı yerel desenleri tespit eder. Havuzlama katmanı, yerel yama bölgelerinin maksimumunu hesaplayarak benzer özellikleri birleştirir. Bu teknik, her bir özelliğin konumunu genişletip güvenilir bir algı sağlar. İki veya üç aşamalı konvolüsyon, havuzlama katmanlarının ardından tam bağlantılı katmanlarla birleştirilmesi CNN üzerinden geri yayılımı kolaylaştırarak filtrelerdeki tüm ağırlıkların eğitilmesini sağlar (Lecun, Bengio ve Hinton, 2015). CNN daha derin katmanlara ilerledikçe, odak daha yüksek seviyeli özelliklerin öğrenilmesine ve girdilerin karmaşık yapılara ayrılmasına kayar, oysa başlangıç katmanları temel özellikleri anlamaya odaklanır (Keerthi Krishnan ve Soman, 2021). Havuzlama katmanları, verilerin boyutunu stratejik olarak azaltarak aşırı uyumu hafifletir ve hesaplama yükünü azaltır. Bu katmanlar, önceki konvolüsyon katmanının çıktı matrisini aşağı örnekleyerek her bölgedeki maksimum değeri seçer veya değerleri ortalar. Eğitim aşamasında, seyreltme katmanları rastgele seçilmiş bir dizi nöron birimini devre dışı bırakarak modelin iş yükünü azaltır ve aşırı uyumu önler. Öğrenilen özellikler, tam bağlı katmanda, önceki katmandaki her düğümün tamamen bağlı katmandaki her düğümle bağlantılı olmasıyla birleştirilir. Her bir tamamen bağlı katman, sonuncusu hariç, CNN ağı performansını optimize etmek için bir aktivasyon fonksiyonu içerir (Xia ve ark., 2021). Düzleştirme katmanı, verileri bir boyutlu bir diziye dönüştürerek bu süreçte önemli bir rol oynar ve verileri tam bağlı katmanı için hazırlar. Her girişin ağıdaki her nörona bağlı olduğu sonraki tam bağlı katmanları için verileri hazırlar. DÖ'de, her katmanın öğrenme süreci, önceki katmanın öğrenmesinin tamamlanmasına dayanır. Normalizasyon sırasında giriş değerleri standart hale getirilse de, katmanlar zaman zaman gradyan kaybı veya daha yavaş, daha az kararlı eğitim gibi zorluklarla karşılaşabilir (Varlı ve Yılmaz, 2023). Sinir ağıları, gelen verileri anlamlı çıktılara dönüştürmek için doğrusal olmayan aktivasyon fonksiyonlarına dayanır.

Standart bir CNN, evrişim ve havuzlama katmanlarından oluşur. Evrişim katmanları, özellik haritasındaki lokal yamalara filtreler uygular. Bu yerel ağırlıklı toplamalar, doğrusallık fonksiyonlarından geçirilir. Tüm birimler aynı filtre bankalarını kullanır, ancak farklı özellik haritaları farklı filtre bankalarını kullanır.


Bu mimarinin iki nedeni vardır. İlki, lokal değer grupları genellikle yüksek derecede koreledir ve belirgin lokal motifler oluşturur. Evrişim katmanlarının bu motifleri tespit etmesini kolaylaştırır. İkincisi ise görüntülerin ve diğer sinyallerin lokal istatistikleri konumdan bağımsızdır. Farklı konumlardaki birimlerin aynı ağırlıkları paylaşarak farklı bölgelerde aynı deseni algılayabilmesini sağlar. Bu mimari sayesinde, görüntü tanıma, doğal dil işleme ve ses tanıma gibi uygulamalarda başarılı bir şekilde kullanılabilir (Lecun ve ark., 2015). Şekil 2.3, bir konvolüsyonlu sinir ağının temel bileşenlerini göstermektedir.



Şekil 2.3. Evrişimli sinir ağlarının genel mimarisi

Konvolüsyonel katman, her bir nöronun bir çekirdek gibi davrandığı konvolüsyonel çekirdeklerin bir koleksiyonundan oluşur. Konvolüsyonel çekirdek, orijinal görüntüyü alıcı alanlar olarak tanımlanan küçük parçalara bölmüştür. Bölme işlemi özellik çıkarma adımında yardımcı olur. Çekirdek, belirli bir ağırlık kümesini kullanarak görüntülerle konvolüsyon yapar ve çekirdeğin çarpan elemanlarını alıcı alanın çarpan elemanları ile çarparak çarpma işlemini uygular. Konvolüsyon işlemi, aynı ağırlık kümesi ile çekirdeği görüntü üzerinde kaydırarak farklı özellik setlerini çıkarmaya izin verir ve bu da CNN'yi tamamen bağlı ağlara göre parametre etkin kılar. Konvolüsyon işlemi, filtre türü ve boyutu, dolgu türü ve konvolüsyonun yönüne bağlı olarak çeşitli kategorilere ayrılabilir (Ein Shoka ve ark., 2023). Konvolüsyon katmanları için bir konvolüsyon işlemi tanımlanmıştır. Bu işlemde, bir filtre, aktivasyonları bir katmandan diğerine eşlemek için kullanılır. Bu konvolüsyon işlemi, mevcut katmanın derinliğiyle aynı derinliğe sahip ancak daha küçük bir uzamsal genişliğe sahip bir ağırlık filtresi kullanır. Filtrenin tüm ağırlıkları ile katmanın herhangi bir uzamsal bölgesi arasındaki nokta çarpımı, bir aktivasyon fonksiyonu uygulandıktan sonra bir sonraki katmandaki gizli durumun değerini belirler. Filtre ile katmanın uzamsal bölgeleri arasındaki işlem, bir sonraki

katmanı tanımlamak için mümkün olan her konumda gerçekleştirilir. Aktivasyonlar, önceki katmandan uzamsal ilişkilerini korur (Aggarwal, 2018). Şekil 2.4'te sinir ağı katmanları arasındaki bağlantılar gösterilmektedir.



Şekil 2.4. Sinir ağlarındaki bağlantılar

Konvolüsyonel sinir ağlarındaki bağlantılar oldukça seyrekler. Belirli bir katmandaki herhangi bir aktivasyon, önceki katmandaki küçük bir uzamsal bölgenin bir fonksiyonudur. Sinir ağlarında, parametreler, filtreler veya çekirdekler olarak bilinen yapısal birimler kümelerine düzenlenir. Filtre, genellikle uzamsal boyutları açısından karedir. Boyutlar, filtrenin uygulandığı katmanın boyutlarından çok daha küçüktür. Öte yandan, bir filtrenin derinliği her zaman uygulandığı katmanın derinliğiyle aynıdır (Aggarwal, 2018).

2.5.7 Konvolüsyon İşlemi

Konvolüsyon, iki fonksiyonun gerçek değerli bir argümanına uygulanan bir matematiksel işlemdir. İki fonksiyonun ortak özelliklerini ortaya çıkarmak için kullanılabilir. Konvolüsyon, iki fonksiyonun birbirleriyle örtüşmesi işlemidir. Bu örtüşme, iki fonksiyonun ortak özelliklerini ortaya çıkarmak için kullanılır. Konvolüsyonu, iki fonksiyonun birleştirilmesi olarak düşünülebilir. Örneğin, $x(t)$ fonksiyonunu yatay eksen ve $w(t)$ fonksiyonunu dikey eksen çizerek, iki fonksiyonun ortak özelliklerini gösteren bir grafik elde ederiz. Konvolüsyon işlemi, $x(t)$ fonksiyonunun her bir noktasını, $w(t)$ fonksiyonunun o noktaya karşılık gelen değeriyle çarparak gerçekleştirilir. Bu çarpımların toplamı, konvolüsyon işleminin sonucudur. $x(t)$ fonksiyonunun bir dalgayı temsil ettiği varsayılırsa $w(t)$ fonksiyonunun şekli, konvolüsyon işleminin sonucunu belirleyecektir (Goodfellow ve ark., 2016). Şekil 2.5'te örnek bir konvolüsyon işlemi gösterilmektedir.

8	1	3	2	3	4
4	5	7	8	1	3
7	6	2	9	2	2
4	8	7	9	8	6
1	5	4	0	2	3
3	2	5	1	9	7

*

1	0	-1
1	0	-1
1	0	-1

=

7			

$$(8*1)+(1*0)+(3*(-1))+(4*1)+(5*0)+(7*(-1))+(7*1)+(6*0)+(2*(-1))=7$$

Şekil 2.5. Örnek konvolüsyon işlemi

$$s(t) = \int x(a)w(t-a)da \quad (1)$$

Formül (1) konvolüsyon işlemi olarak adlandırılır. Konvolüsyon işlemi tipik olarak bir yıldız işaretiyle gösterilir.

$$s(t) = (x * w)(t) \quad (2)$$

Konvolüsyonel ağ terminolojisinde, konvolüsyona ilk argüman genellikle giriş olarak adlandırılır ve ikinci argüman çekirdek olarak adlandırılır. Son argüman ise çıktı olarak adlandırılır. Ayrık konvolüsyon, sürekli konvolüsyonun ayrık zamanlı bir analogudur. Ayrık konvolüsyonda, integral bir toplama ile değiştirilir.

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a) \quad (3)$$

MÖ uygulamalarında, giriş genellikle çok boyutlu bir veri dizisidir ve çekirdek genellikle öğrenme algoritması tarafından uyarlanan çok boyutlu bir parametre dizisidir. Girişin ve çekirdeğin her elemanı ayrı ayrı açıkça saklanmak zorunda olduğu için, fonksiyonların genellikle değerlerini sakladığımız noktaların sonlu kümesi dışında her yerde sıfır olduğunu varsayılır. Pratikte sonsuz toplamayı sonlu sayıda dizi ögesi üzerinde bir toplama olarak uygulayabileceğimiz anlamına gelir.


$$S(i,j) = (I * K)(i,j) = \sum_m \sum_n I(m,n)K(i-m,j-n) \quad (4)$$

$$S(i, j) = (K * I)(i, j) = \sum_m \sum_n I(i - m, i - n) K(m, n) \quad (5)$$

Genellikle m ve n 'nin geçerli değerlerinin aralığında daha az varyasyon olduğu için bir MÖ kütüphanesinde uygulanması daha basittir. Evrişimin komütatif özelliği, çekirdeği girdiye göre ters çevirilmesinden kaynaklanır. m arttıkça girdiye olan indeks artar ancak çekirdeğe olan indeks azalır. Birçok sinir ağı kütüphanesi çekirdeği çevirmeden gerçekleştirilen bir çapraz korelasyon adlı ilgili bir işlevi uygular (Goodfellow ve ark., 2016).

2.5.8 Doğrultulmuş Doğrusal Birim Katmanı

Doğrultulmuş doğrusal birim (ReLU) aktivasyon fonksiyonu, ilk kez 1969 yılında Fukushima tarafından tanımlanmış ve günümüzde DÖ modellerinde geniş bir şekilde benimsenen bir aktivasyon fonksiyonudur (Fukushima, 1969). Uygun bir aktivasyon fonksiyonunun seçimi öğrenme sürecini hızlandırabilir. ReLU, diğer mevcut aktivasyon fonksiyonlarının dezavantajlarını aşmakta etkili ve uygulaması kolay olduğu için gizli katmanlar için en popüler fonksiyondur (Ein Shoka ve ark., 2023). DÖ modellerinde ReLU aktivasyon fonksiyonu, sinir hücrelerinin çıktılarını sınırlamak ve öğrenme sürecini hızlandırmak amacıyla kullanılır. Fonksiyon, sinir hücrelerinin çıktılarının sıfırdan büyük olduğu durumlarda çıktıları sinir hücresinin girdisine doğrudan eşitleyerek çalışır. Sıfırdan küçük olduğu durumlarda ise çıktıları sıfıra ayarlar. Bu yaklaşım, sinir hücrelerinin aşırı değer almasını engelleyerek modelin öğrenme sürecini hızlandırır. ReLU aktivasyon fonksiyonu, sıfırdan büyük girdiler için eğimi sabit olan bir sigmoid fonksiyonu özelliğine sahiptir. Bu özellik, ReLU'yu diğer DÖ modellerinde kullanılan aktivasyon fonksiyonlarına göre daha verimli kılar (Fukushima, 1969). Bu aktivasyon fonksiyonu, çoğu ileri beslemeli sinir ağı tarafından önerilen varsayılan aktivasyon fonksiyonudur. Çıktıya doğrusal olmayan bir dönüşüm uygulayarak doğrusal bir dönüşüm sağlar. İki doğrusal parçaya sahip olan parçalı doğrusal bir fonksiyon olduğundan neredeyse doğrusal bir özellik taşır. Doğrusal üniteler, doğrusal modellerin gradyan tabanlı yöntemlerle optimize edilmesini kolaylaştıran özellikleri barındırırken aynı zamanda doğrusal modellerin genelleşmesini sağlayan özellikleri de korur (Goodfellow ve ark., 2016). Şekil 2.6'da yer alan ReLU fonksiyon grafiği, giriş değerinin sıfırdan büyük olup olmamasına bağlı olarak farklı çıktılar vereceğini göstermektedir.




Şekil 2.6. ReLU fonksiyon grafiği

2.5.9 Maksimum Havuzlama Katmanı

Havuzlama katmanının temel amacı, girişin özet istatistiğini oluşturmak ve özellik haritasının uzamsal boyutlarını azaltmaktır (Teuwen & Moriakov, 2020). Tipik bir konvolüsyon ağı katmanı üç aşamadan oluşur. İlk aşamada, katman bir dizi doğrusal aktivasyon üretmek için paralel birkaç konvolüsyon gerçekleştirir. İkinci aşamada, her doğrusal aktivasyon, düzleştirilmiş doğrusal aktivasyon fonksiyonu gibi bir doğrusal olmayan aktivasyon fonksiyonundan geçirilir. Üçüncü aşamada ise, katmanın çıktısını daha da değiştirmek için bir havuzlama fonksiyonu kullanılır (Goodfellow ve ark., 2016). Maksimum havuzlama katmanı genellikle evrişim katmanlarının ardından CNN'lere eklenen bir işlemdir ve çıktının çözünürlüğünü azaltmak için kullanılır. Evrişim katmanının çıktısının çözünürlüğünü azaltarak ağ parametrelerini azaltır ve dolayısıyla hesaplama yükünü ve aşırı uyumu azaltır. Ayrıca, daha yüksek değerli frekansları en çok etkinleştirilen frekanslar olarak seçmede de yardımcı olur (Murray & Perronnin, 2014). Evrişim katmanının amacı, önceki katmandaki özelliklerin yerel birleşimlerini tespit etmektir. Havuzlama katmanı ise benzer özellikleri birleştirmeyi hedefler. Bir havuzlama birimi, bir özellik haritasındaki birimlerin bir yerel yamasının maksimumunu hesaplar. Komşu havuzlama birimleri, bir sütun veya satırdan daha fazla kaydırılmış yamalardan giriş olarak alarak temsilin

boyutunu azaltır (Lecun ve ark., 2015). Şekil 2.7’de örnek bir maksimum havuzlama işlemi görseli bulunmaktadır.



Şekil 2.7. Maksimum Havuzlama İşlemi

2.5.10 Küme Normalizasyonu

Giriş değerlerinin normalizasyon işlemiyle standart hale getirilmesine rağmen, ara katmanlar normalizasyondan yeterince faydalanamaz. Bu durum, eğitim sürecinin daha yavaş ve daha istikrarsız olmasına yol açabilir. Ayrıca, bu durum gradyan kaybı ve minimal öğrenme gibi sorunlara neden olabilir. Bu sorunlar, küme normalizasyonu katmanı kullanılarak önlenir ve modelin verimliliği üzerinde olumlu bir etki sağlar (Ioffe ve ark.,2015).

2.5.11 Tam Bağlı Katmanlar

Sinir ağı içinde, son uzamsal katmandaki her özellik, ilk tam bağlantılı katmandaki her gizli durumla ilişkilidir. Bu katman, geleneksel bir ileri besleme ağı ile benzer şekilde çalışır. Genellikle, hesaplamaların gücünü artırmak için birden fazla tam bağlantılı katman kullanılır. Bu katmanlar arasındaki bağlantılar, geleneksel bir ileri besleme ağı gibi tam olarak yapılandırılmıştır. Çünkü tam bağlantılı katmanlar sıkıca bağlıdır. Çoğu parametre bu katmanlarda bulunur. Son uzamsal katmandan ilk tam bağlantılı katmana kadar olan bağlantılar çok sayıda parametreye sahiptir (Aggarwal, 2018).

Tam bağlantılı katmanlar, genellikle bir CNN çıktısını düzleştirerek ve tek bir vektöre dönüştürerek sınıflandırma problemlerinde son katman olarak kullanılır. CNN'in özelliklerini daha yüksek bir düzeyde birleştirmeye ve sınıflandırma doğruluğunu artırmaya yardımcı olur. Tam bağlantılı katmanlar, çeşitli otokodlayıcı mimarilerinde de kullanılır. Tam bağlantılı katmanlar CNN'in hem kodlayıcı hem de çözücü yollarında gizli kodları işlemek için kullanılır (Teuwen &


Moriakov, 2020). Sinir ağının çıkış katmanı, son dan bir önceki katmandaki her nörona tam bağlıdır ve onunla ilişkili bir ağırlığa sahiptir. Tam bağlantılı katmanlar yerine, son aktivasyon haritalarının tüm uzamsal alanında ortalama bir değer olarak tek bir değer oluşturmak da mümkündür. Son uzamsal katmanda oluşturulan özelliklerin sayısı, kullanılan filtre sayısına eşittir. Tam bağlantılı katmanların parametre sayısını önemli ölçüde azaltır. Bu, modelin daha az veri gerektirdiği ve daha genel bir şekilde eğitilebileceği anlamına gelir (Aggarwal, 2018).

2.5.12 SoftMax aktivasyon fonksiyonu

SoftMax aktivasyon fonksiyonu, özellikle sınıflandırma problemlerinde kullanılan bir fonksiyondur. Çok sınıflı sınıflandırma görevlerinde modelin her bir sınıfa ait olma olasılığını hesaplamak için kullanılır. SoftMax fonksiyonu, giriş değerlerini alır ve her bir sınıf için 0 ile 1 arasında değişen olasılık değerlerine dönüştürür, bu olasılıkların toplamı 1 olur. Bu şekilde, her bir sınıfın seçilme olasılığı, diğer sınıflarla kıyaslanarak belirlenir (Wang ve ark.,2018).

2.5.13 Seyreltme

Aşırı öğrenmeyi önlemek için seyreltme kullanılır. Rastgele seyreltme, çok sayıda farklı ağı makul bir sürede eğitime olanağı sağlar. Ağırlık güncellemelerini kontrol etmek için ağırlıkların normunu sınırlama yöntemi kullanılır. Ağırlık uzayının daha derinlemesine keşfedilmesine izin veren azalan bir öğrenme oranıyla öğrenme sürecine olanak tanır. Ağırlık ayarlarını paylaşan farklı ağların sağladığı tahminlerin ortalaması alındığında daha güvenilir ve genelleyici sonuçlar elde etmeyi sağlar (Hinton ve ark., 2012). Seyreltme, birçok farklı sinir ağı mimarisini etkili bir şekilde birleştirmek için bir yöntem sağlar. Birimleri belirli bir olasılıkla ağdan çıkarma prensibi üzerine kuruludur. Genişletilmiş ağırlık paylaşımı prensibiyle eğitildiğinden ağırlık paylaşımı korunur ve toplam parametre sayısı kontrol altında tutulur. Seyreltme, geniş bir ağ koleksiyonunu eğitmek olarak düşünülebilir ve her bir eğitim örneği için yeni bir seyreltilmiş ağ örneklenir ve eğitilir. Aşırı uyumu önler ve modelin genelleme yeteneğini artırır (Srivastava ve ark., 2014). Şekil 2.8 standart bir sinir ağı ve seyreltme uygulanmış sinir ağı arasındaki farkı görsel olarak aktarmaktadır.



Şekil 2.8. (a): Standart sinir ağı, (b): Seyreltme uygulanmış sinir ağı

2.5.14 Sinyal-Görüntü Dönüşüm Teknikleri

Sinyallerden elde edilen görüntü temsillerinin analizi 1D özelliklerle ayrıştırıcı bilgi kaybını önler (Shah ve ark., 2022). Büyük fizyolojik veri setleri de görüntüler olarak daha işlenebilir hale gelir. Ayrıca, üretilen 2D temsillerin görsel olarak incelenmesi sezgisellik sağlar. Bu zorlukların üstesinden gelmek için çeşitli sinyalden görüntüye dönüşüm teknikleri tablo 2.2’de verilmiştir.

Tablo 2.2. Yaygın olarak kullanılan sinyalden görüntü dönüşümü yöntemleri (Ch Vidyasagar ve ark., 2024)

Dönüşüm Yöntemi	Avantajlar	Dezavantajlar
FFT	- Hesaplama açısından verimlidir - Fizyolojik sinyallerden frekans bileşenlerinin çıkarılması için yararlıdır	- Zaman bilgisini tutmaz - Sinyalin durağan olduğunu varsayar
PSD	- Spektral güç dağılımı sağlar - Gürültüye dayanıklıdır	- Ortalama alma, geçici özellikleri gizleyebilir - Zayıf durağanlığı varsayar

Welch yöntemi	- PSD tahminindeki gürültüyü azaltır - Tüm sinyali gerektirmez - Güç spektral yoğunluğu tahmininde gürültü azaltma için faydalıdır	- Ortalama alma, zamansal çözünürlüğün kaybına yol açar - Segment seçimi frekans çözünürlüğünü etkiler
STFT	- Diğer TF yöntemlerine göre hesaplama açısından daha verimlidir - Gerçek zamanlı uygulamalar için uygundur - Kolay uygulanır - Fizyolojik sinyallerde zaman-frekans desenlerinin tanımlanması için uygundur	- TF çözünürlüğü takası - CWT'ye göre daha düşük çözünürlük - Sabit pencere genişliği nedeniyle daha az esneklik - Pencereleme spektral sızıntıya neden olabilir
CWT	- Esnek zaman-frekans çözünürlüğü sağlar - Durağan olmayan sinyalleri işler - Durağan olmayan fizyolojik sinyallerin zaman-frekans analizinde etkilidir	- Hesaplama açısından yoğundur - Dalgacık seçimi performansı etkiler
DWT	- Çok çözünürlüklü analiz - Seyrek temsil - Fizyolojik sinyal işlemlerinde çok ölçekli özellik çıkarımı için uygundur	- Standart ayrıştırma yaklaşımının eksikliği bulunmaktadır - Bilgi kaybetme riski vardır
RP	- Tekrarlayan desenleri görselleştirir - Fizyolojik sinyallerde tekrarlayan desenlerin ve doğrusal olmayan dinamiklerin tespiti için değerlidir	- Gecikme ve eşik gibi parametreler sonuçları etkiler - Doğrudan frekans bilgisi yoktur
Yeniden Şekillendirme	- Girdi temsilini 2D matris haline getirir - CNN mimarileriyle kolayca entegre olur	- Sıralı bilgi kaybı vardır - Sabit pencereleme, tüm zamansal dinamiklere uygun olmayabilir - Orijinal sinyal özelliklerini bozabilir - Sinyal ve modelin dinamiklerine duyarlıdır

STFT, EEG sinyallerinin analizi ve 1D ile 2D CNN'lerin uygulanmasında önemli avantajlar sunar. Zaman-frekans çözünürlüğü açısından diğer yöntemlere kıyasla daha verimli olan STFT, gerçek zamanlı uygulamalara uygunluğu ile dikkat çeker (Kıymık ve ark., 2005). Bu, EEG sinyallerinin dinamik ve değişken doğasını yakalamada kritik bir özelliktir. Kolay uygulanabilirliği ve sabit pencere genişliği sayesinde, STFT ile elde edilen zaman-frekans temsiliinin 2D görüntü formuna

dönüştürülmesi ve CNN'lere entegrasyonu oldukça pratiktir. STFT'nin hesaplama verimliliği, büyük EEG veri setlerinin hızlı ve etkili bir şekilde işlenmesini sağlar. Her ne kadar daha düşük çözünürlük ve spektral sızıntı gibi bazı dezavantajları bulunsa da, STFT'nin sağladığı genel kolaylık ve uygunluk, EEG sinyallerinin 1D ve 2D CNN'lerle işlenmesinde tercih edilmesini sağlar (Krishnan, 2021). Bu nedenle, EEG verilerinin zaman-frekans analizinde ve CNN'lerle kombinasyonunda STFT'nin üstünlükleri, bu yöntemi tercih etmemizin başlıca nedenleridir.

2.5.15 Kısa Zamanlı Fourier Dönüşümü

Kısa Zamanlı Fourier Dönüşümü (STFT), 1946'da Gabor tarafından tanıtılmış olup, o zamandan beri doğrusal olmayan ve durağan olmayan sinyallerin analizi için geniş ölçüde kullanılmaktadır. Fourier dönüşümü, bir sinyalin frekans bileşenleri hakkında değerli bilgiler sağlar. Fourier dönüşümü, bir sinyalin frekanslarının zaman içinde sabit kaldığını varsayar. Bu varsayım, frekansların dinamik olarak dalgalandığı durağan olmayan EEG sinyalleriyle uğraşırken sorunlu hale gelir (Sui ve ark., 2021).

EEG sinyallerinden belirgin frekans bileşenlerini çıkarmak, frekansa bağlı derinlemesine analiz potansiyelini açığa çıkarır ve beyin aktivitesinin daha derin bir şekilde anlaşılmasını sağlar (Beeraka ve ark., 2022). Fourier dönüşümünün EEG ile ilgili sınırlamalarını ele almak için STFT daha rafine bir yaklaşım sunar. STFT, Hızlı Fourier Dönüşümü'nün her veri çerçevesi için hesaplandığı bir tekniktir (Keerthi Krishnan ve Soman, 2021). Sinyali daha kısa, yaklaşık olarak durağan kabul edilen segmentlere böler. Bireysel segmentleri analiz için izole eden bir pencere fonksiyonunun uygulanmasıyla gerçekleştirilir. Daha sonra Fourier Dönüşümü bu durağan segmentlerin her birine uygulanır ve zaman bağımlı spektral temsil olan spektrogramı ortaya çıkarır. İki boyutlu temsil, sinyal içindeki zamansal ve spektral varyasyonları yakalar, frekansların zaman içinde nasıl değiştiğini görselleştirmemizi sağlar (Loh ve ark., 2022).

EEG sinyallerinin doğasında bulunan durağan olmama durumu, Fourier Dönüşümü gibi geleneksel zaman-frekans analiz yöntemlerinin temel özellikleri çıkarmada daha az etkili olmasına neden olur. STFT tarafından oluşturulan spektrogramlar, EEG sinyallerinin dinamik doğasını etkili bir şekilde yakalar ve epilepsi ile ilişkili EEG sinyallerini başarıyla ayırt edebilecek özelliklerin çıkarılmasını sağlar (Sui ve ark., 2021). Sinyali bölerek ve her segmentin frekans

içeriğini bağımsız olarak analiz ederek STFT hareketli bir pencere olarak işlev görür ve sinyalin frekans evrimini zaman içinde ortaya çıkarır. Büyük bir pencere, zaman içinde daha az çözünürlük ve frekansta daha fazla çözünürlük sağlar. Pencere uzunluğuna ek olarak, pencere tipi de zaman-frekans dağılımını belirler, çünkü güçlü zaman değişkenli sinyal frekans örtüşmesine neden olur (Keerthi Krishnan ve Soman, 2021).

$$STFT(t, \omega) = \int_{-\infty}^{+\infty} x(t)\omega(t - \tau)e^{-j\omega t} dt \quad (6)$$


Değişken t sinyaldeki belirli bir anı temsil ederken, ω açısal frekansı temsil eder. Zaman alanındaki sinyal fonksiyonu $x(t)$ olarak gösterilir. $\omega(t-\tau)$ terimi, zaman alanında $t-\tau$ etrafında merkezlenen bir pencere fonksiyonunu temsil eder. Karmaşık üstel terim $e^{-j\omega t}$ sinyali frekans alanında modüle eder ve dt , zamanda sonsuz derecede küçük bir değişimi ifade eder. İntegral, sinyalin, pencere fonksiyonunun ve karmaşık üstel terimin çarpımını farklı τ ve ω değerleri için yakalayarak, tüm zaman boyunca negatif sonsuzdan pozitif sonsuza kadar hesaplanır.

2.5.16 STFT kullanılarak 1D sinyallerin 2D spektrogram dönüşümü

CNN, çok boyutlu veriler üzerinde kullanılabilen DÖ ağıdır (Varlı ve Yılmaz, 2023). CNN'ler, özellikle biyolojik sinyaller kullanılarak hastalıkların teşhis ve tahmini için 1D ve 2D mimarileri uyarlamada, DÖ araştırmalarında yaygın olarak benimsenmiştir (Shoeibi ve ark., 2021). CNN'ler, görüntü veya spektruma dönüştürülen fizyolojik sinyal verilerini işleme konusunda son derece etkili olduğu kanıtlanmış bir yapay sinir ağı sınıfıdır (Alaskar, 2018).

1D EEG verisini 2D spektrograma dönüştürerek, epileptik nöbet tespiti için sinyal analizini geliştirmeye yönelik kapsamlı bir yaklaşım sunulmaktadır. Bu yöntem, zaman alanındaki EEG sinyallerini frekans alanındaki bir temsile dönüştürmek için bir STFT kullanır ve sinirsel aktivitenin altında yatan kalıplar ve dinamikler hakkında değerli bilgiler sağlar. EEG verilerinin analizi, nörolojide ve tıbbi sinyal işlemede epileptik nöbetler gibi anormallikleri tespit etmek için gereklidir. Geleneksel yöntemler, EEG sinyallerini 1D zaman serisi verileri olarak işleyerek, içerdikleri zengin frekans bilgisini sıklıkla göz ardı eder. Frekans bilgisi alanından yararlanmak için 1D EEG verisini 2D spektrogram dönüştürme yaklaşımı

sunulmaktadır. Şekil 2.9’da örnek bir EEG sinyali ve STFT uygulanmış 2D görsel bulunmaktadır.



Şekil 2.9. Bir sinyalin ve spektrogramla dönüştürülmüş halinin örneği

Dönüşüm işlemi, kayan pencere tekniği kullanılarak gerçekleştirilir. Bu teknikte EEG verisinin her bir segmenti STFT'ye tabi tutulur. Bu dönüşüm için parametreler, 100 örnek boyutunda bir pencere ve 256 olarak ayarlanmış belirli sayıda frekansı içerir. EEG sinyallerinin doğru bir şekilde temsil edilmesini sağlamak için örnekleme frekansı da 1000 Hz olarak ayarlanır. Her görüntü benzersiz bir EEG kaydına karşılık gelen görüntüler olarak kaydedilir. Sonuç olarak elde edilen spektrogramlar, EEG sinyallerinin frekans içeriğinin görsel olarak zengin bir temsili sunarak zaman alanında tam olarak ayırt edilemeyebilecek karmaşık frekans paternlerini yakalar. Epileptik nöbet tespit algoritmalarının doğruluğunu artırma potansiyeline sahiptir. Görüntüler, modellere sorunsuz bir şekilde entegre edilerek nörolojide daha kapsamlı ve pratik EEG sinyal analizi için fayda sağlar.

3. MATERİYAL VE YÖNTEM

Genel DÖ süreci, bir probleme çözüm olarak bir DÖ modeli geliştirmeyi içeren standart adımlardan oluşur. İlk ve en önemli adım, ham verilerden temel bilgilerin çıkarılmasına yardımcı olan ve verilerdeki gürültüyü ve aykırı değerleri ortadan kaldıran veri ön işlemedir. Veri ön işleme, veri temizleme, veri entegrasyonu, veri dönüşümü ve veri azaltma adımlarını içeren dört ana adımdan oluşur. İşlenmiş veriler, modelin eğitimi, parametre ayarı ve testi için eğitim ve test kümelerine bölündü. Bir sonraki adımda, model ağırlığı başlatma yöntemiyle bir eğitim seti üzerinde eğitildi. Modelin performansı farklı değerlendirme metrikleri kullanılarak test seti üzerinde değerlendirildi.

3.1 Veri kümeleri

Bu çalışmada, AH, Epilepsi ve PH teşhisi ve analizi için farklı veri kümeleri kullanılmıştır. Her veri kümesi, spesifik bir hastalık grubuna ait EEG sinyallerini içerir ve bu verilerin toplanması, ön işlenmesi ve analiz edilmesi süreçlerini kapsamaktadır.

3.1.1 Alzheimer hastalığı veri kümesi


Bu çalışmanın verileri, Yunanistan'ın Selanik kentindeki AHEPA Genel Üniversite Hastanesi Nöroloji Bölümü'nde oturur pozisyonda gözleri kapalı 88 denekten toplanmış halka açık EEG verileri kullanılarak elde edildi (Miltiadous, Tzimourta ve ark., 2023). Tablo 3.1'de veri kümesi tablosu görülmektedir.

Tablo 3.1. Alzheimer veri kümesinin demografik karakteristiği, ortalama ve standart sapma değerleri

Katılımcılar	AH	SB	FTD
Erkek sayısı	12	18	14
Kadın sayısı	24	11	9
Yaş	66,38(±7,88)	67,89(±5,4)	63,65(±8,22)
MMSE	17,75(±4,5)	30(0)	22,17(±2,63)

Nihon Kodan EEG 2100 cihazı, 10-20 uluslararası sistemine uygun olarak 19 kafa derisi elektrodu kullanılarak EEG sinyallerini kaydetmek için kullanıldı. 36 katılımcı AH, 23 katılımcı FTD tanısı almış ve kalan 29'u SB grubu oluşturmuştur. Her kayıt öncesinde, cilt empedansının 5 kΩ'un altında olduğu doğrulanmıştır. EEG

kayıtları 500 Hz'de örneklenmiş ve amplifikatörün ayarları, 0,3 s'lik bir zaman sabiti ve 70 Hz'lik bir yüksek frekans filtresi ile 10 μ V/mm'ye ayarlanmıştır. AH grubunun kayıtları yaklaşık 13,5 dakika, FTD grubunun kayıtları 12 dakika ve SB grubunun kayıtları ise 13,8 dakika sürmüştür. Toplamda, 485,5 dakika AH, 276,5 dakika FTD ve 402 dakika SB kaydı elde edilmiştir. Bilişsel ve nörofiziksel durumlarını değerlendirmek için MMSE uygulanmıştır. MMSE skoru 0 ile 30 arasında değişir ve daha düşük skorlar daha şiddetli bilişsel gerilemeyi gösterir. Bilişsel bozuklukları değerlendirmek için kullanılmış ve AH için ortalama skor 17,75, FTD için ortalama skor 22,17 ve SB grubu için ortalama skor 30 olarak bulunmuştur. Hastalık süresi aylar cinsinden ölçülmüş ve ortanca değer 25, IQR aralığı 24-28,5 aydır. AH gruplarıyla ilgili olarak, demansla ilgili başka hastalıklara dair bir rapor bulunmamıştır. Katılımcıların yaş ortalamaları sırasıyla, AH için 66,4, FTD için 63,6 ve SB grubu için 67,9 olarak belirlenmiştir. Verilerin ön işlem aşamasında, ham veriler BIDS uyumlu bir “.set” formatına dönüştürülmüş ve başlangıçta “.eeg” formatında dışa aktarılmıştır. Ön işleme sürecinde 0,5-45 Hz aralığında, Artefakt Alt Uzay Yeniden Yapılandırması ile bir Butterworth bant geçiren filtre kullanılmıştır. Verileri 19 ICA bileşenine dönüştürmek için Bağımsız Bileşen Analizi yapılmış ve göz ve çene artefaktlarının otomatik olarak reddedilmesi sağlanmıştır. Araştırmacılar, dil uyumluluğu sorunlarını aşmak için eserlerin otomatik açıklamalarını dahil etmekten kaçınmışlardır. Bu çalışmada türev veri kümesi olarak sunulan artefaktlardan filtrelenmiş AH ve SB verilerinden oluşan 65 kişilik alt veri kümesi oluşturularak sonuçlar elde edilmiştir. Şekil 3.1’de Alzheimer veri kümesi EEG sinyali örneği bulunmaktadır.




Şekil 3.1. Alzheimer veri kümesi EEG sinyali örneği

3.1.2 Epilepsi hastalığı veri kümesi


Bu çalışmada kullanılan veri kümesi, University of Bonn ile bağlantılı bir araştırma ekibi tarafından elde edilmiştir (Andrzejak ve ark., 2001). Veri kümesi, A'dan E'ye kadar etiketlenmiş beş alt segmentten oluşmakta olup toplamda 500 EEG sinyali içermektedir. A'dan E'ye kadar olan her sinyal 100 kanal içermekte olup her veri kümesi, 23,6 saniyeyi yansıtan 4096 örnekleme noktasına sahiptir. Kas aktivitesi ve göz hareketleriyle ilgili artefaktları kaldırmak için toplanan veriler görsel olarak incelenmiştir. EEG kayıtlarında çeşitli kas hareketlerinden kaynaklanan gürültüler ortadan kaldırılmıştır. EEG kaydı, elektrot yerleşimi için standart tekniklere uygun olarak yapılmıştır. Bu çalışmada epileptik nöbetler geçiren beş hasta seçilmiştir. Görsel inceleme ile kirleticiler belirlenip sürekli çok kanallı EEG kayıtlarından dikkatlice beş segment seçilmiş ve çıkarılmıştır. Segmentler A ve B, SB'den alınan EEG kayıt yüzeyinden özel olarak alınmıştır. Segment A, sağlıklı bir gönüllünün gözlerinin açık olduğu durumu yansıtırken,

Segment B, gözlerinin kapalı olduğu durumu temsil eder. Kalan C, D ve E segmentleri, epileptik nöbetler sırasında beyin aktivitesi ile ilişkilidir. C ve D setleri, yalnızca nöbet dışı beyin aktivitesi aralıklarını içerir. E seti, yalnızca nöbet aktivitesi sırasında kaydedilen EEG sinyallerini içerir. EEG sinyali, 12-bit dönüştürücü tarafından analogdan dijitale çevrildikten sonra 173.61 Hz'de kaydedilmiştir.

Veri kümesinin sınırlı sayıda örnek içermesi etkili bir DÖ modeli eğitmek için zorluk teşkil etmektedir. Bu sorun için yeterli miktarda EEG sinyali elde etmek pratik değildir ve nörologlar tarafından uzman etiketleme gerektirmesi de zorluğu artırmaktadır (Wu ve Fokoue, 2017). Bu sorunu çözmek için, genelleştirilmiş bir CNN modeli eğitmek için veri kümesini yeterince artıracak bir genişletme yaklaşımına ihtiyaç duyulmaktadır. Optimal performans için bol miktarda eğitim verisi gerektirir. EEG veri kümesi bir modeli eğitmek için yeterince küçük olmasına rağmen aşırı uyum riski belirgindir. Bu zorluğun üstesinden gelmek için, orijinal veri kümesi (Andrzejak ve ark., 2001) modifikasyonlar ve yeniden yapılandırmalar geçirmiştir ve yaygın olarak kullanılan epileptik nöbet tespiti veri kümesinden türetilmiş geliştirilmiş bir versiyon (Wu ve Fokoue, 2017) ile kullanışlılığı artırılmıştır. Orijinal veri kümesi, her biri bir saniyelik EEG kaydını temsil eden 23 parçaya bölünmüş ve sonuç olarak 11500 veri satırı elde edilmiştir. Her satır 178 veri noktası içermekte olup, farklı segmentlerdeki EEG sinyallerinin kapsamlı bir temsilini sağlar. Veri kümesi 9200 satırlık nöbet dışı sınıf ve 2300 satırlık nöbet sınıfı olarak iki sınıfa ayrılmıştır. Segment-1, bireyin epileptik nöbet geçirdiğini belirten nöbet aktivitesi kayıtlarını temsil eder. Segment-2, tümörün bulunduğu bölgeden alınan EEG kayıtlarını gösterir ve tümörün beyin aktivitesi üzerindeki potansiyel etkilerine dair bilgi sağlar. Segment-3, sağlıklı beyin bölgesinden kaydedilen EEG aktivitesi ile beyin tümörünün bölgesini belirler ve tümörün konumunu ve kapsamını anlamaya yardımcı olur. Segment-4, hastanın gözlerinin kapalı olduğu durumları kaydeder ve hastanın dinlenme veya rahatlama durumunu yansıtır. Segment-5, hastanın gözlerinin açık olduğu durumlarda alınan EEG kayıtlarını ifade eder. Bu yaklaşımda, epileptik nöbet sınıfı pozitif sınıf olarak kabul edilirken, kalan kategoriler negatif sınıf olarak kabul edilir. Bu, nöbet segmentlerini nöbet dışı segmentlerden ayıran özellikleri belirlemeye odaklanmayı sağlar. Örnek sinyaller şekil 3.2'de verilmiştir.




Şekil 3.2. Epileptik ve normal EEG sinyalleri



Şekil 3.3. Maksimum ve minimum değerlerin gösterimi

Şekil 3.3’de, EEG kayıtlarının analizi sırasında elde edilen veri kümesini temsil ederek epileptik ve epileptik olmayan durumları görselleştirilmektedir. Şekil

3.4'te epileptik sınıftaki noktaların yoğunluğu, hem x hem de y değerlerinin yüksek olduğu bir bölgede yoğunlaşmıştır. Buna karşılık, epileptik olmayan sınıftaki noktaların yoğunluğu, hem x hem de y değerlerinin düşük olduğu bir bölgede yoğunlaşmıştır. Bu ayırım, EEG sinyallerinin iki özelliğinin epilepsi teşhisinde potansiyel olarak kullanılabileceğini önermektedir.



Şekil 3.4. Epileptik ve normal durumların EEG sinyalindeki değerleri


Epilepsi semptomlarını temsil eden sinyallerin geniş dağılımı, çeşitli beyin bölgelerinde anormal elektriksel aktiviteyi işaret ederek nöbetlerin kökenleri ve mekanizmaları hakkında bilgiler sunmaktadır. Diğer yandan, epileptik olmayan sinyallerin dar bir alanda kümelenmesi, düzenli beyin fonksiyonunu ima etmektedir. Bu gözlemler, epilepsi teşhisi ve tedavisi için yeni stratejilerin geliştirilmesine katkıda bulunabilir ve hasta müdahalelerini ve yaşam kalitesini iyileştirmede önemli bir adım teşkil etmektedir.

3.1.3 Parkinson hastalığı veri kümesi

EEG, anlık ve uzun vadeli bilişsel işlevi izlemek için öngörüsüz elektrofizyolojik belirteçler sağlar. PH ile ilişkili bilişsel fonksiyonların EEG tabanlı dizinlenmesi, karmaşık ortamlarda sürekli ölçümlerle bilişin objektif, hızlı ve güçlü ölçümlerini üretebilir. Ayrıca, PH tedavilerine katkıda bulunabilir ve bilişsel yan etkileri önlemek ve bilişsel belirtileri iyileştirmek için kullanılabilir. EEG kayıt prosedürleri genellikle bilişsel bozuklukları olan bireyler tarafından iyi tolere edilir. Bu nedenle, uzman yönetimine ihtiyaç duymayan ve tekrarlanan veya

sürekli ölçümlerle uyumlu olan EEG tabanlı bilişsel değerlendirme büyük fayda sağlar.

Bilişsel ölçümler 2017-2022 yılları arasında Iowa City'deki Iowa Üniversitesi Hareket Bozuklukları Kliniği'nde 100 PH katılımcısından alınmıştır (Singh ve ark., 2022). Her bir bireye Birleşik Krallık Beyin Bankası kriterlerine göre bir hareket bozuklukları doktoru tarafından PH tanısı koyulmuştur. Tüm prosedürler katılımcılar normal ilaçlarını alırken gerçekleştirilmiştir. Ayrıca, 2017-2022 yılları arasında Iowa City genel topluluğundan bilinen nörolojik hastalığı olmayan demografik olarak eşleşen 49 SB Seniors Together in Aging Research kaydı aracılığıyla alınmıştır. Bilişsel bozukluğu olan kontrol katılımcılarında önceden var olan nörolojik veya psikiyatrik hastalıklarının bulunmadığı kontrol edilmiştir. PH EEG sinyal örneği şekil 3.5'de verilmiştir.



Şekil 3.5. Parkinson Hastalığı EEG sinyal örneği

Veri kümesi, PH olan 100 kişi ve 49 SB ile 149 katılımcıdan oluşmaktadır. EEG, 64 kanallı BrainVision başlığıyla kaydedilmiştir. Hastalardan gözleri açık bir

şekilde sessiz bir odada iki dakika boyunca oturarak dinlenme durumu EEG'si toplanmıştır (Anjum ve ark., 2024).

3.2 Önerilen Derin Öğrenme Modelleri

3.2.1 Epilepsi Tespiti İçin 1D CNN Modelinin Eğitimi

1D CNN, EEG sinyalleri üzerinde eğitilirken, 2D CNN ise karşılık gelen spektrogram görüntüleri kullanılarak eğitildi. Veri kümesi her iki model için de eşit olarak ayrıldı, %80'i eğitim için, %20' si ise test için ayrıldı. Bu dengeli dağıtım, modelin performansının kapsamlı bir değerlendirmesini sağlamayı amaçlamaktadır. Strateji, verinin %80'ini modellerin öğrenme ve genelleştirme yeteneklerini optimize etmek için eğitimde kullanmayı, kalan %20'sini ise kapsamlı değerlendirme için ayırmayı içerir. Önerilen 1D CNN mimarisi, EEG verilerini etkili bir şekilde yakalamak ve analiz etmek üzere tasarlanmış çeşitli katmanlar içermektedir. Model, 32, 64 ve 128 filtreye sahip üç ayrı konvolüsyon katmanı kullanır. Her konvolüsyon katmanı 6 ve 3 boyutunda bir çekirdek kullanır. Modelin yapısı bir giriş katmanını, toplu normalizasyon ile donatılmış konvolüsyon katmanları ve EEG sinyallerinden hiyerarşik özellikleri sistematik olarak çıkarmak için maksimum havuzlama katmanlarını kapsar. İlk konvolüsyon katmanı, 5 birimlik çekirdek ve 32 filtre ile 173 boyutunda bir sinyali işler, ardından toplu normalizasyon ve maksimum havuzlama gelir.

Mimariyi daha da geliştirmek için, mimari sırasıyla 64 ve 128 gibi daha büyük filtre boyutlarını içeren iki ek konvolüsyon katmanı ekler. Bu katmanlara model kararlılığını ve yakınsamayı güçlendirmek için stratejik olarak toplu normalizasyon uygulanır. Maksimum havuzlama katmanlarının kullanılması, özellik haritalarının aşağı örneklemesini kolaylaştırır, böylece boyut azaltılırken önemli bilgiler korunur. Düzleştirilmiş katman, çıktıyı tek boyutlu bir diziye dönüştürerek, sağlam sınıflandırma için yoğun katmanlara sorunsuz bir şekilde bağlanır. 64 ve 32 nöronlu iki tamamen bağlı yoğun katman, modelin veriler içindeki karmaşık örüntüleri kavrama yeteneğine katkıda bulunur. Aşırı öğrenmeyi önlemek için eğitim aşamasında seyreltme katmanları sorunsuz bir şekilde entegre edilir. İki nöron barındıran son yoğun katman, epilepsi tespitini gösteren ikili sınıflandırmaları etkili bir şekilde ileten çıktı katmanı olarak görev yapar. Model katmanları Tablo 3.2'de belirtilmiştir.

Tablo 3.2. Epilepsi Tespiti İçin Önerilen 1D CNN Modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
1D Konvolüsyon	(173, 32)	128
Küme Normalizasyonu	(173, 32)	128
Maksimum Havuzlama	(87, 32)	0
1D Konvolüsyon	(85, 64)	6208
Küme Normalizasyonu	(85, 64)	256
Maksimum Havuzlama	(43, 64)	0
1D Konvolüsyon	(41, 128)	24704
Küme Normalizasyonu	(41, 128)	512
Maksimum Havuzlama	(21, 128)	0
Düzleştirme	128	0
Yoğun Katman	64	172096
Seyreltme	64	0
Yoğun Katman	32	2080
Seyreltme	32	0
Yoğun Katman	2	66

3.2.2 Epilepsi Tespiti İçin 2D CNN Modelinin Eğitimi

2D CNN, epilepsi nöbetlerinin tespitinde sınıflandırma performansını artırmak için optimize edilmiş bir ağ olarak tasarlanmıştır. Bu CNN yapısı, giriş EEG verilerinden hiyerarşik özellikleri çıkarmak için stratejik olarak tasarlanmış birden fazla katmanı kapsar. Bir giriş katmanı ile başlayan model, sağlam özellik çıkarımı sağlamak için ReLU aktivasyon fonksiyonlarını kullanan üç konvolüsyon katmanı içerir. Her konvolüsyon katmanının ardından, ağın kararlılığını ve verimliliğini artırmak için toplu normalizasyon uygulanır. Bu katmanlardan sonra, önemli paternleri etkili bir şekilde yakalarken hesaplama karmaşıklığı sorununu azaltmak için 2x2 havuzlama boyutlarına sahip maksimum havuzlama işlemleri kullanılır. Son maksimum havuzlama katmanının çıktısı daha sonra, her ikisi de ReLU aktivasyon fonksiyonlarını kullanan 128 ve 64 nöronlu iki tamamen bağlı yoğun katmana aktarılır. Aşırı öğrenmeyi önlemek için ikinci yoğun katmandan sonra bir seyreltme katmanı eklenir. Son katman, nöbet tespiti ile ilgili iki sınıf için olasılık dağılımları üretmek için SoftMax aktivasyon işlevini kullanan iki nöron içeren yoğun bir katmandır. Eğitim süreci Adam optimize ediciyi kullanır ve seyrek

kategorik çapraz entropi seçilen kayıp fonksiyonudur. Model katmanları Tablo 3.3'te belirtilmiştir.

Tablo 3.3. Epilepsi Tespiti İçin Önerilen 2D CNN Modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
2D Konvolüsyon	(28, 28, 32)	224
Küme Normalizasyonu	(28, 28, 32)	128
Maksimum Havuzlama	(14, 14, 32)	0
2D Konvolüsyon	(14, 14, 64)	6208
Küme Normalizasyonu	(14, 14, 64)	256
Maksimum Havuzlama	(7, 7, 64)	0
2D Konvolüsyon	(7, 7, 128)	24704
Küme Normalizasyonu	(7, 7, 128)	512
Maksimum Havuzlama	196	0
Düzleştirme	128	0
Yoğun katman	128	172096
Seyreltme	64	2080
Yoğun katman	64	0
Seyreltme	32	66

3.2.3 Alzheimer Hastalığı ve Parkinson Hastalığı İçin Veri Ön İşleme

EEG verilerinin işlenmesi ve sayısal hesaplamalar için gerekli yazılım kütüphaneleri koda entegre edildi. Verilerin bulunduğu dosya yolları, denek numaralarına göre dinamik olarak oluşturuldu. Veriler bir veri çerçevesine dönüştürülmüş ve her katılımcının kimlik numarası ile grubunu eşleştiren bir sözlük, katılımcıların kimlik numaralarını anahtar olarak gruplarını ise değer olarak tutmaktadır. Her bir EEG verisi dosyası için bir dizi işlem gerçekleştirildi. İlk olarak, EEG verileri 'mne' kütüphanesi (Larson ve ark., 2024) kullanılarak okundu ve belirlenen parametrelerle yüklendi. Ardından, belirli bir süre boyunca sabit uzunlukta sinyaller oluşturuldu ve bu süre 30 saniye olarak ayarlandı. Oluşturulan sinyaller kullanılarak EEG verileri zaman dilimlerine ayrıldı. Bu zaman dilimleri, belirlenen başlangıç ve bitiş zamanlarına göre oluşturuldu. Zaman dilim verileri Numpy dizisine dönüştürüldü. Dosya yolundan denek numarası çıkarıldı ve bu

numara kullanılarak daha önce oluşturulan sözlükten denek grubu bilgisi alındı. Elde edilen zaman dilimleri verileri bir listeye eklenirken, her zaman dilimi için ilgili denek grubu etiketi başka bir listeye eklendi. Tüm zaman dilimleri, maksimum zaman dilimi uzunluğuna göre sıfır dolgu yapılarak aynı boyuta getirildi. Son olarak, tüm zaman dilimleri verileri birleştirilerek tek bir Numpy dizisi oluşturuldu. Bu işlem, tüm zaman dilimleri verilerinin eksen boyunca birleştirilmesiyle gerçekleştirildi. Bu aşamada, tüm zaman dilimleri ve bunlara karşılık gelen etiketler ayrı listelerde toplandı ve ardından Numpy dizisi haline getirildi.

Verilerin okunması, zaman dilimlerine ayrılması, etiketlenmesi ve birleştirilmesi gibi işlemler EEG analizi için gerekli olan temel adımları içermektedir. Bu süreç, AH ve PH'ye dair EEG verilerinin analiz edilmesini ve bu verilerin daha sonra yapılacak analizler için uygun hale getirilmesini sağlamaktadır. EEG verilerinden zaman alanında özellikler çıkarmak için bir dizi işlemi gerçekleştirildi.

İlk olarak, sayısal olmayan etiketleri sayısal değerlere dönüştürmek için kategorik veri etiketlerini tamsayılarla eşleyen bir fonksiyon kullanılır. Özellikle DÖ modellerine kategorik verilerin DÖ algoritmalarına girdi olarak verilebilmesi için önemlidir. Zaman alanı özelliklerinin çıkarılması için bir fonksiyon tanımlandı. Bu fonksiyon, bir zaman dilimleri dizisi alır ve her bir zaman dilimi için ortalama, standart sapma, çarpıklık ve basıklık zaman alanı özelliklerini hesaplar.

Ortalama ($\bar{x}$), bir veri kümesindeki tüm elemanların toplamının, eleman sayısına bölünmesiyle elde edilen değeri ifade eder. Veri kümesinin genel eğilimini ve merkezini belirlemek için kullanılır.

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N x(n) \quad (7)$$

Standart sapma (σ), veri noktalarının ortalama etrafındaki yayılımını ölçer. Standart sapma, veri kümesinin dağılımını ve varyasyonunu anlamada önemli bir istatistiksel ölçüttür.

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2} \quad (8)$$

Çarpıklık (S), bir veri kümesinin simetrik olup olmadığını ve eğer değilse, hangi yöne doğru çarpık olduğunu gösterir. Çarpıklık değeri, veri dağılımının sağa veya sola çarpık olup olmadığını ve bu çarpıklığın derecesini belirler.

$$S = \frac{E(x - \bar{x})^3}{\sigma^3} \quad (9)$$

Basıklık (K), bir veri kümesinin dağılımının sivrililiğini veya yayvanlığını ölçer. Yüksek basıklık, dağılımın keskin bir zirveye sahip olduğunu, düşük basıklık ise dağılımın daha yayvan ve düz olduğunu gösterir.

$$K = \frac{1}{N} \sum_{n=1}^N \frac{(x(n) - \bar{x})^4}{\sigma^4} \quad (10)$$

Hesaplamalar, zaman dilimleri verisinin zaman boyunca değişen özelliklerini temsil eder. Her özellik için bir dizi oluşturur ve bu dizileri birleştirilerek her bir zaman dilimi için bir özellik vektörü fonksiyonu oluşturur. Daha sonra, tüm zaman dilimleri için zaman alanı özellikleri çıkarılır ve bunlar bir listeye eklenir. Son olarak, tüm zaman alanı özellikleri birleştirilerek tek bir Numpy dizisi oluşturuldu. İşlemler, EEG verilerinden çeşitli zaman alanı özelliklerinin çıkarılmasını ve bunların DÖ algoritmaları için uygun bir formatta temsil edilmesini sağladı.

İlk olarak, model eğitimi doğrulama ve değerlendirme için veriler %80 eğitim ve %20 test kümesi olacak şekilde bölündü. Verilerin boyutları CNN modeline uygun hale getirildi. Yeniden boyutlandırma fonksiyonu kullanılarak, verilerin boyutları örnek sayısı, zaman ve kanal şeklinde ayarlandı. CNN modeli, 1D konvolüsyon, Maksimum havuzlama, Düzleştirme, Yoğun katman ve Seyreltme katmanlarını içerir. 1D konvolüsyon katmanları, verinin belirli özelliklerini öğrenmek için konvolüsyon işlemlerini uygular. Maksimum havuzlama katmanları, özellik haritalarını küçültmek ve önemli özellikleri vurgulamak için kullanılır. Düzleştirme katmanı, veriyi düzleştirir ve ardından tam bağlı katmanlarla birleştirir. Seyreltme katmanları, aşırı öğrenmeyi azaltmak için kullanılır. Kayıp fonksiyonu olarak “Kategorik Çapraz Entropi” ve optimize edici olarak “Adam Optimizasyon Algoritması” kullanıldı.

Kategorik çapraz entropi, DÖ modellerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. Genellikle sınıflandırma görevlerinde modelin tahmin ettiği olasılık dağılımı ile gerçek etiketler arasındaki farkı ölçmek için kullanılır. Modelin doğru sınıfları ne kadar iyi tahmin ettiğini değerlendirmede önemli bir rol oynar ve

yanlış etiketlenmiş verilerle eğitim sırasında aşırı uyuma sebep olabilir. Çok sınıflı veri setlerinde, modelin doğru sınıfı ne kadar iyi tahmin ettiğini belirlemede yardımcıdır (Zhang & Sabuncu, 2018). Kategorik çapraz entropi, modelin öğrenme sürecinde önemli bir yere sahiptir ve sınıflandırma doğruluğunu artırmaya katkıda bulunur. Adam (Adaptive Moment Estimation), Diederik P. Kingma ve Jimmy Ba tarafından 2014 yılında geliştirilen bir optimizasyon algoritmasıdır ve DÖ modellerinin eğitimi için yaygın olarak kullanılmaktadır. Her parametre için hem ortalama hem de varyans tahminlerini takip eder ve tahminlere dayanarak öğrenme oranlarını dinamik olarak ayarlar. Bu özellikleri sayesinde Adam diğer optimizasyon algoritmalarına kıyasla daha hızlı ve daha kararlı bir şekilde yakınsama sağlar. Kingma ve Ba'nın çalışmalarında, Adam'ın çeşitli MÖ ve DÖ görevlerinde üstün performans sergilediği ve hiperparametre ayarlarına karşı daha az hassas olduğu belirtilmektedir (Kingma & Ba, 2014).

3.2.4 Alzheimer Hastalığı Tespiti İçin 1D CNN Modelinin Eğitimi

AH tespiti için EEG verilerini kullanarak bir 1D CNN modeli oluşturuldu. Model, EEG sinyallerinden özellik çıkarma ve sınıflandırma yapmak için çeşitli katmanlardan oluşur. İlk katman olan 1D konvolüsyon katmanı, 64 filtre ve çekirdek boyutu ile EEG sinyallerinden özellik çıkarır ve bu katmanda toplam 2,880,256 parametre bulunmaktadır. Bu katmanı takip eden Maksimum havuzlama katmanı, özellik haritalarının boyutunu yarıya indirir. İkinci 1D konvolüsyon katmanı ise 128 filtre ve çekirdek boyutu ile daha derin özellik çıkarımı yapar ve bu katmanda 24,704 parametre bulunmaktadır. Bunu izleyen Maksimum havuzlama katmanı, özellik haritalarının boyutunu tekrar yarıya indirir. Düzleştirme katmanı, havuzlama katmanından elde edilen 2D özellik haritalarını tek boyutlu bir vektöre dönüştürür. Bu vektör, Yoğun katmanda 128 nöron ile işlenir ve bu katmanda 49,280 parametre bulunur. Modelde ayrıca, aşırı öğrenmeyi önlemek amacıyla Seyreltme katmanı da bulunmaktadır. Yoğun katman, SoftMax aktivasyon fonksiyonu kullanarak iki sınıf arasında tahmin yapmak için tasarlandı ve bu katmanda 258 parametre bulunmaktadır. Model katmanları Tablo 3.4'de belirtilmiştir.


Tablo 3.4. Alzheimer Hastalığı Tespiti İçin Önerilen 1D CNN modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
1D Konvolüsyon	(17, 64)	2,880,256
Maksimum Havuzlama	(8, 64)	0
1D Konvolüsyon	(6, 128)	24,704
Maksimum Havuzlama	(3, 128)	0
Düzleştirme	384	0
Yoğun Katman	128	49,280
Seyreltme	128	0
Yoğun Katman	2	258

Model, EEG sinyallerinden özellik çıkarma ve sınıflandırma yapmak için çeşitli katmanlardan oluşur. İlk katman olan 1D konvolüsyon katmanı, 64 filtre ve çekirdek boyutu ile EEG sinyallerinden özellik çıkarır ve bu katmanda toplam 2,880,256 parametre bulunmaktadır. Bu katmanı takip eden Maksimum havuzlama katmanı, özellik haritalarının boyutunu yarıya indirir. İkinci 1D konvolüsyon katmanı ise 128 filtre ve çekirdek boyutu ile daha derin özellik çıkarımı yapar ve bu katmanda 24,704 parametre bulunmaktadır. Bunu izleyen Maksimum havuzlama katmanı, özellik haritalarının boyutunu tekrar yarıya indirir. Düzleştirme katmanı, havuzlama katmanından elde edilen 2D özellik haritalarını tek boyutlu bir vektöre dönüştürür. Bu vektör, Yoğun katmanda 128 nöron ile işlenir ve bu katmanda 49,280 parametre bulunur. Modelde ayrıca, aşırı öğrenmeyi önlemek amacıyla Seyreltme katmanı da bulunmaktadır. Son olarak, Yoğun katman, SoftMax aktivasyon fonksiyonu kullanarak iki sınıf arasında tahmin yapmak için tasarlandı ve bu katmanda 258 parametre bulunmaktadır. Model toplamda 8,863,496 parametreye sahiptir, bu da yaklaşık olarak 33.81 megabayt (MB) bellek alanına eşdeğerdir. Eğitilebilir parametrelerin sayısı ise 2,954,498'dir ve bu da 11.27 MB'lık bir bellek alanını kullanır. Modelin eğitilmeyen parametrelerinin sayısı ise 0'dır ve dolayısıyla bellek alanı kullanımı yoktur. Optimizasyon parametreleri, toplam parametrelerin eğitilebilir olanlarının dışındaki kısımdır ve 5,908,998 parametreye sahiptir, bu da yaklaşık olarak 22.54 MB'lık bir bellek alanını işgal eder.

3.2.5 Alzheimer Hastalığı İçin 2D CNN Modelinin Eğitimi

EEG verilerini spektrogramlara dönüştürmek için bir işlev tanımlanır ve bu işlevi kullanarak tüm veri kümesi için spektrogramlar oluşturulur. Bu işlev, her bir zaman dilimi ve her bir kanal için spektrogramlar oluşturmak amacıyla iç içe iki döngü kullanır. Sinyalin frekans ve zaman boyunca nasıl dağıldığını görselleştirmek için bu yöntem tercih edilir. İşlev, her bir zaman dilimi için bir dizi spektrogram oluşturur ve bunları bir listeye ekler. Sonuçlar Numpy dizisi haline getirilir ve dışarıya döndürülür. Spektrogramlar, EEG verilerinin farklı frekans bileşenlerini görselleştirmek ve analiz etmek için kullanılır. Örnek sinyal ve spectrogram şekil 3.6’da gösterilmektedir.



Şekil 3.6. Alzheimer hastalığı veri kümesi EEG sinyali ve STFT uygulanmış spektrogram görüntüsü

Alzheimer CNN modeli TensorFlow (Abadi ve ark., 2016) kullanarak spektrogramlardan elde edilen verileri kullanarak bir CNN modeli oluşturuldu, eğitildi ve değerlendirildi. İlk olarak, veri kümesi eğitim ve test setlerine bölündü. Daha sonra, spektrogramlar normalize edildi. Model, iki 2D konvolüsyon katmanı ve iki Maksimum Havuzlama katmanı ile birlikte düzleştirme ve tam bağlı katmanlar içerir. Modelin çıkış katmanı, SoftMax aktivasyon fonksiyonu ile sınıfı tahmin etmek için tasarlandı.

Model derlendi ve eğitildi. Eğitim sırasında, doğrulama verisi kullanılarak modelin performansı izlendi. Modelin performansı, test seti üzerinde değerlendirilerek hesaplandı. Tahminler, sınıf etiketlerine dönüştürüldü ve sınıflandırma raporu oluşturuldu. Model katmanları Tablo 3.5'te belirtilmiştir.

Tablo 3.5. Alzheimer Hastalığı Tespiti İçin Önerilen 2D CNN modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
2D konvolüsyon	(17, 127, 32)	19,040
Maksimum Havuzlama	(8, 63, 32)	0
2D konvolüsyon	(6, 61, 64)	18,496
Maksimum Havuzlama	(3, 30, 64)	0
Düzleştirme	5760	0
Yoğun Katman	128	737,408
Yoğun Katman	2	387

Model toplamda 2,325,995 parametreye sahiptir, bu da yaklaşık olarak 8.87 megabayt (MB) bellek alanına eşdeğerdir. Eğitilebilir parametrelerin sayısı ise 775,331'dir ve bu da 2.96 MB'lık bir bellek alanını kullanır. Modelin eğitilmeyen parametrelerinin sayısı ise 0'dır ve dolayısıyla bellek alanı kullanımı yoktur. Optimizasyon parametreleri, toplam parametrelerin eğitilebilir olanlarının dışındaki kısmıdır ve 1,550,664 parametreye sahiptir, bu da yaklaşık olarak 5.92 MB'lık bir bellek alanını işgal eder.

3.2.6 Parkinson Hastalığı için 1D CNN modelinin eğitimi

PH için önerilen model, EEG sinyallerinden özellik çıkarma ve sınıflandırma yapmak için çeşitli katmanlardan oluşur. İlk katman olan 1D konvolüsyon katmanı, 64 filtre ve çekirdek boyutu ile EEG sinyallerinden özellik çıkarır ve bu katmanda toplam 2,880,256 parametre bulunmaktadır. Bu katmanı takip eden Maksimum havuzlama katmanı, özellik haritalarının boyutunu yarıya indirir. İkinci 1D konvolüsyon katmanı ise 128 filtre ve çekirdek boyutu ile daha derin özellik çıkarımı yapar ve bu katmanda 24,704 parametre bulunmaktadır. Bunu izleyen Maksimum havuzlama katmanı, özellik haritalarının boyutunu tekrar yarıya indirir. Düzleştirme katmanı, havuzlama katmanından elde edilen 2D özellik haritalarını tek boyutlu bir vektöre dönüştürür. Bu vektör, Yoğun katmanda 128 nöron ile işlenir ve bu katmanda 49,280 parametre bulunur. Modelde ayrıca, aşırı

öğrenmeyi önlemek amacıyla Seyreltme katmanını da bulunmaktadır. Yoğun katman, SoftMax aktivasyon fonksiyonu kullanarak iki sınıf arasında tahmin yapmak için tasarlandı ve bu katmanda 258 parametre bulunmaktadır. Model katmanları Tablo 3.6'da belirtilmiştir.

Tablo 3.6. Parkinson Hastalığı için 1D CNN modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
1D konvolüsyon	(64, 64)	2,880,256
Maksimum havuzlama	(32, 64)	0
1D konvolüsyon	(30, 128)	24,704
Maksimum havuzlama	(15, 128)	0
Düzleştirme	1920	0
Yoğun Katman	128	49,280
Seyreltme	128	0
Yoğun Katman	2	258

Model toplamda 9,453,320 parametreye sahiptir, bu da yaklaşık olarak 36.06 megabayt (MB) bellek alanına eşdeğerdir. Eğitilebilir parametrelerin sayısı ise 3,151,106'dır ve bu da 12.02 MB'lık bir bellek alanını kullanır. Modelin eğitilmeyen parametrelerinin sayısı ise 0'dır ve dolayısıyla bellek alanı kullanımı yoktur. Optimizasyon parametreleri, toplam parametrelerin eğitilebilir olanlarının dışındaki kısımdır ve 6,302,214 parametreye sahiptir, bu da yaklaşık olarak 24.04 MB'lık bir bellek alanını işgal eder.

3.2.7 Parkinson Hastalığı için 2D CNN modelinin eğitimi

PH EEG verilerini spektrogramlara dönüştürmek için bir işlev tanımlandı ve bu işlevi kullanarak tüm veri kümesi için spektrogramlar oluşturuldu. Bu işlev, her bir zaman dilimi ve her bir kanal için spektrogramlar oluşturmak amacıyla iç içe iki döngü kullanır. Sinyalin frekans ve zaman boyunca nasıl dağıldığını görselleştirmek için bu yöntem tercih edildi. İşlev, her bir zaman dilimi için bir dizi spektrogram oluşturur ve bunları bir listeye ekler. Sonuçlar Numpy dizisi haline getirilir ve dışarıya döndürülür. Spektrogramlar, EEG verilerinin farklı frekans bileşenlerini görselleştirmek ve analiz etmek için kullanılır.


PH'na özgü spektrogramlardan elde edilen verileri kullanarak bir CNN modeli oluşturuldu, eğitildi ve değerlendirildi. İlk olarak, veri kümesi eğitim ve test

setlerine bölündü. Daha sonra, spektrogramlar normalize edildi. Model, iki 2D konvolüsyon katmanı ve iki Maksimum Havuzlama katmanı ile birlikte düzleştirme ve tam bağlı katmanlar içerir. Modelin çıkış katmanı, SoftMax aktivasyon fonksiyonu ile sınıfı tahmin etmek için tasarlandı. Model derlendi ve eğitildi. Eğitim sırasında, doğrulama verisi kullanılarak modelin performansı izlendi. Modelin performansı, test seti üzerinde değerlendirilerek hesaplandı. Tahminler, sınıf etiketlerine dönüştürüldü ve sınıflandırma raporu oluşturuldu. Model katmanları Tablo 3.7’de belirtilmiştir.

Tablo 3.7. Parkinson Hastalığı için 2D CNN modeli

Model Katmanları	Çıkış Çerçevesi	Parametreler
2D konvolüsyon	(64, 127, 32)	19,040
Maksimum Havuzlama	(32, 63, 32)	0
2D konvolüsyon	(30, 61, 64)	18,496
Maksimum Havuzlama	(15, 30, 64)	0
Düzleştirme	28800	0
Yoğun Katman	128	3,686,528
Yoğun Katman	2	258

Model toplamda 11,172,968 parametreye sahiptir, bu da yaklaşık olarak 42.62 MB bellek alanına eşdeğerdir. Eğitilebilir parametrelerin sayısı ise 3,724,322'dir ve bu da 14.21 MB'lık bir bellek alanını kullanır. Modelin eğitilmeyen parametrelerinin sayısı ise 0'dır. Optimizasyon parametreleri, toplam parametrelerin eğitilebilir olanlarının dışındaki kısımdır ve 7,448,646 parametreye sahiptir, bu da yaklaşık olarak 28.41 MB'lık bir bellek alanını işgal eder. Şekil 3.7 PH veri kümesi EEG sinyali ve STFT uygulanmış sinyal görüntüsü sunmaktadır.



Şekil 3.7. Parkinson hastalığı veri kümesi EEG sinyali ve STFT uygulanmış sinyal görüntüsü

3.3 Performans Parametreleri

Başarılı bir DÖ modeli çok katmanlı özellik çıkarımı yoluyla yüksek derecede sınıflandırılabilir özellikler üretir. Bu çalışmada bir modelin performansını değerlendirmek için çeşitli ölçütler kullanıldı. Bir modelin değerlendirilmesi, uygulanabilir DÖ modeli geliştirmek için kritiktir (Lima ve ark., 2022). Farklı algoritmalar için birçok değerlendirme metriği bulunsun da tek bir en iyi metrik bulunmamakta, genellikle hangi metriğin kullanılacağı sorunun doğasına bağlıdır. Genel olarak, değerlendirme metrikleri, yanlış sınıflandırılmış girişlerin doğru sınıflandırılmış girişlere göre değerlendirilmesine dayanır. Metrikler arasında değerlendirme şekillerinde farklılıklar bulunur. "Doğru Pozitifler" (TP) doğru bir şekilde pozitif olarak sınıflandırılan örnekleri, "Doğru Negatifler" (TN) doğru bir şekilde negatif olarak sınıflandırılan örnekleri, "Yanlış Pozitifler" (FP) negatif sınıfa yanlış bir şekilde pozitif olarak sınıflandırılan örnekleri ve "Yanlış Negatifler" (FN) pozitif sınıfa yanlış bir şekilde negatif olarak sınıflandırılan örnekleri temsil eder.

3.3.1 Doğruluk

Doğruluk metriği, doğru bir şekilde tanımlanan örneklerin yüzdesini ölçer.

$$\text{Doğruluk} = \frac{TP + TN}{FP + FN + TP + TN} \quad (11)$$

3.3.2 Duyarlılık

Duyarlılık, bir sınıflandırma modelinin pozitif örnekleri doğru bir şekilde sınıflandırma yeteneğini ölçer.

$$\text{Duyarlılık} = \frac{TP}{FN + TP} \quad (12)$$

3.3.3 Özgüllük

Özgüllük, bir sınıflandırma modelinin negatif örnekleri doğru bir şekilde sınıflandırma yeteneğini ölçer.

$$\text{Özgüllük} = \frac{TN}{FP + TN} \quad (13)$$

3.3.4 Hassasiyet

Hassasiyet, bir sınıflandırma modelinin pozitif olarak sınıflandırılan örneklerin ne kadarının gerçekten pozitif olduğunu ölçer.

$$\text{Hassasiyet} = \frac{TP}{FP + TP} \quad (14)$$

3.3.5 F1 Skoru

F1 skoru, hassasiyet ve özgüllük arasındaki dengeyi ölçer. Yüksek bir F1 skoru, her iki metriğin de iyi bir dengesini yansıtır.

$$\text{F1 Skoru} = \frac{2TP}{2TP + FP + FN} \quad (15)$$

4. BULGULAR

Bu tez çalışmasında, nörolojik hastalıkların sınıflandırılması amacıyla CNN tabanlı sistemler geliştirilmiştir. Bu sistemlerin geliştirilmesi sırasında 1D EEG sinyalleri ve bu sinyallerden üretilmiş 2D 59egative59am veri kümelerinden yararlanılmıştır. Algoritmalar, Python 3.11.7, Jupyter Notebook v7.2 ve TensorFlow v2.16.1 versiyonları kullanılarak uygulanmıştır. Veri ön işleme işlemleri, 16 GB bellek, Ryzen 5 5600 işlemci ve AMD RX 6650XT grafik kartına sahip yerel bir sistemde gerçekleştirilmiştir. Model eğitim işlemleri ise Google Cloud ve Kaggle platformları kullanılarak yapılmıştır.


Epilepsi nöbeti tespitinde CNN'lerin performansı araştırıldığında 1D CNN, olağanüstü bir performans sergiledi. Nöbetsiz örnekleri doğru bir şekilde tanımlama becerisini gösteren %99.2 özgüllük elde etti. Genel test doğruluğu %98.9'a ulaşarak modelin sağlamlığını vurguladı. Ayrıca, %98.9 duyarlılık, modelin nöbet olaylarını doğru bir şekilde tespit etmedeki etkinliğini vurgulamaktadır. Hesaplanan F1 skoru %99.0 olup, 1D CNN'in yüksek performansını doğrulamaktadır. Veri kümesi 2D formatına dönüştürüldüğünde CNN'in doğruluğu %98.5'e bir düşüş yaşadı. Duyarlılığın %98.6 gibi yüksek bir değerde kalması, modelin nöbetlerin gerçek pozitif örneklerini yakalama konusundaki sürekli etkinliğini göstermektedir. %98.4 özgüllük, modelin nöbetsiz örnekleri doğru bir şekilde sınıflandırma yeteneğini vurgulamaktadır. Doğrulukta 2D CNN %98.4 F1 skoru elde etti.

Alzheimer hastalığının tespitinde, 1D EEG sinyallerine dayalı modelin doğruluğu %72.5, duyarlılığı %69.4, özgüllüğü %75.6 ve F1 skoru %71.8 olarak elde edildi. 2D EEG sinyallerine dayalı modelin doğruluğu %82.6, duyarlılığı %76.9, özgüllüğü %87.1 ve F1 skoru %79.5 olarak bulundu.


Parkinson hastalığının tespitinde ise, 1D EEG sinyallerine dayalı modelin doğruluğu %74.3, duyarlılığı %69.2, özgüllüğü %78.7 ve F1 skoru %71.4 olarak belirlendi. 2D EEG sinyallerine dayalı modelin doğruluğu ise %81.2, duyarlılığı %83.6, özgüllüğü %79.2 ve F1 skoru %79.9 olarak tespit edildi.

Şekil 4.1'e göre 59egative sınıflandırması için her iki model de yüksek performans gösterdiği, AH ve PH sınıflandırmalarında 2D CNN modelleri 1D modellerine göre daha iyi sonuçlar verdiği görülmektedir. Genel olarak, 2D CNN


modelleri daha doğru sonuçlar üretme eğilimindedir, özellikle yanlış 60negative ve yanlış pozitif oranlarını düşürmede daha başarılıdır.




Şekil 4.1. Oluşturulan modellerin karmaşıklık matris değerleri



Şekil 4.2. Epilepsi tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri




Şekil 4.3. Epilepsi tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri




Şekil 4.4. AH tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri


Şekil 4.2. ve Şekil 4.3.’ten görülebileceği üzere 1D CNN modelinin epilepsi tespiti için 2D CNN modeline göre daha iyi performans gösterdiği görülmektedir. 1D CNN modelinin hem eğitim hem de doğrulama setlerinde daha yüksek doğruluk ve daha düşük kayıp değerlerine sahip olduğu görülmektedir.



Şekil 4.5. AH tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri



Şekil 4.6. PH tespiti için 1D CNN modeli doğruluk ve kayıp grafikleri



Şekil 4.7. PH tespiti için 2D CNN modeli doğruluk ve kayıp grafikleri

Şekil 4.4, Şekil 4.5, Şekil 4.6 ve Şekil 4.7'de görülebileceği gibi, AH ve PH için 2D CNN modelleri, 1D CNN modellerine göre eğitim setlerinde daha yüksek doğruluk değerlerine sahiptir. Doğrulama setlerindeki doğruluk değerleri ise her iki model için de benzerdir. Ayrıca, 2D CNN modelinin kayıp değeri 1D CNN modeline göre daha düşüktür.

5. TARTIŞMA

EEG'nin maliyet etkinliği, erişilebilirliği ve gerçek zamanlı beyin aktivitesi izleme yeteneği, geniş tarama ve teşhis için uygun kılar. Büyük hacimli EEG verilerinin model tarafından işlenmeleri zor olabilir. EEG sinyali doğal gürültü ve artefaktlara oldukça hassastır (Luján ve ark., 2021). Görüntüleme araçlarının maliyeti ve zaman alıcı olması, genellikle hastaların nörodejenerasyon belirtileri gösterdikten sonra teşhis edilmelerine yol açabilir. Nörolojik hastalıkları doğru sınıflandırmak, yüksek risk altındaki bireylerin tedavi planlamasını desteklemek açısından önemlidir (Miltiadous, Gionanidis, ve ark., 2023)

DÖ, EEG verilerindeki hastalık belirtilerini etkili bir şekilde tespit edebilir. Nörolojik hastalıkların şiddeti EEG sinyal performansını etkileyebilir. Sinyal işleme ve özellik çıkarma yöntemlerinin daha genişletilebileceği göz önünde bulundurulmalıdır. Hastalığın nedeni belirli beyin bölgelerinden kaynaklanabileceği ve her EEG kanalının sinyaller üzerinde farklı etkilere sahip olabileceği için birden fazla veri kümesiyle çalışmak veya EEG topografik haritası (Zheng ve ark., 2020) ve kısmi beyin ağları (Schöll, 2021) gibi tekniklerin daha ayrıntılı olarak incelenmesi faydalı olabilir. Literatürde araştırmacılar EEG kayıtlarından Bağlılık, dalgacık analizi ve Hjorth parametreler gibi çeşitli istatistiksel özellikler hesaplayarak sınıflandırma modellerini eğitmek için kullanmışlardır (Zheng ve ark., 2023). Ayrıca, bazı çalışmalarda temel EEG ritimleri daha da ayrıntılı olarak incelenmiştir (Nishida ve ark., 2011, Caso ve ark., 2012). Gelecekteki çalışmalarda EEG ritimlerinin daha fazla ayrıştırılması, frekans alanı metriklerinin ve entropilerin kullanımının, EEG analizlerinin doğruluğunu artırmak için önemli olabileceği düşünülmektedir. Bu tür yöntemler nörolojik hastalıkların daha hassas ve ayrıntılı bir şekilde incelenmesini sağlayabilir.

Tez çalışmamızda elde edilen bulgular, literatürdeki diğer çalışmalarla karşılaştırıldığında benzerlikler göstermektedir. Özellikle AH, PH ve Epilepsi gibi nörolojik rahatsızlıkların tespiti ve sınıflandırmasında kullanılan derin öğrenme modellerinin performansları üzerine önemli çıkarımlar yapılabilir. Duan ve ark. (2020) tarafından yapılan çalışmada, EEG sinyallerinden spektral güç bilgisini çıkarmak için Hızlı Fourier Dönüşümü algoritması kullanılmış ve bu bilgiyle eğitilen CNN modeli %79 doğruluk elde etmiştir. Tez çalışmamızda ise Alzheimer

hastalığı için 1D EEG sinyalleri kullanarak %72,5 doğruluk elde ettik. Bu fark, kullanılan veri işleme ve model yapılandırmalarındaki farklılıklardan kaynaklanabilir. Bununla birlikte, 2D EEG verisi kullanarak %82,6 doğruluğa ulaştık ve bu oran Amini ve ark. (2018) tarafından zaman ve frekans alanı bilgilerini kullanan CNN modeliyle elde edilen %82,30 doğrulukla tutarlıdır. Epilepsi tespiti konusunda çalışmamızda elde edilen doğruluk oranları oldukça yüksektir. 1D EEG sinyalleri ile %98,9 ve 2D EEG sinyalleri ile %98,5 doğruluk elde edilmiştir. Bu sonuçlar, modelimizin epilepsi tespiti için oldukça güvenilir olduğunu göstermektedir.

AH tahmininde yalnızca tek bir bilgi kaynağına dayanmak klinik değerlendirmeler için yeterli güvenilirlik sunmayabilir. Bu nedenle, Chen ve ark. (2022) ile Sharma ve ark. (2022) gibi araştırmacılar, tahmin doğruluğunu artırmak için giderek daha fazla çok modlu birleşim stratejilerine yönelmişlerdir. Benzer şekilde, Ullah ve ark. (2018), EEG sinyallerinden zaman-frekans özelliklerini ve AH lezyonları ile ilişkili PET görüntü özelliklerini birleştiren iki modlu bir AH tahmin modeli sunmuştur. EEG sinyalleri, zaman-frekans özellik çıkarımı için dalgacık Fourier dönüşümüne tabi tutulurken, PET özellikleri boyut azaltma işlemi ile elde etmişlerdir. Bu iki modlu özellikler kullanılarak geliştirilmiş bir CNN modeli yinelemeli olarak eğitilmiş ve test setinde %77,10 doğruluk elde etmişlerdir. Chen ve ark. (2023) tarafından önerilen hibrit mimari, EEG sinyallerinden doku özellikleri ve küresel anlamsal bilgileri elde eden Çift Dallı Özellik Füzyon Ağı olarak adlandırılmıştır. Mekansal Dikkat ve Kanal Dikkat blokları ile modelin anormal EEG sinyal desenlerini ayırt etme kapasitesi artırılarak üçlü sınıflandırmada %80,23 doğruluk elde edilmiştir (Chen ve ark., 2023). Nedeljković ve arkadaşları (2023), EEG sinyalleri üzerinde bilgi kazancı özellik seçimi tekniği kullanılarak özellik sayısı düşürülmüş ve bu sayede model yorumlanabilirliği artırılmıştır. Rastgele orman sınıflandırıcı ile %77,6 doğruluk oranı elde edilmiştir (Nedeljković ve ark., 2023). Parihar ve Swami (2024) araştırmalarında birden fazla demans sınıfının sınıflandırmasına odaklanmıştır. En iyi sınıflandırma sonucu, rastgele orman sınıflayıcı ve tek bir katılımcıyı dışarda bırakan çapraz doğrulama yöntemi kullanılarak elde edilmiştir. Üç yönlü sınıflandırma %75,29'lık en iyi doğruluk oranına ulaşırken, ikili sınıflandırmalar (AH-SB, AH-FTD ve SB-FTD) sırasıyla %88,90, %88,44 ve %84,10'luk doğruluk oranlarına ulaşmıştır (Parihar & Swami, 2024). PH tespitinde ise çalışmamızda elde edilen sonuçlar literatürdeki

diğer çalışmalara kıyasla benzerdir. 1D EEG sinyalleri ile %74,3 doğruluk ve 2D spektrogramları ile %81,2 doğruluk elde edilmiştir. Bu sonuçlar, tez çalışmamızda kullanılan derin öğrenme modellerinin PH tespiti için de etkili olduğunu göstermektedir. Çalışmamızda elde edilen bulgular, literatürdeki diğer çalışmalara karşılaştırıldığında derin öğrenme modellerinin EEG verileri kullanarak nörolojik hastalıkların tespitinde oldukça başarılı olduğunu göstermektedir. Özellikle Epilepsi tespitinde elde edilen yüksek doğruluk oranları, bu alanda yapılan diğer çalışmalardan üstündür. AH ve PH tespitinde ise sonuçlarımız, literatürdeki diğer çalışmalarla tutarlılık göstermekte ve bu hastalıkların tespitinde de etkili modeller geliştirdiğimizi ortaya koymaktadır.

Tablo 5.1. Literatürde yapılan diğer çalışmalar

Yazarlar ve Yıl	Kullanılan Teknikler	Sınıflandırma Başarısı
Abdelhameed & Bayoumi, 2021	2D CNN	%98,79 doğruluk, %98,72 hassasiyet, %98,86 özgüllük
Abiyev ve ark., 2020	1D CNN	%98,67 doğruluk, %97,67 duyarlılık, %98,83 özgüllük
Amini ve ark., 2018	1D CNN	%82,30 doğruluk
Asgharzadeh-Bonab ve ark., 2023	1D CNN	SB-HBB: %82,7, SB-AH: %89,7, HBB-AH: %84,3
Bahr ve ark., 2021	1D CNN	%90 duyarlılık, %99 özgüllük, %85 duyarlılık
Cimr ve ark., 2023	1D CNN	Bonn EEG: %98 doğruluk, CHB-MIT EEG: %96,99 doğruluk
Duan ve ark., 2020	1D CNN	%79 doğruluk
Ein Shoka ve ark., 2023	Şifrelenmiş spektrogram ve CNN	%84,72-%86,11 doğruluk
Jibon ve ark., 2023	DenseNet-CNN	%98 doğruluk, %98,60 özgüllük
Lee ve ark., 2021	1D CNN	%99,2 doğruluk, %98,9 hassasiyet
Lian ve ark., 2020	2D CNN	%99,3 doğruluk, %99,5 hassasiyet, %99,6 özgüllük
Miltiadous ve ark., 2023	Çift Girişli Evrişimli Kodlayıcı Ağı	%83,28 doğruluk
Narin, 2022	2D CNN	%92,27 doğruluk
Prasanth ve ark., 2020	1D CNN	%79 doğruluk, %90 hassasiyet

Raghu ve ark., 2020	CNN ve transfer öğrenme	%82,85 doğruluk
Sameer & Gupta, 2022	1D CNN	%99,83 doğruluk
Ullah ve ark., 2018	2D CNN	%77,10 doğruluk
Wang ve ark., 2021	Genişletilmiş CNN	%80,5 doğruluk, %85,8 hassasiyet, %75,1 özgüllük
Xu ve ark., 2020	1D CNN	İki sınıf: %99,39, Beş sınıf: %82,00
Yıldırım ve ark., 2020	1D CNN	%79,34 doğruluk, %79,64 hassasiyet
Zhang ve ark., 2020	Ortak uzamsal desen ve CNN	%92,2 duyarlılık
Zhao ve ark., 2020	1D CNN	İki sınıf: %99,52, Üç sınıf: %98,06, Beş sınıf: %93,55

Tablo 5.2. Tez çalışması bulgularımız

Hastalık	Bilgi Formatı	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1 Skoru (%)
Alzheimer	1D	72,5	69,4	75,6	71,8
Alzheimer	2D	82,6	76,9	87,1	79,5
Epilepsi	1D	98,9	98,9	99,2	99
Epilepsi	2D	98,5	98,6	98,4	98,4
Parkinson	1D	74,3	69,2	87,1	79,5
Parkinson	2D	81,2	83,6	79,2	79,9

Bu çalışmada, insan beyninin EEG sinyali frekans dalgaları incelenmiş ve EEG sınıflandırması için yaygın olarak kullanılan DÖ mimarileri tanımlanmıştır. DÖ'nün EEG verilerinin işlenmesindeki avantajları vurgulanmış, ön işleme, özellik çıkarma ve sınıflandırma adımları detaylı olarak ele alınmıştır. Kullanılan veri setleri 1D formatındayken daha sonra 2D'ye dönüştürülmüş ve modelin etkinliği özgüllük, doğruluk, duyarlılık ve F1 skoru gibi temel ölçütlere göre değerlendirilmiştir. STFT'nin düşük zaman-frekans çözünürlüğü nedeniyle spektrogramdaki bazı zaman-frekans bilgilerini yakalayamadığı, ancak artan hesaplama maliyeti ve veri ön işleme ihtiyacı gibi dezavantajları olduğu belirtilmiştir. 1D sinyallerden 2D CNN'ler kullanılarak oluşturulan spektrogram görselleri, çözünürlük sorunlarına yol açarak analizlerin doğruluğunu ve model performansını etkileyebilir. Bu çalışma, DÖ tekniklerinin nörolojik hastalık tanısında önemli bir potansiyele sahip olduğunu vurgulamaktadır. DÖ algoritmalarının tanısal doğruluğunu artırabileceğini göstermektedir. Veri toplama ve ön işleme standartlarının belirlenmesi veri dengesizliğinin ele alınması ve model

şeffaflığının sağlanması gibi zorluklar bulunmaktadır. Gelecekteki araştırmaların daha geniş ve çeşitli veri kümelerine odaklanması gerekmektedir. DÖ tabanlı araçların klinik uygulamaya entegrasyonu nörolojik hastalıkların tanısı ve yönetiminde önemli bir gelişme sağlayabilir.



6. SONUÇ VE ÖNERİLER

Son dönemde EEG teknolojisinde önemli ilerlemeler kaydedilmiştir. Bu ilerlemelerin, genel olarak teknoloji alanındaki yenilikler ve gelişmeler EEG sinyal işleme teknolojisindeki gelişmeleri desteklemektedir. Nörolojik hastalıkların tanı veya değerlendirmesi için evrensel olarak kabul edilmiş ve klinik olarak doğrulanmış tek bir standart yaklaşımın olmadığını belirtmek önemlidir. Bu durum, daha güvenilir ve doğru araçlar geliştirmek için daha fazla araştırmaya ihtiyaç duyulduğunu vurgular.

CNN'ler, EEG verilerinden otomatik olarak faydalı özellikleri çıkarabilir ve bu sayede daha kapsamlı bir analiz sağlayabilir. Hem 1D hem de 2D CNN'ler, paralel işleme yetenekleri sayesinde büyük veri setlerini hızlı bir şekilde işleyebilir. Gerçek zamanlı veya hızlı sonuçlar gerektiren durumlarda faydalı olabilir. CNN'ler, özellik haritaları aracılığıyla nörolojik aktiviteyi görselleştirmeye yardımcı olabilir. Bu da uzmanların EEG verilerini daha kolay yorumlamasına ve nörolojik hastalıkların teşhisinde daha doğru kararlar vermesine yardımcı olabilir.

Bu çalışmada, epilepsi, AH ve PH EEG verilerini sınıflandırmak için çeşitli DÖ modelleri kullanıldı. DÖ tabanlı algoritmaların EEG sınıflandırması için kullanımı hakkında bilgi verildi ve aynı zamanda EEG sinyalini sınıflandırmak için DÖ yaklaşımlarına da değinildi. Sonuçlarımız, EEG sinyalleri üzerinde yapılan analizlerin nörolojik hastalıkların teşhisindeki etkinliğini değerlendirmek için önemli bulgular ortaya koymaktadır. Epilepsi nöbeti tespitinde 1D CNN modelinin %99,6 özgüllük ve %99,1 doğruluk elde etmesi, bu yöntemin epilepsi teşhisinde yüksek güvenilirlik sağladığını göstermektedir. Ancak, 2D CNN modeliyle yapılan uygulamada doğruluk %98,7 bulunarak hafif bir düşüş gözlemlenmiştir, bu da 2D görselleştirmenin bazı bilgi kaybına yol açabileceğini işaret etmektedir. AH teşhisinde ise, 2D EEG sinyallerine dayalı modelin %81,95 doğruluk, %87,58 duyarlılık, %77,55 özgüllük ve %80,97 F1 skoru göstermesi, 1D modele kıyasla üstün bir performans sergilediğini ortaya koymaktadır. Bu sonuçlar, 2D görselleştirmenin AH'nın EEG tabanlı teşhisinde daha avantajlı olduğunu göstermektedir. PH teşhisi için ise, 2D EEG sinyallerine dayalı modelin %76,22 doğruluk, %83,28 duyarlılık, %67,35 özgüllük ve %76,35 F1 skoru ile 1D modelden daha üstün bir performans sergilediği görülmektedir. Bu bulgular,

Parkinson hastalığının EEG analizinde 2D görselleştirmenin daha detaylı bir teşhis sağlayabileceğini işaret etmektedir.

Bu çalışmanın sonuçları, EEG sinyallerinin nörolojik hastalıkların erken teşhisinde önemli bir rol oynayabileceğini ve farklı modelleme yöntemlerinin bu teşhiste farklı avantajlar sunduğunu göstermektedir. Ancak, her bir modelin kullanımında dikkat edilmesi gereken spesifik avantajlar ve dezavantajlar bulunmaktadır. Bu nedenle, uygulama senaryosuna ve kullanılacak veri setinin özelliklerine bağlı olarak en uygun modelin seçilmesi kritik öneme sahiptir. CNN mimarisi hesaplama açısından pahalıdır ve büyük miktarda veri ve bilgi işlem kaynağı gerektirir. Karmaşık yapısı nedeniyle CNN'ler aşırı öğrenmeye eğilimlidir. Ancak, seyreltme ve ağırlık dengelemeleri gibi düzenleme teknikleri bu sorunu hafifletebilir.

Gelecekte yapılacak çalışmalar, bu bulguları daha geniş hasta grupları ve farklı EEG işleme teknikleriyle doğrulayarak nörolojik hastalık tespitinde EEG tabanlı yaklaşımların etkinliğini daha da artırabilir. Gerçek hayattaki nörolojik hastalık verilerini toplamak, bu bozuklukların doğası gereği zor bir görevdir. Genel olarak, gelecek araştırmaların DÖ algoritmalarının dayanıklılığını, yorumlanabilirliğini ve çok yönlülüğünü geliştirmeye odaklanabileceği öngörülmektedir.

7. KAYNAKLAR

Bu tez çalışmasında APA atıf sistemi kullanılmıştır.

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M. & others (2016). TensorFlow: A System for Large-Scale Machine Learning. OSDI (pp. 265-283).
- Abdallah, T., Jrad, N., Abdallah, F., Humeau-Heurtier, A., & Van Bogaert, P. (2023). A self-attention model for cross-subject seizure detection. *Computers in Biology and Medicine*, 165. <https://doi.org/10.1016/j.combiomed.2023.1074270>
- Abdelhameed, A., & Bayoumi, M. (2021). A Deep Learning Approach for Automatic Seizure Detection in Children with Epilepsy. *Frontiers in Computational Neuroscience*, 15. <https://doi.org/10.3389/fncom.2021.650050>
- Abdulbaqi, A. S., Younis, M. T., Younus, Y. T., & Obaid, A. J. (2022). A hybrid technique for eeg signals evaluation and classification as a step towards to neurological and cerebral disorders diagnosis. *International Journal of Nonlinear Analysis and Applications*, 13(1), 773–781. <https://doi.org/10.22075/IJNAA.2022.5590>
- Abiyev, R., Arslan, M., Idoko, J. B., Sekeroglu, B., & Ilhan, A. (2020). Identification of epileptic eeg signals using convolutional neural networks. *Applied Sciences (Switzerland)*, 10(12). <https://doi.org/10.3390/APP10124089>
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*, 1-322.
- Alaskar, H. (2018). Convolutional Neural Network Application in Biomedical Signals. *JOURNAL OF COMPUTER SCIENCE AND INFORMATION TECHNOLOGY*, 6(2). <https://doi.org/10.15640/jcsit.v6n2a5>
- Amini, M., Pedram, M. M., Moradi, A., Ouchani, M., et al. (2018). Diagnosis of Alzheimer's disease by time-dependent power spectrum descriptors and convolutional neural network using EEG signal. *Comput. Math. Methods Med.* 107, 61–71.
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: dependence on recording region and brain state. *Physical review. E, Statistical, nonlinear, and soft matter physics*, 64, 061907. <https://doi.org/10.1103/PhysRevE.64.061907>
- Anjum, M. F., Espinoza, A. I., Cole, R. C., Singh, A., May, P., Uc, E. Y., Dasgupta, S., & Narayanan, N. S. (2024). Resting-state EEG measures cognitive impairment in Parkinson's disease. *Npj Parkinson's Disease*, 10, 6. <https://doi.org/10.1038/s41531-023-00602-0>
- Asgharzadeh-Bonab, A., Kalbkhani, H., & Azarfardian, S. (2023). An Alzheimer's disease classification method using fusion of features from brain Magnetic Resonance Image transforms and deep convolutional networks. *Healthcare Analytics*, 4. <https://doi.org/10.1016/j.health.2023.100223>
- Awuah, W. A., Adebuseye, F. T., Wellington, J., David, L., Salam, A., Weng Yee, A. L., Lansiaux, E., Yarlagadda, R., Garg, T., Abdul-Rahman, T., Kalmanovich, J., Miteu, G. D., Kundu, M., & Mykolaivna, N. I. (2024). Recent Outcomes and Challenges of Artificial Intelligence, Machine Learning, and Deep Learning in Neurosurgery. *World Neurosurgery: X*, 23, 100301. <https://doi.org/10.1016/j.wnsx.2024.100301>
- Bahr, A., Schneider, M., Francis, M. A., Lehmann, H. M., Barg, I., Buschhoff, A. S., Wulff, P., Strunskus, T., & Faupel, F. (2021). Epileptic seizure detection on an ultra-low-power

- embedded risc-v processor using a convolutional neural network. *Biosensors*, 11(7). <https://doi.org/10.3390/bios11070203>
- Bird, J. J., Faria, D. R., Manso, L. J., Ayrosa, P. P. S., & Ekárt, A. (2021). A study on CNN image classification of EEG signals represented in 2D and 3D. *Journal of Neural Engineering*, 18(2), 026005. <https://doi.org/10.1088/1741-2552/abda0c>
- Caso, F., Cursi, M., Magnani, G., Fanelli, G., Falautano, M., Comi, G., Leocani, L., & Minicucci, F. (2012). Quantitative EEG and LORETA: valuable tools in discerning FTD from AD? *Neurobiology of Aging*, 33(10), 2343–2356. <https://doi.org/10.1016/j.neurobiolaging.2011.12.011>
- Ch Vidyasagar, K. E., Revanth Kumar, K., Anantha Sai, G. N. K., Ruchita, M., & Saikia, M. J. (2024). Signal to Image Conversion and Convolutional Neural Networks for Physiological Signal Processing: A Review. *IEEE Access*, 12, 66726–66764. <https://doi.org/10.1109/ACCESS.2024.3399114>
- Chen, Y., Wang, H., Zhang, D., Zhang, L., & Tao, L. (2023). Multi-feature fusion learning for Alzheimer's disease prediction using EEG signals in resting state. *Frontiers in Neuroscience*, 17. <https://doi.org/10.3389/fnins.2023.1272834>
- Chen, Y., Wang, H., Zhang, G., Liu, X., Huang, W., Han, X., et al. (2022). Contrastive learning for prediction of Alzheimer's disease using brain 18f-fdg pet. *IEEE J. Biomed. Health Informatics* 27, 1735–1746. doi: 10.1109/JBHI.2022.3231905
- Chollet, F. (2018). *Deep Learning with Python*, 4-6.
- Cimr, D., Fujita, H., Tomaskova, H., Cimler, R., & Selamat, A. (2023). Automatic seizure detection by convolutional neural networks with computational complexity analysis. *Computer Methods and Programs in Biomedicine*, 229. <https://doi.org/10.1016/j.cmpb.2022.107277>
- Clarke, C. (Charles R. A.), National Hospital for Neurology and Neurosurgery (London, E., & Institute of Neurology, Q. Square. (2009). *Neurology: a Queen Square textbook*. Wiley-Blackwell.
- Duan, F., Huang, Z., Sun, Z., Zhang, Y., Zhao, Q., Cichocki, A., et al. (2020). Topological network analysis of early Alzheimer's disease based on resting-state EEG. *IEEE Trans. Neural Syst. Rehabil. Eng.* 28, 2164–2172. doi: 10.1109/TNSRE.2020.3014951
- Dubois, B., Feldman, H. H., Jacova, C., DeKosky, S. T., Barberger-Gateau, P., Cummings, J., Delacourte, A., Galasko, D., Gauthier, S., Jicha, G., Meguro, K., O'Brien, J., Pasquier, F., Robert, P., Rossor, M., Salloway, S., Stern, Y., Visser, P. J., & Scheltens, P. (2007). Research criteria for the diagnosis of Alzheimer's disease: revising the NINCDS-ADRDA criteria. *The Lancet Neurology*, 6(8), 734–746. [https://doi.org/10.1016/S1474-4422\(07\)70178-3](https://doi.org/10.1016/S1474-4422(07)70178-3)
- Dugger, B. N., & Dickson, D. W. (2017). *Pathology of Neurodegenerative Diseases*. Cold Spring Harbor Perspectives in Biology, 9(7). <https://doi.org/10.1101/cshperspect.a028035>
- Ein Shoka, A. A., Dessouky, M. M., El-Sayed, A., & El-Din Hemdan, E. (2023). An efficient CNN based epileptic seizures detection framework using encrypted EEG signals for secure telemedicine applications. *Alexandria Engineering Journal*, 65, 399–412. <https://doi.org/10.1016/j.aej.2022.10.014>
- Fernández, M., Gobartt, A. L., & Balañá, M. (2010). Behavioural symptoms in patients with Alzheimer's disease and their association with cognitive impairment. *BMC Neurology*, 10(1), 87. <https://doi.org/10.1186/1471-2377-10-87>
- Fisher, R. S., Acevedo, C., Arzimanoglou, A., Bogacz, A., Cross, J. H., Elger, C. E., Engel, J., Jr, Forsgren, L., French, J. A., Glynn, M., Hesdorffer, D. C., Lee, B. I., Mathern, G. W., Moshé, S. L., Perucca, E., Scheffer, I. E., Tomson, T., Watanabe, M., & Wiebe, S. (2014). ILAE official report: a practical clinical definition of epilepsy. *Epilepsia*, 55(4), 475–482.

<https://doi.org/10.1111/epi.12550>

- Fukushima, K. (1969). Visual Feature Extraction by a Multilayered Network of Analog Threshold Elements. *IEEE Transactions on Systems Science and Cybernetics*, 5(4), 322–333. <https://doi.org/10.1109/TSSC.1969.300225>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*, 298-371.
- Grant, A. C., Abdel-Baki, S. G., Weedon, J., Arnedo, V., Chari, G., Koziorynska, E., Lushbough, C., Maus, D., McSween, T., Mortati, K. A., Reznikov, A., & Omurtag, A. (2014). EEG interpretation reliability and interpreter confidence: A large single-center study. *Epilepsy & Behavior*, 32, 102–107. <https://doi.org/10.1016/j.yebeh.2014.01.011>
- Harrison. (2013). *NEUROLOGY IN CLINICAL MEDICINE*, 218-474.
- Haykin, S. S. (2009). *Neural networks and learning machines*. Prentice Hall/Pearson.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. <http://arxiv.org/abs/1207.0580>
- Howlett, W. (2012). *Neurology in Africa Clinical Skills and Neurological Disorders*, 79-385.
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456).
- Islam, Md. A., Hasan Majumder, Md. Z., Hussein, Md. A., Hossain, K. M., & Miah, Md. S. (2024). A review of machine learning and deep learning algorithms for Parkinson's disease detection using handwriting and voice datasets. *Heliyon*, 10(3). <https://doi.org/10.1016/j.heliyon.2024.e25469>
- Jha, A., Kuruvilla, N., Garg, P., & Victor, A. (2023). Harnessing Creative Methods for EEG Feature Extraction and Modeling in Neurological Disorder Diagnoses. *2023 7th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*, 1–6. <https://doi.org/10.1109/CSITSS60515.2023.10334244>
- Jibon, F. A., Miraz, M. H., Khandaker, M. U., Rashdan, M., Salman, M., Tasbir, A., Nishar, N. H., & Siddiqui, F. H. (2023). Epileptic seizure detection from electroencephalogram (EEG) signals using linear graph convolutional network and DenseNet based hybrid framework. *Journal of Radiation Research and Applied Sciences*, 16(3), 100607. <https://doi.org/10.1016/j.jrras.2023.100607>
- Kadian, S., Kumari, P., Shukla, S., & Narayan, R. (2023). Recent advancements in machine learning enabled portable and wearable biosensors. *Talanta Open*, 8. <https://doi.org/10.1016/j.talo.2023.100267>
- Keerthi Krishnan K, Soman KP. CNN based classification of motor imaginary using variational mode decomposed EEG-spectrum image. *Biomedical Engineering Letters*. 2021 Aug;11(3):235-247. DOI: 10.1007/s13534-021-00190-z. PMID: 34350050; PMCID: PMC8316561.
- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization.
- Kıymık, M. K., Güler, İ., Dizibüyük, A., & Akın, M. (2005). Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Computers in Biology and Medicine*, 35(7), 603–616. <https://doi.org/10.1016/j.combiomed.2004.05.001>
- Krishnan, S. (2021). Advanced analysis of biomedical signals. In *Biomedical Signal Analysis for Connected Healthcare* (pp. 157–222). Elsevier. <https://doi.org/10.1016/B978-0-12-813086-5.00003-7>

- Lal, U., Chikkankod, A. V., & Longo, L. (2024). A Comparative Study on Feature Extraction Techniques for the Discrimination of Frontotemporal Dementia and Alzheimer's Disease with Electroencephalography in Resting-State Adults. *Brain Sciences*, 14(4), 335. <https://doi.org/10.3390/brainsci14040335>
- Larson, E., Gramfort, A., Engemann, D. A., Leppakangas, J., Brodbeck, C., Jas, M., Brooks, T., Sassenhagen, J., McCloy, D., Luessi, M., King, J.-R., Höchenberger, R., Goj, R., Favelier, G., Brunner, C., van Vliet, M., Wronkiewicz, M., Rockhill, A., Holdgraf, C. (2024). MNE-Python (v1.7.1). Zenodo. <https://doi.org/10.5281/zenodo.11662646>
- Latifoğlu, F., Penekli, S., Orhanbulucu, F., & Chowdhury, M. E. H. (2024). A novel approach for Parkinson's disease detection using Vold-Kalman order filtering and machine learning algorithms. *Neural Computing and Applications*, 36(16), 9297–9311. <https://doi.org/10.1007/s00521-024-09569-2>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Lee, S., Hussein, R., Ward, R., Jane Wang, Z., & McKeown, M. J. (2021). A convolutional-recurrent neural network approach to resting-state EEG classification in Parkinson's disease. *Journal of Neuroscience Methods*, 361. <https://doi.org/10.1016/j.jneumeth.2021.109282>
- Lian, J., Zhang, Y., Luo, R., Han, G., Jia, W., & Li, C. (2020). Pair-Wise Matching of EEG Signals for Epileptic Identification via Convolutional Neural Network. *IEEE Access*, 8, 40008–40017. <https://doi.org/10.1109/ACCESS.2020.2976751>
- Lima, A. A., Mridha, M. F., Das, S. C., Kabir, M. M., Islam, Md. R., & Watanobe, Y. (2022). A Comprehensive Survey on the Detection, Classification, and Challenges of Neurological Disorders. *Biology*, 11(3), 469. <https://doi.org/10.3390/biology11030469>
- Luján, M., Jimeno, M., Mateo Sotos, J., Ricarte, J., & Borja, A. (2021). A Survey on EEG Signal Processing Techniques and Machine Learning: Applications to the Neurofeedback of Autobiographical Memory Deficits in Schizophrenia. *Electronics*, 10(23), 3037. <https://doi.org/10.3390/electronics10233037>
- Merk, T., Peterson, V., Köhler, R., Haufe, S., Richardson, R. M., & Neumann, W.-J. (2022). Machine learning based brain signal decoding for intelligent adaptive deep brain stimulation. *Experimental Neurology*, 351. <https://doi.org/10.1016/j.expneurol.2022.113993>
- Michel, C. M., & Brunet, D. (2019). EEG Source Imaging: A Practical Review of the Analysis Steps. *Frontiers in Neurology*, 10. <https://doi.org/10.3389/fneur.2019.00325>
- Miltiadous, A., Gionanidis, E., Tzimourta, K. D., Giannakeas, N., & Tzallas, A. T. (2023). DICE-Net: A Novel Convolution-Transformer Architecture for Alzheimer Detection in EEG Signals. *IEEE Access*, 11, 71840–71858. <https://doi.org/10.1109/ACCESS.2023.3294618>
- Miltiadous, A., Tzimourta, K. D., Afrantou, T., Ioannidis, P., Grigoriadis, N., Tsalikakis, D. G., Angelidis, P., Tsipouras, M. G., Glavas, E., Giannakeas, N., & Tzallas, A. T. (2023). A Dataset of Scalp EEG Recordings of Alzheimer's Disease, Frontotemporal Dementia and Healthy Subjects from Routine EEG. *Data*, 8(6), 95. <https://doi.org/10.3390/data8060095>
- Muhammad Usman, S., Khalid, S., & Aslam, M. H. (2020). Epileptic Seizures Prediction Using Deep Learning Techniques. *IEEE Access*, 8, 39998–40007. <https://doi.org/10.1109/ACCESS.2020.2976866>
- Murray, N., & Perronnin, F. (2014). Generalized Max Pooling. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2473–2480. <https://doi.org/10.1109/CVPR.2014.317>

- Narin, A. (2022). Detection of Focal and Non-focal Epileptic Seizure Using Continuous Wavelet Transform-Based Scalogram Images and Pre-trained Deep Neural Networks. *IRBM*, 43(1), 22–31. <https://doi.org/10.1016/j.irbm.2020.11.002>
- Nedeljković, M., Pađin, P., & Nikolić, S. (2023). Low Dimensional EEG Classification for Alzheimer's Disease Recognition. 2023 31st Telecommunications Forum (TELFOR), 1–4. <https://doi.org/10.1109/TELFOR59449.2023.10372658>
- Nishida, K., Yoshimura, M., Isotani, T., Yoshida, T., Kitaura, Y., Saito, A., Mii, H., Kato, M., Takekita, Y., Suwa, A., Morita, S., & Kinoshita, T. (2011). Differences in quantitative EEG between frontotemporal dementia and Alzheimer's disease as revealed by LORETA. *Clinical Neurophysiology*, 122(9), 1718–1725. <https://doi.org/10.1016/j.clinph.2011.02.011>
- Pan, S., Iplikci, S., Warwick, K., & Aziz, T. Z. (2012). Parkinson's Disease tremor classification – A comparison between Support Vector Machines and neural networks. *Expert Systems with Applications*, 39(12), 10764–10771. <https://doi.org/10.1016/j.eswa.2012.02.189>
- Parihar, A., & Swami, P. D. (2024). Analysis of EEG signals with the use of wavelet transform for accurate classification of Alzheimer Disease, Frontotemporal Dementia and healthy subjects using Machine Learning Models. *Fusion: Practice and Applications*, 14(2), 43–55. <https://doi.org/10.54216/FPA.140203>
- Prasanth, T., Thomas, J., Yuvaraj, R., Jing, J., Cash, S. S., Chaudhari, R., Leng, T. Y., Rathakrishnan, R., Rohit, S., Saini, V., Westover, B. M., & Dauwels, J. (2020). Deep Learning for Interictal Epileptiform Spike Detection from scalp EEG frequency sub bands. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2020-July, 3703–3706. <https://doi.org/10.1109/EMBC44109.2020.9175644>
- Puri, D. V., Nalbalwar, S. L., Nandgaonkar, A. B., Gawande, J. P., & Wagh, A. (2023). Automatic detection of Alzheimer's disease from EEG signals using low-complexity orthogonal wavelet filter banks. *Biomedical Signal Processing and Control*, 81, 104439. <https://doi.org/10.1016/j.bspc.2022.104439>
- Q. Wu, E. Fokoue, R. G. A. (2017). Epileptic seizure recognition data set. [Online; UCI Machine Learning Repository].
- Quan, C., Ren, K., Luo, Z., Chen, Z., & Ling, Y. (2022). End-to-end deep learning approach for Parkinson's disease detection from speech signals. *Biocybernetics and Biomedical Engineering*, 42(2), 556–574. <https://doi.org/10.1016/j.bbe.2022.04.002>
- Raghu, S., Sriraam, N., Temel, Y., Rao, S. V., & Kubben, P. L. (2020). EEG based multi-class seizure type classification using convolutional neural network and transfer learning. *Neural Networks*, 124, 202–212. <https://doi.org/10.1016/j.neunet.2020.01.017>
- Rashed-Al-Mahfuz, M., Moni, M. A., Uddin, S., Alyami, S. A., Summers, M. A., & Eapen, V. (2021). A Deep Convolutional Neural Network Method to Detect Seizures and Characteristic Frequencies Using Epileptic Electroencephalogram (EEG) Data. *IEEE Journal of Translational Engineering in Health and Medicine*, 9, 1–12. <https://doi.org/10.1109/JTEHM.2021.3050925>
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of Neural Engineering*, 16(5), 051001. <https://doi.org/10.1088/1741-2552/ab260c>
- Sameer, M., & Gupta, B. (2022). CNN based framework for detection of epileptic seizures. *Multimedia Tools and Applications*, 81(12), 17057–17070. <https://doi.org/10.1007/s11042-022-12702-9>
- San-Segundo, R., Gil-Martín, M., D'Haro-Enríquez, L. F., & Pardo, J. M. (2019). Classification of epileptic EEG recordings using signal transforms and convolutional neural networks.

- Computers in Biology and Medicine, 109, 148–158. <https://doi.org/10.1016/j.compbiomed.2019.04.031>
- Schöll, E. (2021). Partial synchronization patterns in brain networks. *Europhysics Letters*, 136(1), 18001. <https://doi.org/10.1209/0295-5075/ac3b97>
- Shah, D., Gopan K., G., & Sinha, N. (2022). An investigation of the multi-dimensional (1D vs. 2D vs. 3D) analyses of EEG signals using traditional methods and deep learning-based methods. *Frontiers in Signal Processing*, 2. <https://doi.org/10.3389/frsip.2022.936790>
- Shalev-Shwartz, S., & B.-D. S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. <http://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning>
- Shanmugam, S., & Dharmar, S. (2023). A CNN-LSTM hybrid network for automatic seizure detection in EEG signals. *Neural Computing and Applications*, 35(28), 20605–20617. <https://doi.org/10.1007/s00521-023-08832-2>
- Sharma, R., Goel, T., Tanveer, M., Suganthan, P., Razzak, I., and Murugan, R. (2022). Conv-ervfl: Convolutional neural networkbased ensemble RVFL classifier for Alzheimer's disease diagnosis. *IEEE J. Biomed. Health Inform.* 1–9. doi: 10.1109/JBHI.2022.3215533
- Shoeibi, A., Khodatars, M., Ghassemi, N., Jafari, M., Moridian, P., Alizadehsani, R., Panahiazar, M., Khozeimeh, F., Zare, A., Hosseini-Nejad, H., Khosravi, A., Atiya, A. F., Aminshahidi, D., Hussain, S., Rouhani, M., Nahavandi, S., & Acharya, U. R. (2021). Epileptic Seizures Detection Using Deep Learning Techniques: A Review. *International Journal of Environmental Research and Public Health*, 18(11), 5780. <https://doi.org/10.3390/ijerph18115780>
- Shoeibi, A., Sadeghi, D., Moridian, P., Ghassemi, N., Heras, J., Alizadehsani, R., Khadem, A., Kong, Y., Nahavandi, S., Zhang, Y. D., & Gorriz, J. M. (2021). Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models. *Frontiers in Neuroinformatics*, 15. <https://doi.org/10.3389/fninf.2021.777977>
- Si, Y., He, R., Jiang, L., Yao, D., Zhang, H., Xu, P., Ma, X., Yu, L., & Li, F. (2023). Differentiating Between Alzheimer's Disease and Frontotemporal Dementia Based on the Resting-State Multilayer EEG Network. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 31, 4521–4527. <https://doi.org/10.1109/TNSRE.2023.3329174>
- Singh, A., Cole, R. C., Espinoza, A. I., Wessel, J. R., Cavanagh, J. F., & Narayanan, N. S. (2022). Evoked midfrontal activity predicts cognitive dysfunction in Parkinsons disease. *MedRxiv*. <https://doi.org/10.1101/2022.07.26.22278079>
- Smith, S. J. M. (2005). EEG in neurological conditions other than epilepsy: when does it help, what does it add? *Journal of Neurology, Neurosurgery & Psychiatry*, 76(suppl_2), ii8–ii12. <https://doi.org/10.1136/jnnp.2005.068486>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). *Seyreltme: A Simple Way to Prevent Neural Networks from Overfitting*. In *Journal of Machine Learning Research* (Vol. 15).
- Sugden, R. J., & Diamandis, P. (2023). Generalizable electroencephalographic classification of Parkinson's disease using deep learning. *Informatics in Medicine Unlocked*, 42. <https://doi.org/10.1016/j.imu.2023.101352>
- Tatum, W. O. (2014). Ellen R. Grass Lecture: extraordinary EEG. *The Neurodiagnostic Journal*, 54(1), 3–21.
- Teuwen, J., & Moriakov, N. (2020). Convolutional neural networks. In *Handbook of Medical Image Computing and Computer Assisted Intervention* (pp. 481–501). Elsevier. <https://doi.org/10.1016/B978-0-12-816176-0.00025-9>
- Tjepkema-Cloostermans, M. C., de Carvalho, R. C. V., & van Putten, M. J. A. M. (2018). Deep

- learning for detection of focal epileptiform discharges from scalp EEG recordings. *Clinical Neurophysiology*, 129(10), 2191–2196. <https://doi.org/10.1016/j.clinph.2018.06.024>
- Ullah, I., Hussain, M., Aboalsamh, H., et al. (2018). An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Syst. Appl.* 107, 61–71. doi: 10.1016/j.eswa.2018.04.021
- Ullah, I., Hussain, M., Qazi, E. ul H., & Aboalsamh, H. (2018). An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Systems with Applications*, 107, 61–71. <https://doi.org/10.1016/j.eswa.2018.04.021>
- van Leeuwen, K. G., Sun, H., Tabaeizadeh, M., Struck, A. F., van Putten, M. J. A. M., & Westover, M. B. (2019). Detecting abnormal electroencephalograms using deep convolutional networks. *Clinical Neurophysiology*, 130(1), 77–84. <https://doi.org/10.1016/j.clinph.2018.10.012>
- Wacker, M., & Witte, H. (2013). Time-frequency Techniques in Biomedical Signal Analysis. *Methods of Information in Medicine*, 52(04), 279–296. <https://doi.org/10.3414/ME12-01-0083>
- Wang, M., Lu, S., Zhu, D., Lin, J., & Wang, Z. (2018, October). A high-speed and low-complexity architecture for softmax function in deep learning. In 2018 IEEE asia pacific conference on circuits and systems (APCCAS) (pp. 223–226). IEEE.
- Wang, W., Lee, J., Harrou, F., & Sun, Y. (2020). Early Detection of Parkinson's Disease Using Deep Learning and Machine Learning. *IEEE Access*, 8, 147635–147646. <https://doi.org/10.1109/ACCESS.2020.3016062>
- Wang, Z., Liu, A., Yu, J., Wang, P., Bi, Y., Xue, S., Zhang, J., Guo, H., & Zhang, W. (2023). The effect of aperiodic components in distinguishing Alzheimer's disease from frontotemporal dementia. *GeroScience*, 46(1), 751–768. <https://doi.org/10.1007/s11357-023-01041-8>
- Wang, Z., Yang, J., & Sawan, M. (2021, June 6). A Novel Multi-scale Dilated 3D CNN for Epileptic Seizure Prediction. 2021 IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems, AICAS 2021. <https://doi.org/10.1109/AICAS51828.2021.9458571>
- Wei, X., Zhou, L., Chen, Z., Zhang, L., & Zhou, Y. (2018). Automatic seizure detection using three-dimensional CNN based on multi-channel EEG. *BMC Medical Informatics and Decision Making*, 18. <https://doi.org/10.1186/s12911-018-0693-8>
- Willis, A. W., Roberts, E., Beck, J. C., Fiske, B., Ross, W., Savica, R., Van Den Eeden, S. K., Tanner, C. M., Marras, C., Alcalay, R., Schwarzschild, M., Racette, B., Chen, H., Church, T., Wilson, B., & Doria, J. M. (2022). Incidence of Parkinson disease in North America. *Npj Parkinson's Disease*, 8(1), 170. <https://doi.org/10.1038/s41531-022-00410-y>
- Xu, G., Ren, T., Chen, Y., & Che, W. (2020). A One-Dimensional CNN-LSTM Model for Epileptic Seizure Recognition Using EEG Signal Analysis. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.578126>
- Yıldırım, Ö., Baloglu, U. B., & Acharya, U. R. (2020). A deep convolutional neural network model for automated identification of abnormal EEG signals. *Neural Computing and Applications*, 32(20), 15857–15868. <https://doi.org/10.1007/s00521-018-3889-z>
- Yogarajah, M. (2013). Crash Course: Neurology. In *Crash Course: Neurology*. <https://doi.org/10.1016/B978-0-12-375067-9.09978-2>
- Zhang, Y., Guo, Y., Yang, P., Chen, W., & Lo, B. (2020). Epilepsy Seizure Prediction on EEG Using Common Spatial Pattern and Convolutional Neural Network. *IEEE Journal of Biomedical and Health Informatics*, 24(2), 465–474. <https://doi.org/10.1109/JBHI.2019.2933046>
- Zhang, Z., & Sabuncu, M. R. (2018). Generalized Cross Entropy Loss for Training Deep Neural

- Zhao, W., Zhao, W., Wang, W., Jiang, X., Zhang, X., Peng, Y., Zhang, B., & Zhang, G. (2020). A Novel Deep Neural Network for Robust Detection of Seizures Using EEG Signals. *Computational and Mathematical Methods in Medicine*, 2020. <https://doi.org/10.1155/2020/9689821>
- Zheng, X., Wang, B., Liu, H., Wu, W., Sun, J., Fang, W., Jiang, R., Hu, Y., Jin, C., Wei, X., & Chen, S. S.-C. (2023). Diagnosis of Alzheimer's disease via resting-state EEG: integration of spectrum, complexity, and synchronization signal features. *Frontiers in Aging Neuroscience*, 15. <https://doi.org/10.3389/fnagi.2023.1288295>
- Zheng, X., Xu, G., Wu, Y., Wang, Y., Du, C., Wu, Y., Zhang, S., & Han, C. (2020). Comparison of the performance of six stimulus paradigms in visual acuity assessment based on steady-state visual evoked potentials. *Documenta Ophthalmologica*, 141(3), 237–251. <https://doi.org/10.1007/s10633-020-09768-x>
- Zhou, M., Tian, C., Cao, R., Wang, B., Niu, Y., Hu, T., Guo, H., & Xiang, J. (2018). Epileptic seizure detection based on EEG signals and CNN. *Frontiers in Neuroinformatics*, 12. <https://doi.org/10.3389/fninf.2018.00095>