

T.C.  
SİİRT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

EEG VERİLERİ İLE DERİN ÖĞRENME TABANLI EPİLEPSİ NÖBETİ  
TEŞHİSİ

YÜKSEK LİSANS TEZİ

Abdulkadir BULDU  
(213111006)

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Melih KUNCAN

II. Danışman: Dr. Öğr. Üyesi Kaplan KAPLAN

Haziran-2023  
SİİRT

## TEZ KABUL VE ONAYI

Abdulkadir BULDU tarafından hazırlanan ‘‘EEG Verileri ile Derin Öğrenme Tabanlı Epilepsi Nöbeti Teşhisi’’ adlı tez çalışması 14/06/2023 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Doç. Dr. Yılmaz KAYA

.....

#### Danışman

Doç. Dr. Melih KUNCAN

.....

#### Üye

Doç. Dr. Mehmet Recep MİNAZ

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr. Harun BEKTAŞ  
Fen Bilimleri Enstitüsü Müdürü

## ÖN SÖZ

Bu bölümde kendi adıma kıymetli danışman hocalarım; Doç. Dr. Melih KUNCAN'a ve Dr. Öğr. Üyesi Kaplan KAPLAN'a göstermiş oldukları ilgi, yapmış oldukları danışmanlık ve kazandırmış oldukları bilgi ve tecrübelerden ötürü minnetlerimi sunarım.

Ayrıca çalışmalarımın sürdürdüğü esnada desteklerini esirgemeyen çalışma arkadaşlarım Arş. Gör. İbrahim Halil İLÇİN, Arş. Gör. Rıdvan ÇETİN'e teşekkürü bir borç bilirim

Bugüne kadar hayatımın her alanında her daim yanımda olan değerli aile fertlerime de teşekkür ederim

Tez çalışmasını gerçekleştirdiğim süreç içerisinde yanımda olarak motivasyonumu yükselten değerli dostum Uğurcan DEMİR'e teşekkür ederim.

Ayrıca bu tez çalışması kapsamında yapılan denemeler, Siirt Üniversitesi Mühendislik Fakültesi İşaret İşleme Laboratuvarı'nda gerçekleştirilmiştir. Bu vesileyle İşaret İşleme Laboratuvarı personellerine destekleri için ayrıca teşekkür ederim.

Abdulkadir BULDU  
SİİRT-2023

# İÇİNDEKİLER

Sayfa

ÖNSÖZ .....	iii
İÇİNDEKİLER .....	iv
TABLolar LİSTESİ .....	v
ŞEKİLLER LİSTESİ .....	vi
KISALTMALAR ve SİMGELER LİSTESİ .....	vii
ÖZET .....	viii
ABSTRACT.....	ix
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI .....	5
3. MATERYAL VE METOT.....	16
3.1. Beynin Yapısı.....	16
3.1.1. Nöronlar.....	16
3.1.2. Elektroensefalografi .....	17
3.1.2.1. EEG verilerinin toplanması .....	17
3.1.2.1.1. 10-20 Elektrot sistemi yardımıyla EEG sinyallerinin toplanması: ..	17
3.1.2.2. EEG verileri yardımıyla hastalık teşhisi .....	20
3.1.2.2.1. Epilepsi.....	20
3.1.2.2.2. Uyku bozuklukları.....	20
3.1.2.2.3. Beyin tümörleri .....	20
3.2. Materyal .....	21
3.2.1. Kullanılan sistem .....	21
3.2.2. Veri seti .....	21
3.2.2.1. Bonn veri seti .....	21
3.2.2.2. The Hauz Khas veri seti.....	23
3.3. Metot .....	24
3.3.1. Derin öğrenme .....	26
3.3.1.1. Evrişimli sinir ağları (CNN) .....	27
3.3.1.1.1. CNN tabanlı mimariler .....	28
3.3.1.1.1.1. Resnet 101 .....	28
3.3.1.1.1.2. Resnet 50.....	29
3.3.1.1.1.3. AlexNet .....	29
3.3.1.1.1.4. GoogleNet .....	30
3.3.1.1.1.5. VGG-19.....	31
3.3.2. Kısa zamanlı fourier dönüşümü.....	32
3.3.3. Sürekli dalgacık dönüşümü .....	35
3.3.4. Performans parametreleri .....	37
4. DENEYSSEL SONUÇLAR .....	39
5. TARTIŞMA.....	47
6. KAYNAKÇA .....	50
ÖZGEÇMİŞ .....	56

## TABLolar LİSTESİ

	<u>Sayfa</u>
<b>Tablo 3.1.</b> Bonn veri seti detayları .....	222
<b>Tablo 3.2.</b> The Hauz Khas Delhi veri seti detayları .....	255
<b>Tablo 3.3.</b> Performans ölçütlerine ait bilgiler .....	37
<b>Tablo 4.1.</b> Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (128 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar) .....	39
<b>Tablo 4.2.</b> Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (128 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar) .....	40
<b>Tablo 4.3.</b> Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (256 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar) .....	40
<b>Tablo 4.4.</b> Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (256 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar) .....	41
<b>Tablo 4.5.</b> Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (CWT uygulanması sonucu elde edilen sonuçlar) .....	41
<b>Tablo 4.6.</b> Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (CWT uygulanması sonucu elde edilen sonuçlar) .....	42
<b>Tablo 4.7.</b> 128 pencere aralığına sahip Kaiser penceresi kullanılarak STFT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları .....	43
<b>Tablo 4.8.</b> 256 pencere aralığına sahip Kaiser penceresi kullanılarak STFT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları .....	44
<b>Tablo 4.9.</b> CWT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları ..	45
<b>Tablo 4.10.</b> Sunulan yaklaşımın literatürdeki çalışmalarla karşılaştırılması .....	456

## ŞEKİLLER LİSTESİ

### Sayfa

Şekil 1.1. Yapay zeka tabanlı yöntemlerinin ilişkilendirilmesi.....	3
Şekil 3.1. Bir nötronun temel yapısı.....	177
Şekil 3.2. 10-20 sistemi elektrot dağılımı.....	18
Şekil 3.3. EEG sinyal türlerine ait örnekler.....	199
Şekil 3.4. A grubuna ait sinyallerden bir örnek.....	23
Şekil 3.5. B grubuna ait sinyallerden bir örnek.....	23
Şekil 3.6. C grubuna ait sinyallerden bir örnek.....	23
Şekil 3.7. D grubuna ait sinyallerden bir örnek.....	24
Şekil 3.8. E grubuna ait sinyallerden bir örnek.....	24
Şekil 3.9. Preiktal anına ait bir EEG sinyali.....	25
Şekil 3.10. İktal anına ait bir EEG sinyali.....	25
Şekil 3.11. İnteriktal anına ait bir EEG sinyali.....	26
Şekil 3.12. CNN algoritması genel şeması.....	27
Şekil 3.13. Resnet-101 sınıflandırıcısına ait mimari.....	28
Şekil 3.14. AlexNet sınıflandırıcısına ait mimari.....	30
Şekil 3.15. VGG-19 mimarisi.....	32
Şekil 3.16. The Hauz Khas veri seti 128 pencere boyutlu Kaiser yöntemi tabanlı STFT çıktı örnekleri. (a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali....	33
Şekil 3.17. Bonn veri seti 128 pencere boyutlu Kaiser yöntemi tabanlı STFT yöntemi çıkı örnekleri: (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu.....	34
Şekil 3.18. The Hauz Khas veri seti 256 pencere boyutlu Kaiser yöntemi tabanlı STFT çıktı örnekleri: (a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali....	34
Şekil 3.19. Bonn veri seti 256 pencere boyutlu Kaiser yöntemi tabanlı STFT yöntemi çıkı örnekleri: (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu.....	35
Şekil 3.20. Bonn veri seti CWT tabanlı analiz sonucu elde edilen örnekler: (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu.....	36
Şekil 3.21. The Hauz Khas veri seti CWT tabanlı analiz sonucu elde edilen örnekler: (a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali.....	37

## KISALTMALAR ve SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Acıklama</u>
1D	: 1 Boyutlu
2D	: 2 Boyut
AE	: Otomatik Kodlayıcı
CNN	: Evrimsel Sinir Ağları
CWT	: Sürekli Dalgacık Dönüşümü
DCT	: Ayrık Kosinüs Dönüşümü
DT	: Karar Ağaçları
DWT	: Ayrık Dalgacık Dönüşümü
EEG	: Elektroensefalografi
ELM	: Aşırı Öğrenme Makinesi
FuzzyEn	: Bulanık Entropi
GB	: Gigabyte
Hz	: Herz
IMF	: İçsel Mod İşlevleri
kNN	: k En Yakın Komşular
LS	: En Küçük Kareler
LSTM	: Uzun-Kısa Süreli Hafıza
MRG	: Manyetik Rezonans Görüntüleme
NB	: Navie Bayes
PCA	: Temel Bileşenler Analizi
PE	: Permütasyon Entropisi
QDA	: Karesele Ayrım Analizi
RF	: Rastgele Ağaçlar
S2I	: Kaynaktan Görüntüye
SamplEn	: Örnek Entropi
STFT	: Kısa Zamanlı Fourier Dönüşümü
SVD	: Tekil Değer Ayrışımı
SVM	: Destek Vektör Makineleri
YSA	: Yapay Sinir Ağları

### Simge

$\theta$	: Bessel işlev değeri
$\lambda$	: Langrange Çarpanı
$\varphi$	: Dalgacık Fonksiyonu

## ÖZET

### YÜKSEK LİSANS TEZİ

## EEG VERİLERİ İLE DERİN ÖĞRENME TABANLI EPİLEPSİ NÖBETİ TEŞHİSİ

Abdulkadir BULDU

Siirt Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Melih KUNCAN

II. Danışman: Dr. Öğr. Üyesi Kaplan KAPLAN

2023, 56+IX Sayfa

Canlıların vücudunun düzenli bir şekilde işlemlerini ve hayatını devam ettirmesi için gereken işleri yerine getirmesinin kontrolünü sağlayan temel organ beyindir. Bu açıdan düşünüldüğünde beyin insan hayatı için de hayati bir öneme sahip olduğu ve bu organ üzerinde meydana gelecek aksaklıkların direkt olarak vücudu etkileyeceği aşikardır. Elektroensefalografi (EEG) beyinde meydana gelen aksaklıkların tespit edilmesini sağlayan bir araç niteliğindedir ve beyinde gerçekleşen elektriksel aktivitenin sonucunda elde edilen bir sinyal türüdür. EEG sinyallerinin nörolojik hastalıklarının birçoğuna özel bilgiler taşıması da araştırmacıları bu sinyalleri incelemeye itmiştir.

Beyinde meydana gelen ve EEG sinyallerinden faydalanılarak tespiti gerçekleştirilen hastalıklardan biri de gün geçtikçe görülme oranı artan ve kısıtlı imkanlar sebebiyle ölüm veya kalıcı hasarla sonuçlanabilen epilepsi hastalığıdır. Bu imkansızlıklardan doğan tehlikelerin varlığı araştırmacıları maliyeti düşük asistan sistemler önermeye sürüklemiştir.

Bu çalışma kapsamında bizler de epilepsi hastalığının bu yayılışına istinaden uzmanların çevresel faktörlerden kaynaklı olarak yapabilecekleri hataları azaltmak ve bu hataların doğurabileceği telafisi zor olan veya olmayan hataların önüne geçilmesi adına bir asistan fikir oluşturmayı amaçladık. Bu doğrultuda iki farklı veri setiyle çalışmamızı gerçekleştirerek sağlıklı ve epilepsi hastalığına sahip insanların verilerini analiz edip bu analizler sonucunda deneklerin bulunduğu hallerin tespitini gerçekleştirmeyi amaçladık.

Edindiğimiz bu amaç doğrultusunda The Hanz Khas veri setini ve literatürde sıklıkla kullanılan Bonn Epilepsi veri setini derin öğrenme yöntemlerinden Resnet-50, Resnet-101, AlexNet, GoogleNet ve VGG-19 yaklaşımlarını veri setlerine uygulayarak sınıflandırdık. Ancak verileri ham bir şekilde almaktansa sınıflandırma işlemine daha keskin sınırlarla tabi tutmak adına Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform, STFT) ve Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT) yöntemlerini uygulayarak sınıflandırma doğruluğunu dolayısıyla da yöntemin kabul edilebilirliğini artırmaya çalıştık. Yapılan çalışma nihayetinde özellik çıkarım yöntemi olarak CWT kullanımının sonucunda The Hanz Khas veri seti üzerindeki preiktal ve iktal anlarını tüm sınıflandırıcılarla %100 oranında sınıflandırmayı başardık. Ayrıca Bonn veri setinin ikili sınıflandırmalarında da CWT özellik çıkarım yönteminden faydalanarak tüm sınıflandırıcılarla %100 başarı oranına ulaşırken AB-CD-E grubunun sınıflandırılmasında %99,33 oranında sınıflandırma başarısı elde ettik.

**Anahtar Kelimeler:** CWT, Derin öğrenme, EEG, Epilepsi teşhisi, STFT

## **ABSTRACT**

### **MS THESIS**

## **DEEP LEARNING BASED DIAGNOSIS OF EPILEPSY SEIZURE WITH EEG DATA**

**Abdulkadir BULDU**

**The Graduate School of Natural and Applied Science of Siirt University  
The Degree of Master of Science  
In Electrical-Electronics Engineering**

**Supervisor: Assoc. Prof. Dr. Melih KUNCAN**

**Co-Supervisor: Assis. Prof. Dr. Kaplan KAPLAN**

**2023, 56+IX Pages**

The brain is the basic organ that controls the regular functioning of the body of living things and the fulfillment of the tasks necessary for their survival. When considered from this point of view, it is obvious that the brain has a vital importance for human life and that any malfunctions in this organ will directly affect the body. Electroencephalography (EGG) is a tool that enables the detection of malfunctions in the brain and is a type of signal obtained as a result of electrical activity in the brain. The fact that EEG signals carry specific information about many neurological diseases has pushed researchers to examine these signals.

One of the diseases that occur in the brain and that can be detected by using EEG signals is epilepsy, the incidence of which is increasing day by day and may result in death or permanent damage due to limited opportunities. The existence of the dangers arising from these impossibilities has led researchers to propose low-cost assistant systems.

Within the scope of this study, we aimed to create an assistant approach in order to reduce the mistakes that the specialists can make due to environmental factors and to prevent the irreparable or unrecoverable mistakes that these mistakes may cause. In this direction, we aimed to analyze the data of healthy people and people with epilepsy by performing our study with two different data sets and to determine the states of the subjects as a result of these analyzes.

Within the scope of this study, we aimed to create an assistant approach in order to reduce the mistakes that the specialists can make due to environmental factors and to prevent the irreparable or unrecoverable mistakes that these mistakes may cause. In this direction, we aimed to analyze the data of healthy people and people with epilepsy by performing our study with two different data sets and to determine the states of the subjects as a result of these analyzes. For this purpose, we classified The Hauz Khas dataset and Bonn Epilepsy dataset, which is frequently used in the literature, by applying the deep learning methods Resnet-50, Resnet-101, AlexNet, GoogleNet and VGG-19 approaches to the datasets. However, we tried to increase the classification accuracy and thus the acceptability of the method by applying the Short Time Fourier Transform (STFT) and Continuous Wavelet Transform (CWT) methods to the data in order to subject the data to the classification process with sharper limits rather than taking the data in a raw way. At the end of the study, as a result of using CWT as a feature extraction method, we were able to classify the preictal and ictal moments on The Hauz Khas dataset at 100% with all classifiers. In addition, we achieved 100% success rate with all classifiers by using the CWT feature extraction method in binary classifications of the Bonn dataset. Finally, we achieved a classification success rate of 99,33% in the classification of the AB-CD-E group.

**Keywords:** CWT, Deep learning, EEG, Emotion analysis, STFT

## 1. GİRİŞ

Epilepsi, beyinde aniden gerçekleşen ve kontrolü sağlanamayan genel bazda etkisi çok uzun sürmese de nöbet esnasında nöbeti geçiren hasta üzerinde bıraktığı mevcut kasılma veya kontrolsüz hallerden (diş veya dil ısırma, kontrolsüz yere düşüşler, üst raddede gerçekleşen kasılmalar vb.) ötürü hasarlar bırakma ihtimali yüksek olan bir hastalık türü olarak tanımlanabilir (Duru ve ark., 2010; Çelebi ve Güllü, 2019). Bu kontrol dışı gerçekleşen nöbetlerin sonucuysa kimi zaman maruz kalan hastaların ölümüyle sonuçlanabilmektedir. Gelişmişlik durumunun tedavi imkanlarıyla doğru orantılı olduğu dünyada, düşük seviyede gelişmişlik oranına sahip ülkelerde yaşayan epilepsi hastalarının ölüm oranının bir hayli yüksek olduğu araştırmacılar tarafından paylaşılmıştır ve bu orandaki artışın en öne çıkan sebebiyse hastaların tedaviye olan uzaklıklarıdır (Pal ve ark., 2000). Ayrıca epilepsi beyinde gerçekleşen hastalıklar arasında en yaygın olanları arasında yerini almaktadır ve bu da hastalığı araştırmaların gündemine oturtmaktadır (Tzallas ve ark., 2009). Hastalık üzerine yapılan araştırmalar dünya nüfusunun %1'inin beyinde gerçekleşen bu bozukluklardan muzdarip olduğunu göstermektedir (Thijs ve ark., 2019). Paylaşılan istatistikler doğrultusunda dünya üzerinde hastalığın görülme oranının yıldan yıla artışının, epilepsi hastalığının literatürde önemli bir çalışma alanına sahip olmasında etkili bir faktör olduğu söylenebilir (Görgülü ve Fesci, 2011). Bu artış ve gelişmemiş ülkelerde bulunan maddi imkansızlıkların tedavilere olan erişimi zorlaştırması göz önünde bulundurulacak olursa epilepsi nöbetlerinin yardımcı fikirler aracılığıyla önceden teşhis edilmesi, hastalığın bırakabileceği kalıcı hasarlar ve ölümlerin azalması yönünde önemli bir etkiye sahip olabilir.

İnsanın doğası gereği yorumlama konusunda yeri geldiğinde hata yapma potansiyeli vardır. Bu hataların sebep olabileceği yanlış yönlendirmeleri azaltmak adına uzmanlara bir yardımcı fikir sunulabilir. Bu yardımcı fikirlerse araştırmacıları beyinden elde edilen ve Elektroensefalografi (EEG) olarak adlandırılan beyin sinyalleri üzerine yoğunlaşmaya itmektedir (Noachtar ve Remi, 2009). EEG beyinde gerçekleşen elektriksel aktiviteye bir ölçüt olarak kabul edilen ve beyinde gerçekleşen reaksiyonların sinyal bazlı izlenmesini sağlayan bir sinyal serisi olarak tanımlanabilir (Kirschstein ve Köhling, 2009). EEG sinyallerinden faydalanılarak epilepsi hastalarının nöbet esnasında beyinlerinde nasıl bir elektriksel aktiviteye sahip olduğu gözlemlenebilmektedir. Tanınmış olduğu gözlemlenebilme imkanı, EEG sinyallerinin epilepsi hastalarının bulunduğu

mevcut haller üzerine yapılan çalışmalarda sıklıkla tercih edilmesinin ana sebeplerinden biri olarak görülmektedir (Maganti ve Rutecki, 2013).

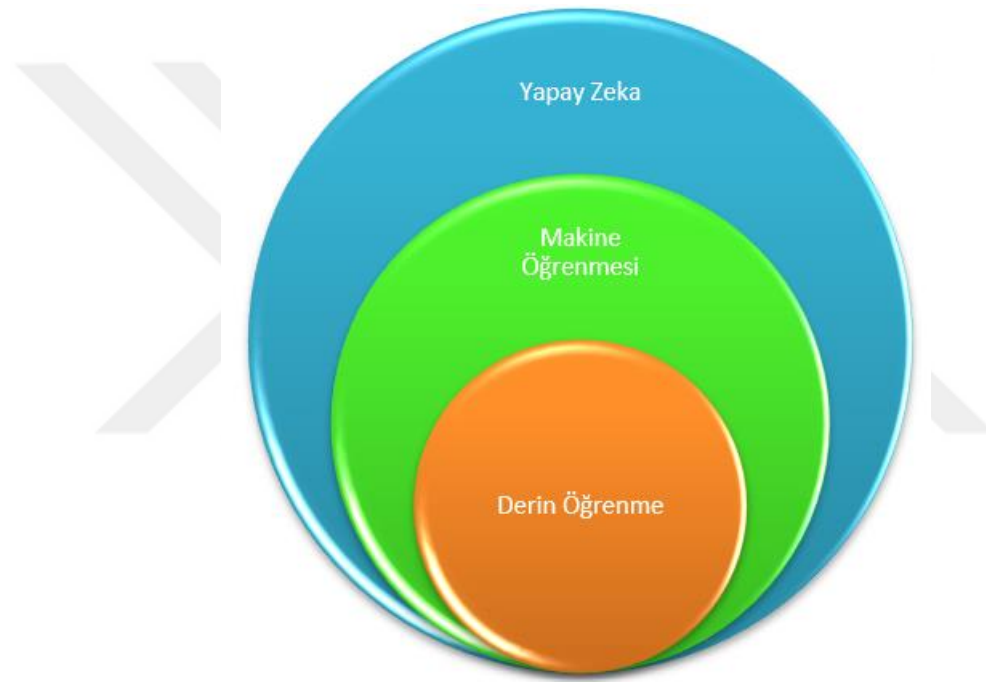
Yapay zeka yöntemlerinin bir hayli gelişme gösterdiği günümüzde EEG sinyalleri üzerinden birçok hastalık teşhisi veya nörolojik bozukların tespiti veya öngörüsü yapılabilmektedir (Hossain ve ark., 2019). Bu yöntemler aslında hastalık üzerine uzmanlaşan araştırmacıların çeşitli faktörlerden kaynaklı olarak yorumsal hatalara düşmemesi adına bir uyarıcı mekanizma olarak da değerlendirilebilir. İnsanın doğasında bulunan ve iç-dış etkenlere bağlı olarak gelişen dikkat dağınıklığından kaynaklı doğabilecek sorunları elimine etmenin bir yolu olarak da düşünülebilir. Bu yöntemlerinin tercih edilmesindeki temel faktörlerden bir diğeryse maliyet konusunda sunmuş olduğu avantajlardır (Kaur ve ark., 2021). Yukarıda da bahsedildiği gibi gelişmişlik oranı düşük ülkelerin epilepsi ve diğer ölümcül sonuçlara sebebiyet verebilecek hastalıklar konusunda özelleştirilmiş tedavi imkanlarının olmayışı, hastalarının imkansızlıklar sebebiyle ölümüne sebebiyet vermektedir. Bu sebeple EEG sinyallerinin analize olan yatkınlığı da düşünüldüğünde yapay zeka veya makine öğrenmesinin özelleştirilmiş alt bir dalı olarak nitelendirilen derin öğrenme yöntemleri, bahsedilen asistan fikirleri sunma adına tercih edilme oranı yüksek olan yollardan biri olarak literatürde birçok çalışmaya konu olmakta ve gün geçtikçe kullanım oranı da artış göstermektedir (Paul ve ark., 2018).

EEG sinyalleri yardımıyla epileptik nöbet teşhisi literatürde geniş bir çalışma alanına sahiptir ve bu konu üzerine yapılacak çalışmaların sıklaştırılması adına birçok veri seti de paylaşılmıştır. Paylaşılan bu veri setleri arasında en sık kullanılanları çocuklara ait EEG sinyal ölçümlerine içeren CHB-MIT, Freiburg Üniversitesi Epileptoloji Bölümü tarafından araştırmacıların kullanımına sunulan Freiburg veri seti ve Bonn Üniversitesi Epileptoloji bölümü tarafından kullanıma sunulmuş BONN veri setidir (Andrzejak ve ark., 2001; Shoeb, 2009; Andrzejak ve ark., 2012). Bu tez kapsamında yukarıda bahsedilen veri setlerinden biri olan BONN veri setine ek olarak The Hauz Khas Delhi veri seti üzerine de çeşitli çalışmalar gerçekleştirilmiştir.

Literatürde kullanılan birçok EEG veri setinde olduğu gibi her veri seti direkt olarak kullanıma hazır hale gelmeyeceği için birçok araştırmacı veri setlerine toplama esnasında meydana gelen gürültülerden kaynaklı olarak çeşitli filtreler uygulamaktadırlar. Bu gürültülerin temel sebebiyse elektriksel aktiviteden etkilenme ihtimali yüksek olan EEG toplama cihazlarında, dış etkenlere bağlı olarak oluşan bozukluklardır. Bu bozuklukların meydana geliyorsa çalışmayı gerçekleştirenleri kullanacakları sinyaller üzerine çeşitli iyileştirme yöntemlerine itmektedir. Bu işlem

yalnızca EEG sinyallerinde değil, sinyaller tarafından oluşturulan bütün veri topluluklarında genellikle kullanılan bir işlemdir (Tadeusiewicz, 2010).

Veri setlerinin elde edilmesinin yanında veri seti üzerine uygulanacak olan sınıflandırma yönteminin de elde edilecek sonuçlar üzerinde bir hayli etkisi vardır. Literatürde yapılan araştırmalara bakılacak olursa sınıflandırma işlemleri 2 başlık altında dallanmaktadır (Ongsulee, 2017). Bunların bir başlığı makine öğrenmesi yöntemlerinden oluşurken diğer başlık aslında makine öğrenmesinin bir alt dalı olmasına rağmen ayrı bir kategoriye konulan derin öğrenme yöntemleriyle sınıflandırma işlemidir. Yapay zeka yöntemleri tabanlı sınıflandırma işlemlerini Şekil 1.1’de gösterilen şekilde ifade etmek mümkündür.



Şekil 1.1. Yapay zeka tabanlı yöntemlerinin ilişkilendirilmesi

Şekil 1.1’de de görüldüğü üzere derin öğrenme algoritmaları, makine öğrenmesi algoritmalarının özelleştirilmiş bir alt dalıdır. Derin öğrenme algoritmalarını makine öğrenmesi yöntemlerinden ayıran en önemli fark ise öğrenme işlemini gerçekleştirmek için bir özellik çıkarım yöntemine gerek duymaksızın bünyesinde barındırdığı katmanlar yardımıyla transfer bir öğrenme işlemi gerçekleştirmesidir (Janiesch ve ark., 2021). Bu transfer öğrenme işleminin en büyük getirisiyse zaman ve işlem yüküdür. Ayrıca derin öğrenme algoritmalarının günümüzde yapılan çalışmalarda sıklıkla tercih edilmesinde bir diğer önemli husus ise büyük boyutlu verilerin analizinde bir hayli seri ve başarılı performans sergileyişidir (Tan ve ark., 2018). Bu işlemi gerçekleştirme potansiyelini kendisini oluşturan katmanlı yapıya borçlu olan derin öğrenme algoritmaları, öğrenme

işlemini tek bir katmanda gerçekleştirmektense veriyi parça parça öğrenerek düşük boyutlu veri topluluklarıyla işlem yapılmasını sağlar (Najafabadi ve ark., 2015).

Bu tez çalışmasında literatürde çalışma sıklığı açısından değerlendirildiğinde önemli bir yere sahip olan Bonn EEG epilepsi veri seti ve The Hauz Khas veri setinden faydalanılarak epilepsi hastalarının nöbet öncesi, nöbet hali ve nöbetsiz halinin yanı sıra sağlıklı bir insana ait EEG verileriyle epilepsi hastası olan insanlara ait EEG verilerinin sınıflandırılması işlemi gerçekleştirilmiştir. Bu sınıflandırma işlemi için 5 farklı derin öğrenme yöntemi kullanılmıştır. Bu yöntemler aşağıdaki şekilde sıralanabilir;

- Resnet-101
- Resnet-50
- Alexnet
- Googlenet
- VGG-19

Derin öğrenme algoritmaları tabanlı bu yöntemleri uygulamadan önce yöntemlerin öğrenme işlemini iyileştirmek adına eldeki verilere EEG sinyallerinden özellik çıkarmayı amaçlayan Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform, STFT) ve Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT) yöntemleri uygulanmıştır.

## 2. LİTERATÜR ARAŞTIRMASI

EEG sinyalleri yardımıyla epilepsi nöbetinin literatürde çalışılma sıklığı gün geçtikçe hastalığın insanlarda görülme sıklığına bağlı olarak daha da artmaktadır. Buna insan nüfusundaki artış büyük oranda etki etmektedir. Literatürde yapılmış çalışmaları ve bu çalışmalarda kullanılan özellik çıkarımı, sınıflandırma metodu ve performans kriterlerini inceleyelim.

Chua ve arkadaşları EEG sinyallerinden epilepsi nöbeti esnası ve nöbet öncesi tespitini yapmak adına gerçekleştirdikleri çalışmada yüksek dereceleri spektrumlardan faydalanarak özellik çıkarım yöntemi işlemini gerçekleştirmişlerdir. Ardından yazarlar veriyi sınıflandırmaya en uygun sınıflandırıcıyı tespit etmek adına geliştirmiş oldukları algoritmadan gelen bilgiler doğrultusunda sayısallaştırılmış ve sınıflandırmaya hazır hale gelen veriyi Gauss karışım modeli ve Destek Vektör Makineleri yöntemlerine tabi tutmuşlardır. Yazarlar nöbet ve öncesi olmak üzere iki farklı etiketlendirme üzerine yaptıkları sınıflandırmada Destek Vektör Makineleri yardımıyla %92,56 oranında bir başarı elde ederken Gauss karışım modelinde bu oranın %93,11 oranına yükseldiğini paylaşmışlardır (Chua ve ark., 2011).

Li ve arkadaşları yaptıkları çalışma kapsamında interiktal ve iktal durumunda olan epilepsi hastalarının tespitini yapmayı amaçlamışlardır. Yazarlar çalışma için kullanmış oldukları veri setini Bonn veri tabanından elde etmişlerdir. Veri seti 173.61 Hz frekansında örneklenen ve 500 tek kanallı EEG sinyalinden oluşan bir yapıya sahiptir. Ayrıca veri seti hasta ve sağlıklı denekleri göstermek adına 5 farklı grup içermektedir. O ve Z olarak nitelendirilen denekler sağlıklıyken; N, S ve F gruplarına ait denekler epilepsi hastalığına sahiptir. Epilepsi hastalığına sahip olan deneklerden de yalnızca S grubundaki deneklerin atak esnasında (iktal) verileri toplanmıştır. Geriye kalan iki gruptan toplanan sinyallerse nöbetsiz durumda alınmıştır. Veri setini elde eden yazarlar bu sinyalleri sayısallaştırıp sınıflandırma işlemine hazır hale getirmek adına Bulanık Entropi (FuzzyEn) ve Dağıtım Entropisi (DistEn) yöntemlerini uygulamışlardır. Ardından sınıflandırmaya uygun hale gelmiş veri setini, Karesel Ayrım Analizi (QDA) sınıflandırıcısına tabi tutan yazarlar, sınıflandırıcının performansını %92,80 olarak paylaşmışlardır (Li ve ark., 2018).

Bizopoulos ve arkadaşları EEG sinyalleri kullanarak epilepsi nöbeti üzerinin derin öğrenme yöntemleri yardımıyla teşhis edilmesi adına yaptıkları çalışmada, sinyalleri görüntüye çevirip sınıflandırma yöntemlerini bu görüntüler üzerinde denemeyi

amaçlayan bir yaklaşım sunmuşlardır. Yazarlar bu çalışmada Kaliforniya Üniversitesi Irvine Kampüsünün (UCI) kullanıma sunmuş olduğu 500 sinyal ve 4097 örnekten oluşan ve 5 farklı sınıfı bünyesinde barındıran bir veri setinden yararlanmışlardır. Bu veri seti sağlıklı ve epilepsi hastası olan deneklerin gözlerinin açık veya kapalı olduğu durumların etiketlenmesiyle oluşturulmuştur. Ayrıca yazarlar sundukları yaklaşım kapsamında sinyalleri 178 örneğe bölerek toplamda 11500 EEG sinyali barındıran kendi yaklaşımlarına has bir veri seti elde etmişlerdir. Yazarlar ardından kullanıma hazır hale yaklaştırdıkları veri setine, verileri sinyalden görüntüye çevirmek adına S2I yöntemini uygulamış ve veri setini istedikleri forma getirmişlerdir. Sonrasında eldeki görüntüleri LeNet, VGGnet, Alexnet, Resnet, Densenet yöntemlerine tabi tutan yazarlar bu evrişimli sinir ağı yöntemlerinden elde ettikleri sonuçları paylaşmıştır. Sonuçlar incelendiğinde en yüksek doğruluk oranının %85,30 ile Densenet yönteminin kullanılarak elde edildiği görülmektedir (Bizopoulos ve ark., 2019).

Park ve arkadaşları yapmış oldukları çalışma kapsamında derin öğrenme algoritmalarından istifade ederek epilepsi nöbeti geçiren insanların teşhisine dayalı yeni bir yaklaşım sunmaya çalışmışlardır. Yazarlar çalışmalarında Seul Üniversitesi Hastanesinde 54 denekten, 21 elektrot yardımıyla toplanmış olan ve 200 Hz örnekleme frekansına sahip olan bir veri setinden (SNUH-HYU EEG) yararlanmanın yanında Boston Çocuk Hastanesi bünyesinde toplanan ve 23'ü pediatrik hastalara 1'iyse erişkin bir hastaya ait 256 Hz örnekleme frekansına sahip ikinci bir veri setini (CHB-MIT EEG) de çalışmaları kapsamında kullanarak epilepsi nöbeti teşhisi işlemini gerçekleştirmeyi amaçlamışlardır. Yazarlar sinyalleri efektif olarak kullanabilmek adına Alçak Geçiren Filtre kullanmış ve bu filtrenin üst limitini sırasıyla 10-20-30 Hz olarak belirlemişlerdir. Yapılan bu işlemlerin ardından derin öğrenme algoritmalarına filtrelenmiş veriyi tabi tutan yazarlar, iki veri seti açısından da 30 Hz'lik filtreye tabi tutuldukları durumun en yüksek başarı oranını verdiğini paylaşmışlardır. Bu paylaşımlara göre yazarlar, SNUH-HYU EEG veri setinden % 90,5 oranında doğruluk elde ederken diğer veri seti üzerine uygulanan metodun doğruluk oranını % 85,6 olarak elde ettiklerini belirtmişlerdir (Park ve ark., 2018).

Türk ve Özerdem geliştirmeye çalıştıkları yöntem doğrultusunda ellerinde bulunan veri setine Sürekli Dalgacık Dönüşüm yöntemini uygulayarak epilepsi nöbeti teşhisinin yapay zeka yöntemleri yardımıyla yüksek doğrulukta sağlanabilmesini hedeflemişlerdir. Yazarlar kullandıkları veri setinin 10 parçadan oluşan ve 10-20 arasında değişen elektrottan gelen sinyallerden alınmış olduğunu belirtirken 23,6 saniyelik

sürelerden oluştuğunu da paylaşmışlardır. Veri setine 0,53-40 Hz aralığında bant geçiren filtre uygulayan yazarlar bu sayede ellerinde bulunan veri setini 173,61 Hz örnekleme frekansına sahip hale getirip, özellik çıkarım işlemine hazır hale getirmeyi amaçlamıştır. Ardından çalışmanın temel dayanaklarından olan veri setini CWT yardımıyla görselleştirme işlemi tamamlayan yazarlar, ellerinde bulunan resim kümelerine yapay zeka yöntemlerini uygulamışlardır. Bu bağlamda yazarlar 5 farklı denek grubunu içeren veri setinde genel sınıflandırma başarısını %93,60 olarak elde etmişlerdir (Türk ve Özerdem, 2019).

Ahmad ve arkadaşları yaptıkları çalışmada Boston Çocuk Hastanesi tarafından toplanan ve üzerine çeşitli çalışmalar gerçekleştirilmesi için paylaşımına sunulan CHB-MIT veri seti üzerinde epilepsi teşhisinin yapay zeka yöntemleriyle gerçekleştirilmesi adına bir yaklaşım sunmayı hedeflemişlerdir. Veri seti 24 denekten gelen EEG sinyallerinden oluşmaktadır ve 916 saatlik kayıt süresine sahiptir. Yazarlar bu veri seti üzerine Ayrık Dalgacık Dönüşümü (DWT) yöntemini uygulayarak sınıflandırma işleminin doğruluğunu artırmayı sağlayacak özellikleri elde etmeyi amaçlamışlardır. Ardından DWT uyguladıkları verilerden yazarlar ortalama, standart sapma gibi istatistiksel özellikleri çıkarmış ve Temel Bileşenler Analizi (PCA) adı verilen özellik seçim yöntemiyle de sınıflandırmaya etkisi olmayan verileri uzaklaştırarak veriyi optimal hale getirmişlerdir. Bu işlemlerin ardından verileri sınıflandırma işlemine tabi tutan yazarlar Destek Vektör Makineleri (DVM) yöntemiyle % 94,8 oranında bir ortalama doğruluk elde etmişlerdir (Ahmad ve ark., 2014).

Tian ve arkadaşları yaptığı çalışmada CHB-MIT veri setinden faydalanmış ve bu kapsamda epilepsi nöbeti teşhisine asistan fikir oluşturabilecek doğruluk oranlarında sonuçlar verecek bir yaklaşım sunmuştur. Yazarlar sinyallerden oluşan veri setini sayısallaştırıp üzerine sınıflandırma işleminin kendi sundukları yaklaşımlarla uygulanması adına öncelikle Evrişimsel Sinir Ağları (CNN) uygulayarak zaman ve frekans bazlı derin özellikleri elde etmeyi amaçlamışlardır. Ardından sık kullanılan makine öğrenmesi yöntemlerinden olan Destek Vektör Makineleri (SVM), K-En yakın komşular (KNN), Navie Bayes (NB) ve Karar Ağaçları (DT) yöntemlerinden yararlanarak sınıflandırma işlemi gerçekleştirmişlerdir. Yazarlar bu sınıflandırıcılardan sırasıyla %92,85, %93,31, %92,56 ve %91,66 doğruluk oranı elde ettiklerini paylaşmışlardır (Tian ve ark., 2019).

Nicolaou and Georgiou yaptıkları çalışma kapsamında Bonn Üniversitesi Epileptoloji Kliniği tarafından hazırlanmış ve akademik çalışmalara yardımcı olması

adına paylaşılmış olan ve 5'i sağlıklı, 5'i ise epilepsi hastalığına sahip deneklerden oluşan 173,61 Hz örnekleme frekansına sahip ayrıca 0,53 Hz ile 40 Hz arasında tutulması adına bant filtreden geçirilmiş veri üzerinde bir yaklaşım sunmuşlardır. Yazarlar sunulan yaklaşım doğrultusunda Permütasyon Entropisi (PE) özellik çıkarım yönteminin bu alanda ilk kez kullanıldığını ve amaçlarının bu yöntemin SVM sınıflandırıcısıyla kombine çalışarak nasıl bir başarı sağlayacağını araştırdıklarını açıklamışlardır. Özellik çıkarım PE yöntemi yardımıyla gerçekleştirdikten sonra sayısallaştırılmış EEG sinyali verisini SVM sınıflandırıcısına tabi tutan yazarlar, %93,55 oranında sınıflandırma doğruluğu elde ettiklerini paylaşmışlardır (Nicolaou ve Georgiou, 2012).

Parvez ve Paul, Almanda Freiburg Üniversite Hastanesinin Epilepsi Merkezinde epilepsi hastalarının ve sağlıklı deneklerin içinde bulunduğu bir grup insandan toplanmış olan 256 Hz örnekleme frekansına sahip veriler yardımıyla epilepsi hastalığına sahip deneklerin iktal ve interiktal durumda buldukları anların makine öğrenmesi yöntemleriyle tespiti üzerine bir yaklaşım sunmuşlardır. Yazarlar amaçları doğrultusunda öncelikle mevcut veri setine Ayrık Kosinüs Dönüşümü (DCT), DCT-DWT, İçsel Mod İşlevleri (IMF) ve Tekil Değer Ayrışımı (SVD) özellik çıkarım yöntemlerini uygulamış ve özgül bir yaklaşımla başarılı bir sınıflandırma gerçekleştirmeyi hedeflemişlerdir. Yazarlar veriden gereken özellikleri çıkardıktan sonra En küçük kareler SVM (LS-SVM) yöntemi yardımıyla mevcut veriyi sınıflandırma işlemini gerçekleştirmişlerdir. Bu doğrultuda yazarlar nöbet esnasında ve nöbet geçirmeyen hastaların tespitini %91,36 başarı oranıyla sağlayabilmiştir (Parvez ve Paul, 2014).

Zhang ve arkadaşları sundukları yaklaşım kapsamında örnek ve yaklaşık entropi olmak üzere Dalgacık Paket Ayrışımına ait 2 farklı özellik çıkarım yönteminden yararlanarak bu iki yöntemi SVM ve Aşırı Öğrenme Makinesi (ELM) sınıflandırıcılarıyla değerlendirmeyi hedeflemişlerdir. Bu amaç doğrultusunda yazarlar Beyin-Bilgisayar Arayüzü Laboratuvarında (BCI Lab) toplanıp araştırmacıların çalışmaları için kullanımına sunulan ve epilepsi nöbeti geçiren hastalardan standart bir şekilde toplanıp A, B, C, D, E olmak üzere 5 sınıfa ayrılan bir EEG veri setinden faydalanmışlardır. Yazarlar her bir sınıflandırıcıyı özellik çıkarımları üzerinde birer birer deneyerek sınıflandırıcı ve özellik çıkarım yöntemi kombinasyonu işlemini gerçekleştirmiştir. Bu deneyler nihayetindeyse yazarlar 5 farklı grubun tamamının sınıflandırılması konusunda en yüksek başarı oranını Örnek Entropi ve ELM yöntemlerinin kombinasyonu ile % 95,58 olarak elde etmiş ve uyguladıkları bu özgün yaklaşımı paylaşmışlardır (Zhang ve ark., 2015).

Kaya ve Ertuğrul yaptıkları çalışmada EEG sinyallerinin belirleyici özelliklerinin tespitinin sınıflandırma başarısını etkilemek adına bir yöntem sunmayı hedeflemişlerdir. Yazarlar bu kapsamda önceki çalışmalarda da bahsedilen BONN veri setinden faydalanmışlardır. Veri setini makine öğrenmesi algoritmalarına tabi tutmak isteyen yazarlar veriyi sayısallaştırmak adına öncelikle kendi önermiş oldukları görüntü işleme bazlı çalışan yerel üçlü desenler özellik çıkarım yönteminden faydalanmışlardır. Bu yöntem doğrultusunda alt ve üst öznitelikler olmak üzere iki farklı özellik grubu elde eden yazarlar, her bir öznitelik grubunu ayrı ayrı RF, DVM, BayesNet, Yapay Sinir Ağları (YSA), Kümeler ve fonksiyonel ağaçlar olmak üzere 6 farklı makine öğrenmesi tabanlı sınıflandırıcıya tabi tutmuşlardır. Sağlıklı ve epilepsi teşhisine sahip insanlardan alınıp A ile E arasında harflendirilen veri setinde yazarların ilk amacı epileptik nöbet geçiren hastaya ait olan E grubunu diğer gruplardan ayırt etmektir. Bu doğrultuda sağlıklı ve gözleri açık bir insana ait olan A grubuyla olan sınıflandırma işlemini %100 doğruluk oranıyla gerçekleştiren yazarlar bunun haricinde B, C, D gruplarının E grubu ile olan sınıflandırma işleminde sırasıyla %97,5, % 97,5, %94,5 oranında sınıflandırma başarıları elde etmişlerdir. Son olarak yazarlar, sağlıklı insandan alınan EEG verileri (A), epilepsi hastası deneklerden gözleri açık halde alınan EEG verileri (D) ve epileptik nöbet esnasında toplanmış EEG verilerinin kıyaslanmasındansa %95,7 oranında sınıflandırma başarısı elde etmişlerdir. Bu sonuçları alt öznitelikler yardımıyla elde eden yazarlar, üst öznitelikler yardımıyla elde ettikleri sonuçların da bu oranla yakın sınıflandırma başarı oranlarına sahip olduğunu paylaşmışlardır (Kaya ve Ertuğrul, 2018).

Roy ve arkadaşları derin öğrenme tabanlı epilepsi teşhisi üzerine geliştirmiş oldukları yöntem kapsamında Temple Üniversite Hastanesi (TUH) Anormal EEG Korpusu tarafından paylaşılan epilepsi veri setine üzerine bir yaklaşım sunmayı hedeflemişlerdir. Veri seti, boyut bakımından bugüne kadar paylaşılmış en büyük veri seti özelliğine sahiptir ve 1488 epilepsi hastasını içerisinde barındırırken 1529 sağlıklı denek de EEG sinyallerini içinde barındırmaktadır. Yazarlar bu kapsamlı veri setini eğitim ve test verilerine ayırmadan önce sinyallere dördüncü dereceden 0,01 Hz frekansa sahip Butterworth filtresi uygulayarak sinyalin sınıflandırılması işleminin doğruluğunu artırma yolunda bir yaklaşımda bulunmuşlardır. Ayrıca derin öğrenme algoritmalarının kendi çıkarmış olduğu derin özelliklere dayanarak da herhangi bir özellik çıkarım yöntemi uygulamadıkları veri setini 1 Boyutlu ve 7 katmana sahip CNN sınıflandırıcısına tabi tutan yazarlar, izledikleri bu yolun sonucunda %82,04 oranında sınıflandırma başarısı elde etmişlerdir (Roy ve ark., 2018).

Antoniades ve arkadaşları da epilepsi hastalarının yaşadığı nöbetlerin EEG sinyallerinden faydalanarak teşhisi üzerine derin öğrenme algoritmaları tabanlı bir çalışma gerçekleştirmişlerdir. Yazarlar King's College London Hastanesi'nde görev yapan bir epilepsi uzmanının hazırlanmış olduğu EEG sinyallerinden oluşan veri setini görüntüye çevirip ardından bu görüntülerden epilepsi nöbeti asistan görüş olabilecek bir tanı yöntemi geliştirmeyi hedeflemiştir. Bu kapsamda literatürde kullanım oranı yüksek olan sinyali spektograma çevirerek sınıflandırmaya tabi tutma işlemine başvurmuşlardır. Sinyalleri istedikleri şekilde görselleştirmeyi başaran yazarlar eldeki görüntüleri 2 Boyutlu CNN sınıflandırıcısıyla sınıflandırdığıdaysa %87,51 oranında başarı elde edebildiklerini paylaşmışlardır (Antoniades ve ark., 2016).

Yao ve arkadaşları epilepsi nöbeti geçiren ve nöbet geçirmiyor halde bulunan hastaların durumlarını teşhis etmek adına yapay zeka yöntemlerinin kolu olan derin öğrenme algoritmalarından faydalanmak üzerine bir çalışma gerçekleştirmişlerdir. Yazarlar bu çalışmadaki amaçlarından bir diğerinin Tekrarlayan Sinir Ağı (IndRNN) olarak adlandırılan yeni bir yaklaşımın bu konu üzerine göstereceği performansı test etmek olduğunu açıklamışlardır. Bu yaklaşımıysa yaşları 1,5 ila 22 yaş arasında değişen 23 denekten oluşan ve literatür taramasına dahil edilen diğer çalışmalarda da kullanılan CHB-MIT veri seti üzerinde denemeyi amaçlayan yazarlar, veri setinde birkaç eksik değer olduğunu belirterek bu eksikleri dikkate almadan çalışmayı ilerlettiklerini belirtmişlerdir. Herhangi bir özellik çıkarım yöntemi kullanmaya gerek duymayan yazarlar 6,9,12 ve 15 katmanlı IndRNN sınıflandırıcıları yardımıyla gerçekleştirdikleri sınıflandırma işlemlerinden sırasıyla %86,55, %86,05, %86,25 ve %87,00 oranında başarı elde etmişlerdir. Yazarlar bu sonuçla Uzun-Kısa Süreli Hafıza (LSTM) ve CNN algoritmalarında elde ettikleri başarı oranlarından daha yüksek başarı oranları elde ettiklerini de ayrıca belirtmişlerdir (Yao ve ark., 2019).

Wen ve Zhang yapmış oldukları çalışmada epilepsi teşhisi üzerine yeni bir yaklaşım sunmayı amaçlamışlardır. Yazarlar etiketlenmemiş halde bulunan EEG verilerini sundukları yöntem doğrultusunda denetimsiz bir özellik öğrenim yolu izleyerek Derin Evrişim Ağlarıyla kombine ederek başarılı bir sınıflandırma işlemi gerçekleştirme hedefleri doğrultusunda 2 farklı veri setinden yararlanmışlardır. Bunlar literatürde sıklıkla denk geldiğimiz CHB-MIT ve Bonn veri setleridir. Önceki araştırmalarda bu veri setlerinin içeriklerinden bahsedilmiştir. Yazarlar EEG sinyallerinin alındığı kanalları filtreleyerek bir nevi özellik seçimi yapma yöntemi izlemişlerdir. Bu bağlamdaysa kanallardan gelen dalgalanmaların şiddetini baza aldılar ve FT9 ve FT10 kanalından

gelen verilerin istenilen dalgalanma seviyesinde olduğuna kanaat getirerek bu kanallardan gelen sinyallerden 200'er adet epileptik ve epileptik olmayan örnek aldılar. Ardından yazarlar bu verileri kendi geliştirmiş oldukları Otomatik Kodlayıcı Tabanlı Derin Evrişim Ağı (AE-CDNN) yöntemiyle sınıflandırma işlemine aldılar. Bu sınıflandırmanın sonucundaysa %92 oranında başarı elde ederek geliştirmiş oldukları yöntemin kabul edilebilirliğini gözler önüne serdiler (Wen ve Zhang, 2018).

Thomas ve arkadaşları derin öğrenme ve makine öğrenmesinin birlikte çalıştığı bir sistem tasarlamayı öngörerek EEG sinyallerinden epilepsi nöbeti teşhisi yapmayı amaçlayan bir yaklaşım sunmuşlardır. Yazarlar yaklaşımlarında içerisinde 93'ü epilepsi hastalığına sahip 63'üye sağlıklı olacak şekilde 156 deneğe ait EEG verilerini barındıran, Massachusetts General Hospital (MGH) tarafından toplanmış veri setini kullanmayı uygun görmüşlerdir. Veri setine verilen kararın ardından verileri efektif bir şekilde kullanabilmek ve veriden kaynaklı sorunları giderebilmek adına örtüşme engelleyici filtre kullanmayı tercih eden yazarlar, bu işlemin ardından veriyi 128 Hz frekansta alt örnekleme işlemine tabi tutmuştur. Sonrasındaysa tek katmanlı bir CNN yardımıyla sinyallerden özellik çıkarımı işlemini gerçekleştiren yazarlar, sayısallaştırılmış bu veriyi SVM sınıflandırıcısı yardımıyla sınıflandırdı ve %83,86 oranında doğruluk etti (Thomas ve ark., 2018).

Ahmedt-Aristizabal ve arkadaşları yaptıkları çalışmada LSTM ve derin öğrenme algoritmalarından olan Tekrarlayan Sinir Ağları arasında kombine bir çalışma yürüterek EEG sinyallerinin epilepsi hastalarına ait olup olmadığını denetleyen asistan bir sistem tasarlamayı amaçlamışlardır. Yazarların yaklaşımlarındaki öncelikli amaçlarından biri verilerin ham haliyle yapılan özellik çıkarım işleminin de başarılı olabileceğini sundukları yöntem doğrultusunda gösterebilmektir. Ayrıca bir diğer hedefleriye az bellek tüketip hesaplama işlemlerini de minimize ederek sınıflandırma işlemi gerçekleştirmektir. Çünkü bu sisteme hız kazandıracak ve zamandan tasarruf sağlanmasını sağlayacaktır. Yazarlar elde ettikleri sonuçlar doğrultusunda sistemlerinin epilepsi hastalarının teşhisinde %95,54 oranında başarı sağladığını paylaşmış ve derin öğrenme algoritmalarının klinik uygulamalarda daha fazla yer edinmesi üzerine bir dayanak niteliğinde bir çalışma gerçekleştirdiklerini belirtmişlerdir (Aristizabal ve ark., 2018).

Yuan ve arkadaşları sunmuş oldukları yaklaşım kapsamında epilepsi nöbetinin başlangıcının öngörülebilmesi adına yardımcı fikir oluşturabilecek bir çalışma gerçekleştirmiştir. Yazarlar bu bağlamda sık bir kullanıma sahip olan CHB-MIT veri setinden faydalanmıştır. Veri seti üzerine öncelikle sinyal segmentasyonu işlemlerini

uygulayan yazarlar sonrasında çalışmalarının temel dayanaklarından olan Kısa Süreli Fourier Dönüşümü (STFT) yardımıyla sinyallerini spektrograma çevirmiş ve resim olarak kaydederek derin öğrenme algoritmalarının sınıflandırma işlemine müsait hale getirmişlerdir. Yazarlar yalnızca spektrogramla kalmayıp kanallar arası bir korelasyon yaklaşımı yardımıyla özellik elde etmiştir. Son olarak da sınıflandırma performansını etkilemeyen ve sistemin yükünü artıran kanalların veri setinden arındırılması adına bir seçim gerçekleştirmiş ve 3 farklı özelliği kombine ederek eldeki mevcut veri setini Yığılmış Seyrek Gürültü Giderici Otomatik Kodlayıcılar (SSDA) metoduna tabi tutmuş ve % 93,82 oranında başarılı bir sınıflandırma işlemi gerçekleştirmişlerdir (Yuan ve ark., 2017).

Hosseini ve arkadaşları epilepsi hastalarının hayatında büyük bir kolaylık sağlayacağını düşündükleri EEG sinyalleri üzerinden epilepsi nöbeti tahminlemesi üzerine bir çalışma gerçekleştirmişlerdir. Yazarlar çalışmalarında Amerikan Epilepsi Derneği sponsorluğunda toplanmış ve 60 interiktal, 60 preiktal olmak üzere 2 farklı gruptan oluşan bir veri seti üzerine çalışma yapmayı tercih etmişlerdir. Yazarların amaçlarından biriye uğraşmış oldukları verinin kapladığı büyük boyutun etkilerini azaltmak adına bir bulut sistemi geliştirmek ve çalışmaları bu bulut aracılığıyla gerçekleştirmektir. Bu amaç doğrultusunda yazarlar öncelikle bir Beyin-Bilgisayar Arayüzü tasarlamış ve sonrasında verilere boyut indirgeme işlemini uygulamışlardır. Yazarlar boyut indirgeme tekniğini işlem yükünü azaltıp hızı artırmanın yanında sınıflandırma doğruluğunu artırmak için de tercih etmişlerdir. Makine öğrenmesi teknikleri ve kendi sunmuş oldukları model arasında kıyaslama yapmak adına SVM ve Random Forest yöntemlerinden de faydalanan yazarlar, kullanmış oldukları büyük veri üzerinde yaptıkları sınıflandırma işleminde makine öğrenmesi yöntemleriyle maksimum %75 oranında doğruluk oranı elde ederken bu oranın kendi sundukları yöntem kapsamında %94 oranına yükseldiğini belirtmişlerdir (Hosseini ve ark., 2016).

Yuan ve arkadaşları EEG sinyallerinden otomatik bir şekilde epilepsi nöbeti tespit etme işlemini gerçekleştirerek hastalarının hayatını kolaylaştırmayı hedefledikleri çalışmada bir önceki çalışmalarında da bahsedilen CHB-MIT veri setinden faydalanmışlardır. Yazarların sunmuş oldukları bu yaklaşımdaki temel amacı birkaç yöntemin kombinasyonunun bu tespit algoritmasının doğruluğuna olan etkisini araştırmaktır. Bu kapsamda yazarlar çoklu görüntü özelliklerini harmanlayıp öğrenme kabiliyetini geliştiren bir yöntem öngörerek sınıflandırıcının eğitim konusunda güçlenmesini sağlayıp sistemin başarı oranının artırılmasını amaçlamıştır. Yazarlar eldeki

veri setine öncelikle otomatik kodlayıcıları gürültüden arındırma (DA) yöntemini uygulayarak sinyallerde öğrenmeyi olumsuz etkileyecek bölgeleri veriden uzaklaştırmış ardından da arındırılmış veri setine STFT yöntemini uygulayarak sinyalleri görsel bir tabana aktarmıştır. Ardından Otomatik Kodlayıcı Tabanlı CNN (CNN-AE) yardımıyla sınıflandırma işlemini gerçekleştirdikleri veriden %94,37 oranında sınıflandırma başarısı elde etmişlerdir (Yuan ve ark., 2018).

Acharya ve arkadaşları yapmış oldukları çalışmada epilepsi hastalarının içerisinde bulunduğu nöbet hali, nöbet öncesi ve normal halleri tespit etmek adına makine öğrenmesi yöntemlerine nazaran daha iyi etki edebileceğini düşündükleri 13 katmanlı bir CNN derin öğrenme sınıflandırıcısından faydalanmışlardır. Yazarlar literatürde üzerine yapılan çalışmalarla yer edinmiş olan Bonn veri setinden faydalanmışlardır. Veriyi optimize etmek sınıflandırıcıya tabi tutmadan önce Z skor normalizasyonu, standart sapma ve sıfır ortalama yöntemleri yardımıyla ön işlemden geçirip optimize eden yazarlar bu sayede veriler içerisinde bulunan ve eğitimin yanlış gerçekleştirilmesini etkileyecek veri düzensizliklerini minimize etmeyi amaçlamıştır. Sınıflandırmaya hazır hale gelmiş veri setine 13 katmanlı CNN derin öğrenme algoritmasını uygulayan yazarlar, çalışmanın sonunda %88,67 doğruluk oranına ulaştıklarını paylaşmışlardır (Acharya ve ark., 2018).

Zhao ve arkadaşları yapmış oldukları çalışmada hekimlerin tespitlerini asiste edebilmesi adına bir yaklaşım sunmayı hedeflemişlerdir ve bu yaklaşımda makine öğrenmesi ve özellik çıkarım yöntemlerinin aldığı zamandan kurtulabilmek adına da derin öğrenme yöntemlerinden olan ve kendi öğrenme algoritması sayesinde işlemleri hızlandırıp kolaylaştıran tek boyutlu CNN (1D-CNN) yönteminden faydalanmışlardır. Yazarlar sunmuş oldukları yaklaşımı Barcelona ve İsviçre arasında gerçekleşen ortak bir çalışma aracılığıyla toplanmış Bern-Barcelona iEEG veri seti üzerinde test etmişlerdir. Veri setinin içinde barındırdığı 15000 örnek yazarların derin öğrenme algoritmalarının kendi bünyesinde barındırdığı öğrenme algoritmalarının süreci hızlandırdığını gösterebilmesi adına da bir dayanak teşkil etmektedir. Yazarlar veriye 0,5 Hz ile 150 Hz aralığında bir Butterworth filtresi uyguladıktan sonra DA yöntemi yardımıyla veriyi 1D-CNN yöntemine tabi tutmuşlardır ve %89,28'lik başarı oranıyla çalışma kapsamında kullanmış oldukları makine öğrenmesi yöntemlerinden daha yüksek bir doğruluk oranı elde ederek 1D-CNN yönteminin büyük verilerde makine öğrenmesi yöntemleriyle olan kıyaslamasını paylaşmıştır (Zhao ve ark., 2020).

Sagga ve arkadaşları yapmış oldukları çalışma doğrultusunda CHB-MIT veri seti aracılığıyla epilepsi hastalığına sahip insanların nöbet tahminlemesini yaparak nöbet

esnasında hastanın kontrolsüz halinden kaynaklı olarak meydana gelebilecek zararları önleyebilmek adına derin öğrenme tabanlı sınıflandırıcılar aracılığıyla bir yaklaşım sunmuşlardır. Yazarlar bu bağlamda veri setindeki EEG sinyallerine 1 katmanlı CNN uygulayarak modeli bir ön eğitim aşamasına tabi tutmuşlardır. Ardından yazarlar önden CNN yöntemiyle eğitilmiş veriye Resnet ve VGGNet sınıflandırıcılarını uygulamışlardır. Bu işlemler sonucunda yazarlar Resnet ve VGGNet sınıflandırıcılarından sırasıyla %97,6 ve %97,32 oranında sınıflandırma başarısı elde ettiklerini paylaşmışlardır (Sagga ve ark., 2020).

Malekzadeh ve arkadaşları yapmış oldukları çalışma kapsamında Bonn veri seti üzerine detaylı bir yaklaşımda bulunmuşlardır. Yazarlar veri setinin A, B, C, D, E gruplarını öncelikle A-E, B-E, C-E, D-E, ABCD-E, AB-CD-E olacak şekilde 6 farklı durum için sınıflandırmayı amaçlamıştır. Yazarlar öncelikle veri setindeki EEG sinyal verilerinden istatistiksel özellikleri (ortalama, varyans, kurtosis, skewness, standart sapma vb.) çıkarmak adına bir özellik çıkarma işlemi uygulamıştır. Ardından frekans bazlı özellikleri elde etmek adına Yoğunluk Ağırlıklı Ortalama Frekans (IWMF) yöntemini uygulamışlardır. Son olarak da entropi özelliklerinin elde edilmesi adına da birkaç yöntemden faydalanarak özellik çıkarım işlemini gerçekleştirmişlerdir. Yazarlar elde edilen bu özelliklerden oluşan veri gruplarını SVM, KNN ve CNN tabanlı SVM (CNN-SVM) sınıflandırıcılarına tabi tutmuştur. Bu işlemler sonucunda en yüksek başarımın CNN-SVM sınıflandırıcısı kullanılarak elde edildiği görülmüş ve A-E, B-E, C-E, D-E, ABCD-E, AB-CD-E grupları için sırasıyla %99,61, %99,46, %99,51, %99,82, %99,78, %99,71 oranında sınıflandırma başarısı elde etmişlerdir. Yazarlar çıkarılan onlarca özelliğe kıyasla CNN tabanlı evrimsel olarak özellik çıkarıcı bir yöntemle başvurulmasının sınıflandırmaya olan etkisi göstermişlerdir (Malekzadeh ve ark., 2021).

Ullah ve arkadaşları EEG sinyalleri yardımıyla geliştirilen epilepsi teşhisi için sunmuş oldukları araştırmada sıklıkla çalışmalarda görülen Bonn veri setinden faydalanmışlardır. Yazarlar bu veri seti kapsamında en çok kullanılan ve A-E, B-E, C-E, D-E ve AB-CD-E gruplandırması üzerine gerçekleştirmek istedikleri sınıflandırma işleminde 1D-CNN modelinden faydalanmışlardır. Veriyi 10 katlı çapraz doğrulama işlemi yardımıyla zenginleştirerek öğrenme aşamasını güçlendirmeyi hedefleyen yazarlar 1D-CNN yöntemini önden eğitebilmek adına gelenekselleşmiş olan çapraz entropi kaybı fonksiyonlu geri yayılım tekniğini ve Adam optimizasyonu yardımıyla da gradyan iniş yaklaşımını kullanmış ve sınıflandırıcıyı önden eğitme işlemini tamamlamıştır. Ardından

yukarıda bahsedilen veri gruplarından sırasıyla %100, %99,6, %98,5, %98,8 ve %94,33 oranında sınıflandırma başarısı elde etmişlerdir (Ullah ve ark., 2018).

Ramakrishnan ve Muthanatha literatürde popüleritesi yüksek olan Bonn veri seti ve CHB-MIT veri seti üzerine gerçekleştirdikleri çalışma kapsamında CNN yöntemi yardımıyla sınıflandırma işlemi gerçekleştirip sonuçlarının yapılan çalışmalarla karşılaştırılması amacı doğrultusunda bir yaklaşım sundular. Yazarlar öncelikle veri setinden zaman ve frekans bazlı özellikler çıkarmak adına özellik çıkarım yöntemleri uyguladılar ve böylelikle zaten transfer öğrenme yardımıyla öğrenme işlemini gerçekleştiren CNN algoritmasına daha optimal bir veri sağlamış oldular. Yazarlar Bonn veri setine ait verileri A-E, AB-E, AC-E, A-D-E ve AB-CD-E gruplarına ayırarak sınıflandırırken CHB-MIT veri setini A-B gruplarına ayırarak sınıflandırmayı amaçladılar. Bu bağlamda elde edilen sonuçlar doğrultusunda CHB-MIT veri setinin sınıflandırılmasından %98,34 oranında sınıflandırma başarısı elde edildiği paylaşılırken Bonn veri setinin yukarıda verilen gruplarından sırasıyla %99,57, %98,95, %98,63, %98,57 ve %98,37 oranında sınıflandırma başarısı elde edildiği paylaşılmıştır (Ramakrishnan ve Muthanatha., 2019).

### **3. MATERYAL VE METOT**

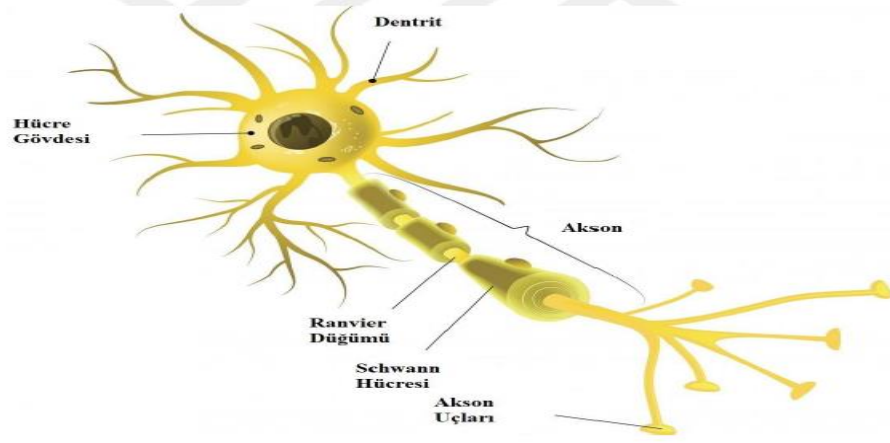
#### **3.1. Beynin Yapısı**

Beyin, kafatasının çeperlemiş olduđu ve her biri farklı görevleri üstlenen iki farklı yarım küreden (sağ-sol) kıvrımlı yapıya sahip bir organdır (DeArmond ve ark., 1989). Bu iki yarım küre her ne kadar farklı işlevleri yerine getiriyor olsa da aralarında bir bağlantı her daim mevcuttur ve beyin arada kopuklukların oluşması halinde vücudun işleyişini en yüksek oranda etkileyen organ olarak da bilinmektedir. Bahsedilen iki yarım küreyi birbirine bağlayan yapı bünyesinde barındırdığı milyonlarca liften oluşmakta ve Corpus callosum olarak anılmaktadır (Gooijers ve Swinnen, 2014). Bunun haricinde beyin görevini yerine getirmesi adına elektriksel sinyalleri de taşıyan milyarlarca sinir hücresi (nöron) mevcuttur. Bu sinirsel yapı aslında Yapay Zeka yöntemlerinin doğmasında esinlenen yapı olarak da bilinmektedir (Fan ve ark., 2020).

##### **3.1.1. Nöronlar**

Nöronlar genel yapısı itibariyle beyin ve buna bağlı olarak da vücudun işleyişinin düzenli bir şekilde ilerlemesindeki en temel birim sayılmaktadır. Çünkü nöronların temel görevi bilgiyi istenilen bölgeye taşıma işlemini gerçekleştirmektir. Böylesine kritik bir göreve sahip olan nöronlar, beyin tarafından organlara nasıl davranmaları gerektiği bilgisi aktararak fiziksel etkilerin meydana gelmesine aracılık sağlar (Grafstein, 1975).

Beynin yapısına bakılacak olduğunda nöronların beyni sarıp sarmaladığı açık bir şekilde görülmektedir. Nöronlar temel olarak 3 bölümden oluşmaktadır. Bunlar hücre gövdesi, akson ve dendritler olarak sıralanabilir. Bu tez kapsamında da ilgilenilen EEG sinyallerinin oluştuđu bölümler akson olarak adlandırılan bölümlerdir. Aksonlar taşımış olduğu bilgiyi elektrokimyasal yollarla iletmekle yükümlü olan bölümdür ve bunu sinapslar aracılığıyla gerçekleştirir. Şekil 3.1’de bir nöronun temel bölümlerine yer verilmiştir.



Şekil 3.1. Bir nötronun temel yapısı

### 3.1.2 Elektroensefalografi


Elektroensefalografi, yani bilinen haliyle EEG, beynin elektriksel aktivitesini ölçmek ve kaydetmek için kullanılan bir tekniktir. Beynin elektriksel aktivitesi, nöronların ateşlenmesiyle üretilir ve kafa derisine yerleştirilen elektrotlar kullanılarak tespit edilebilir (Takahashi ve ark., 2009).

#### 3.1.2.1. EEG verilerinin toplanması

Bir EEG prosedürü sırasında, bir teknisyen iletken bir jel veya macun kullanarak kafa derisine küçük metal elektrotlar bağlarken, teste tabi tutulan kişi tipik olarak oturur veya uzanır. Bu elektrotlar, 10-20 sistemi adı verilen uluslararası bir standarda göre kafa derisi üzerindeki belirli konumlara stratejik olarak yerleştirilir. Elektrotlar, beyinden gelen elektrik sinyallerini algılayan ve güçlendiren bir amplifikasyon sistemine bağlanır.

##### 3.1.2.1.1. 10-20 Elektrot sistemi yardımıyla EEG sinyallerinin toplanması

10-20 sistemi yardımıyla EEG sinyallerinin toplanması işlemi, alanında en yaygın olarak kullanılan toplama yöntemidir. Bu yöntemin yaygınlığının yüksek olmasını sağlayan ana faktörler arasında elektrotların kafa derisine yerleşiminin düzenli ve tutarlı bir şekilde gerçekleştirilmesinden kaynaklı olarak güvenilir sonuçlar içermesidir. Bu güvenilirlikse bu sinyal toplama yöntemini literatürde standart hale getirmiştir (Morley ve ark., 2016). Şekil 3.2’de 10-20 sistemine göre elektrotların yerleşimi ve harflendirilmesi işleminin nasıl gerçekleştiği gösterilmiştir.



Şekil 3.2. 10-20 sistemi elektrok dağılımı

Elektrotları yukarıdaki düzene getirmek adına öncelikle baş çevresi ölçülür ve bu ölçüm esnasında referans alınan noktalar Şekil 1.3'te de görüldüğü gibi inion (başın arka bölümündeki tümsek) ve nasion (burun köprüsü) olarak adlandırılan iki noktadır (Khazi, Kumar, Vidya, 2012). Çevre hesaplamasının gerçekleşmesinin ardından elektrotlar saçlı deriye beynin Frontal (F), Central (C), Paryetal (P) ve Oksipital (O) bölgelerine denk gelen bölgelerin baş harfleriyle harflendirilerek (F, C, P, O) yerleştirilir. Harflendirmelerin ardından sayı atama işlemiyse kafatasının sol yarım küresindeki noktalarda tek sayı; kafatasının sağ yarım küresindeki noktalara uzaklıklarına bağlı olarak çift sayı ataması yapılarak gerçekleştirilir. Kafatasının orta bölümüne denk gelen bölgelerse 'z' harfi ile temsil edilir. Bu temsili 'z' yerleştirmeleri ek elektrot yerleşimine gerek duyulduğu durumlarda kullanılmaktadır (Jasper, 1958).


Güçlendirilmiş sinyaller daha sonra elektroensefalogram olarak bilinen bir dizi dalga formu olarak kaydedilir ve görüntülenir. Bu dalga biçimleri, beyindeki milyonlarca nöronun toplu elektriksel aktivitesini temsil eder. EEG, frekans ve genlik bakımından değişen ve farklı beyin aktivitesi durumlarıyla ilişkili olan alfa, beta, delta ve teta dalgaları gibi farklı beyin dalgalarını gösterebilir. Bu dalgaları ayrı ayrı inceleyecek olursak eğer;

**Alfa dalgaları:** Bu dalga tipi kişinin uyanık halinden elde edilmiş ve 8-12 Hz frekans aralığına sahiptir. Bu dalga tipinden kişinin gevşeme, sakinlik hallerinde bulunduğu çıkarımı yapılabilir (Bazanova ve Vernon, 2014).

**Beta dalgaları:** 12-30 Hz bandındaki frekans aralığıyla alfa dalgalarına nazaran daha yüksek frekans değerlerine sahip olan beta dalgaları kişinin odaklanma halinde beliren dalga tipi olarak tanımlanabilir. Yani beta dalgaları kontrasyon odaklı olarak belirmektedir (Perlis ve ark., 2001).

Gamma dalgaları: Gamma dalgaları frekans değeri 30-100 Hz bandında değişen ve bilginin beynin bölgelerine dağıtımının gerçekleştiğinin temsilcisi olan dalga türüdür. Hafıza ve algının içerisinde bulunduğu aktiviteler gamma dalgalarının oluşumunu tetikler (Herrmann ve Demiralp, 2005).

Teta dalgaları: Vücutta gerçekleşen aktivitelere bağlı olarak ortaya çıkan diğer 3 dalga türüne nazaran en düşük frekans bandına sahip olan teta dalgaları 4-12 Hz bandında değişim göstermektedir. Frekanstaki yükselişin aktivitesel bazda bir canlılık ifade ettiği öngörüsünden yola çıkarak teta dalgalarının rahatlık sonucunda oluşan alfa dalgalarından bir düzey üstte bir rahatlık anında ortaya çıktığını söylemek mümkündür (Schacter, 1977). Şekil 3.3'te yukarıda bahsedilen dalga türlerinin her birine ait birer örnek verilmiştir (Url-1).



Şekil 3.3. EEG sinyal türlerine ait örnekler

Şekil 3.3'te de görüldüğü üzere beynin elektrokimyasal yöntemlerle ilettiği mesajlar aracılığıyla vücutta fiziksel aktiviteler gerçekleşmektedir. Bu da aslında bu mesaj iletiminin kesintisiz bir şekilde devam etmesinin insan hayatında ne kadar büyük bir yere sahip olduğunun göstergesidir. Nöronlar arası bu ileti işlemindeki aksamaların insanlara nörolojik hastalıklar olarak dönebileceği de açıkça görülmektedir (Chen ve Berry, 2003). Beyindeki haberleşmenin aksamasından kaynaklı olarak oluşan hastalıklar birçoğu EEG sinyallerinde meydana gelene bozukluklar aracılığıyla tespit edilebilmektedir.

### **3.1.2.2. EEG Verileri yardımıyla hastalık teşhisi**

EEG, epilepsi, uyku bozuklukları, beyin tümörleri, beyin yaralanmaları ve belirli psikiyatrik bozukluklar dahil olmak üzere çeşitli nörolojik durumları ve bozuklukları teşhis etmeye ve izlemeye yardımcı olmak için klinik ortamlarda yaygın olarak kullanılan invazif olmayan ve ağrısız bir prosedürdür (Binnie, Prior, 1994). Sağlıklı bireylerde veya belirli koşullara sahip kişilerde beyin fonksiyonlarını ve aktivite modellerini incelemek için araştırmalarda da kullanılabilir (Smith, 2005). Şimdi bu hastalıkları ve EEG ile olan ilişkilerini yüzeysel bir şekilde inceleyelim.

#### **3.1.2.2.1. Epilepsi**

Epilepsi beyinde aniden aktivitesel bazda patlamalar olarak gerçekleşen ve bunu düzensiz bir tekrarla sürekli hale getiren bir nörolojik hastalıktır. EEG sinyalleri beyinde gerçekleşen bu anormal aktivitenin sinyallere yansımaları gözlemlememizi sağlayan en ideal araç olarak görülmektedir. EEG sinyallerinden yola çıkarak epilepsi nöbeti geçiren bir hastanın nöbet tipini ve beyinde nerede gerçekleştiğini bulmamız mümkündür (Rossi ve ark., 1995).

#### **3.1.2.2.2. Uyku bozuklukları**

Uyku esnasında elde edilen elektriksel sinyaller yani EEG verileri bize kişinin uykunun hangi evresinde olduğunu ve uyku düzenini tespit etme imkanı tanımaktadır. Bunun yanında kişinin uyku esnasında hangi aşamaları sorunlu bir şekilde geçirdiğini tespit edebilmek de araştırmacılara insan hayatını doğrudan etkileyen uykunun verimli bir şekilde gerçekleşmesi üzerine soruna yönelik tedavi uygulama şansı sunmaktadır. Uykuda gerçekleşen ve EEG ile tespit edilen uyku hastalıkları arasında en yaygın olanları uyku apnesi, narkolepsi ve sirkadiyen ritim bozuklukları olarak sıralanabilir (Cho ve ark., 2006).

#### **3.1.2.2.3. Beyin tümörleri**

Her ne kadar beyin tümörlerinin tespitinde birincil yöntem olarak tercih edilen yol beyin tomografisi gibi görselleştirmeyi baza alan yöntemlerden geçse de EEG sinyalleri de beyinde oluşan tümör ve lezyonları hakkında bilgi verme potansiyeline sahiptir.

Beyin tümöründen kaynaklı olarak gerçekleşen çeşitli epileptik aktiviteler gerçekleşen aktivitenin tümör bazlı olduğu hakkında bilgi verebilir. Bu elektriksel aktivitenin alındığı bölge tümörün konumu ve boyutu hakkında bilgi verebilir. Bunun yanında çeşitli tümör veya lezyon ameliyatlarından önce çıkarılacak olan bölgenin oluşturabileceği sorunların öngörülmesi açısından kaydedilen EEG sinyallerinden faydalanılabilir (Sharanreddy ve Kulkarni, 2013). Bu yöntem her ne kadar tümör tespiti için Manyetik Rezonans Görüntüleme (MRG) yöntemi kadar kullanışlı olmasa da tümör kaynaklı gerçekleşene epileptik bir atağın yorumlanmasıyla tümör oluşumu analizinin yapılmasına ön ayak olacak asistan bir yaklaşım olarak değerlendirilebilir.

## **3.2. Materyal**

### **3.2.1. Kullanılan sistem**

Bu tez kapsamında çalışmalar MATLAB Deep Network Designer modülü içerisinde bulunan sınıflandırıcılar aracılığıyla gerçekleştirilmiştir. Çalışmalar i5 işlemcili 16 GB Ram belleğine ve maksimum 4,4 GHz çalışma kapasitene sahip bir dizüstü bilgisayarda gerçekleştirilmiştir.

### **3.2.2. Veri seti**

Bu tez çalışmasında sonuçların iki adımlı denetlenmesini gerçekleştirmek adına The Hauz Khas Delhi veri seti ve Bonn veri seti olmak üzere iki farklı veri setinden faydalanılmıştır.

#### **3.2.2.1. Bonn veri seti**

Bonn Üniversitesi EEG veri tabanı olarak da bilinen Bonn Epilepsi veri seti, epilepsi araştırmaları alanında yaygın olarak kullanılan bir veri setidir. Epilepsi hastalarından elde edilen Elektroensefalogram (EEG) kayıtlarının bir koleksiyonudur. Veri seti, Almanya'daki Bonn Üniversitesi Tıp Merkezi'ndeki Epileptoloji Bölümü tarafından derlenmiştir. Kullanılan veri setine ait genel bilgiler aşağıdaki gibi derlenmiştir (Andrzejak ve ark., 2001).

Amaç: Veri seti, otomatik nöbet tespiti ve sınıflandırması için algoritma ve modellerin geliştirilmesini ve değerlendirilmesini desteklemek üzere oluşturulmuştur. Bu bağlamda düşünüldüğünde üzerine yapılacak çalışmalar göz önüne alınırsa literatüre

geniş bir katkı sağlama potansiyeli yüksektir ve literatürdeki epilepsi tespiti çalışmalarında sıklıkla kullanılıyor olması da bunu destekler niteliktedir.

**Veri Toplama:** Bonn Epilepsi veri setindeki EEG kayıtları sağlıklı ve epilepsi hastalığına sahip olmak üzere iki grup gönüllüden toplanmıştır. Hastalar, kafa derisi elektrotları kullanılarak EEG sinyallerinin sürekli olarak kaydedildiği uzun süreli görüntülenmesi işlemine tabi tutuldu. Veri seti interiktal (nöbet dışı) EEG bölümlerinin yanı sıra farklı nöbet tiplerine karşılık gelen bölümlerini de içerir.


**Toplanan EEG Sinyallerinin Özellikleri:** Bonn Epilepsy veri setindeki EEG sinyallerinin toplanması işlemi 173,61 Hz örnekleme frekansı ile gerçekleştirilmiş olup kafatasının çeşitli yerlerine yerleştirilen elektrotlar yardımıyla toplanmıştır.

**Veri Kümesi Yapısı:** Bonn Epilepsi veri kümesi, "A", "B", "C", "D" ve "E" olarak gösterilen beş alt küme halinde düzenlenmiştir. Her bir alt küme, farklı hastalardan alınan çok sayıda EEG kaydı içerir ve her kayda, nöbetlerin varlığını ve zamanlamasını gösteren karşılık gelen bir ek açıklama dosyası eşlik eder. Bu harflendirmeye sahip deneklerin temsil ettiği gruplar Tablo 3.1’de verilmiştir.

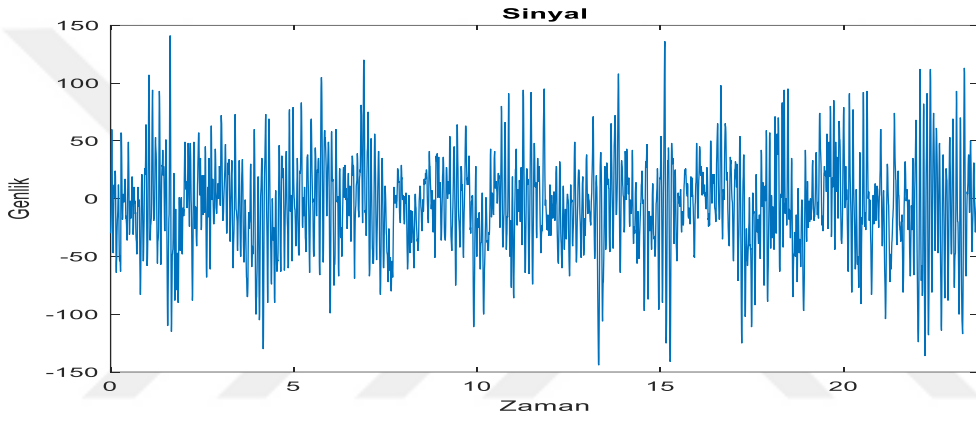
**Tablo 3.1.** Bonn veri seti detayları

<b>Grup</b>	<b>Tanım</b>
A	Bu sinyal grubu sağlıklı ve gözü açık deneklerin sinyallerinden oluşmaktadır.
B	Bu sinyal grubu sağlıklı ve gözü kapalı deneklerin sinyallerinden oluşmaktadır.
C	Gözler açık ancak nöbetsiz epilepsi hastalarından toplanan sinyallerdir.
D	Gözler kapalı ancak nöbetsiz epilepsi hastalarından toplanan sinyallerdir.
E	Bu sinyaller epilepsi hastası olan deneklerin nöbet geçirdiği anlara aittir.


Şekil 3.4, Şekil 3.5, Şekil 3.6, Şekil 3.7 ve Şekil 3.8’de Bonn veri setine ait A, B, C, D ve E gruplarına ait sinyallere sırasıyla birer örnek gösterilmiştir.




Şekil 3.4. A grubuna ait sinyallerden bir örnek



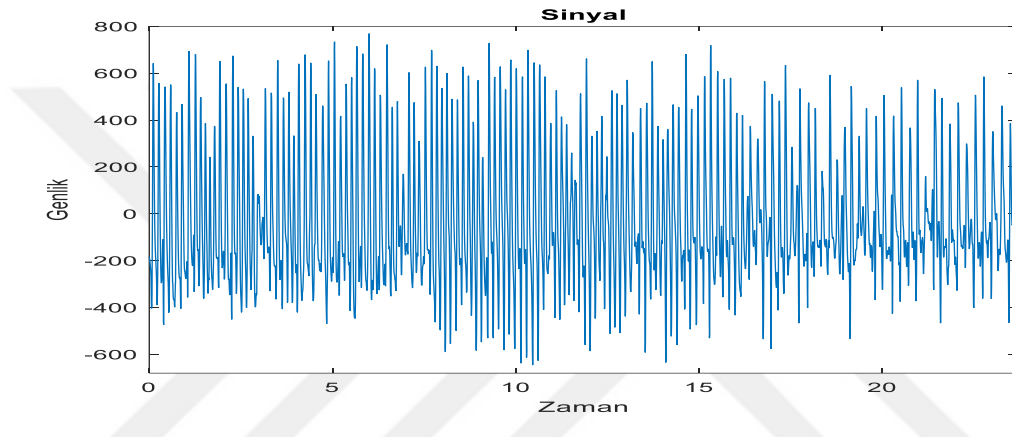
Şekil 3.5. B grubuna ait sinyallerden bir örnek



Şekil 3.6. C grubuna ait sinyallerden bir örnek



Şekil 3.7. D grubuna ait sinyallerden bir örnek



Şekil 3.8. E grubuna ait sinyallerden bir örnek

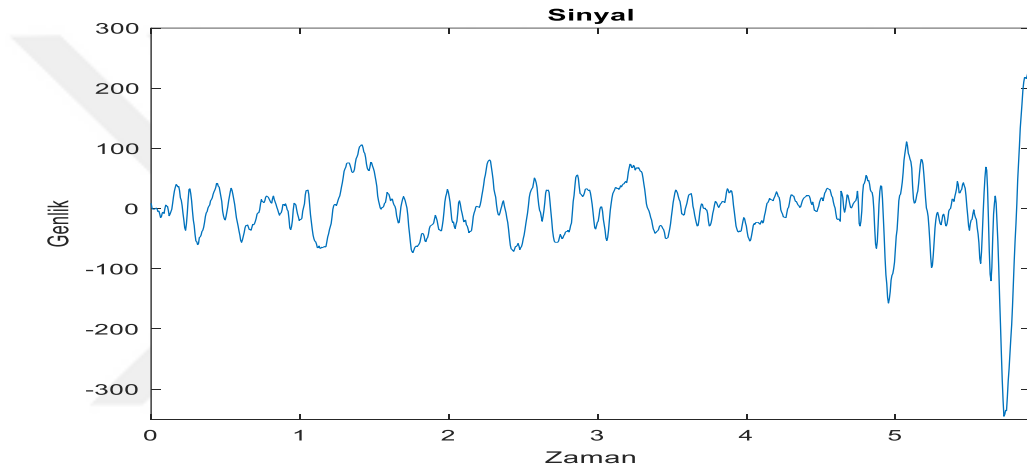
### 3.2.2.2 The Hauz Khas veri seti

The Hauz Khas veri seti Nöroloji ve Uyku Merkezi aracılığıyla toplanıp epilepsi hatalığı üzerine çalışmalar yapılması adına araştırmacıların kullanımına sunulmuştur. Sinyaller 10 farklı denekten 200 Hz örnekleme frekansıyla toplanmıştır. Ayrıca EEG sinyalleri toplanırken en yaygın yöntem olan 10-20 elektrot yerleşim sistemiyle toplanmıştır. Verilerin tamamına elde edilen sinyalleri 0,5-70 Hz frekans bandında filtreleyecek bant geçiren filtre uygulanmıştır. Verilerin toplanma süresi toplamda 5,12 saniye olmakla birlikte her bir sinyal verisi 1024 adet örnek içermektedir (Swami ve ark., 2016). Paylaşılan veriler Preiktal, İktal ve İnteriktal olmak üzere 3 gruptan oluşmakta ve her grubun içerisinde 50 EEG sinyal örneği bulunmaktadır. Bu 3 grup ve temsil ettikleri hal Tablo 3.2’de açıklanmıştır.

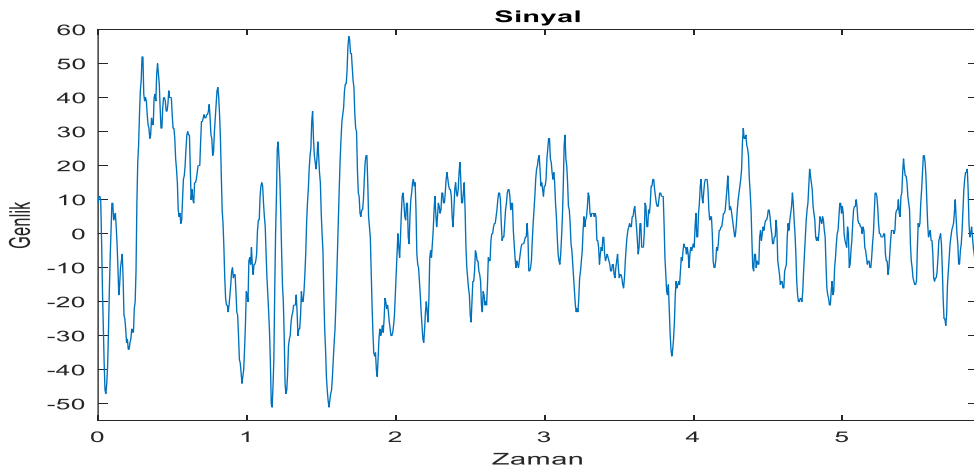
**Tablo 3.2.** The Hauz Khas Delhi veri seti detayları

Grup	Tanım
Preiktal	Epilepsi nöbeti öncesi toplanmış EEG sinyallerinden oluşmaktadır.
İktal	Nöbet esnasında hastalardan toplanmış EEG sinyallerinden oluşmaktadır.
İnteriktal	Nöbetsiz dönemde toplanmış EEG sinyallerinden oluşmaktadır.

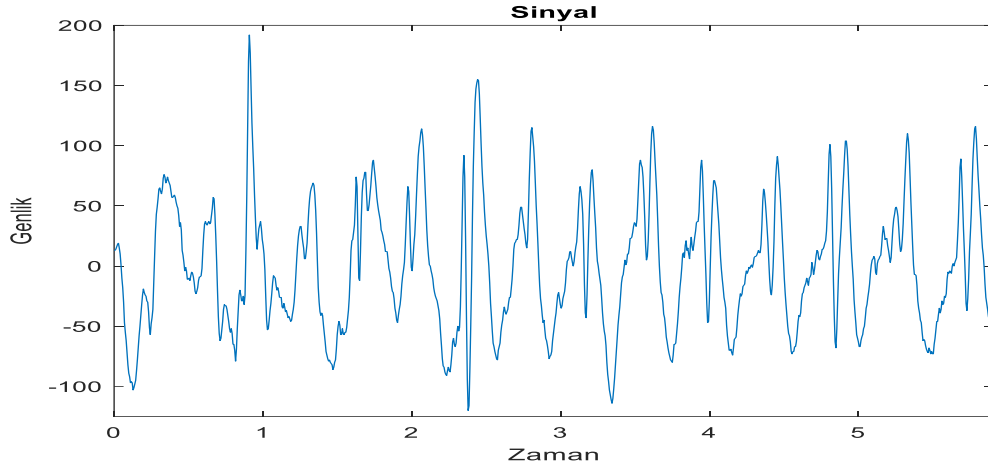
Bu 3 grup sinyalin her birine ait birer örnek preiktal, iktal ve interiktal anına göre olmaz üzere sırasıyla Şekil 3.9, Şekil 3.10 ve Şekil 3.11’de verilmiştir.



**Şekil 3.9.** Preiktal anına ait bir EEG sinyali



**Şekil 3.10.** İktal anına ait bir EEG sinyali



Şekil 3.11. İnteriktal anına ait bir EEG sinyali

### 3.3. Metot

#### 3.3.1. Derin öğrenme

Derin öğrenme insan beyninden ilham alınarak tasarlanmış ve ağlardan meydana gelen, makine öğrenmesinin özelleştirilmiş bir alt dalı olarak sınıflandırılan bir öğrenme yöntemleri topluluğudur. Bilgisayarlara insan gibi düşünüp karar verme yetisini kazandırmayı amaçlayan bu yöntemler topluluğu makine öğrenmesinin yetersiz kaldığı yüksek boyuta sahip karmaşık veriler üzerinde göstermiş olduğu yüksek başarı sebebiyle günümüzde sıklıkla başvurulan yöntemler arasında yerini almaktadır (LeCun ve ark., 2015).


Sinir ağlarından esinlenerek tasarlanmış ve katmanlı bir yapıya sahip olan derin öğrenme yöntemleri bu sayede katmanları giren verileri bir bir analiz edip bir sonraki katmana gereken bilginin aktarılmasını sağlayarak optimal bir öğrenme yolu sunmaktadır. Bu düzen de büyük verilerin işlenmesi konusunda bir hayli kolaylık sağlamaktadır (Nielsen, 2015).

Derin öğrenme yöntemlerinin literatürde en sık kullanılan dallarından biri olan Evrişimli Sinir Ağları (CNN), sinyallerin sınıflandırılması alanında sıklıkla kullanılan yöntemlere sahiptir (LeCun ve ark., 2015).

### 3.3.1.1 Evrişimli sinir ağları (CNN)

Evrişimli Sinir Ağları (CNN) genel olarak görüntünün işlenmesi üzerine olan görevlerine yerine getirmek adına sıklıkla tercih edilen bir derin öğrenme yöntemidir. CNN tabanlı yöntemler özellik çıkarım işlemini gerçekleştirmek adına diğer derin öğrenme yöntemlerine nazaran daha fazla katmana sahip olduğu için yapılan çalışmalarda kullanılma sıklığı yüksektir (Goodfellow ve ark., 2016).

CNN algoritmaları özellik çıkarımı ve sınıflandırma işlemleri yapısındaki katmanların üstlenmiş olduğu farklı görevlerden kaynaklı olarak bir arada gerçekleştirme potansiyeline sahiptir. Özellik çıkarım işlemlerini evrişimli katmanları aracılığıyla yapan CNN tabanlı yaklaşımlar, bu işlemi uygularken filtrelerden yararlanmaktadır. Ardından özellikleri elde edilen verinin boyutunun azaltılması adına havuzlama katmanlarına girdi olarak giren veri, bu aşamadan sonra daha ufak boyuta sahip hale gelir. Bu da sistemin hız kazanmasını sağlayan en önemli işlemlerden biri olarak sayılabilir. Bu iki işlemin gerçekleşmesinin ardından sınıflandırıcı katmanlar gelmektedir (Alzubaidi ve ark., 2021). Bu katmanlarda yapılan özelleştirmeler de CNN tabanlı yöntemlerin çeşitlenmesi sağlamıştır. Bu tez çalışmasında da 5 farklı CNN tabanlı sınıflandırıcıdan faydalanılmıştır. Bu sınıflandırıcıların her birinden alt başlıklar halinde aşağıda bahsedilmektedir. CNN algoritmasının genel şeması Şekil 3.12’de gösterilmiştir.



Şekil 3.12. CNN algoritması genel şeması (Kaplan, 2020)

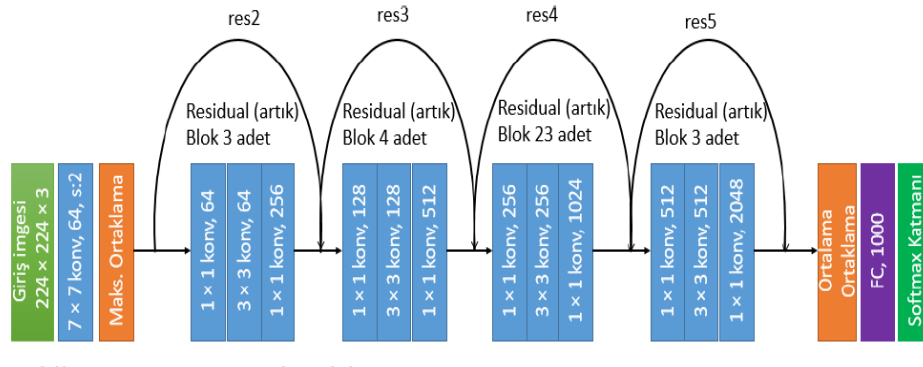
### 3.3.1.1.1 CNN tabanlı mimariler

#### 3.3.1.1.1.1. Resnet 101

ResNet olarak bilinen ve Artık Ağ anlamına gelen sınıflandırıcı ailesine ait olan ResNet101 sınıflandırıcısı CNN tabanlı bir yöntem olup 2015 yılında Microsoft Research ekibinde çalışan bir grup araştırmacı tarafından tasarlanmış ve tanıtılmıştır. Sınıflandırıcının genel amacı görüntü işleme, nesne algılama ve görüntüleri segmente etmektir (Khan ve ark., 2018).

Bunun yanında ağa Artık Ağ denmesinin temel sebebi artık öğrenme işleminin gerçekleşiyor olmasıdır. Artık öğrenme derinliği yüksek olan ağlarda meydana gelen gradyan sorununu çözmek amaçlı tasarlanmış bir yöntemdir. Bu yöntem sayesinde ağ, artık eşleşmeleri öğrenme işlemini gerçekleştirir. Bu işlemiyle atlama ve kısayol bağlantılarından faydalanarak gerçekleştirir.

Sınıflandırıcının sonuna gelen '101' sayısı içerdiği katman sayısını temsil etmektedir. Bununla birlikte genel bazda evrişimli katmanlar, havuzlama katmanları, tamamen bağlı katmanlar ve kısayol bağlantılarını sağlayan katmanlar olmak üzere 4 farklı katman türünü bünyesinde barındıran Resnet 101 sınıflandırıcısı 33 artık bloktan meydana gelmektedir. Bu 33 bloktan 29 tanesi bir önceki katmanda gelen artık bilgilerle beslenmektedir (Ghosal ve ark., 2019). Resnet 101'in mimari yapısı Şekil 3.10'da verilmiştir.



Şekil 3.13. Resnet-101 sınıflandırıcısına ait mimari

Şekil 3.13'te de gösterildiği üzere Resnet-101 sınıflandırıcısı geleneksel yapılardaki gibi doğrudan girdiden çıktıya doğru bir yol izlemek yerine katmanlara kazandırılan haritalama yetisi sayesinde katman çıktıları artık ağlardan gelen bilgilerin katman girişinde toplanması sonucu elde edilir. Bu özellikse ağı sıfırdan öğrenme yükünden kurtararak ağa eldeki optimize edilmesi daha kolay olan kalıntılarla çalışma

imkanı tanır. Ayrıca Şekil 3.13 incelendiğinde Resnet-101 sınıflandırıcısının artık blokların yan yana eklenmesiyle elde edildiği de görülmektedir. Bu artık bloklar bünyesinde normalizasyon ve ReLU aktivasyon işlevlerine sahip katmanları barındırır (Feng ve ark., 2020). Bloklar arası bağlantıya ek olarak dahil olan artık bilginin bir sonraki katmanın girişine aktarılışı da şekilde gösterilmiştir.

Sergilemiş olduğu başarı doğrultusunda literatürde görüntülerin sınıflandırılması işlemlerinde sıklıkla kullanılan Resnet 101 sınıflandırıcısı gün geçtikçe daha yoğun bir kullanım alanına sahip olmaktadır.


### **3.3.1.1.1.2. Resnet 50**

ResNet-50 sınıflandırıcısı da ResNet-101 gibi Microsoft Research ekibi üyeleri tarafından görüntüden öğrenme işlemini yerine getirmek amaçlı geliştirilen sınıflandırıcılardan biridir. Bu sınıflandırıcının tanıtıldığı yıl da ResNet-101'de olduğu gibi 2015'tir (Wen ve ark., 2020).

50 adet katmana sahip ResNet50 algoritması da görüntü bölütleme ve nesne tanıma görevlerini başarıyla yerine getirmek üzere eğitilmiş bir altyapıya sahiptir. Bu öğrenimin altyapısını da ImageNet'teki verilerden almaktadır. Böylelikle gerçekleştirmek istenen göreve önden eğitilmiş bir şekilde dahil olmaktadır. ResNet-101'de olduğu gibi bu yapıda da yok olan gradyanların artık ağlarla kurtarılması özelliği ResNet50'nin en öne çıkan özellikleri arasında yer almaktadır.

### **3.3.1.1.1.3. AlexNet**

AlexNet, derin öğrenme ve bilgisayar görüşü alanında ilerleme sağlamada çok önemli bir rol oynayan CNN tabanlı bir sınıflandırıcı olarak literatürdeki çalışmalarda sıklıkla kullanılmaktadır. 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen ve aynı yıl ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını (ILSVRC) kazanan AlexNet, 3'ü tam bağlantılı katman ve 5'i evrişimli katman olmak üzere toplamda 8 katmandan meydana gelmektedir (Yu ve ark., 2016). Şekil 3.14'te AlexNet sınıflandırıcısının mimarisi gösterilmiştir.



Şekil 3.14. AlexNet sınıflandırıcısına ait mimari (Kumar ve Chakrapani, 2022)

AlexNet, tasarımcıları tarafından ImageNet üzerindeki binlerce sınıftan ve milyonlarca görselden oluşan bir veri kümesiyle eğitilmiştir. Ayrıca eğitim aşamasında GPU gücünden de yararlanana AlexNet görüntülerin sınıflandırılmasında gösterdiği başarılı performansla derin öğrenme yöntemlerinin bu görevi yerine getirmesi konusundaki başarısını ortaya koyan yöntemler arasında yerini almıştır. Ayrıca bu başarı görüntü işleme içeren uygulamalarda CNN tabanlı uygulamaların kullanılmasının önünü de açmıştır.

### 3.3.1.1.1.4 GoogleNet

GoogLeNet de anlatılan diğer sınıflandırıcılar gibi desteğini CNN algoritmasından alan ve 2014 yılında Google tarafından tasarlanıp tanıtılan, bir diğer adı da Inception-v1 olarak bilinen derin öğrenme tabanlı bir yöntemdir (Yoo, 2015).

Ağa adını veren Inception kelimesi aslında GoogLeNet ağının en önemli özelliğinden kaynaklanmaktadır. Bu katman, içerisinde barındırmış olduğu filtreler yardımıyla filtreleme işlemini gerçekleştirirken bir yandan yapısında bulunan  $1 \times 1$  boyutundaki evrimsel katman yardımıyla boyut indirgeme işlemini gerçekleştirmektedir. Yani hem boyut indirgeme hem de özellik öğrenme işlemini bu katmanda gerçekleştirdiği için bu katmanın adıyla nitelendirilmektedir. Bu birliktelik modele hesaplama karmaşıklığı azaltarak bir hız kazandırmakta ve bir yandan da ağa yüksek bir verim katmaktadır (Kim ve ark., 2019).

Ayrıca ana katmanların yanı sıra ara katmanlarla da mimarisini güçlendiren GoogLeNet, Resnet-101 ağının artık ağırları bir sonraki aşamada dahil etmesiyle gerçekleştirmiş olduğu gradyan yok olma problemini ortadan kaldırma işlemini katmanlara eklenen küçük sınıflandırıcılar yardımıyla gerçekleştirmektedir. Aşırı

uyumun önüne geçen düzenleyici ara katmanları da mevcut olan GoogLeNet öğrenme aşamasında ortaya çıkabilecek problemi bu pratik yolu izleyerek ortadan kaldırmayı hedeflemektedir.

GoogLeNet kıyaslanmış olduğu diğer modellere nazaran daha az parametre yardımıyla daha yüksek başarı etmesi sonucunda bir hayli ilgi çeken bir model haline geldi. Bu da modelin tasarımcılarını model üzerine çeşitli çalışmalar yapmaya itti ve v1 olarak tanıtmış oldukları Inception-v1 modelinden sonra Inception-v4'e kadar uzayacak şekilde 3 farklı model daha üretildi.


### **3.3.1.1.1.5. VGG-19**

VGG-19 yöntemi adını Görsel Geometri Grubu (Visual Geometry Group) isminin İngilizce Kısaltmasından almaktadır. VGG-19 da bu çalışmada kullanılan diğer sınıflandırıcılar gibi CNN tabanlı olup Oxford Üniversitesi bünyesinde çalışma gerçekleştiren Görsel Geometri Grubu üyeleri tarafından geliştirilmiştir. Bu yöntem aynı grup tarafından üretilen VGG-16 mimarisinin bir devamı niteliği taşımaktadır ve 2014 yılında ImageNet tarafından düzenlenen Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) kapsamında üst düzey bir performans sergileyerek dikkatleri toplamayı başarmıştır (Bagaskara ve Suryanegara, 2021).

Bahsedilen diğer sınıflandırıcılarla kıyaslandığında VGG-19 sınıflandırıcısı basite indirgenmiş yapısıyla dikkat çekmektedir. 16 evrişimli, 5 havuzlama ve 3 tamamen bağlı katmanın bir araya getirilmesi sonucu oluşan bu mimari adındaki '19' ekini de bu katmanların sayılarından almaktadır (Shaha ve Pawar, 2018).

VGG-19 adını da almış olduğu Görsel Geometri Grubundan anlaşılacağı üzere ResNet ağı gibi görüntü bölütleme ve nesne algılama görevlerini yerine getirmek üzere tasarlanmış bir yapıya sahiptir. Bu işlemleri güçlendirmek adına yapısında bulundurmış olduğu ve ağ boyunca sürekli devrede olan 3x3 boyutundaki filtre ile lokal kalıpları kaçırmamayı hedefleyen mimarinin dezavantajıysa çok sayıda parametreye sahip olması

ve bunun getirmiş olduğu hesaplama ve bellek yüküdür. VGG-19 mimarisinin basit bir gösterimi Şekil 3.15'te gösterilmiştir.



Şekil 3.15. VGG-19 mimarisi

### 3.3.2 Kısa zamanlı Fourier dönüşümü

Kısa Zamanlı Fourier dönüşümü sinyallerin zaman içerisindeki analizini frekans bileşenleri aracılığıyla yapmamızı sağlayan bir analiz yöntemi olarak literatürdeki sinyal bazlı çalışmalarda sıklıkla kullanılmaktadır. Sinyalin zaman içerisindeki değişimini gözlemlemeye imkan tanıyan Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform, STFT) yöntemi 4 aşamada bu işlemi gerçekleştirebilme imkanına sahiptir (Kıymık ve ark., 2005).

İlk aşamada zamansal olarak bir bölütleme gerçekleştirilir ve bunlar pencerelere bölünerek yapılır ve bu pencereler genel olarak sabit bir zaman aralığına sahiptir. Ayrıca pencereler arası geçişteki doğabilecek eksiklikleri gidermek adına da örtüşen pencereler yönteminden faydalanılmaktadır. STFT yöntemleri kapsamında Dikdörtgen, Hanning, Hamming, Blackman ve Kaiser olmak üzere 5 farklı pencere tipinden faydalanılmaktadır ve bu tez çalışması kapsamında Kaiser penceresinden yararlanarak sinyallerin analizi işlemi gerçekleştirilmiştir (Sameer ve Gupta, 2022).

Kaiser penceresi temelinde yatan ana lob genişliği ve yan loblardan gelen bastırmalar arasındaki dengeyi kontrol etmesi sebebiyle spektrum analizlerinde sıklıkla kullanılan pencere türlerinden biri olarak yerini almaktadır. Kaiser penceresinin matematiksel ifadesi Denklem 3.1'de verilmiştir.


$$W(n) = \frac{I_0\left(\beta \sqrt{\frac{1-4n^2}{(M-1)^2}}\right)}{I_0(\beta)} \quad (3.1)$$

Denklem (3.1)'de verilen Kaiser penceresine ait formülün parametreleri aşağıdaki gibidir.

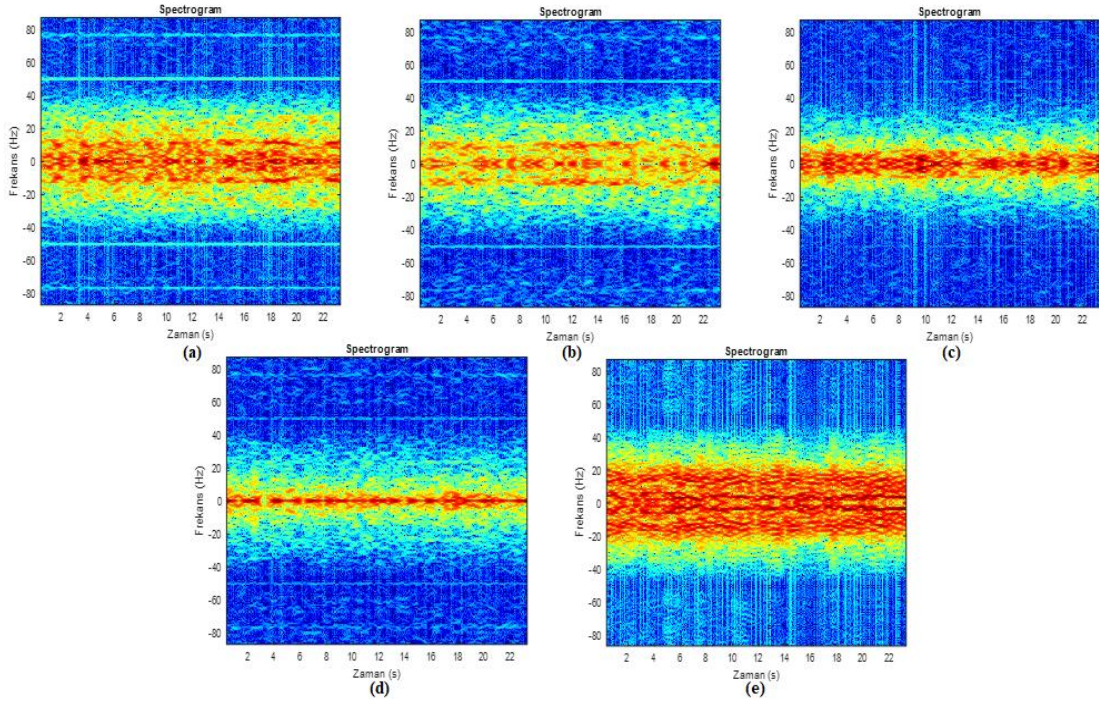
- $I_0$ : Bessel işlevi değerini içerir.
- $\beta$  : Şekil faktörünü temsil eder.
- $n$  : Pencere uzunluğudur.
- $M$  : Filtre sırasını temsil eder.

Pencere seçimi işleminin ardından seçilen pencerelerin her birinin içerisinde kalan sinyal gruplarına ayrı ayrı Fourier Dönüşümü (FT) işlemi uygulanır. Her bir pencere için uygulanan FT yönteminin çıktısı da sinyal spektrumlarıdır (Zabidi ve ark., Spektrogramlar sinyallerin genliklerini baz alarak renklendirilerek bir araya getirilmesi işlemi sonucunda oluşmaktadır.

Bu tez çalışması kapsamında STFT yöntemi kullanılarak spektrogramlar elde edilmiştir. Bu spektrogramların elde edilmesi için Kaiser penceresinden yararlanılmıştır ve kaiser pencere aralıkları da 128 ve 256 olarak seçilmiştir. Şekil 3.16, Şekil 3.17'de iki veri setinin her bir sinyal grubuna ait Kaiser penceresinin 128 pencere aralığına sahip STFT bazlı spektrogram çıktıları paylaşılmıştır. Kaiser penceresinin 128 pencere aralığına sahip STFT bazlı spektrogram çıktıları paylaşılmıştır.




**Şekil 3.16.** (a) The Haus Khas veri seti 128 pencere boyutlu Kaiser yöntemi tabanlı STFT çıktı örnekleri (a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali




**Şekil 3.17.** (a) Bonn veri seti 128 pencere boyutlu Kaiser yöntemi tabanlı STFT yöntemi çıktı örnekleri (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu

Şekil 3.16 ve 3.17’de uygulanan 128 pencere aralığına sahip Kaiser penceresi tabanlı STFT yönteminin 256 pencere aralığına sahip Kaiser penceresi tabanlı çıktıları Şekil 3.18 ve Şekil 3.19’da verilmiştir.



**Şekil 3.18.** The Hauz Khas veri seti 256 pencere boyutlu Kaiser yöntemi tabanlı STFT çıktı örnekleri (a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali



**Şekil 3.19.** Bonn veri seti 256 pencere boyutlu Kaiser yöntemi tabanlı STFT yöntemi çıktı örnekleri (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu

### 3.3.3 Sürekli Dalgacık Dönüşümü

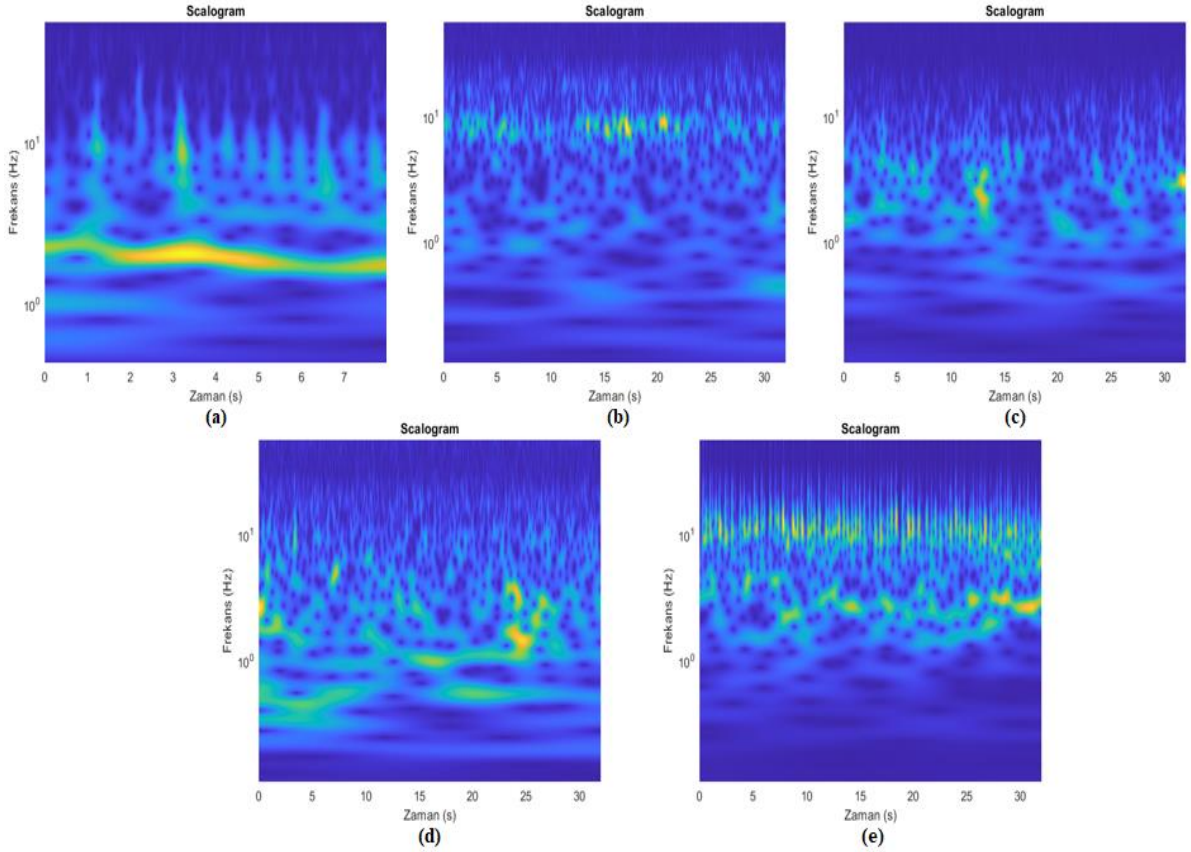
Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT), bir sinyalin zaman ve frekans bileşenlerinin ortak bir şekilde işleme alınmasına imkan tanıyan bir analiz yöntemidir. Yani bu yöntem ilgilenilen sinyalin frekans değerlerinin zamana bağlı olarak nasıl bir değişim gösterdiğinin incelenmesine olanak sağlamaktadır (Jadhav ve ark., 2020). Adını da almış olduğu dalgacıklar sayesinde zaman ve frekans bileşenlerini farklı çözünürlük değerlerinde analiz etme imkanı olan CWT yöntemi, kısa süreli ve salınım yapan dalgacık formlarının bütünüyle oluşmaktadır. CWT analiz yönteminin dönüştürme işlemini gerçekleştirmiş olduğu matematiksel ifade Denklem 3.2’de verilmiştir.

$$T(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \varphi \left( \frac{t-b}{a} \right) dt \quad (3.2)$$

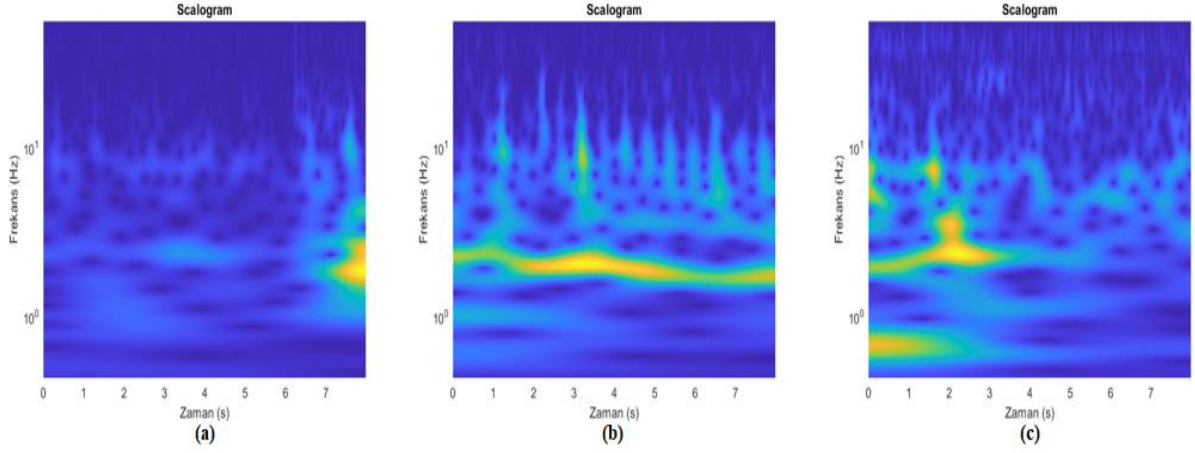
Denklem 3.2’de verilen matematiksel ifadeyi oluşturan parametrelerin neler olduğu aşağıda açıklanmıştır;

- $a$  : Ölçeklendirme parametresi
- $b$  : Dönüşümün konumu
- $\varphi$  : Dalgacık Fonksiyonu
- $x(t)$  : Giriş sinyali

Bu denklem tarafından dönüşüm işlemi gerçekleştirilen fonksiyon her bir ölçek için tek tek dönüşüm işlemine tabi tutulur. Ardından STFT yönteminde olduğu gibi bir spektrograma dönüştürülür. CWT bazında bu spektrogramın karşılığı Skalogram olarak isimlendirilmektedir (Roy ve Islam, 2020). Skalogram Denklem 3.1 yardımıyla elde edilmiş olan CWT katsayılarının enerjisini ve katsayı büyüklüğünü temsil eden bir yoğunluk haritasıdır. Bu enerjinin yoğunluğu ve katsayıların büyüklüğü doğrultusunda renklendirme işlemi gerçekleştirilerek sinyalden görüntü elde etme işlemi gerçekleştirilmiş olur (Meintjes ve ark., 2018). Şekil 3.20 ve Şekil 3.21’de Bonn ve The Hauz Khas veri setlerinin her grubuna CWT uygulanması sonucu elde edilmiş görsellerden birer örnek gösterilmiştir.



Şekil 3.20. Bonn veri seti CWT tabanlı analiz sonucu elde edilen örnekler (a): A grubu, (b) : B grubu, (c) : C grubu, (d) : D grubu, (e): E grubu



**Şekil 3.21.** The Hauz Khas veri seti CWT tabanlı analiz sonucu elde edilen örnekler(a): Preiktal hali, (b) : İktal hali, (c) : İnteriktal hali

### 3.3.4. Performans Parametreleri

Bu tez çalışmasında gerçekleştirilen EEG tabanlı verilerden epileptik halin tespiti üzerine sunulan yöntemin başarısının değerlendirilmesi adına doğruluk, f ölçüleri, duyarlılık ve kesinlik parametrelerinden faydalanılmıştır.

Bahsedilen parametrelerin hesaplanmasında kullanılan temel değerler Tablo 3.3'te verilmiştir.

**Tablo 3.3.** Performans Ölçütlerine Ait Bilgiler

		Gerçek Değerler	
		Pozitif	Negatif
Tahminlenen Değerler	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (TN)	Doğru Negatif (TN)

Tabloda verilen bilgiler, sınıflandırma işleminde verilerin doğru veya yanlış sınıflandırılması baza alınarak oluşturulmuştur. Bu parametreler ışığında tez kapsamında kullandığımız parametrelerin elde edilişi aşağıda açıklanmaktadır.

**Doğruluk:** Doğruluk en temel ölçütlerinden biridir ve sınıflandırma işlemi esnasında doğru sınıflandırılan verilerin tüm veriye olan oranıyla elde edilir.

$$\text{Doğruluk} : \frac{TP+TN}{TP+FP+FN+TN} \quad (3.3)$$

**Duyarlılık:** Duyarlılık bir modelin pozitif örnekleri sınıflandırmasındaki başarıyı

veren bir ölçüttür. Doğru pozitif verilerin, yanlış negatif verilerle birlikte değerlendirilmesi sonucu elde edilir.

$$\text{Duyarlılık} : \frac{TP}{TP+FN} \quad (3.4)$$

**Kesinlik:** Kesinlik ölçütü, model tarafından yapılan sınıflandırma işlemi sonucunda elde edilen doğru tahminlenmiş pozitif verilerin pozitif verilerin geneline oranlanmasıyla elde edilir.

$$\text{Kesinlik} : \frac{TP}{TP+FP} \quad (3.5)$$

F ölçütleri: F ölçütleri F1 puanı olarak da bilinmekle birlikte kesinlik ve duyarlılık bilgilerinin ortak değerlendirilmesi sonucu elde edilir. Modelin sergilemiş olduğu performans üzerine detaylı bir değerlendirmenin sonucudur.

$$F \text{ skoru} : \frac{2xTP}{2xTP+FN+FP} \quad (3.6)$$

#### 4. DENEYSEL SONUÇLAR

EEG verilerinden yararlanılarak epilepsi nöbeti teşhisi işlemi çeşitli basamakların bir araya getirilmesi sonucunda elde edilir. Bu işlem bir makine öğrenmesi sınıflandırıcısı aracılığıyla yapılacaksa genel olarak çeşitli ön işlemler ve ardından özellik çıkarım yöntemleri yardımıyla sınıflandırıcıya hazır hale getirme işlemi gerçekleştirilirken; bu teşhis işleminin derin öğrenme yöntemleriyle gerçekleştirilmesi durumunda özellik çıkarımı işlemi yapılan çalışmayı gerçekleştiren araştırmacının izlediği yola göre değişmektedir. Derin öğrenme algoritmalarının katmanlı yapısından kaynaklı olarak gerçekleştirmiş olduğu transfer öğrenme işlemi, özellik çıkarım işlemini zaten kendi bünyesinde gerçekleştirmektedir. Ancak çeşitli özellik çıkarım işlemi algoritmaları kullanarak da eldeki veriler derin öğrenme yöntemlerinin öğrenme başarısını artırmak adına kullanılabilir.

Bu tez çalışmasında derin öğrenme tabanlı sınıflandırıcılar yardımıyla epilepsi nöbeti teşhisi gerçekleştirmek amaçlanmıştır. Bu doğrultuda The Hauz Khas ve Bonn epilepsi veri setlerinden faydalanılmış ve bu veri setlerinden özellik çıkarmak adına verilere STFT ve CWT özellik çıkarım yöntemleri uygulanmıştır. Özellik çıkarım yöntemlerinin sınıflandırmaya olan etkisini ölçmek adına 5 farklı CNN tabanlı sınıflandırıcı kullanılmıştır. Bu sınıflandırıcıların STFT ve CWT uygulanmış verilere uygulanması sonucu elde edilen performans parametreleriyle sınıflandırma yöntemi ve özellik çıkarım yöntemi ikililerinin başarıları ölçülmüştür.

Öncelikle The Hauz Khas veri setine STFT yöntemi Kaiser penceresi yardımıyla uygulandı ve pencere aralığı 128 olarak belirlendi. Bu işlemin The Hauz Khas veri setindeki preiktal, iktal ve interiktal sinyallere uygulanması sonucu elde edilen başarı oranları Tablo 4.1’de paylaşılmıştır.

**Tablo 4.1.** Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (128 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	<b>0,911</b>	<b>0,911</b>	<b>0,876</b>	<b>0,893</b>
Resnet 50	0,866	0,827	0,850	0,838
AlexNet	0,777	0,822	0,863	0,842
GoogLeNet	0,688	0,689	0,759	0,722
VGG 19	0,600	0,6	0,407	0,485

Tablo 4.1 incelendiğinde üçlü sınıflandırma işlemi sonucunda elde edilen en yüksek doğruluk oranının Resnet-101 sınıflandırıcısına ait olduğu görülmektedir. Bu işlemin ardından bir de The Hauz Khas veri seti üzerinde preiktal ve iktal anları arasındaki farklardan faydalanarak teşhis işlemi gerçekleştirmek adına ikili bir sınıflandırma işlemi uygulanmıştır ve bu sınıflandırma işleminde özellik çıkarım yöntemi olarak yine STFT sınıflandırıcısına ait 128 pencere aralığına sahip Kaiser penceresi kullanılmıştır. Elde edilen sonuçlar Tablo 4.2’de gösterilmektedir.

**Tablo 4.2.** Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (128 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırma	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
Resnet 50	0,933	0,933	0,933	0,933
AlexNet	0,800	0,800	0,800	0,800
GoogLeNet	0,933	0,933	0,941	0,937
VGG 19	0,500	0,500	0,500	0,500

Tablo 4.2’de de görüldüğü üzere Resnet-101 sınıflandırıcısı bu işlemi %100 başarıyla tamamlamıştır. 128 pencere boyutlu Kaiser penceresi yardımıyla elde edilen verilere ek olarak veri seti üzerinde Kaiser penceresinin boyutunun sınıflandırıcıya olan etkisini test etmek adına pencere aralığını 256’ya yükselterek sınıflandırma işlemi gerçekleştirildi. Bir önceki sınıflandırma işleminde olduğu gibi bu sınıflandırma işlemi de iki farklı veri grubu için yapıldı. Üçlü olarak gerçekleştirilen sınıflandırma işleminin sonuçları Tablo 4.3’te, ikili olarak gerçekleştirilen sınıflandırma işleminin sonuçlarıysa Tablo 4.4’te paylaşılmıştır.

**Tablo 4.3.** Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (256 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırma	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	<b>0,867</b>	<b>0,866</b>	<b>0,875</b>	<b>0,870</b>
Resnet 50	0,822	0,822	0,844	0,832
AlexNet	0,800	0,799	0,801	0,799
GoogLeNet	0,778	0,729	0,792	0,759
VGG 19	0,600	0,569	0,447	0,500

**Tablo 4.4.** Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (256 pencere boyutlu Kaiser penceresi ile STFT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	0,933	0,933	0,941	0,937
Resnet 50	0,933	0,933	0,933	0,933
AlexNet	0,867	0,867	0,867	0,867
GoogLeNet	<b>0,966</b>	<b>0,967</b>	<b>0,969</b>	<b>0,968</b>
VGG 19	0,867	0,867	0,867	0,867

Tablo 4.3 incelendiğinde en yüksek sınıflandırma başarısının yine GoogLeNet yöntemiyle elde edildiği görülmektedir ancak doğruluk oranlarındaki düşüşte dikkat edilmesi gereken bir diğer husus olarak göze çarpmaktadır. İkili sınıflandırmanın sonuçlarını temsil eden Tablo 4.4 incelendiğindeyse bu işlem sonucunda en yüksek başarı oranlarının Resnet-50 ve Resnet-101 yöntemleri tarafından elde edildiği fakat yine 128 boyutlu Kaiser penceresi kullanılarak elde edilen verilere yapılan sınıflandırma işlemine nazaran daha düşük sınıflandırma doğruluğu elde edildiği de görülmektedir.

The Hauz Khas veri seti üzerine yapılan son işlemse özellik çıkarım yöntemlerinin etkisini tespit etmek amacıyla uygulanan Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT). Doğru bir kıyaslama gerçekleştirilmesi adına burda da veri seti üzerine ikili ve üçlü gruplar üzerine sınıflandırma gerçekleştirilmiştir. Üçlü grup üzerine gerçekleştirilen sınıflandırma işleminin sonuçları Tablo 4.5'te, ikili grup üzerine gerçekleştirilen sınıflandırma işleminin sonuçlarıysa Tablo 4.6'da paylaşılmıştır.

**Tablo 4.5.** Preiktal, iktal ve interiktal gruplarının sınıflandırılmasına ait başarı oranları (CWT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	<b>0,955</b>	<b>0,933</b>	<b>0,941</b>	<b>0,937</b>
Resnet 50	0,800	0,8000	0,8000	0,8000
AlexNet	0,689	0,689	0,759	0,722
GoogLeNet	0,867	0,866	0,875	0,870
VGG 19	0,667	0,633	0,634	0,633

Tablo 4.5 incelendiğinde üçlü sınıflandırma işlemi doğrultusunda en yüksek sınıflandırma doğruluğunun yine Resnet-101 sınıflandırıcısı %95,5 oranı ile elde edildiği ve bu doğruluğunun diğer 2 yöntemle kıyaslandığında da daha yüksek seviyeye çıktığı görülmektedir.

**Tablo 4.6.** Preiktal, iktal gruplarının sınıflandırılmasına ait başarı oranları (CWT uygulanması sonucu elde edilen sonuçlar)

Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F skoru
Resnet 101	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>
Resnet 50	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>
AlexNet	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>
GoogLeNet	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>
VGG 19	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>	<b>1,0000</b>

Preiktal ve iktal anlarına ait sinyalleri içeren veri gruplarına uygulanan CWT özellik çıkarımının ardından gerçekleştirilen sınıflandırma işlemlerine dair özellikleri gösteren Tablo 4.6 incelendiğinde yöntemlerin tamamında %100 oranında doğruluk elde edildiği görülmektedir. The Hauz Khas veri seti üzerine yapılan çalışmalarda genel olarak Resnet-101 yönteminin sınıflandırma konusunda gösterdiği başarının özellik çıkarım yöntemlerinin değişmesi durumunda da en yüksek seviyede olduğu görülmektedir. Ayrıca özellik çıkarım yöntemlerinin sınıflandırma başarısının da incelenmesi halinde CWT yönteminin diğer iki yönteme nazaran sınıflandırma doğruluğa daha olumlu etki ettiği söylenebilmektedir.

Önerilen yaklaşımın bir diğer safhasında The Hauz Khas veri setine nazaran daha büyük bir veri seti olan Bonn veri setinden faydalanılmıştır. Bonn veri seti üzerinde materyal kısmında belirtilen A, B, C, D, E gruplarını baza olarak sınıflandırma işlemleri gerçekleştirilmiştir. Bu sınıflandırma işlemleri A-E, B-E, C-E ve D-E olmak üzere epilepsi nöbeti ve diğer hallerin tespitini sağlayabilmek adına gruplandırılmıştır. Bu ikili sınıflandırma işlemlerine ek olarak da sağlıklı olan denekler, epilepsi hastalığına sahip ancak epilepsi nöbeti geçirmeyen denekler ve sinyal verileri nöbet esnasında toplanan deneklerin teşhisi üzerine gerçekleştirilen sınıflandırma işleminde kullanılmak üzere AB-CD-E gruplandırması kullanılmıştır. Bu sınıflandırma işlemlerinde de The Hauz Khas veri setinde kullanılan özellik çıkarım ve sınıflandırma yöntemlerinden faydalanılmıştır.

Bonn veri seti üzerinde öncelikle STFT özellik çıkarım yönteminin sınıflandırma işlemine katkısını ölçebilmek adına 128 pencere boyutlu Kaiser penceresi uygulanmıştır. Sınıflandırma işlemine hazır hale gelen veriler sınıflandırıcılara tabi tutulmuş ve yöntemlerin sınıflandırma başarıları Tablo 4.7’de paylaşılmıştır.

**Tablo 4.7.** 128 pencere aralığına sahip Kaiser penceresi kullanılarak STFT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları

Veri Grupları	Resnet-101 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	Resnet-50 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	AlexNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	GoogLeNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	VGG-19 (Doğruluk, Kesinlik, Duyarlılık, F skoru)
A-E	0,967	0,983	0,983	<b>1,000</b>	0,867
	0,967	0,983	0,983	<b>1,000</b>	0,867
	0,969	0,984	0,984	<b>1,000</b>	0,895
	0,968	0,983	0,983	<b>1,000</b>	0,881
B-E	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>
	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>
	<b>0,984</b>	<b>0,984</b>	<b>0,984</b>	<b>0,984</b>	<b>0,984</b>
	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>	<b>0,983</b>
C-E	0,983	<b>1,000</b>	<b>1,000</b>	0,967	0,800
	0,983	<b>1,000</b>	<b>1,000</b>	0,967	0,720
	0,984	<b>1,000</b>	<b>1,000</b>	0,969	0,783
	0,983	<b>1,000</b>	<b>1,000</b>	0,968	0,750
D-E	0,983	<b>1,000</b>	0,983	0,983	0,900
	0,983	<b>1,000</b>	0,983	0,983	0,900
	0,984	<b>1,000</b>	0,984	0,984	0,916
	0,983	<b>1,000</b>	0,983	0,983	0,907
AB-CD-E	0,913	0,920	0,933	0,926	<b>0,947</b>
	0,906	0,920	0,933	0,913	<b>0,946</b>
	0,914	0,927	0,938	0,914	<b>0,949</b>
	0,909	0,923	0,935	0,913	<b>0,947</b>

Tablo 4.7 incelendiğinde her grupta farklı farklı sınıflandırıcı performanslarının üstünlük gösterdiğini görülmektedir. A-E sınıflandırması işleminde GoogLeNet yöntemi %100 başarı oranını sahipken B-E gruplarının sınıflandırılmasında tüm sınıflandırıcılar %98,33 doğruluk oranına ulaşmıştır. C-E gruplarının sınıflandırılmasında Resnet-50 ve AlexNet sınıflandırıcıları %100 oranında doğruluk oranıyla sınıflandırma işlemini gerçekleştirmiştir. D-E gruplarını sınıflandırmada en yüksek başarı oranı Resnet-50 sınıflandırıcısına aittir ve son olarak AB-CD-E gruplarının sınıflandırılmasında en yüksek doğruluk oranı %94,7 ile VGG-19 sınıflandırıcısıyla elde edilmiştir.

Pencere boyutlarının Bonn veri seti üzerindeki sınıflandırma performansını ölçmek adına Kaiser penceresinin pencere aralığı 256'ya yükseltilerek verilere STFT özellik çıkarım yöntemi uygulanmış ve tekrardan derin öğrenme tabanlı sınıflandırıcılara tabi tutulmuştur. Yapılan sınıflandırma işleminin performans kriterleri Tablo 4.8'de paylaşılmıştır.

**Tablo 4.8.** 256 pencere aralığına sahip Kaiser penceresi kullanılarak STFT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları

Veri Grupları	Resnet-101 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	Resnet-50 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	AlexNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	GoogLeNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	VGG-19 (Doğruluk, Kesinlik, Duyarlılık, F skoru)
A-E	<b>0,983</b>	<b>0,983</b>	0,950	0,967	0,950
	<b>0,983</b>	<b>0,983</b>	0,950	0,967	0,950
	<b>0,984</b>	<b>0,984</b>	0,955	0,969	0,954
	<b>0,983</b>	<b>0,983</b>	0,952	0,968	0,952
B-E	0,967	<b>0,983</b>	<b>0,983</b>	0,917	0,867
	0,967	<b>0,983</b>	<b>0,983</b>	0,916	0,867
	0,969	<b>0,984</b>	<b>0,984</b>	0,928	0,882
	0,968	<b>0,983</b>	<b>0,983</b>	0,922	0,874
C-E	0,983	0,983	0,967	<b>1,000</b>	0,900
	0,983	0,983	0,967	<b>1,000</b>	0,900
	0,984	0,984	0,969	<b>1,000</b>	0,907
	0,983	0,983	0,968	<b>1,000</b>	0,904
D-E	0,967	0,967	0,983	<b>1,000</b>	0,867
	0,967	0,967	0,983	<b>1,000</b>	0,866
	0,969	0,969	0,984	<b>1,000</b>	0,882
	0,968	0,968	0,983	<b>1,000</b>	0,874
AB-CD-E	<b>0,973</b>	0,966	0,946	0,933	0,753
	<b>0,973</b>	0,966	0,954	0,933	0,753
	<b>0,975</b>	0,968	0,946	0,939	0,766
	<b>0,974</b>	0,967	0,950	0,936	0,759

Tablo 4.8 incelendiğinde bir Tablo 4.7'dekine benzer bir tabloyla karşı karşıya kalındığı görülmektedir. Sınıflandırıcılar birbirine yakın doğruluk oranları elde etmişken Resnet-50 sınıflandırıcısı A-E, B-E gruplarını %98,33 oranında doğru sınıflandırarak gruplar özelinde en yüksek sınıflandırma doğruluğuna ulaşmıştır. C-E ve D-E grupları GoogLeNet sınıflandırıcısı kullanılarak %100 oranında doğruluk oranıyla sınıflandırılmıştır. AB-CD-E gruplarından oluşan blok ise Resnet-101 yöntemi yardımıyla %97,3 oranında doğrulukla sınıflandırılmıştır.

Bonn veri seti üzerine son olarak STFT ve CWT yöntemlerinin kıyaslanması adına CWT yöntemi uygulanmış ve bu işlem sonucunda elde edilen skalogram görüntüleri 5 sınıflandırıcının her birine tabi tutulmuştur. Her bir grupta sınıflandırmaya ait sınıflandırıcı performans kriterleri Tablo 4.9'da paylaşılmıştır.

**Tablo 4.9.** CWT uygulanmış Bonn veri setinden elde edilen sınıflandırma başarıları

Veri Grupları	Resnet-101 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	Resnet-50 (Doğruluk, Kesinlik, Duyarlılık, F skoru)	AlexNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	GoogLeNet (Doğruluk, Kesinlik, Duyarlılık, F skoru)	VGG-19 (Doğruluk, Kesinlik, Duyarlılık, F skoru)
A-E	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
B-E	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
C-E	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
D-E	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,900
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,901
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,899
	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,900
AB-CD-E	<b>0,993</b>	0,986	0,973	0,953	0,800
	<b>0,993</b>	0,987	0,973	0,953	0,800
	<b>0,993</b>	0,986	0,974	0,953	0,803
	<b>0,993</b>	0,986	0,973	0,953	0,802

Tablo 4.9 incelendiğinde sınıflandırıcı başarılarındaki artış göze çarpmaktadır. A-E, B-E, C-E grupları tüm sınıflandırıcılar tarafından %100 oranında doğruluk oranıyla sınıflandırılmıştır. D-E grubu ise VGG-19 yöntemi dışında uygulanan tüm yöntemlerle %100 oranında doğru sınıflandırılmıştır. AB-CD-E gruplarından oluşan veriler ise Resnet-101 sınıflandırıcısı tarafından %99,33 oranında doğru sınıflandırılmıştır.

Bu tez çalışmasında iki farklı veri seti, iki farklı özellik çıkarım yöntemi ve 5 farklı derin öğrenme tabanlı sınıflandırıcı kullanılarak epilepsi teşhisi üzerine bir yaklaşım gerçekleştirilmiştir. Literatürde de sıklıkla üzerine çalışma gerçekleştirilen epilepsi hastalığı üzerine yapılan çalışmaların, bu tez kapsamında yapılan çalışmalarla olan kıyası Tablo 4.10'da gösterilmektedir.

**Tablo 4.10.** Sunulan yaklaşımın literatürdeki çalışmalarla karşılaştırılması

İsim, (Yıl)	Metot	Veri Seti	Başarı
Kaya ve Ertuğrul (2018)	Tek Boyutlu Üçlü Modeller (1D-TP)	Bonn Veri Seti (A-E,B-E,C-E,D-E)	%100, %97,5, %97,5, %94,5
Türk ve Özerdem (2019)	CWT	Bonn Veri Seti (A-E,B-E,C-E,D-E)	%99,5, %99,5 %98,5, %98,5
Du ve ark., (2022)	CNN tabanlı özellik çıkarımı ve SVM sınıflandırıcısı kombiansyonu (CNN-SVM)	The Hauz Khas veri seti	%98,0
Zhang ve ark, (2022)	-İstatistiksel özellikler -KNN	Bonn veri seti(AB-CD-E)	%97,4
Malekzadeh ve ark, (2021)	- İstatistiksel özellikler, frekans bazlı özellikler, entropi, SVM,KNN,CNN-RNN	Bonn Veri Seti (A-E, B-E, C-E, D-E, AB-CD-E)	%99,61, %99,46, %99,51, %99,82, %99,71
Ullah ve ark, (2018)	-1D-CNN, 10 katlı çapraz doğrulama, Adam optimizeleri	Bonn veri seti (A-E, B-E, C-E, D-E, AB-CD-E)	%100, %99,6, %98,5, %98,8, %94,33
Ramakrishnan ve Murugavel (2019)	-Zaman ve frekans bazlı özellikler, CNN	CHB-MIT Bonn veri seti (A-E, AB-CD-E)	- %98,34 %99,57 %98,37
<b>Bu tez çalışması</b>	<b>-STFT, CWT, Resnet-101, Resnet-50, AlexNet, GoogLeNet, VGG-19</b>	<b>The Hauz Khas veri Seti (Preiktal-İktal) (Preiktal-İktal-İnteriktal) ---</b> <b>Bonn veri seti (A-E, B-E, C-E, D-E, AB-CD-E)</b>	<b>%100</b> <b>%95,56</b> --- <b>%100</b> <b>%100</b> <b>%100</b> <b>%100</b> <b>%99,33</b>

## 5. TARTIŞMA

Epilepsi hastalığı yaygınlığının gün geçtikçe artmasına bağlı olarak günümüzde akademik birçok çalışmaya konu olmaktadır. Hastalığın artış hızı da bu konu üzerine yapılacak çalışmaların sürekliliğini gösteren temel faktörlerden biridir (Tzallas et al., 2012). EEG sinyalleri yardımıyla üzerine gerçekleştirilen çalışmaların daha verimli hale gelmesi üzerine epilepsi hastalığı, sinyallerle sıklıkla uğraşan yapay zeka tabanlı sistemler üreten araştırmacı gruplara da bir çalışma alanı oluşturmuştur. Araştırmacılar zamana bağlı bir şekilde değişen EEG sinyallerinden özellikler çıkartarak uzman fikirleri asiste etmek adına çeşitli yardımcı sistemler geliştirmeyi hedef edinmiş ve bu bağlamda yaklaşımlar ortaya koymuşlardır (Boonyakitanont ve ark., 2020).

Çeşitli araştırma toplulukları da yapılan çalışmaları artırmak ve yöntemlerinin gelişmesini sağlamak adına epilepsi hastalığına sahip olan, olmayan denek gruplarından oluşan topluluklardan EEG sinyalleri toplayıp etiketleyerek araştırmacıların önüne sunuyor ve böylelikle konu üzerine çalışma gerçekleştirmek isteyen araştırmacılar verilere rahat bir şekilde erişim sağlayabiliyor (Wen ve ark., 2021). Bu tez çalışması kapsamında da kullanıma açık olan veri setlerinden olan The Hauz Khas ve Bonn epilepsi veri setlerinden faydalanılmıştır. Bu veri setlerinden The Hauz Khas veri seti epilepsi yalnızca epilepsi hastalarından ve bu hastalarının epilepsi anı, epilepsi öncesi ve epilepsiden bağımsız halde buldukları durumlara ait EEG sinyallerinden oluşmaktadır. Bunun yanında daha kapsamlı bir yapıda olan Bonn veri setiyse epilepsi hastalığına sahip olan ve olmayan deneklerin EEG verilerinin bir araya gelmesinden oluşturulan bir yapıya sahiptir. Bonn veri seti veriyi erişime açan çalışma ekibi tarafından 5 farklı denek grubundan toplanan sinyallerle paylaşılmış ve bu sinyallerin özellikleri de tezin içeriğinde verilmiştir.

Bu tez çalışması kapsamında da bir asistan sistem tasarlamak adına yukarıda bahsedilen veri setlerinden faydalanılarak derin öğrenme tabanlı bir yaklaşım sunmak amaçlanmıştır. Derin öğrenmenin tercih edilmesinin temel sebebi yapılan işlemlerin daha hızlı bir şekilde gerçekleştirilebilmesine olanak tanınmasıdır. Derin öğrenme tabanlı sistemler, makine öğrenmesi sınıflandırıcılarından farklı olarak sinyal verilerini sayısallaştırarak bunlardan özellik çıkarılmasına ihtiyaç duymadan sinyalin kendi yapısından da sınıflandırma işlemlerini gerçekleştirebilme potansiyeline sahiptir. Literatürde de biyomedikal sinyalleri kullanarak makine öğrenmesi yöntemleri ve derin öğrenme tabanlı yöntemler arasında karşılaştırma işlemi gerçekleştiren birçok çalışma

mevcuttur (Feng ve ark., 2023).

Yukarıda bahsedilen ve derin öğrenmeyi avantajlı kılan özelliklerden ötürü bu tez çalışmasında derin öğrenme algoritmalarından olan CNN tabanlı 5 farklı sınıflandırma algoritmasından yararlanılmıştır. Verilerin ham hallerini sınıflandırma işlemine tabi tutmaktansa önce bir özellik çıkarım işlemi uygulayıp sınıflandırma başarısını artırmanın hedeflendiği bu çalışma kapsamında verilere STFT ve CWT yöntemlerini uygulanmış ve bu yöntemlerin sınıflandırma performansına olan etkisini gözlemlenmiştir. Bu iki yöntem verilerin görsel hale gelmesini ve EEG sinyallerindeki genlik ve frekans bazlı değişimlerin oluşturduğu spektrumları göz önüne sermek adına sıklıkla kullanılan özellik çıkarım yöntemleri arasındadır. Özellikle epilepsi hastalarının nöbet anına ait EEG sinyal verilerini keskin sınırlarla ortaya koyan bu iki yöntemin CNN tabanlı sınıflandırıcılarla kombine edilmesi sonucu ortaya çıkan sonuçlar tez çalışmasının sonuçlar kısmında bir paylaşmıştır.

Bu tez çalışması kapsamında kullanılan özellik çıkarım yöntemleri üzerine bir değerlendirme yapılacak olursa eğer; öncelikle Kaiser penceresi tabanlı STFT özellik çıkarım yönteminde pencere aralığının etkisinin incelenmesi gerekmektedir. Bu bağlamda iki veri seti üzerinde de 128 pencere aralığına sahip Kaiser penceresi yardımıyla elde edilmiş STFT spektogramlarının sınıflandırılma doğruluğunun daha yüksek oranlarda olduğu söylenebilir. Ancak bu yöntemlerin ikisinin CWT ile karşılaştırıldığı durumlarda CWT ile elde edilen skalogramların CNN tabanlı sınıflandırıcıların eğitimi açısından daha net bir veri sunduğu ve daha yüksek sınıflandırma başarıları elde edilmesini sağladığı sonuçlar bölümündeki tablolarda paylaşılan verilerde de açıkça görülmektedir. Özellikle nöbet anının nöbet öncesi anından ayırt edilmesinde The Hanz Khas veri setinde gösterdiği başarı ve Bonn veri setinde ortaya koymuş olduğu her sınıflandırıcıdaki yüksek performans CWT'nin bu çalışma kapsamında tercih edilme potansiyeli yüksek olan özellik çıkarım yöntemi olduğunu göstermektedir.

Tezin bütünü literatürle karşılaştırılacak olursa eğer bu tez çalışmasına benzer çalışmalar incelendiğinde aynı veri setleri üzerine yüksek başarıların elde edildiği görülse de CWT tabanlı sınıflandırmada elde edilen başarıların literatürdeki birçok çalışmanın doğruluk oranından daha yüksek değerlere erişmiş olması yöntemin kullanılabilirliği üzerine pozitif bir etki oluşturmaktadır.

Bu yapılan çıkarımlar ışığında EEG sinyalleri yardımıyla yapılan epilepsi teşhisi düşünüldüğünde bu tez çalışması özelinde uygulanan yöntemlerin iyi bir yere sahip

olacağı öngörülmektedir. EEG sinyallerinin yapısı düşünüldüğünde; insanların içinde bulunduğu hallere göre değişken sinyaller (alfa, beta, gama ve teta) üreten beynin içinde bulunduğu hali tespit etmek adına da yardımcı bir sistem olarak değerlendirilmesi muhtemeldir. Bu yardımcı sistemler beyinden kaynaklı olarak gerçekleşen, EEG sinyallerine yansıyan ve insan hayatına doğrudan etki eden birçok hastalık veya geçici stresin tespitinde kullanılma potansiyeline sahiptir.



## 6. KAYNAKLAR

- Acharya, U.R., Oh, S. L., Hagiwara, Y., Tan, J.H., Adeli, H., 2018. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals, *Computers in biology and medicine*, 100, 270-278.
- Ahmad, M.A., Khan, N.A., Majeed, W., 2014. Computer assisted analysis system of electroencephalogram for diagnosing epilepsy, *In 2014 22nd International Conference on Pattern Recognition*, 3386-3391.
- Ahmedt-Aristizabal, D., Fookes, C., Nguyen, K., Sridharan, S., 2018. Deep classification of epileptic signals, *In 2018 40th Annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 332-335.
- Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Farhan, L., 2021. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions, *Journal of big Data*, 8, 1-74.
- 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*, 64(6), 061907.
- Andrzejak, R.G., Schindler, K., Rummel, C., 2012. Nonrandomness, nonlinear dependence, and nonstationarity of electroencephalographic recordings from epilepsy patients, *Physical Review E*, 86(4), 046206.
- Antoniades, A., Spyrou, L., Took, C.C., Sanei, S., 2016. Deep learning for epileptic intracranial EEG data, *In 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP)*, 1-6.
- Bagaskara, A., Suryanegara, M., 2021. Evaluation of VGG-16 and VGG-19 Deep Learning Architecture for Classifying Dementia People, *In 2021 4th International Conference of Computer and Informatics Engineering (IC2IE)*, 1-4.
- Bazanov, O.M., Vernon, D., 2014. Interpreting EEG alpha activity, *Neuroscience and Biobehavioral Reviews*, 44, 94-110.
- Binnie, C., Prior, P.J.J.o.N., 1994. Electroencephalography, *Neurosurgery and Psychiatry*, 57(11), 1308-1319.
- Bizopoulos, P., Lambrou, G.I., Koutsouris, D., 2019. Signal2image modules in deep neural networks for eeg classification, *In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* 702-705.
- Boonyakitanont, P., Lek-Uthai, A., Chomtho, K., Songsiri, J., 2020. A review of feature extraction and performance evaluation in epileptic seizure detection using EEG, *Biomedical Signal Processing and Control*, 57, 101702.
- Chen, J., Berry, M.J., 2003. Selenium and selenoproteins in the brain and brain diseases, *Journal of Neurochemistry*, 86(1), 1-12.
- Cho, S.P., Lee, J., Park, H.D., Lee, K.J., 2006. Detection of arousals in patients with respiratory sleep disorders using a single channel EEG, *In 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, 2733-2735.
- Chua, K.C., Chandran, V., Acharya, U.R., Lim, C.M., 2011. Application of higher order

- spectra to identify epileptic EEG, *Journal of medical systems*, 35, 1563-1571.
- Çelebi, M., Güllü, M.K., 2019. Epileptic Seizure Forecasting Using AR Model Coefficients and Machine Learning Techniques, *In 2019 Medical Technologies Congress (TIPTEKNO)*, 1-4.
- DeArmond, S.J., Fusco, M.M., and Dewey, M.M., 1989. Structure of the human brain: a photographic atlas, *Oxford University Press*, 8-12.
- Du, R., Huang, J., Zhu, S., 2022. EEG-Based Epileptic Seizure Detection Model Using CNN Feature Optimization, *In 2022 15th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 1-6.
- Duru, A.D., Akdeniz, G., Kara, E., Özkara, Ç., Uzan, M., Ademoğlu, A., Demiralp, T., 2010. Epileptic source localizations based on EEG and SDE measurements, *In 2010 15th National Biomedical Engineering Meeting*, 1-4.
- Fan, J., Fang, L., Wu, J., Guo, Y., Dai, Q., 2020. From brain science to artificial intelligence, *Engineering*, 6(3), 248-252.
- Feng, B., Yu, T., Wang, H., Liu, K., Wu, W., Long, W., 2023. Machine learning and deep learning in biomedical signal analysis, *Frontiers in Human Neuroscience*, 17, 1183840.
- Feng, T., Liu, J., Fang, X., Wang, J., Zhou, L., 2020. A double-branch surface detection system for armatures in vibration motors with miniature volume based on ResNet-101 and FPN, *Sensors*, 20(8), 2360.
- Ghosal, P., Nandanwar, L., Kanchan, S., Bhadra, A., Chakraborty, J., Nandi, D., 2019. Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network, *In 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, pp. 1-6.
- Goodfellow, I., Bengio, Y., Courville, A., 2016. Deep learning, *MIT Press*, 353-359.
- Gooijers, J., Swinnen, S.P., 2014. Interactions between brain structure and behavior: the corpus callosum and bimanual coordination, *Neuroscience and Biobehavioral Reviews*, 43, 1-19.
- Görgülü, Ü., Fesci, H., 2011. Epilepsi ile yaşam: Epilepsinin psikososyal etkileri, *Göztepe Tıp Dergisi*, 26(1), 27-32.
- Grafstein, B., 1975. The nerve cell body response to axotomy, *Experimental Neurology*, 48(3), 32-51.
- Herrmann, C.S., Demiralp, T., 2005. Human EEG gamma oscillations in neuropsychiatric disorders, *Clinical Neurophysiology*, 116(12), 2719-2733.
- Hossain, M.S., Amin, S.U., Alsulaiman, M., Muhammad, G., 2019. Applying deep learning for epilepsy seizure detection and brain mapping visualization, *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 15(1s), 1-17.
- Hosseini, M.P., Soltanian-Zadeh, H., Elisevich, K., Pompili, D., 2016. Cloud-based deep learning of big EEG data for epileptic seizure prediction, *In 2016 IEEE global conference on signal and information processing (GlobalSIP)*, 1151-1155.
- Jadhav, P., Rajguru, G., Datta, D., Mukhopadhyay, S., 2020. Automatic sleep stage classification using time–frequency images of CWT and transfer learning using

- convolution neural network, *Biocybernetics and Biomedical Engineering*, 40(1), 494-504.
- Janiesch, C., Zschech, P., Heinrich, K., 2021. Machine learning and deep learning, *Electronic Markets*, 31(3), 685-695.
- Jasper, H.H., 1958. Ten-twenty electrode system of the international federation, *Electroencephalogr. Clinical Neurophysiology*, 10, 371-375.
- Kaplan, K., 2020. Beyin tümör tiplerinin makine öğrenmesi ve derin öğrenme tabanlı teknikler ile sınıflandırılması.
- Kaur, T., Diwakar, A., Mirpuri, P., Tripathi, M., Chandra, P.S., Gandhi, T.K., 2021. Artificial intelligence in epilepsy, *Neurology India*, 69(3), 560.
- Kaya, Y., and Ertuğrul, Ö.F. 2018. A stable feature extraction method in classification epileptic EEG signals, *Australasian physical and engineering sciences in medicine*, 41, 721-730.
- Khan, R.U., Zhang, X., Kumar, R., Aboagye, E.O., 2018. Evaluating the performance of resnet model based on image recognition, *In Proceedings of the 2018 International Conference on Computing and Artificial Intelligence*, 86-90.
- Khazi, M., Kumar, A., Vidya, M.J., 2012. Analysis of EEG using 10: 20 electrode system, *International Journal of Innovative Research in Science, Engineering and Technology*, 1(2), 185-191.
- Kim, J. H., Seo, S.Y., Song, C.G., Kim, K.S., 2019. Assessment of electrocardiogram rhythms by GoogLeNet deep neural network architecture, *Journal of healthcare engineering*, 1-10.
- Kirschstein, T., Köhling, R., 2009. What is the source of the EEG?, *Clinical EEG and neuroscience*, 40(3), 146-149.
- 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.
- Kumar M.A., Chakrapani, A., 2022. Classification of ECG signal using FFT based improved Alexnet classifier, *Plos One*, 17(9), e0274225.
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *Nature*, 521(7553), 436-444.
- Li, P., Karmakar, C., Yearwood, J., Venkatesh, S., Palaniswami, M., Liu, C., 2018. Detection of epileptic seizure based on entropy analysis of short-term EEG, *PloS one*, 13(3), e0193691.
- Maganti, R.K., Rutecki, P., 2013. EEG and epilepsy monitoring, *CONTINUUM: Lifelong Learning in Neurology*, 19(3), 598-622.
- Malekzadeh, A., Zare, A., Yaghoobi, M., Kobravi, H.R., Alizadehsani, R. 2021. Epileptic seizures detection in EEG signals using fusion handcrafted and deep learning features, *Sensors*, 21(22), 7710.
- Meintjes, A., Lowe, A., Legget, M., 2018. Fundamental heart sound classification using the continuous wavelet transform and convolutional neural networks, *In 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 409-412.

- Morley, A., Hill, L., Kaditis, A.G., 2016. 10-20 system EEG Placement, *European Respiratory Society*, 4-13.
- Najafabadi, M.M., Villanustre, F., Khoshgoftaar, T.M., Seliya, N., Wald, R., Muharemagic, E., 2015. Deep learning applications and challenges in big data analytics, *Journal of Big Data*, 2(1), 1-21.
- Nicolaou, N., Georgiou, J., 2012. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines, *Expert Systems with Applications*, 39(1), 202-209.
- Nielsen, M.A., 2015. Neural networks and deep learning, *USA: Determination press*, 25, 15-24.
- Noachtar, S., Rémi, J., 2009. The role of EEG in epilepsy: a critical review, *Epilepsy and Behavior*, 15(1), 22-33.
- Ongsulee, P., 2017. Artificial intelligence, machine learning and deep learning, *In 2017 15th international conference on ICT and knowledge engineering (ICTandKE)*, 1-6.
- Pal, D.K., Carpio, A., Sander, J.W., 2000. Neurocysticercosis and epilepsy in developing countries, *Journal of Neurology, Neurosurgery and Psychiatry*, 68(2), 137-143.
- Park, C., Choi, G., Kim, J., Kim, S., Kim, T. J., Min, K., Chong, J., 2018. Epileptic seizure detection for multi-channel EEG with deep convolutional neural network, *In 2018 International Conference on Electronics, Information, and Communication (ICEIC)*, 1-5.
- Parvez, M.Z., and Paul, M., 2014. Epileptic seizure detection by analyzing EEG signals using different transformation techniques, *Neurocomputing*, 145, 190-200.
- Paul, S., Verma, J.K., Datta, A., Shaw, R.N., Saikia, A., 2018. Deep learning and its importance for early signature of neuronal disorders, *In 2018 4th International Conference on Computing Communication and Automation (ICCCA)*. 1-5.
- Perlis, M.L., Merica, H., Smith, M.T., Giles, D.E., 2001. Beta EEG activity and insomnia, *Sleep medicine reviews*, 5(5), 365-376.
- Ramakrishnan, S., Muthanatha Murugavel, A.S., 2019. Epileptic seizure detection using fuzzy-rules-based sub-band specific features and layered multi-class SVM, *Pattern Analysis and Applications*, 22(3), 1161-1176.
- Rossi, P.G., Parmeggiani, A., Bach, V., Santucci, M., Visconti, P., 1995. EEG features and epilepsy in patients with autism, *Brain and Development*, 17(3), 169-174.
- Roy, A.D., and Islam, M.M., 2020. Detection of Epileptic Seizures from Wavelet Scalogram of EEG Signal Using Transfer Learning with AlexNet Convolutional Neural Network, *In 2020 23rd International Conference on Computer and Information Technology (ICCIT)*, 1-5.
- Roy, S., Kiral-Kornek, I., Harrer, S., 2018. Deep learning enabled automatic abnormal EEG identification, *In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2756-2759.
- Sagga, D., Ectiou, A., Khemakhem, R., Ghorbel, M., 2020. Epileptic seizure detection using EEG signals based on 1D-CNN Approach, *In 2020 20th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)*, 51-56.

- Sameer, M., and Gupta, B., 2022. Time–frequency statistical features of delta band for detection of epileptic seizures, *Wireless Personal Communications*, 122, 489-499.
- Schacter, D. L. 1977. EEG theta waves and psychological phenomena: A review and analysis, *Biological psychology*, 5(1), 47-82.
- Shaha, M., Pawar, M., 2018. Transfer learning for image classification, *Paper presented at the 2018 second international conference on electronics, communication and aerospace technology (ICECA)*.
- Sharanreddy, M., Kulkarni, P.K., 2013. Can EEG test helps in identifying brain tumor?, *International Journal of Health and Medical Engineering*, 7(11), 703-708.
- Shoeb, A.H., 2009. Application of machine learning to epileptic seizure onset detection and treatment, *Doctoral dissertation, Massachusetts Institute of Technology*, 85-90.
- Smith, S.J., 2005. EEG in the diagnosis, classification, and management of patients with epilepsy, *Journal of Neurology, Neurosurgery and Psychiatry*, 76(suppl 2), ii2-ii7.
- Swami, P., Gandhi, T.K., Panigrahi, B.K., Tripathi, M., Anand, S., 2016. A novel robust diagnostic model to detect seizures in electroencephalography. *Expert Systems with Applications*, 56, 116-130.
- Tadeusiewicz, R., 2010. Neural network as a tool for medical signals filtering, diagnosis aid, therapy assistance and forecasting improving, *In World Congress on Medical Physics and Biomedical Engineering, September 7-12, 2009, Munich, Germany: Vol. 25/4 Image Processing, Biosignal Processing, Modelling and Simulation, Biomechanics*, 1532-1534.
- Takahashi, M., Gouko, M., Ito, K., 2009. Fundamental research about electroencephalogram (EEG)-functional electrical stimulation (FES) rehabilitation system, *In 2009 IEEE International Conference on Rehabilitation Robotics*, 316-321.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., Liu, C., 2018. A survey on deep transfer learning, *In Artificial Neural Networks and Machine Learning–ICANN 2018: 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings*, 3(27), 270-279.
- Thijs, R.D., Surges, R., O'Brien, T.J., Sander, J.W., 2019. Epilepsy in adults, *The Lancet*, 393(10172), 689-701.
- Thomas, J., Comoretto, L., Jin, J., Dauwels, J., Cash, S.S., Westover, M.B., 2018. EEG classification via convolutional neural network-based interictal epileptiform event detection, *In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 3148-3151.
- Tian, X., Deng, Z., Ying, W., Choi, K.S., Wu, D., Qin, B., Wang, S., 2019. Deep multi-view feature learning for EEG-based epileptic seizure detection, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(10), 1962-1972.
- Türk, Ö., and Özerdem, M.S., 2019. Epilepsy detection by using scalogram based convolutional neural network from EEG signals, *Brain sciences*, 9(5), 115.
- Tzallas, A.T., Tsipouras, M.G., Fotiadis, D.I., 2009. Epileptic seizure detection in EEGs

using time–frequency analysis, *IEEE transactions on information technology in biomedicine*, 13(5), 703-710.

- Tzallas, A.T., Tsipouras, M.G., Tsalikakis, D.G., Karvounis, E.C., Astrakas, L., Konitsiotis, S., Tzaphlidou, M., 2012. Automated epileptic seizure detection methods: a review study, *Epilepsy–Histological, Electroencephalographic and Psychological Aspects*, 2027-2036.
- Ullah, I., Hussain, M., 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.
- Wen, L., Li, X., Gao, L., 2020. A transfer convolutional neural network for fault diagnosis based on ResNet-50, *Neural Computing and Applications*, 32, 6111-6124.
- Wen, T., Du, Y., Pan, T., Huang, C., Zhang, Z., 2021. A deep learning-based classification method for different frequency EEG data, *Computational and Mathematical Methods in Medicine*, 2021.
- Wen, T., and Zhang, Z., 2018. Deep convolution neural network and autoencoders-based unsupervised feature learning of EEG signals, *IEEE Access*, 6, 25399-25410.
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *nature*, 521(7553), 436-444.
- Yao, X., Cheng, Q., Zhang, G.Q. 2019. A novel independent rnn approach to classification of seizures against non-seizures, *arXiv preprint arXiv*,1903.09326..
- Yoo, H.J., 2015. Deep convolution neural networks in computer vision: a review, *IEIE Transactions on Smart Processing and Computing*, 4(1), 35-43.
- Yu, W., Yang, K., Bai, Y., Xiao, T., Yao, H., Rui, Y., 2016. Visualizing and comparing AlexNet and VGG using deconvolutional layers, *In Proceedings of the 33 rd International Conference on Machine Learning*, 5-7.
- Yuan, Y., Xun, G., Jia, K., Zhang, A., 2017. A multi-view deep learning method for epileptic seizure detection using short-time fourier transform, *In Proceedings of the 8th ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, 213-222.
- Yuan, Y., Xun, G., Jia, K., Zhang, A., 2018. A multi-view deep learning framework for EEG seizure detection, *IEEE journal of biomedical and health informatics*, 23(1), 83-94.
- Zabidi, A., Mansor, W., Lee, Y.K., Fadzal, C.C.W., 2012. Short-time Fourier Transform analysis of EEG signal generated during imagined writing, *In 2012 International Conference on System Engineering and Technology (ICSET)*, 1-4.
- Zhang, Y., Zhang, Y., Wang, J., Zheng, X., 2015. Comparison of classification methods on EEG signals based on wavelet packet decomposition, *Neural Computing and Applications*, 26, 1217-1225.
- Zhao, X., Solé-Casals, J., Li, B., Huang, Z., Wang, A., Cao, J., Zhao, Q., 2020. Classification of epileptic EEG signals by CNN and data augmentation, *In ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 926-930.

Url-1<<https://www.doktorfizik.com/sinir-sistemi/norobilim/beyin-dalgalari-nedir-tipleri/>>, [Ziyaret Tarihi: 28 Mayıs 2023].

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı:** Abdulkadir BULDU

### EĞİTİM

<b>Derece</b>	<b>Kurum</b>	<b>Mezuniyet Tarihi</b>
Lisans	Kocaeli Üniversitesi Mekatronik Mühendisliği	2020
Lise	İstanbul Bahçelievler Anadolu Lisesi	2015

### İŞ DENEYİMLERİ

<b>Yıl</b>	<b>Kurum</b>	<b>Görev</b>
2022- ...	Siirt Üniversitesi Elektrik - Elektronik Mühendisliği Bölümü	Araştırma Görevlisi

### YABANCI DİL

Almanca, İngilizce