



DERİN ÖĞRENME TABANLI EPİLEPTİK NÖBET TEŞHİSİ

Muhammet VARLI

**2022
YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Hakan YILMAZ**

DERİN ÖĞRENME TABANLI EPİLEPTİK NÖBET TEŞHİSİ

Muhammet VARLI

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Hakan YILMAZ**

**KARABÜK
Ocak 2022**

Muhammet VARLI tarafından hazırlanan “DERİN ÖĞRENME TABANLI EPİLEPTİK NÖBET TEŞHİSİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Hakan YILMAZ

.....

Tez Danışmanı, Biyomedikal Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 05/01/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Ergin YILMAZ (BEÜN)

.....

Üye : Dr. Öğr. Üyesi Hakan YILMAZ (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Daver ALI (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Muhammet VARLI

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI EPİLEPTİK NÖBET TEŞHİSİ

Muhammet VARLI

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Hakan YILMAZ

Ocak 2022, 59 sayfa

Epilepsi hastalığı yaygın nörolojik hastalıklardan bir tanesi olarak öne çıkmaktadır. Epilepsi hastalığının teşhisinde elektroensefalografi (EEG) kullanılarak beynin sinirsel aktivitesi gözlemlenir ve bu da epilepsi hastalığının teşhisine olanak sağlar. Günümüzde genel olarak biyolojik sinyallerden hastalık teşhisinde klasik makine öğrenmesi yöntemleri sıklıkla kullanılmakla birlikte son yıllarda derin öğrenme yapıları ön plana çıkmaktadır. Derin öğrenme ağları sinyallerden özellik çıkarımına gerek duymaması, özellikler için ek bir çaba gerektirmemesi, insan kaynaklı hesaplama hatalarının ve zaman kaybının önüne geçmesi açısından klasik makine öğrenmesi yöntemlerine göre daha avantajlı bir konuma gelmektedir. Bu çalışmada, zaman serisi EEG sinyalini zaman-frekans bileşenlerini temsil edecek görüntüleri ve ham EEG sinyallerinin sayısal değerlerini kullanarak epilepsi nöbet aktivitesini otomatik bir şekilde tespit eden ve EEG sinyallerini sınıflandıran kombine bir derin öğrenme modeli oluşturulmaya çalışılmıştır. Çalışmada Bonn Üniversitesi'nin halka açık epilepsi veri seti kullanılmıştır.

Veri seti, sađlıklı ve epilepsi hastası insanlardan kaydedilen A, B, C, D, E řeklinde etiketlenmiř EEG kayıtlarını iermektedir. Bu alıřmada, EEG sinyallerinin zaman dizisini ve zamana bađlı EEG sinyallerinin zaman-frekans-görüntü dönüşümlerini kullanarak kombine bir model ortaya konulmuřtur. Sinyalleri görüntüleme dönüşürmede CWT ve STFT yöntemleri kullanılmıřtır. CWT ve STFT yöntemleri ile oluřturulan görüntülerle ayrı ayrı iki model oluřturulmuřtur. Veri setindeki A, B, C, D ve E setleri eřitli kombinasyonlar ile bir araya getirilerek EEG sinyalleri ikili ve üçlü sınıflandırmalar ile sınıflandırılmıřtır. İkili sınıflandırmalar için skalogram ve spektrogram görüntüleriyle sırasıyla %99.07, %99.28 ve üçlü sınıflandırmalar için skalogram ve spektrogram görüntüleriyle sırasıyla %97.60, %98.56 ortalama dođruluk oranları elde edilmiřtir. 8 katlı apraz dođrulama iřlemi yapılan AB_CDE, ABCD_E ve AB_CD_E kombinasyonları için sırasıyla %99.21 (± 0.56), %99.50 (± 0.45) ve %98.84 (± 1.58) ortalama dođruluk oranları elde edilmiřtir. Oluřturulan model, EEG verilerinde epilepsi nöbet aktivitesinin olup olmadıđını ve EEG sinyallerinin sınıflandırmasını yüksek başarı oranı ile yapabilmektedir.

Anahtar Sözcükler : Epilepsi, evriřimli sinir ađı, yinelenen sinir ađı, EEG, epileptik nöbet teřhisi.

Bilim Kodu : 92.5.17

ABSTRACT

M. Sc. Thesis

DEEP LEARNING BASED EPILEPTIC SEIZURE DIAGNOSIS

Muhammet VARLI

Karabük University

Institute of Graduate Programs

Department of Biomedical Engineering

Thesis Advisor:

Assist. Prof. Dr. Hakan YILMAZ

January 2022, 59 pages

Epilepsy stands out as one of the common neurological diseases. In the diagnosis of epilepsy, the neural activity of the brain is observed using electroencephalography (EEG), which allows the diagnosis of epilepsy disease. Although classical machine learning methods are frequently used to diagnose diseases from biological signals, deep learning structures have come to the fore in recent years. Deep learning networks are in a more advantageous position than classical machine learning methods in that they do not require feature extraction from signals, do not require additional effort for features, and prevent human-induced computational errors and time loss. In this study, a combined deep learning model that automatically detects epileptic seizure activity and classifies EEG signals by using images representing time-frequency components of time series EEG signal and numerical values of raw EEG signals has been tried to be created. The public epilepsy dataset of the University of Bonn was used in the study. The dataset includes EEG recordings labeled as A, B, C, D, E recorded from healthy and epileptic people.

This study presents a combined model using the time sequence of EEG signals and time-frequency-image transformations of time-dependent EEG signals. CWT and STFT methods were used to convert signals to images. Two models were created separately with the images created by CWT and STFT methods. A, B, C, D, and E sets in the dataset were combined with various combinations, and EEG signals were classified with binary and triple classifications. Average accuracy rates of 99.07%, 99.28%, respectively, in binary classifications and 97.60% and 98.56%, respectively, were obtained with scalogram and spectrogram images in triple classifications. The average accuracy rates of 99.21% (± 0.56), 99.50% (± 0.45), and 98.84% (± 1.58) were obtained with the combinations of AB_CDE, ABCD_E, and AB_CD_E, which underwent 8-fold cross-validation, respectively. The created model can determine whether there is epileptic seizure activity in EEG data and classify EEG signals with a high success rate.

Key Word : Epilepsy, convolutional neural network, recurrent neural network, EEG, epileptic seizure diagnosis

Science Code : 92.5.17

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Hakan YILMAZ'a sonsuz teşekkürlerimi sunarım.

Sevgili aileme manevi hiçbir yardımını esirgmeden yanımda oldukları için tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	5
EPİLEPSİ.....	5
2.1. EEG VE EEG SİNYALLERİ.....	5
2.2. EPİLEPSİ NÖBETİ VE EPİLEPSİ NÖBET TÜRLERİ	7
2.3. EEG SİNYALLERİNİN SINIFLANDIRMASI	8
BÖLÜM 3	10
EPİLEPSİ ÜZERİNE YAPILAN ÇALIŞMALAR	10
3.1. MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE YAPILAN ÇALIŞMALAR	10
3.2. DERİN ÖĞRENME YAKLAŞIMLARI İLE YAPILAN ÇALIŞMALAR... 12	
BÖLÜM 4	16
MATERYAL VE YÖNTEM	16
4.1. VERİ SETİ	16
4.2. VERİ ÖN İŞLEME	17

	<u>Sayfa</u>
4.3. SİNYAL DÖNÜŞÜMLERİ	17
4.3.1. Fourier Dönüşümü	18
4.3.2. Kısa Zamanlı Fourier Dönüşümü	19
4.3.3. Sürekli Dalgacık Dönüşümü	21
4.4. EVRİŞİMLİ SİNİR AĞLARI	24
4.5. YİNELEMELİ SİNİR AĞI	26
4.6. 2D CNN + RNN KOMBİNE MODELİ	27
4.7. HİPER PARAMETRE OPTİMİZASYONU	30
4.8. MODEL PERFORMANSI DEĞERLENDİRME	33
BÖLÜM 5	36
ÇALIŞMA BULGULARI VE TARTIŞMA	36
5.1. ÖNERİLEN MODEL İLE ELDE EDİLEN BULGULAR	36
5.2. TARTIŞMA	46
BÖLÜM 6	51
SONUÇLAR	51
KAYNAKLAR	54
ÖZGEÇMİŞ	59

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. 10-20 uluslararası EEG elektrot yerleştirme sistemi.....	5
Şekil 2.2. Bonn veri setinden EEG kayıt örnekleri	6
Şekil 3.1. Makine öğrenmesi yaklaşımlarının şematik gösterimi	11
Şekil 3.2. Derin öğrenme yaklaşımlarının şematik gösterimi	13
Şekil 4.1. EEG sinyalinin bölütlenmesi.....	17
Şekil 4.2. FT ile elde edilen sinyal spektrumu.	19
Şekil 4.3. STFT ile elde edilen spektrogram görüntüsü.....	20
Şekil 4.4. CWT ile elde edilen skalogram görüntüsü.....	22
Şekil 4.5. EEG sinyal dönüşümleri	23
Şekil 4.6. Her set için spektrogram ve skalogram görüntü örnekleri.....	24
Şekil 4.7. LSTM blok diyagramı.....	27
Şekil 4.8. Model blok diyagramı	28
Şekil 4.9. Skalogram scale parametresinin etkisi	31
Şekil 4.10. Spektrogram pencere boyutu parametresinin etkisi	31
Şekil 5.1. Çeşitli kombinasyonlarla ROC eğrileri	45

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. Epilepsi nöbetlerinin sınıflandırması	8
Çizelge 2.2. İkili EEG sınıflandırmaları	9
Çizelge 2.3. Üçlü EEG sınıflandırmaları	9
Çizelge 4.1. Bonn üniversitesi veri seti.....	16
Çizelge 4.2. CNN bloğu	29
Çizelge 4.3. RNN bloğu	29
Çizelge 4.4. Concatenate sonrası blok	29
Çizelge 4.5. Karışıklık matrisi örneği	34
Çizelge 5.1. Skalogram görüntüleriyle yapılan ikili sınıflandırma sonuçları	37
Çizelge 5.2. Spektrogram görüntüleriyle yapılan ikili sınıflandırma sonuçları.....	39
Çizelge 5.3. Skalogram görüntüleriyle yapılan üçlü sınıflandırma sonuçları.....	41
Çizelge 5.4. Spektrogram görüntüleriyle yapılan üçlü sınıflandırma sonuçları.....	42
Çizelge 5.5. Çeşitli kombinasyonlarla elde edilen çapraz doğrulama sonuçları.....	44
Çizelge 5.6. Bonn veri seti ile yapılan benzer çalışmalarda elde edilen ikili sınıflandırma sonuçları ile karşılaştırma	47
Çizelge 5.7. Bonn veri seti ile yapılan benzer çalışmalarda elde edilen üçlü sınıflandırma sonuçları ile karşılaştırma	50

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

μ	: Mi
τ	: Tau
σ	: Sigma
$\psi(t)$: Dalgacık Fonksiyonu
$W(t)$: Pencereleme Fonksiyonu
$f(t)$: Zaman Alanındaki Sinyal
a	: Ölçeklendirme Parametresi
b	: Kaydırma (Öteleme) Parametresi

KISALTMALAR

EEG	: Electroencephalography (Elektroensefalografi)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağları)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ağı)
LSTM	: Long Short-Term Memory (Uzun-Kısa Süreli Bellek)
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
STFT	: Short-Time Fourier Transform (Kısa Zamanlı Fourier Dönüşümü)
WT	: Wavelet Transform (Dalgacık Dönüşümü)
CWT	: Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
EMD	: Empirical Mode Decomposition (Ampirik Mod Ayırıştırma)
IMF	: Intrinsic Mode Function (İntrinsik Mod Fonksiyonları)
KNN	: K-Nearest Neighbors (K-En Yakın Komşu)
LDA	: Linear Discriminant Analysis (Doğrusal Ayırma Analizi)
NB	: Naive Bayes (Naive Bayes)
LBP	: Local Binary Patterns (Yerel İkili Örüntüler)

HOG : Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)
HVD : Hilbert Vibration Decomposition (Hilbert Titreşim Ayrıştırmasını)
DCT : Discrete Cosine Transform (Ayrık Kosinüs Dönüşümü)
ARMA : Auto-Regressive Moving Average (Oto-Regresif Hareketli Ortalama)
DWT : Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
ILAE : International League Against Epilepsy (Epilepsiye Karşı Uluslararası Birlik)
FT : Fine Tuning (İnce Ayar)
TL : Transfer Learning (Transfer Öğrenimi)
RGB : Red Green Blue (Kırmızı Yeşil Mavi)
BN : Batch Normalization (Toplu Normalizasyon)
FC : Fully Connected (Tam Bağlantılı)
TP : True Positive (Gerçek Pozitif)
FN : False Negative (Yanlış Negatif)
TN : True Negative (Gerçek Negatif)
FP : False Positive (False Positive)
TPR : True Positive Rate (Gerçek Pozitif Oranı)
FPR : False Positive Rate (False Positive Oranı)
ROC : Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
AUC : Area Under the Curve (Eğri Altındaki Alan)
Hz : Frekans

BÖLÜM 1

GİRİŞ

Epilepsi hastalığı yaklaşık olarak dünya genelinde 70 milyondan fazla kişiyi etkilemektedir [1]. Bu kadar çok sayıda insanı etkisi altına almasından dolayı epilepsi, dünya çapında oldukça fazla insanın muzdarip olduğu bir nörolojik hastalık olarak bilinmektedir. Epilepsi, beynin olağan elektriksel aktivitesi dışında sinir hücrelerinde meydana gelen anormal elektriksel boşalmalar sonucu ortaya çıkabilen kronik bir rahatsızlıktır [2]. Epilepsi nöbetleri aniden meydana gelebilir ve hastaların günlük yaşantılarını olumsuz yönde etkiler. EEG, beynin elektriksel aktivitesinin gözlemlenmesinde kullanılan invaziv olmayan klinik bir tanı yöntemi olarak kabul edilir. EEG sinyalleri düşük uzamsal çözünürlüğe sahip olmasının aksine yüksek zamansal çözünürlüğe sahiptir ve bu da sinyal analizi için önemli bir avantaj sağlamaktadır [3].

EEG sinyalleri beyinde gerçekleşen sinirsel aktiviteleri doğrudan gösterdiği için birçok sinirsel hastalığın teşhisinde doktor için önemli bir tanı yöntemi olarak kabul görmektedir. EEG sinyalleri her ne kadar birçok sinirsel hastalığın teşhisinde önemli rol oynasa da bazen doktorların sinyaller üzerinden doğrudan hastalık tespiti yapması mümkün olmamaktadır. Bunun gibi durumlarda hastalığı tespit etmek için sinyal işleme ile sinyallerdeki hastalığa ait özelliklerin gün yüzüne çıkarılmasına başvurulabilir. Sinyal işleme ile ortaya çıkarılan özellikler makine öğrenmesi veya derin öğrenme gibi son yıllarda sıklıkla kullanılan yöntemler sayesinde otomatik olarak tespit edilebilmektedir.

EEG sinyallerinden epilepsi, otizm, parkinson gibi birçok nörolojik rahatsızlığın tespiti mümkündür. Nörolojik rahatsızlıkların otomatik teşhisi ile ilgili birçok çalışma mevcuttur [4–7]. EEG sinyallerinin özellikleri çıkarılarak bu özellikler sayesinde bir sınıflandırma yapılarak nörolojik hastalıklar otomatik olarak tespit edilmektedir.

EEG sinyalleri ile yapılan çalışmalar genel olarak iki farklı yaklaşım üzerine kurulmuştur. Bu yaklaşımlar, makine öğrenmesi yaklaşımları ve derin öğrenme yaklaşımlarıdır. Her iki yaklaşımda günümüzde sıklıkla kullanılmakla beraber son yıllarda derin öğrenme ile yapılan çalışma sayısı hızla artmaktadır.

Makine öğrenmesi yaklaşımında modelde kullanılacak olan özellikler manuel olarak seçilmektedir. Makine öğrenmesi yaklaşımı, sinyallerden elde edilen özelliklerin bir kısmının çeşitli istatistiksel hesaplamalar vasıtasıyla kullanılmasını amaçlamaktadır. Sinyal özelliklerinden hesaplanan istatistiksel parametrelere katsayıların mutlak değerlerinin ortalaması, katsayıların mutlak değerlerinin maksimumu ve minimumu, katsayıların kuvvetlerinin ortalaması, standart sapma, varyans, çarpıklık gibi parametreler örnek verilebilir [8]. Bu istatistiksel parametreler hesaplanırken, makine öğrenmesi yaklaşımında sinyallerin tüm özelliklerinden ziyade manuel olarak seçilen belirli bir kısmı kullanılmaktadır. Bu sebepten dolayı sinyal içerisindeki önemli olabilecek özelliklerin kaybolması gibi sonuçlar ortaya çıkabilmektedir. Ayrıca özelliklerin manuel seçimi ve istatistiksel parametre hesaplamaları gibi işlemlerde insan faktörünün devreye girmesi insan kaynaklı hataların oluşmasına sebebiyet vermektedir. Son olarak makine öğrenmesi yaklaşımları özellik seçimi gibi işlemlerde insan kaynağı gerektirdiği için büyük veriler için verimli bir seçenek değildir.

Makine öğrenimi yaklaşımları sınıflandırma için geleneksel sinyal işleme yöntemlerinden türetilen özellik vektörlerini kullanır ve iyi bir doğruluk sağlar. Ancak bu tekniklerden geliştirilmiş bir model beklenemez. Verilerdeki gürültü ve yapaylıkların varlığı, özellik çıkarımının ve verilerin işlenmesini çok karmaşık hale getirir. Bu nedenle, özellikle sınırlı eğitim örnekleri mevcut olduğunda sadık performansa sahip geliştirilmiş bir model üretmek zordur. Bu gibi zorlukların önüne geçmek için derin öğrenme yaklaşımları iyi bir seçenek olabilir. Derin öğrenme yaklaşımları tıpkı insan beynindeki sinir hücrelerinin çalışmasını taklit eden çok katmanlı yapay sinir ağları ile çalışmaktadır. Derin öğrenme yapılarında insanlardakine benzer bir nöron bilgi iletim sistemi söz konusudur. Nöronlara gelen verilere aktivasyon fonksiyonu uygulanır ve fonksiyon sonucuna göre hangi bilgilerin çıkış katmanına ulaşacağına karar veren yapılar kullanılır. Derin öğrenme yaklaşımında modelde kullanılacak olan özellikler otomatik bir şekilde seçilerek

belirlenmektedir. Yani özellik çıkarımından sonra hiçbir insan müdahalesi olmaksızın modelde kullanılacak özellikler sistemin kendisi tarafından belirlenmektedir. Makine öğrenmesi yaklaşımlarındaki gibi insan kaynaklı hatalar oluşmamaktadır. Ayrıca derin öğrenme yaklaşımları büyük çaptaki verilerde elde ettiği başarılar sebebiyle oldukça ideal bir seçenek olarak öne çıkmaktadır. Son yıllarda derin öğrenme yapılarının elde ettiği yüksek başarılar ve sinyallerdeki gizli kalmış özelliklerin makine öğrenmesi yaklaşımları ile açığa çıkarılmasının zorluğu tez çalışmasının derin öğrenme yapıları üzerine kurulmasında rol oynamıştır.

Bu tez çalışmasının amacı, EEG sinyallerini kullanarak epilepsi nöbet aktivitesinin varlığı, epilepsi hastası ve sağlıklı birey ayrımı, epileptik nöbet ve nöbet öncesinin ayrımı, epilepsi hastalarının nöbet geçirme durumlarının tespiti gibi teşhislerin otomatik bir şekilde yapılmasını sağlamaktır. Çalışma kapsamında, halka açık olarak sunulan Bonn Üniversitesi'nin EEG verileri kullanılarak iki farklı derin öğrenme yaklaşımının birleştirilmesi ile kombine bir derin öğrenme modeli önerilmiştir. Tez çalışmasında, CNN (Evrışimli Sinir Ağları) ve bir RNN (Yinelenen Sinir Ağları) türü olan LSTM (Uzun-Kısa Süreli Bellek) olmak üzere iki farklı derin öğrenme yapısı kullanılmıştır.

Son yıllarda hızlı bir şekilde gelişen ve yaygınlaşan derin öğrenme yaklaşımları birçok alanda sıklıkla kullanılmaktadır. Tıp alanında derin öğrenme yapıları ile hastalık teşhisi, hastalıklara ait biyobelirteçlerin tespiti gibi birçok çalışma mevcuttur. Ancak nörolojik rahatsızlıkların tespiti ile ilgili çalışma sayısı çok fazla değildir. Özellikle epilepsi hastalığının teşhisi, epilepsi sınıflandırması gibi konularda derin öğrenme yapıları ile yapılan çalışmaların az olması bu tez çalışmasının önemini arttırmaktadır. Ayrıca Bonn veri seti üzerine literatürde yapılan çalışmalardan farklı olarak bu tez çalışmasında kombine bir derin öğrenme modeli önerilmiştir.

Bu tez çalışmasının birinci bölümünde "Giriş" başlığı altında tez çalışması ile ilgili özet bilgiler, tez çalışmasının amacı, tez çalışmasının önemi ve tez çalışmasının içeriği anlatılmıştır. İkinci bölümde EEG sinyalleri, epilepsi, epilepsi nöbeti ve epilepsi nöbet sınıflandırması hakkında bilgiler anlatılmıştır. Üçüncü bölümde epilepsi ile ilgili literatürde yapılan çalışmalar hakkında bilgiler verilmiştir. Dördüncü bölümde tez

alışmasında kullanılan materyaller, yöntemler ve önerilen yöntem hakkında detaylı bilgiler verilmiştir. Beşinci bölümde tez çalışmasında elde edilen bulgular ve literatürde Bonn veri seti ile yapılmış benzer çalışmaların karşılaştırılması verilmiştir. Altıncı bölümde ise çalışmanın sonucunda elde edilen bulgular tez çalışmasının amacına yönelik bir şekilde yorumlanarak önerilen yöntemin katkıları anlatılmıştır.


BÖLÜM 2

EPİLEPSİ

Epilepsi, tekrarlayan, rastgele ve ne zaman oluşacağı tahmin edilemeyen nöbetlerle tanımlanan kronik bir nörolojik rahatsızlıktır. Epilepsi normal sinirsel aktiviteye sahip nöronların çeşitli tetikleyiciler vasıtasıyla anormal sinirsel aktivite göstermesi sonucu ortaya çıkmaktadır.


2.1. EEG VE EEG SİNYALLERİ

EEG birçok nörolojik rahatsızlığın teşhisinde ve izlenmesinde kullanılan beyin dalgalarının elektriksel aktivitelerini ölçen klinik bir yöntem olarak bilinmektedir. EEG sinyalleri beynin sinirsel aktivitesi hakkında bilgiler barındırması açısından birçok nörolojik rahatsızlığın altında yatan sebeplerin incelenmesi için önemlidir. EEG sinyalleri beynin elektriksel aktivitesinin zamana göre değişen genliklerini içermektedir. EEG sinyalleri kafa derisine yerleştirilen elektrotlar vasıtası ile serebral elektriksel potansiyelleri ölçmektedir. EEG kaydı için elektrotlar Şekil 2.1’de gösterildiği gibi kafa derisine 10-20 elektrot sistemi adı verilen bir protokol ile yerleştirilmektedir [9].



Şekil 2.1. 10-20 uluslararası EEG elektrot yerleştirme sistemi [10].

EEG sinyalleri zaman alanlı sinyaller olup yetişkin bireylerde genlik değerleri yaklaşık olarak 10 μV ile 100 μV arasında değişmektedir [11]. Şekil 2.2’de bu tez çalışmasında kullanılan Bonn veri setindeki her bir set için birer EEG kaydı görselleştirilmiştir.



Şekil 2.2. Bonn veri setinden EEG kayıt örnekleri.

EEG sinyallerinin tipik olarak 0-63 Hz. arasında bilgi taşıdığı düşünülmektedir ve bu frekans aralığının dışındakiler gürültü olarak kabul edilebilir. EEG sinyallerinin frekans bantları genellikle Delta (0,1–4 Hz. veya 0,5–4 Hz.), Teta (4–8 Hz.), Alfa (8–14 Hz.), Beta (14–30 Hz.), Gama (30–63 Hz.) olarak kabul görmektedir [12].

2.2. EPİLEPSİ NÖBETİ VE EPİLEPSİ NÖBET TÜRLERİ

Epilepsi nöbetinin temeli normal elektriksel aktivitedeki nöronların aşırı ve hipersenkronize elektriksel boşalmalarıdır. Normal sinirsel aktivitede nöronların uyarım ve inhibisyonu bir denge içerisinde çalışmaktadır. Epilepsi nöbet aktivitesi meydana geldiğinde ise bu denge bozulmaktadır. Yani uyarıcı reseptörler aşırı uyarılır ya da inhibe edici reseptörler az inhibe edilir. Epilepsinin birçok sebebi olabilir. Örneğin genetik faktörler, tümör, merkezi sinir sistemi enfeksiyonları, bağışıklık aracılı iltihaplar, beyin dokusundaki gelişimsel bozukluklar, hipokampal lezyonlar, travma gibi birçok sebepten dolayı epilepsi oluşabilir.

Genel olarak epilepsi nöbetlerinin sınıflandırması kabaca başlama yerine göre sınıflandırılmaktadır. Genelleştirilmiş epilepsi nöbetleri beynin her iki yarım küresini de etkileyen nöbetlerdir. Odak epilepsi nöbetleri ise serebral korteksin küçük bir bölgesinde veya serebrumun daha derin bölgelerinde gerçekleşen nöbetlerdir. Odak epilepsi türü tek odaklı ve çok odaklı nöbetler içermekle birlikte bir yarım kürede meydana gelmektedir. Kombine genelleştirilmiş ve odak epilepsi nöbetleri hem odak hem de genelleştirilmiş nöbet türlerinin de meydana geldiği nöbet türüdür. Bilinmeyen nöbetler ise hastanın epilepsisinin olduğu bilinmesine rağmen eldeki verilerin hastanın genelleştirilmiş ya da odak epilepsisi olduğunun belirlenmesinde yeterli olmadığı durumları belirtmek için kullanılmaktadır. ILAE (Epilepsiye Karşı Uluslararası Birlik) tarafından yapılan epilepsi türlerinin sınıflandırması aşağıda Çizelge 2.1'de verilmiştir.

Çizelge 2.1. Epilepsi nöbetlerinin sınıflandırması.

1. Genelleştirilmiş Epilepsi Nöbetleri	a) Absans
	b) Miyoklonik
	c) Klonik
	d) Tonik
2. Odak Epilepsi Nöbetleri	a) Basit Odak
	b) Karmaşık Odak
3. Kombine Genelleştirilmiş ve Odak Epilepsi Nöbetleri	
4. Bilinmeyen Nöbetler (Epilepsi ancak Odak ya da Genelleştirilmiş Epilepsi olduğu bilinmeyen)	

2.3. EEG SİNYALLERİNİN SINIFLANDIRMASI

EEG sinyalleri beynin elektriksel aktivitesinin gözlemlenmesi açısından oldukça önemlidir ve beynin elektriksel aktivitesinin zamana göre değişimini göstermektedir. Bu yönüyle EEG, sağlıklı bireylerin sinirsel aktivitelerinin epilepsi rahatsızlığı olan hastaların sinirsel aktivitelerine göre farklılıklarının belirlenmesinde önemli bir tanı yöntemi olarak kullanılmaktadır. Ancak bazı durumlarda nörologlar sinyallerden doğrudan hastalık teşhisi veya nöbet aktivitesinin olup olmadığını belirlenmesinde zorluk yaşamaktadır. Bu zorlukların önüne geçmek adına EEG sinyallerini sınıflandırmada makine öğrenmesi veya derin öğrenme modelleri kullanılmaktadır.

Epilepsi hastalarından nöbet geçirmeden önce alınan EEG kayıtlarına inter-iktal EEG kayıtları, nöbet aktivitesi sırasında alınan EEG kayıtlarına ise iktal EEG kayıtları denilmektedir. Epilepsi nöbet anının tespitinde sağlıklı, inter-iktal ve iktal sınıflarının ayrımı oldukça önemlidir. Bu tez çalışmasında EEG kayıtlarında epileptik nöbet aktivitesinin var olup olmadığı, sağlıklı-hasta ayrımı, normal (sağlıklı)-interiktal-iktal gibi sınıflandırmalar ile EEG sinyallerinin sınıflandırması yapılmıştır. Bu tez çalışmasında ikili ve üçlü olmak üzere iki farklı şekilde sınıflandırma yapılmıştır. Çizelge 2.2’de ikili olarak yapılan sınıflandırmalar ve Çizelge 2.3’te ise üçlü olarak yapılan sınıflandırmalar verilmiştir.

Çizelge 2.2. İkili EEG sınıflandırmaları.

Durum	Sınıf 1	Sınıf 2
A_E	Sağlıklı	İktal
B_E	Sağlıklı	İktal
AB_E	Sağlıklı	İktal
C_E	İnter-iktal	İktal
D_E	İnter-iktal	İktal
CD_E	İnter-iktal	İktal
ABC_E	Nöbet Aktivitesi Yok	İktal
ABD_E	Nöbet Aktivitesi Yok	İktal
AC_E	Nöbet Aktivitesi Yok	İktal
ACD_E	Nöbet Aktivitesi Yok	İktal
AD_E	Nöbet Aktivitesi Yok	İktal
BC_E	Nöbet Aktivitesi Yok	İktal
BCD_E	Nöbet Aktivitesi Yok	İktal
BD_E	Nöbet Aktivitesi Yok	İktal
ABCD_E	Nöbet Aktivitesi Yok	İktal
AB_CDE	Sağlıklı	Epilepsi Hastası

Çizelge 2.3. Üçlü EEG sınıflandırmaları.

Durum	Sınıf 1	Sınıf 2	Sınıf 3
AB-CD-E	Sağlıklı	İnter-İktal	İktal
A-C-E	Sağlıklı	İnter-İktal	İktal
A-D-E	Sağlıklı	İnter-İktal	İktal
B-C-E	Sağlıklı	İnter-İktal	İktal
B-D-E	Sağlıklı	İnter-İktal	İktal
A_CD_E	Sağlıklı	İnter-İktal	İktal
B-CD-E	Sağlıklı	İnter-İktal	İktal
AB_C_E	Sağlıklı	İnter-İktal	İktal
AB_D_E	Sağlıklı	İnter-İktal	İktal

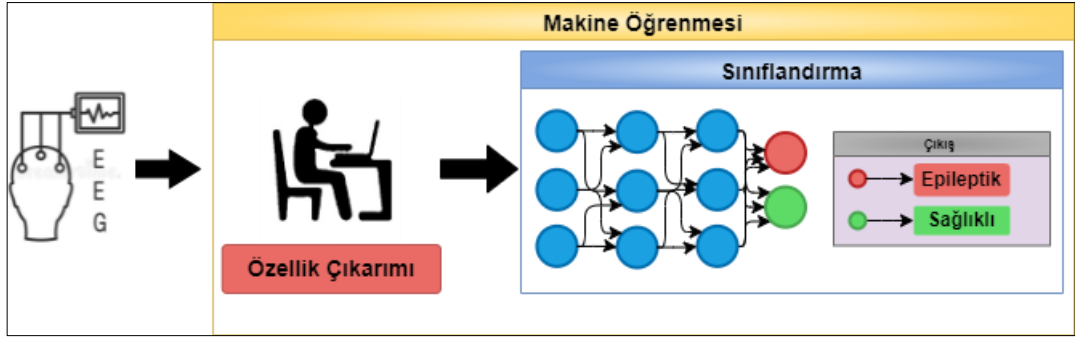
BÖLÜM 3

EPİLEPSİ ÜZERİNE YAPILAN ÇALIŞMALAR

Bu tez çalışmasında Bonn veri seti içerisindeki sağlıklı ve epilepsi hastası bireylerin EEG kayıtları ile kombine bir derin öğrenme algoritması oluşturulmuştur. Bu bölümde literatürde epilepsi sınıflandırması üzerine hem makine öğrenmesiyle hem de derin öğrenme ile yapılan çalışmalar ayrı ayrı ele alınmıştır.

3.1. MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE YAPILAN ÇALIŞMALAR

EEG sinyalleri zaman alanında sinyaller olup, sadece zaman ve genlik bilgisi mevcuttur. EEG sinyallerinin frekans alanındaki davranışlarını incelemek, analiz etmek ve sinyallerin frekans alanındaki özelliklerine ulaşabilmek için FFT (Hızlı Fourier Dönüşümü), STFT (Kısa Zamanlı Fourier Dönüşümü) ve WT (Dalgacık Dönüşümü) gibi sinyal dönüşümleri yapılmaktadır. Bu dönüşümler sonucunda ortaya çıkan özellikler ile çeşitli istatistiksel parametreler hesaplanmaktadır. Sinyalin öznitelik vektörlerinin oluşturulmasında kullanılan istatistiksel parametrelere katsayıların mutlak değerlerinin ortalaması, katsayıların mutlak değerlerinin maksimumu ve minimumu, katsayıların kuvvetlerinin ortalaması, standart sapma, varyans, çarpıklık gibi istatistiksel parametreler örnek verilebilir. Oluşturulan öznitelik vektörleri sınıflandırma işlemi için kullanılmaktadır. Daha önce de bahsedildiği üzere makine öğrenmesi yaklaşımlarında özniteliklerin oluşturulması işlemi manuel olarak yapılmaktadır. Bu sebepten dolayı insan kaynaklı hataların oluşması, sinyallerdeki önemli olan bazı özelliklerin hesaba katılmayarak kaybolması ve büyük çaptaki verilerin işlenmesinde zorluklar yaşanması gibi birçok sorun oluşabilmektedir. Şekil 3.1'de epilepsi sınıflandırmasıyla ilgili makine öğrenmesi yaklaşımları ile yapılan çalışmaların şematik gösterimi verilmiştir.



Şekil 3.1. Makine öğrenmesi yaklaşımlarının şematik gösterimi.

Aşağıda literatürde makine öğrenmesi yaklaşımları ile Bonn veri seti kullanılarak yapılan bazı çalışma örnekleri verilmiştir.

Wang vd. (2017) zaman alanı, frekans alanı, zaman-frekans alanı gibi birden fazla alanda öznitelik çıkarımı ve sinyallerin doğrusal olmayan analizinin kombinasyonuna dayanan çalışmalarında birden fazla sınıflandırıcı çeşidi ile sınıflandırma işlemi yapmışlardır. Çalışmalarında önerdikleri yöntem ile %99.25 ortalama doğruluk oranı elde etmişlerdir [13].

Mohammadpoory vd. (2017) EEG sinyallerinden WVGE (Ağırlıklı Görünürlük Grafiği Entropisi) yöntemi ile özellikler çıkarttıktan sonra EEG sinyallerinden epilepsi sınıflarını, normal (sağlıklı), nöbetsiz (inter-iktal) ve nöbet sırasında (iktal) şeklinde 3 gruba ayırarak SVM (Destek Vektör Makinesi), KNN (K-En Yakın Komşu), DT (Karar Ağacı) ve NB (Naive Bayes) sınıflandırıcılar ile sınıflandırmışlardır. Çalışmaları sonucunda %97 gibi bir doğrulukla EEG sinyallerini sınıflandırmışlardır [14].

Akan vd. (2018) EEG sinyallerinin zaman-frekans analizini gerçekleştirmek için EMD (Ampirik Mod Ayırıştırma) yöntemi ile IMF 'lere (İntrinsik Mod Fonksiyonları) ayırıştırmışlardır. Tsallis Entropy, Renyi Entropy, Relative Entropy ve Coherence yöntemleri ile öznitelik vektörleri oluşturularak KNN, LDA (Doğrusal Ayırma Analizi) ve NB sınıflandırma algoritmaları ile EEG sinyallerini sınıflandırmışlardır ve çalışmalarında %96.97 doğruluk değeri elde etmişlerdir. [15].


Rao vd. (2019) VMD (Değişken Mod Ayrışım) yöntemi ile gerçek değer modunu frekans spektrumu ile analitik sinyale dönüştürmüştür. Daha sonra öznelikleri oluşturmak için anlamsal öznelik çıkarımı uygulayarak diferansiyel entropi ve ortalama kare oranın tepe büyüklüğü gibi istatistiksel değerler hesaplatmışlardır. Rao vd. (2019) yaptığı bu çalışmada Random Forest sınıflandırıcı kullanmış ve %94.1 doğruluk oranında başarı sağlamışlardır [16].

Sheoran vd. (2020) EEG sinyallerini CWT (Sürekli Dalgacık Dönüşümü) ile zaman alanından frekans uzayına geçiş yaparak skalogram görüntülerini elde etmişlerdir. Daha sonra elde edilen skalogram görüntülerinden anlık frekans bileşenlerinin LBP (Yerel İkili Örüntüler) ve HOG (Yönlendirilmiş Gradyanların Histogramı) potansiyel özellik değerleri hesaplatılarak özellik çıkarımını yapmışlardır. Çalışmalarında SVM sınıflandırıcı ile %99.08 doğruluk değeri elde etmişlerdir [17].

3.2. DERİN ÖĞRENME YAKLAŞIMLARI İLE YAPILAN ÇALIŞMALAR

Derin öğrenme yaklaşımları son yıllarda kullanımı hızla artan yapılar olarak ön plana çıkmaktadır. Makine öğrenmesi yaklaşımlarında daha önce de bahsedildiği üzere özellik çıkarma işlemleri manuel olarak yapılmaktadır. Özellik çıkarımının manuel yapılması bazen karmaşık verilerde önemli özelliklerin kaybolmasına yani sınıflandırma işleminde hesaba katılmamasına sebebiyet verebilmektedir. Özellikle verilerin parazit ve yapaylık içermesi manuel özellik çıkarma işlemini çok daha karmaşık hale getirir. Büyük çaptaki verilerde manuel bir şekilde özellik çıkarma işlemi oldukça zaman kaybettirmektedir. Ayrıca manuel özellik çıkarma işleminde insan faktörünün işin içerisine girmesinden kaynaklı hataların oluşmasına sebep olabilmektedir. Tüm bu sorunların üstesinden gelmesi açısından derin öğrenme yaklaşımları tercih edilebilir. Çünkü derin öğrenme yaklaşımlarında özellik çıkarma işlemi otomatik bir şekilde sistemin kendisi tarafından yapılmaktadır. Derin öğrenme yaklaşımları ile insan kaynaklı hatalar, önemli verilerin kaybolması problemi, karmaşık verilerden özellik çıkarmanın zorluğu, büyük veri boyutlarında performans problemi gibi birçok sorunun üstesinden gelinmektedir. Derin öğrenme yaklaşımları verilerdeki üst düzey özellikleri öğrenmeye çalışır. Derin öğrenme yaklaşımlarının

veri boyutu arttıkça performansları artmaktadır. Şekil 3.2’de epilepsi sınıflandırmasıyla ilgili derin öğrenme yaklaşımları ile yapılan çalışmaların şematik gösterimi verilmiştir.



Şekil 3.2. Derin öğrenme yaklaşımlarının şematik gösterimi.

Aşağıda literatürde derin öğrenme yaklaşımları ile Bonn veri seti kullanılarak yapılan bazı çalışma örnekleri verilmiştir.

Acharya vd. (2018) EEG sinyallerinin 1D (boyutlu) halleri yani dizi veri noktası şeklindeki hallerini 1D CNN derin öğrenme yapısını kullanarak epilepsi sınıflandırmasını normal (sağlıklı), nöbetsiz (inter-iktal) ve nöbet sırasında (iktal) şeklinde sınıflandırmışlardır. Çalışmalarında kullandıkları model 13 katmanlı olup %88.67 doğruluk, %90.00 özgüllük ve %95.00 duyarlılık elde etmişlerdir [18].

Abbasi vd. (2019) EEG sinyallerini öncelikle DCT (Ayrık Kosinüs Dönüşümü) ile iki eşit frekans aralığında alt bantlara bölmüşlerdir. Daha sonra Hurst Exponent ve ARMA (Oto regresif Hareketli Ortalama) özellikleri çıkarıldıktan sonra çift katmanlı LSTM derin öğrenme ağı ile sınıflandırmışlardır. Çalışmaları EEG sinyallerini üçlü olarak normal (sağlıklı), nöbetsiz (inter-iktal) ve nöbet sırasında (iktal) şeklinde %94.81 doğruluk ve ikili olarak nöbetsiz (inter-iktal) ve nöbet sırasında (iktal) şeklinde %97.78 doğruluk oranlarını elde etmişlerdir [19].

Türk ve Özerdem (2019) zaman alanındaki EEG sinyallerini frekans alanına CWT yöntemi ile dönüştürerek skalogram görüntülerini elde etmişlerdir. Daha sonra elde

ettikleri skalogram görüntüleri ile 2D CNN derin öğrenme ağı ile Bonn veri seti içerisindeki A, B, C, D, E setlerindeki EEG kayıtlarını çeşitli kombinasyonlar ile sınıflandırmışlardır. Çalışmalarında ikili olarak A-E ve B-E setlerindeki sinyalleri %99.50, A-D ve B-D setlerindeki sinyalleri %100.00, üçlü olarak A-D-E setlerindeki sinyalleri %99.00, dördü olarak A-C-D-E setlerindeki sinyalleri %90.50, B-C-D-E setlerindeki sinyalleri %91.50 ve beşli olarak A-B-C-D-E setlerindeki sinyalleri %93.60 doğruluk oranında sınıflandırmışlardır [20].

Zhao vd. (2020) EEG sinyallerini, sinyalin 1 D hali ile 1D CNN derin öğrenme yapısını kullanarak sınıflandırmışlardır. Çalışmalarında elde ettikleri doğruluk oranları sırasıyla, iki sınıflı sınıflandırma probleminde %97.63~%99.52, üç sınıflı EEG sınıflandırma probleminde %96.73~%98.06 ve beş sınıflı sınıflandırma probleminde %93.55 olarak elde etmişlerdir [21].

Khan vd. (2021) HVD (Hilbert Titreşim Ayrıştırmasını) kullanarak EEG sinyalini genlik ve frekans açısından değişen çoklu tek bileşenli olarak elde etmişlerdir. HVD ile sinyalin özniteliklerini çıkarttıktan sonra korelasyon tabanlı Q-puanı ile seçilen özellikleri, LSTM tabanlı bir derin öğrenme modeli kullanarak sınıflandırmışlardır. Çalışmalarını iki farklı veri seti ile yapmışlardır. Bonn veri seti için %96.00 doğruluk, Sensor Networks Research Lab verileri için %83.30 doğruluk elde etmişlerdir [22].

Wang vd. (2021) EEG sinyallerinden özellik çıkarımını hem klasik yaklaşım olarak doğrusal olmayan öznitelik analizinde kullanılan EMD ve DWT (Ayrık Dalgacık Dönüşümü) yöntemleri ile hem de 1D sinyalden 1D CNN derin öğrenme vasıtasıyla otomatik bir şekilde özellik çıkarımı yapmışlardır. Klasik yaklaşım ile sinyalden bir zaman serisi özellik dizisi oluşturmak için zaman-frekans alanlı sinyal dalgası özelliklerini çıkartmışlardır. Oluşturulan bu zaman serisi özellik dizisini çift yönlü Bi-LSTM-AM (Uzun Kısa Süreli Hafıza Dikkat Makinesi) sınıflandırıcısı aracılığıyla soyutlamışlardır. Daha sonra soyutlanan klasik özellikleri, 1D CNN ile otomatik çıkarılan özellikleri birleştirmişlerdir. Son olarak özellikleri, MLP (Çok Katmanlı Algılayıcı) sınıflandırıcı ile sınıflandırmışlardır. Çalışmalarında Bonn veri seti için %92.07 doğruluk %91.13 duyarlılık ve %92.96 özgüllük elde etmişlerdir [23].

Rashed-Al-Mahfuz vd. (2021) EEG sinyallerini zaman alanından frekans alanına STFT ve CWT yöntemleri ile dönüştürerek STFT ile spektrogram, CWT ile skalogram görüntülerini elde etmişlerdir. Daha sonra çeşitli modeller ile epilepsi için EEG sınıflandırması yapmışlardır. Dört katmanlı CNN, TL (Transfer Öğrenimi) -VGG16, TL-ResNet50, FT (İnce Ayar) -VGG16 ve FT-ResNet50 olarak birden fazla model uygulamışlardır. FT-VGG16 modelleri ile en yüksek %99.21 doğruluk oranı elde etmişlerdir [24].

BÖLÜM 4

MATERYAL VE YÖNTEM

Materyal ve yöntem bölümünde, bu tez çalışmasında kullanılan veriler, verilerin hazırlanması, verilere uygulanan dönüşümler, modellemede kullanılan derin öğrenme yapıları, oluşturulan model, hiper parametre optimizasyonu ve model performansının değerlendirilmesi yapılmıştır.

4.1. VERİ SETİ


Veri seti olarak Bonn Üniversitesi'nin sunmuş olduğu EEG kayıtları kullanılmıştır [25]. Veri seti A, B, C, D, E olmak üzere beş set içermektedir. Her bir dizi toplam 23.6 saniye olmak üzere tek kanallı 100 EEG sinyal kaydından oluşmaktadır. EEG kayıtları her türlü kas hareketinden kaynaklı gürültülerden arındırılmıştır. A seti beş sağlıklı kişiden gözleri açık bir şekilde elde edilmiştir. B seti yine aynı beş sağlıklı kişiden gözleri kapalı bir şekilde elde edilmiştir. C, D, E setleri ise beş epilepsi hastasından elde edilen kayıtları içermektedir. C seti epilepsi hastalarına ait nöbet öncesi (inter-iktal) olup zıt hemisferik bölgenin hipokampal yarım küresinden kayıtlar içermektedir. D seti epilepsi hastası olup nöbet öncesi (inter-iktal) epileptik bölgeden kayıtlar içermektedir. E seti ise epilepsi hastalarının epilepsi nöbeti geçirirken (iktal) elde edilen kayıtları içermektedir. EEG verilerinin örnekleme frekansı 173.61 Hz.'dir. Veri seti için özet bilgiler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Bonn üniversitesi veri seti.

A	B	C	D	E
Sağlıklı	Sağlıklı	Epilepsi Hastası	Epilepsi Hastası	Epilepsi Hastası
100 Tane	100 Tane	100 Tane	100 Tane	100 Tane
23.6 sn.	23.6 sn.	23.6 sn.	23.6 sn.	23.6 sn.
Gözleri Açık	Gözleri Kapalı	Nöbet Öncesi Hipokampal Yarım Küreden	Nöbet Öncesi Epilepsi Bölgesi Üzerinden	Nöbet Anında

4.2. VERİ ÖN İŞLEME

Veri setinde her bir EEG kaydı 4097 veri noktasından oluşmaktadır. Veri sayısını çoğaltmak için veriler eşit parçalara bölünmüştür. 16 eşit parçaya bölmek için son veri noktaları silinerek 4096 veri noktası üzerinden işlem yapılmıştır. Bir EEG kaydından 16 tane 256 veri noktası içeren her bir set için toplam 1600 gözlem oluşturulmuştur. Böylece beş set için toplam 8000 tane gözlem elde edilmiştir. Oluşturulan modelde RNN kısmı için kullanılacak ham sinyaller için normalizasyon işlemi uygulanmıştır. Bu işlemin asıl amacı veri setindeki olası aykırı değerlerden kaynaklı olan olumsuz etkileri önleyebilmektir. EEG sinyalleriyle zaman alanından zaman-frekans alanına geçiş yaparak 2D-CNN yapısı için gerekli olan girdi görüntüleri elde edilmiştir. Dönüşümler için CWT ve STFT olmak üzere iki farklı yöntem kullanılmıştır. Şekil 4.1’de sinyallerin bölütlenmesi şematik olarak gösterilmiştir.



Şekil 4.1. EEG sinyalinin bölütlenmesi.

4.3. SİNYAL DÖNÜŞÜMLERİ

EEG sinyallerinin zaman alanından, frekans alanına geçmesini sağlamak amacı ile sinyal dönüşümleri yapılmaktadır. Sinyal dönüşümleri sinyallerin spektral analizlerinin yapılmasını sağlamaktadır. Bazen sinyaller içerisinde barındırdıkları

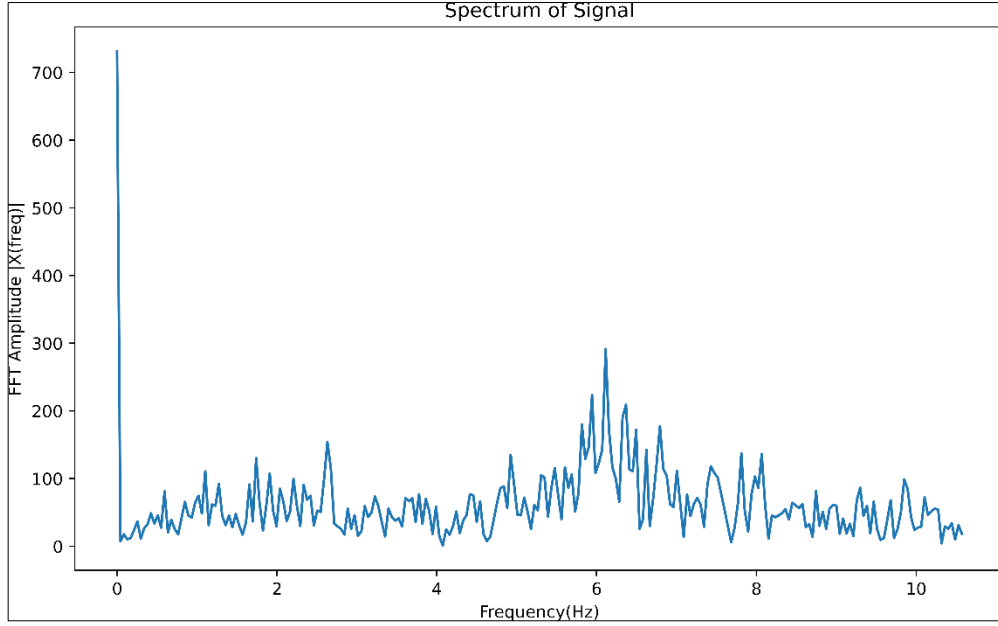
önemli özellikleri frekans alanında barındırabilir bu yüzden frekans alanına geçiş yapılması gerekmektedir. Sinyallerin frekans alanına geçiş yapmasını sağlayan önemli sinyal dönüşümlerine örnek olarak FT (Fourier Dönüşümü), STFT (Kısa Zamanlı Fourier Dönüşümü), CWT (Sürekli Dalgacık Dönüşümü), DWT (Ayrık Dalgacık Dönüşümü) sayılabilir. Bu tez çalışmasında EEG sinyallerinin frekans analizlerini gerçekleştirmek için STFT ve CWT sinyal dönüşümleri yapılmıştır. Sinyal dönüşümleri uygulandıktan sonra sinyallerin iki boyutlu görüntüleri elde edilmiştir. EEG sinyallerine STFT uygulandıktan sonra spektrogram görüntüleri, CWT uygulandıktan sonra ise skalogram görüntüleri oluşturulmuştur.

4.3.1. Fourier Dönüşümü

EEG sinyalleri zaman alanlı sinyallerdir. Yani zamana göre değişmektedir. Sinyallerin barındırdığı özellikler her zaman zaman alanında ortaya çıkmayabilir. Bu sebeple sıklıkla frekans alanına geçiş yapılmaktadır. FT (Fourier Dönüşümü) ile sinyaller frekans alanına dönüştürülebilir. Ancak FT'nin bazı eksik yönleri vardır. FT aynı anda zaman ve frekans lokalizasyonu sağlayamaz. Yani hem zaman hem de frekans bilgisine aynı anda ulaşılamaz. Eşitlik 4.1'de Fourier dönüşümü ifade edilmiştir. Burada $f(t)$ ile zaman alanında sinyal ifade edilmiştir. $F(w)$ ile sinyalin frekans alanındaki değeri ifade edilmektedir. Son olarak w frekans parametresini, t ise zaman parametresini ifade etmektedir.

$$F(w) = \int f(t)e^{-j\omega t} dt \quad (4.1)$$

FT sonrasında sinyalin sadece frekans ve genlik bilgisi mevcuttur. FT, zamana göre değişen, durağan olmayan sinyalleri analiz etmek için çok kullanışlı değildir. Yani durağan olmayan sinyaller için, sinyalin tam davranışını sağlayamaz. Bu yüzden durağan olmayan sinyallerin analizinde kullanılmamaktadır. FT, sinyallerdeki süreksizlikleri temsil etmek için uygun değildir. FT'nin bu eksikliklerinden dolayı bu tez çalışmasında FT kullanılmamıştır. Şekil 4.2'de EEG sinyalinin FT sonrasında elde edilen sinyal spektrumunun örneği gösterilmiştir.




Şekil 4.2. FT ile elde edilen sinyal spektrumu.

4.3.2. Kısa Zamanlı Fourier Dönüşümü

FT, zamana bağlı sinyalleri frekans alanına dönüştürmek için kullanılmaktadır. Yani sinyallerin spektral analizlerine olanak sağlar. FT, sinyali sonsuz sayıda sinüs/kosinüs dalgasına ayrıştırabilir. Fakat FT’de zaman bilgisi kaybolur sadece sinyalin genlik ve frekansı elde edilir. Yani olayın tam olarak nerede olduğu bilinemez. FT, sinyalin aniden patlamaları ve süreksizliği ile mücadele edemez. FT, durağan olmayan sinyalleri analiz etmek için uygun bir yöntem değildir [26]. FT’nin bu dezavantajlarının önüne geçebilmek adına STFT (Kısa Zamanlı Fourier Dönüşümü) geliştirilmiştir. STFT, FT’de yaşanan problemlerin önüne geçebilmek adına belirli bir zamanda sinyalin sadece küçük bir bölümünü analiz ederek hareket eder. Durağan olmayan sinyaller küçük parçalara ayrılır ve bu parçaların art arda geldiği düşünülür. Böylece her bir parçaya FT uygulanır. Bu parçalar bir pencereleme fonksiyonu uygulayarak elde edilir. Bu yöntemle sinyal pencereleme denir. STFT ile zamana bağlı sinyaller frekans ve zaman ekseninde ifade edilebilir. Yani STFT ile sinyallerin hem zaman bilgisi hem de frekans bilgisi elde edilmiş olur. STFT’nin en önemli sorunu pencereleme fonksiyonunun seçimidir. STFT’de pencere fonksiyonu seçiminde çözünürlük ikilemi ortaya çıkabilir. Pencere fonksiyonu seçilirken ya zaman ya da frekans çözünürlüğünden vazgeçilmesi gerekebilir. Dar pencereler iyi zaman

çözünürlüğü sağlarken düşük frekans çözünürlüğü verir. Geniş pencereler iyi frekans çözünürlüğü sağlarken düşük zaman çözünürlüğü verir. Bunun sonucu olarak bazı sinyallerin analizinde pencere boyutu optimum şekilde seçilmez ise çözünürlük ikilemini ortaya çıkarmaktadır. Bu sorunun önüne geçmek adına optimum pencere boyutu seçilebilir veya WT (Dalgacık Dönüşümü) kullanılabilir. Bu tez çalışmasında STFT’de pencereleme fonksiyonu olarak Hamming kullanılmıştır. STFT sonrasında spektrogram görüntüleri elde edilir. Spektrogram bir sinyalin zamanla değişen spektrumunun görsel temsidir. A, B, C, D, E setlerinin her birisi için 1600’er tane görüntü oluşturulmuştur. Toplamda 8000 adet spektrogram görüntüsü elde edilmiştir. Oluşturulan spektrogram görüntülerinin her biri 77x75 boyutlarındadır. Şekil 4.3’te STFT ile oluşturulan bölütlenmemiş haldeki spektrogram örneği verilmiştir. Eşitlik 4.2’de STFT ifade edilmiştir. Burada $f(t)$ zaman alanındaki sinyali, W ise pencereleme fonksiyonunu ifade etmektedir. Son olarak w frekans parametresini, t zaman parametresini ve τ ise yavaş zaman parametresini ifade etmektedir.

$$\gamma(w, \tau) = STFT\{f(t)\} = \int f(t)W(t - \tau)e^{-jw t} dt \quad (4.2)$$



Şekil 4.3. STFT ile elde edilen spektrogram görüntüsü.

4.3.3. Sürekli Dalgacık Dönüşümü

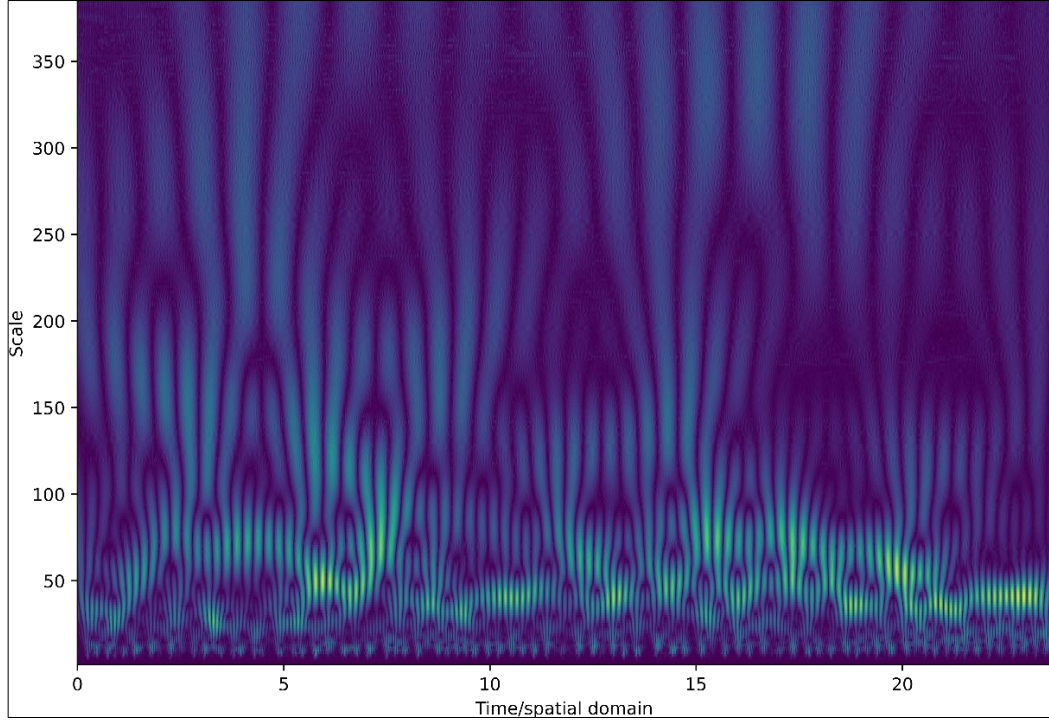
Wavelet Transform STFT'nin pencere boyutu seçiminden kaynaklanan çözünürlük kaybını azaltmayı amaçlamaktadır [27]. CWT'de (Sürekli Dalgacık Dönüşümü) ana dalgacık denilen bir pencereleme fonksiyonu kullanılır. Bu pencereleme fonksiyonunun STFT'de kullanılan pencereleme fonksiyonundan farklılığı ölçeklenebilir olmasıdır. CWT yapılırken dalgacık fonksiyonu zaman içerisinde kaydırılır ve Eşitlik 4.3'te gösterildiği gibi ölçeklendirilir.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R, \quad a \neq 0 \quad (4.3)$$

Burada a parametresi ölçeklendirme, b parametresi ise ötelemeyi yani kaydırmayı ifade eder. Düşük ölçek parametreleri sinyalleri sıkıştırırken yüksek ölçek parametreleri sinyalleri genişletir. Yüksek ölçek parametreleri düşük frekansları yakalarken, düşük ölçek parametreleri yüksek frekansları yakalar. CWT analiz edilecek olan sinyalin, dalgacık fonksiyonunun karmaşık eşleniği ile integrali şeklinde Eşitlik 4.4'te gösterildiği gibi tanımlanır. Burada f(t) zamana bağlı sinyali ifade etmektedir.

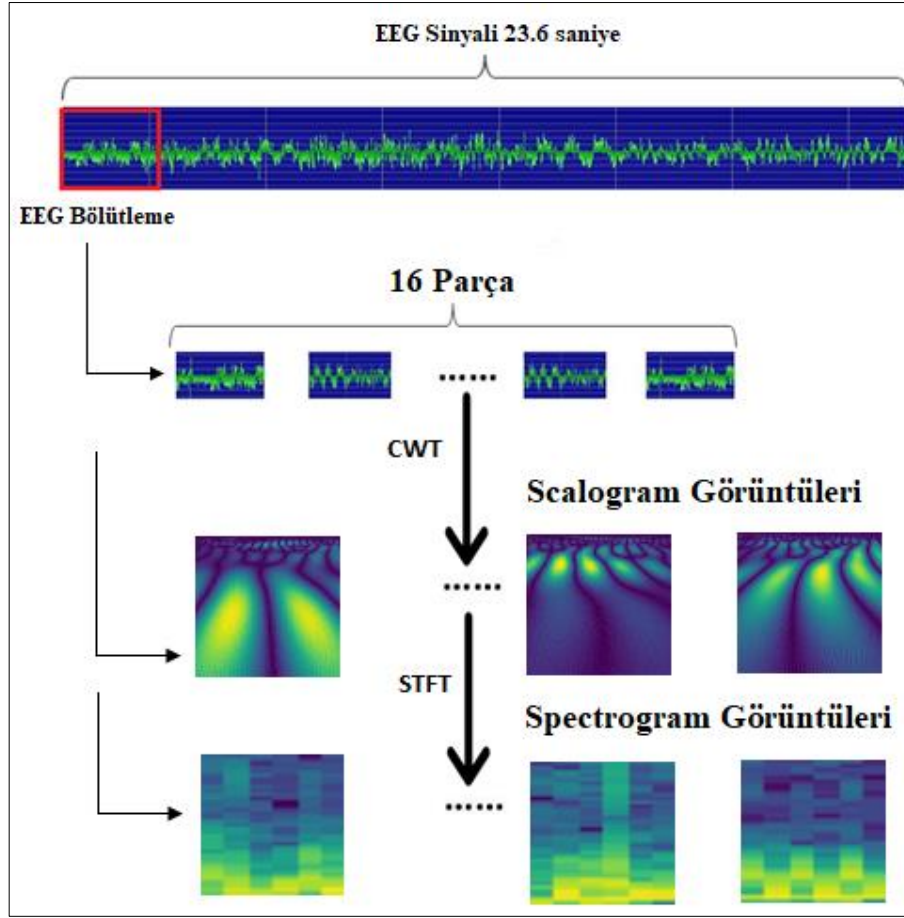
$$CWT\{f(t), a, b\} = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}^*(t) dt \quad (4.4)$$

EEG sinyalleri için düşük frekanstaki bilgilerde önemlidir. Çünkü EEG sinyallerinin Delta bandı oldukça düşük frekanslar içerir. Bu çalışmada ana dalgacık fonksiyonu olarak düşük frekanslarda etkili olan Morlet dalgacık fonksiyonu kullanılmıştır [12]. CWT dönüşümü yaptıktan sonra katsayılar ve ölçek parametrelerine göre sinyalin skalogram görüntüleri oluşturulur. A, B, C, D, E setlerinin her birisi için 1600'er tane görüntü oluşturulmuştur. Toplamda 8000 adet skalogram görüntüsü elde edilmiştir. Oluşan skalogram görüntülerinin her biri 77x75 boyutlarındadır. Şekil 4.4'te CWT ile oluşturulan bölütlenmemiş haldeki skalogram örneği verilmiştir.



Şekil 4.4. CWT ile elde edilen skalogram görüntüsü.

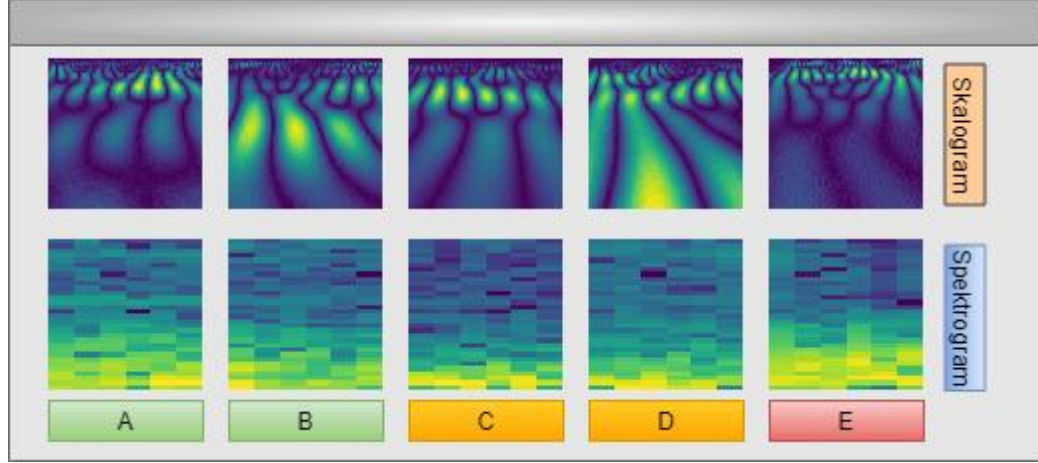
Sinyal görüntülerinin elde edildiği CWT ve STFT yöntemlerinin 4096 veri noktasına sahip her bir EEG kaydı için nasıl işleme alındığı ile ilgili olarak Şekil 4.5'te özet bir diyagram görselleştirilmiştir.



Şekil 4.5. EEG sinyali dönüşümleri.

EEG sinyalleri STFT ve CWT sinyal dönüşümleri uygulanmadan önce eş parçalara bölünmüştür. Bunun amacı veri sayısını artırarak derin öğrenme modelinin performansını yükseltmektir. Derin öğrenme modelleri veri sayısı arttıkça daha güzel performanslar ortaya koymaktadır.

4096 veri noktası olan her bir EEG kaydı 16 eş parçaya bölünmüştür. Bölünme sonrasında her bir EEG sinyali içerisinde toplam 256 adet veri noktası bulundurmaktadır. Bu sayı spektrogram ve skalogram görüntüleri için aynıdır. Veri集中的 bölünmüş sinyallerin her set için oluşturulan spektrogram ve skalogram görüntülerinden birer örnek Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Her set için spektrogram ve skalogram görüntü örnekleri.

4.4. EVRİŞİMLİ SİNİR AĞLARI

CNN (Evrışimli Sinir Ağları) tek, iki ya da üç boyutlu verilerde kullanılabilen bir derin öğrenme ağıdır. CNN genel olarak iki boyutlu verilerde özellikle görüntülerde kullanılmak için oluşturulmuştur [28]. CNN yapıları içerisinde çeşitli katmanlar barındırmaktadır.

Evrışim Katmanı: Bu katman CNN yapısı için oldukça önemlidir. Bu katman görüntüdeki özelliklerin tespit edilmesini sağlar. Görüntü verileri içerisinde düşük ya da yüksek dereceli özellikler barındırır. Bu özelliklerin algılanması için görüntüye filtre veya kernel adı verilen örnek bir matris uygulanır. Filtre matrisinin boyutları genellikle 3x3, 5x5, 7x7 gibi değerlerdedir. Filtre matrisi görüntünün sol üst köşesinden başlayarak görüntü boyunca kaydırılarak gezer. Filtre matrisi görüntü boyunca ilerlerken görüntü ve filtre matrisi değerleri indislerine göre birbirleri ile çarpılır ve elde edilen sonuçlar toplanır. Daha sonra toplam sonuç bir çıktı matrisine kaydedilir. Bu işlem tüm görüntü boyunca aynı şekilde devam ettirilir. Çıktı matrisine kaydedilen değerler sonucu oluşan matrisine Feature Map (Özellik Haritası) denir. Eğer görüntü üç kanallı bir görüntü ise, örnek olarak RGB bir görüntü için tüm işlemler her bir renk kanalında yapılır ve sonuçlar bias (önyargı) değeri ile toplandıktan sonra çıktı matrisi elde edilir. Bu işleme evrişim denir. Eşitlik 4.5 ve 4.6'da evrişim işlemi gösterilmiştir. Giriş görüntüsü f ile ifade edilirken, filtre h ile ifade edilmiştir.

$$G[m, n] = (f * h)[m, n] \quad (4.5)$$

$$G[m, n] = \sum_j \sum_k h[j, k]f[m - j, n - k] \quad (4.6)$$

BN (Batch Normalizasyon) Katmanı: Derin öğrenme yapılarında her bir katman bir sonraki katmanın girdisi şeklinde çalışır. Bir katmandaki öğrenme işlemi bitmeden bir diğer katmanda öğrenme işlemi başlamaz. Normalizasyon işlemi ile girdi değerleri standartlaştırılır. Ancak başta yapılan normalizasyon işleminden ara katmanlar yararlanamaz. Bu yüzden eğitim daha yavaş, daha kararsız ya da gradyan kaybolması yani öğrenmenin minimum düzeyde gerçekleşmesi gibi problemlerde karşılaşılabılır [29]. Tüm bu sorunların önüne geçmek adına BN kullanılır. BN uygulamanın model skorlarına olumlu yönde etkisi olduğu bilinmektedir [29].

Aktivasyon Katmanı: Bu katmana doğrusal olmayan katman da denilebilir. Bu katmanda doğrusal olmayan sigmoid, tanh, ReLU vb. aktivasyon fonksiyonları kullanılır. Aktivasyon fonksiyonları bir nöronun gelen girişe nasıl bir işlem uygulaması gerektiğini belirler ve böylece çıkışı oluşturur. Eşitlik 4.7'de tanh, Eşitlik 4.8'de sigmoid, Eşitlik 4.9'da ReLU ve Eşitlik 4.10'da softmax aktivasyon fonksiyonunun denklemi gösterilmiştir.

$$\text{Tanh}(x) = \tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(+x) + \exp(-x)} \quad (4.7)$$

$$\text{Sigmoid}(x) = \sigma(x) = \frac{1}{1 + \exp(-x)} \quad (4.8)$$

$$\text{ReLU}(x) = (x)^+ = \max(0, x) \quad (4.9)$$

$$S(y)_i = \frac{\exp(y_i)}{\sum_{j=1}^n \exp(y_j)} \quad (4.10)$$

Havuzlama (Pooling) Katmanı: Havuzlama katmanı, evrişim katmanı ile benzer şekilde çalışır ve görüntü boyutlarını küçülterek verilerin hesaplanma yükünü

azaltmaktadır [28]. Max Pooling ve Average Pooling olmak üzere iki çeşit havuzlama vardır. Max Pooling filtrenin/kernelin gezdiği kısmın maksimum değerini alır ve çıktı matrisinde depolar. Average Pooling ise filtrenin/kernelin kapsadığı kısmın ortalamasını alarak çıktı matrisinde depolar. Bu işlemi her iki havuzlama yöntemi de görüntü boyunca tekrarlayarak çıktı matrisini oluşturur. Max Pooling katmanı ayrıca bir gürültü bastırıcı olarak çalışmaktadır. Verideki gürültülü kısımları tamamen ortadan kaldırabilir. Bu yönü ile diğer pooling yönteminden daha iyi performans gösterebilir [28].

Bırakma (Dropout) Katmanı: Bu katman model eğitimi sırasında rastgele bir şekilde belirlenen oran miktarınca nöron birimlerinin in-aktif edilerek kullanılmamasını sağlamaktadır. Dropout katmanı hem modelin aşırı öğrenmesini (over-fitting) önleyebilir hem de modelin iş yükünü azaltır [30].

Flatten Katmanı: Bu katman sayesinde veriler tek boyutlu bir dizi haline getirilir. Bundan sonra gelecek olan FC (Tam Bağlantılı) katmanının giriş verisi Flatten sayesinde hazırlanmış olur.

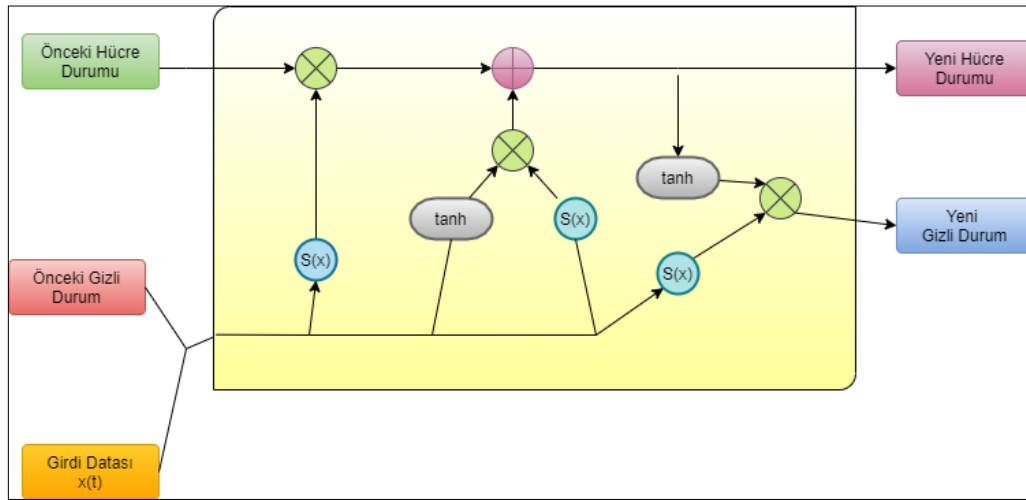
FC Katmanı: Flatten ile tek boyutlu dizi şekline getirilen veriler FC'nin giriş verisidir. FC'de her bir giriş tüm nöronlar ile bağlıdır.

4.5. YİNELEMELİ SİNİR AĞI

RNN (Yinelemeli Sinir Ağı) zaman serileri, doğal dil işleme ve sıralı veriler için kullanılmaktadır [29]. Normalde klasik derin öğrenme ağlarında giriş ve çıkışlar birbirinden bağımsız bir şekildedir. Ancak RNN'lerde girdiler birbiriyle ilişkilidir. Bir önceki katmandaki girdilerden alınan çıktı hafızaya alınır. Yani RNN'lerin kısa süreli bir hafızası vardır. Diğer katmanda girdiler ile bir girdi olarak kullanılır. RNN'de her çıkış bir önceki adıma bağımlıdır. Bir önceki girdiler sonraki katmanın çıktısını etkilemektedir. Ancak RNN'nin bu kısa süreli hafızası bazı durumlarda yetersiz kalmaktadır. Ayrıca geriye yayılımda gradyan yok olması yani öğrenmenin minimum düzeyde kalmasına sebep olabilmektedir [29].

LSTM (Uzun-Kısa Süreli Bellek), RNN'nin bu eksikliklerinin önüne geçmek için ortaya çıkmıştır. RNN'de bir tane tanh katmanı varken LSTM'de hafıza hücresi, unutma kapısı, giriş kapısı ve çıkış kapısı olmak üzere dört farklı katman bulunmaktadır [31].

Hafıza hücresi, unutulmaması gereken önemli bilgiyi hücreler boyunca taşıyan iletim hattına ve ağ hafızasına verilen isimdir. Bu yöntem ile kısa- süreli hafıza probleminin önüne geçilir. Unutma kapısı, bir sigmoid fonksiyonu vasıtasıyla hangi bilgilerin hafızada tutulacağı ve hangi bilgilerin unutulacağına karar verir. Hafıza hücresinin, önceki ve sonraki bilginin sigmoid işleminin sonucu ve tanh işlemi sonucu çarpılarak güncellenip güncellenmeyeceğine giriş kapısı karar verir. Çıkış kapısı, sonraki hücrenin girişini belirlemek için kullanılır. Çıkış kapısı önceki bilgi ve mevcut girişin sigmoid fonksiyonu sonucu ile hafıza hücresinde var olan bilginin tanh fonksiyonundaki sonucunu çarparak bir sonraki hücrenin giriş bilgilerine karar verir. Şekil 4.7'de LSTM'in içyapısındaki bileşenler gösterilmiştir.

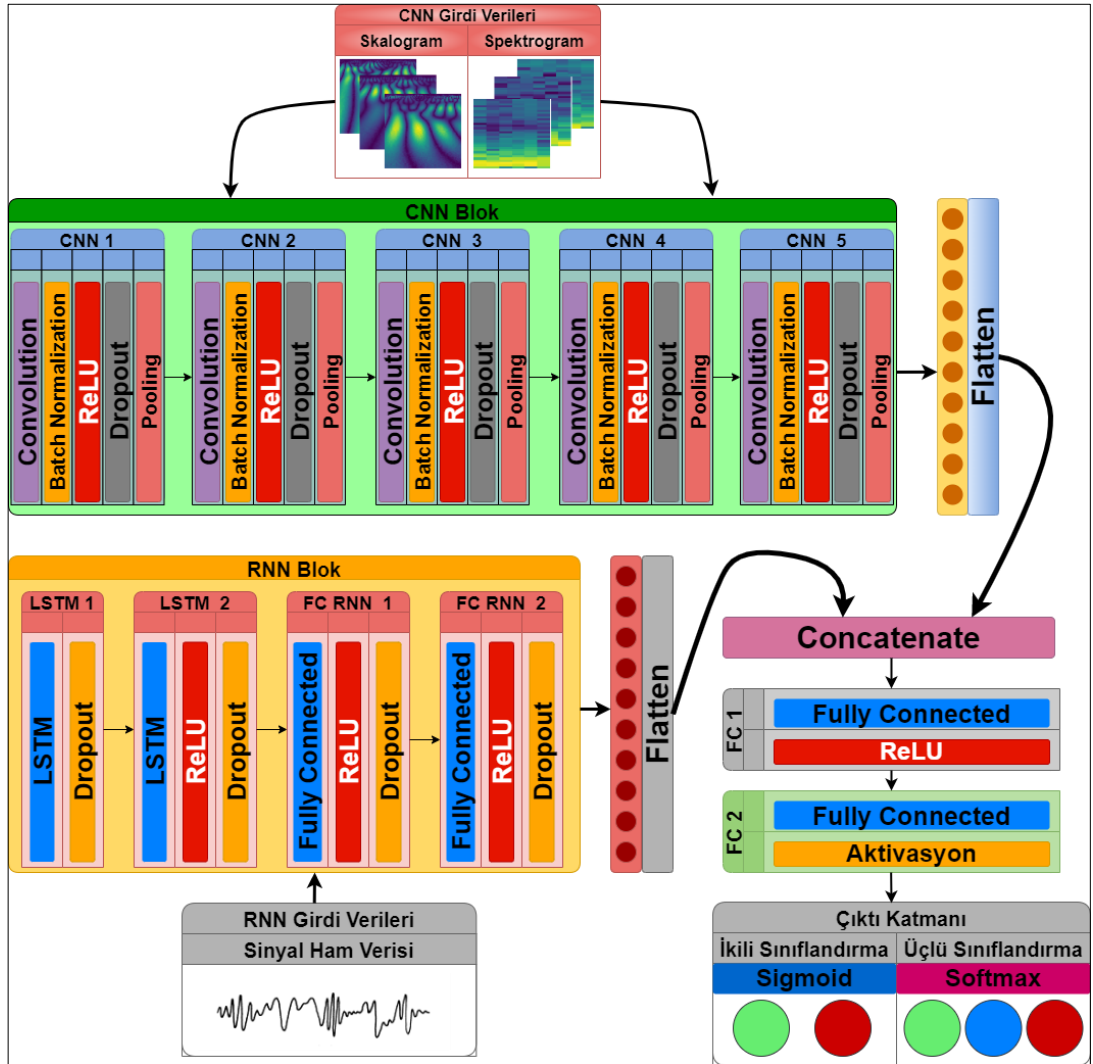


Şekil 4.7. LSTM blok diyagramı.

4.6. 2D CNN + RNN KOMBİNE MODELİ

Bu tez çalışmasında CNN ve RNN yapılarının ikisi de kullanılarak kombine bir sistem oluşturulmuştur. CNN bloğunda beş katman CNN kullanılmıştır. RNN bloğu için iki katman LSTM yapısı kullanılmıştır. Daha sonra her iki blok düzleştirilerek

birleştirilmiştir. Birleştirildikten sonra model sanki tek bir yapı gibi FC katmanı eklenmiştir. Daha sonra sınıflandırma katmanı için çıkış katmanı eklenmiştir. Modelde hem ikili hem de üçlü sınıflandırma işlemi yapıldığı için buradaki aktivasyon fonksiyonu ve çıkış sayısı farklılık göstermektedir. İkili sınıflandırma için sigmoid aktivasyon fonksiyonu ile model çıktısı elde edilmiştir. Üçlü sınıflandırma için softmax aktivasyon fonksiyonu ile model çıktısı elde edilmiştir. Model blok diyagramı Şekil 4.8’de gösterilmiştir.



Şekil 4.8. Model blok diyagramı.

CNN bloğu için kullanılan parametreler Çizelge 4.2’de RNN bloğu için kullanılan parametreler Çizelge 4.3’te ve birleştirme işlemi sonrasında kullanılan parametreler

ise Çizelge 4.4’te verilmiştir. Modelde dropout oranı olarak 0.2 kullanılmıştır. Optimizer olarak Adam kullanılmıştır. Batch_size olarak ise 4 seçilmiştir.

Çizelge 4.2. CNN bloğu.

Blok	Tipi	Kernel Boyutu	Filtre Sayısı	Stride
Convolution 1	Convolution	3x3	32	1
	BN	-	-	-
	ReLU	-	-	-
	Dropout	-	-	-
	Max-Pooling	2x2	-	-
Convolution 2	Convolution	3x3	64	1
	BN	-	-	-
	ReLU	-	-	-
	Dropout	-	-	-
	Max-Pooling	2x2	-	-
Convolution 3	Convolution	3x3	128	1
	BN	-	-	-
	ReLU	-	-	-
	Dropout	-	-	-
	Max-Pooling	2x2	-	-
Convolution 4	Convolution	3x3	64	1
	BN	-	-	-
	ReLU	-	-	-
	Dropout	-	-	-
	Max-Pooling	2x2	-	-
Convolution 5	Convolution	3x3	32	1
	BN	-	-	-
	ReLU	-	-	-
	Dropout	-	-	-
	Max-Pooling	2x2	-	-

Çizelge 4.3. RNN bloğu.

Blok	Tipi	Nöron Sayısı
LSTM_1	LSTM	256
	Dropout	-
LSTM_2	LSTM	64
	ReLU	-
	Dropout	-
FC_RNN1	Fully Connected	128
	ReLU	-
	Dropout	-
FC_RNN2	Fully Connected	32
	ReLU	-
	Dropout	-

Çizelge 4.4. Concatenate sonrası blok.

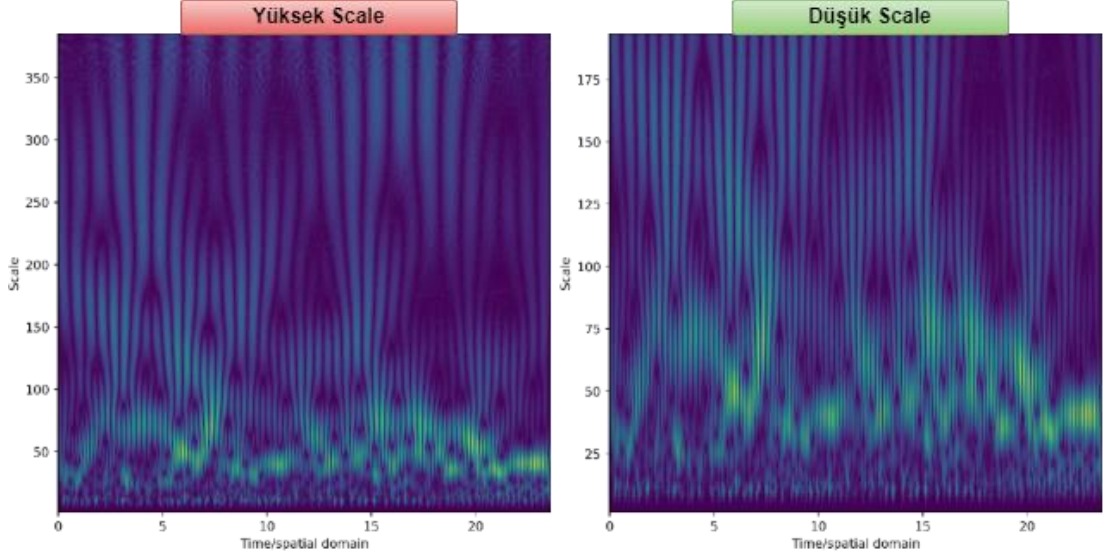
Blok	Tipi	Nöron Sayısı
Flatten 1	Flatten	256
Flatten 2	Flatten	256
Concatenate	Concatenate	
FC 1	Fully Connected	1024
	ReLU	-
FC 2	Fully Connected	
	Softmax / Sigmoid	3/1

4.7. HİPER PARAMETRE OPTİMİZASYONU

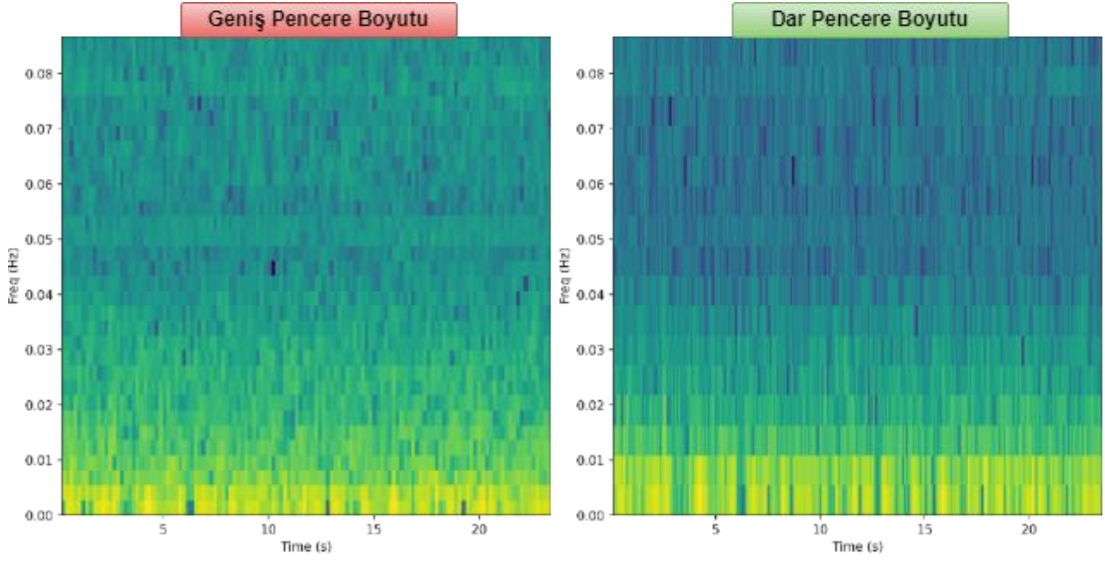
Bu tez çalışmasında model ve sinyal görüntülerinin oluşturulmasında birçok hiper parametre optimize edilmiştir. Bu hiper parametreler modelin eğitimini dolayısıyla elde edilen skorları doğrudan etkilemektedir. Skalogram görüntülerini elde ederken Mexican Hat, Morlet ve Gaussian ana dalgacık fonksiyonları denenmiştir. Elde edilen sonuçlara göre daha iyi sonuç vermesinden dolayı Morlet ana dalgacık fonksiyonu tercih edilmiştir. Skalogram görüntülerini oluştururken ölçek (scale) parametresi sinyaldeki gizli olan önemli özelliklerin ortaya çıkmasında oldukça önemlidir. Düşük ölçek (low scale) parametreleri ana dalgacık fonksiyonunun daralmasına sebep olur ve sinyaldeki yüksek frekans bileşenlerinin yakalanmasına olanak sağlar. Yüksek ölçek (high scale) parametreleri ana dalgacık fonksiyonunun genişlemesine sebep olur ve sinyaldeki düşük frekans bileşenlerinin yakalanmasına olanak sağlar. Scale parametresini 1,5'ten 384'e kadar 1,5'er aralıklarla seçerek sinyaldeki özelliklerin açığa çıkması sağlanmıştır. Şekil 4.9'da düşük ve yüksek scale parametresinin görüntü üzerindeki etkileri gösterilmiştir. Düşük scale parametresi ile oluşturulan görüntü yüksek scale parametresi ile oluşturulan görüntüye göre daha yüksek frekanstaki değerlerin gözlemlenmesini sağlamıştır ve bunun sonucu olarak düşük frekanstaki bazı sinyal özelliklerinin elde edilmesi zorlaşmıştır.

Spektrogram görüntüleri için ise pencere boyutunun seçimi oldukça önemlidir. Dar pencere boyutları iyi zaman çözünürlüğü sağlarken düşük frekans çözünürlüğü verir. Geniş pencere boyutları iyi frekans çözünürlüğü sağlarken düşük zaman çözünürlüğü verir. Pencere boyutundaki bu değişiklikler de çözünürlük ikilemini ortaya çıkarmaktadır. Bu sorunun önüne geçmek adına optimum pencere boyutu seçilmelidir. Spektrogram görüntülerini elde ederken Hamming, Hann, Blackman ve Kaiser pencereleme fonksiyonları denenmiştir. Elde edilen sonuçlara göre daha iyi sonuç vermesinden dolayı Hamming pencereleme fonksiyonu tercih edilmiştir. Pencere boyutu 64 olarak seçilmiştir. Çalışmada “noverlap” parametresi yani pencereler arasında örtüşecek nokta sayısı ise 32 olarak belirlenmiştir. Şekil 4.10'da dar ve geniş pencere boyutunun görüntü üzerindeki etkileri gösterilmiştir. Dar pencere boyutu ile oluşturulan görüntü zamansal olarak iyi sonuç göstermesine rağmen frekans çözünürlüğü açısından geniş pencere boyutuna göre daha düşük sonuçlar vermektedir.

Oluşturulan sinyal görüntü çeşitlerinden her iki yöntem için de kullanılan parametreler özenli bir şekilde ayarlanarak en iyi performansı elde edecek parametreler seçilmiştir.



Şekil 4.9. Skalogram scale parametresinin etkisi.



Şekil 4.10. Spektrogram pencere boyutu parametresinin etkisi.

Özellikle modelin görüntü verilerinin hazırlanmasında birçok deneme yapılmıştır. Yapılan denemeler sonucunda en iyi sonuç veren parametrelerin belirlenmesi oldukça uğraştırıcı ve zaman alıcı bir süreç olmuştur. Verilerin düzgün bir şekilde hazırlanıp doğru parametrelerin belirlenmesi modelin başarısını doğrudan etkilemektedir. Bu

sebepten dolayı görüntü verilerini oluştururken gereken parametreler özenli bir şekilde seçilip tekrar tekrar denenmiştir.

Model için birçok hiper parametre mevcuttur. Bu hiper parametreler modelin performansını oldukça etkilemektedir. Model için en iyi performansı veren hiper parametrelerin belirlenmesi oldukça uzun zaman alan bir işlemdir. Model eğitiminde bir devirin bitme süresi ortalama 23 sn. olmakla birlikte modelin kaç devirde eğitileceği ise belirsizdir. Çünkü bazı modeller erken durdurma fonksiyonu sayesinde eğer aşırı öğrenme veya az öğrenme durumu mevcutsa durdurulmaktadır. Ancak ortalama olarak 10 tane hiper parametrenin deneme işlemi yaklaşık olarak 4-5 saat arasında sürmektedir. Hiper parametre optimizasyonunda deneme sayısı denenecek parametrelerin birbiri ile çarpımı ile belirlenmektedir. Bu süre, modelde kullanılan veri seti bölümlenmesi, hiper parametre, model eğitimi sırasında rastgele bırakılan özellikler gibi birçok etken ile değişmektedir.

Öncelikle modeldeki uygun olabilecek nöron sayıları ve katman sayısının belirlenmesi gereklidir. Modelin CNN bloğunda kullanılan nöron sayıları ile ilgili olarak 32-64-128-64-32, 16-32-64-32-16 ve 64-128-256-128-64 denenmiştir. RNN bloğunda ise 256-64-128-32 ve 512-128-256-64 nöron sayıları denenmiştir. Son olarak her iki bloğun birleştirilmesinden sonraki FC katmanının nöron sayısı olarak 1024, 512 ve 256 nöron sayıları denenmiştir.

Modeldeki CNN ve RNN bloklarının aktivasyon fonksiyonları belirlenmesi için CNN bloğu için 'relu', 'tanh', 'selu', 'elu', 'sigmoid' fonksiyonları, RNN bloğu için ise ('relu', 'sigmoid', 'relu'), ('sigmoid', 'relu', 'relu'), ('relu', 'elu', 'relu'), ('relu', 'relu', 'relu') kombinasyonları denenmiştir. Her iki bloğun birleştirilmesinden sonraki FC katmanının aktivasyon fonksiyonu için ise 'relu', 'elu' fonksiyonları denenmiştir.

Optimizör (optimize edici) seçimi için Adam, Nadam, SGD, RMSprop, Adamax optimizör çeşitleri denenmiştir. Modelde dropout oranı için ise 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7 değerleri denenmiştir. Batch_size için 4, 8, 16 değerleri denenmiştir. Öğrenme oranı üst sınırı 10^{-5} olacak şekilde belirlenmiştir. Eğitim sırasında eğitim sürecine göre öğrenme oranı fonksiyon tarafından değiştirilerek öğrenmenin en iyi şekilde

devam etmesi sağlanmıştır. Eğitim sırasında oluşabilecek maksimum devir sayısı ise 300 olarak belirlenmiştir.

Model için tüm bu bahsedilen parametreleri bir arada denemeye çalışmak yaklaşık olarak 75600 tane denemenin yapılması anlamına gelmektedir. Bu kadar çok sayıda deneme ise bir hayli fazla zaman gerektirmektedir. Bu sebepten dolayı bazı parametreleri parçalayarak birbiriyle deneme yöntemi ile uygun parametreler belirlenmiştir. Son olarak yüksek sonuç veren denemelerin parametreleri birlikte ele alınarak en iyi performans veren hiper parametreler belirlenmiştir. CNN bloğunda kullanılan nöron sayıları 32-64-128-64-32, RNN bloğunda kullanılan nöron sayıları 256-64-128-32, her iki bloğun birleştirilmesinden sonraki FC katmanının nöron sayısı 1024, CNN bloğunun aktivasyon fonksiyonu olarak 'relu', RNN bloğunun aktivasyon fonksiyonu olarak ('relu', 'relu', 'relu'), her iki bloğun birleştirilmesinden sonraki FC katmanının aktivasyon fonksiyonu olarak 'relu', optimizasyon olarak Adam, dropout oranı olarak 0.2, batch_size olarak 4 değerleri belirlenerek model için hiper parametre optimizasyon işlemi sonuçlandırılmıştır.

4.8. MODEL PERFORMANSI DEĞERLENDİRME

Modelin performansını değerlendirmek için birçok değerlendirme metriği mevcuttur. Bu bölümde model değerlendirmesinde kullanılan metriklerden bahsedilmektedir. Model değerlendirme metriklerine geçmeden önce bu metrikleri hesaplamak için bazı tanımların bilinmesi gerekmektedir.

TP (Gerçek Pozitif): Gerçekte pozitif olan gözlem pozitif olarak tahmin edilmiştir.

FN (Yanlış Negatif): Gerçekte pozitif olan gözlem negatif olarak tahmin edilmiştir.

TN (Gerçek Negatif): Gerçekte negatif olan gözlem negatif olarak tahmin edilmiştir.

FP (Yanlış Pozitif): Gerçekte negatif olan gözlem pozitif olarak tahmin edilmiştir.

TPR (Gerçek Pozitif Oranı) ve FPR (Yanlış Pozitif Oranı) gibi türetilmiş terimlerin hesaplanma şekli ise Eşitlik 4.11 ve 4.12'de verilmiştir.

$$TPR = \frac{TP}{TP + FN} \quad (4.11)$$

$$FPR = \frac{FP}{FP+TN} \quad (4.12)$$

Karışıklık Matrisi: Sınıflandırma sonuçlarının özetini verir. Karışıklık matrisi sınıflandırma da yapılan doğru tahminleri, yanlış tahminleri ve en önemlisi yapılan yanlış tahminlerin türlerini de vermektedir. Çizelge 4.5'te ikili sınıflandırma için örnek bir karışıklık matrisi verilmiştir.

Çizelge 4.5. Karışıklık matrisi örneği.

	Sınıf =1 => Pozitif Sınıf = 0 => Negatif	
	Sınıf =1 Tahmin Edilen	Sınıf =0 Tahmin Edilen
Sınıf = 1 Gerçek	TP	FN
Sınıf = 0 Gerçek	FP	TN

Model değerlendirmesinde ROC (Receiver Operating Characteristic) eğrisi sıklıkla kullanılmaktadır. ROC eğrisi TPR ve FPR değerleri kullanılarak çizdirilen bir eğridir. Modelin başarısını görselleştirmek adına önemli bir yöntemdir. Ancak bazı durumlarda bu eğriyi sayısal bir değer ile ifade etmek daha kullanışlı olabilir. AUC (Eğri Altındaki Alan) olarak isimlendirilen metrik ile ROC eğrisinin altında kalan alan sayısal olarak ifade edilerek değerlendirme metriği olarak sıklıkla kullanılmaktadır. Eşitlik 4.13-4.18'de doğruluk, duyarlılık, özgüllük, kesinlik, F1 ve MCC (Matthews Korelasyon Katsayısı) gibi bazı performans değerlendirme metrikleri verilmiştir.

$$Doğruluk (Accuracy) = \frac{TP + TN}{TP + FP + FN + TN} \quad (4.13)$$

$$Duyarlılık (Sensitivity / Recall) = \frac{TP}{TP + FN} \quad (4.14)$$

$$Özgüllük (Specificity) = \frac{TN}{TN + FP} \quad (4.15)$$

$$Kesinlik (Precision) = \frac{TP}{TP + FP} \quad (4.16)$$

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (4.17)$$

$$F_1 = \frac{2 \times \textit{Kesinlik} \times \textit{Duyarlılık}}{\textit{Kesinlik} + \textit{Duyarlılık}} \quad (4.18)$$

BÖLÜM 5

ÇALIŞMA BULGULARI VE TARTIŞMA

5.1. ÖNERİLEN MODEL İLE ELDE EDİLEN BULGULAR

Bu tez çalışmasında EEG sinyalleri zaman-frekans görüntü dönüşümü ile sinyallerin frekans alanındaki görüntüleri ve EEG sinyallerinin kendisi kullanılarak kombine bir sistem oluşturulmuştur. Modelin CNN girdisi için spektrogram ve skalogram verileri ayrı ayrı kullanılarak iki ayrı model oluşturulmuştur. Çalışma, CNN ve LSTM olmak üzere iki farklı derin öğrenme yapısını bir araya getirerek kabul gören sonuçlar alması açısından oldukça önemlidir. Veri seti A, B, C, D ve E olmak üzere beş farklı EEG kayıt setinden oluşmaktadır. Modellerin performanslarını daha iyi analiz etmek açısından veri seti daha önceden bahsedildiği üzere çeşitli kombinasyonlar ile ikili ve üçlü olmak üzere bir araya getirilmiş ve kullanılmıştır (Bkz. Çizelge 2.2 ve Bkz. Çizelge 2.3). Önerilen modeller ikili ve üçlü sınıflandırmaları başarılı bir şekilde sınıflandırmıştır. Önerilen modellerin başarısı çeşitli değerlendirme skorları ile değerlendirilmiştir. Çizelge 5.1’de skalogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleriyle eğitilen modelin ikili sınıflandırma sonuçları verilmiştir. Çizelge 5.2’de spektrogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleriyle eğitilen modelin ikili sınıflandırma sonuçları verilmiştir. Çizelge 5.3’te skalogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleriyle eğitilen modelin üçlü sınıflandırma sonuçları verilmiştir. Çizelge 5.4’te spektrogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleriyle eğitilen modelin üçlü sınıflandırma sonuçları verilmiştir. Oluşturulan modelin veri setinin sadece bir bölümünde değil farklı bölümlerinde de başarılı sonuçlar alabildiğini göstermek için çapraz doğrulama yapılmıştır. Stratified ShuffleSplit çapraz doğrulayıcı kullanılarak 8 katlı çapraz doğrulama uygulanmıştır. İş yükünün fazla olmasından dolayı zamandan tasarruf etmek için AB_CDE, ABCD_E ve AB_CD_E kombinasyonları seçilerek 8 katlı çapraz doğrulama işlemi yapılmıştır. Çizelge 5.5’te çapraz doğrulamalar için alınan doğruluk değerleri verilmiştir.

Çizelge 5.1. Skalogram görüntüleriyle yapılan ikili sınıflandırma sonuçları.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi	
									A	E
2D CNN CWT+LSTM	A_E	98.97	98.97	98.97	98.97	98.98	97.95	99.94	A	1598
									E	2
2D CNN CWT+LSTM	B_E	99.62	99.62	99.62	99.62	99.63	99.25	99.99	B	1591
									E	9
2D CNN CWT+LSTM	C_E	99.09	99.09	99.09	99.09	99.11	98.20	99.98	C	1599
									E	1
2D CNN CWT+LSTM	D_E	98.56	98.56	98.56	98.56	98.56	97.12	99.73	D	1577
									E	23
2D CNN CWT+LSTM	AB_E	99.46	99.46	99.26	99.46	99.46	98.78	99.97	AB	3189
									E	11
2D CNN CWT+LSTM	ABC_E	99.23	99.23	98.33	99.23	99.23	97.95	99.93	ABC	15
									E	4785
2D CNN CWT+LSTM	ABD_E	99.36	99.36	98.62	99.36	99.36	98.29	99.94	ABD	13
									E	28
2D CNN CWT+LSTM	AC_E	98.83	98.83	98.26	98.83	98.83	97.37	99.87	AC	19
									E	3181
									E	1563

Çizelge 5.1. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi		
2D CNN CWT+LSTM	ACD_E	98.91	98.91	97.22	98.90	98.91	97.07	99.84	ACD	E	
									ACD	4788	12
									E	58	1542
2D CNN CWT+LSTM	AD_E	99.00	99.00	98.44	99.00	99.00	97.75	99.91	AD	E	
									AD	3186	14
									E	34	1566
2D CNN CWT+LSTM	BC_E	99.46	99.46	99.17	99.46	99.46	98.78	99.98	BC	E	
									BC	3192	8
									E	18	1582
2D CNN CWT+LSTM	BCD_E	99.47	99.47	98.74	99.47	99.47	98.58	99.95	BCD	E	
									BCD	4792	8
									E	26	1574
2D CNN CWT+LSTM	BD_E	99.10	99.10	98.71	99.10	99.10	97.98	99.85	BD	E	
									BD	3184	16
									E	27	1573
2D CNN CWT+LSTM	ABCD_E	99.42	99.42	98.64	99.42	99.42	98.20	99.95	ABCD	E	
									ABCD	6380	20
									E	26	1574
2D CNN CWT+LSTM	CD_E	98.92	98.92	98.55	98.92	98.92	97.56	99.90	CD	E	
									CD	3177	23
									E	29	1571
2D CNN CWT+LSTM	AB_CDE	98.34	98.34	98.29	98.34	98.34	96.54	99.72	AB	CDE	
									AB	3142	58
									CDE	75	4725

Çizelge 5.2. Spektrogram görüntüleriyle yapılan ikili sınıflandırma sonuçları.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi	
									A	E
2D CNN STFT+LSTM	A_E	99.81	99.81	99.81	99.81	99.81	99.63	99.98	A	E
									A	1600
									B	E
									E	6
2D CNN STFT+LSTM	B_E	99.94	99.94	99.94	99.94	99.94	99.88	100.00	B	E
									B	1598
									C	E
									E	0
2D CNN STFT+LSTM	C_E	99.62	99.62	99.62	99.62	99.63	99.25	99.99	C	E
									C	1596
									D	E
									E	8
2D CNN STFT+LSTM	D_E	98.06	98.06	98.06	98.06	98.11	96.17	99.86	D	E
									D	1594
									E	E
									E	56
2D CNN STFT+LSTM	AB_E	99.81	99.81	99.81	99.81	99.81	99.58	100.00	AB	E
									AB	3194
									E	E
									E	3
2D CNN STFT+LSTM	ABC_E	99.53	99.53	99.47	99.53	99.53	98.75	99.97	ABC	E
									ABC	4779
									E	E
									E	9
2D CNN STFT+LSTM	ABD_E	98.55	98.55	98.97	98.56	98.59	96.21	99.94	ABD	E
									ABD	4720
									E	E
									E	13
2D CNN STFT+LSTM	AC_E	99.58	99.58	99.45	99.58	99.58	99.06	99.99	AC	E
									AC	3191
									E	E
									E	11

Çizelge 5.2. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi		
										ACD	E
2D CNN STFT+LSTM	ACD_E	98.52	98.52	99.13	98.53	98.58	96.15	99.94			
									ACD	4714	86
									E	9	1591
2D CNN STFT+LSTM	AD_E	99.38	99.38	99.19	99.37	99.37	98.59	99.97		AD	E
									AD	3186	14
									E	16	1584
2D CNN STFT+LSTM	BC_E	99.60	99.60	99.58	99.60	99.60	99.11	99.98		BC	E
									BC	3188	12
									E	7	1593
2D CNN STFT+LSTM	BCD_E	98.94	98.94	99.06	98.94	98.96	97.20	99.96		BCD	E
									BCD	4746	54
									E	14	1586
2D CNN STFT+LSTM	BD_E	99.15	99.15	98.73	99.14	99.15	98.08	99.95		BD	E
									BD	3186	14
									E	27	1573
2D CNN STFT+LSTM	CD_E	99.17	99.17	99.05	99.17	99.17	98.13	99.93		CD	E
									CD	3177	23
									E	17	1583
2D CNN STFT+LSTM	AB_CDE	99.45	99.45	99.44	99.45	99.45	98.85	99.96		AB	CDE
									AB	3181	19
									CDE	25	4775
2D CNN STFT+LSTM	ABCD_E	99.55	99.55	99.04	99.55	99.55	98.59	99.98		ABCD	E
									ABCD	6382	18
									E	18	1582

Çizelge 5.3. Skalogram görüntüleriyle yapılan üçlü sınıflandırma sonuçları.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi			
									A	C	E	
2D CNN CWT+LSTM	A-C-E	96.19	96.19	98.09	96.19	96.23	94.30	99.58	A	1554	35	11
									C	95	1493	12
									E	13	17	1570
2D CNN CWT+LSTM	A-D-E	96.65	96.65	98.32	96.65	96.74	95.01	99.69	A	1586	12	2
									D	46	1545	9
									E	57	35	1508
2D CNN CWT+LSTM	B-C-E	99.00	99.00	99.50	99.00	99.00	98.50	99.97	B	1581	14	5
									C	12	1581	7
									E	3	7	1590
2D CNN CWT+LSTM	B-D-E	98.65	98.65	99.32	98.65	98.65	97.97	99.94	B	1585	8	7
									D	4	1572	24
									E	3	19	1578
2D CNN CWT+LSTM	AB-CD-E	97.30	97.30	98.35	97.30	97.31	95.78	99.78	AB	3110	84	6
									CD	62	3116	22
									E	12	30	1558
2D CNN CWT+LSTM	A-CD-E	96.61	96.61	98.19	96.62	96.67	94.61	99.64	A	1548	40	12
									CD	112	3072	16
									E	12	25	1563

Çizelge 5.3. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi			
									B	CD	E	
2D CNN CWT+LSTM	B-CD-E	97.98	97.98	98.48	97.98	97.99	96.77	99.78	B	1561	33	6
									CD	10	3166	24
									E	8	48	1544
2D CNN CWT+LSTM	AB-C-E	97.80	97.80	99.02	97.81	97.85	96.51	99.85	AB	3107	85	8
									C	21	1570	9
									E	3	15	1582
2D CNN CWT+LSTM	AB-D-E	98.22	98.22	98.95	98.22	98.22	97.15	99.86	AB	3171	26	3
									D	41	1548	11
									E	3	30	1567

Çizelge 5.4. Spektrogram görüntüleriyle yapılan üçlü sınıflandırma sonuçları.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi			
									A	C	E	
2D CNN STFT+LST M	A-C-E	98.04	98.04	99.02	98.03	98.06	97.08	99.86	A	1586	11	3
									C	40	1527	33
									E	3	4	1593
2D CNN STFT+LST M	A-D-E	99.02	99.02	99.51	99.02	99.02	98.53	99.93	A	1594	6	0
									D	21	1570	9
									E	1	10	1589

Çizelge 5.4. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi			
									B	C	E	
2D CNN STFT+LSTM	B-C-E	99.31	99.31	99.66	99.31	99.32	98.97	99.98	B	1591	7	2
									C	3	1593	4
									E	0	7	1583
2D CNN STFT+LSTM	B-D-E	99.02	99.02	99.51	99.02	99.02	98.53	99.96	B	1596	4	0
									D	1	1572	27
									E	0	15	1585
2D CNN STFT+LSTM	AB-CD-E	98.20	98.20	98.99	98.09	98.20	97.19	99.90	AB	3164	34	2
									CD	41	3125	34
									E	0	33	1567
2D CNN STFT+LSTM	A-CD-E	98.20	98.20	99.09	98.20	98.22	97.14	99.90	A	1587	13	0
									CD	55	3116	29
									E	1	17	1582
2D CNN STFT+LSTM	B-CD-E	98.97	98.97	99.35	98.97	98.97	98.35	99.94	B	1592	7	1
									CD	2	3164	34
									E	0	22	1578

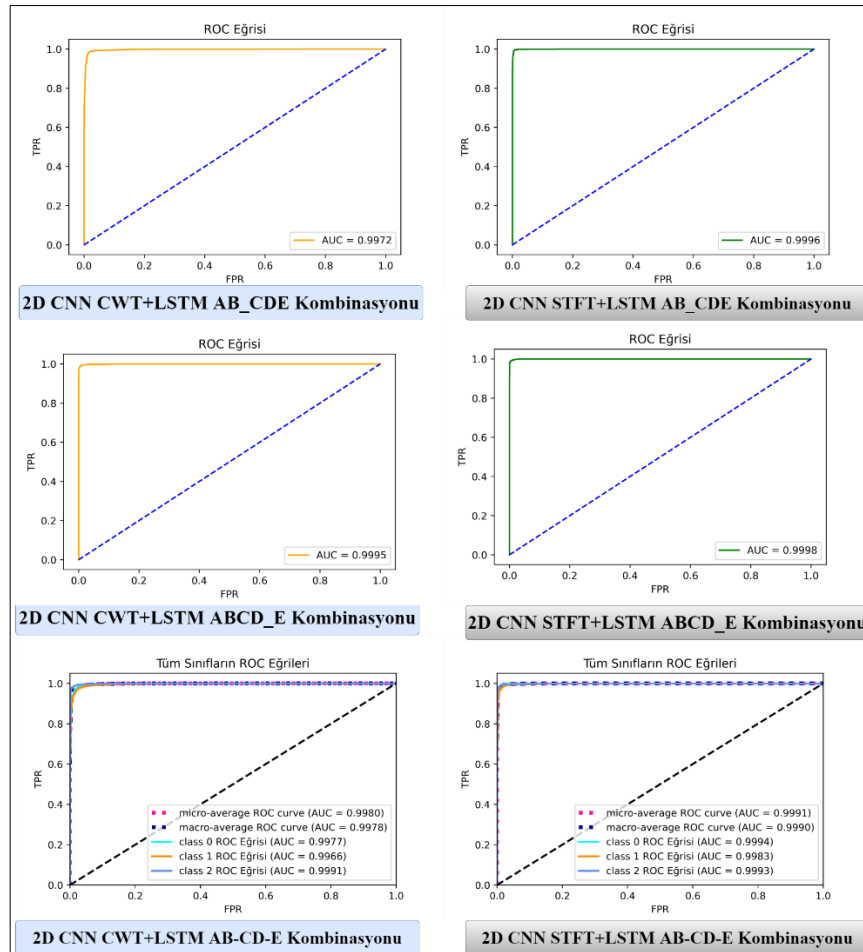
Çizelge 5.4. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)	Kesinlik (%)	MCC (%)	AUC (%)	Karışıklık Matrisi			
									AB	C	E	
2D CNN STFT+LSTM	AB-C-E	98.22	98.22	99.05	98.21	98.22	97.15	99.90	AB	3167	31	2
									C	34	1527	39
									E	0	8	1592
2D CNN STFT+LSTM	AB-D-E	98.03	98.03	99.21	98.03	98.07	96.87	99.89	AB	3161	18	21
									D	12	1529	59
									E	1	15	1584

Çizelge 5.5. Çeşitli kombinasyonlarla elde edilen çapraz doğrulama sonuçları.

Çalışma	Veriler	Metrik	K1	K2	K3	K4	K5	K6	K7	K8	Ortalama	Standart Sapma
2D CNN STFT+LSTM	AB_CDE	Doğruluk (%)	97.90	99.05	99.00	99.55	99.35	99.30	99.70	99.80	99.21	±0.56
2D CNN CWT+LSTM	AB_CDE	Doğruluk (%)	94.50	97.20	97.75	98.55	98.70	99.15	99.50	99.80	98.14	±1.6
2D CNN STFT+LSTM	ABCD_E	Doğruluk (%)	97.75	98.75	98.60	99.30	99.45	99.80	99.55	99.85	99.13	±0.67
2D CNN CWT+LSTM	ABCD_E	Doğruluk (%)	98.45	99.20	99.55	99.65	99.80	99.75	99.85	99.85	99.50	±0.45
2D CNN STFT+LSTM	AB_CD_E	Doğruluk (%)	95.05	97.85	98.95	99.50	99.60	99.95	99.90	99.90	98.84	±1.58
2D CNN CWT+LSTM	AB_CD_E	Doğruluk (%)	94.40	97.65	98.90	98.65	99.40	99.65	99.90	99.85	98.55	±1.72

Çapraz doğrulama sonucunda elde edilen doğruluk oranlarından da görüldüğü üzere önerilen her iki model de veri setinin bölümlenmesinden bağımsız olarak yüksek doğruluk oranları elde etmektedir. Bu sonuçlar da modelimizin sadece veri setinin belirli bir noktasında değil farklı noktalarında da iyi bir şekilde çalıştığını göstermektedir. İkili sınıflandırma için elde edilen en yüksek doğruluk oranı 2D CNN STFT+LSTM modeli ile B_E kombinasyonunda %99.94 elde edilmiştir. Üçlü sınıflandırma için elde edilen en yüksek doğruluk oranı 2D CNN STFT+LSTM modeli ile B-C-E kombinasyonunda %99.31 elde edilmiştir. Her iki modelle elde edilen sonuçlar birbirine oldukça yakındır. Bazı kombinasyonlarda skalogram görüntülerini kullanan 2D CNN CWT+LSTM modeli daha yüksek sonuçlar alırken genel olarak spektrogram görüntülerini kullanan 2D CNN STFT+LSTM modeli çoğu veri seti kombinasyonunda daha iyi sonuçlar elde etmiştir. Son olarak Şekil 5.1’de AB_CDE, ABCD_E ve AB_CD_E kombinasyonları ile elde edilen ROC eğrileri gösterilmiştir.



Şekil 5.1. Çeşitli kombinasyonlarla ROC eğrileri.

5.2. TARTIŞMA

Özellikle epilepsi olmak üzere birçok sinirsel hastalığın teşhisinde EEG sinyallerinden faydalanılmaktadır. Günümüzde makine öğrenmesi ve derin öğrenme yaklaşımlarının yaygınlaşması ve gelişmesinden dolayı sinyal işleme, sinyallerden özellik çıkarımı, sinyallerden otomatik hastalık tayini gibi birçok ilerleme meydana gelmiştir. Bu tez çalışmasında epilepsi hastalığının tespiti ve epilepsi hastalarına ait EEG sinyallerinin sınıflandırılması için 2D CNN CWT + LSTM ve 2D CNN STFT + LSTM modelleri geliştirilmiştir. Alınan sonuçlar neticesinde klinik açıdan önemli bir başarı elde edilmiştir. 2D CNN CWT + LSTM için sinyal zaman-frekans-görüntü dönüşümlerinden birisi olan CWT ile skalogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleri kullanılarak model oluşturulmuştur. 2D CNN STFT + LSTM için sinyal zaman-frekans-görüntü dönüşümlerinden birisi olan STFT ile spektrogram görüntüleri ve sinyallerin bir boyutlu sayısal değerleri kullanılarak model oluşturulmuştur. Literatürde bu tarz sinyal dönüşümleri kullanılarak sinyallerin görüntüleri ile yapılan çalışmalar mevcuttur. Önerilen model, sadece sinyalin frekans alanı görüntüsü ile CNN yapısını kullanmamaktadır aynı zamanda sinyalin ham zaman dizisi halini bir RNN çeşidi olan LSTM yapısı ile kullanan kombine bir model olarak öne çıkmaktadır. Model birçok veri seti kombinasyonunda literatürde aynı veri seti üzerine yapılmış çalışmalardan daha iyi sonuçlar elde etmiştir. Ayrıca bu tez çalışmasında literatürdeki diğer çalışmalardan farklı kombinasyonlar olan A-CD-E, B-CD-E, AB-C-E ve AB-D-E kombinasyonları da kullanılmıştır. Kullanılan bu farklı kombinasyonlar ile EEG verileri sağlıklı, inter-iktal ve iktal olmak üzere üçlü şekilde sınıflandırılmasını sağlayarak daha önce kullanılan AB-CD-E kombinasyonuna ek olarak farklı birer sınıflandırma modeli kazandırılmıştır. Bu çalışma da derin öğrenme yaklaşımı kullanıldığı için kıyaslamalar, literatürdeki diğer derin öğrenme kullanılan çalışmalar ile yapılmıştır. Zhao vd. (2020) 1D CNN derin öğrenme yapısı ile yaptıkları çalışmalarında EEG kayıtlarını ABCD_E ve AB-CD-E kombinasyonlarında sırasıyla %98.76 ve %96.97 doğruluk değerleriyle ikili ve üçlü olarak sınıflandırmışlardır [21]. Khan vd. (2021) LSTM tabanlı bir derin öğrenme modeli kullanarak EEG kayıtlarını AB-CD-E kombinasyonunda %96.00 doğruluk değeriyle üçlü olarak sınıflandırmışlardır [22]. Wang vd. (2021) çalışmalarında derin öğrenmesi ile oluşturulan otomatik özellikleri, klasik yöntemle oluşturulan özellikler ile birleştirerek

oluşan öz nitelik vektörünü MLP sınıflandırıcı kullanarak sınıflandırmışlardır. EEG kayıtlarını, AB-CD-E kombinasyonunda %92.07 doğruluk %91.13 duyarlılık ve %92.96 özgüllük değeriyle üçlü olarak sınıflandırmışlardır [23]. Ullah vd. (2018) çalışmalarında, 1D CNN derin öğrenme yaklaşımı ile EEG kayıtlarını AB_CDE kombinasyonunda %98.10 doğruluk, %98.00 özgüllük ve %98.00 duyarlılık, ABCD_E kombinasyonunda %99.70 doğruluk ve AB-CD-E kombinasyonunda %96.15 doğruluk, %96.00 duyarlılık ve %97.50 özgüllük değerlerini elde ederek ikili ve üçlü olarak sınıflandırmışlardır [32]. Ramakrishnan vd. (2019) 1D CNN derin öğrenme yapısı kullanarak EEG kayıtlarını ABCD_E ve AB-CD-E kombinasyonlarında sırasıyla %97.64 ve %98.37 doğruluk değerleriyle ikili ve üçlü olarak sınıflandırmışlardır [33]. Aliyu vd. (2019) RNN derin öğrenme yapısı kullanarak EEG kayıtlarını ABCD_E kombinasyonunda %99.00 doğruluk değeriyle ikili olarak sınıflandırmışlardır [34]. Tez çalışması kapsamında önerdiğimiz kombine derin öğrenme yaklaşımı, literatürde derin öğrenme yaklaşımları ile yapılan çalışmalara göre birçok sınıflandırma kombinasyonunda daha yüksek başarılar sağlamaktadır. Bu tez çalışması, Bonn verileri kullanılarak yapılan çalışmalarla sınıflandırma kombinasyonu sayısı açısından kıyaslandığında en fazla sınıflandırma kombinasyonunda sınıflandırma yapan çalışmadır. Çizelge 5.6'da Bonn veri seti ile ikili sınıflandırma yapılarak oluşturulan benzer çalışmalarla elde edilmiş sonuçların bu tez çalışmasında ikili sınıflandırma sonucu elde edilen sonuçlarla detaylı olarak kıyaslanması verilmiştir. Çizelge 5.7'de ise üçlü sınıflandırma yapılarak oluşturulan benzer çalışmalarla elde edilmiş sonuçların bu tez çalışmasında üçlü sınıflandırma sonucu elde edilen sonuçlarla detaylı olarak kıyaslanması verilmiştir.

Çizelge 5.6. Bonn veri seti ile yapılan benzer çalışmalarda elde edilen ikili sınıflandırma sonuçları ile karşılaştırma.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)
2D CNN STFT+LSTM	A_E	99.81	99.81	99.81	99.81
2D CNN CWT+LSTM	A_E	98.97	98.97	98.97	98.97
[20]	A_E	99.50	99.00	100.00	99.50
[21]	A_E	99.52	—	—	—
[24]	A_E	99.38	100.00	98.75	—
[32]	A_E	99.90	—	—	—

Çizelge 5.6. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)
2D CNN STFT+LSTM	B_E	99.94	99.94	99.94	99.94
2D CNN CWT+LSTM	B_E	99.62	99.62	99.62	99.62
[20]	B_E	99.50	100.00	100.00	99.50
[21]	B_E	99.11	—	—	—
[24]	B_E	100.00	100.00	100.00	—
[32]	B_E	99.00	—	—	—
2D CNN STFT+LSTM	C_E	99.62	99.62	99.62	99.62
2D CNN CWT+LSTM	C_E	99.09	99.09	99.09	99.09
[20]	C_E	98.50	98.01	98.98	98.50
[21]	C_E	98.02	—	—	—
[24]	C_E	99.69	99.38	100.00	—
[32]	C_E	98.10	—	—	—
2D CNN STFT+LSTM	D_E	98.06	98.06	98.06	98.06
2D CNN CWT+LSTM	D_E	98.56	98.56	98.56	98.56
[19]	D_E	97.78	96.77	98.85	—
[20]	D_E	98.50	98.01	98.98	98.50
[21]	D_E	97.63	—	—	—
[24]	D_E	98.44	97.50	99.38	—
[32]	D_E	97.40	—	—	—
2D CNN STFT+LSTM	AB_E	99.81	99.81	99.81	99.81
2D CNN CWT+LSTM	AB_E	99.46	99.46	99.26	99.46
[19]	AB_E	99.17	98.88	99.45	—
[21]	AB_E	99.38	—	—	—
[24]	AB_E	100.00	100.00	100.00	—
[32]	AB_E	98.80	—	—	—
[33]	AB_E	98.95	—	—	—
2D CNN STFT+LSTM	ABC_E	99.53	99.53	99.47	99.53
2D CNN CWT+LSTM	ABC_E	99.23	99.23	98.33	99.23
[21]	ABC_E	98.89	—	—	—
[24]	ABC_E	100.00	100.00	100.00	—
2D CNN STFT+LSTM	ABD_E	98.55	98.55	98.97	98.56
2D CNN CWT+LSTM	ABD_E	99.36	99.36	98.62	99.36
[21]	ABD_E	98.52	—	—	—
[24]	ABD_E	98.46	98.75	98.18	—

Çizelge 5.6. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)
2D CNN STFT+LSTM	AC_E	99.58	99.58	99.45	99.58
2D CNN CWT+LSTM	AC_E	98.83	98.83	98.26	98.83
[21]	AC_E	99.03	—	—	—
[24]	AC_E	99.38	98.75	100.00	—
[33]	AC_E	98.63	—	—	—
2D CNN STFT+LSTM	ACD_E	98.52	98.52	99.13	98.53
2D CNN CWT+LSTM	ACD_E	98.91	98.91	97.22	98.90
[24]	ACD_E	98.46	97.50	99.39	—
2D CNN STFT+LSTM	AD_E	99.38	99.38	99.19	99.37
2D CNN CWT+LSTM	AD_E	99.00	99.00	98.44	99.00
[21]	AD_E	98.50	—	—	—
[24]	AD_E	98.13	97.50	98.75	—
2D CNN STFT+LSTM	BC_E	99.60	99.60	99.58	99.60
2D CNN CWT+LSTM	BC_E	99.46	99.46	99.17	99.46
[21]	BC_E	98.68	—	—	—
[24]	BC_E	100.00	100.00	100.00	—
2D CNN STFT+LSTM	BCD_E	98.94	98.94	99.06	98.94
2D CNN CWT+LSTM	BCD_E	99.47	99.47	98.74	99.47
[21]	BCD_E	98.36	—	—	—
[24]	BCD_E	98.46	98.75	98.18	—
2D CNN STFT+LSTM	BD_E	99.15	99.15	98.73	99.14
2D CNN CWT+LSTM	BD_E	99.10	99.10	98.71	99.10
[21]	BD_E	97.83	—	—	—
[24]	BD_E	98.44	98.75	98.13	—
2D CNN STFT+LSTM	CD_E	99.17	99.17	99.05	99.17
2D CNN CWT+LSTM	CD_E	98.92	98.92	98.55	98.92
[21]	CD_E	98.03	—	—	—
[24]	CD_E	99.38	98.75	100.00	—
[32]	CD_E	98.80	—	—	—
2D CNN STFT+LSTM	AB_CDE	99.45	99.45	99.44	99.45
2D CNN CWT+LSTM	AB_CDE	98.34	98.34	98.29	98.34
[32]	AB_CDE	98.10	98.00	98.00	—

Çizelge 5.6. (devam ediyor).

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)
2D CNN STFT+LSTM	ABCD_E	99.55	99.55	99.04	99.55
2D CNN CWT+LSTM	ABCD_E	99.42	99.42	98.64	99.42
[21]	ABCD_E	98.76	—	—	—
[23]	ABCD_E	92.07	91.13	92.96	—
[24]	ABCD_E	100.00	100.00	100.00	—
[32]	ABCD_E	99.70	—	—	—
[33]	ABCD_E	97.64	—	—	—
[34]	ABCD_E	99.00	—	—	—

Çizelge 5.7. Bonn veri seti ile yapılan benzer çalışmalarda elde edilen üçlü sınıflandırma sonuçları ile karşılaştırma.

Çalışma	Veriler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	F1_w (%)
2D CNN STFT+LSTM	A-C-E	98.04	98.04	99.02	98.03
2D CNN CWT+LSTM	A-C-E	96.19	96.19	98.09	96.19
[19]	A-C-E	94.81	92.63	99.43	—
[20]	A-C-E	92.00	92.00	96.53	92.59
[21]	A-C-E	96.73	—	—	—
2D CNN STFT+LSTM	A-D-E	99.02	99.02	99.51	99.02
2D CNN CWT+LSTM	A-D-E	96.65	96.65	98.32	96.65
[20]	A-D-E	99.00	99.00	99.50	99.00
[21]	A-D-E	97.04	—	—	—
[33]	A-D-E	98.57	—	—	—
2D CNN STFT+LSTM	B-C-E	99.31	99.31	99.66	99.31
2D CNN CWT+LSTM	B-C-E	99.00	99.00	99.50	99.00
[20]	B-C-E	98.67	98.67	99.33	98.66
[21]	B-C-E	97.91	—	—	—
2D CNN STFT+LSTM	B-D-E	99.02	99.02	99.51	99.02
2D CNN CWT+LSTM	B-D-E	98.65	98.65	99.32	98.65
[18]	B-D-E	88.67	95.00	90.00	—
[20]	B-D-E	98.00	98.00	98.98	97.99
[21]	B-D-E	98.06	—	—	—
2D CNN STFT+LSTM	AB-CD-E	98.20	98.20	98.99	98.09
2D CNN CWT+LSTM	AB-CD-E	97.30	97.30	98.35	97.30
[21]	AB-CD-E	96.97	—	—	—
[22]	AB-CD-E	96.00	—	95.00	95.36
[32]	AB-CD-E	96.15	96.00	97.50	95.62
[33]	AB-CD-E	98.37	—	—	—

BÖLÜM 6

SONUÇLAR

Bu çalışmada, zaman serisi EEG sinyallerinin zaman-frekans bileşenlerini temsil eden iki farklı sinyal dönüşümü ile elde edilen sinyal görüntüleri ve ham EEG sinyallerinin sayısal değerlerini kullanarak epilepsi nöbet aktivitesini otomatik bir şekilde tespit eden ve EEG sinyallerini sınıflandıran kombine bir derin öğrenme modeli üzerine çalışılmıştır. Bu çalışma da sağlıklı ve epilepsi hastası bireylere ait EEG sinyalleri ikili ve üçlü olmak üzere yüksek doğruluk oranı ile sınıflandırılmıştır. Bu tez çalışması ile elde edilen sonuçlar aşağıda maddeler halinde listelenmiştir.

1. Halka açık veri seti olan Bonn veri seti üzerinde kurulan model literatürde bulunan diğer çalışmalar ile rekabet edebilir sonuçlar aldığı gözlemlenmiştir.
2. Önerilen modelde EEG verilerini sinyal dönüşüm yöntemleri olan STFT ve CWT yöntemleri ile görüntülere dönüştürerek ve buna ek olarak EEG sinyallerinin sayısal değerlerini de kullanarak iki farklı derin öğrenme yapısı ile tek bir model oluşturarak kombine bir derin öğrenme yapısı üzerine çalışılmıştır. Önerilen model literatürdeki benzer çalışmalarda kullanılan veri setinin kombinasyonlarının birçoğunda daha yüksek performans gösterdiği gözlemlenmektedir.
3. Önerilen modelde aynı veri seti üzerine yapılan çalışmalardan farklı olarak iki farklı derin öğrenme yapısını birlikte kullanarak kombine bir model ile çalışılması açısından literatüre farklı bir bakış açısı kazandırmaktadır.
4. İki farklı derin öğrenme yapısını kullanarak kombine bir model ile elde ettiği sonuçlar açısından oldukça başarılı bir model olarak öne çıkmaktadır.

5. Önerilen modelin skalogram ve spektrogram görüntüleri kullanılarak yapılan eğitimlerin her ikisinde de benzer sonuçlar alması önerilen modelin başarısını ortaya koymaktadır.
6. Önerilen modelin çapraz doğrulama sonuçlarından da anlaşılacağı üzere modelin veri setinin sadece bir bölümde değil farklı bölümlerinde de yüksek performans gösterdiği doğrulanmaktadır.
7. Bu tez çalışması literatüre kazandırdığı farklı yaklaşım ve aldığı yüksek skorlar açısından klinik olarak oldukça önemli sonuçlar elde etmiştir. Klinik olarak, önerilen çalışma oldukça kolay bir şekilde uygulanabilir. Tez çalışması kapsamında yazılan program, EEG kayıtları programın istediği gibi bir dizi şeklinde elde edildikten sonra herhangi bir ek işleme gerek kalmadan EEG sinyallerini sınıflandırabilmektedir. Önerdiğimiz çalışma herhangi bir EEG kayıt sistemine kolay bir şekilde entegre edilebilecek şekilde hazırlanmıştır.
8. Önerilen model sinyallerin elde edilme şekilleri ve yerleri bakımından farklı ancak sinyal tipleri aynı olan EEG kayıtlarını birbirinden ayırt etmede yüksek başarı sağlayamamıştır. Burada bahsedilen iki sağlıklı EEG kaydının gözler açık-gözler kapalı ayrımı ve inter-iktal dönemde farklı yerlerden elde edilmiş iki EEG kaydının birbirinden ayrımıdır. İlerleyen çalışmalarda sinyallerin tipleri aynı olsa bile elde edilme şekilleri ve yerleri farklı olan EEG sinyallerinin de birbirinden yüksek başarı oranı ile ayırt edilmesi amaçlanmaktadır.
9. Önerilen modelin verilerden bağımsız bir şekilde nasıl çalıştığını gözlemlemek amacıyla, ilerleyen dönemlerde herhangi bir hastaneden alınan EEG kayıtları üzerinde bir çalışma yapılması planlanmaktadır.

Bu tez çalışması kapsamında katılım sağlanan konferans, yayınlanan bildiri özeti ve makale ile ilgili aşağıda bilgiler verilmiştir.

Konferans/Bildiri Özeti

- 1 st International Conference on Applied Engineering and Natural Sciences (1 st ICAENS) November 1-3, 2021 Konya/Turkey.
- ICAENS Bildiri Kitabı Sayfa 943 “Combined Deep Learning Based Epileptic Seizure Diagnosis” isimli bildiri özeti.

Makale

- Varlı, M. & Yılmaz, H. (2021). Kombine Derin Öğrenme Tabanlı Epileptik Nöbet Teşhisi . Avrupa Bilim ve Teknoloji Dergisi , Ejosat Özel Sayı 2021 (ICAENS) , 1210-1216 . DOI: 10.31590/ejosat.1013489.

KAYNAKLAR

1. Singh, A. and Trevick, S., "The Epidemiology of Global Epilepsy", *Neurol Clin*, 34 (4): 837–847 (2016).
2. Beghi, E., "The Epidemiology of Epilepsy", *Neuroepidemiology*, 54 (2): 185–191 (2020).
3. van Mierlo, P., Vorderwülbecke, B. J., Staljanssens, W., Seeck, M., and Vulliémoz, S., "Ictal EEG source localization in focal epilepsy: Review and future perspectives", *Clinical Neurophysiology*, 131 (11): 2600–2616 (2020).
4. Brian Penchina, Avirath Sundaresan, Sean Cheong, Victoria Grace, Antoni Valero-Cabré, and Adrien Martel, *Brain Informatics*, (2021).
5. Shah, S. A. A., Zhang, L., and Bais, A., "Dynamical system based compact deep hybrid network for classification of Parkinson disease related EEG signals", *Neural Networks*, 130: 75–84 (2020).
6. Sun, J., Cao, R., Zhou, M., Hussain, W., Wang, B., Xue, J., and Xiang, J., "A hybrid deep neural network for classification of schizophrenia using EEG Data", *Scientific Reports*, 11 (1): 4706 (2021).
7. Sundaresan, A., Penchina, B., Cheong, S., Grace, V., Valero-Cabré, A., and Martel, A., "Evaluating deep learning EEG-based mental stress classification in adolescents with autism for breathing entrainment BCI", *Brain Informatics*, 8 (1): 13 (2021).
8. Hussain, L., "Detecting epileptic seizure with different feature extracting strategies using robust machine learning classification techniques by applying advance parameter optimization approach", *Cognitive Neurodynamics*, 12 (3): 271–294 (2018).

9. Montoya-Martínez, J., Vanthornhout, J., Bertrand, A., and Francart, T., "Effect of number and placement of EEG electrodes on measurement of neural tracking of speech", *PLOS ONE*, 16 (2): e0246769 (2021).
10. Rojas, G., Alvarez, C., Montoya Moya, C., de la Iglesia Vaya, M., Cisternas, J., and Gálvez, M., "Study of Resting-State Functional Connectivity Networks Using EEG Electrodes Position As Seed", *Frontiers In Neuroscience*, 12: (2018).
11. Aurlien, H., Gjerde, I. O., Aarseth, J. H., Eldøen, G., Karlsen, B., Skeidsvoll, H., and Gilhus, N. E., "EEG background activity described by a large computerized database", *Clinical Neurophysiology*, 115 (3): 665–673 (2004).
12. Bajaj, N., "Wavelets for EEG Analysis", (2020).
13. Wang, L., Xue, W., Li, Y., Luo, M., Huang, J., Cui, W., and Huang, C., "Automatic Epileptic Seizure Detection in EEG Signals Using Multi-Domain Feature Extraction and Nonlinear Analysis", *Entropy*, 19 (6): (2017).
14. Mohammadpoory, Z., Nasrolahzadeh, M., and Haddadnia, J., "Epileptic seizure detection in EEGs signals based on the weighted visibility graph entropy", *Seizure*, 50: 202–208 (2017).
15. Yol, S., Özdemir, M., Akan, A., and Chaparro, L., "Detection of Epileptic Seizures by the Analysis of EEG Signals Using Empirical Mode Decomposition", (2018).
16. Ravi Kumar, M. and Srinivasa Rao, Y., "Epileptic seizures classification in EEG signal based on semantic features and variational mode decomposition", *Cluster Computing*, 22 (6): 13521–13531 (2019).
17. P. Sheoran, N. Rathee, and J. S. Saini, "Epileptic Seizure Detection using Bidimensional Empirical Mode Decomposition and Distance Metric Learning on Scalogram", *2020 7th International Conference on Signal Processing and Integrated Networks (SPIN)*, (2020).

18. Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., and Adeli, H., "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals", *Computers In Biology And Medicine*, 100: 270–278 (2018).
19. M. U. Abbasi, A. Rashad, A. Basalamah, and M. Tariq, "Detection of Epilepsy Seizures in Neo-Natal EEG Using LSTM Architecture", *IEEE Access*, 7: 179074–179085 (2019).
20. Türk, Ö. and Özerdem, M. S., "Epilepsy Detection by Using Scalogram Based Convolutional Neural Network from EEG Signals", *Brain Sciences*, 9 (5): 115 (2019).
21. Zhao, W., Zhao, W., Wang, W., Jiang, X., Zhang, X., Peng, Y., Zhang, B., and Zhang, G., "A Novel Deep Neural Network for Robust Detection of Seizures Using EEG Signals", *Computational And Mathematical Methods In Medicine*, 2020: 9689821 (2020).
22. Khan, P., Khan, Y., Kumar, S., Khan, M. S., and Gandomi, A. H., "HVD-LSTM based recognition of epileptic seizures and normal human activity", *Computers In Biology And Medicine*, 136: 104684 (2021).
23. Wang, Y., Dai, Y., Liu, Z., Guo, J., Cao, G., Ouyang, M., Liu, D., Shan, Y., Kang, G., and Zhao, G., "Computer-Aided Intracranial EEG Signal Identification Method Based on a Multi-Branch Deep Learning Fusion Model and Clinical Validation", *Brain Sciences*, 11 (5): (2021).
24. M. Rashed-Al-Mahfuz, M. A. Moni, S. Uddin, S. A. Alyami, M. A. Summers, and V. Eapen, "A Deep Convolutional Neural Network Method to Detect Seizures and Characteristic Frequencies Using Epileptic Electroencephalogram (EEG) Data", *IEEE Journal Of Translational Engineering In Health And Medicine*, 9: 1–12 (2021).
25. Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., and Elger, C. E., "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 (2001).

26. Kıymık, M. K., Güler, İ., Dizibüyük, A., and Akın, M., "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 (2005).
27. Rajoub, B., "Chapter 2 - Characterization of biomedical signals: Feature engineering and extraction", Biomedical Signal Processing and Artificial Intelligence in Healthcare, *Academic Press*, 29–50 (2020).
28. Indolia, S., Goswami, A. K., Mishra, S. P., and Asopa, P., "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach", *International Conference On Computational Intelligence And Data Science*, 132: 679–688 (2018).
29. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., and Farhan, L., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions", *Journal Of Big Data*, 8 (1): 53 (2021).
30. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., and Chen, T., "Recent advances in convolutional neural networks", *Pattern Recognition*, 77: 354–377 (2018).
31. Chen, G., "A Gentle Tutorial of Recurrent Neural Network with Error Backpropagation", (2016).
32. Ullah, I., Hussain, M., Qazi, E.-H., and Aboalsamh, H., "An automated system for epilepsy detection using EEG brain signals based on deep learning approach", *Expert Systems With Applications*, 107: 61–71 (2018).
33. S. Ramakrishnan, A. S. Muthanatha Murugavel, and P. Saravanan, "Epileptic EEG Signal Classification using Multi-class Convolutional Neural Network", *2019 International Conference on Vision Towards Emerging Trends in Communication and Networking (ViTECoN)*, (2019).

34. Aliyu, I., Lim, Y., and Lim, C., "Epilepsy Detection in EEG Signal Using Recurrent Neural Network", 53 50 (2019).

ÖZGEÇMİŞ

Muhammet VARLI ilk ve orta öğrenimini Şehit Kâmil İlkokulu'nda tamamladı. Lise öğrenimini 2010-2014 yılları arasında Ereğli'nin gözde okullarından İvriz Anadolu Öğretmen Lisesi'nde okudu. Liseden 91.13 (maksimum 100) ortalama ile mezun oldu. 2014 yılında Karabük Üniversitesi Tıp Mühendisliği (%100 İngilizce) bölümüne başlayıp 2019 yılında 3.58/4 ortalama ile bölüm birincisi olarak tamamladı. 2017 yılında yine Karabük Üniversitesinde Elektrik Elektronik Mühendisliği bölümüne çift ana dal programına başlayıp 2019 yılında bu bölümü de 3.41/4 ortalama ile tamamladı. 2020 Ocak ayında Karabük Üniversitesi Biyomedikal Mühendisliği bölümünde yüksek lisansa başladı. Genel olarak güncel çalışma ve ilgi alanları; veri bilimi, veri analizi, makine öğrenmesi, derin öğrenme, istatistik, görüntü işleme, devre çizimi, devre simülasyonu yapma, PCB tasarımı. Son olarak Python, Matlab, C#, C++, C (Pic Programlama), Labview programlama dillerini bilmektedir.