

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



EEG SİNYALLERİNDEN ŞİZOFRENİ HASTALARININ
DERİN ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ

Büşra ÇETİN SÖYLEMEZ

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ŞUBAT, 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**EEG SINYALLERİNDEN ŞİZOFRENİ HASTALARININ
DERİN ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ**

Tez Yazarı
Büşra ÇETİN SÖYLEMEZ

Danışman
Prof. Dr. Taner TUNCER

ŞUBAT, 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	EEG Sinyallerinden Şizofreni Hastalarının Derin Öğrenme Yöntemleri ile Belirlenmesi
Yazarı:	Büşra ÇETİN SÖYLEMEZ
İlk Teslim Tarihi:	02.01.2023
Savunma Tarihi:	13.02.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

	<i>İmza</i>	
Danışman:	Prof. Dr. Taner TUNCER Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Başkan:	Doç. Dr. Ahmet ÇINAR Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Hafzullah İŞ Batman Üniversitesi, Mühendislik – Mimarlık Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “ EEG Sinyallerinden Şizofreni Hastalarının Derin Öğrenme Yöntemleri ile Belirlenmesi ” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

13.02.2023

Büşra ÇETİN SÖYLEMEZ



ÖNSÖZ

Şizofreni, hastalara, ailelerine ve topluma büyük yükler getiren kronik ruhsal bir rahatsızlıktır. Şizofreni tanısı görüşme ve klinik semptomlara dayanılarak konur. Şizofreninin erken ve doğru teşhisi, tedavinin planlanmasını kolaylaştırabilir ve hastalığın sonucunu iyileştirebilir. Klasik görüşme ve klinik semptomların yerine EEG sinyallerinden otomatik tespitler gerçekleştiren sistemler geliştirilmelidir. Bu yüzden yapay zekanın yönettiği günümüzde bu teşhis sürecinin hızlı ve kolay bir şekilde sağlanabilmesi gerekmektedir. 80’li yılların ortalarından itibaren derin öğrenme mimarilerinin ortaya çıkması ile birlikte, birçok alanda olduğu gibi sağlık alanında da derin öğrenme yöntemleri kullanılmaya başlanmıştır. Dolayısıyla bu ağır hastalığın teşhisinin sağlanabilmesi etkin bilgisayar sistemlerinin devreye girmesi için etkin çözümler sunan derin öğrenme mimarilerinin kullanımı işe yarar sistemler geliştirilmesine katkı sunabilecektir. Bu nedenle tezde, şizofreni gibi ağır bir ruhsal bozukluğun tespiti için derin öğrenme yöntemlerinden yararlanılmıştır.

Bu çalışmada değerli vaktini bana ayırarak çalışmamın bitirilmesinde her türlü desteğini esirgemeyen danışman hocam Prof. Dr. Taner TUNCER’e teşekkürlerimi sunmak istiyorum. Ayrıca benim bugünlere gelmemde büyük emeği olan rahmetli Babama, hayatımın her anında ilgi, anlayış ve her türlü desteğini esirgemeyen eşime ve aileme de teşekkürü borç bilirim.

Büşra ÇETİN SÖYLEMEZ

ELÂZİĞ, 2023

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ.....	viii
TABLolar LİSTESİ.....	ix
KISALTMALAR	x
1. GİRİŞ	1
1.1. Tezin Amacı.....	3
1.2. Tezin Organizasyonu	4
2. LİTERATÜR TARAMASI	1
3. MATERYAL VE METOT.....	12
3.1. Veri Seti	12
3.2. Metot.....	14
3.2.1. Derin Öğrenme Mimarileri.....	15
3.2.2. Makine Öğrenmesi Algoritmaları.....	27
3.2.3. LSTM	29
3.2.4. Performans Değerlendirme Parametreleri	31
4. UYGULAMALAR	35
4.1. Spektrogram Verileri Elde Edilerek Yapılan Uygulama.....	35
4.2. Ham Veriler ile Gerçekleştirilen Uygulama.....	45
6. SONUÇLAR	49
KAYNAKLAR	50
ÖZGEÇMİŞ	

ÖZET

EEG Sinyallerinden Şizofreni Hastalarının Derin Öğrenme Yöntemleri ile Belirlenmesi

Büşra ÇETİN SÖYLEMEZ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı
Şubat 2023, Sayfa x+54

Şizofreni teşhisi, alanında uzman bir psikiyatrist tarafından hasta görüşmeleri yoluyla gerçekleştirilir. Bahsedilen tespit işlemi uzun zaman gerektiren, masraflı ve hataya açık bir işlemdir. Ciddi ve kronik bir hastalık olan şizofrenide hastalar gerçek hayatla arasındaki bağlantısını yitirerek farklı davranışlar sergilemeye, gerçek olmayan olaylara inanmaya ve kişiliklerini değiştirmeye eğilim gösterirler. Hayat boyu süren bu hastalıkta doğru tedavi ile hastalık kontrol altına alınabilir. Bu sayede hastalar sağlıklı bir birey olarak yaşamını sürdürebilir, sosyal ilişkilerinde ve iş hayatlarında başarılı olabilirler. Tedavi süreci, yapılan en küçük bir ihmalde hastalığın yeniden nüksünü tetikleyebileceğinden büyük bir özen ve hassasiyet gerektirir. Bütün bu sebeplerden kaynaklı olarak hastalığın teşhisi önem arz etmektedir. Bu tez çalışmasında Şizofreni hastalığının tanı ve teşhis sürecini hızlandırmak için EEG sinyallerinden kişilerin şizofreni olup olmadığının tespit edilmesi amaçlanmaktadır. Bu amaçla, iki uygulama gerçekleştirilmiştir. Uygulamalarda kullanılan veri seti NNCI platformundan alınan uluslararası 10-20 sistemine uygun bir şekilde 16 kanal üzerinden elde edilen EEG sinyallerinden oluşmaktadır. İlk uygulamada; ilgili veri setinde yer alan sinyallerin spektrogram görüntüleri elde edilmiştir. Derin öğrenme mimarileri ve makine öğrenmesi algoritmalarıyla (AlexNet-SVM, AlexNet-KNN, GoogleNet-SVM, GoogleNet-KNN, VGG16-SVM ve VGG16-KNN) hibrit modelleri oluşturulup spektrogram görüntüleri kullanılarak uygulamalar gerçekleştirilmiştir. Her bir kanalın sınıflandırma sonuçlarının başarımları gözlemlenerek en yüksek doğruluk oranının VGG16-SVM modeliyle elde edildiği gözlemlenmiştir. Ek olarak kanallarına ayrılmadan EEG kanallarının tümü üzerinden yapılan sınıflandırmalar aynı hibrit modeller üzerinde gerçekleştirilmiştir. Tüm kanalların bir arada bulunduğu uygulama için en iyi sonucu %99,39 ile AlexNet-KNN hibrit modeli vermiştir. Denenen 6 hibrit modelin sonuçları üzerinde durulup kanal bazlı sınıflandırmanın avantajları üzerinde durulmuştur.

Bu tez kapsamında yer alan ikinci bir uygulamada aynı veri seti üzerinden alınan ham EEG verileri LSTM ağı ile birlikte ele alınıp sınıflandırmaya tabi tutulmuştur. LSTM ağı ile gerçekleştirilen sınıflandırma işlemlerinde hem 16 EEG kanalı üzerinden hem de tüm kanalların bir arada bulunduğu veriler üzerinden sınıflandırmalar gerçekleştirilmiştir.

Anahtar Kelimeler: Şizofreni, Elektroensefalogram, Derin Öğrenme, Spektrogram, LSTM

ABSTRACT

Determination of Schizophrenia Patients from EEG Signals with Deep Learning Methods

Büşra ÇETİN SÖYLEMEZ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences

Department of Computer Engineering
February 2023, Page x+54

The diagnosis of schizophrenia is made through patient interviews by a psychiatrist who is an expert in the field. The mentioned detection process is a time-consuming, costly and error-prone process. In schizophrenia, which is a serious and chronic disease, patients tend to exhibit different behaviors, believe in unreal events and change their personalities by losing their connection with real life. In this life-long disease, the disease can be brought under control with the right treatment. In this way, patients can continue their lives as healthy individuals and be successful in their social relations and business life. The treatment process requires great care and sensitivity as it can trigger the recurrence of the disease in the slightest neglect. Because of all these reasons, diagnosis of the disease is important. In this thesis, it is aimed to determine whether people have schizophrenia from EEG signals in order to accelerate the diagnosis and diagnosis process of schizophrenia. For this purpose, two applications were carried out. The data set used in the applications consists of EEG signals obtained over 16 channels in accordance with the international 10-20 system received from the NNCI platform. In the first application; Spectrogram images of the signals in the relevant data set were obtained. Hybrid models were created with deep learning architectures and machine learning algorithms (AlexNet-SVM, AlexNet-KNN, GoogleNet-SVM, GoogleNet-KNN, VGG16-SVM and VGG16-KNN) and applications were carried out using spectrogram images. By observing the performance of the classification results of each channel, it was observed that the highest accuracy rate was obtained with the VGG16-SVM model. In addition, classifications made over all EEG channels without dividing into channels were performed on the same hybrid models. The AlexNet-KNN hybrid model gave the best result with 99.39% for the application where all channels are combined. The results of the 6 hybrid models tested are emphasized and the advantages of channel-based classification are emphasized.

In a second application within the scope of this thesis, the raw EEG data obtained from the same data set were handled and classified together with the LSTM network. In the classification processes performed with the LSTM network, classifications were carried out both over 16 EEG channels and on the data in which all channels were together.

Keywords: Schizophrenia, Electroencephalogram, Deep Learning, Spectrogram, LSTM

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1.	16 Kanallı EEG Elektrotları [48]	12
Şekil 3.2.	Sağlıklı Bireyin 16 Kanallı EEG Değişimi	13
Şekil 3.3.	Şizofren Bireyin 16 Kanallı EEG Değişimi	14
Şekil 3.4.	AlexNet Mimarisi	17
Şekil 3.5.	Konvolüsyon İşlemi I.....	19
Şekil 3.6.	I. Adımın Matematiksel Gösterimi.....	19
Şekil 3.7.	Konvolüsyon İşlemi II.....	19
Şekil 3.8.	II. Adımın Matematiksel Gösterimi	20
Şekil 3.9.	ReLU Aktivasyon Fonksiyonu.....	22
Şekil 3.10.	Maksimum Havuzlama İşlemi	23
Şekil 3.11.	Ortalama Havuzlama İşlemi.....	23
Şekil 3.12.	Dropout İşlemi Uygulandıktan Sonra Ağın Değişimi	24
Şekil 3.13.	Tam Bağlantılı Katman	25
Şekil 3.14.	GoogleNet Başlangıç Modülü.....	26
Şekil 3.15.	VGG16 Mimarisi	27
Şekil 3.16.	Destek Vektör Makinesinin Grafikselsel Gösterimi	28
Şekil 3.17.	LSTM Hücre Yapısı.....	30
Şekil 3.18.	AlexNet (a), VGG16(b) ve GoogleNet(c) Blok Şemaları	34
Şekil 4.1.	Sınıflandırma Modeli	35
Şekil 4.2.	1.Hastanın 16 Kanallı EEG Sinyali.....	42
Şekil 4.3.	2.Hastanın 16 Kanallı EEG Sinyali.....	42
Şekil 4.4.	1 ve 2.Hastanın 16 Kanal Verilerini Kullanarak ($u=0,3$) Çoğaltılan Verinin EEG Sinyali	43
Şekil 4.5.	1.Hastanın 16 Kanallı EEG Spektrogram Görüntüsü.....	43
Şekil 4.6.	2. Hastanın 16 Kanallı EEG Spektrogram Görüntüsü.....	44
Şekil 4.7.	1 ve 2.Hastanın 16 Kanal Verilerini Kullanarak ($u=0,3$) Çoğaltılan Verinin Spektrogram Görüntüsü.....	44
Şekil 4.8.	LSTM Uygulama Modeli.....	45
Şekil 4.9.	LSTM Eğitim Verisi Karmaşıklık Matrisi	46
Şekil 4.10.	LSTM Test Verisi Karmaşıklık Matrisi	46
Şekil 4.11.	LSTM Eğitim Eğrisi.....	48

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Literatürde Bulunan İlgili Çalışmalar.....	10
Tablo 3.1. Aktivasyon Fonksiyonları	21
Tablo 3.2. Karmaşıklık Matrisi	32
Tablo 4.1. Kanal Bazlı Yapılan Sınıflandırmaların Doğruluk Sonuçları.....	38
Tablo 4.2. Kanal Bazlı Yapılan Sınıflandırmaların Duyarlılık Sonuçları	39
Tablo 4.3. Kanal Bazlı Yapılan Sınıflandırmaların Özgüllük Sonuçları	40
Tablo 4.4. Kanal Bazlı Yapılan Sınıflandırmaların Kesinlik Sonuçları	41
Tablo 4.5. Hibrit Modellerle Kanallarına Ayrılmadan Yapılan Sınıflandırma Sonuçları.....	44
Tablo 4.6. 16 Kanal Bazlı LSTM Sonuçları	47
Tablo 4.7. Tüm Kanalların LSTM Sonucu.....	47

KISALTMALAR

BDDDA	: Boosted Version of Direct Linear Discriminant Analysis
CNN	: Convolutional Neural Network
CMT	: Cross Modal Task
CWT	: Sürekli Dalgacık Dönüşümü
DSÖ	: Dünya Sağlık Örgütü
EEG	: Elektroensefalografi
EBT	: Ensemble Bagged Tree
EMD	: Empirical Mode Decomposition
ERP	: Event Related Potentials
DT	: Desicion Tree
fMRI	: Functional Magnetic Resonance İmaging
FSVM	: Fuzzy Support Vector Machine
GPU	: Graphics Processing Units
ILSVRC	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge)
IMF	: İçsel Mod Fonksiyonları
LDA	: Linear Discrete Analysis
LZC	: Lempel-Ziv Complexity
MCCA	: Multiset Canonical Correlation Analysis
MDC-CNN	: Multi-Domain Connectome Convolutional Neural Network
MZC	: Multiscale Lempel-Ziv Complexity
MRI	: Magnetic Resonance Imaging
PNN	: Probabilistic Neural Network
PCC	: Pearson Correlation Coefficient
PLS	: Partial Least Squares
RGB	: Red, Green, Blue
RBF	: Radial Basis Function
RFE	: Recursive Feature Elimination
ReLU	: Rectified Linear Units
ROC	: Receiver Operating Characteristics
SMRI	: Semi Quantitative Magnetic Resonance Imaging
SNR	: The Signal To-Noise Ratios
SPN	: Spatial Pattern of Network
SSPEV	: Steady-State Visual Evoked Potentials
YSA	: Yapay Sinir Ağları
VGG	: Visual Geometry Group

1. GİRİŞ

Şizofreni insanın rutin davranışlarının yanı sıra düşünme yetisini de etkileyen kronik bir hastalıktır. Dünya Sağlık Örgütü'nün (DSÖ) raporu, şizofreninin ciddi bir ruhsal bozukluk olduğunu ve dünya çapında 21 milyondan fazla insanın bundan etkilendiğini vurgulamaktadır [1]. Şizofreni, sanrılar (doğru olmayan garip sabit inançlar), halüsinasyonlar (var olmayan şeyleri görme veya duyma), düzensiz konuşma veya algı, duygular, dil, benlik ve bozulmuş bilişsel yetenek gibi bir yığın belirtiliyle karakterize olmuş karmaşık ve uzun süreli bir beyin bozukluğudur [2]. Buna rağmen DSÖ, şizofreninin tedavi edilebilir olduğunu, erken veya sonradan teşhisin ciddiyetini ve evresini belirlemeye yardımcı olabileceğini de belirtmiştir. Düşünme, hafıza, algı ve diğer yaşam aktivitelerinde önemli rahatsızlıklar yarattığından hastalar ve hasta yakınları için şizofreninin saptanması ve tedavisi önemlidir. Tedavi edilmediği takdirde, sonraki aşamalarda kişinin davranışsal yetilerine zarar veren, geri döndürülemez bir sürece dönüşebilir [3].

Genel olarak, şizofreniyi tespit edebilecek herhangi bir test veya fiziki muayene yoktur. Bunun yerine, ruh sağlığı uzmanları teşhis koymaya yardımcı olmak için çeşitli araçlar kullanır. Bu araçlar şunları içerir:

- tıbbi geçmiş,
- psikolojik değerlendirme,
- laboratuvar testleri,
- beyin görüntülemeler.

Tıbbi bir geçmiş sırasında, doktor herhangi bir kişisel veya aile akıl hastalığı öyküsü hakkında soru soracaktır. Doktor ayrıca mevcut semptomları, ne zaman başladığını ve zaman içinde nasıl değiştiklerini de soracaktır.

Psikolojik bir değerlendirme genellikle düşünce, duygu ve davranışları tartışmak için bir ruh sağlığı uzmanı ile görüşmeyi içerir. Akıl sağlığı uzmanı, bazen şizofreninin bir belirtisi olabileceğinden, herhangi bir madde kötüye kullanımı hakkında da soru soracaktır. Klinik değerlendirme sırasında bireyin belirti ve davranışları dikkatle değerlendirilmektedir. Klinisyen ayrıca bireyin kişisel ve aile öyküsünün yanı sıra olası çevresel stres faktörlerini de dikkate almaktadır. Şizofreni tanısının konulabilmesi için, kişinin önemli bir süre boyunca aşağıdaki belirtilerden en az ikisini yaşamış olması gerekir:

- Sanrılar
- Halüsinasyonlar
- Düzensiz konuşma
- Düzensiz veya katatonik davranış
- Olumsuz belirtiler

Ayrıca bu semptomlar bireyin iş, okul veya sosyal ortamlarda işlev görme yeteneğini önemli ölçüde etkilemektedir.

Şizofreni tanısı, bireyin semptomlarının diğer potansiyel nedenlerinin dışlanmasına da dayanmaktadır. Örneğin, uyuşturucu kullanımının veya tıbbi bir durumun sonucu olan semptomlar şizofreni göstergesi değildir. Şizofreni tanısı konulduktan sonra kişi tedavi görmeye başlayabilir. Tedavi tipik olarak ilaç ve psikoterapiyi içermektedir. Teşhiste yardımcı olacak yöntemin hastalık şüphesi bulunan kişinin beyin fonksiyonları hakkında bilgi vermesi gerekmektedir. Beyin fonksiyonları hakkında bilgi veren manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi gibi görüntüleme teknikleri maliyetlidir ve elektroensefalografi (EEG) gibi sinyal verme prosedürlerine kıyasla ek kayıt ve hesaplama süresi gerektirir [4-7]. Bu yüzden EEG, Şizofreni tespitinde hem maliyet hem zaman açısından tercih edilmektedir.

Literatürdeki ilgili çalışmalar sonucunda beynin hem uyanık hem de uyku durumunda sürekli bir elektriksel aktiviteye sahip olduğu gözlenmiştir. Bu biyoelektrik aktiviteye EEG sinyalleri adı verilmiştir [8]. EEG, çoğunlukla kafa derisinin farklı bölgelerine manuel olarak yerleştirilen elektrotlar veya bu amaç için tasarlanmış bir kulaklık cihazı aracılığıyla kafa derisi boyunca beyindeki elektriksel aktivitenin ölçülmesidir. EEG, genel bilişsel aktivite için düşük çözünürlüklü bir tanı aracı ve mobil hızlı kurulum bir araç olarak etkinliği nedeniyle belirli bir zamanda mevcut beyin durumunun bir göstergesi olarak invaziv olmayan (hastaya fiziksel bir zarar verme ihtimali olmayan) bir yöntem olarak giderek daha da fazla kullanılmaktadır. Bu ölçüm sırasında yerleştirilen elektrotların kafa derisine yerleştirilmesine ilişkin uluslararası düzenlemeler vardır. Günümüzde standart bir 10-20 elektrot düzenlemesi kullanılmaktadır. Kaydedilen bu EEG sinyalleri hem zaman alanında hem de frekans alanında bileşenlere bölünerek analiz edildiğinde, EEG sinyallerinin anlamlı veriler sağladığı çalışmalarla keşfedilmiştir [9]. Son yıllarda, EEG, epilepsi [10], Alzheimer hastalığı [11] ve Şizofreni [12] dahil olmak üzere çeşitli sinir sistemi hastalıklarının araştırılmasında ve teşhisinde yaygın olarak kullanılmaktadır.

Şizofreniyi tespit etmek için EEG kullanımını destekleyen bilimsel kanıtlar vardır. 2012 yılında Biological Psychiatry dergisinde yayınlanan bir araştırma [13], şizofreni hastalarının sağlıklı kontrollere kıyasla önemli ölçüde farklı beyin aktivitesi modellerine sahip olduğunu buldu. Çalışma, beyin aktivitesini ölçmek için EEG kullandı ve şizofreni hastalarının ön ve temporal loblarda daha düşük aktivite seviyelerine sahip olduğunu buldu. Beyin aktivitesindeki bu farklılık, düzensiz düşünme ve halüsinasyonlar gibi şizofreninin klinik semptomlarıyla da ilişkilidir.

NeuroImage dergisinde 2013 yılında yayınlanan bir başka çalışmada [14], şizofreni hastalarının beynin farklı bölümlerinin birbirleriyle iletişim kurma biçiminde anormallikler olduğu bulundu. Çalışma, beyin aktivitesini ölçmek için EEG kullandı ve şizofreni hastalarının ön

ve temporal loblar arasındaki bağlantının azaldığını buldu. Bu azalan bağlantı, düzensiz düşünce ve halüsinasyon semptomlarıyla ilişkilendirildi. Bu çalışmalar, EEG'nin şizofreniyi saptamak için yararlı bir araç olabileceğini düşündürmektedir. EEG sinyalleri doğası gereği doğrusal olmadığı için, normal ve Şizofreni hastalarının EEG sinyallerini ayırt etmek için genellikle doğrusal olmayan öznitelik çıkarma teknikleri kullanılmaktadır [15]. Bu öznitelik çıkarma teknikleri genelde manuel olarak makine öğrenmesi (ML) algoritmalarıyla, otomatik olarak da derin öğrenme (DL) algoritmalarıyla gerçekleştirilir.

Makine öğrenimi yaygın olarak örüntü tanıma için kullanılır. Makine öğreniminin birçok sınıflandırma uygulamalarında kullanımıyla birlikte bu son teknoloji, teknik bazı engeller sergilemektedir. Temel tanımlama görevleri için iyi çalışır [16], ancak incelenen özelliklerin önemli değişkenlik gösterdiği gerçekçi ortamlarda, onları tanımak için daha büyük eğitim veri setlerine ihtiyaç vardır [17]. Ek olarak, büyük bir öğrenme kapasitesine sahip bir model, geleneksel makine öğrenimi tekniklerine kıyasla büyük veri kümelerinden verilerin öğrenilmesi yoluyla daha yüksek düzeyde özelliklerin çalışılmasına olanak tanır. Ayrıca, geleneksel teknikler, verideki özelliklerin manuel olarak çıkarılmasını gerektirir. Derin öğrenmede, geleneksel makine öğrenme tekniklerinden farklı olarak hem özellik çıkarma hem de sınıflandırma işlemleri otomatik olarak gerçekleştirilmektedir [18,19]. LSTM ağ yapısı özel bir tekrarlayan sinir ağı türü olduğu için DL algoritmaları arasında değerlendirilerek ele alınmaktadır.

1.1. Tezin Amacı

Şizofreninin saptanmasında klinik görüşmeye ek olarak bir dizi başka değerlendirme aracı kullanılabilir. Bunlara psikolojik testler, tıbbi testler ve beyin görüntüleme dahildir. Bilimsel araştırmalar, şizofreniyi kesin olarak teşhis edebilecek tek bir test veya araç olmadığını göstermiştir. Tek bir test veya araç yerine Şizofreni teşhis mevcut tüm bilgilerin kapsamlı bir değerlendirmesine dayanarak yapılmaktadır. Her ne kadar Şizofreninin saptanması karmaşık bir süreç olsa da DSÖ'nün görüşüne göre bozukluğun büyük ölçüde tedavi edilebilir olduğunu bilmek önem arz etmektedir. Erken teşhis ve uygun tedavi ile şizofreni hastaları mutlu ve üretken bir yaşam sürdürebilmektedir.

Bu çalışmanın ana amacı tanı ve teşhis süreci zor olan şizofreni gibi mental bir hastalığın, teşhisini kolaylaştıracak adımlar ve bu alanda geliştirilebilecek sistemler için EEG kullanımının yanı sıra derin öğrenme ve makine öğrenmesi gibi hibrit yapıların da kullanımının bu alanda kayda değer sonuçlar verip veremeyeceğini gözlemleyebilmektir. Hastalığın psikolojik bir hastalık olması sebebiyle teşhis zorluğu göz önünde bulundurulduğunda, hastalığın öncelikle bilgisayar sistemleriyle tespiti bir nebze olsa doktorlara kolaylık sağlayıp, zaman kazandıracaktır. Geliştirilebilecek olan sistemler sağlık sektöründe işe yarar adımlar atılmasına

öncülük edecektir. Böylece teşhis süreci hızlanacak, bu da hastanın tedavi edilebilirliğini kolaylaştıracaktır. Tedavi öncesinde hayata karışamayan hasta bireyler böylelikle gerçek hayata uyum sağlayabilecekler ve böylelikle günlük hayatlarını sürdürebileceklerdir. Hastaların tedavi edilebilmesiyle elde edilen avantajların yanında hasta yakınları da ağır bir yükten kurtulabileceklerdir. Bu tezin amacı; EEG sinyallerini kullanarak, DL yöntemleri ve LSTM ağı ile şizofreni hastalığının tespitini hem kolaylaştırmak hem de hızlandırmak ve bu sayede hastaların günlük hayatlarını yaşanılabilir hale getirmektir.

1.2. Tezin Organizasyonu

Bu tez çalışması 5 bölümden oluşmaktadır. Tezin organizasyonu şu şekildedir. Birinci bölüm giriş bölümü olup; Şizofreninin ne olduğu ve tezin amacı açıklanmıştır. İkinci bölümde ise ilgili çalışmalara değinilerek literatür taraması özetlenmiştir. Üçüncü bölümde, şizofreni tespiti çalışmasında yer alan konvolüsyonel sinir ağı mimarileri, geleneksel makine öğrenmesi sınıflandırıcıları, aktivasyon fonksiyonları ve sınıflandırma problemlerinde kullanılan başarı ölçüm metrikleri anlatılmıştır. Dördüncü bölümde, çalışmada gerçekleştirilen uygulamalara ve bu uygulamalardan elde edilen başarımların sonuçlarına yer verilmiştir. Son olarak beşinci bölümde ise, tezde yapılanlar özetlenmiş ve bulunan genel sonuçlardan bahsedilerek çeşitli önerilerde bulunulmuştur.

2. LİTERATÜR TARAMASI

Geleneksel makine öğrenmesi ve derin öğrenme, yapay zekânın iki önemli dalıdır, derin öğrenme aslında geleneksel makine öğreniminin daha ileri versiyonudur. Son yıllarda makine öğrenmesine ek olarak derin öğrenme teknikleri, farklı nörolojik ve zihinsel bozuklukları gerçek zamanlı olarak etkin bir şekilde teşhis etmek için görüntü tabanlı veya sinyal veri kümelerinin analizi için çeşitli sağlık uygulamalarında yaygın olarak kullanılmaktadır. Geleneksel makine öğreniminde, şizofreni teşhisi için uygun özellik çıkarma algoritmalarının seçilmesi, sinyal işleme ve yapay zekâ alanında çok fazla bilgi gerektiren nispeten zorlu bir görevdir. Bu sorunun üstesinden gelmek için, son yıllarda EEG sinyalleri aracılığıyla şizofreni teşhisi için, öznelik çıkarma işlemlerinin derin katmanlar tarafından otomatik olarak gerçekleştirildiği DL tabanlı yöntemler geliştirilmiştir. İleri seviye bir sinir ağı olan LSTM derin öğrenme alanında değerlendirilir. Şizofreni tespitinde LSTM ile ilgili çalışmaların sayısı makine öğrenmesi ve DL mimarilerine oranla daha az olsa da son yıllarda uygulanma oranında artış gözlenmektedir.

Birçok alanda uygulanan bu yöntemlerin sağlık sektöründe de giderek kullanımının yaygınlaştığı gözlemlenmektedir. Şizofreninin makine öğrenmesi ve derin öğrenme algoritmaları ile EEG sinyallerinden tespiti üzerine birçok çalışma bulunmaktadır. Bunlardan bazıları: Kim ve ark. [20] tarafından yapılan bir çalışmada, 10–20 uluslararası standartlara göre konumlandırılmış 21 altın kupa elektrottan EEG sinyallerini çıkararak katılımcıların yatay ve dikey göz hareketlerini incelemişlerdir. Ön işlem aşamasından sonra, analiz için beş frekans bandı seçilerek beş bandın her biri için, EEG'nin spektral gücü, Hızlı Fourier Dönüşümü kullanılarak hesaplanmış ve ardından EEG güç sapmalarını incelemek için Varyans Analizi (ANOVA) yöntemi kullanılmıştır. Normal ve Şizofreni hastalarını ayırt etmede kullanılan bir testin tanısallık performansını belirlemek için Alıcı Çalışma Eğrisi (ROC) analiz tekniği kullanılmış ve en yüksek sınıflandırma doğruluğu %62,2 ile delta gücü için elde edilmiştir.

Dvey-Aharon ve ark. [21] sağlıklı denekler ile şizofreni teşhisi konmuş ve ilgili reçeteli ilaçları alan deneklerini sınıflandırabilmek için kısa bir süre içinde (bir dakikadan daha az) toplanan EEG verilerinin yeterli olup olmadığı incelenmiştir. Şizofreni ayırım sistemi EEG sinyalinin Özellik Optimizasyonu tarafından takip edilen bir zaman-frekans dönüşümüne (TFFO) dayanmaktadır. Bu çalışmada, EEG sinyalini bir görüntüye dönüştürmek için bir Stockwell yaklaşımı uygulanmış ve ardından daha iyi sonuçlar elde etmek için özellik çıkarma ve sınıflandırma yöntemleri uygulanmıştır. İlk beş benzersiz elektrotun %92,0 ile %93,9 arasında bir tahmin doğruluğuna sahip olduğu ve F2 bölgesinin en iyi elektrot olduğu belirlenmiştir.

Ibáñez-Molina ve ark. [22] şizofreni hastalarında ve sağlıklı kontrollerde bilişsel talepler altında beyin karmaşıklığının nasıl değiştiğini gözlemlemek amacıyla katılımcılardan istirahat halindeyken ve resim adlandırma görevi esnasında EEG kayıtları alınmıştır. 18 hasta ve 17

eşleşen sağlıklı kontrolden resimleri isimlendirmeleri istenmiştir. EEG'ler klasik Lempel-Ziv Karmaşıklığı (LZC) ve Çok Ölçekli LZC(MLZC) ile analiz edilmiştir. Veri toplama için Neuroscan SynAmps 32 kanallı amplifikatör kullanılmıştır. Dinlenme aşamasındaki segmentler hareketli bir pencere yöntemi kullanılarak analiz edilip, ardından her bir pencere için LZC hesaplanmıştır. Normalizasyondan sonra, hareketli pencere yönteminden elde edilen değerlerin ortalaması hesaplanarak nihai LZC değeri hesaplanmıştır. Toplam 80 EEG segmenti görevde değerlendirilmiş, en son elde edilen Çok Ölçekli LZC değerini elde etmek için bu segmentlerin ortalaması alınmıştır. Dinlenme durumundaki hastaların sağ frontal bölgelerinde daha yüksek karmaşıklık değerleri belirlenmiştir.

Johannesen ve ark. [23] EEG kayıtlarını elde etmek için 64 elektrotlu bir sistem kullanmıştır. Katılımcılar tarafından verilen yanıt, dört aşamalı işleme yoluyla analiz edilmiş ve bölümlere ayrılmıştır. Beş frekans bandının her biri için zaman-frekans verileri hesaplanmış ve ön, merkezi ve oksipital konumlar için spektral güç istatistiksel olarak analiz edilmiştir. Sınıflandırma için iki model geliştirilmiş olup ilk model, doğru ve yanlış denemeleri ayırt etmek için geliştirilmiş ve %87 doğruluk elde edilmiştir. İkinci model, doğru deneme verilerini normale karşı Şizofreni durumuna göre sınıflandırmak için kullanılır ve SVM kullanılarak %87'lik bir doğruluk elde edilmiştir.

Diğer bir çalışmada Santos-Mayo ve ark. [24] elektrot gruplama ve filtreleme dahil olmak üzere çeşitli ML yaklaşımlarını ve özellik seçim algoritmalarını test etti. Sonuç olarak, Çok Katmanlı Algılayıcı (MLP) ve SVM algoritmalarının sırasıyla %93,42 ve %92,23 ile sınıflandırma performansında en iyi doğruluğa sahip olduğunu bildirmişlerdir. Ayrıca, J5 öznitelik seçim algoritmasından [25] elde edilen öznitelikler üzerinden sınıflandırma daha iyi performans göstermiştir.

Shalhaf ve ark. [26] ise sağlıklı kontrollerden şizofreni hastalarının teşhisi için CNN tabanlı DL mimarileri ile transfer öğrenmeye dayalı otomatik bir metodoloji sunar. İlk olarak, sürekli dalgacık dönüşümü (CWT) yöntemi ile bir zaman-frekans yaklaşımı uygulanarak EEG sinyalleri görüntüye dönüştürülmüştür. Ardından, EEG sinyallerinin görüntüleri önceden eğitilmiş dört popüler DL mimarisi olan AlexNet, ResNet-18, VGG-19 ve Inception-v3 ile denenmiştir. Şizofreni hastalarını ve sağlıklı denekleri sınıflandırmak için bu modellerin konvolüsyon ve havuzlama katmanlarının çıktıları derin özellikler olarak kullanılır ve SVM sınıflandırıcısına kaynak oluşturularak sınıflandırma için gerekli olan veriler olarak kullanılmıştır. Önerilen yöntemin etkinliği 14 sağlıklı denek ve 14 şizofreni hastasından alınan EEG sinyalleri üzerinden değerlendirilmiştir. Deneyler, ResNet-18-SVM'ye uygulanan frontal, santral, parietal ve oksipital bölgelerin kombinasyonunun sırasıyla $98,60 \pm 2,29$, $99,65 \pm 2,35$ ve $96,92 \pm 2,25$ doğruluk, duyarlılık ve özgüllük ile en iyi sonuçların elde edildiği gözlemlenmiştir.

Diğer bir çalışmada Ahmedt-Aristazabal ve ark. [27] tipik gelişen çocuklara kıyasla şizofreni riski yüksek olan çocukları belirlemek için ham EEG dalga biçimlerini işleyebilen otomatik teknikler önermişlerdir. Katılımcılardan gelen EEG verileri, işitsel tuhaflik görevinin üç farklı denemesi sırasında kaydedilen EEG sinyallerinin analizini kullanarak çocuklarda şizofreninin tanımlanması için bir DL yaklaşımı sundu. Bu yaklaşımda, KNN, SVM, karar ağacı, 1D-CNN, 2D-CNN, LSTM, 1D-CNN-LSTM, 1D-CNN-GRU, 2D-CNN'den oluşan normal ve şizofreni sınıflarını sınıflandırmak için çeşitli algoritmalar test edilmiştir. Önce manuel tasarlanmış özelliklere (olayla ilgili potansiyel bileşenler) uygulanan sınıflandırma yöntemlerini kullanarak geleneksel makine öğrenimi algoritmalarını keşfederek beyin anormalliklerini belirlemek için bütünsel bir çalışma yapılmıştır. Ardından, ham verilere uygulanan uçtan uca derin öğrenme teknikleri ile bu yöntemlerin performansı karşılaştırılmıştır. Tekrarlayan derin konvolüsyonel sinir ağlarının (R-CNN), dizi modelleme için geleneksel makine öğrenme yöntemlerinden daha iyi performans gösterebileceğini ortalama çapraz doğrulama performans ölçümleriyle gösterilmiştir. Derin öğrenme modelleri için doğrudan daha kısa süreli ham EEG segmentlerini ele alınmıştır. Tüm bu algoritmalar arasında, 2D-CNN ve LSTM algoritmalarının hibrit modeli olan R-CNN, üç farklı deneme için %69,80'lik bir genel test doğruluğu elde ederek iyi performans göstermiştir.

Oh ve ark. [28], şizofreninin sınıflandırılması için on bir katmanlı derin öğrenme modeli geliştirmişlerdir. Konu bazında testler ve konu bazında olmayan testler için iki CNN modeli ayrı ayrı geliştirilmiştir. 14 sağlıklı denekten ve 14 şizofreni hastasından EEG sinyalleri toplanmış ve sinyalleri analiz etmek için on bir katmanlı CNN modeli geliştirilmiştir. Çalışmada, önemli öznitelikleri otomatik olarak çıkarabilen ve sınıflandırabilen derin öğrenme algoritmaları kullanılmıştır. Özellikler, maksimum havuzlama aşamasında çıkarılan en önemli özelliklerle birlikte konvolüsyon aşamasında otomatik olarak çıkarılmış ve sinyalleri sınıflandırmak için tam bağlantılı katman kullanılmıştır. Önerilen model, konu bazlı olmayan testler ve konu bazlı testler için sırasıyla %98,07 ve %81,26 sınıflandırma doğruluğu üretmiştir.

Shoeibi ve ark. [29] çalışmalarında otomatik şizofreni tespiti için EEG sinyalleri aracılığıyla çeşitli DL temelli yöntemleri kullanmışlardır. Derin öğrenme aracılığıyla gerçekleştirilen sonuçlar, geleneksel akıllı yöntemlerle karşılaştırılmıştır. Önerilen yöntemleri uygulamak için Polonya, Varşova'daki Psikiyatri ve Nöroloji Enstitüsü'nün veri setini kullanmışlardır. İlk olarak, EEG sinyalleri 25 saniyelik zaman çerçevelerine bölünmüş ve ardından z-skoru veya L2 normu ile normalize edilmiştir. Sınıflandırma adımı, EEG sinyalleri aracılığıyla şizofreni teşhisi için iki farklı yaklaşım ele alınmıştır. Bu adımda, EEG sinyallerinin sınıflandırılması ilk olarak, örneğin destek vektör makinesi, KNN, karar ağacı, rastgele orman, aşırı derecede rastgele ağaçlar ve torbalama gibi geleneksel makine öğrenme yöntemleriyle gerçekleştirilmiştir. LSTM'ler, tek boyutlu konvolüsyonel ağlar (1D-CNN) ve 1D-CNN-LSTM

gibi önerilen çeşitli DL modelleri kullanılmıştır. Bu adımda, DL modelleri uygulanmış ve farklı aktivasyon fonksiyonları ile karşılaştırılmıştır. Önerilen DL modelleri arasında CNN-LSTM mimarisi en iyi performansa sahip olmuştur. Ele alınan mimaride, z-skoru ve L2 normalizasyonu ile ReLU aktivasyon fonksiyonu kullanılmıştır. Önerilen CNN-LSTM modelinde, bu alanda daha önce ele alınan birçok çalışmanın sonuçlarından daha iyi bir başarı sağlamış olup, %99,25 doğruluk değerine ulaşmışlardır.

Başka bir çalışma da Sun ve ark. [30], EEG sinyallerini kullanarak şizofreni hastaları ve sağlıklı kontrollerin EEG sinyallerini temsil edecek daha iyi bir özelliği tanımlamayı ve sınıflandırma doğruluğunu iyileştirmeyi amaçlamışlardır. Ele alınan yöntem iki adımdan oluşmaktadır. İlk olarak, EEG zaman serisi ön işleme tabi tutulur ve çıkarılan zaman alanı ve frekans alanı öznitelikleri, uzamsal bilgi taşıyan bir dizi kırmızı-yeşil-mavi (RGB) görüntüye dönüştürülmüştür. İkinci olarak, Şizofreni hastalarını ve sağlıklı kontrolleri sınıflandırmak için RGB görüntülerini ele almak için konvolüsyonel sinir ağlarını ve uzun kısa süreli belleği birleştiren hibrit derin sinir ağları (DNN) oluşturulmuştur. Sonuçlar, beyin tomografisinde bulanık entropi (FuzzyEn) özelliğinin hızlı Fourier dönüşümü (FFT) özelliğinden daha önemli olduğunu göstermiştir. Önerilen derin öğrenme yöntemi, FuzzyEn ile uygulanınca %99,22 ortalama doğruluk ve FFT ile uygulanınca ortalama %96,34 doğruluk elde edilmiştir.

Singh ve ark. [31], gerçek zamanlı olarak çok kanallı EEG sinyallerinin spektral analizini kullanarak şizofreni hastalarının doğru bir şekilde tanımlanması için spektral özniteliklere dayalı CNN modeli önermişlerdir. Ele alınan model öncelikle EEG sinyallerini filtreleme, segmentasyon ve frekans alanına dönüştürme adımlarından oluşmaktadır. Bu gerçekleştirilen işlemlerden sonra, verilen frekans alanı segmentleri delta, teta-1, teta-2, alfa, beta ve gama gibi altı farklı spektral banda bölünmüştür. Ortalama spektral genlik, spektral güç ve Hjorth tanımlayıcıları (etkinlik, hareketlilik ve karmaşıklık) dahil olmak üzere spektral özellikler her banttan çıkarılmıştır. Bu özellikler, sınıflandırma için önerilen spektral öznitelik tabanlı CNN ve LSTM modellerine bağımsız olarak beslendiği tespit edilmiştir. Bu çalışma aynı anda, aynı mimarilerin sırasıyla zamansal CNN ve spektral CNN modellerini kullanarak sınıflandırma için ham zaman etki alanı ve frekans etki alanı EEG segmentlerini kullandığı gözlemlenmiştir. Tüm modellerin simülasyon sonuçlarının genel analizi, önerilen spektral öznitelik tabanlı CNN modelinin, iki farklı veri kümesi için ortalama %94,08 ve %98,56 sınıflandırma doğruluğu ile sağlıklı bireyler arasında şizofreni hastalarının doğru ve hızlı tanımlanması için optimal olarak kısıtlı sınıflandırma süresine sahip olmasına karşın etkili bir teknik olduğunu göstermiştir.

Siuly ve ark. [32], durağan olmayan ve doğrusal olmayan EEG sinyallerinin davranışını en iyi şekilde işlemek için EEG sinyallerinden şizofreninin teşhisi için ampirik mod ayrıştırma (EMD) tekniğini kullanan bir yöntem üzerinde çalışmışlardır. Öncelikle her bir EEG sinyali, Grup Torbalı Ağaç (EBT) algoritması tarafından içsel mod fonksiyonlarına (IMF) ayrıştırılmış ve

daha sonra bu IMF'lerden 22 istatistiksel özellik çıkarılmıştır. Belirlenen 22 istatistiksel özellik arasından Kruskal Wallis testi uygulanarak en anlamlı 5 özellik seçilmiştir. Elde edilen öznelik seti ile ele alınan EEG veri seti üzerinde birçok sınıflandırma yöntemi denenmiştir. Bu algoritmalar arasında, EBT Şizofreni için %93,21'lik doğru sınıflandırma oranı ve IMF 2 için %89,59'luk genel doğruluk oranı elde ederek üstün bir performans sergilediğini göstermişlerdir.

Jamnuah ve ark. [33], EEG sinyal modellerini araştırmak, normal ve şizofreni sınıflarına ayırmak için bir Otomatik Tanı Aracı (ADT) geliştirmeyi amaçlamışlardır. ADT, EEG serisi bölme, doğrusal olmayan özellik madenciliği, *t*-testine dayalı özellik seçimi, sınıflandırma ve doğrulama gibi işlemleri uygulamak için geliştirilmiştir. Önerilen ADT, normal ve şizofreni sınıfı gönüllülerden toplanan 19 kanallı 6250 örnek noktası bulunan ham EEG veri seti ile çalışmışlardır. Doğrusal olmayan özellik çıkarımı, her bir EEG verisinden 157 özellik çıkarmak için uygulandı ve bunlardan 14 tanesi en işe yarar özellikler olarak belirlendi. Son olarak, Karar Ağacı (DT), Doğrusal Ayrım Analizi (LDA), *k*-En Yakın Komşu (KNN), Olasılıklı Sinir Ağı (PNN) ve Destek Vektör Makinesi (SVM) ile bir sinyal sınıflandırma uygulaması çeşitli parçalarına uygulandı. Radyal Temelli İşlevli (SVM-RBF) SVM, bu çalışmada uygulanan diğer sınıflandırıcılara oranla, dikkate alınan EEG veri setinde %92,91'lik üstün bir ortalama performans değeri sergilemiştir.

Devia ve ark. [34], görüntülerin serbest görsel keşfi kullanılarak şizofreninin klinik tanısını desteklemek için elektrofizyolojik bir araç geliştirmeyi amaçlamışlardır. Şizofreni sendromunun biyobelirteçleri olarak EEG kayıtları alınırken hastalar doğal sahneleri serbestçe izlemiş ve görüntü başlangıcına kilitlenmiş ortalama EEG aktivitesi yani olaya ilişkin potansiyelleri (ERP) analiz edilmiştir. Görüntü başladıktan yaklaşık 500 ms sonra beynin oksipital alanlarında hastalar ve sağlıklı kontrollerin kayıtları arasında önemli farklılıklar bulunmuştur. Belirlenen farklılıklar, şizofreni hastalarını kontrollerden ayırt edecek bir sınıflandırma yöntemi geliştirmek için kullanıldı. Kayıtlar filtrelenerek kullanılmıştır. Sınıflandırmalar sonucunda en iyi sınıflandırıcı, hastaların saptanmasında %81 duyarlılığa, kontrollerin saptanmasında %59 özgüllüğe sahip ve genel olarak %71'ik bir doğruluğa sahip olan Doğrusal Diskriminant Analizi (LDA) bulunmuştur.

Prabhakar ve ark. [35] şizofreninin EEG sinyallerinden sınıflandırılmasını analiz etmek için optimizasyon ve sınıflandırmaya dayalı bilgisayarlı bir yaklaşım yapılmıştır. Çalışma kapsamında Kısmi En Küçük Kareler (PLS), Doğrusal Olmayan Regresyon tekniği, Beklenti Maksimizasyonuna dayalı Temel Bileşen Analizi (EM-PCA) tekniği ve İzometrik Haritalama (Isomap) tekniği kullanılarak özellikler belirlenmiştir. Çıkarılan özellikler, Çiçek Tozlaşma algoritması, farklı evrim algoritması kullanan Eagle stratejisi, Geri İzleme (Backtracking) optimizasyon algoritması ve Grup Arama optimizasyon algoritması gibi dört optimizasyon algoritması ile optimize edilmiştir. Optimize edilmiş değerler daha sonra hem Adaboost sınıflandırıcısının hem de Naive Bayesian Sınıflandırıcısının çeşitli sürümleriyle

sınıflandırılmıştır. İzometrik Haritalama özniteliklerinin Geri İzleme optimizasyon algoritması ile optimize edildikten sonra Modest Adaboost sınıflandırıcısı ile sınıflandırıldığında, %98,77'lik bir sınıflandırma doğruluğu elde edilmiştir.

Alimardani ve ark. [36], dış etkenlerle uyarılan EEG'lerin bipolar ve şizofreni hastalarının sınıflandırılmasında kullanılıp kullanılamayacağını araştırmak için, kararlı durum görsel uyarılmış potansiyeli (SSVEP) indüklemek için belirli bir frekansta modüle edilmiş bir görsel uyaran kullanmışlardır. EEG verileri kaydedilirken şizofreni ve bipolar hastalarından oluşan iki gruba 16 Hz'de modüle edilmiş bir ışık uyarı 95 saniye süreyle sunulmuştur. Sinyal-gürültü oranları (SNR) birimlerinde açıklanan SSVEP'lerin (ortalama, çarpıklık ve basıklık) istatistiksel ölçümleri yapılmıştır. İki gruptaki beyin aktivite modellerinin varyasyonlarını belirlemek ve sınıflandırmak için özellikler olarak çıkarılmıştır. İki beyin alanı, O1 ve Fz, sırasıyla SNR ortalaması ve basıklık için iki grup arasında istatistiksel olarak anlamlı bir fark gösterdi. Uygulanan beş sınıflandırıcı arasında KNN, Fisher skoru ile seçilen en iyi özellik seti ile %91,30 ile en yüksek sınıflandırma doğruluğunu sağlamıştır.

Shim ve ark. [37] çalışmalarında şizofreni hastalarının ve sağlıklı kontrollerin sınıflandırılması için işitsel bir görev sırasında kaydedilen EEG sinyallerinden çıkarılan hem sensör düzeyinde hem de kaynak düzeyinde özellikler kullanılmıştır. 34 şizofreni hastası ve 34 sağlıklı kontrolden EEG sinyalleri kaydedilirken, her deneğin tuhaf tonlara dikkat etmesi istendi. Fisher Skoru kullanılarak sensör düzeyi ve kaynak düzeyindeki özellikler çıkarılıp SVM sınıflandırma algoritmasıyla sınıflandırılmıştır. Sonuçlar yalnızca sensör düzeyindeki özelliklerin kullanıldığı duruma oranla, kaynak düzeyindeki özellikler sensör düzeyindeki özelliklerle birlikte kullanıldığında daha yüksek sınıflandırma doğruluğu göstermiştir. Kombine öznitelik seti kullanıldığında maksimum sınıflandırma doğruluğu %88,24 olarak elde edilirken, en yüksek sınıflandırma doğrulukları sensör seviyesi ve kaynak seviyesi özellik setleri için sırasıyla %80,88 ve %85,29 olmuştur. Ek olarak, seçilen sensör seviyesi özellikleri çoğunlukla ön bölgeden belirlenmiş ve seçilen kaynak düzeyindeki özellikler çoğunlukla, şizofreni hastalarında bilişsel işlevin iyi bilinen patolojik bölgesiyle örtüşen zamansal alandan çıkarılmıştır.

Li ve ark. [38], şizofreni ve sağlıklı kontroller arasındaki farklılaştırılabilir ağ topolojilerinin yanı sıra bir görev sırasında uyarılmış P300 genliğini ele almışlardır. Dinlenme ve P300 görev EEG veri setlerini ele alarak, işlevsel EEG ağları oluşturup ardından her iki beyin durumu için doğal uzamsal ağ modeli (SPN) özelliklerini elde etmişlerdir. SPN kullanılarak çıkarılan EEG ağının uzamsal modeli, şizofrenik bireyleri sağlıklı kontrollerden ayırt etmede P300 genliği ve ağ özellikleri gibi ortak özelliklerden çok daha iyi performans göstermiştir. Sonuçta, farklı beyin durumlarındaki (yani dinlenme ve çalışma) SPN özelliklerinin kombinasyonu, %90,48'lik bir doğruluk, %89,47'lik bir duyarlılık ve %91,30'luk bir özgüllük ile iki grubu güvenilir bir şekilde ayırt edebileceği gözlenmiştir.

Prasad ve ark. [39] belirli işlevler için uzmanlaşmış farklı beyin bölgelerinin göreve özgü topluluk aktivitelerini ölçmek için en etkili sinyal işleme araçlarından biri olan faz senkronizasyonunu ele alarak, Frobenius normuna dayanan bir kümenin tüm EEG kanal çiftleri boyunca, farklı sayıda kanala sahip kümeler arasında doğrudan bir karşılaştırma sağlayan 0-1 ölçeğinde bir topluluk senkronizasyon ölçüsü önerilmiştir. Bu metriği kullanarak, düşük gama bandında (30-40 Hz) intrahemisferik EEG senkronizasyonunu çalışılmıştır. 5 şizofreni hastası ve 5 sağlıklı kontrol deneğinden kaydedilen görsel-işitsel entegrasyon çapraz modal görevin (CMT) sınıflandırma denemeleri gerçekleştirilmiştir. Lojistik regresyon kullanılarak belirlenen özellikler ile EEG'nin şizofreni hastasına veya sağlıklı bir kontrol deneğine ait olduğu, %73 doğrulukla, alıcı işlem eğrisi altındaki alanla 0,83'lük bir başarımla sağlanmıştır.

Luo ve ark. [40], dinlenme durumundaki 128 kanallı EEG verileri; klinik olarak stabil olan ilk epizod şizofreni (FESZ) bireyler, ultra yüksek riskli (UHR), yüksek riskli bireyler ve sağlıklı bireyler dahil olmak üzere 65 katılımcıdan elde edilmiştir. Bu dört grubun davranışsal göstergelerden ve EEG mikro durumlarından çıkarılan birleşik özelliklerinin kullanıldığı hesaplamalar yapılmıştır. Sonuç olarak Destek vektör makinesi (SVM) ve uzun kısa süreli bellek (LSTM) ağları ile karşılaştırıldığında rastgele orman modeli kullanılarak en yüksek sınıflandırma performansının elde edilmesi, ortalama %92 sınıflandırma, ortalama %91,8 hassasiyet ve %90,8 özgüllük ile sadece davranışsal özellikleri kullananlardan çok daha yüksek sonuçlar elde edilmiştir.

Phang ve ark. [41], nöropsikiyatri hastalarının otomatik ayırt edici analizi için beyin fonksiyonel bağlantısındaki değiştirilmiş kalıplardan yararlanılarak şizofrenide EEG kaynaklı beyin sinirsel bağlantı ağının sınıflandırılması için derin bir konvolüsyonel sinir ağı (CNN) çerçevesi geliştirmeyi amaçlamışlardır. Etkili bağlantı ve karmaşıklığın zaman ve frekans alanı ölçümleri de dâhil olmak üzere sınıflandırma amacıyla farklı alanlara ve boyutsallığa ait çoklu beyin bağlantı tanımlayıcılarından gelen tamamlayıcı bilgileri etkili bir şekilde birleştirebilen çok alanlı bağlantı verileri için tasarlanmış yeni bir CNN mimarisi olan paralel bir 1D ve 2D CNN topluluğuna dayanan yeni birçok alanlı bağlantı CNN (MDC-CNN) tasarlanmıştır. Dinlenme durumu EEG veri kümesi üzerindeki sonuçlar, önerilen CNN'lerin geleneksel SVM sınıflandırıcısından kayda değer bir farkla daha iyi performans elde ettiğini belirlemiştir. Entegre edilmiş bağlantı özelliklerine sahip MDC-CNN, bireysel özellikleri kullanan tek alanlı CNN'lere oranla performansını daha da iyileştirerek, karar düzeyinde bir füzyonla %91,69'luk yüksek bir doğruluk oranına ulaşmıştır.

Naira ve Alamo [42], çalışmalarında EEG sinyallerinin sağladığı bilgiler ve Derin Öğrenme yöntemleri kullanılarak EEG sinyalleri aracılığıyla şizofreni hastaları ve sağlıklı insanların sınıflandırılması için bir model önermişlerdir. Bir EEG'nin yüksek boyutlu ve çok kanallı özelliklerini dikkate alarak, bir EEG'nin sağladığı büyük miktarda veriyi kullanmak

yerine, kanallar arasındaki ilişkileri temsil etmek için Pearson korelasyon katsayısını (PCC) uygulayarak konvolüsyonel sinir ağına (CNN) giriş olarak daha kısa bir matris sağlanmıştır. Önerilen EEG tabanlı sınıflandırma modelinde sırasıyla %90 doğruluk, %90 özgüllük ve %90 duyarlılığa ulaşıldığı belirlenmiştir.

Chu ve ark. [43], tarafından uzay-zamansal dinlenme durumu EEG verilerine dayalı bireysel tanıma şemaları önerilmiştir. Sınıflandırma yapmak için bir kişinin benzersiz özelliklerini otomatik olarak çıkarmayı amaçlayan değiştirilmiş derin öğrenme mimarileri geliştirmeyi amaçlamışlardır. Tasarlanan derin öğrenme modelinde, softmax katmanını Rastgele Orman algoritması (RF) ile değiştirmenin kayda değer bir avantajı olduğunu belirlemişlerdir. Ayrıca, EEG akışlarından kaynaklanan sınıflandırma sorununu çözmek için tasarlanan sinir ağlarının üstüne bir oylama katmanı eklenmiştir. Son olarak, önerilen EEG tabanlı bireysel tanıma şemasının; yüksek riskli bireylerdeki özellikler için %81,6, klinik olarak stabil ilk atak şizofreni hastaları için %96,7 ve sağlıklı kontroller için %99,2 sınıflandırma doğruluğu sağladığını saptamışlardır.

Sui ve ark. [44] şizofreni hastaları için geçerli olan anormallikleri ve ayrıca çoklu tedavi yöntemleri ya da cihazları arasındaki değişkenliği aydınlatmak için dinlenme durumu işlevsel manyetik rezonans görüntüleme (fMRI), EEG ve sMRI verilerini birleştirmek için çok setli kanonik korelasyon analizi (MCCA) uygulanması amaçlanmıştır. Her birinde en az iki değişken bulunan, iki değişken seti arasındaki ilişkilerin incelenmesinde kullanılan bir analiz tekniği olan kanonik korelasyon analizinin çok setli hali olan MCCA'nın, özellikle multimodal füzyonda etkili bir özellik seçme tekniği olduğu gösterilmiştir. MCCA, iki örnek t-testi ve özyinelemeli özellik eliminasyonlu destek vektör makinesini (SVM-RFE) özellik seçme yöntemlerinin avantajlarından yararlanarak her modalite için en uygun özellikleri belirlemek için bir topluluk özellik seçim stratejisi belirlenmiştir. 7 modalite kombinasyonu aracılığıyla yukarıda seçilen özelliklere dayalı olarak iki grup arasındaki sınıflandırma gücünü karşılaştırılmış ve fMRI-sMRI-EEG kombinasyonunun, eğitimde en iyi sınıflandırma doğruluğu %91 olarak elde edilmiştir. Sonuç olarak, Şizofreniyi sınıflandırmada multimodal füzyonun etkinliğini ve avantajlarının bulunduğu gözlemlenmiştir.

Thilakvathi ve ark. [45] dinlenme ve zihinsel aktivite gibi çeşitli durumlarda, EEG sinyal karmaşıklığını göz önünde bulundurarak şizofreniyi normal deneklerle karşılaştırmalı olarak saptamak için EEG'yi araç olarak kullanmayı amaçlamışlardır. EEG verileri 55 şizofrenik ve 23 normal olmak üzere 78 katılımcıdan gözler kapalı, istirahat halinde ve uygulanan uyaranlar sırasında kaydedilerek alınmıştır. EEG kayıtlarının Shannon entropisi, Spektral entropisi, Bilgi entropisi, Higuchi'nin Fraktal Boyutu, Kolmogorov karmaşıklığı ve Yaklaşık Entropileri özellikler olarak ele alınarak, dinlenme durumunda ve zihinsel aktivite için uyaranın uygulanması sırasında olmak üzere iki açıdan incelenmiştir. Zihinsel aktivite sırasındaki EEG sinyal

karmaşıklığının şizofreni hastalarını tanımlamak için kullanılabileceği, en yüksek sınıflandırma doğruluğunu %88,5 ile Kolmogorov karmaşıklığı ve Yaklaşık Entropisi uyarılarının özellikleri birlikte değerlendirildiğinde elde edilerek gözlemlenmiştir.

Boostani ve ark. [46] 13 şizofreni hastası ve aynı yaştaki 18 kontrol katılımcıdan 22 kanal üzerinden alınan EEG sinyalleri, iki grubu sınıflandırmak amacıyla analiz edilmiştir. Alınan sinyallerden otoregresif (AR) model parametreleri, bant gücü ve fraktal boyut vb. çeşitli özellikler çıkarılmıştır. Çıkarılan öznitelikler üzerinde uygulanan etkili bir sınıflandırıcı olarak seçilmiştir. Öznitelikler belirlendikten sonra standart LDA, Adaboost, destek vektör makinesi (SVM), bulanık SVM (FSVM) ve Doğrudan Doğrusal Ayrım Analizinin (BDDDA) artırılmış versiyonu gibi çeşitli sınıflandırıcılar uygulanmıştır. En iyi sınıflandırma sonucu BDLDA ile elde edilmiştir. BDLDA, LDA, Adaboost için sınıflandırma oranları sırasıyla %87,51, %85,36 ve %85,41 olarak bulunmuştur. %50'den daha düşük doğruluk değerleri elde eden SVM ve FSVM sınıflandırıcıları bu uygulama için kayda değer bir başarı sağlayamamıştır.

Son olarak Piryatinska ve ark. [47] önerilen yaklaşımla çok kanallı EEG kayıtlarının ikili sınıflandırmasını sağlayan düşük boyutlu bir öznitelik uzayı oluşturmak amaçlanmıştır. İlk olarak vektör fonksiyonları durumuna kadar genişletilen sürekli fonksiyonların yani sinyallerin ϵ -karmaşıklık katsayıları kullanılarak özellikler belirlenmiştir. Daha sonra, rastgele orman (RF) veya destek vektör makinesi (SVM) sınıflandırıcılarını bir grup 39 kişi sağlıklı ergen ve diğer grup 45 kişi şizofren ergenden oluşan katılımcıların çok kanallı EEG kayıtlarının sınıflandırılması için uygulamışlardır. Rastgele orman sınıflandırıcısı %85,3 gibi yüksek bir doğruluk oranı ile üstün bir sonuç sağlamıştır. 10 katlı çapraz doğrulama kullanan RF bir test setinde ortalama %84,5'lik bir doğruluk oranı üretirken, SVM %81,07'lik bir doğrulukla başarı sağlamıştır. Sonuç olarak rastgele orman sınıflandırıcısının bu veri seti için destek vektör makinesinden daha iyi performans gösterdiği tespit edilmiştir.

Değinen çalışmaların isimleri, katılımcı sayıları, özellik çıkarma teknikleri, kullanılan sınıflandırma algoritmaları ve doğruluk oranlarının özeti Tablo 2.1'de yapılmıştır.

Tablo 2.1. Literatürde Bulunan İlgili Çalışmalar

Çalışma	Katılımcı Sayısı	Özellik Çıkarma	Sınıflandırıcı	Doğruluk
Kim ve ark.[20]	Sz:90 N:90	FFT	ROC	%62,2
Dvey-Aharon ve ark.[21]	Sz:25 N:25	TFFO Stockwell dönüşümü		% 92- %93,9
Ibanez-Molina ve ark.[22]	Sz:18 N:17	LZC MLZC	MLP	
Johannnesen ve ark.[23]	Sz:40 N:12	teta 1 ve 2, alfa,beta ve gama frekans bantları	SVM	%87
Santos-Mayo ve ark.[24]	Sz:16 N:31	ERP J5	MLP SVM	%93,42 %92,23
Shalhaf ve ark [26]	Sz:14 N: 14	CWT	ResNet-18	% 98.60 $\pm$ 2.29
Ahmedt-Aristazabal ve ark.[27]	Sz:65 N: 40; Sz:65 N:45; Sz:65 N:57	Ham EEG Verileri	CNN-LSTM	%69,80
Oh ve ark.[28]	Sz:14 N:14	Z-Skor Normalizasyon	11 katmanlı CNN	Konu bazlı olmayan testler: % 98,07 Konu bazlı testler: % 81,26
Shoeibi ve ark.[29]	Sz:14 N:14	L2 Normalizasyon Z-Skor	CNN-LSTM	% 99,25
Sun ve ark. [30]	Sz:54 N:55	FuzzyEn FFT	DNN	FuzzyEn %99,22 FFT % 96,36
Singh ve ark.[31]	Sz:45 N:39	Filtreleme	CNN-LSTM	İki farklı veri kümesi için %94,08 ve %98,56
Siuly ve ark. [32]	Sz:49 N:32	İstatiksel Özellikler, KW Testi	EBT	%89,59
Jamnuah ve ark. [33]	Sz:14 N:14	Doğrusal olmayan özellikler ve t-testi	SVM-RBF	%92,90
Devia ve ark. [34]	Sz:11 N:9	ERP	LDA	%71
Prabhakar ve ark. [35]	Sz:14 N:14		AdaBoost	%98,77
Alimardani ve ark. [36]	Sz:23 N:23	SSVEP Fisher Skoru	KNN	%91,30
Shim ve ark. [37]	Sz:34 N:34	Sensör-seviyesi ve kaynak-seviyesi özellikler	SVM	%88,24
Li ve ark. [38]	Sz:19 N:23	SPN Özellikleri	SVM	%90,48

Tablo 2.1. (Devamı) Literatürde Bulunan İlgili Çalışmalar

Prasad ve ark. [39]	Sz:5 N:5		Lojistik regresyon	%73
Luo ve ark. [40]	Farklı sayı setleri		RF	%92
Phang ve ark. [41]	Sz:45 N:39		MDC-CNN	%93,06
Naira ve Alamo [42]	Sz:45 N:39	PCC	CNN	%90
Chu ve ark. [43]	Sz:40 N:40		CNN RF	%99,20
Sui ve ark. [44]	Sz:48 N:53	MCCA	SVM	%74,0
Thilaktavi ve ark. [45]	Sz:55 N:23	Shannon Entropi, Spektral Entropi, Bilgi Entropisi, Kolmogrov Karmaşıklığı ve Yaklaşık Entropi	SVM	%88,50
Boostani ve ark. [46]	Sz:13 N:13		LDA	%87,50
Piryatinska ve ark. [47]	Sz:45 N:39	€-Karmaşıklık Katsayıları	RF	%83,60

Sz: Şizofren Katılımcı Sayısı, N: Normal Katılımcı Sayısı

3. MATERYAL VE METOT


Bu bölümde tezin amacına uygun gerçekleştirilen uygulamalı analizlerde kullanılan veri kümesi hakkında detaylı bilgiler yer almaktadır. Ayrıca bu bölümde, deneysel analizlerde kullanılan teknikler, yöntemler ve önerilen modellerin katmanları ile genel mimari yapıları hakkında da detaylı bilgilere yer verilmiştir.

3.1. Veri Seti

Bu tez kapsamında Moskova Devlet Üniversitesi bünyesinde yer alan Nörofizyoloji ve Nöro-Bilgisayar Arayüzleri (NNCI) Laboratuvarından alınan veri seti kullanılmıştır [48]. İki sınıftan oluşan mevcut veri setinin denekleri 10-14 yaş arası ergenlerdir. İlk grup, 11-14 yaşları arasında şizofren 45 erkek çocuktan oluşmaktadır. İkinci grup, 10-13 yaşları arasında 39 sağlıklı erkek çocuğu içerir. EEG sinyalleri gözleri kapalı, uyanık ve gevşemiş durumdaki 39 sağlıklı ve 45 şizofreni semptomları olan ergenlerin kafa derisindeki 16 kanal üzerinden alınmıştır. Veri setinde yer alan her bir vakaya ait txt dosyası, 16 EEG kanalından (elektrot konumları) alınan EEG örnekleri içeren bir sütundan oluşmaktadır. Sütundaki her sayı, farklı örnekte mV cinsinden bir EEG genliğidir.


İlk 7680 örnek birinci kanalı, sonraki 7680 örnek ikinci kanalı vb. temsil etmektedir. Sinyallerin örnekleme hızı 128 Hz'dir ve her 7680 örnek 1 dakikalık EEG kaydına karşılık gelmektedir. Kanal numaralarının topografik konumları Şekil 3.1'de gösterilmiştir.

1	F7
2	F3
3	F4
4	F8
5	T3
6	C3
7	Cz
8	C4
9	T4
10	T5
11	P3
12	Pz
13	P4
14	T6
15	O1
16	O2




Şekil 3.1. 16 Kanallı EEG Elektrotları [48]

Günümüzde EEG kayıtları alınırken kafa derisi üzerine yerleştirilen elektrotların yerlerinin belirlenmesinde uygulanan standart bir 10-20 elektrot düzenlemesi kullanılmaktadır. Kaydedilen bu EEG sinyalleri hem zaman alanında hem de frekans alanında bileşenlere bölünerek analiz edildiğinde, EEG sinyallerinin anlamlı veriler sağladığı çalışmalarla keşfedilmiştir. Bu 16 kanalın dizilimi bu sisteme göre yapılmıştır: 'F7', 'F3', 'F4', 'F8', 'T3', 'C3', 'Cz', 'C4', 'T4', 'T5', 'P3', 'Pz', 'P4', 'T6', 'O1', 'O2'. Bu sistem beyindeki sinyaller alınırken elektrotların kafa derisine yerleştirilmesi gereken yerleri belirtir. Böylece dünya genelinde ortak bir sistemle veriler kaydedilir. Kanallara verilen harflendirmelerde beynin yapısına göre (frontal lob, center vb.) yapılır. Bu harflendirmeler üzerinden yapılan 16 kanal ve sinyal değişimleri Şekil 3.2 ve Şekil 3.3'te sağlıklı ve şizofren bireyler için verilmiştir.



Şekil 3.2. Sağlıklı Bireyin 16 Kanallı EEG Değişimi



Şekil 3.3. Şizofren Bireyin 16 Kanallı EEG Değişimi

3.2. Metot

Şizofreni, hasta ailelerine ve topluma büyük yükler getiren kronik ruhsal bir hastalıktır. Şizofreni tanısı bir uzman ile görüşmeye ve klinik semptomlara dayanılarak konulmaktadır. Şizofreninin erken ve doğru teşhisi, tedavinin planlanmasını kolaylaştırır böylece hastalığın tedavi sürecini iyileştirebilir. Klasik görüşme ve klinik semptomlar hataya yapmaya açık ve zaman alıcı olduğundan bunun yerine EEG sinyallerinden otomatik tespitler gerçekleştiren sistemler geliştirilmelidir. Yapay zekanın yönettiği günümüzde bu teşhis sürecin hızlı ve kolay bir şekilde sağlanabilmesi için etkin bilgisayar sistemlerinin devreye girmesi için etkin çözümler sunan Derin öğrenme mimarilerinin kullanımı işe yarar sistemler geliştirilmesine katkı sunabilmektedir. Bu nedenle Şizofreni gibi ağır bir ruhsal bozukluğun tespiti için temel alınan Derin öğrenme yaklaşımlarından bahsedilmiştir. Ayrıca farklı geri beslemeli bir sinir ağ çeşidi olan LSTM ağı ile de sınıflandırmalar gerçekleştirilmiştir.

Bu tez çalışmasında sinyali görüntüye çevirerek görüntü üzerinden sınıflandırmalar gerçekleştiren makine öğrenmesi ve derin öğrenmenin bütünleşmesiyle oluşan hibrit modeller ve ham veriyi ele alarak sınıflandıran LSTM ağı kullanılmıştır. Uygulamaları gerçekleştirirken ele alınan bu yöntemlere aşağıda sırasıyla yer verilmiştir.

3.2.1. Derin Öğrenme Mimarileri

Derin öğrenme, beynin yapısından ve işlevinden ilham alan algoritmalarla ilgilenen makine öğreniminin bir alt dalıdır. Derin öğrenmenin yapısı insan gibi düşünen ve karar veren yapılar oluşturmayı amaçlar. Bu amaç doğrultusunda sadece sayısal verileri işlemekle kalmaz aynı zamanda piksel, metin, ses, vb. verileri de kullanabilmektedir. Derin öğrenme yaklaşımları, köklerini sinir ağlarından almış olup ağı derin olarak ifade edilmesi ise birbirinin üzerine yığılan birçok katmandan oluşmasından kaynaklanmaktadır. Bir derin öğrenme mimarisi, her biri verinin en kapsamlı özelliklerini belirlemesi ve ortaya çıkarması beklenen birçok katmandan meydana gelmektedir. Derin öğrenme yöntemleri, sınıflandırma görevleri, doğal dil işleme, görüntü işleme, konuşma tanıma vb. konularında kullanılmaya uygundur ve bunlar sığ mimarilere kıyasla çok daha güçlüdürler [49].

Derin öğrenme algoritmalarını oluşturan her bir katman, bir önceki katmandan aldığı verileri dönüştürür. Derin öğrenme algoritmasındaki ilk katman, tipik olarak verileri alan bir giriş katmanıdır. Son katman tipik olarak nihai sonucu üreten bir çıktı katmanıdır. Girdi ve çıktı katmanları arasında bir dizi gizli katman bulunur. Gizli katmanlar, verilerden özellikleri çıkarır ve çıktı katmanının istenen sonucu üretmesini kolaylaştıracak şekilde dönüştürür. Gizli katman sayısı ve her katmandaki nöron sayısı çözülmekte olan probleme göre yapılması gereken bir tasarım seçimidir. Tasarlayıcı, problemin gereksinimine bağlı olarak katman sayısı değiştirebilmektedir.

Son yıllardaki çalışmalarda biyolojik ve devre karmaşıklığına sahip olan yapılardaki derin öğrenme kullanımının, özellikle problemin oldukça karmaşık matematiksel fonksiyonları çözümlemede geleneksel mimarilere göre daha iyi sonuçlar verdiği görülmüştür. Derin öğrenme temel olarak ele alındığında bir yapay sinir ağıdır. 1970'lerde ortaya çıkan yapay sinir ağları ilk ortaya çıktığında sadece birkaç katmandan oluşmaktaydı. Günümüzde ise bu katman sayısı gittikçe artmaktadır. Bununla birlikte yakın zamana kadar YSA eğitmenin çok zor olduğuna inanılıyordu. Bunun başlıca sebebi donanımsal eksiklikler olarak görülmüştür. Teknolojik gelişmeler sayesinde bu eksiklikler giderilmiş ve katman sayısı artırılarak derin ağ yapıları oluşturulmaya başlanmıştır. Günümüzde önemli ölçüde artan çip işleme yetenekleri (örneğin GPU birimleri), kayda değer düşük bilgi işlem donanımı maliyeti ve makine öğrenimi

algoritmalarında ki önemli gelişmeler derin öğrenmenin çığır aşmasının başlıca üç önemli sebebidir [50].

Derin öğrenme teknolojisinin esası, katmanlarının mühendisler tarafından tasarlanması ve bunun yerine genel amaçlı bir öğrenme prosedürü kullanılarak verilerin özelliklerinin otomatik bir şekilde öğrenilmesidir. Derin öğrenme temel olarak verinin temsilinden öğrenmeye dayalıdır. Bir görüntü için temsil; piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi özellikler ifade etmektedir. Bu özelliklerin içinden bazıları veriyi daha iyi temsil etmektedir. Bu aşamada yine bir avantaj olarak, derin öğrenme yöntemleri, manuel olarak elde edilen özellikler yerine veriyi en iyi temsil eden hiyerarşik özellik çıkarımında etkili algoritmalar kullanmaktadır [51].


Derin öğrenme, özellikle CNN, görüntü analizi ve uygulamaları için onaylanmış bir görüntü temsili ve sınıflandırma tekniğidir [52]. Derin öğrenme mimarisinin temeli olan CNN, daha fazla tam bağlı katman tarafından takip edilen bir veya daha fazla konvolüsyon katmanından oluşan bir tür ileri beslemeli yapay sinir ağıdır. Konvolüsyon katmanı, bir CNN'nin temel yapı taşıdır. CNN, görüntü sınıflandırma, nesne algılama ve görüntü tespiti sistemlerinde ileri uygulamalara sahiptir. CNN, doğal dil işleme, nesne sınıflandırma ve görüntü bölütleme gibi çoklu uygulamalarda büyük başarılar elde etmiştir [53]. CNN, çeşitli bilgisayar görme problemlerinde en gelişmiş sonuçları sağlar. CNN, küçük bir örneklem boyutu problemi için sınırlayıcı faktör haline gelen çok sayıda eğitim örneği gerektiren çok sayıda parametreye sahiptir [54]. Bu nedenle, son zamanlarda derin öğrenme, tıbbi görüntüleri çoğunlukla CNN ile işlemek, analiz etmek ve değerlendirmek için bir yöntemler bütünü olarak sıklıkla kullanılmaktadır [55].

CNN yapısının yaygın olarak kullanılan konfigürasyonuna ek olarak, daha derin ağları ortaya çıkaran yaklaşımlar da vardır. Zamanla katman sayılarında farklılıklar ya da katmanlarda bulunan işlem özellikleri değiştirilerek CNN tabanlı birçok mimari geliştirilmiştir. Bu derin katmanlı mimariler arasında günümüzde popülerliğini koruyan AlexNet, GoogleNet ve VGG16 derin mimarileri ele alınmıştır. Katman sayılarının değişimine örnek olarak AlexNet'e göre, VGG daha fazla konvolüsyon katmanı ekleyerek ve tüm katmanlarda çok küçük konvolüsyon filtrelerinden yararlanarak ağı derinliğini artırmıştır [56]. Benzer şekilde, Szegedy ve ark. [57], oldukça derin bir yapıya (22 katman) sahip olan ve ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nı (ILSVRC 2014) yarışmasında [58] lider performans elde eden GoogleNet adlı bir model önermişlerdir.

AlexNet: 2012 yılında AlexNet'i tasarlayan Krizhevsky [55] ILSVRC 2012 yarışmasını önemli bir farkla kazanmıştır. ILSVRC, büyük ölçekli nesne algılama ve görüntü sınıflandırma algoritmaları için her yıl düzenlenen bir yarışmadır. ImageNet, her bir düğümünün yüzlerce ve binlerce görüntüyle gösterildiği WordNet hiyerarşisine göre düzenlenmiş bir görüntü veri

tabanıdır. ILSVRC, bilgisayarla görme ve derin öğrenme araştırmalarının ilerlemesinde katkılar sağlamıştır. ImageNet veri tabanında bulunan veriler, ticari olmayan kullanım için araştırmacılara ücretsiz olarak sunulmaktadır. Bu veri tabanı üzerinden sağlanan verilerin standart karakteristik özellikleri ve sınıflandırıcı eğitim yöntemlerini kullanan diğer araştırmacıların aksine, Krizhevsky özellikle konvolüsyonel sinir ağlarını kullanarak 2012’de düzenlenen ILSVRC yarışmasını önemli bir farkla kazanmıştır. AlexNet mimarisi, 3 tam bağlantılı katman ve 5 konvolüsyon katmanından oluşmaktadır. AlexNet’in ilk katmanı, sırasıyla genişlik, yükseklik ve derinlik (kırmızı, yeşil, mavi- RGB) için $227 \times 227 \times 3$ boyutunda filtrelenmiş bir görüntünün girişi için kullanılmaktadır. Son tam bağlı katman, 1000 bağlı katmanı birbirine bağlamakta ve katmanların geri kalanı bir özellik çıkarıcı olarak çalışmaktadır. AlexNet, her girdi görüntüsü için çıktı katmanından hemen önce gizli katman aktivasyonlarını içeren 4096 boyutlu bir özellik vektörü üretmektedir. AlexNet ’in kendisi 650.000 nöron ve 60 milyon parametre içeren devasa bir yapıya sahiptir. Bu mimari yaklaşık 1,2 milyon ImageNet eğitim verisi üzerinde eğitilmiş ve 150.000 ImageNet test verisi üzerinde test edilmiştir. Bu model, seyreltme ve veri artırmayı sürdürmenin yardımıyla fazla uyum (overfitting) sorununu azaltmak için çok etkilidir. AlexNet, en çok araştırılan CNN olduğu ve hız ile başarımları arasında doğru bir orantı bulunduğu için bu çalışmada kullanılmıştır.

Şekil 3.4’te verilen AlexNet mimarisi, öğrenme özellikleri için 5 konvolüsyon katmanının yanı sıra 2 tam bağlantılı katman içermektedir. Bu mimari, birinci, ikinci ve beşinci konvolüsyon katmanından sonra maksimum havuzlama işlemlerine ve toplamda 650K nörona, 60M parametreye ve 630M bağlantıya sahiptir [59].



Şekil 3.4. AlexNet Mimarisi

Çok katmanlı bir yapıya sahip olan derin öğrenme konvolüsyonel sinir ağında her bir katmanda ayrı bir işlem yürütülerek bir sonraki katmana veriler aktarılmaktadır. Konvolüsyon

işlemleriyle bir görüntüde yer alan kenarlar, kıvrımlar ve baskın noktalar gibi belirgin özellikler çıkarılarak sonraki katmanlara bu özellikler aktarılmaktadır. Derin öğrenme mimarilerinin temeli olan CNN ağında yer alan katmanlar ve bu katmanların yapmış olduğu işlemler şunlardır.

a. Giriş (İnput) Katmanı


CNN'nin ilk katmanını oluşturmaktadır. Bu katmanda veri işlenmemiş yani ham olarak ağına verilmektedir. Tasarlanacak modelin başarısı açısından bu katmandaki verinin boyutu önem arz etmektedir. Giriş görüntü boyutunun yüksek seçilmesi hem yüksek bellek ihtiyacını hem eğitim süresini hem de görüntü başına düşen test süresini uzatabilmekte ve bunun yanında ağına başarısını da arttırabilmektedir. Giriş görüntü boyutunun düşük seçilmesi bellek ihtiyacını azaltmak ve eğitim süresini kısaltmak ile birlikte kurulacak ağına derinliğini azaltıp, performansını düşürebilmektedir. CNN ağında kullanılan giriş görüntülerinin analizinde hem ağına derinliği hem donanımsal hesaplama maliyeti hem de ağına başarısı açısından uygun bir giriş görüntü boyutu seçilmelidir.

b. Konvolüsyon (Evrişim) Katmanı

Görüntünün belirli özelliklerini çıkarabilmek için orijinal görüntünün boyutlarından daha küçük bir filtre (kernel) görüntünün üzerinde satır ve sütunlar boyunca dolaştırılır. Aşağıda verildiği gibi filtrenin ve gerçek verinin değerleri konvolüsyon işlemine tabi tutularak filtreleme işlemi sonrasında görüntünün özellik haritası (feature map) çıkarılmaktadır.


Konvolüsyon katmanında, giriş verileri üzerinde dolaştırılacak bir dizi filtre kullanılmaktadır. Yapılacak uygulamaya bağlı olarak kullanılacak filtrelerin içerikleri, büyüklükleri ve sayısı da değişmektedir. Uygulamada kullanılacak olan filtrelerin boyutu, kullanılan verinin boyutundan küçük olmak zorundadır. Veri üzerinde yatay ve dikey olarak dolaştırılan filtreler, bulunduğu yerdeki veri değerleri ile çarpılarak yeni veri seti elde edilmektedir. Bu şekilde, seçilen filtreler tüm veri üzerinde dolaştırılmaktadır.

Ağına verilen giriş verisi üzerinde dolaştırılacak olan filtre, ağına başarısını doğrudan etkilemektedir. Örneğin ağına üzerinde dolaştırılan filtre çok büyük boyutlu ve büyük sayılabilecek rakamlardan oluşuyorsa, ağına eğitim süresi çok uzun sürebilir, hatta tercih edilen filtreye göre hata ile karşılaşma durumu da söz konusu olabilmektedir [60].



Şekil 3.5. Konvolüsyon İşlemi I


Şekil 3.5'te verilen konvolüsyon işleminde filtre boyutu 3×3 boyutunda olduğundan, giriş verisi üzerinde 3×3 boyutunda matrisler üzerinde dolaştırılarak konvolüsyon işlemi gerçekleştirilip verinin özellik haritası oluşturulur.



Şekil 3.6. I. Adımın Matematiksel Gösterimi

Şekil 3.6'da verilen işlem şu şekilde gerçekleşir:

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



Şekil 3.7. Konvolüsyon İşlemi II

Şekil 3.7’de gösterildiği gibi filtreyi dolaştırırken çıktı matrisinin ilk değeri bulunduktan sonra giriş matrisinde kayma adımı özellikle belirtilmediği takdirde 1 kaydırma yapılır ve çıktı değerinin 2.değeri hesaplanır.

The diagram illustrates the convolution operation. On the left is a 3x3 input matrix (green) with values:

$$\begin{bmatrix} 2 & 3 & 3 \\ 5 & 3 & 8 \\ 3 & 2 & 8 \end{bmatrix}$$
 In the middle is a 3x3 kernel matrix (orange) with values:

$$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$$
 An asterisk (*) indicates the convolution operation. To the right of the asterisk is an equals sign (=) followed by a single green square containing the value -9, representing the result of the operation at the current position.

Şekil 3.8. II. Adımın Matematiksel Gösterimi

Şekil 3.8’de verilen işlem şu şekilde gerçekleşir:

$$(2 \ 1) + (3 \ 0) + (3 \ -1) + (5 \ 1) + (3 \ 0) + (8 \ -1) + (3 \ 1) + (2 \ 0) + (8 \ -1) = -9$$

Konvolüsyon işlemi bu şekilde çıktı matrisinin tüm değerleri bulununcaya kadar devam eder.






c. Aktivasyon Fonksiyonları

Derin öğrenme, çoğunlukla doğrusal olmayan problemlerin çözümünde kullanılmaktadır. Bunun sebebi, derin öğrenmenin bilinen diğer yöntemlere oranla doğrusal olmayan problemlerde daha başarılı olmasıdır. Konvolüsyon katmanındaki matris çarpımı sonrasında elde edilen değerler doğrusaldır. Değerlerin doğrusal olmayan hale dönüştürülmesi için aktivasyon fonksiyonları kullanılmaktadır [61].

Aktivasyon fonksiyonları, bir sinir ağının çıktısının aralığına karar veren matematiksel denklemlerdir. Bu matematiksel işlem, ağ içindeki her bir nörona bağlıdır ve her bir nöronun girdisinin modelin mimarisi için uygun olup olmadığına bağlı olarak, etkinleştirilip etkinleştirilmeyeceğine karar vermektedir. Her nöron için girdi, nörondaki ağırlıklarla çarpıldıktan sonra toplanarak sonuca aktarılır. Aktivasyon fonksiyonunun seçimi, modelin yapabileceği tahminlerin çeşidini belirler. Dolayısıyla bu katmanlarda kullanılacak olan fonksiyon, tahmin probleminin tipine bağlı olarak seçilir [62].

Aktivasyon fonksiyonlarından en yaygın kullanılan fonksiyon çeşitleri Tablo 3.1’de verilmiştir. Bu fonksiyonlardan DL mimarilerinde genellikle ReLU aktivasyon fonksiyonu kullanılmaktadır.

Tablo 3.1. Aktivasyon Fonksiyonları

İsim	Denklem	Grafik
Basamak (Step) Fonksiyonu	$f(x) = \begin{cases} -1 & x < 0 \\ 0 & x = 0 \\ 1 & x > 0 \end{cases}$	
Doğrusal (Linear) Fonksiyon	$f(x) = x$	
Sigmoid Fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
ReLU	$f(x) = \max(0, x)$	

d. ReLU Aktivasyon Fonksiyonu


AlexNet, daha önce ortaya çıkan bir derin öğrenme mimarisi olan LeNet'ten farklı olarak sigmoid aktivasyon fonksiyonu yerine daha basit bir aktivasyon fonksiyonu olan ReLU aktivasyon fonksiyonunu kullanmıştır. ReLU aktivasyon fonksiyonunun hesaplanması sigmoid fonksiyonunun hesaplanmasından daha basittir. Çünkü ReLU sigmoid aktivasyon fonksiyonunda bulunan üs alma işlemine sahip değildir. Öte yandan, ReLU aktivasyon fonksiyonu, farklı parametre başlatma yöntemlerini kullanırken model eğitimi kolaylaştırmaktadır. Bunun nedeni, sigmoid aktivasyon fonksiyonunun çıktısı 0 veya 1'e çok yakın olduğunda, bu bölgelerin gradyanının neredeyse 0 olmasıdır. Böylece geri yayılım bazı model parametrelerini güncellemeye devam edemez. Buna karşılık, pozitif aralıktaki ReLU aktivasyon fonksiyonunun

gradyanı her zaman 1'dir. Bu nedenle, model parametreleri uygun şekilde başlatılmazsa, sigmoid fonksiyonu pozitif aralıkta neredeyse 0'lık bir gradyan elde edebilir, böylece model etkili bir şekilde eğitilemez.

ReLU modeli denklem 3.1 ile ifade edilen bir fonksiyon olarak tanımlanmaktadır:

$$f(x) = \max(0, x) \quad (3.1)$$

Denklem 1'e göre x pozitif olduğunda çıktının girdiye eşit olduğu x sayısı ve diğer değerler için 0 değerini almaktadır [63]. ReLU işlevi grafiksel olarak Şekil 3.9'daki gibi temsil edilmektedir.




Şekil 3.9. ReLU Aktivasyon Fonksiyonu


Aktivasyon fonksiyonu uygulanmadığında, çıkış sinyali basit bir doğrusal fonksiyon olur. Doğrusal fonksiyonlar yalnızca tek dereceli polinomlar gibi çalışır. Aktivasyon fonksiyonu kullanılmayan bir sinir ağı sınırlı öğrenme gücüne sahip bir doğrusal bağlantı (lineer regresyon) gibi davranacaktır. Ama bir sinir ağının doğrusal olmayan durumları da öğrenmesi istenir. Çünkü sinir ağının öğrenmesi için görüntü, video, yazı ve ses gibi karmaşık gerçek dünya bilgileri de verilebilir bu sayede çok katmanlı derin sinir ağları bu sayede verilerden anlamlı özellikleri çıkarabilmektedir.

e. Havuzlama (Pooling) Katmanı

Havuzlama katmanı boyutsallığı azaltmak amacıyla gerçekleştirilmektedir. Bu sayede hem gereken işlem gücü azalır hem de yakalanan gereksiz özellikler yok sayılarak daha önemli özelliklere odaklanılmaktadır. Maksimum, minimum ve ortalama havuzlama türlerinden biri kullanılarak bu işlemler gerçekleşir. Şekil 3.10 ve Şekil 3.11'de gösterilen maksimum ve ortalama havuzlama türleri en çok kullanılan türlerdir.



Şekil 3.10. Maksimum Havuzlama İşlemi




Şekil 3.11. Ortalama Havuzlama İşlemi

Havuzlamanın ana fikri, çok fazla katman bulunduğundan karmaşıklığı azaltmak için alt örnekleme yapmaktır. Havuzlama işlemi, filtre sayısını etkilememektedir. Maksimum, ortalama ve minimum çeşitleri bulunan havuzlamanın en çok uygulanan maksimum havuzlama ve ortalama havuzlama için Boureau ve ark. [64] performanslarının ayrıntılı bir teorik analizini yapmışlardır. Scherer ve ark. [65] ayrıca iki havuzlama işlemi arasında bir karşılaştırma yaparak maksimum havuzlamanın daha hızlı yakınsamaya, üstün değişmez özellikleri seçmeye ve genellemeyi iyileştirmeye yol açabileceğini bulmuşlardır. Son yıllarda, çoğu maksimum havuzlama stratejisini kullanan CNN varyantlarının çeşitli hızlı GPU uygulamaları sunulmuştur [55,66]. Genellikle kullanılan maksimum havuzlama, havuzlama yöntemlerinin en yaygın türlerinden biridir. Burada görüntüyü en yaygın kullanılan 2x2 boyutlarında alt bölge dikdörtgenlerine bölerek yalnızca o alt bölgenin iç kısmının maksimum değerini döndürmektedir. Şekil 3.10 ve Şekil 3.11’de görüldüğü gibi sol üst 2x2 bloklarda havuzlama yapıldığında 2 adım hareket eder ve sağ üst kısma odaklanır. Bu, 2. adımın havuzda kullanıldığı anlamına gelir. Alt örneklemeden kaçınmak için, yaygın olmayan 1. adım kullanılabilir. Alt örneklemenin bilginin konumunu korumadığı dikkate alınmalıdır. Bu nedenle, yalnızca bilginin varlığının önemli olduğu durumlarda uygulanmalıdır. Ayrıca, verimliliği artırmak için havuzlama, eşit olmayan filtreler ve adımlar ile kullanılabilir. Örneğin, adım 2 ile 3x3 maksimum havuzlama, alanlar arasında bazı çakışmaları korur [67, 68, 69].

Bir havuzlama katmanı, öğrenilmesi gereken parametre sayısını azaltarak bir sinir ağının hesaplama maliyetini azaltmak için kullanılabilir. Ayrıca girdinin varyansını azaltarak bir sinir ağının performansını iyileştirebilir.

f. Dropout (Seyreltme) Katmanı


Derin öğrenme katmanlarında öğrenimi gerçekleştirilmiş bir ağda, aşırı öğrenmeyi (overfitting) yani ağdaki ezberlemeyi ortadan kaldırmak için kullanılan bir katmandır. Şekil 3.12’de görüldüğü gibi, bu katmanda yapılan işlemler sinir ağı içerisinde aşırı öğrenmeyi oluşturan bazı bağlantıları ortadan kaldırma işlemi yapmaktadır. Böylelikle ağı ezber yapması engellenmekte ve bu da ağın performansını artırmaktadır [70,71].



Şekil 3.12. Dropout İşlemi Uygulandıktan Sonra Ağı Değişimi

g. Tam Bağlantılı Katman (Fully Connected Layer)

Kendisinden önce gelen katmandaki verileri bu katmanda tek boyutlu bir matris şekline dönüştüren katmandır. Nöronlar bu katmanda tam bağlantılı olarak yer almaktadır. Her nöron kendinden sonra gelen nöronla bağlanmaktadır. Bu sebeple tam bağlantılı katman olarak bilinmektedir [72]. Şekil 3.13’te bu katmanın çalışma mantığı gözlemlenmektedir:




Şekil 3.13. Tam Bağlantılı Katman

h. Sınıflandırma (Softmax) Katmanı

Derin öğrenme mimarisinin son katmanıdır. Tam bağlantı katmanından gelen veriler değerlendirilerek ağın çıkışının oluşturulduğu katmandır.

GoogleNet: GoogleNet, 2014'te gerçekleştirilen ILSVRC yarışmasında Szegedy ve arkadaşları tarafından önerilen klasik bir derin öğrenme mimarisidir [73]. Bu mimari, birbiri üzerine yerleştirilmiş başlangıç modüllerinden oluşan 22 katmanlı derin konvolüsyonel bir sinir ağıdır. Her başlangıç modülü, sabit düzenleme sorunlarından uzak durmak için 1×1 , 3×3 ve 5×5 çekirdek boyutlarıyla sınırlandırılmıştır. Donanım ve maliyet hesaplamalarının öngörülemezliğini azaltmak için, maliyetli 3×3 ve 5×5 konvolüsyonel adımlarından önce boyutsallığı azaltmak için ilk önce 1×1 konvolüsyon işlemlerini kullanmaktadır [74].

GoogleNet mimarisinin temelini birçok konvolüsyon işlemini bir arada bulunduran başlangıç modülleri oluşturmaktadır. Bu başlangıç modüllerinin içeriği Şekil 3.14'te verilmiştir.




Şekil 3.14. GoogleNet Başlangıç Modülü

GoogleNet, bir görüntüdeki yakın pikseller arasındaki korelasyona dayanmaktadır. Başlangıç bloğu, 1×1 konvolüsyonları kullanarak kanallar arası korelasyonları gerçekleştirmektedir. Bu işlemleri, çapraz uzamsal ve kanallar arası korelasyonları gerçekleştirmek için 3×3 ve 5×5 filtreler takip etmektedir. GoogleNet'te çok seviyeli öznetelik çıkarımı, birden çok konvolüsyon filtresine sahip başlangıç modülü yardımıyla aynı giriş üzerinde yapılmaktadır. Bahsedilen öznetelik çıkarımı için 1×1 , 3×3 ve 5×5 konvolüsyonlarının sonuçları daha sonra birleştirilmektedir. GoogleNet, tam bağlantılı katmanlar yerine ortalama havuzlamayı kullanarak çok sayıda parametreyi ortadan kaldırmaktadır. Bu ağ sadece 4 milyon parametreye sahipken AlexNet 60 milyon parametreye sahiptir. Görüntülerin boyutunun yükseklik ve genişlik değerlerinin düşürülmesi özellik kaybına neden olsa da sinir ağının eğitilmesini hızlandırmaktadır.

VGGNet: Oxford Üniversitesi Görsel Geometri Grubu (VGG) tarafından icat edilen VGGNet, ILSVRC 2014'te ilk sırada yer almıştır. VGGNet'in yaygın olarak kullanılan iki varyasyonu vardır. Bunlar sırasıyla 16 ve 19 katman içeren VGG16 ve VGG19'dur. VGGNet, 3×3 'lük filtre yığınınından oluşmaktadır. Büyük filtreler yerine 3×3 filtre kullanımı parametre sayısını büyük ölçüde azaltmaktadır. Ağın giriş kanallarının doğrusal dönüşümünü sağlamak için 1 piksellik sabit bir konvolüsyon adımına sahip konfigürasyonlardan birinde 1×1 konvolüsyon filtreleri kullanılmaktadır. Konvolüsyon işlemleri gerçekleştirildikten sonra, çözünürlüğü korumak için dolgu (padding) işlemi gerekebilmektedir.

VGG16 derin öğrenme algoritması 13 konvolüsyon 3 tam bağlı katmandan oluşan bir sinir ağıdır. Ağın girdi katmanında yer alacak görüntü $224 \times 224 \times 3$ boyutunda olmalıdır. Havuzlama, tam bağlantılı, ReLU, seyreltme ve sınıflandırma katmanlarıyla birlikte toplamda 41 katman yer almaktadır. Bu ağ, ImageNet veri tabanında %89 doğruluk başarımlarını yakalamış bir derin

öğrenme algoritmasıdır [75,76]. Şekil 3.15'te VGG16 derin öğrenme mimarisi örneği yer almaktadır.



Şekil 3.15. VGG16 Mimarisi

3.2.2. Makine Öğrenmesi Algoritmaları


Bu çalışma kapsamında derin öğrenmede özellikleri otomatik olarak çıkarılan verilerin hibrit modellerde sınıflandırılmaları için en temel makine öğrenmesi algoritmalarından olan SVM ve KNN algoritmaları kullanılmıştır.

SVM: Destek vektör makinesi (SVM), hem sınıflandırma hem de regresyon görevleri için kullanılabilen denetimli bir makine öğrenimi algoritmasıdır. Algoritma, mümkün olduğu kadar geniş bir karar sınırı ürettiği için maksimal marj sınıflandırıcısı olarak da bilinir. Destek vektör makinesinin bilimsel alıntısı ilk olarak 1995 yılında Cortes ve Vapnik tarafından yayınlandı [77]. Algoritma, görüntü sınıflandırma, el yazısı tanıma ve biyoinformatik gibi çeşitli alanlarda yaygın olarak kullanılmaktadır.

SVM'ler, iki veri sınıfını ayıran hiper düzlemler olarak tanımlanan karar düzlemleri kavramına dayanır. Karar düzlemi, bir düzlemi her biri farklı bir veri sınıfı içeren iki bölüme ayıran bir çizgidir. İki sınıf arasındaki marjı maksimize eden karar düzlemini bulmak için SVM algoritması, ikinci dereceden programlama adı verilen bir optimizasyon tekniği kullanır. Karar sınırı, her bir sınıfın en yakın veri noktalarından mümkün olduğunca uzak olacak şekilde oluşturulmaktadır. Hiperdüzlemi belirleyen bu veri noktalarına destek vektörleri denmektedir.

Şekil 3.16'da verilen SVM algoritmasında destek vektörleri, sadece gözlemin koordinatlarıdır. İki veri noktası sınıfını ayırmak için seçilebilecek birçok olası hiper-düzlem vardır. Amaç, maksimum marja sahip, yani her iki sınıfın veri noktaları arasındaki maksimum

mesafeye sahip bir düzlem bulmaktır. Marj mesafesini en üst düzeye çıkarmak, gelecekteki veri noktalarının daha güvenle sınıflandırılabilmesi için gerekmektedir.



Şekil 3.16. Destek Vektör Makinesinin Grafikselsel Gösterimi

Yöntemin güçlü bir kuramsal temelini olması, büyük veri setleri üzerinde çalışabilmesi, kullanılan çekirdek fonksiyonlar ile esnek bir algoritmasının olması ve sonuçlarındaki yüksek doğruluk oranı nedeniyle son yıllarda yaygın olarak kullanılmasını sağlamıştır. Yöntem, doğrusal olarak sınıflandırılabilen verileri birbirinden ayırt edebilmek için olası pek çok doğrusal fonksiyon içerisinde marjini en büyük olanı belirler. Doğrusal olarak sınıflanamayan verileri de çekirdek fonksiyonları kullanarak daha yüksek boyutlu uzaya aktarır ve marjini en büyük olan çoklu düzlemleri bulur.

KNN: K-en yakın komşu algoritması (KNN), hem sınıflandırma hem de regresyon için kullanılabilen denetimli bir makine öğrenimi algoritmasıdır. Sınıflandırma durumunda, algoritma, eğitim setindeki diğer veri noktalarına benzerliğine dayalı olarak yeni bir veri noktasının sınıfını tahmin eder. Regresyon durumunda, algoritma, eğitim setindeki diğer veri noktalarına benzerliğine dayalı olarak yeni bir veri noktasının değerini tahmin eder. Algoritmadaki k değeri, k en yakın komşu tahmini yapmak için kullanılan en yakın komşu sayısını ifade eder. Algoritmanın anlaşılması ve uygulanması nispeten basittir. Ancak, özellikle eğitim seti büyükse hesaplama açısından yoğun olabilir. Ek olarak, algoritma k seçimine ve kullanılan mesafe metriğine duyarlı olabilir. Sınıflar, komşuların oy çokluğu temelinde test örneklerine atanır, yani etiketlenmemiş bir nokta, eğitim sınıfına ait en yakın k etiketli nokta içindeki belirgin sınıfa atıfta bulunulur [78].

KNN, eğitim verilerini öğrenmez, bunun yerine eğitim veri kümesini ezberler. Tahmin yapılmak istendiği zaman tüm veri kümesinde en yakın komşuları arar. En yakın komşuyu bulmak için mesafe hesaplama işlemi için Öklid, Manhattan, Minkowski ve Hamming

fonksiyonlarından biri kullanılmaktadır. En yaygın kullanılan fonksiyon denklem 3.2’de formülü verilen öklid mesafesidir [79].


$$d(i,j) = \sqrt{\sum_k^p (x_{ik} - x_{jk})^2} \quad (3.2)$$

3.2.3. LSTM

İnsanlar düşüncelerini önceden öğrendiği bilgilere dayanarak oluşturur. Örneğin bir cümleyi okuduğunuzda her kelimeyi bir önceki kelimeyi baz alarak anlarız yani önceki kelimeyi hatırlayarak sonraki kelime veya kelimeleri anlamlandırırız. Geleneksel sinir ağları geçmiş verileri hatırlayamadığı için önceki verilere bağlı anlamlandırma işlemini gerçekleştiremez ve bu önemli bir eksikliktir. Tekrarlayan sinir ağları (RNN) ise bu tür sorunları ele almaktadır ve bu soruna çözüm bulmak için Jeff Elman tarafından 1990’larda RNN önerilmiştir [80]. Tekrarlayan sinir ağındaki temel düşünce sıralı bilgileri kullanmaktır. RNN, zamanın her noktasındaki veriler arasındaki zamansal ilişkilerden yararlanarak her bir çıktıyı tahmin etmek için ağdaki tüm girdi geçmişini bellekte tutup eşleştirme işlevini gerçekleştirir. Geleneksel bir sinir ağında tüm girdiler ile çıktıların birbirinden bağımsız olduğunu kabul edilmektedir. Bu durumu daha iyi anlamak için örnek vermek gerekirse, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, hangi sözcüklerin o anki kelimedenden önce geldiğini bilmek gerekmektedir. RNN mimarisinin tekrarlanan olarak bilinmesinin sebebi, bir dizinin her ögesi için aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir. Tekrarlayan sinir ağları (RNN), EEG zaman serileri gibi sıralı verilerden birimler arasındaki bağımlılıkları çıkarmak için kullanılabilir [81]. RNN birimleri, sadece kendinden sonraki katmanlar arasında değil, aynı anda önceki girdilerden bilgi almak için kendi aralarında da bağlantılara sahiptir. Geleneksel RNN’ler kısa vadeli bağımlılıkları kolayca öğrenebilir; ancak, kaybolan ve patlayan gradyan problemlerinden dolayı uzun vadeli dinamikleri öğrenmede zorluk yaşarlar. Uzun kısa süreli bellek (LSTM), hem uzun hem de kısa vadeli bağımlılıkları öğrenerek kaybolan ve patlayan gradyan problemlerinin çözüme kavuşturan bir RNN türüdür [82]. Uzun süreli bağımlılıkları öğrenebilen Tekrarlayan Yapay Sinir Ağlarından biri de Uzun Kısa Süreli Bellek (LSTM) algoritmasında, girdinin ne zaman ve ne kadarının hesaplamalara dahil edileceğini ve gizli katmanın ne zaman sıfırlanacağına karar verileceğini düzenleyen ek kapılar vardır. Bu kapılar ve yaptıkları işlemler aşağıda denklemlerle açıklanmıştır.

Bir LSTM ağı, çıktıları ağ üzerinden geçmiş bellek içeriğine dayalı olarak gelişen hücrelerden oluşur. Hücreler, tüm LSTM hücre zinciri boyunca uzun vadeli bağımlılıkları belleğinde tutan ortak bir hücre yapısına sahiptir. Bilgi akışı daha sonra giriş kapısı ve unut kapısı tarafından kontrol edilir, böylece ağın önceki durumu unutmaya veya mevcut durumu yeni bilgilerle güncellemeye karar vermesine izin verir. Şekil 3.18’de görüldüğü üzere her bir hücrenin

çıkışı (gizli durum), bir çıkış kapısı tarafından kontrol edilir ve hücrenin, güncellenmiş hücre durumu verilen çıkışı hesaplamasına izin verir.



Şekil 3.17. LSTM Hücre Yapısı

LSTM ağ mimarisi Şekil 3.17’de gösterilen sıralı bloklardan meydana gelmektedir. Unutma, giriş ve çıkış kapısı olmak üzere 3 kapıdan oluşur. Bu katmanlarda gerçekleşen işlem aşamaları aşağıdaki (3.3-3.8) eşitliklerle verilmiştir. Unutma kapısı (f_t), hücre belleğinde hangi bilgilerin unutulacağını yani kaldırılacağını kontrol eder. LSTM mimarisinde öncelikle girdi olarak x_t ve h_{t-1} bilgileri kullanılarak hangi bilgilerin silineceğine karar verilir. Unutma kapısında, değerlerin bir sigmoid işlevi tarafından filtrelenmesi, sıfıra yakın değerlerin atılacak bilgi olarak kabul edileceği anlamına gelir ve 1’e yakın değerlerin saklanmaya değer yararlı bilgiler olduğu kabul edilir. Böylece hücre durumu, denklem 3.3 ile unutma kapısına göre tutulacak bilgilerle güncellenir.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3.3)$$

İkinci adımda yeni bilgilerin belirleneceği giriş kapısı devreye girer ve öncelikle i_t denklem 3.4 kullanılarak *sigmoid* fonksiyonu ile bilgiler güncellenir. Ardından denklem 3.5 ile yeni bilgiyi oluşturacak aday bilgiler *tanh* fonksiyonu tarafından belirlenir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (3.4)$$

$$C_t = \tanh(W_c [h_{t-1}, X_t] + b_c) \quad (3.5)$$

Hücre durumu, LSTM'in belleği olarak bilinir, unutma kapısı ve giriş kapısı tarafından güncellenir. Kısaca unutma kapısı, bellekte nelerin tutulmaması gerektiğini tanımlar ve giriş kapısı, bellekte nelerin tutulması gerektiğini tanımlar denilebilir. Yeni bilgiler oluşturulurken denklem 3.6 ile belleğin güncellenme işlemi sırasında hücre durum vektörü, unutma kapısı aracılığıyla eski belleği ve giriş kapısı aracılığıyla yeni belleği aşağıdaki gibi toplar:

$$C_t = C_{t-1} \cdot f_t + C_t \cdot i_t \quad (3.6)$$

Son olarak, sonuç olarak yeni gizli durumu oluşturan çıkış kapısında belirli şartlara bağlı olarak çalışan işlemler gerçekleşir ve bu işlemler aşağıdaki denklemler ile hesaplanır:

$$o_t = \sigma(W_o [h_{t-1}, X_t] + b_o) \quad (3.7)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (3.8)$$

Denklem 3.7 çıkış kapısındaki çıkışı hesaplamamızı sağlar denklem 3.8 ise yeni gizli durum denklemdir. W ve b değerleri ise sinir ağında yer alan ağırlık ve bias değerlerini ifade eder.

3.2.4. Performans Değerlendirme Parametreleri

Denenen hibrit modellerin ve uygulamaların deneysel değerlendirmesini yapmak için karmaşıklık matrisi parametreleri kullanılmıştır. Karmaşıklık matrisi, sınıflandırma problemiyle ilgili tahmin sonuçlarının özeti olarak düşünülebilir. Makine öğrenmesi ve Derin öğrenme ile yapılan birçok sınıflandırma sistemlerinin değerlendirilmesinde karmaşıklık matrisi kullanılır. Karmaşıklık matrisi hem sınıflandırmalarda yapılan hatalar hakkında hem de geliştirilen sistemde yapılan hatalar hakkında da değerlendirmeler yapmamızı sağlar. Tablo 3.2'de gösterildiği gibi bir karmaşıklık matrisinin aşağıdaki gibi dört beklenen sonucu vardır. Bu sonuçlar geliştirilen sistem için sınıflandırma ile ilgili tahmin ve hatalar hakkında genel bir değerlendirmeye varılmasını sağlayarak, sistemin performansının kolaylıkla yorumlanması hedeflenmektedir. Karmaşıklık matrisinde karşılaşılabilecek dört durumu aşağıdaki gibi özetleyebiliriz:

1. Doğruya doğru demek (Doğru Pozitif–TP) DOĞRU
2. Yanlışla yanlış demek (Doğru Negatif–TN) DOĞRU
3. Doğruya yanlış demek (Yanlış Pozitif–FP) YANLIŞ
4. Yanlışla doğru demek (Yanlış Negatif–FN) YANLIŞ

Tablo 3.2. Karmaşıklık Matrisi

Tahmini Değerler	Gerçek Değerler		
	Pozitif (1)	Negatif (0)	
	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

Karmaşıklık matrisi üzerinden hesaplanabilen performans değerlendirme parametreleri doğruluk, duyarlılık, kesinlik, özgünlük ve F1-skoru değerleridir. Performansı değerlendirmek için kullandığımız parametrelerin denklemleri aşağıda verilen 3.9- 3.13 numaralı denklemlerden elde edilmektedir.

Doğruluk

En çok kullanılan değerlendirme ölçütüdür. Bu parametre, sınıflandırmanın etkinliğini, tüm örneklerin sayısını doğru tahmin edilen örnek sayılarıyla değerlendirir. Sistemde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.9)$$

Kesinlik

Pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren işlemdir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.10)$$

Özgünlük

Doğru tahmin edilen gerçek olumsuz durum sayısının tüm olumsuz örneklerin sayısına oranıdır. Negatif olanı tahmin etme işlemidir. Algoritmanın negatif olanı ne derece doğru bulabildiğini gösterir.

$$\text{Özgünlük} = \frac{TN}{TN+FP} \quad (3.11)$$

Duyarlılık

Doğru olarak tahmin edilen gerçek pozitif örneklerin sayısının tüm pozitif örneklerin sayısına oranıdır. Pozitif durumların ne kadar başarılı tahmin edildiğini gösterir.


$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.12)$$

F1-Skoru

F1-Skoru, kesinlik ve duyarlılığı birleştiren modelin doğruluk oranının genel bir ölçümüdür. F1-Skoru, çarpma ile kesinlik ve duyarlılık parametrelerinin toplamı arasındaki oranın iki katıdır.

$$F1 - Skoru = \frac{2*(Kesinlik+Duyarlılık)}{Kesinlik+Duyarlılık} \quad (3.13)$$

Matlab'ta yer alan Deep Analyzer Network araç kutusuyla mimarilerin ağ yapıları ve ağı katmanlarında gerçekleşen işlemler adım adım gösterilmektedir. Ağa katılan verinin boyutu ve katmanların isim ve işlemleri de ayrıca gözlemlenmektedir. Şekil 3.18'de bu tez kapsamında yoğunlukla üzerinde durulan 3 DL mimarisinin blok şemaları verilerek ağda bulunan en temel katmanları net bir şekilde karşılaştırılmıştır.




Şekil 3.18. AlexNet (a), VGG16(b) ve GoogleNet(c) Blok Şemaları

4. UYGULAMALAR

Tüm deneyler, simülasyon platformu Matlab (R2019b) üzerinde gerçekleştirilmiştir. Deneyi gerçekleştirmek için Matlab tarafından sağlanan sayısal sinyal işleme araç kutusu, makine öğrenimi araç kutusu ve derin öğrenme araç kutusu kullanılmıştır.

4.1. Spektrogram Verileri Elde Edilerek Yapılan Uygulama

Bu tez kapsamında sınıflandırma doğruluğunu geliştirmek ve şizofreni araştırmaları için EEG sinyallerinin analizinde kullanılmak üzere 6 adet hibrit derin öğrenme mimarisi uygulandı. Şekil 4.1’de verilen sınıflandırma modeli Şizofreninin sınıflandırılması aşamasında ilk uygulamada gerçekleştirilen aşamaları adım adım göstermektedir. EEG veri seti hem kanallarına ayrılarak ve hem de kanallarına ayrılmadan bahsedilen 6 hibrit modelde kullanıldığından bu modelde kanallarına ayırma adımı vurgulanmamıştır.



Sınıflandırma süreci aşağıdaki adımlardan oluşmaktadır:

1. Veri çoğullama: Lineer interpolasyon yöntemi ile EEG sinyalleri çoğaltıldı. Toplam 84 normal ve şizofren EEG verisi 714 normal ve 828 şizofreni EEG verisine çoğullandı. Toplam olarak 1542 EEG verisi elde edildi.

Bu çoğullamanın nasıl yapıldığını örnek vermek gerekirse, EEG1 ve EEG2, bir ve ikinci hastanın herhangi bir kanalından alınan EEG sinyalini gösterebilir. Bu iki EEG sinyalinden lineer interpolasyon yöntemi ile veri çoğullama denklem 4.1'e göre yapılır. u değeri $[0,1]$ aralığında herhangi bir değer alabilmektedir.

$$EEG_{yeni} = (1 - u) \times EEG1 + u \times EEG2 \quad (4.1)$$

Örneğin, EEG₁: 347.78, 507.87, ...

EEG₂: 488.54, 369.86,... olduğunda $u=0.1$ için EEG_{yeni}:361.856, 494,069,... elde edilir.

Direkt sinyaller üzerinden bir sınıflandırma da bulunmak mümkün değildir. Dahası ham EEG verilerinden özellik çıkarımında bulunmak klasik makine öğrenmesi algoritmaları ile daha zorlu bir süreci gerektirir. Bu yüzden şizofreni hastalığı bulunan ve bulunmayan kişilerin EEG verilerinin sınıflandırılmasını kolaylaştırmak için işe yarar yöntemler geliştirilip, bu yöntemler denenerek çalışmalar yapıp yeni sistemlere katkı sağlanabilmektedir. Ayrıca ele alınan EEG gibi elektriksel sinyaller genellikle gürültülü olduğundan ve birçok yapaylık (artefact) içerdiğinden, ham sinyaller derin öğrenme algoritmalarında girdi olarak kullanılmadan önce genellikle dalgacık veya frekans bileşenlerine ayrıştırılır. Bu frekans dönüşümleri aracılığıyla ham sinyaller görüntüye çevrilip, özellik haritaları elde edilerek derin öğrenme mimarilerinde kullanımları sağlanmaktadır. Bu tez çalışmasında spektrogram verileri kullanılarak yapılan uygulama da ele alınan dönüşüm Kısa Süreli Fourier Dönüşümüdür (STFT). Fourier dönüşümlerinden olan bu dönüşüm Matlab üzerinde hazır bir fonksiyon olan spektrogram fonksiyonuyla elde edilebilmektedir.

2. Spektrogram: Spektrogram, belirli bir dalga biçiminde mevcut çeşitli frekanslarda zaman içinde bir sinyalin sinyal gücünü veya yüksekliğini temsil etmenin görsel bir yoludur. Ayrık zaman durumunda, dönüştürülecek veriler parçalara veya çerçevelere bölünür. Her çerçeve denklem 4.2'deki STFT dönüşümüyle elde edilir [83].

$$STFT\{x(t)\}(\tau, \omega) \equiv \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-i\omega t} dt \quad (4.2)$$

Burada sinyal $x[n]$ ve pencere $w[n]$ ile temsil edilir. S=spektrogram (x), x giriş sinyalinin STFT döndürür. Her bir S sütunu, x 'in kısa vadeli, zamanla yerleştirilmiş sıklık içeriğinin bir tahminini içerir. Fourier dönüşümü; sinyalin içindeki bilgilerin yeniden kullanılmaya uygun bir veri formatına çevrilmesi işlemidir. Fourier dönüşümüyle bir sinyal, farklı genlik, frekans ve fazlarda kosinüs ve sinüs temel bileşenlerinin toplamı olarak ifade edilir. Her bileşenin frekans ve genliği ile birlikte tablolaşması verilerin bilgisayarda işlenmesini sağlar. Bu yüzden zamana göre değişen EEG sinyallerinin frekans spektrumu oluşturuldu ve EEG sinyallerinden spektrogram görüntüleri elde edildi.

3.Derin Öğrenme Özellik Çıkarımı: AlexNet, GoogleNet ve VGG16 modelleri ile görüntülere ait özellik vektörleri oluşturuldu. Konvolüsyonel sinir ağlarının gelişmesi ile birlikte sınıflandırma işlemleri daha başarılı sonuçlar vermiştir. Klasik görüntü işleme sürecinde gerçekleştirilen tüm işlemler derin öğrenmede bir arada yürütülmektedir. Özellikle ön işlem ve özellik çıkarımı gibi süreçler otomatik olarak yapılmaktadır. Derin konvolüsyonel sinir ağında özellik çıkarımı bir dizi konvolüsyon, havuzlama, normalizasyon gibi katmanların kullanılması ile elde edilir. Elde edilen özellikler softmax katmanı ile sınıflandırılır. Bu çalışmada

sınıflandırma katmanının yerine SVM ve KNN sınıflandırma algoritmaları kullanılmaktadır. Sınıflandırma için AlexNet, GoogleNet ve VGG16 modellerinin tam bağlı katmanındaki özellik vektörleri kullanıldı. Önceden eğitilmiş AlexNet, GoogleNet ve VGG16 modellerinin tam bağlı katmanlarından elde edilen özellik vektörleri SVM ve KNN ile sınıflandırıldı. Bu katmandan elde edilen 1x1000 boyutlu özellik vektörü sınıflandırıcılara verilmektedir.

Uygulanan her bir mimarinin katmanları Matlab içinde bulunan Deep Analyzer Network aracı ile incelendi ve en son bulunan havuzlama katmanı dikkate alındı. AlexNet'te son havuzlama katmanının ismi 'pool5' ve bu her bir model için değiştiğinden bu nedenle uygulamayı yaparken son havuzlama katmanının ismi derin öğrenme mimarisine göre isimlendirildi. GoogleNet için son havuzlama katmanı 'pool5-drop_7x7_s1' VGGNet için ise yine 'pool5' olarak alındı.

4. Sınıflandırma: İkili sınıflandırma, makine öğrenmesinin en yüksek başarıma sahip algoritmalarından olan SVM ve KNN algoritmaları ile derin öğrenme mimarilerinin tam bağlı katmana kadar elde edilen özellik vektörleri kullanılarak sınıflandırıldı.

AlexNet mimarisinin son havuzlama katmanı, görüntülerin özellik haritalarını içerir. Bu katmandan sonra uygulanan sınıflandırma katmanı kaldırılarak yerine SVM sınıflandırma algoritması yerleştirilir. Böylelikle havuzlama katmanında AlexNet girişine verilen bir görüntünün özellikleri çıkarılıp tam bağlı katmanda SVM algoritmasına verilerek sınıflandırma yapılır [83]. AlexNet mimarisinde anlattığımız katmanlar sırasıyla gerçekleşirken son havuzlama katmanından sonra tek boyuta indirgeme (flatening) ve tam bağlantılı katmanları gerçekleştir. Havuzlama katmanından sonra gelen flattening katmanı matrisi tek boyuta indirir fakat hibrit modelde buna gerek kalmaz havuzlama katmanından sonra matris bilgileri klasik makine öğrenmesi sınıflandırma algoritmasına verilir ve bu şekilde sınıflandırma tamamlanmış olur yani hibrit modelde tek boyuta indirgeme ve tam bağlantılı katmanlarının işlevlerine gerek kalmaz.

Ek olarak verileri kanallarına ayırmadan ham EEG sinyallerinden veriler çoğaltıldıktan, sonra spektrogram görüntüleri elde edildi. Lineer interpolasyon yöntemiyle çoğaltılan veriler sonucunda 381 normal veri 441 hasta verisi elde edildi. Spektrogram görüntüleri derin öğrenme ve makine öğrenmesi algoritmalarının hibritlenmesi ile sınıflandırıldı.

Çoğaltılan veriler AlexNet-SVM, AlexNet-KNN, GoogleNet-SVM, GoogleNet-KNN, VGG16-SVM ve VGG16-KNN gibi 6 adet hibrit modele tabi tutularak sınıflandırma başarımları tespit edilmiştir. Tablo 4.1'de kanallarına ayrılarak yapılan sınıflandırmaların doğruluk değerleri verilmiştir.

Karmaşıklık matrisi üzerinden hesaplanabilen değerlendirme parametreleri hesaplanmış, Tablo 4.1.'de kanallar üzerinden yapılan sınıflandırmaların doğruluk değerleri verilmiştir.

Tablo 4.1. Kanal Bazlı Yapılan Sınıflandırmaların Doğruluk Sonuçları

Kanal	AlexNet-SVM	AlexNet-KNN	GoogleNet-SVM	GoogleNet-KNN	VGG16-SVM	VGG16-KNN
1	0,9838	0,9903	0,7994	0,7702	0,9806	0,9903
2	0,9968	1	0,8900	0,9159	1	0,9871
3	0,9709	0,9838	0,7864	0,7929	0,9806	0,9968
4	0,9644	0,9968	0,7023	0,7702	0,9806	0,9903
5	0,9612	0,9903	0,7994	0,7896	0,9968	0,9838
6	0,9838	0,9968	0,8544	0,7961	0,9935	0,9968
7	0,9871	0,9935	0,8641	0,7605	1	0,9968
8	0,9806	0,9806	0,8188	0,8123	0,9968	0,9935
9	0,9806	0,9903	0,8479	0,7832	0,9968	0,9741
10	0,9806	0,9903	0,8285	0,8252	0,9935	0,9871
11	0,9903	0,9968	0,8932	0,8123	1	0,9935
12	0,9968	0,9935	0,9029	0,8511	1	0,9935
13	0,9903	0,9903	0,8997	0,8155	1	0,9968
14	0,9741	0,9838	0,8414	0,8026	1	0,9935
15	0,9935	0,9935	0,9515	0,9029	0,9968	1
16	1	1	0,9450	0,8608	1	0,9968

Tablo 4.2.'de kanallar üzerinden yapılan sınıflandırmaların duyarlılık değerleri verilmiştir.

Tablo 4.2. Kanal Bazlı Yapılan Sınıflandırmaların Duyarlılık Sonuçları

Kanal	AlexNet-SVM	AlexNet-KNN	GoogleNet-SVM	GoogleNet-KNN	VGG16-SVM	VGG16-KNN
1	0,9662	-	0,7535	0,7535	0,9790	0,9795
2	0,9931	-	0,8759	0,9149	-	-
3	0,9786	0,9726	0,8182	0,7842	0,9928	0,9931
4	0,9583	0,9931	0,6759	0,7727	0,9724	-
5	0,9517	0,9795	0,7872	0,7955	0,9931	-
6	0,9792	-	0,8224	0,8077	0,9862	0,9931
7	0,9929	0,9862	0,8483	0,7674	-	-
8	0,9790	0,9790	0,8042	0,7972	0,9931	0,9862
9	0,9660	0,9930	0,8243	0,7794	0,9931	0,9720
10	0,9790	0,9861	0,7922	0,8248	0,9862	0,9793
11	0,9930	0,9931	0,8986	0,8148	-	0,9862
12	-	0,9930	0,9380	0,8593	-	0,9862
13	0,9861	0,9861	0,9242	0,8071	-	-
14	0,9787	0,9929	0,8357	0,8015	-	0,9930
15	0,9862	0,9862	0,9384	0,8897	-	-
16	-	-	0,9437	0,8906	-	-

Tablo 4.3.'te kanallar üzerinden yapılan sınıflandırmaların özgüllük değerleri verilmiştir.

Tablo 4.3. Kanal Bazlı Yapılan Sınıflandırmaların Özgüllük Sonuçları

Kanal	AlexNet-SVM	AlexNet-KNN	GoogleNet-SVM	GoogleNet-KNN	VGG16-SVM	VGG16-KNN
1	-	0,9822	0,7844	0,7844	0,9819	-
2	-	-	0,9024	0,9167	-	0,9765
3	0,9645	0,9939	0,7660	0,8000	0,9706	-
4	0,9697	-	0,7256	0,7684	0,9878	0,9822
5	0,9695	-	0,8095	0,7853	-	0,9708
6	0,9879	0,9940	0,8854	0,7877	-	-
7	0,9821	-	0,8780	0,7556	-	0,9940
8	0,9819	0,9819	0,8313	0,8253	-	-
9	0,9938	0,9880	0,8696	0,7861	-	0,9759
10	0,9819	0,9939	0,8645	0,8256	-	0,9939
11	0,9880	-	0,8889	0,8103	-	-
12	0,9940	0,9940	0,8778	0,8448	-	-
13	0,9939	0,9939	0,8814	0,8225	-	0,9940
14	0,9702	0,9763	0,8462	0,7865	-	0,9940
15	-	-	0,9632	0,9146	0,9930	-
16	-	-	0,9461	0,8398	-	0,9940


Tablo 4.4'te kanallar üzerinden yapılan sınıflandırmaların kesinlik değerleri verilmiştir.

Tablo 4.4. Kanal Bazlı Yapılan Sınıflandırmaların Kesinlik Sonuçları


	AlexNet-SVM	AlexNet-KNN	GoogleNet-SVM	GoogleNet-KNN	VGG16-SVM	VGG16-KNN
1	-	0,9790	0.7483	0.7483	0.9790	-
2	-	-	0,8881	0,9021	-	0,9720
3	0,9580	0,9930	0,6923	0,7622	0,9650	-
4	0,9650	-	0,6853	0,7133	0,9860	0,9790
5	0,9650	-	0,7762	0,7343	-	0,9650
6	0,9860	0,9930	0,8741	0,7343	-	-
7	0,9790	-	0,8601	0,6923	-	0,9930
8	0,9790	0,9790	0,8042	0,7972	-	-
9	0,9930	0,9860	0,8531	0,7413	-	0,9720
10	0,9790	0,9930	0,8531	0,7902	-	0,9930
11	0,9860	-	0,8671	0,7692	-	-
12	0,9930	0,9930	0,8462	0,8112	-	-
13	0,9930	0,9930	0,8531	0,7905	-	0,9930
14	0,9650	0,9720	0,8182	0,7343	-	0,9930
15	-	-	0,9580	0,9021	0,9930	-
16	-	-	0,9371	0,7972	-	0,9930

16 EEG kanal üzerinden yapılan işlemler tüm kanallar için de gerçekleştirildi. Kanallara ayrılmadan veriler kullanılarak her bir katılımcının spektrogram verileri elde edildi. NNCI platformundan alınan kaynak dosyada 39 normal 45 şizofreni olmak üzere toplam 84 katılımcı üzerinden lineer interpolasyon yöntemi ile veriler çoğaltılarak 381 normal ve 441 şizofreni veri elde edildi. Daha sonra çoğullanan verilerin de spektrogram verileri elde edilerek tekrar 6 hibrit model üzerinde sınıflandırmalar elde edildi.


EEG sinyallerinin örnekleri Şekil 4.2 ve Şekil 4.3'te görülmektedir. İki hastanın tüm kanallarının sinyallerinin kullanılarak lineer interpolasyon yöntemi ile çoğaltılan verinin bir örneği Şekil 4.4'te verilmiştir.



Şekil 4.2. 1.Hastanın 16 Kanallı EEG Sinyali




Şekil 4.3. 2.Hastanın 16 Kanallı EEG Sinyali




Şekil 4.4. 1 ve 2.Hastanın 16 Kanal Verilerini Kullanarak ($u=0,3$) Çoğaltılan Verinin EEG Sinyali


Şekil 4.5 ve Şekil 4.6’da tüm kanallar üzerinden 1 ve 2. hastanın spektrogram görüntüleri ve çoğaltılan verinin spektrogram görüntüsü Şekil 4.7’de verilmiştir.



Şekil 4.5. 1.Hastanın 16 Kanallı EEG Spektrogram Görüntüsü



Şekil 4.6. 2. Hastanın 16 Kanallı EEG Spektrogram Görüntüsü



Şekil 4.7. 1 ve 2. Hastanın 16 Kanal Verilerini Kullanarak ($u=0,3$) Çoğaltılan Verinin Spektrogram Görüntüsü

Sınıflandırma başarımını gözlemlemek amacıyla Tablo 4.5.'te kanallarına ayrılmadan hibrit modellerle yapılan sınıflandırmaların performans parametrelerinin sonuçları verilmiştir.


Tablo 4.5. Hibrit Modellerle Kanallarına Ayrılmadan Yapılan Sınıflandırma Sonuçları

	AlexNet-SVM	AlexNet-KNN	GoogleNet-SVM	GoogleNet-KNN	VGG16-SVM	VGG16-KNN
Doğruluk	0,9756	0,9939	0,9634	0,9207	0,9695	0,9512
Özgüllük	0,9565	1	0,9556	0,9518	0,9770	0,9255
Duyarlılık	1	0,9870	0,9730	0,8889	0,9610	0,9857
Kesinlik	0,9474	1	0,9474	0,9474	0,9737	0,9079

4.2. Ham Veriler ile Gerçekleştirilen Uygulama

İlk olarak LSTM ile yapılan bu uygulama da ham veriler kullanıldı. LSTM uygulamasını gerçekleştirirken platform olarak kullanılan Matlab için veriler uygun forma dönüştürüldü. NNCI platformu üzerinden elde edilen veri setindeki veriler txt dosyası şeklindeydi. Her bir hastaya ait txt dosyasındaki veriler mat uzantılı dosyalara çevrilerek normal ve şizofren bireylerin matris dosyaları oluşturuldu. Daha sonra bu ağ için kullanacağımız veri yeterli olmayacağından lineer interpolasyon yöntemi kullanılarak veriler eşit bir sayıya (300) kadar çoğaltıldı. Ayrıca bu ağ için gerekli etiketleme işi için ise normal ve şizofren bireylerin verilerini etiketleyecek şekilde ayrı bir mat dosyasında “cell” tipinde bir dosya oluşturuldu. Bu yapılan uygulama hem kanallarına ayrılarak her bir kanal için ayrı ayrı denendi. Hem de kanallarına ayırmadan 16 kanalı içeren verilerin üzerinden denendi.

Ham veriler ve kanallara ayırarak gerçekleştirilen uygulamanın modeli Şekil 4.8’de verilmiştir. LSTM ile yapılan bu uygulama için aynı veri setinin ham verileri kullanıldı. Ham veriler ilk olarak kanallarına ayrılıp, lineer interpolasyon yöntemiyle çoğaltıldı. Uygulamanın kanallara ayırmadan yapılan halinde de veriler çoğaltıldı. İkisi arasındaki tek fark, ham verilerin kanallarına ayrılması oldu.



Şekil 4.8. LSTM Uygulama Modeli

Şekil 4.9 ve Şekil 4.10’da verilen karmaşıklık matrisleri üzerinden 300’e çoğaltılan verilerin %90’ı eğitim verisi, %10’u test verisi olarak alındı. Ağın eğitimi sırasında; farklı döngü(epoch) sayıları denenerek ağın performansı gözlemlendi. Döngü sayısının 100 olması ağ için uygun bulundu.

Eğitim Verisi için Karmaşıklık Matrisi

Doğru Sınıf	N	270		100%	
	Sch		270	100%	
		100%	100%		
		N	Sch	N: Normal Birey Sch: Şizofren Birey	
		Tahmini Sınıf			

Şekil 4.9. LSTM Eğitim Verisi Karmaşıklık Matrisi

Test Verisi için Karmaşıklık Matrisi					
N	28	2	93.3%	6.7%	N: Normal Birey Sch: Şizofren Birey
	1	29	96.7%	3.3%	
Sch	96.6%	93.5%			
	3.4%	6.5%			
	N	Sch	Tahmini Sınıf		

Şekil 4.10. LSTM Test Verisi Karmaşıklık Matrisi

Kanal bazlı yapılan uygulamalarda test ve eğitim doğrulukları birbirine yakın çıkmıştır. Bu da yapılan uygulamanın başarısının gayet iyi olduğunu gösterir. Tablo 4.6'dan doğruluklara bakılıp kanallara ayrı ayrı değerlendirilirse eğitim ve test doğruluğunun en tutarlı olduğu kanal 13. kanal olarak gözlemlenir.

Tablo 4.6. 16 Kanal Bazlı LSTM Sonuçları


Kanal	Eğitim Doğruluğu	Test Doğruluğu
1	%98,57	%97,50
2	%98,40	%97,83
3	%98,50	%97,00
4	%98,85	%97,33
5	%98,51	%96,16
6	%98,38	%97,50
7	%98,29	%96,00
8	%98,16	%96,11
9	%98,40	%97,66
10	%98,57	%96,50
11	%98,42	%97,00
12	%98,50	%98,16
13	%98,50	%98,50
14	%98,59	%97,83
15	%98,40	%97,33
16	%98,51	%96,33

Tablo 4.7.'de EEG verileri kanallarına ayrılmadan LSTM ağı ile eğitilerek sınıflandırılmıştır. Eğitim ve test doğruluğu yakın değerlerde bulunduğu için iyi bir sonuçla başarımlar sağladığı gözlemlenmektedir.

Tablo 4.7. Tüm Kanalların LSTM Sonucu

Train Accuracy	% 100
Test Accuracy	% 95

Şekil 4.11’de eğitim doğruluk grafiği ve eğitimin işlem grafiği görülmektedir. Alttaki grafikte ise eğitimin işlem grafiğinde hem ağı doğruluk grafiği hem de yapılan eğitimin kayıp grafiği gözlenmektedir. Farklı iterasyonlar denenip eğitimin stabil olduğu döngü sayısı bulunarak eğitim sonlandırılmıştır.



Şekil 4.11. LSTM Eğitim Eğrisi

6. SONUÇLAR

Bu tez çalışmasının temel amacı ağır mental bir hastalık olan şizofrenin tanı ve teşhisinde hız kazandıracak sistemler geliştirmektir. Bu nedenle bu tez çalışmasında araç olarak EEG sinyalleri ve son yıllarda sağlık ve bilişim alanında yaygın olarak uygulanan DL mimarileri ve LSTM ağı kullanılmıştır.

Son yıllarda endüstri, tıp, robotik, görüntü işleme, bilgisayar görmesi, nesne tespiti, ses işleme-tanıma, çeviri, gelecek tahmini, sağlık ve finansal gibi pek çok alanda akıllı çözümler üretmekte olan Derin öğrenme yöntemlerinden ve Makine öğrenmesinin en çok kullanılan algoritmalarından olan SVM ve KNN'den bahsedilmiştir. Bu çalışmada bu yöntemlerin kullanımıyla gerçekleştirilen şizofreni tespiti üzerinde durulmuştur.

Tez kapsamında şizofreni hastalığına sahip hastaların EEG kayıtları en çok tercih edilen Derin Öğrenme Mimarilerinden olan AlexNet, GoogleNet, VGG16 ile SVM ve KNN'in hibritlenmesi ile analiz edilmiştir. Bu analizler sonucunda EEG kayıtlarının 16 kanal üzerinden alınmış olup elde edilen özellikler, hibrit sistemlerin sınıflandırması ile ilgili özelliklerin hastalığı ayırt edici özelliğe sahip olup olmadıkları değerlendirilmiştir. Sonuç olarak, mimariler arasında yapılan değerlendirme de AlexNet ve VGG16 mimarileriyle oluşturulan hibrit yapıların GoogleNet ile yapılan hibrit yapılara oranla sınıflandırma başarımları daha yüksek değerlerde gözlenmiştir. SVM ve KNN arasında ise net bir ayırım gözlenmemektedir. Kanal kanal fark gösteren sonuçlarla kimi kanalda KNN, kimi kanalda ise SVM ile yapılan hibrit yapıların daha başarılı olduğu gözlenmiştir. Kanal bazında bakılacak olursa; çok net olmamakla birlikte 15. kanalın sonuçları en başarılı yüzdeleri elde etmiştir. Bu değerlendirmeyi AlexNet ve VGG16 ile yapılan modeller yakın değerlerde sonuçlar verdiğinden GoogleNet baz alınarak söylenebilir. Çünkü GoogleNet 'in en yakın olduğu sonuçlar 15. kanalda gözlemlendi. Hibrit yapıların değerlendirilmesinde ise en başarılı hibrit yapının VGG16-SVM hibrit yapısının olduğu gözlemlenmiştir. Değerlendirmeye tabi tutulan yöntem bize şizofreni hastalarının normal bireylerden ayırt edilebilmesini sağlayacak yardımcı bir uzman sistem geliştirilebileceğini göstermekte ve bu yöndeki çalışmaları destekleyebilir sonuçlarına varılmıştır.

Sinyal işleme uygulamaları zaman serisi problemleri olarak ele alındığından, LSTM ağının bu çalışma kapsamında yüksek başarımlar sağladığı gözlemlenmiştir. LSTM ağının baz alınarak kullanıldığı sistemler geliştirilebileceği gözlemlenmiştir.

Araştırmacılar kanal bazında yapılan uygulamalarda her bir kanalın başarımları değiştiğinden en başarımları sağlayan kanallar gözlemlenip; ileride yapılacak olan çalışmalara bu kanallar ve başarımları sağlayan uygulamalar üzerine daha yoğun bir şekilde odaklanılıp, sağlık alanında daha verim sağlanabilecek çalışmalar yapabileceklerdir.

KAYNAKLAR

- [1] WHO: https://www.who.int/mental_health/management/schizophrenia/en/.
- [2] S. L. Oh, J. Vignes, E. J. Ciaccio, R. Yuvaraj and U. R. Acharya, "Deep Convolutional Neural Network Model for Automated Diagnosis of Schizophrenia Using EEG Signals", *Appl. Sci.*, vol.9, no. 14, 2870, 2019.
- [3] Acharya UR, Oh SL, Hagiwara Y, Tan JH, Adeli H. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Comput Biol Med* 2018; 100:270–8.
- [4] Subudhi A, Acharya UR, Dash M, Jena S, Sabut S. Automated approach for detection of ischemic stroke using Delaunay Triangulation in brain MRI images. *Comput Biol Med* 2018; 103:116–29.
- [5] Talo M, Baloglu UB, Yıldırım Ö, Acharya UR. Application of deep transfer learning for automated brain abnormality classification using MR images. *Cogn Syst Res* 2019; 54:176–88.
- [6] Gudigar A, Raghavendra U, San TR, Ciaccio EJ, Acharya UR. Application of multi-resolution analysis for automated detection of brain abnormality using MR images: a comparative study. *Future Gener Comput Syst* 2019; 90:359–67.
- [7] Acharya UR, Sree SV, Ang PCA, Yanti R, Suri JS. Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals. *Int J Neural Syst* 2012;22(02):1250002 <https://doi.org/10.1142/S0129065712500025>.
- [8] Roohi-Azizi, M., Azimi, L., Heysicattalab, S., & Aamidfar, M. (2017). Changes of the brain's bioelectrical activity in cognition, consciousness, and some mental disorders. *Medical journal of the Islamic Republic of Iran*, 31, 53.
- [9] Jasper, H., 1958. Report of the committee on methods of clinical examination in electroencephalography. *Electroencephalography and Clinical Neurophysiology*, 10: 370-375.
- [10] Cogan, D., Birjandtalab, J., Nourani, M., Harvey, J. & Nagaraddi, V. Multi-biosignal analysis for epileptic seizure monitoring. *Int. J. Neural Syst.* https://doi.org/10.1142/s0129_06571_65003_13 (2017).
- [11] Morabito, F. C. et al. A longitudinal EEG study of Alzheimer's disease progression based on a complex network approach. *Int. J. Neural Syst.* https://doi.org/10.1142/s0129_06571_55000_57 (2015).
- [12] Akar, S. A., Kara, S., Latifoğlu, F. & Bilgiç, V. Analysis of the complexity measures in the EEG of schizophrenia patients. *Int. J. Neural Syst.* 26, 1650008 (2016).
- [13] Kapur, S., Phillips, A. G., & Insel, T. R. (2012). Why has it taken so long for biological psychiatry to develop clinical tests and what to do about it?. *Molecular psychiatry*, 17(12), 1174-1179.
- [14] Ford, J. M., Roach, B. J., Palzes, V. A., & Mathalon, D. H. (2016). Using concurrent EEG and fMRI to probe the state of the brain in schizophrenia. *NeuroImage: Clinical*, 12, 429-441.
- [15] Hornero, R.; Abasolo, D.; Jimeno, N.; Sanchez, C.I.; Poza, J.; Aboy, M. Variability; regularity; complexity of time series generated by schizophrenic patients and control subjects. *IEEE Trans. Biomed. Eng.* 2006, 53, 210–218.
- [16] LeCun, Y.; Huang, F.J.; Bottou, L. Learning methods for generic object recognition with invariance to pose and lighting. In *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition; CVPR 2004*, Washington, DC, USA, 27 June–2 July 2004; Volume 2, pp. 97–104.
- [17] Krizhevsky, A.; Sutskever, I.; Hinton, G.E. ImageNet Classification with Deep Convolutional Neural Networks. In *Proceedings of the 25th International Conference on Neural Information Processing Systems*, Lake Tahoe, Nevada, 3–6 December 2012.
- [18] Acharya, U.R.; Fujita, H.; Lih, O.S.; Hagiwara, Y.; Tan, J.H.; Adam, M. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network. *Inf. Sci.* 2017, 405, 81–90.

- [19] Acharya, U.R.; Fujita, H.; Lih, O.S.; Adam, M.; Tan, J.H.; Chua, C.K. Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network. *Knowl. Based Syst.* 2017, 132, 62–71.
- [20] Kim JW, Lee YS, Han DH, Min KJ, Lee J, Lee K. Diagnostic utility of quantitative EEG in un-medicated schizophrenia. *Neurosci Lett* 2015; 589:126–31.
- [21] Dvey-Aharon Z, Fogelson N, Intrator N. Schizophrenia detection and classification by advanced analysis of EEG recordings using a single electrode approach. *PLoS One* 2015;10(4):e0123033 <https://doi.org/10.1371/journal.pone.0123033>.
- [22] Ibáñez-Molina AJ, et al. EEG multiscale complexity in schizophrenia during picture naming. *Front Physiol* 2018; 9:1213. <https://doi.org/10.3389/fphys.2018.01213>.
- [23] Chen C-MA, Jiang R, Kenney JG, Bi J, Johannesen JK. Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults. *Neuropsychiatr Electrophysiol* 2016;2(1):1–21.
- [24] Santos-Mayo L, San-José-Revuelta LM, Arribas JI. A computer-aided diagnosis system with EEG based on the P3b wave during an auditory odd-ball task in schizophrenia. *IEEE Trans Biomed Eng* 2017;64(2):395–407.
- [25] Devijver, P.A., Kittler, J. (1982). *Pattern Recognition: A Statistical Approach*. Prentice Hall.
- [26] Shalbaf, A., Bagherzadeh, S., & Maghsoudi, A. (2020). Transfer learning with deep convolutional neural networks for automated detection of schizophrenia from EEG signals. *Physical and Engineering Sciences in Medicine*, 43(4), 1229-1239.
- [27] Aristizabal DA, Fernando T, Denman S, et al. Identification of children at risk of schizophrenia via deep learning and eeg responses. *IEEE J Biomed Health Inform* 2020. DOI: 10.1109/JBHI.2020.2984238.
- [28] Oh SL, Jahmunah V, Ciaccio EJ, Yuvaraj R, Acharya UR. Deep convolutional neural network model for automated diagnosis of schizophrenia using EEG signals. *Appl Sci* 2019. (revised & submitted).
- [29] Shoeibi A, Sadeghi D, Moridian P, Ghassemi N, Heras J, Alizadehsani R, Khadem A, Kong Y, Nahavandi S, Zhang Y-D, Gorriz JM, Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models. *Frontiers in Neuroinformatics*. 2021; 15:1-16.
- [30] Sun J, Cao R, Zhou M. et al. A hybrid deep neural network for classification of schizophrenia using EEG Data. *Sci Rep*. 2021; 11, 4706.
- [31] Singh K, Singh S, and Malhotra J. Spectral features based convolutional neural network for accurate and prompt identification of schizophrenic patients. *Proc. Inst. Mech. Eng. Part H J. Eng. Med.* 2021; 235, 167–184.
- [32] Siuly, S., Khare, S. K., Bajaj, V., Wang, H., & Zhang, Y. (2020). A computerized method for automatic detection of schizophrenia using EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(11), 2390-2400.
- [33] Jahmunah, V., Oh, S. L., Rajinikanth, V., Ciaccio, E. J., Cheong, K. H., Arunkumar, N., & Acharya, U. R. (2019). Automated detection of schizophrenia using nonlinear signal processing methods. *Artificial intelligence in medicine*, 100, 101698.
- [34] Devia, C., Mayol-Troncoso, R., Parrini, J., Orellana, G., Ruiz, A., Maldonado, P. E., & Egaña, J. I. (2019). EEG classification during scene free-viewing for schizophrenia detection. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(6), 1193-1199.
- [35] Prabhakar, S. K., Rajaguru, H., & Lee, S. W. (2020). A framework for schizophrenia EEG signal classification with nature inspired optimization algorithms. *IEEE Access*, 8, 39875-39897.
- [36] Alimardani, F., Cho, J. H., Boostani, R., & Hwang, H. J. (2018). Classification of bipolar disorder and schizophrenia using steady-state visual evoked potential based features. *IEEE Access*, 6, 40379-40388.

- [37] Shim, M., Hwang, HJ, Kim, DW, Lee, SH ve Im, CH (2016). Kombine sensör seviyesi ve kaynak seviyesi EEG özelliklerini kullanarak şizofreninin makine öğrenimine dayalı teşhisi. Şizofreni araştırması, 176 (2-3), 314-319.
- [38] Li, F., Wang, J., Liao, Y., Yi, C., Jiang, Y., Si, Y., ... & Xu, P. (2019). Differentiation of schizophrenia by combining the spatial EEG brain network patterns of rest and task P300. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 27(4), 594-602.
- [39] Prasad, P. D., Halahalli, H. N., John, J. P., & Majumdar, K. K. (2013). Single-trial EEG classification using logistic regression based on ensemble synchronization. IEEE journal of biomedical and health informatics, 18(3), 1074-1080.
- [40] Luo, Y., Tian, Q., Wang, C., Zhang, K., Wang, C., & Zhang, J. (2020). Biomarkers for prediction of schizophrenia: Insights from resting-state EEG microstates. IEEE Access, 8, 213078-213093.
- [41] Phang, C. R., Noman, F., Hussain, H., Ting, C. M., & Ombao, H. (2019). A multi-domain connectome convolutional neural network for identifying schizophrenia from EEG connectivity patterns. IEEE journal of biomedical and health informatics, 24(5), 1333-1343.
- [42] Naira, T., & Alberto, C. (2020). Classification of people who suffer schizophrenia and healthy people by EEG signals using deep learning.
- [43] Chu, L., Qiu, R., Liu, H., Ling, Z., Zhang, T., & Wang, J. (2017). Individual recognition in schizophrenia using deep learning methods with random forest and voting classifiers: Insights from resting state EEG streams. arXiv preprint arXiv:1707.03467.
- [44] Thilakvathi, B., Devi, S. S., Bhanu, K., & Malaippan, M. (2017). EEG signal complexity analysis for schizophrenia during rest and mental activity. Biomedical Research-India, 28(1), 1-9.
- [45] Sui, J., Castro, E., He, H., Bridwell, D., Du, Y., Pearlson, G. D., ... & Calhoun, V. D. (2014, August). Combination of FMRI-SMRI-EEG data improves discrimination of schizophrenia patients by ensemble feature selection. In 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (pp. 3889-3892). IEEE.
- [46] Boostani, R., Sadatnezhad, K., & Sabeti, M. (2009). An efficient classifier to diagnose of schizophrenia based on the EEG signals. Expert Systems with Applications, 36(3), 6492-6499.
- [47] Piryatinska, A., Darkhovsky, B., & Kaplan, A. (2017). Binary classification of multichannel-EEG records based on the ϵ -complexity of continuous vector functions. Computer methods and programs in biomedicine, 152, 131-139.
- [48] http://brain.bio.msu.ru/eeeg_schizophrenia.htm, Erişim Tarihi:10.04.2021
- [49] N. Jiang, S. Dosen, K.R. Muller, D. Farina, Myoelectric control of artificial limbs: is there a need to change focus? [In the spotlight], IEEE Signal Process. Mag. 29 (5) (2012) 148–152, <http://dx.doi.org/10.1109/MSP.2012.2203480>.
- [50] L. Deng, A tutorial survey of architectures, algorithms, and applications for deep learning, APSIPA Trans. Signal Inf. Process. 3 (2014) e2.
- [51] H. A. Song and S.-Y. Lee, “Hierarchical Representation Using NMF,” in International Conference on Neural Information Processing., 2013, pp. 466–473.
- [52] G. Carneiro, Y. Zheng, F. Xing ve L. Yang, Mamografi Kardiyovasküler ve Mikroskopi Görüntü Analizinde Derin Öğrenme Yöntemlerinin İncelenmesi, Cham:Springer, s. 11-32, 2017.
- [53] c
- [54] Aslan, Z. (2019). On the use of deep learning methods on medical images. The International Journal of Energy and Engineering Sciences, 3(2): 1-15.
- [55] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, in: Proceedings of the NIPS, 2012.
- [56] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, in: Proceedings of the ICLR, 2015.
- [57] C. Szegedy, W. Liu, Y. Jia, et al., Going deeper with convolutions, in: Proceedings of the CVPR, 2015.

- [58] O. Russakovsky, J. Deng, H. Su, et al., Imagenet large scale visual recognition challenge, *Int. J. Comput. Vis.* 115 (3) (2015) 211–252.
- [59] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [60] Pang, Yanwei, Manli Sun, Xiaoheng Jiang, and Xuelong Li. 2017. “Convolution in Convolution for Network in Network.” *IEEE transactions on neural networks and learning systems* 29(5): 1587–97.
- [61] Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*
- [62] Sharma, S., Sharma, S., Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), 310-316.
- [63] V. Nair and G. E. Hinton, “Rectified linear units improve restricted boltzmann machines,” in *Proc. 27th Int. Conf. Mach. Learn. (ICML)*, 2010, pp. 807–814.
- [64] Y.L. Boureau, J. Ponce, Y. LeCun, A theoretical analysis of feature pooling in visual recognition, in: *Proceedings of the ICML*, 2010.
- [65] D. Scherer, A. Müller, S. Behnke, Evaluation of pooling operations in convolutional architectures for object recognition, in: *Proceedings of the ICANN*, 2010.
- [66] D.C. Cireşan, U. Meier, J. Masci, et al., High-performance neural networks for visual object classification, in: *Proceedings of the IJCAI*, 2011.
- [67] https://www.opendatascience.com/blog/an-intuitive-explanationofconvolutionalneuralnetworks/?utm_source=Open+Data+Science+News&utm_campaign=f4ea9cc60fEMAIL_CAMPAIGN_2016_12_21&_medium=email&utm_term=0_2ea92bb125-f4ea9cc60f245860601.
- [68] D. Stutz and L. Beyer, “Understanding Convolutional Neural Networks,” 2014.
- [69] <http://www.slideshare.net/hanneshapke/introduction-to-convolutionalneural-networks>.
- [70] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- [71] Xiao, T., Li, H., Ouyang, W., & Wang, X. (2016, June). Learning deep feature representations with domain guided dropout for person re-identification. In *Computer Vision and Pattern Recognition (CVPR)*, 2016 IEEE Conference on (pp. 1249-1258). IEEE.
- [72] Adler, A., Elad, M., & Zibulevsky, M. (2016). Compressed Learning: A Deep Neural Network Approach. *arXiv preprint arXiv:1610.09615*.
- [73] C. Szegedy, S. Ioffe, V. Vanhoucke and A. A. Alemi, "Inception-v4 inception-resnet and the impact of residual connections on learning", *Proc. 31st AAAI Conf. Artif. Intell.*, pp. 4278-4284, 2017.
- [74] Y. Ge, S. Jiang, Q. Xu, C. Jiang, and F. Ye, “Exploiting representations from pre-trained convolutional neural networks for high-resolution remote sensing image retrieval,” *Multimedia Tools Appl.*, vol. 77, no. 13, pp. 17489–17515, Jul. 2018.
- [75] Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2016). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *arXiv preprint arXiv:1606.00915*.
- [76] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [77] J. Han dan and M. Kamber, *Data Mining Concept and Tehniques*, San Fransisco:Morgan Kauffman, 2006.
- [78] Besserve, M., K. Jerbi, F. Laurent, S. Baillet, J. Martinerie, and L. Garnero. 2007. “Classification Methods for Ongoing EEG and MEG Signals.” *Biological Research* 40 (4): 415–437.
- [79] M. Bramer, *Principles of Data Mining*, London:Springer, 2007.

- [80] Rodriguez, P., Wiles, J., & Elman, J. L. (1999). A recurrent neural network that learns to count. *Connection Science*, 11(1), 5-40.
- [81] Z. C. Lipton, J. Berkowitz, and C. Elkan, "A critical review of recurrent neural networks for sequence learning," 2015, arXiv:1506.00019. [Online]. Available: <https://arxiv.org/abs/1506.00019>
- [82] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 28, no. 10, pp. 2222–2232, Oct. 2017.
- [83] Tuncer SA, Alkan A, Classification of EMG signals taken from arm with hybrid CNN-SVM architecture. *Concurrency and Computation: Practice and Experience*. 2022; <https://doi.org/10.1002/cpe.6746>



ÖZGEÇMİŞ

Büşra ÇETİN SÖYLEMEZ

[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]