



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**EEG SİNYALLERİNİN BÜTÜNLEŞİK
AMPIRİK DÖNÜŞÜMLÜ
DERİN ÖĞRENME
YÖNTEMLERİYLE ANALİZİ**

Gülçin İNAT

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

KASIM 2024





**EEG SİNYALLERİNİN BÜTÜNLEŞİK AMPİRİK DÖNÜŞÜMLÜ DERİN
ÖĞRENME YÖNTEMLERİYLE ANALİZİ**

Gülçin İNAT

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

KASIM 2024

Gülçin İNAT tarafından hazırlanan “EEG SİNYALLERİNİN BÜTÜNLEŞİK AMPİRİK DÖNÜŞÜMLÜ DERİN ÖĞRENME YÖNTEMLERİYLE ANALİZİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Gökhan ALTAN

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Başkan: Prof. Dr. Celaleddin YEROĞLU

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Dr. Öğr. Üyesi Murat UÇAR

Bilgisayar Mühendisliği Anabilim Dalı, İzmir Bakırçay Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Tez Savunma Tarihi: 28/11/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- ☒ Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - ☒ Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - ☒ Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - ☒ Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - ☒ Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - ☒ Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Gülçin İNAT

28/11/2024

EEG SİNYALLERİNİN BÜTÜNLEŞİK AMPİRİK DÖNÜŞÜMLÜ DERİN ÖĞRENME
YÖNTEMLERİYLE ANALİZİ
(Yüksek Lisans Tezi)

Gülçin İNAT

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Kasım 2024

ÖZET

Beyin hücreleri, ortalama 30.000 sinir hücresi ile etkileşim halindedir. Bu etkileşim sırasında beyinde elektriksel dalgalanmalar meydana gelir ve bu dalgalanmalar, Elektroensefalografi (EEG) cihazı ile ölçülebilir. Bu çalışmada, 18 sağlıklı bireyden alınan ve 29 farklı kanaldan elde edilen EEG verileri kullanılmıştır. Mekansal dikkat kaymasını incelemek amacıyla, literatürde de vurgulandığı üzere, dikkat kaymasının etkili olduğu PO7 ve PO8 kanalları üzerinde odaklanılmıştır. EEG kayıtları, standart olarak yerleştirilmiş 29 Ag/AgCl elektrotlar aracılığı ile kaydedilmiştir, sağ mastoid referans alınarak, 250 Hz frekansında örneklenmiştir.

Öznitelik çıkarma yöntemlerinden Ampirik Dalgacık Dönüşümü (Empirical Wavelength Transform, EWT) ve Topluluk Ampirik Mod Ayrışımı (Extended Empirical Mode Decomposition, EEMD) kullanılmıştır. Bu öznitelikler, derin öğrenme ve makine öğrenmesi algoritmaları ile analiz edilmiştir. Analiz kapsamında hem kanal bazlı hem de içsel mod fonksiyonu (Intrinsic Mode Functions, IMF) bazlı karşılaştırmalar yapılmıştır. Kanal bazlı analizlerde PO7 ve PO8 kanallarına odaklanılmış ve PO7 kanalının dikkat kayması için daha başarılı sonuçlar verdiği görülmüştür. IMF bazlı analizlerde ise 6, 8, 10 ve 12 değerleri test edilmiştir. EEMD yöntemi uygulandığında ve tek boyutlu zaman sinyalleri iki boyutlu görüntülere dönüştürüldüğünde, en yüksek başarı IMF=6 değerinde elde edilmiştir. Algoritma bazlı karşılaştırmalarda ise aynı veri setleri üzerinde yapılan analizler sonucunda, makine öğrenmesi yöntemlerinden k-NN ve karar ağacı %100,0; derin öğrenme yöntemlerinden GNN algoritması ise %99,84 test başarımları ile en yüksek başarıyı sağlamıştır.

Anahtar Kelimeler : Elektroensefalografi, EEG, ampirik dalgacık dönüşümü, EWT, topluluk ampirik mod ayrışımı, EEMD, k-NN, SVM, MLP, karar ağacı, DBN, DNN, CNN, GCN, GNN

Sayfa Adedi : 79

Danışman : Doç. Dr. Gökhan ALTAN

EEG ANALYSIS USING DEEP LEARNING METHODS WITH INTEGRATED
EMPIRICAL TRANSFORMATION
(M. Sc. Thesis)

Gülçin İNAT

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

Kasım 2024

ABSTRACT

Brain cells interact with an average of 30,000 neurons. During these interactions, electrical oscillations occur in the brain, which can be measured using an Electroencephalography (EEG) device. In this study, EEG data collected from 18 healthy individuals through 29 different channels were utilized. To examine spatial attention shifts, the analysis focused on the PO7 and PO8 channels, which are indicated in the literature as being influenced by attention shifts. EEG signals were recorded using 29 standard Ag/AgCl electrodes, referenced to the right mastoid, and sampled at a frequency of 250 Hz.

For feature extraction, Empirical Wavelet Transform (EWT) and Ensemble Empirical Mode Decomposition (EEMD) methods were employed. The extracted features were analyzed using deep learning and machine learning algorithms. Both channel-based and Intrinsic Mode Function (IMF)-based comparisons were conducted. In channel-based comparisons, the analysis emphasized PO7 and PO8 channels, with the PO7 channel providing more accurate results for attention shifts. In IMF-based comparisons, values of 6, 8, 10, and 12 were tested. When EEMD was applied, and one-dimensional time signals were transformed into two-dimensional images, the highest accuracy was achieved with IMF=6.

In algorithm-based comparisons, the analysis revealed that, among machine learning methods, k-NN and decision tree algorithms achieved the highest test accuracy with 100.0%, while among deep learning methods, the GNN algorithm attained a maximum test accuracy of 99.84%.

Key Words : Electroencephalography, EEG, empirical wavelet transform, EWT, ensemble empirical mode decomposition, EEMD, k-NN, SVM, MLP, decision tree, DBN, DNN, CNN, GCN, GNN

Page Number : 79

Supervisor : Assoc. Prof. Dr. Gökhan ALTAN

TEŞEKKÜR

Bu tez çalışmam süresince her konuda, anlayış ve desteğini esirgemeyen, bu akademik yolculukta bana her konuda destek veren ve çalışmalarımda bana yol gösteren danışmanım Doç. Dr. Gökhan ALTAN'a ve tüm hocalarıma ilgi ve yardımlarından dolayı teşekkürü bir borç bilirim. Sevgi ve özverileriyle bugünlere gelmemi sağlayan, hoşgörülerini ile her zaman yanımda olan sevgili anneme, babama, teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	8
2.1. Derin Öğrenme	8
2.2. EEG Nedir	12
2.2.1. EEG analizini baz alan uygulama alanları	16
2.3. EEG Üzerine Gerçekleştirilen Farklı Derin Öğrenme Yaklaşımları	20
2.3.1. EEG üzerine gerçekleştirilen CNN çalışmaları	20
2.3.2. EEG üzerine gerçekleştirilen DBN çalışmaları	21
2.3.3. EEG üzerine gerçekleştirilen DNN çalışmaları	23
2.3.4. EEG üzerine gerçekleştirilen GCN çalışmaları	25
2.3.5. EEG üzerine gerçekleştirilen GNN çalışmaları	26
2.4. Mekansal Dikkat Kayması (Spatial Attention Shift)	28
2.5. EEG Kullanılarak Dikkat Kayması Çalışmaları ve Derin Öğrenme	29
3. MATERYAL VE METOT	30
3.1. Derin Öğrenme	30
3.1.1. Derin inanç ağları (deep belief networks, DBN)	30

	Sayfa
3.1.2. Derin sinir ağıları (deep neural networks, DNN)	31
3.1.3. Evrişimli sinir ağıları (convolutional neural networks, CNN)	33
3.1.4. Grafik sinir ağıları (graph neural networks, GNN)	34
3.1.5. Grafik evrişimli ağılar (graph convolutional networks, GCN)	36
3.2. Geleneksel Makine Öğrenmesi Algoritmaları	38
3.2.1. Karar ağacı (decision tree)	38
3.2.2. Destek vektör makineleri (support vector machines, SVM)	40
3.2.3. En yakın k tane komşu algoritması (k-nearest neighbour, k-NN)	41
3.2.4. Çok katmanlı algılayıcı (multilayer perceptron, MLP)	42
3.3. Öznitelik Çıkartma Yöntemleri	43
3.3.1. Zaman tabanlı analiz	43
3.3.2 Zaman-frekans tabanlı analiz	44
3.3.3. İstatistiksel öznitelik çıkarma	46
3.4. Veriseti	48
3.5. Veriseti Bölütleme Stratejileri	50
3.5.1. Leave-one-out (LOO) çapraz doğrulama yöntemi	50
3.6. Performans Kriterleri ve İstatistiksel Değerlendirme	51
3.6.1. Karmaşıklık matrisi (confusion matrix)	51
3.6.2. Doğruluk (accuracy, acc)	52
3.6.3. Hassasiyet (precision)	52
3.6.4. Duyarlılık (recall)	53
3.6.5. F1 skoru	53
3.6.6. Kayıp fonksiyonu (loss function)	53
3.6.7. R ² skoru (R-kare)	54

Sayfa

3.6.8. Alıcı işletim karakteristiği (receiver operating characteristic, ROC) eğrisi ve eğri altındaki alan (area under curve, AUC)	54
4. ARAŞTIRMA BULGULARI	56
4.1. Strateji 1: Veriseti-1 Kullanılarak Makine Öğrenmesi Yöntemlerinin Uygulanması, Farklı Sınıflandırıcılar Üzerindeki Eğitim ve Test Sonuçlarının Değerlendirilmesi	56
4.1.1. Tek kanal ve tek kişi üzerinde strateji 1 uygulanması	57
4.1.2. PO7 ve PO8 kanalları ve tüm kişiler üzerinde strateji 1 uygulanması	58
4.2. Strateji 2: Veriseti-2 Kullanılarak Transfer Öğrenmesi Yöntemlerinin CNN Tabanlı Çalışan Ön Eğitimli Popüler Modellerle Uygulanarak Derin Öğrenme Üzerinde Eğitim ve Test Sonuçlarının Değerlendirilmesi	60
4.3. Strateji 3: Veriseti-1 Kullanılarak Kanal Bazlı Değerlendirmeler Yapılıp Derin Öğrenme Yaklaşımlarının Daha Anlamlı Olduğunu Göstermeye Yönelik Analizlerin Gerçekleştirilmesi	63
5. SONUÇ VE ÖNERİLER	69
KAYNAKLAR	73

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. P01 kişisine ait Fp1 adlı EEG kanalı üzerinde uygulanan makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları.....	57
Çizelge 4.2. 18 sağlıklı bireye ait PO7 ve PO8 adlı EEG kanalı üzerinde uygulanan makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları.....	58
Çizelge 4.3. Niyet-geri bildirim karşılaştırması.....	61
Çizelge 4.4. Farklı IMF değerlerindeki homojen dağılımlı veri sayıları	62
Çizelge 4.5. Veriseti-2 üzerinde yapılan VGG16 modeli ile elde edilen en yüksek analiz sonuçları.....	62
Çizelge 4.6. Veriseti-2 üzerinde yapılan VGG19 modeli ile elde edilen en yüksek analiz sonuçları.....	63
Çizelge 4.7. Veriseti 2 üzerinde yapılan RESNET50 modeli ile elde edilen en yüksek analiz sonuçları.....	63
Çizelge 4.8. Herhangi bir ön işlem yapılmadan tek katmanlı DBN analiz sonuçları....	64
Çizelge 4.9. Normalizasyon ön işlemi yapılarak tek katmanlı DBN analiz sonuçları.....	64
Çizelge 4.10. Standardizasyon ön işlemi yapılarak tek katmanlı DBN analiz sonuçları.....	65
Çizelge 4.11. Normalizasyon ön işlemi yapılarak iki katmanlı DBN analiz sonuçları..	65
Çizelge 4.12. Normalizasyon ön işlemi yapılarak üç katmanlı DBN analiz sonuçları..	65
Çizelge 4.13. Normalizasyon ön işlemi yapılarak, DNN analiz sonuçları.....	66
Çizelge 4.14. Standardizasyon ön işlemi yapılarak, DNN analiz sonuçları.....	66
Çizelge 4.15. Normalizasyon ön işlemi yapılarak, GNN analiz sonuçları.....	67
Çizelge 4.16. Standardizasyon ön işlemi yapılarak, GNN analiz sonuçları.....	67
Çizelge 5.1. Zaman ile frekans tabanlı açısından ve derin öğrenme ile makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları.....	71

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1 Kafa üzerindeki EEG elektrot yerleşimi.....	13
Şekil 3.1. Karmaşıklık matrisi (confusion matrix).....	52
Şekil 4.1. Verisetindeki beşinci kişinin PO7 kanalı üzerinde IMF-6 sonucunda kaydedilen birinci denemesi için hayır etiketli bir örnek resim	60
Şekil 4.2. Verisetindeki beşinci kişinin PO7 kanalı üzerinde IMF-6 sonucunda kaydedilen birinci denemesi için evet etiketli bir örnek resim	60



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

η	Öğrenme oranı
db	Desibel
hz	Hertz
f_aktivasyon	Aktivasyon fonksiyonu
R^2	R kare
mV	Mili volt

Kısaltmalar

Açıklamalar

AEO	Yapay zeka optimizasyonu
ANN	Yapay sinir ağları
AR	Artırılmış gerçeklik
ARIMA	Otoregresif entegreli hareketli ortalama model
AUC	ROC eğrisinin altındaki alan
BCI	Beyin-bilgisayar arayüzü
BT	Torba ağaç algoritması
CART	Sınıflandırma ve regresyon ağaçları
CNN	Evrişimli sinir ağı
CWT	Sürekli dalgacık dönüşümü
ÇD	Çapraz doğrulama
DBN	Derin inanç ağları
DEAP	Duygu ve fizyoloji değerlendirme
DNN	Derin sinir ağları
DWT	Ayrık dalgacık dönüşümü
EEMD	Topluluk ampirik mod ayrışımı
EOG	Elektrookülografi
ELM	Aşırı öğrenme makinesi

EMD	Ampirik mod ayrıştırma
EWI	Ampirik dalgacık dönüşümü
FC	Fonksiyonel bağlantılılık
FFT	Hızlı fourier dönüşümü
FP	Yanlış pozitif
FPR	Yanlış pozitif oranı
FN	Yanlış negatif
fMRI	Fonksiyonel manyetik rezonans görüntüleme
GAT	Grafik dikkat ağları
GCN	Grafik evrişimli ağlar
GNN	Grafik sinir ağları
HHT	Hilbert-Huang dönüşümü
ICA	Bağımsız bileşen analizi
ID3	Tekrarlı ikilikçi ağaç
IMF	İçsel mod fonksiyonları
IQR	Çeyrekler arası açıklık
k-NN	En yakın k tane komşu algoritması
LDA	Doğrusal ayırım analizi
LMT	Mantıksal model ağacı
LOO	Leave-one-out
LS-SVM	En küçük kare destek vektör makinesi
LTSM	Uzun kısa süreli hafıza
MA	Hareketli ortalama model
MAE	Ortalama mutlak hata
MEG	Manyetoensefalografi
MLP	Çok katmanlı algılayıcı
MRA	Çoklu çözünürlük analizi
MRG	Manyetik rezonans görüntüleme
MSC	Büyüklik-kare koheransı
MSE	Ortalama karesel hata
NB	Naive bayes
N2PC	Negatif-going potansiyel component
OAQFS	Karşıt aquila optimizasyonu tabanlı özellik seçimi
OMTLBP_SMC	Çoklu seviyeli tıknaz lokalleştirilmiş ikili desen

PCA	Temel bileşen analizi
PCC	Pearson korelasyon katsayıları
PSD	Güç spektrumu yoğunluğu
RBM	Sınırlı boltzmann makinesi
Relu	Doğrultulmuş lineer birim
RF	Rastgele orman
RNN	Tekrarlayan sinir ağları
ROC	Alıcı işletim karakteristiği
SDN	Yazılım-tanımlı ağlar
SEED	Duygu sinyal analizi için standart eeg verisi
SOM	Kendinden organize olan haritalar
STFT	Kısa zamanlı fourier dönüşümü
SVM	Destek vektör makineleri
TCNN	Transformer ve konvolüsyonel sinir ağları
TN	Doğru negatif
TMS	Transkraniyal manyetik stimülasyon
TP	Doğru pozitif
TPR	Doğru pozitif oranı
tDCS	Transkraniyal doğru akım stimülasyonu
VMD	Varyasyon mod ayrıştırma
VR	Sanal gerçeklik
WNN	Dalgacık tabanlı sinir ağı
WT	Dalgacık dönüşümü
WVD	Wigner-ville dağılımı

1. GİRİŞ

Nörolojik sinir hücreleri, birbirleri ile sürekli etkileşim halinde bulunan, biyolojik geçerlilikte sistemin en basit fonksiyonel yapılarıdır. Sinir hücreleri arasındaki bu etkileşim, elektriksel aktivite olarak tanımlanır. Elektroensefalografi (EEG), beyindeki elektriksel aktivitenin ölçülmesi ve kayıt altına alınmasını sağlayan biyomedikal sinyal türüdür. EEG, ilk yıllarında invazif olarak deri altı müdahalelerle elde edilirken günümüzde non-invaziv olarak uygulanan bir yöntemdir. Bu yöntemde, kafadaki saçlı deriye pasta denilen kaygan ve iletken bir sıvı yardımı ile elektrotlar yapıştırılır ve beyindeki sinir hücrelerinin birbiri ile etkileşimi sonucunda ortaya çıkan elektriksel aktivitelerin ölçümü, mili volt (mV) seviyesinde gerçekleştirilir. EEG, epilepsi, felç, konuşma ve dil bozuklukları, demans gibi nörolojik bozuklukların teşhisinde, uyku evrelerinin incelenmesi, uyku bozukluğu teşhisinde, beyin-bilgisayar arayüzlerinde (BCI) bireylerin düşüncelerini cihazlara veya protezlere aktarımında, beyin işlevleri ve motor/bilişsel süreçlerin araştırılmasında gibi birçok alanda kullanılır. Mekansal dikkat kaymaları (Spatial Attention Shifts), farklı nörolojik uyaranlara bağlı olarak bireyin dikkatinin bir işlevden farklı bir alana yönlendirilmesi sürecidir. Bu süreç, çevresel uyarıcılara veya görev gereksinimlerine yanıt olarak istemsiz olarak gerçekleşir. Görsel bilgilerin daha etkili ve daha verimli bir şekilde işlenmesine olanak tanır. Mekansal dikkat kaymaları, yaygın olarak 2 ana grupta incelenebilir: Seçici (top-down) ve Spontan (bottom-up) dikkat. Seçici dikkat, belirli bir göreve odaklanmak gibi içsel ipuçlara/niyetlere dayanırken; spontan (bottom-up) dikkat, ani bir hareketin veya beklenmedik kıs süreli uyaran değişikliğine bağlı olarak bireyin nörolojik fonksiyonunun farklı bir uyaran geçmesi süreci gibi, dışsal uyarılara yanıt olarak gerçekleşir (Delibalta, 2022).

Mekansal dikkat kaymalarını tespit edebilmek için kullanılan tanı araçları içerisinde EEG, manyetoensefalografi (MEG), fonksiyonel manyetik rezonans görüntüleme (fMRI), göz takip cihazları, nöroplastik değerlendirmeler, BCI, makine öğrenmesi, derin öğrenme, yapay zeka, sanal gerçeklik (VR), arttırılmış gerçeklik (AR), transkraniyal manyetik stimülasyon (TMS), transkraniyal doğru akım stimülasyonu (tDCS) gibi birçok farklı yöntem kullanılmaktadır. EEG, mekansal dikkat kaymalarının incelenmesi için güçlü ve hassas bir araçtır ve yaygın olarak kullanılır. EEG'nin yüksek zaman çözünürlüğü sayesinde, dikkatin nasıl ve ne zaman yönlendirildiğini incelenebilmektedir. Mekansal

dikkat kaymalarında EEG kullanımı sayesinde nörofizyolojik temellerinin anlaşılması sağlanabilmektedir.

EEG sinyalleri, genellikle nörolojik çalışmaların bir parçası olarak kullanılır. Ancak, bu çalışmada EEG sinyallerini nörolojik perspektiften değil, mühendislik perspektifinden analiz edilmesi amaçlanmıştır. EEG sinyallerini hem zaman hem de frekans tabanlı elde edilecek ayırıcı öznitelikler kullanılarak daha etkili ve verimli bir şekilde analiz etmek için derin öğrenme ve makine öğrenmesi yöntemlerinin kullanması planlanmıştır. Yapılan araştırmalarda, medikal görüntü ve sinyallerde, makine öğrenmesi ve derin öğrenme algoritmaları özellikle sınıflandırma ve destekleyici tanı süreçlerin için kullanılabilecek en önemli araçlardır. Sinyal işleme alanındaki analizlerle, EEG sinyallerinin daha hassas ve doğru şekilde yorumlanmasını ve farklı nörolojik çıkarımlar gerçekleştirilmesi hedeflenmektedir. Derin öğrenme ve makine öğrenmesi algoritmaları, insan gücüyle analiz edilemeyecek kadar büyük veri ve detaylı verisetlerini işleyebilir ve bu verilerdeki gizli kalıpları ve sistematik anomalilere sebep olan anlamsal ilişkileri lineer olmayan modeller, optimizasyon teknikleri ve farklı aktivasyon fonksiyonları ile ortaya çıkarabilmektedir. Derin öğrenme ve makine öğrenmesinin bu avantajları, dikkat kaymaları gibi nörolojik süreçlerin daha iyi anlaşılmasını ve yönetilmesini sağlayacağı düşünülmektedir. Mekansal dikkat kayması olan bireylerden elde edilen çok kanallı EEG sinyallerinden öznitelik çıkartma işlemleri için Ampirik Dalgacık Dönüşümü (Empirical Wavelet Transform, EWT) ve Topluluk Ampirik Mod Ayırışımı (Ensemble Empirical Mode Decomposition, EEMD) yöntemleri kullanılarak; elde edilen yeni frekans modülasyonlarından çıkarılan istatistiksel ve entropi bazlı öznitelik kümeleri, geleneksel makine öğrenmesi algoritmalarından, karar ağacı (Decision tree), destek vektör makineleri (Support vector machines, SVM), en yakın k tane komşu algoritması (k-nearest neighbour, k-NN) ve çok katmanlı yapay sinir ağları (Artificial Neural Networks, ANN, MLP); Derin öğrenme algoritmaları olarak evrişimli sinir ağları (Convolutional Neural Networks, CNN), derin inanç ağları (Deep Belief Networks, DBN), derin sinir ağları (Deep Neural Networks, DNN), grafik evrişimli ağlar (Graph Convolutional Networks, GCN) ve grafik sinir ağları (GNN) yöntemleri kullanılarak analiz edilmiştir.

EEG üzerinden elde edilen morfolojik özellikler genellikle nörolojik çalışmalar kapsamında sıklıkla uygulanmaktadır. Tez çalışması kapsamında temel motivasyonumuz, EEG sinyallerini mühendislik perspektifiyle analiz ederek, elde edilecek zaman ve frekans

tabanlı çıkarılan özniteliklerin derin öğrenme ve makine öğrenmesi algoritmaları ile analiz edilmesini sağlayarak farklı modellerin mekânsal dikkat kaymasının tespiti üzerine etkisini araştırmaktır. Bu yaklaşımla, EEG tabanlı çalışan nörolojik çalışmaların bilgisayar destekli yöntemlerle daha ileriye taşınması, sinyallerin daha detaylı analiz edilmesi, farklı kanal ve kişilerden alınan sinyaller arasındaki korelasyonun araştırılması, yenilikçi ve güncel çözümler geliştirilmesini sağlamaktır.

EEG sinyallerinin bilgisayar destekli analizi ve farklı nörolojik anomalilerin sınıflandırılması üzerine birçok farklı algoritma geliştirilmiştir. Bu çalışmada, EEG sinyalleri üzerindeki zaman ve frekans tabanlı modülasyon ayrıştırma yöntemi olan EWT ve zaman tabanlı ayrıştırma yöntemi olan EEMD kullanılmıştır.

EEG sinyalleri üzerinde ön işlem süreci, verilerin hazır hale getirilerek frekans indirgenmesi, tek boyutlu sinyallere ayrıştırma ve dönüşüm süreçlerinin uygulanması, çıkarılan yeni modülasyonlardan istatistiksel özniteliklerin çıkarılması ve dikkat kayması olup olmadığının tespitini yapan adımları içeren klasik örüntü tanıma süreci gerçekleştirilmiştir. Verisetinde bulunan 18 tane nörolojik olarak rahatsızlığı bulunmayan sağlıklı bireyden alınan, 29 farklı kanaldan kaydedilmiş EEG verileri üzerinde EWT yöntemi kullanılarak ortaya çıkan yeni sinyallerden elde edilen 30 öznitelik kullanılarak konvensiyonel sınıflandırıcılar denenmiştir. Sınıflandırıcılar içerisinde k-NN, karar ağacı, SVM, MLP algoritmaları ile analizler gerçekleştirilmiştir.

EEMD yöntemi ile çıkartılan öznitelikleri ise, önce derin öğrenme algoritması olan DBN algoritması ile analiz edildi. Ardından 1 boyutlu EEG sinyalleri görüntüye dönüştürülerek 2 boyutlu hale getirilmiştir. Bu görüntüler CNN algoritması ile analiz edildi ve öğrenmenin aktarımı yaklaşımı baz alınarak popüler ön eğitilmiş modeller üzerinde yeniden eğitimler gerçekleştirilmiştir. Frekans tabanlı EWT analizi ile elde edilen dalgacık modülasyonlarından elde edilen öznitelikler yerine artık zaman tabanlı EEMD ile analiz yaparak yeni öznitelik setleri oluşturulmuştur. Bu sayede analizler üzerinde yüksek başarımlara ulaşılmış olan standart yapı elde edilmiştir. EEG verilerinin mekânsal dikkat kayması kaynaklı kullanımını baz alan verisetinin ilk kez kullanıldığı çalışmada, PO7 ve PO8 (24. ve 28. kanal) kanalları için görsel uyaranlarda dikkat kayması anlamlı olduğu vurgulanması sebebiyle, tez çalışmaları kapsamında gerçekleştirilen analizlerde de bu 2 kanal üzerinden çalışmalar gerçekleştirilmiştir. N2PC (N2-posterior-contralateral) analizi

yapılmıştır. EEMD yöntemi farklı içsel mod fonksiyonu (Intrinsic Mode Functions, IMF) sayıları için ele alınarak modülasyon sayıları 6, 8, 10 ve 12 olacak şekilde ele alınarak daha detaylı karşılaştırılmak hedeflenmiştir. Farklı IMF değerleri için dikkat kaymasının tespiti ve karakterize edilmesinde yeni oluşan sinyallerin anlamını yitirip yitirmediğinin kontrolü yapılmıştır.

EEG kayıtları toplanırken sınırlı sayıda dikkat kayması anı yer alırken, bu anlara ait zaman ve test değeri (trial) çıkarılmıştır. Tüm EEG kayıtları ele alındığında homojen olmayan mekânsal dikkat kayması var (YES) ve yok (NO) verilerine ulaşılmıştır. Buna bağlı olarak homojen her deneğe ait değer toplanırken aynı oturumdan sayıları birbiriyle aynı olacak şekilde kayıtlar seçilmiştir. Bu işlem yürütülürken rastsallıktan uzak durulmasının sebebi nörolojik faaliyetlerin zamana bağımlılığının ve mekânsal değişime bağımlılığının yüksek olmasından kaynaklanmıştır. Ayrıca her kişiye ait dikkat kayması sayıları aynı olmadığı için YES ve NO sınıfları arasında homojen bir dağılım elde etmek adına aynı kişinin farklı oturumlara ait kayıtları kullanılmıştır. Kişiler arasından 2, 3, 5, 7, 8 ve 14 numaralı denekler seçilerek analizlere devam edilmiştir. Bu sayede bilimsellikten uzak rastsal değerlendirmenin önüne geçilmiş olup, veri sayılarında eşlik sağlanmış ve makine öğrenmesi ve derin öğrenme yaklaşımlarının test durumunu aşırı öğrenmesi (overfitting) durumunun önüne geçilmiştir. Elde edilen bu dağılımlar çerçevesinde kişi bazlı, EEMD sonrası elde edilen modülasyonlardan IMF bazlı ve her strateji için kanal bazlı olarak veriseti oluşturulmuştur. Yeni oluşturduğumuz verisetleri üzerinde farklı stratejilere bağlı kalınarak CNN algoritmalarından olan VGG16, VGG19 ve RESNET50 modelleri, geleneksel makine öğrenme algoritmaları, lineer yöntemler, DBN, DNN, GCN ve GNN ile analizler gerçekleştirilmiştir.

Son aşamada, EEG sinyallerine EWT uygulanarak farklı dalgacık cevaplarından elde edilen özniteliklerle elde edilen veriseti üzerinde analizler gerçekleştirilerek, öznitelik merkezli normalizasyon ve standardizasyon işlemleri gerçekleştirilmiş ve verisetleri analize hazır hale getirilmiştir. Nörolojik olarak ispatlanmış mekana bağlı dikkat kaymasının anlamlı olduğu kanallar olan PO7 ve PO8 kanalları (24 ve 28. Kanallar) analizlerde odak kanallar olarak belirlenmiştir. PO7 (24. Kanal) adlı kanalın eğitim verisi için, gürültü temizleme işlemi sonrası 2147 kayıt silinip geriye 27337 kayıt bırakılmıştır. PO7 kanalının test veriseti için ise aynı işlem tekrarlandığında 458 kayıt silinip geriye 6130 kayıt kalmıştır. PO8 kanalının eğitim verisinde, 1544 kayıt silinmiş ve 20819 satır

kalmıştır. PO8 kanalının test verisinde ise, 382 kayıt silinmiş ve 4908 kayıt kalmıştır. İki kanalın eğitim ve test verisetlerinde, her biri farklı istatistiksel ve entropi bazlı öznitelikleri temsil edecek şekilde 27 sütun ve 1 etiket (evet/hayır) kolonu olarak yer almaktadır.

Bunun sonucunda ortaya çıkan eğitim ve test verisetleri üzerinde; tek, iki ve üç katmanlı DBN algoritması, tek, iki katmanlı ve üç katmanlı GCN algoritması, tek, iki ve üç katmanlı GNN algoritması, k-NN, SVM, rastgele orman (random forest, RF), karar ağacı algoritmaları ile analizler yapılmıştır. Böylece, makine öğrenmesi ile elde edilen başarılar ile güncel olan derin öğrenme modelleriyle de analiz edilerek başarı durumları/sonuçları kıyaslanmıştır.

Tez çalışması kapsamında mekana bağlı dikkat kayması problemi, farklı kişilerden alınmış EEG kayıtları üzerinde, anomaliler tanımlama yaklaşımları göz önünde bulundurularak ilk aşamada EWT yöntemi ile analiz edilmiş, daha sonrasında buradan çıkarılan farklı modülasyonlar ile CNN, DNN, DBN, GCN ve GNN algoritmaları denenerek derin öğrenmenin frekans ve zaman tabanlı elde edilen öznitelikler üzerindeki sınıflandırıcı başarımları verilmiştir. Gerçekleştirilen tüm analizler ve kullanılan bir boyutlu ve iki boyutlu (1D ve 2D) verisetleri hakkında detaylı açıklamalar, bu analizlere yönelik araştırma bulguları ve tartışma bölümleri sonraki başlıklar altında detaylı şekilde anlatılmıştır. Bu çalışmadan elde edilen tüm verileri, kodlar, betikler ve deneysel sonuçların <https://github.com/gulcininat> github adresinde paylaşılması planlanmaktadır.

Bu tez, EEG üzerinden yapılan istatistiksel analizlerin ötesine geçerek mekansal dikkat kaymalarını tespit etmede makine öğrenmesi ve derin öğrenme modellerinin kullanımı ve bunların kıyaslanması üzerine odaklanmaktadır. Geleneksel istatistiksel yöntemleriyle elde edilen önem derecesi analiz edilen kişi sayısının belirli bir aralıkta olmasına ve çeşitliliğine bağlıdır. Bu durumda analizlerin doğruluğunu ve hızını kısıtlamaktadır. Ancak, son yıllarda gelişen makine öğrenmesi ve derin öğrenme algoritmaları, bu sınırlamaların üstesinden gelerek daha hızlı, öz seçiciliği yüksek ve spesifik tespitler yapılmasına olanak sağlamaktadır.

Tezin temel özgünlüklerinden biri, mekansal dikkat kaymalarının tespitinde EEG kayıtları üzerinde klasik istatistik haricinde makine öğrenmesi algoritmalarının kullanılmasıdır. Bu yaklaşım, geleneksel yöntemlere kıyasla daha yüksek doğruluk ve başarı oranları elde

edilmesini sağlamaktadır. Ayrıca, derin öğrenme algoritmalarının EEG verileri üzerinde uygulanması ve bu algoritmaların performanslarının karşılaştırılması da bu tezin özgünlüklerinden biridir. EEG verilerinin analizine derin öğrenme tekniklerini dahil ederek, dikkat kaymalarının daha detaylı ve kapsamlı bir şekilde incelenmesini, bilgisayar destekli sistemlerle desteklenmesini, karar destek mekanizmalarına dönüştürülmesini ve sonuçların daha hızlı olarak kesinliği yüksek yöntemlerle desteklenerek tespitler yapmasını amaçlamaktadır.

Tez kapsamında, EEG sinyallerini hem 1 boyutlu zaman seri sinyalleri olarak ele alınmış hem de bu sinyalleri 2 boyutlu resimlere dönüştürerek görüntü tabanlı çalışan öznelik öğrenimi ve transfer öğrenme yaklaşımlarıyla analizlerini yaparak veya güncel yöntemlerin başarımlarına etkisinin kıyaslamaları gerçekleştirilmiştir. Çalışmanın bir diğer farklı ve özgün noktası ise EEG'nin farklı kanallarından elde edilen verilerin analiz edilmesi ve analizlerin karşılaştırılması; dikkat kaymalarının hangi kanallar üzerinde daha belirgin olduğunu göstermemize yardımcı olmuştur.

Veri sayısının az olması, nörolojik çalışmalarda sıkça karşılaşılan bir sorundur. Bu sorunu aşmak için, analiz öncesi süreçlere çeşitli veri artırma yöntemleri entegre edilmiştir. Özellikle derin öğrenme algoritmaları ile bu sorunun üstesinden gelinmiştir. Veri artırma (data augmentation) teknikleri kullanılarak, daha yüksek sayıda örnek içeren ve baz alınan sinyallerin farklı domainlerdeki modülasyonlarını içeren verisetleri oluşturulmuştur. Böylece, elde edilen sonuçların güvenilirliğini ve genellenebilirliğini artırılmıştır. Çalışmamızda kullanılan farklı yöntemlerle elde edilmiş veri setleri şunlardır:

- Veriseti-1: EEG sinyallerine EWT kullanılarak elde edilen öznelik kümesidir. 18 sağlıklı bireyden alınan toplam 29 farklı kanaldan EEG sinyallerinin üzerinde EWT yöntemi kullanılmıştır. Toplam 30 öznelik çıkartılmış ve konvensiyonel işlemler kullanılmıştır
- Veriseti-2: EEG sinyallerine EEMD uygulayarak IMF görünümünün 2 boyutlu grafiklere dönüştürülmesidir. 18 sağlıklı bireyden alınan toplam 29 farklı kanaldan EEG sinyallerinin üzerinde EEMD yöntemi kullanılmıştır. Tek boyutlu sinyal modülasyonları, grafiğe dönüştürülerek, iki boyutlu hale getirilmiş ve resim olarak kaydedilmiştir. PO7 ve PO8 (24. ve 28.) kanallar üzerinden elde edilen IMF modülasyonları sayıları 6, 8, 10 ve 12 alınarak farklı çıktılarının etkisi araştırılmıştır.

Bu stratejiler sayesinde veri sayımızı önemli ölçüde artırarak farklı veri tipleri ve miktarları ile analizler gerçekleştirilmiştir. Özellikle EWT açısından veri sayımızı artırarak daha geniş bir analiz yapma olanağı elde edilmiştir.

Çalışmalarda kullanılan farklı verisetleri üzerinde çeşitli stratejiler denenmiştir. Bu stratejiler şunlardır:

- Strateji 1: Veriseti-1 kullanılarak makine öğrenmesi yöntemlerinin uygulanması farklı sınıflandırıcılar üzerindeki eğitim ve test sonuçlarının değerlendirilmesi
- Strateji 2: Veriseti-2 kullanılarak transfer öğrenmesi yöntemlerinin CNN tabanlı çalışan ön eğitilmiş popüler modellerle uygulanarak derin öğrenme üzerinde eğitim ve test sonuçlarının değerlendirilmesi,
- Strateji 3: Veriseti-1 kullanılarak kanal bazlı değerlendirmeler yapıp derin öğrenme yaklaşımlarının daha anlamlı olduğunu göstermeye yönelik analizlerin gerçekleştirilmesi.

Tezin ilerleyen bölümlerinde detaylandırılmış farklı öznelik çıkartma teknikleri ile elde edilmiş olan verisetleri, makine öğrenmesi ve derin öğrenme algoritmaları üzerine yapılan çalışmalar hakkında literatür taraması kısmı yer almaktadır. EEG sinyalleri ve mekansal dikkat kayması ile ilgili yapılmış çalışmalar hakkında detaylı bilgi verilmiştir. Materyal ve metot kısmında bu çalışmada kullanılan sınıflandırıcılarda derin öğrenme algoritmaları, makine öğrenmesi algoritmaları, ayrıştırma yöntemlerinden EWT ve EEMD teknikleri açıklanmıştır. Öznelik çıkartma algoritmalarından EWT hakkında farklı parametreler içerisinden değerler paylaşılmıştır. Kullanılan EEG kayıtlarının toplanması, bilimsel ve teknik özellikleri; sinyallerin kaynağı, kullanılan kanallar ve örnek sayıları, filtreleme ve ön işlem basamakları gibi tüm özellikler detaylıca açıklanmıştır. Tez'in ilerleyen bölümlerinde, her bir strateji için kullanılan 2 farklı veriseti üzerinde elde edilen sonuçlar paylaşarak, bu sonuçlar hakkında karşılaştırma, farklı makine öğrenmesi ve derin öğrenme algoritmalarının başarımlarına üzerine etkisi tartışılmıştır.

2. LİTERATÜR TARAMASI

2.1. Derin Öğrenme

Çok büyük verilerin insan gücüyle işlenmesi veya analiz edilmesi oldukça masraflı ve uzun sürelerde sonuç alınmasına sebep olan zorluklar içermektedir. Bu sebeple; Makine öğrenmesi, belirli bir probleme özgü geçmiş verileri kullanarak gelecek karşılaşılabilecek benzer veya yeni veriler hakkında tahminlerde bulunabilmeyi sağlayan bir yöntemdir. Örneğin, el yazısından kişileri tanıma, nesne tespiti, zaman serilerinden regresyon analizi, kredi taleplerini değerlendirmesi, tıbbi karar destek mekanizmaları oluşturma, görüntüleme sistemleri tasarımları ve benzeri gibi birçok konuda makine öğrenmesi, mevcut verileri analiz ederek optimizasyon sonrası oluşturdukları gizli fonksiyonu, sistemin daha önceden hiç görmediği verilerle tahmin etmeye çalışır.

Derin öğrenme, makine öğrenmesinin paylaşımlı ağırlık ve gelişmiş öğrenme aktarımı yaklaşımlarını baz alan, kendi içerisinde öznitelik tanıma yetkinlikleri bulunduran bir alt dalıdır. İnsan beynindeki sinir hücrelerinin işleme mantığı ile sinir ağlarını taklit eden yapay sinir ağları modeli oluşturulmuştur. Bu yapı aracılığıyla büyük veri kümelerinden, öğrenme süreci gerçekleşir. Bu sayede makineler, insan gibi davranışlar (görme, konuşma, karar verme gibi karmaşık davranışlar) gösterebilir (Tang ve diğerleri, 2019). Derin öğrenme, bilgisayarlı görü, ilişkisel bağlam oluşturma ve tahmin süreçleri gibi birçok alanda etkinliğini ispatlamış güncel bir alandır.

Temel kavramları şu şekildedir:

- Yapay sinir ağları: Derin öğrenme yönteminin yapı taşlarıdır. Birbirlerine çeşitli yerlerden bağlı sinir ağları, katmanlar halindedir. Veri öncelikle giriş katmanından girer, her bir katmandan sırası ile geçerek, çıkış katmanına ulaştığında en soyut temsiline dönüşerek bilgiyi çıkarır.
- Derinlik: Derin öğrenmede, derin terimi yapay sinir ağlarındaki gizli katman sayılarını ifade eder. Gizli katman sayısı arttıkça, derin öğrenme modeli daha karmaşık problemleri veya ilişkileri daha rahat çözme yeteneğine sahip olabilir. Katman sayısı ile başarımlar arasındaki doğru orantı ilişkisi, kesin olarak ispatlanmamıştır. Literatürdeki bazı çalışmalarda ve bizim de bu tezde yaptığımız çalışmada gördüğümüz, katman sayısı arttıkça başarımlar artmakta fakat sonsuza kadar gitmemekle beraber diğer değişkenlerin de bunu etkilediği görülmektedir.
- Öğrenme: Derin öğrenme modelleri, büyük veriler üzerinde eğitilir ve eğitim verisi haricindeki başka veriler üzerinde test edilir. Test edilirken, derin öğrenme modelinin tahminleri ile test verisinin gerçek yanıtı karşılaştırılır. Ardından

oluşturulan modeldeki parametreler bu 2 veri (gerçek yanıt ve tahmin) arasındaki farkı en aza düşürecek şekilde model güncellenir.

Derin öğrenme, yapay sinir ağları adı verilen hesaplama modelleri kullanarak, verilerden karmaşık ilişkileri otomatik olarak öğrenme yöntemidir. Bu model, genellikle büyük miktarda veri kullanarak, insanların algılaması zor olan desenleri ve bağlantıları keşfetmek için kullanılır. Derin öğrenme modelleri, veri analizi, görüntü işleme, doğal dil işleme, otomatik sürüş ve robotik gibi birçok alanda kullanılır (Çalışkan ve Demir, 2022). Bu modeller, geleneksel makine öğrenmesi algoritmalarından daha yüksek doğruluk oranlarına ve daha iyi sonuçlara sahip olabilirler.

Çalışkan ve Demir, (2022), suçlu davranışlarını tespit etmek için gönüllü kişiler ile video çekimleri ile bir veriseti oluşturmuşlardır. Elde ettikleri verisetini amaca uygun şekilde temizleme, etiketleme ve normalize etme işlemleri gerçekleştirip, test ve eğitim verilerini ayırmışlardır. DarkNet ve YOLO (You Only Look Once) kullanarak %72,1 F1 Skora ulaşmışlardır.

Aslan (2022), Manyetik rezonans görüntülüne (MRG) yönetime ile elde edilen görüntüler üzerinde MobilNetV2 derin öğrenme modeli ve k-NN algoritması kullanarak deneysel çalışmalar gerçekleştirmiştir. Beyin tümörlerinin tespitinde, aynı verisetinin kullanıldığı diğer çalışmalara göre daha yüksek bir başarımla olan %96,44 doğruluk elde etmişlerdir.

Ullah ve diğerleri (2021), kalp ritimleri üzerine olan açık kaynaklı iki veriseti üzerinde aritmiyi sınıflandırmak amacı ile derin öğrenme yöntemlerini kullanmışlardır. CNN algoritması hem CNN hem LSTM algoritması; CNN, Uzun Kısa Süreli Hafıza (Long Short term Memory, LSTM) ve Attention modeli ile 3 farklı şekilde analizler gerçekleştirmişlerdir. Sadece CNN sonucunda %99,12; hem CNN hem de LSTM modeli sonucunda %99,3; CNN, LSTM ve Dikkat Modeli sonucunda %99,29 doğruluk elde etmişlerdir.

Altan, Kutlu ve Allahverdi (2016a), inme hastalarında beyin aktivitelerini sınıflandırmak için SCP eğitimini kullanarak bir araştırma yürütmüşlerdir. Bu amaçla, 10 Hz bant geçiren bir filtre ve Hilbert Huang dönüşümü ile öznitelik çıkarma yöntemleri kullanılmıştır. Sınıflandırma yapmak için derin öğrenme yöntemlerinden biri olan DBN yöntemini uygulamışlar ve yüzde 91,15 doğruluk elde etmişlerdir.

Shim ve diğeri (2016), 5 kadın ve 23 erkek olmak üzere toplam 28 kişiden 47 set ham veri şeklinde bilek hareketlerinin (yukarı, aşağı, sağ, sol ve dinlenme olmak üzere toplam 5 farklı hareket) EMG sinyallerinden oluşan bir veriseti hazırlamışlardır. Bu verisetinden 11750 öznitelik seti elde etmişlerdir. DBN ve bu algoritma yöntemin varyasyonlarından olan böl/birleştir derin inanç ağları (SM-DBN) kullanarak 2 farklı sonuç elde etmişlerdir. DBN modeli ile ortalama %88,00 doğruluk elde ederken, SM-DBN ile ortalama %89,29 doğruluk elde etmişlerdir.

Dhiman ve diğeri (2022), turuncgillerin fotoğraflarını içeren bir veriseti kullanmışlardır. Verisetini önce etiketli görüntü yazılımı kullanarak kutucuklar ile bölgeleri sınırlandırmışlardır. Derin öğrenme yöntemlerinden biri olan DNN modelini turuncgillerin yüksek, orta, düşük ve sağlıklı şeklinde etiketleri ile sınıflandırma gerçekleştirmişlerdir. VGGNet ön eğitilmiş modeli ile birlikte, en düşük etiketini önce %99 ardından en yüksek etiketini %98 doğruluk ile tespit edebilmiştir. Orta etiketini %97; sağlıklı etiketini ise %96 doğruluk ile sonuçlandırmışlardır. Çalışmada elde edilen yüksek başarımlar ile DNN algoritması ile turuncgiller veriseti üzerinde etkili bir yöntem olduğu görülmektedir.

Wang, Cao, Chen, Pan, Li, ve Wang (2023), bu makalelerinde durum izleme ve veri odaklı model bazlı rüzgar türbini hata teşhisi için bir correlation-GCN üzerine çalışmışlardır. Çalışmalarında rüzgar türbini hatalarını tahmin etmek için yeni bir metodoloji geliştirmek için correlation-GCN yöntemi önermişlerdir. Durum izleme stratejisi olarak SCADA verilerini giriş verisi olarak ayarlama yapmışlardır. Pearson korelasyon katsayısını durum parametreleri arasında bağlanma seviyelerini niceliksel olarak hesaplamak için baz alarak sıcaklık haritası tasarlamışlardır. Haritayı CNN modelinin giriş verisi olarak kullanmak amacıyla bir görüntü oluşturmak için yeniden yapılandırmışlardır. Son olarak da bunu iki pratik hata, correlation-GCN yönteminin performanslarını incelemek için örnek olarak göstermişlerdir. Yaptıkları çalışma sonucunda hata teşhisinin doğruluğunun yaklaşık %90'a ulaşabileceği sonucunu elde etmişlerdir.

Ravinder ve diğeri (2023), çalışmalarında GCN ve GNN mimarisi kullanarak beyin tümörü sınıflandırması üzerine incelemeler yapmışlardır. Çalışmalarındaki amaçları görüntü verilerinde öklidyen olmayan mesafelerin dikkate alınmaması ve geleneksel modellerin piksel yakınlığına dayalı piksel benzerliğini öğrenme yetersizliğine yeni bir alternatif çözüm aramaktır. Çalışmalarında GCN modelini kullanarak bulgular elde

etmişlerdir. Önceden evrişimli hale getirilmiş bir grafik girdisi alan 26 katmanlı bir CNN ile birleştiren yeni bir teknik ile geliştirip yakınlardaki düğümlerden bilgi toplayarak düğüm özelliklerini değiştirerek grafikler oluşturup giriş 26 katmanlı CNN matrisleri olarak bizlere sunulmuştur. Çalışmalarda farklı eğitim süreçleri için çeşitli özelliklere sahip ağ önerilmiş en yüksek doğruluk oranı %95,01 olarak elde etmişlerdir.

Wu ve diğerleri (2024), çalışmalarında GNN karakterizasyonuna yönelik kapsamlı bir derleme sunmuşlardır. GNN modelleri üzerine yapılan araştırmalarda, SHoGNN, DHoGNN, SHeGNN ve DHeGNN gibi farklı GNN türlerinin performans özellikleri çeşitli boyutlarda incelemişlerdir. Bu modelleri, veri işleme ve hesaplama maliyetleri, bellek kullanımı, iletişim ihtiyaçları, paralellik kapasitesi ve yürütme sınırları gibi 6 temel kriter doğrultusunda sistematik olarak karşılaştırılmıştır:

- Zaman açısından SHoGNN'lerin veri yükleme, örnekleme ve komşu toplama aşamalarında; DHoGNN'lerin ise grafik ve zaman kodlama aşamalarında yoğun kaynak kullanımı gerektirdiği görülmektedir. SHeGNN ve DHeGNN'lerde ise semantik grafik oluşturma ve komşu toplama aşamaları en çok zaman harcanan işlemler olarak öne çıkmaktadır.
- Hesaplama paternleri açısından, tüm modeller yapısal ve semantik bilgileri yakalamak için grafik-topoloji tabanlı ve MLP tabanlı işlemlere ihtiyaç duymaktadır. Ancak DHoGNN ve DHeGNN'ler, zaman kodlaması için ek olarak RNN tabanlı işlemlere gereksinim duyar. Ek olarak, bu dört modelde de grafiğin büyüklüğü ve özellik boyutu arttıkça hesaplama miktarının arttığı saptanmıştır.
- Bellek kullanımı açısından ise GNN modelleri, grafik-topoloji tabanlı ve RNN tabanlı işlemler nedeniyle düzensiz bellek erişimleriyle karşı karşıya kalmakta ve aynı zamanda MLP tabanlı işlemler nedeniyle düzenli bellek erişimlerini de barındırmaktadır. DHoGNN ve DHeGNN, dinamik grafikleri işlemeye ek bellek kullanımına ihtiyaç duyar.
- İletişim açısından, bu GNN modellerinde düzensiz bağlantılar nedeniyle rastgele veri transferleri ve düzensiz tepe dağılımları gözlenmektedir. SHoGNN ve SHeGNN, komşu tepe özelliklerini aktarırken; DHoGNN ve DHeGNN, grafik topolojisinin evrimi ve tepe özellikleri üzerine yoğunlaşır.
- Paralellik potansiyeli bakımından tüm modeller, mini-partiler ve alt grafikler arasında paralel işleme kapasitesine sahiptir. Ancak SHeGNN ve DHeGNN'ler farklı semantik grafikler arasında; DHoGNN ve DHeGNN'ler ise anlık grafik güncellemeleri arasında paralellikten yararlanabilir.
- Yürütme sınırları açısından ise bu modeller, yapısal grafik özelliklerinin yanı sıra, semantik ve zamansal bilgiyi de dikkate alarak hibrit bir yürütme yapısı sergilemektedir. Grafik-topoloji tabanlı veya RNN tabanlı işlemler bellek sınırında çalışırken, MLP tabanlı işlemler ise hesaplama sınırında çalışmaktadır.

Dhadhania ve diğerleri (2024), çalışmalarında dinamik şekilde ağ davranışlarını yakalamak ve geniş ölçekli ağ verilerinden karmaşık örüntüleri öğrenme yetenekleri olması sebebiyle

GNN ve Yazılım-tanımlı Ağlar (Software-defined Networking, SDN) yöntemlerini anomali tespiti için kullanmışlardır. Ağ anomali tespiti için SDN ve GNN'nin birleştirilmesi, anomali tespitinin doğruluğunu ve verimliliğini arttırdığını saptamışlardır. SDN'nin üzerine GNN entegrasyonunun ağ anomali tespiti için çeşitli eğilimlerini, sorunlarını ve zorluklarını ele almışlardır. SDN'nin ağ izleme sürecinde ayrıntılı kontrol ve programlanabilirlik sağlama avantajları dikkat çekmektedirler. Aynı zamanda, GNN ağ davranışını bir grafik olarak modelleyebilmekte ve grafik yapıdaki verilerden temsiller öğrenebilmektedirler. DoS saldırısı tespiti üzerine SDN tabanlı yaklaşımlarının %97 doğruluk ile tespit etmeyi başarmışlardır.

2.2. EEG Nedir

İnsan sinir sisteminde yaklaşık 100 milyar sinir hücresi bulunur ve bu hücrelerin büyük bir kısmı beyindedir. İnsan beyninin karmaşıklığı ve gizemli yapısı, uzun yıllardır araştırma konusu olarak devam etmektedir. Beynin nasıl çalıştığını anlamak, sinirlerin birbirleri arasındaki iletimi, insanların düşünme süreçleri, davranışları, bilinçli olmak, bilinç kaybı gibi birçok konuyu çözmek büyük önem taşımaktadır. Beyin aktivitelerini anlamak için geliştirilen en önemli araçlardan biri EEG cihazıdır. Her bir beyin hücresi 5000-50000 tane sinir hücresi ile etkileşim halindedir. Bu etkileşim gerçekleşirken beyinde elektriksel dalgalanmalar meydana gelir. EEG cihazı yardımı ile canlı üzerindeki beyinde oluşan bu elektriksel dalgalanmalar ölçülür ve beyin fonksiyonları hakkında detaylı bilgi edinilir. EEG ölçümü, elektrotların saçlı deriye pasta adı verilen sıvı aracılığı ile yapıştırılması ile beyin tarafından üretilen elektriksel sinyallerin kaydedilmesi ve analiz edilmesi esasına dayanır. Elektrotlar beyine herhangi bir değerde elektrik veya radyasyon vermez. Non-invaziv bir teknikte gerçekleştirilir, bu sebeple acı hissedilmez. Sadece beyinde oluşan dalgalanmalarını, elektriksel aktivitesini ölçer. Bu sebeple hamileler dahil olmak üzere her yaşta insanın EEG çekilmesinde bir sakıncası yoktur (Altan ve diğerleri, 2016a).

Farklı tiplerde EEG analizleri mevcuttur.

- Frekans Analizi: EEG kayıtlarındaki farklı frekanslardaki beyin dalgaları (alfa, beta, teta, delta gibi) analiz edilir.
- Genlik Analizi: Beyin dalgalarının genliği (amplitüdü) ölçülerek beyin aktivitesinin yoğunluğu değerlendirilir.

kortikal görme bozukluğu gibi daha birçok hastalık EEG testi sonucunda tanısı konulabilmektedir. Literatürde EEG dalgası üzerinde çalışma yapan birçok makale bulunmaktadır. Bunlardan bazıları aşağıda detaylandırılmıştır.

Parsa ve diğerleri (2023), yaptıkları çalışmalarında, EEG sinyalleri üzerinde çalışırken özellikle öznitelik çıkarmanın ve bunun sonuçtaki başarıma etkisinin önemini vurgulamışlardır. PRISMA yöntemi kullanarak, anahtar kelimelerinde EEG ve derin öğrenme kelimesi geçen birçok makale incelemiş ve bunlar arasından sadece derin öğrenmenin en sık kullanılan çok katmanlı yapıları kullanarak insanların hastalıkları üzerinde sınıf etiketleri içeren toplam 82 makale incelemişler. Bu makalelerde, çeşitli parametrelerin sonuçlarındaki başarıyı nasıl etkilediği ile ilgilenmişlerdir. Özellikle derin sinir ağları üzerinde yapılan çalışmaların sonucunda elde edilen performans kriterlerinden doğruluğu yüksek olan çalışmalarda: bant geçirgenliği, giriş özellikleri ve ağ mimarisi ile ilişkili olduğu kanısına ulaşmışlardır. Ağ mimarisindeki çok katmanlı modellerde üzerine çıktığında doğrulukları %80 ve üzerinde olduğunu görmüşlerdir. Aynı zamanda, çok kanallı EEG veriseti üzerinden yapılan çalışmalarda önemli ayırıcı karakteristikler elde ettiklerini gözlemlenmiştir. CNN yöntemi kullanarak, girişlerinde 2 boyutlu görüntü olarak EEG sinyalini kullanan çalışma da çoğunluktadır. Sonuç olarak, EEG sinyalleri üzerinde elde edilen verisetlerine göre önışlemlerden sonra, derin öğrenme yöntemleri kullanıldığında çoğu zaman yüksek başarımlı çalışmaların ortaya çıktığı gözlemlenmiştir.

Othmani ve diğerleri (2023) çalışmalarında EEG sinyallerini uyusukluk ve yorgunluk tespiti için kullanarak hem derin hem de yüzeysel derin öğrenme yöntemlerini kullanan çalışmaları araştırmışlardır. Bu yöntemleri, ayırıcı, üretken, temsili ve hibrit modeller olarak ana başlıklar altında sınıflandırmışlardır. Literatürde bu alandaki çalışmalarda elde edilen başarımların sonuçlarına detaylı şekilde karşılaştırmışlardır. Ayrıca, yorgunluk ve uyusukluk tespiti için yaşanan veya yaşanabilecek zorluklardan da bahsetmişlerdir. Literatürden seçtikleri çalışmaların katılımcı sayısı 1-50 arasında değişmekte ve ortalama katılımcı sayısı on üçtür. Bu konuda tespit ve sınıflandırma yapabilmek için EEG kaydı esnasındaki, göz kırpması gibi reflekslerin EEG sinyalini etkilemesi sebebiyle, verisetlerindeki EEG sinyallerinin analizinden önce bağımsız bileşen analizi veya gürültü giderme algoritmalarının kullanılması önermişlerdir. EEG sinyalleri üzerinde çalışırken bu ve bunun gibi gürültü, düşük sinyal, vb. sorunları en aza indirmek için ilgili yöntemler ile önce önışleme yapılması daha yüksek doğruluklara ulaşmak için gerektiği

kanısına ulaşmışlardır. EEG sinyallerini kullanarak, yorgunluk ve uyuşukluk halini sınıflandırmak için sinir ağları kullanmanın iyi sonuçlar verdiğini, fakat EEG sinyalini modellere sokmadan önce doğruluğunu arttırmak için bireysel değişkenlikleri göz önünde bulundurmak gerektiğini savunmuşlardır.

Seshadri ve diğerleri (2023), veriseti olarak 20 öğrenme güçlüğü çeken ve 20 normal öğrenme süreci gösteren 8-16 yaş aralığındaki çocukların istirahat halinde alınan EEG sinyallerini kullanmışlardır. Çalışmalarında, öğrenme güçlüğü çeken çocukların bu nörolojik gelişimsel bozukluklarını erken teşhis edilebilmesi için bir yaklaşım önermişlerdir. Öncelikle, ham EEG verisi üzerinde ön işleme olarak Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT) kullanmışlar ve alfa, beta, delta, teta bantları ile çeşitli özellikleri bölümlenmişler ve bunlara filtre tabanlı özellik seçme yöntemi uygulamışlardır. Elde edilen tüm bu veriler üzerinde de hem makine öğrenmesi hem de derin öğrenme (sığ ve derin) algoritmaları ile sınıflandırma yaparak sonuçlarını karşılaştırmışlardır. Alfa bandında, 10-katlı çapraz doğrulama ile k-NN kullanıldığında ortalama başarımlar %89,2 en fazla başarımlar %90,2 olarak kaydedilmiştir. SVM yöntemi ve tam özellik kümesi kullanıldığında ise en yüksek başarımlar %94,8 elde etmişlerdir. Makine öğrenmesi sınıflandırma yöntemlerinin ardından derin öğrenme algoritmaları ile de karşılaştırılmak istenmiş ve bunun için tekrar denenmiştir. Sinir ağlarına giriş olarak elde edilen özellik verileri kullanılmıştır. En yüksek ortalama başarımlar %95,8 ve en yüksek başarımlar %97,5 olarak; sığ sinir ağı tabanlı sınıflandırıcı ve Relief algoritmasının birlikte en iyi 30 öznitelik üzerinde kullanılması ile birlikte ulaşılmıştır.

Suhaimi, Mountstephens ve Teo (2020), EEG sinyalleri üzerinde sınıflandırma yapılırken VR ile birlikte analizlerin yapılmasını önermişlerdir. Literatürdeki 2016 ile 2019 yılları arasında yayımlanan 30 makaleyi ele almaktadırlar. Bu makaleleri incelemişler ve bunların arasında en yüksek başarımları Kumaran (2018), RF algoritması kullanarak %98,20 olarak elde ettikleri görülmüştür. Sanal gerçeklik uyaranları ile sadece Hidaka, Qin ve Kobayashi (2017), SVM algoritması kullanarak %81,33 başarımlar elde etmişlerdir fakat denek sayısı 5 olduğu için az bulunmuştur.

Raghu, Sriraam, Temel, Rao ve Kubben (2020), EEG üzerinde yaptıkları analizlerle 7 farklı nöbet çeşidini sınıflandırmak üzerine çalışma gerçekleştirmişlerdir. 19 kanallı EEG zaman serisini önce spektruma dönüştürmüş ve CNN algoritmasına vermek üzere 2

yöntem gerçekleştirmişlerdir. İlk olarak, ön eğitilmiş modellerden AlexNet, VGG16, VGG19, SqueezeNet, GoogleNet, InceptionV3, DenseNet201, ResNet18, ResNet50 ve ResNet101 modellerini kullanmış, ikinci olarak da önceden eğitilmiş bu modeller üzerine öznetelikler çıkararak SVM kullanarak sınıflandırmışlardır. GoogleNet modeli kullanarak %82,85 en yüksek başarımını elde etmiş, InceptionV3 modeli ile transfer öğrenme ve görüntü öznetelik ayıklama yaparak da %88,30 başarım elde etmişlerdir.

Omerhodzic, Avdakovic, Nuhanovic ve Dizdarevic (2010), verisetini sağlıklı bireyler, epilepsi hastaları ve nöbet sırasında epileptik sendromlu hastalardan elde edilen 300 EEG sinyalinin 250 tanesini eğitim ve kalanını test verisi olarak kullanmışlardır. EEG sinyallerinin 5 çözünürlük seviyesinde (delta, teta, alfa, beta ve gama) ayırtmak için Çoklu Çözünürlük Analizi (MRA) ile DWT uygulamışlardır. Ayrıca Parsevals teorimi uygulayarak sinyallerin enerji özneteliklerini yüzde dağılımını farklı çözünürlük seviyelerine ayırtmışlardır. Dalgacık Tabanlı Sinir Ağı (Wavelet Neural Networks, WNN) ile sınıflandırma sonucunda 50 farklı test verisinden 47 tanesini (ortalama %94,0) doğru sınıflandırmayı başarmışlardır.

2.2.1. EEG analizini baz alan uygulama alanları

EEG, genellikle nörolojik hastalıkların teşhisinde kullanılır. Beynin elektriksel aktivitesini analiz ederek motor imgeleme incelenmesinde ve çeşitli nörolojik çalışmalarda kullanılabilen çok yönlü bir tekniktir. EEG'nin kullanım alanları sürekli olarak genişlemekte ve bu teknik, beyin hakkında daha derin bir anlayışa ulaşmamızı sağlamaktadır. EEG sinyalleri, aşağıdaki gibi farklı türden çalışma alanlarına sahiptir

Nörolojik hastalıkların teşhisi ve takibi

EEG, epilepsi teşhisinde en önemli araçlardan biridir. Epileptik nöbetler sırasında beyin dalgalarında görülen karakteristik değişiklikler, nöbet türünü belirlemek ve tedavi planlaması yapmak için kullanılır. Yıldırım ve Yıldız (2017), yılında çalışmasında Bonn Üniversitesi'nin verisetinden 23,6 saniye ve 4096 adet örnek sağlıklı ve epilepsi nöbeti geçiren bireylerden alınan EEG sinyalleri üzerinde çalışmışlardır. Bu veriseti üzerinde otomatik örüntü tanıma sistemi tasarlamışlardır. İlk olarak, EEG sinyallerini 128'den başlayarak 2'nin üssü olacak şekilde 4096'ya kadar uzunluğundaki bölümlere

ayırmışlardır. Ardından, Peridogram ve Welch yöntemlerini kullanmışlar ve EEG sinyallerinin spektral bilgisini elde etmişlerdir. Son olarak, her bir EEG bölümünü ve 16 örnek uzunluğundaki öznitelik vektörlerini k-NN, SVM, aşırı öğrenme makinesi (Extreme Learning Machines, ELM) ile sınıflandırmışlardır. Kullandıkları sınıflandırıcılar ile yapılan araştırmalarda en fazla %100 sonuç elde etmişlerdir.

Uyku apnesi, narkolepsi, uykusuzluk gibi uyku bozukluklarının teşhisi ve takibi için EEG kullanılabilir. EEG, uyku evrelerini (REM uykusu, derin uyku vs.) belirlemek ve uyku sırasında oluşan anormallikleri tespit etmek için kullanılır. Çeper (2022) yazdığı yüksek lisans tez çalışmasında EEG sinyalleri ile uyku evreleme yaptıktan sonra, uyku apnesinin uyku evreleri ile aralarındaki ilişkiyi incelemiştir. Toplamda 3 farklı öznitelik seti oluşturmuştur: EWT yöntemi ile 80 öznitelik; EMD yöntemi ile 26 öznitelik; Varyasyon Mod Ayırıştırma (Variational Mode Decomposition, VMD) yöntemi ile 26 öznitelik çıkarılmıştır. Bu üç veriseti birleştirerek toplam 132 öznitelikten oluşan dördüncü bir veriseti oluşturmuştur. Relief öznitelik seçme yöntemi uygulayarak 91 en etkin özniteliği seçerek bununla da ayrı bir veriseti oluşturmuştur. Tüm bu 5 öznitelik seti üzerinde ayrı ayrı ANN, SVM, k-NN, Torba Ağaç Algoritması (Bagged Tree, BT) sınıflandırıcıları kullanarak, uyku evreleme analizi yapmıştır. Sonuçlarında en yüksek başarıyı, EMD ile elde edilen veriler üzerinden ANN kullanılarak %70,02 olarak raporlamışlardır.

Tümörlerin beyin aktivitesi üzerindeki etkileri, EEG kayıtlarında gözlenebilir. Beyin tümör teşhislerinde doktorlar, beynin tüm işlevini tam anlamıyla analiz etmese de BT taramalarını ve daha fazla beyin fonksiyonu hakkında bilgi sağlayabilen EEG sinyallerini kullanmaktadırlar. Fakat EEG de beyin tümörünün tam yerini saptamak zor olabilir ve bireylere göre değişkenlik gösterebilir. Bu sebeple Karameh ve Dahleh (2000), EEG sinyallerinden öznitelikler çıkarmak için dalgacıklar kullanan yeni bir EEG sinyal analiz yöntemi önermişlerdir. En iyi başarıyı kendi kendine düzenlenen haritalar (SOM) ile dalgacık dönüşümünün (Wavelet Transform, WT) bir arada kullanıldığı yöntemle elde edilmiştir. Önerdikleri yöntem, normal beyin aktivitesi, glioma tümörleri ve meningioma tümörleri arasında ayırım yapmada geleneksel frekans tabanlı yöntemlerden daha başarılı olmuştur. Bu yeni yöntem ile EEG tanısının beyin tümörleri için doğruluğunu arttırmak adına kullanabileceğini ve beyin anatomisi ve işlevi gibi diğer bilgiler ile de birleştirilebileceklerini savunmuşlardır.

Demanda, beyin dalgalarında belirgin yavaşlama ve anormallikler görülebilir. Oltu, Akşahin ve Kibaroglu (2019), yılında yaptıkları araştırmada Alzheimer hastalığı ve hafif bilişsel bozukluk hastalıklarının tanısının otomatik konulabilmesi için, karar destek sistemi geliştirmişlerdir. Geliştirilen sistemde, EEG sinyalleri filtreleyerek Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT) uygulamışlardır. CWT uygulama sonrası, katsayıları ve skalogram değerlerini ortalamalarını ve standart sapmalarını öznetelik olarak kabul etmişlerdir. Bu öznetelikler ile hastalıkları k-NN algoritması ile sınıflandırarak %88,9 başarımla eğitilmiş ve %99,44 başarımla test sonucuna ulaşmışlardır.

Koma, beyin ölümünü tespit etmek ve bilinç düzeyini takip etmek EEG kayıtları kullanılabilir. Ceylan ve Uyar (2024), beyin sapı dahil beyin fonksiyonlarının geri dönüşü olmaksızın tam kaybı olan beyin ölümünün tanımlanması, tanının konulabilmesi gibi kavramların üzerinde durdukları bir makale yayımlamışlardır. Bu makalede, ancak birçok testin sonucunda bu tanının konulabileceği belirtilmiştir. Ardından bekleme (gözlem) süresi olarak yaş ve hastanın beyin hasarına bakılarak 12, 24, 48 saat olarak değişkenlik gösterir.

Motor imgeleme çalışmaları

Motor imgeleme, bir eylemin veya hareketin yapılmadan önce beyinde düşünülmesi, tasarlanması, hayal edilmesi anlamına gelir. Bir eylemi veya hareketi fiziksel olarak gerçekleştirilmeden önce, eyleme ait tüm detayları için bireyin zihninde bir tür simülasyon oluşturmasıdır. Motor imgeleme, rehabilitasyon süreçlerinde, sporcu antrenmanlarında, anksiyete yaşayan kişilerde gibi daha birçok konuda günlük yaşamda farklı amaçlar doğrultusunda gerçekleştirilir. Beynin korteks bölgesi, vücuttaki hareketlerin planlanması ve kontrolünden sorumludur. Motor imajı, beynin bu bölgesini aktive eder. Motor imajı esnasında, beyin, düşünülen hareketi gerçekten yapıyormuş gibi sinyaller üretir. Bu sayede vücuttaki kasların zihinsel olarak uyarılması ve sinir sisteminin güçlenmesi sağlanır (Fadiga, Buccino, Craighero ve Fogassi, 1999).

Motor imajı sırasında EEG kaydı alınırsa, korteks bölgesi aktif hale geldiğinde EEG sinyallerinde belirgin değişiklikler oluşur. Özellikler motor imajı sırasında belirli frekans bantlarında (beta bandı gibi) artışlar gözlemlenir. EEG sinyallerini analiz ederek, bireylerin

sadece beyin aktivitesini kullanarak bilgisayarları veya protezleri kontrol etmek için kullanılan BCI'ların temelini oluşturur. Örneğin bir uzvunu kaybetmiş birey, o uzvunu hareket ettirmeyi düşünerek olmayan uzvun yerine takılan protezi hareket ettirebilir. Özellikle motor imgeleme, yani bir hareketin zihinde hayal edilmesi, kurgulanması, BCI sistemlerinde önemli bir rol oynar. Tanaka, Matsunaga ve Wang, 2005), EEG tabanlı elektrikli tekerlekli sandalye kontrolü üzerine bir çalışmıştır. Bu çalışmanın temel amacı sadece EEG sinyalleri kullanarak bir elektrikli tekerlekli sandalyenin yönünü kontrol edebilmenin mümkün olduğudur. Aslında bu çalışma, beyin sinyallerini tekerlekli sandalyeler gibi mekanik cihazları kontrol etmek için kullanma girişimidir. Hedeflerine ulaşmak için, EEG sinyallerinden tanıma desenleri oluşturmak amacıyla özyinelemeli bir eğitim algoritması geliştirmişlerdir ve yapılan çalışmanın deneysel açıdan sonuçları, önerilen özyinelemeli eğitim algoritmasının faydasını ve yalnızca EEG sinyalleri ile bir elektrikli tekerlekli sandalyenin yön kontrolünü başarmanın oldukça imkanı ve olabilir olduğunu kanıtlamıştır.

Nörorehabilitasyon, beyin hasarı, inme, felç gibi vücut hareketlerini kısıtlayan bir hastalığa sahip olan bireyler için yeniden bu becerilerini kazanmalarında yardımcı olmak için kullanılır. EEG, motor fonksiyonlarında bozukluk yaşayan hastaların rehabilitasyonunda kullanılabilir. Motor imgeleme yoluyla beyin aktivitesi ölçülerek rehabilitasyon sürecinin takibi yapılabilir. Altan ve diğerleri (2016a), inme hastalarında SCP eğitiminden beyin aktivitelerini sınıflandırmak üzerine çalışmış ve 10 Hz bant geçiren filtre kullanmış, Hilbert-Huang dönüşümü ile öznitelik çıkarma uygulamanın ardından, DBN kullanarak sınıflandırma yapmışlardır. Çalışma sonunda %91,15 en yüksek doğruluk elde etmişlerdir.

Nörolojik araştırma alanları

Bilişsel işlevlerin incelenmesi, bilinç durumları (uyanıklık, uyku, koma vb.) aralarındaki farklılıkları, dikkat, bellek, dil, karar verme gibi çeşitli bilişsel süreçlerin beyin aktivitesi üzerindeki etkilerini incelemek için beyin sinyallerini analiz etmek gerekmektedir. EEG bilişsel işlevlerin incelenmesini sağlayan bir izleme aracı olarak da kullanılmaktadır. EEG sinyalleri üzerine EWT analizi kullanarak Anuragi ve Sisodia, (2020), alkollü ve alkolsüz insanların otomatik olarak tespit edilmesi üzerine çalışmışlardır. Zaman-frekans tabanlı özniteliklerini çıkarmak için Hilbert-Huang Dönüşümü (HHT), EEG sinyallerinin Fourier spektrumunu bölümlere ayırmak için Sınır Algılama yöntemi kullanmışlardır. En küçük

kare destek vektör makinesi (LS-SVM), SVM, Naïve Bayes (NB) ve k-NN sınıflandırma algoritmaları ile sınıflandırmışlardır. Birini dışarıda bırakma çapraz doğrulama yöntemi ile de modellerin eğitimi ve testi için kullanılmıştır. En yüksek başarımlar LS-SVM algoritması ile %98,75 doğruluk oranında elde etmişlerdir.

Duygusal tepkilerin ölçülmesinde, stres, kaygı, mutluluk gibi duygusal tepkilerin beyin aktivitesi üzerindeki etkilerini analiz etmek için EEG yaygın olarak kullanılan bir araçtır. EEG sinyali tabanlı kişilik tanımlanması, zihinsel aktiviteler üzerinden gerçekleştirilmektedir. Wilaiprasitporn ve diğerleri (2020) derin öğrenme yöntemleri ile kişilik tanıma performansını arttırmayı hedeflemişlerdir. CNN ve Tekrarlayan Sinir Ağı (RNN) algoritmalarının çapraz olarak kullanılması sonucunda, CNN-GRU ve CNN-LSTM algoritmalarının kişilik tanıma yapabileceğini ve güç spektral yoğunluk özelliklerini kullanan SVM temel sistemini önemli ölçüde geride bırakmıştır ve ortalama %99,9 ile %100 bantları arasında doğru tanıma oranına ulaştıklarını belirtmişlerdir.

2.3. EEG Üzerine Gerçekleştirilen Farklı Derin Öğrenme Yaklaşımları

Bu bölümde EEG üzerine gerçekleştirilen farklı derin öğrenme yaklaşımlarına yer verilmiştir. Derin öğrenme yaklaşımlarından olan CNN, DBN, DNN, GCN ve GNN çalışmaları araştırılıp incelenerek, bu çalışmalar hakkında bilgi ve tanımlar yapılmıştır.

2.3.1. EEG üzerine gerçekleştirilen CNN çalışmaları

Oh ve diğerleri (2020), EEG sinyalleri üzerinde CNN algoritması kullanarak parkinson hastalığını otomatik olarak algılayacak bir sistem üzerine çalışmışlardır. Veriseti olarak 20 parkinson hastası birey ve 20 sağlıklı bireyin EEG sinyallerini kullanmışlardır. Önerdikleri sistem sonucunda CNN modeli ile %88,25 başarımlar elde etmişlerdir.

Parsa ve diğerleri (2023), 82 adet bilimsel dergi makalesini incelemiş, EEG verilerini sınıflandırmak için derin öğrenme yöntemlerinden en çok CNN algoritması kullandığını analiz etmişlerdir. Bu analizin sonucunda, daha önce EEG verileri üzerine yapılan çoğu çalışmanın klinik sınıflandırmaya odaklandığı ve sonuçlarındaki başarımların ortalama %91,83 (+/-7,34) olduğuna erişmişlerdir. Ayrıca, EEG sinyallerinin en çok kullanılan veri türünün ise dinlenme durumu EEG sinyalleri olduğu sonucuna ulaşmışlardır. Bunun yanı

sıra şizofreni, alzheimer ve depresyon türlerindeki hastalıkların teşhisi için de EEG sinyalleri üzerinden analiz süreçleri gerçekleştirildiğini; farklı anomalilerin sınıflandırılması üzerine sıklıkla tercih edildiğini raporlamıştır.

Yao ve diğerleri (2024), çalışmalarında EEG zamansal-mekansal (EEG ZM) özellik öğrenimi ve otomatik duygu sınıflandırması için transformer ve konvolüsyonel sinir ağlarına (TCNN) dayalı yeni bir model önermişlerdir. Önerdikleri EEG ZM-TCNN modeli, EEG sinyallerinde kanal konumlarını ve zaman bilgilerini algılamak için pozisyon kodlaması ve çoklu başlı dikkat mekanizmasını kullanmaktadır. Modeldeki iki paralel transformer kodlayıcı, duygu ile ilgili EEG sinyallerinden mekânsal ve zamansal özellikleri çıkarmakta, bir CNN ise EEG'nin mekânsal ve zamansal özelliklerini birleştirerek bu özellikleri Softmax fonksiyonu kullanarak sınıflandırmaktadır. Önerdikleri modeli farklı verisetlerinde deneyerek doğruluklarını kaydetmişlerdir: SEED verisetinde %96,67; DEAP verisetinde uyarılma-valans için %95,73 uyarılma için %96,95 ve valans için %96,34 doğruluk elde etmişlerdir.

Latreche, Slatnia, Kazar, Harous, ve Khelili (2024), çalışmalarında 14 sağlıklı birey ve 14 şizofreni hastalığı bulunan bireylerin EEG veriseti üzerinde şizofreni tespiti için CNN yöntemi kullanmışlardır. EEG veriseti üzerinde ağ eğitimi için öz nitelikleri otonom olarak çıkartmışlardır. En yüksek başarımları elde ettikleri model: bir max pooling katmanı, bir Global Ortalama Havuzlama katmanı, dört konvolüsyon katmanı, aşırı uyumu önlemek için iki dropout katmanı ve iki tam bağlı katmandan oluşan on katmanlı bir CNN'dir. 10 katlı çapraz doğrulama tekniği kullanarak değerlendirdikleri bu modelin ortalama %99,18 doğruluk skoruna sahiptir. Modeli test etmek için daha önce eğitimi yapılmamış veriler üzerinde de denediklerinde %100'e çok yakın doğruluk sonuçları elde etmişlerdir.

2.3.2. EEG üzerine gerçekleştirilen DBN çalışmaları

Movahedi, Coyle ve Sejdic (2018), çalışmalarında derin öğrenme yöntemlerinden biri olan DBN yöntemini kullanan farklı çalışmaları incelemişler ve diğer popüler derin öğrenme yöntemlerinin de genel olarak değerlendirmelerini yapmışlardır. Geleneksel makine öğrenmesi algoritmalarından ziyade derin öğrenme algoritmalarının daha avantajlı ve doğruluk paylarının daha yüksek olduğunu savunmuşlardır. Özellikle, derin öğrenme yöntemi kullanırken giriş verilerinin daha esnek olması ile denetimsiz öğrenmede daha

kolay kullanımını sağlamışlardır. Çoklu gizli katman kullanım verimliliği sayesinde verileri daha iyi temsil eden bir yapı oluşturmaları, EEG gibi fizyolojik sinyaller üzerinde DBN ve diğer derin öğrenme yöntemleri teşhis/tanı/sınıflandırma için daha uygun olduğunu savunmuşlardır. EEG sinyallerinin çok değişkenli verileri bulunmasının bazı evrelerde DBN için dezavantaj oluşturabilme potansiyelinden bahsetmişlerdir. Fakat birçok çalışmada bu çoklu değişken yapısında DBN'in başarısı oldukça fazla olduğu vurgulanmıştır. Özellikle, EEG verisi büyük miktarda, çok değişkenli veriler olmasından dolayı için ön işleme yapmak önemlidir. Ayrıca EEG sinyali üzerinde derin öğrenme yöntemleri kullanılırken, kan basıncı veya kalp atışı gibi başka fizyolojik sinyallerin de çalışmalara EEG verisi ile birlikte dâhil edilmesini önermişlerdir.

Cherukuvada ve Kayalvizhi (2023), çalışmalarında epilepsi hastalığı bulunan kişilerden alınan EEG kayıtları üzerinde derin öğrenme yöntemi olarak DBN ve öz nitelik çıkarma olarak da karşıt Aquila optimizasyonu tabanlı özellik seçimi (Oppositional Aquila Optimizer-based Feature Selection, OAOFS) tekniklerini DBN altyapısı ile kullanmışlardır. Bu yapılan çalışma ile epilepsi nöbetlerinin varlığı ve yokluğunu sınıflandırarak kategorilere ayırtırmayı hedeflemişlerdir. Çalışmanın ilk aşamasında, bu yöntemleri ile EEG sinyallerinden OAOFS sayesinde optimum bir alt küme seçilmiştir. Bu teknik ile birlikte EEG sinyallerinin epilepsi nöbeti türlerine göre sınıflandırmak için DBN modeli ve yapay ekosistem optimizasyonu (Artificial Ecosystem Optimizer, AEO) uygulamışlardır. Sonuçları başarılı olduklarını gördüklerinde, başka bir veriseti olan bir EEG veriseti üzerinde aynı yöntem ve teknikleri kullandıklarında %97,81 doğruluk başarımları ile ele aldıkları tüm yöntemlerden en başarılı olan sonuca ulaşmışlardır.

Ahmadi ve diğerleri (2022), çalışmalarında EEG analizi yaparak göz durumlarını tahmin etmek üzerine çalışma yapmışlardır. Bu çalışmalarında, kendinden organize olan kümeleme ve RBM içeren DBN yaklaşımı ile EEG sinyallerinin analizi için 15 öz nitelik içeren 14980 veri üzerinde çalışmışlardır. Önerdikleri yöntemin diğer denetimli yöntemlerden daha başarılı olduğunu göstermişlerdir. Modellerini; 2, 4 ve 6 katmanlı RBM modellerinde denemiş ve eğitim süreçlerini 100 epoch (eğitim döngüsü sayısı) üzerine kurmuşlardır. DBN ve öncesinde kümeleme yaklaşımlarıyla 3 farklı model için %87,40 ile %95,20 başarımları değer sonuçlarını elde etmişlerdir.

Dairi, Zerrouki, Harrou ve Sun (2022), çalışmalarında EEG sinyalleri üzerinde gürültü giderme algoritması ve zihinsel görevleri daha iyi tanıyabilmek için zaman-frekans temsilini çıkarmak adına yarı dalgalanma dağılım teoremini uygulamışlardır. Bu sinyalleri sınıflandırmak için DBN tabanlı izolasyon ormanı şemasında girdi olarak kullanmışlardır. 30 elektrot ile ölçülen 5 zihinsel görevi barındıran verisetinin %80 kadarını eğitim; %20 kadarını test için ayırarak çalışmalarını gerçekleştirmişlerdir. 5 sınıf üzerinde yaptıkları analizlerde %98,48 ve %99,19 değerleri arasında sınıflandırma başarımları elde etmişlerdir.

Elsayed, Tolba, Rashad, Belal ve Sarhan (2021), çalışmalarında veriseti olarak 9 insanın 14 farklı kanal ile elde edilen EEG sinyalleri üzerinde, ses-video ve erkek-kadına bağlı olarak EEG'nin çoklu duyuşal özelliklerini belirlemişlerdir. Odak noktasını teşkil eden iki ayrı model için de DBN, DNN, SVM, Doğrusal Ayırıcı Analiz (Linear Discriminant Analysis, LDA) gibi klasik lineer makine öğrenmesi yaklaşımlarının yanı sıra derin öğrenme yöntemlerini de uygulamışlardır. DBN, diğer algoritmalara göre her iki sınıflandırmada çok daha başarılı sınıflandırma değerleri elde ettiğini göstermişlerdir.

Yang (2022), çalışmasında 15 sağır deneğe duyuşal videolar izleterek yüz ifadeleri ve 12 elektrot yardımıyla kaydedilen EEG sinyallerini analiz etmişlerdir. Deneklerin morfolojik 30 yüz ifadesi özellikleri en büyük ağırlıklarına göre seçildikten sonra, öznetelik seçimine bağlı olarak DBN sınıflandırması kullanarak %99,92 başarıma ulaşmışlardır.

2.3.3. EEG üzerine gerçekleştirilen DNN çalışmaları

Alickovic ve diğerleri (2023), çalışmalarında birden fazla konuşmacı olan ortamlarda, nöral takip için konuşma özelliklerini çıkarma üzerine DNN modeli kullanarak, konuşma özelliklerini işitsel yol boyunca tahmin etmişlerdir. Normal işitme yetisi olan 17 kişiden 64 kanallı EEG verileri üzerinde DNN kullanarak diğer birkaç yöntemle göre çok daha iyi tahmin sonuçlarına ulaşmışlardır. En iyi akustik özellik seti için %75, en iyi DNN özellik seti ile %79 doğruluk oranına ulaşmışlardır.

Tatar (2023), çalışmasında EEG sinyalleri tabanlı davranışsal biyometrik verileri kullanarak kişi tanımlama sistemleri üzerine çalışmıştır. 64 kanal ve 96 denekten toplanan EEG verileri kullanılarak, özellik oluşturma, özellik seçimi ve sınıflandırma adımlarını

içeren doğrusal olmayan bir modele dayalı bir kişi tanımlama sistemi önermiştir. İstatistiksel yöntemler kullanarak EEG sinyallerinden özellikler oluşturdu ve komşu bileşen analizi ile en iyi 15 özellik seçildi. Seçilen özellik vektörü, DNN modeline ve geleneksel makine öğrenmesi sınıflandırıcı karar ağacına girdi olarak verildi, k-NN, SVM, rastgele orman sınıflandırıcıları ile 6 görev için test edildi, karşılaştırıldı. Tüm görevler için karar ağacı, rasgele orman, k-NN, SVM ve DNN sınıflandırıcılarının ortalama doğruluğu sırasıyla %98,63; %100; %99,96; %99,91 ve %100 olarak bulundu. Sonuçlar, RF ve DNN sınıflandırıcı tabanlı modellerin EEG sinyalleri kullanılarak sınıflandırma ve kişi tanımlamada oldukça etkili olduğunu göstermektedir.

Siddiqui ve diğerleri (2023), çalışmalarında EEG sinyallerini kullanarak hayal edilen bir görevin zihinsel sınıflandırması için derin sinir ağı (DNN) modeli önermiştir. Öznitelik çıkarımı için Laplacian yüzeyi uygulanarak konumlandırılmış sinyallerden önceden hesaplanmış özellikler elde edilmiştir ve yüksek boyutlu verilerle başa çıkmak için, giriş vektörlerinden en ayırıcı özellikleri çıkarmak için temel bileşen analizi (PCA) uygulanmıştır. Önerilen model, özellikle belirli bir öznenin alınan EEG verilerinden zihinsel görev özgü özellikler çıkarmayı amaçlayan non-invaziv bir yöntemdir. Modelin eğitimi tüm deneklerin (Biri hariç) ortalama birleşik Güç Spektrumu Yoğunluğu (PSD) üzerinde gerçekleştirilmiş ve DNN tabanlı önerilen modelin, EEG sinyallerinden doğru bir şekilde zihinsel görev sınıflandırmasını gerçekleştirmede %77,62 doğruluk ile diğer algoritmalarından daha üstün olduğunu göstermişlerdir.

Alotaibi ve Fawad (2022), çalışmalarında insan duygusal durumunun doğru bir şekilde tanımlanmasının, insan-robot etkileşiminde verimli bir rol oynadığı belirtilmektedir. Bu nedenle, çeşitli biyosinyallere dayanan sağlam ve doğru BCI modelleri geliştirme araştırmaları yapılmaktadır. Yaptıkları literatür çalışmalarına göre birçok DNN yöntemi kullanılmış ve başarılı olduğunu görmüşlerdir. Bu çalışmada da bir DNN modeli olan GoogleNet ile kendileri geliştirdikleri OMTLBP_SMC doku tabanlı özelliklerle ve k-NN algoritması ile birleştirerek DEAP ve SEED verisetleri üzerinde %93,83 ve %96,95 doğruluğa ulaşmışlardır.

2.3.4. EEG üzerine gerçekleştirilen GCN çalışmaları

Chen, Chai, Xie, Liu ve Ma (2024), çalışmalarında 7 katılımcının bulunduğu kendi tasarladıkları deneysel bir veriseti üzerinde zihinsel yorgunluk ve uyanıklık durumlarında kanallar arası uzamsal bağlantıyı araştırmışlardır ve zihinsel yorgunluk tespiti için spektral grafik evrişim ağlarını (GCN) kullanmışlardır. Zamansal bağlantıları oluşturmak için Pearson korelasyon katsayıları (PCC) ve spektral bağlantılar için büyüklük-kare koheransı (MSC) kullanmışlardır. Uzamsal kanallar arası bağlantıların öğrenimini artırmak için, çift-grafik stratejisi kenar özelliklerini düğüm özelliklerine dönüştürerek spektral GCN'ye giriş olarak sunmuşlardır. Model, PCC ve MSC özelliklerini aynı anda öğrenerek, uyanıklık ve yorgunluk durumları arasında bazı beyin ağı özelliklerinde önemli farklılıklar olduğunu göstermiştir. Bu durum, beyin aktivitelerinin senkronizasyonunun uyanıklık durumunda zihinsel yorgunluğa kıyasla farklı olduğunu doğrulamakta ve yorgunluk durumlarının farklı beyin bölgeleri arasındaki korelasyon desenlerini etkileyebileceğini göstermektedir. Üzerinde çalıştıkları modeli kendi tasarladıkları veriseti üzerinde bireysel olarak denendiğinde %95,24 başarımla, grup olarak denendiğinde ise %89,59 başarımla elde etmişlerdir. Ayrıca kamuya açık verisetleri içerisinde SEED-VIG adlı 23 katılımcının verisi bulunan veriseti ile de modellerini test etmişlerdir ve %86,58 başarımla elde etmişlerdir.

Wang ve diğerleri (2021), çalışmalarında yarı denetimli sınıflandırma algoritmalarının depresyon hastalığı üzerinde uygulanabilirliğini araştırmışlardır. Kullandıkları verisetinde, 24 depresyon hastası ve 29 sağlıklı birey olmak üzere toplam 53 gönüllü bireyin dinlenme durumunda 5 dakikalık 128 kanal üzerinden EEG verileri bulunmaktadır. EEG'nin diferansiyel entropi özelliği elde edilip Pearson matrisi, grafiğin düğüm ve komşuluk matrisini oluşturmak için kullanmışlardır. Eğitim setlerini genişletmek ve sınıflandırma etkisini iyileştirmek amacıyla kendini organize eden artımlı sinir ağı (self-organizing incremental neural network) ve GCN yöntemlerini birleştirerek 10 katlı çapraz doğrulama yöntemi ile veriseti üzerinde uygulamışlardır. Etiket sayıları 50 adet olduğunda %70,53 başarımla alırken etiket sayıları 600 olduğunda %92,23 başarımla elde etmişlerdir.

Zhang, Liao, Chen, Zhang ve Huang (2024), çalışmalarında DEAP ve SEED hazır verisetleri üzerinde çalışmışlardır. Farklı bireylerin EEG verileri arasındaki ortak noktalar üzerine odaklanarak, Kontrastif Öğrenme Grafik Sinir Ağı (Contrastive Learning Graph

Convolutional Network) adında yen bir yaklaşım sunmuşlardır. Bu yaklaşım, CL'nin senkronize çoklu denek veri öğrenme avantajlarını ve GCN'nin beyin bağlantı matrislerini çözmedeki becerisini birleştirirerek bireylerin duygusal durumlarıyla ilgili karakteristik özellikleri ve önemli kanal düğümlerini yakalamaktadır. Beş katlı çapraz doğrulama tekniği kullanarak DEAP veriseti üzerinde %97,13 başarımla, SEED ve SEED_IV veriseti üzerinde %99'un üzerinde başarımla elde etmişlerdir. Yeni denek üzerinde modeli test etmek için, SEED veriseti üzerinde başarımla gösteren modelin %5'lik bir ince ayar yapılması sonrasında %92,8 başarımla elde etmişlerdir.

Tian, Li, Ju ve Liu (2022), çalışmalarında günümüzün güvenlik problemlerinden biri olan kimlik doğrulama sistemlerinin doğruluğunu arttırmak için bir GCN modeli geliştirmeyi amaçlamışlardır. Kimlik doğrulamayı arttırmak için daha fazla özellik kullanmak bir çözümdür fakat özellik sayısı arttıkça aşırı öğrenme sorununa da yol açabilmektedir. Bu çalışmada birçok özellik GCN'nin yapı matrisi olarak birleştirilip kullanılmıştır. Sabit sinyal matrisi sayesinde, yapı matrisinin büyümesiyle birlikte eğitim parametreleri artmamaktadır ve bu sayede aşırı öğrenme riski de ortadan kaldırılmıştır. EEG Motor Movement/Imagery Dataset isimli kamuya açık bir veriseti üzerinde GCN yöntemi kullanmışlardır. Fonksiyonel bağlantılılık (functional connectivity, FC) gibi çoklu özelliklerin kullanılması ile birlikte %98,56 başarımla elde etmişlerdir.

2.3.5. EEG üzerine gerçekleştirilen GNN çalışmaları

Chen, Lin, Ma, Wang ve Tang (2024), çalışmalarında panik duygusu ile kaza öncesi kaçınma yeteneği arasındaki bağlantıyı incelemeyi amaçlamışlardır ve simüle edilmiş bir sürüş ortamında EEG verisi toplayarak duygu sınıflandırma yöntemi önermişlerdir. Önerdikleri yöntem, farklı tehlike seviyelerinde engelden kaçınmayı simüle etmek için araç hızını değişken olarak almaktadır. Topladıkları verileri işlemek için GNN yöntemi kullanarak beynin fizyolojik yapısını simüle etmişlerdir. Ek olarak, entropi ve güç bakış açılarıyla elde edilen özelliklerin karşılaştırıldığı çeşitli deneyler gerçekleştirmişlerdir. Üç sınıflı sınıflandırma sonucunda %76,26 başarımla, İkili sınıflandırma sonucunda %91,5 başarımla elde etmişlerdir. Bu sayede önerdikleri çözümün farklı tehlike durumlarını etkili bir şekilde simüle edebildiğini ve toplanan EEG verileri üzerinde GNN modeli ile birlikte sürücülerin duygusal durumunu etkin bir şekilde izleyebildiğini göstermişlerdir.

Xiang ve diğerleri (2024), çalışmalarında EEG'nin hem zamansal hem de mekansal temsillerini analiz etmek için yeni bir çift akışlı model sunmuşlardır. Zamansal temsilleri, dinamik filtreler olarak işlenen bir CNN modeli ile çıkarmışlardır. Mekansal temsilleri, öğrenilebilir komşuluk matrisleri kullanarak GNN ile öğretmişlerdir. Her aşamada, bir "res-block" tasarımı, zamansal ve mekansal temsilleri birleştirerek zamansal-mekansal bilgilerin birleşimine olanak tanımışlardır. Ardından her iki akışın özetlenmiş temsillerini, motor özelliklerini öğrenmek için tam bağlı sinir ağı ile birleştirmişlerdir. Physionet, OpenBMI ve BCI Competition IV Dataset 2a adlı üç farklı EEG veriseti üzerinde modellerini test etmişlerdir. Dört sınıflı konuya bağımlı paradigmlar için %73,6 bağımsız paradigmlar için %70,4 iki sınıflı konuya bağımlı paradigmlar için %84,2 bağımsız paradigmlar için %82,0 ve dört sınıflı konuya bağımlı paradigma için %78,5 başarımlar elde etmişlerdir.

Babu ve Kanaga (2024), çalışmalarında EEG verilerinden türetilen fonksiyonel bağlantı matrislerine GNN yöntemi uygulayarak duygu tanımayı geliştirmeye yönelik yapay zeka tabanlı tekniklerini DEAP veriseti üzerinde incelemişlerdir. İleri düzey ön işleme yöntemlerinden olan Entegre EEG Sinyal Geliştirme ve Gaussian Zaman Bükme Üretici Karşıt Ağ yöntemlerini birleştirerek veri kalitesini ve çeşitliliğini artırmışlardır. Sinyal ayrıştırma, EMD-Wavelet Hibrit Ayrıştırma yöntemini kullanarak EEG sinyallerinin analiz edilmesini sağlayarak öznel çıkarmını iyileştirmişlerdir. Fonksiyonel bağlantı metrikleri ise doğru duygu karakterizasyonu için kritik sinirsel etkileşimlerini yakalamışlardır. Bunlar sonucunda oluşan çıktılar üzerinde GNN modeli ile testler yapmışlardır. DEAP veriseti üzerindeki sonuçlarda hiperparametre ayarları yapılmadan %94,5 başarımlar elde ederken, yapıldıktan sonra %98,6 başarıma ulaşmışlardır.

Klepl, He, Wu, Blackburn ve Sarrigiannis (2022), çalışmalarında dünyadaki en yaygın demans hastalığı olan alzheimer hastalığını EEG verileri kullanarak otomatik tanısı için grafikler üzerinde öğrenme için iyi performans sunan GNN yöntemi üzerine çalışmışlardır. Alzheimer hastalığının otomatik tanısı için literatürde de sıkça rastlanılan FC ölçütlerinden sekiz adet FC ölçütü kullanmışlardır ve sensör düzeyindeki EEG sinyallerinden FC beyin grafiklerini tahmin etmişlerdir. FC ölçütlerinin sonuçlarını karşılaştırmak için GNN modellerini eğitmişlerdir. Ayrıca literatürdeki üç temel model olan CNN, SVM ve MLP modellerini de GNN sonuçları ile karşılaştırma yapabilmek için eğitmişlerdir. GNN modellerinin diğer üç temel modele göre daha iyi performans gösterdiğini kaydetmişlerdir.

En iyi GNN modeli %91,15 başarımlı, en iyi CNN modeli %84,69 başarımlı, en iyi SVM modeli %73,92 başarımlı, en iyi MLP modeli ise %84,97 başarımlı sonucuna ulaşmışlardır. Beyin grafiğini tahmin etmek için de FC ölçütlerinin kullanılması, EEG sensörleri arasındaki mekansal mesafeye dayalı sabit bir grafik kullanan modellere göre GNN'nin performansını arttırdığını kaydetmişlerdir.

2.4. Mekansal Dikkat Kayması (Spatial Attention Shift)

Dikkat, bilişsel işlevlerin ana bileşenlerinden biri olarak bilişsel kaynakları bilgi işleme süreçlerine odaklama sürecidir. Dikkatin alt alanlarından bazıları; uyanıklık, yönelim, sürekli dikkat, seçici dikkat, bölünmüş dikkat ve yürütücü dikkattir (Vasudevan, Ganapathy, Palaniswamy, Searchfield ve Rajashekhar, 2021). Mekansal dikkat kaymaları, bireyin dikkatinin bir noktadan veya alandan başka bir noktaya veya alana kayması veya yönlendirilmesi anlamına gelir. Ortamda bulunan enerjiler, duyuşal reseptörler tarafından beyne ulaştırılır (Barrett, Barman, Boitano ve Brooks, 2010). Beyne ulaştırılan bu uyarıların yanında bir de beynin içerisinde sürekli ve kendiliğinden bir elektriksel aktivite bulunmaktadır (Aminoff, 2012).

Bir uyarandan gelen bilgileri, bireyin daha verimli bir şekilde işlemesi için dikkatin kaydırılması gerekir. Bu, insan beyninin görsel bilgileri işlemek için sıklıkla kullandığı bir stratejidir. Kaynaklarda sıklıkla 2 tür dikkat ele alınmaktadır. Bazı dikkat kaymaları, bireyin kendi isteğiyle bir uyarana odaklar. Bunun için birey, psikolojik veya fiziksel bir çaba harcar. Bu dikkat türüne, seçici (top-down) dikkat denir. Ders çalışırken çok kısa süreli dikkat verilmesi buna örnek verilebilir. bir diğer dikkat türünde ise, bireyin isteği dışında olabilir ve kendine yönelen uyarana dikkat etmek için herhangi bir çaba harcamaz ve dışsal etkenlere bağlıdır. Bu dikkat türüne, spontane (bottom-up) dikkat denir. Çok parlak bir ışık veya ani bir gürültü buna örnek verilebilir (Delibalta, 2022).

Mekansal dikkat kaymalarını tespit edebilmek için, EEG, MEG, fMRI, göz takip cihazları, nöroplastik değerlendirmeler, BCI, makine öğrenmesi, derin öğrenme, yapay zeka, sanal gerçeklik, artırılmış gerçeklik, TMS, tDCS gibi birçok farklı yöntem kullanılmaktadır. Bunlardan biri olan EEG, mekansal dikkat kaymalarının incelenmesi için güçlü ve hassas bir araçtır ve yaygın olarak kullanılır. EEG kaydının alındığı süre içerisinde, beyne bir uyarın (duyuşal, bilişsel, motor, vb.) uygulandığında, EEG kaydında farklı değişimler

meydana gelir. Aynı uyaranları çok sayıda vermek gibi bazı özel yöntemler kullanılarak özgün değişimler tespit edilebilmektedir (Delibalta, 2022). EEG'nin yüksek zaman çözünürlüğü sayesinde, dikkatin nasıl ve ne zaman yönlendirildiğini incelenebilmektedir. Mekansal dikkat kaymalarında EEG kullanımı sayesinde nörofizyolojik temellerinin anlaşılması sağlanır.

2.5. EEG Kullanılarak Dikkat Kayması Çalışmaları ve Derin Öğrenme

Derin öğrenme ve makine öğrenmesi algoritmaları, karmaşık ve büyük veriler üzerinde yüksek başarımlar vermektedirler. Biyomedikal verilerinin işlenmesinde de makine öğrenmesi algoritmaları ve derin öğrenme algoritmaları özellikle sınıflandırmak için sıklıkla kullanılmaktadır. Biyomedikal verilerden biri olan EEG sinyalleri, yüksek boyutlu ve karmaşık yapısı sebebiyle mekansal alanlar (spatial domain) üzerinden ifade edilebilmektedir. Bu sebeple, biyomedikal verilerinin işlenmesinde makine öğrenmesi algoritmaları ve derin öğrenme algoritmaları özellikle sınıflandırmak için sıklıkla kullanılmaktadır (Uyulan, Ergüzel ve Tarhan, 2019).

EEG sinyallerine mühendislik süreçleri uygulanarak mekânsal dikkat kaymasının tespiti üzerine yapılan doğrudan bir derin öğrenme yaklaşımı uygulamasına yapılan araştırmalar sonucunda ulaşılamamıştır. Bu yüzden tez kapsamında, özellikle DBN, DNN ve CNN gibi popüler ve etkinliği birçok alanda ispatlanmış algoritmalarının farklı öznetelik çıkarma ve ayrıştırma yöntemleriyle hibrit kullanımı üzerine yoğunlaşmıştır.

3. MATERİYAL VE METOT

3.1. Derin Öğrenme

Derin öğrenme, yapay zeka ve makine öğrenmesinin bir alt dalı olarak tanımlanır. Kısaca derin öğrenme, makine öğrenmesinin daha karmaşık ve derin yapılarından yararlanarak insana gerek kalmadan veri setlerinden öğrenme ve sonuca varma kapasitesini artırır. Derin öğrenme karmaşık veri setlerinden açıklayıcı kalıplar ve ilişkiler çıkarabilen birden fazla katmanlı yapay sinir ağlarını kullanır. Bu sistemde ilk katmanlar temel özellikleri öğrenirken, sonraki katmanlar bu özellikleri birleştirerek daha karmaşık yapıları sonuca ulaştırır.

3.1.1. Derin inanç ağları (deep belief networks, DBN)

Derin Öğrenme (Deep Learning) algoritmaları 2 yönteme ayrılmaktadır; unsupervised (gözetimsiz) ve supervised (gözetimli) öğrenme yöntemleri. DBN'ler bu 2 yöntemi bir araya getiren çok katmanlı olasılıksal modellerdir. Her katman, olasılıksal grafik modeline dayanan bir dizi gizli birimden oluşmaktadır. DBN'ler, birden fazla gizli katmana sahip olabilir ve her katman, bir önceki katmanın çıktısını girdi olarak almaktadır. DBN'ler genellikle sınıflandırma ve öznetelik çıkarma gibi görevler için kullanılır. DBN'nin gerçek zamanlı uygulama senaryolarında görüntü tanıma, ses tanıma, doğal dil işleme, veri madenciliği, ilaç keşfi (Movahedi, Coyle ve Sejdic 2018), EEG sinyalleri, malzeme kontrolü gibi birçok alanda kullanılabilir (Naskath, Sivakamasundari ve Begum, 2023). Özellikle, karmaşık veri yapılarını ve ilişkilerini öğrenme konusundaki başarısı, DBN'leri popüler kılmaktadır. Çok katmanlı yapıları sayesinde karmaşık veri yapılarını ve ilişkilerini öğrenebilir (Bengio ve Delalleau, 2009; Hinton, Osindero ve Teh, 2006).

Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines, RBM) DBN'lerin yapıtaşlarıdır ve genellikle eğitimleri bu yöntem kullanılarak yapılır. RBM'ler, 2 katmanlı grafik modelidir ve görünür (v) ve gizli (h) birimler içerir (Altan ve diğerleri, 2016a). Olasılıksal bir modeldir ve enerjiyi minimize ederek çalışırlar.

$$E(v, h) = -\sum_i \sum_j v_i h_j W_{ij} - \sum_i b_i c_i - \sum_j c_j \quad (3.1)$$

Burada:

- v : Görünür birimlerin vektörü
- h : Gizli birimlerin vektörü
- W_{ij} : Görünür birim v_i ile gizli birim h_j arasındaki ağırlık
- b_i : Görünür birim v_i için önyargı
- c_j : Gizli birim h_j için önyargı

Ortak olasılık dağılımı ise Gibbs dağılımı kullanılarak tanımlanır:

$$P(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (3.2)$$

Burada Z normalizasyon sabiti (partition function) olup, tüm olası görünür ve gizli birim konfigürasyonları üzerinden toplam alınarak hesaplanır:

$$Z = \sum_{v, h} e^{-E(v, h)} \quad (3.3)$$

DBN'ler, katman katman eğitilir. Her katman, önceki katmanın çıktısını girdi olarak alır ve RBM kullanarak eğitilir. DBN'lerin eğitim sürecinde: Giriş verilerinin ileri besleme adımı olarak giriş verileri, görünür katmandan gizli katmana aktarılır. Gizli birimlerin aktivasyon olasılıkları, giriş verileri kullanılarak hesaplanır. Geri besleme adımı vardır yani gizli katmandan yeniden görünür katmana veri aktarımı yapılır. Ağırlıklar görünür ve gizli katmanlar arasındaki farklara göre güncellenir (Altan, Kutlu ve Allahverdi, 2016b). Bu eğitim süreci, ağırlıkların düzgün bir şekilde optimize edilmesini sağlar ve derin öğrenme modelinin daha karmaşık veri yapılarını öğrenmesine olanak tanır. Tüm RBM'ler ön eğitimle eğitilmesinin ardından, ağırlık tamamı denetimli bir öğrenme algoritması ile ince ayardan (fine-tuning) geçirilerek, modelin doğruluğu artırılır. Genellikle Backpropagation (geri yayılım) algoritması kullanılır (Altan ve diğerleri, 2016b).

3.1.2. Derin sinir ağları (deep neural networks, DNN)

DNN, birden fazla katmandan oluşan yapısıyla, veri içindeki karmaşık ilişkileri öğrenme kapasitesine sahiptir. Her bir katman, girdileri alır, işlem yapar ve sonuçları bir sonraki katmana iletir. Giriş katmanı (input layer), modelin aldığı ham veriyi temsil eder. Örneğin, bir görüntü tanıma uygulamasında, giriş katmanı her bir piksel değerini temsil edebilir. Çıkış katmanı, modelin tahmin ettiği çıktıları sağlar. Çıkış katmanındaki (output layer)

nöronların sayısı, modelin çözmekte olduğu probleme bağlıdır. Örneğin, bir sınıflandırma probleminin çıkış katmanında, sınıf sayısı kadar nöron bulunur. Her nöron, bir ağırlık (w) ve önyargı (b) ile çarpılan girdi değerlerinin toplamını alır ve aktivasyon fonksiyonunu uygular:

$$z_i^{(l)} = -\sum_j w_{ij}^{(l)} a_j^{(l-1)} + b_i^{(l)} \quad (3.4)$$

Aktivasyon fonksiyonu uygulanarak nöronun aktivasyonu elde edilir. Aktivasyon fonksiyonları, nöronların çıktısını hesaplamak için kullanılır ve doğrusal olmayan dönüşümler sağlar. Doğrultulmuş lineer birim (Rectified Linear Unit, relu), Sigmoid, Tanh, Leaky Relu en sık kullanılan aktivasyon fonksiyonları içerisinde yer alır.

Eğitim sürecinde; ileri besleme (forward propagation), kayıp fonksiyonu (loss function), geri yayılım optimizasyon algoritmaları ve dropout, erken durdurma (early stopping) ve L2 düzenlemesi (L2 regularization) yöntemleri sıklıkla kullanılır.

- İleri besleme, verisetinin girişten çıkışa doğru katmanlar boyunca iletilmesidir. Her bir katmandaki nöronlar, bir önceki katmandan gelen veriyi kullanarak aktivasyonlarını hesaplar. Bu süreç: Giriş katmanından veriler alınır; Her gizli katman giriş verisini alarak aktivasyonlarını hesaplar; Çıkış katmanı, son gizli katmandan gelen veriyi kullanarak modelin tahminlerini oluşturur.
- Loss fonksiyonu, model tahminlerinin doğruluğunu ölçmek için kullanılır. Çapraz Entropi (Cross-Entropy) ve Ortalama Karesel Hata (Mean Squared Error, MSE) en sık kullanılan loss fonksiyonlarıdır.
- Geri yayılım, modelin ağırlıklarını ve önyargılarını optimize etmek için kullanılır. Bu süreç, zincir kuralı kullanılarak hata terimlerinin katmanlar boyunca geri iletilmesiyle gerçekleştirilir.
- Optimizasyon algoritmaları, modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlar. Stokastik Gradyan İnişi (SGD), Mini-Batch Gradyan İnişi, Momentum, Adam (Adaptive Moment Estimation), RMSprop en sık kullanılan optimizasyon algoritmalarıdır.
- Dropout, eğitim sırasında rastgele nöronları devre dışı bırakarak aşırı öğrenmeyi önler.
- Early stopping, doğrulama hatası belirli bir sayıda art arda azalmadığı zaman eğitimi durdurarak aşırı öğrenmeyi önler.
- L2 düzenlemesi, ağırlıkların büyüklüğünü sınırlayarak aşırı öğrenmeyi önler.

DNN mimarileri olarak sıklıkla aşağıdaki algoritmalar kullanılmaktadır:

- CNN: Özellikle görüntü ve video işleme görevlerinde kullanılan bir DNN türüdür.
- RNN: Sıralı verileri (örneğin, zaman serileri veya metin) işler.

- LSTM ve Gated Recurrent Units (GRU): RNN'lerin yaygın varyantlarıdır ve uzun vadeli bağımlılıkları öğrenme yeteneklerini artırır.

3.1.3. Evrişimli sinir ağları (convolutional neural networks, CNN)

CNN, biyolojik görme sisteminden ilham alınarak geliştirilen ve özellikle görsel veriler üzerinde yüksek başarımla çalışabilen derin öğrenme yöntemlerinden biridir. Veri içindeki desenleri ve ilişkileri öğrenme kapasitesi nedeniyle sıklıkla tercih edilmektedir. Ayrıca büyük veri kümelerinde yüksek başarımla sağlanması, verinin farklı ölçeklerde ve konumlarda özelliklerini etkili bir şekilde çıkarması, farklı katman yapıları ve filtre boyutları ile özelleştirilebilir olması, girdi verisindeki yerel özellikleri tanımada etkili olması gibi pek çok avantaj sağlar. En büyük dezavantajlarından biri ise CNN modellerini eğitmek çok zaman alıcıdır ve gelişmiş donanım (GPU) gerektirir (Altan, 2022).

CNN'in en güçlü olduğu alan görsel veri işleme alanıdır ancak sadece görüntü işlemede değil, nesne tespiti gibi bilgisayarlı görüde, metin sınıflandırma gibi doğal dil işlemede, hastalık teşhisi gibi tıbbi görüntülemede, otonom araçlarda nesneleri ve yol algılamada gibi birçok farklı alanda da kullanılmaktadır.

Geleneksel yapay sinir ağlarından farklı olarak özel bir katman yapısına sahiptir ve her bir katman giriş verisinden öznitelik çıkarımı ve doğrusal olmayan dönüşüm gibi belirli matematiksel işlemler gerçekleştirir. Genellikle şu ana bileşenlerden oluşmaktadır:

- Evrişim Katmanı: CNN modelindeki giriş verisinden öznitelik haritaları çıkaran ana katmandır. Filtreler (kerneller) kullanarak girdi üzerindeki belirli desenleri tespit eder. Filtreler, giriş verisi üzerinde kayarak verinin farklı özelliklerini çıkarır. Bir filtre (F) ve bir giriş (X) arasındaki evrişim işleminin matematiksel ifadesi Eş. 3.5'te verilmiştir ve i ve j , filtrenin giriş üzerindeki pozisyonlarını belirtmektedir.
- Aktivasyon Fonksiyonu: Evrişim katmanında çıkarılan özelliklerin doğrusal olmayan bir dönüşüm geçirmesi için bir aktivasyon fonksiyonu kullanılır.
- Doğrusal Olmayanlık Katmanı: Modelin doğrusal olmayan ilişkileri öğrenebilmesini sağlamak amacıyla doğrusal olmayan aktivasyon fonksiyonlarının yer aldığı katmandır (Değirmenciler, Cengiz ve İleri, 2022).
- Havuzlama Katmanı: Öznitelik haritalarının boyutunu azaltarak işlem maliyetini düşürür ve ağıın önemli özelliklere odaklanmasını sağlar.
- Düzleştirme Katmanı: Verilerin yapay sinir ağı girişi için hazırlandığı ve çok boyutlu veriyi tek boyutlu bir vektöre dönüştüren katmandır (Değirmenciler ve diğerleri, 2022). Örneğin $5 \times 5 \times 128$ boyutunda bir matris var ise, bu katman ile 3200 boyutunda bir vektöre dönüştürülmektedir.
- Tam Bağlantılı Katman: Ağıın sonunda yer alır ve elde edilen öznitelikleri bir sınıflandırıcıya veya regresyon fonksiyonuna aktarır ve çıktıları hesaplar

(Fukushima, 1980). Ayrıca, ağı tüm nöronlarının birbiriyle bağlantılı olduğu klasik bir sinir ağı yapısını ifade eder.

- Çıkış Katmanı: Problemin türüne bağlı olarak sınıflandırma veya regresyon sonuçlarını verir.

$$(X * F)(i, j) = \sum_m \sum_n X(i + m, j + n) \cdot F(m, n) \quad (3.5)$$

LeNet-5, AlexNet, VGGNet, GoogleNet, ResNet, DenseNet, MobileNet ve Efficient gibi CNN için önceden eğitilmiş kabul görmüş modeller bulunmaktadır (Gaba ve diğerleri, 2022). Bu önceden eğitilmiş modeller büyük veri setlerinde eğitilmiş ve geniş bir akademik literatürde yer bulan ağ yapılarıdır. Yüksek doğruluk oranlarına ulaşmış ve özellikle transfer öğrenme süreçlerinde sıklıkla kullanılmaktadırlar. VGG16, VGG19 ve ResNet50 önceden eğitilmiş modelleri bu tez çalışması kapsamında kullanılan CNN modelleridir.

3.1.4. Grafik sinir ağları (graph neural networks, GNN)

GNN, düzensiz grafik verileri üzerinde öğrenme gerçekleştirmek için geliştirilmiş derin öğrenme modelleridir. Geleneksel derin öğrenme yöntemleri genellikle düzenli ve ızgara benzeri veri yapılarında (örneğin, görüntülerde) etkili bir şekilde çalışırken, GNN'ler, düğümler (nodes) ve kenarlardan (edges) oluşan grafik yapılarında yer alan ilişkileri modellemek için tasarlanmıştır. Bu model, düğümler arasındaki bağlantılar ve ilişkilerden öğrenerek, her bir düğüm, kenar veya grafik yapısının tamamı için anlamlı temsiller (representations) oluşturur. GNN'lerin temel amacı, grafik yapısını ve düğüm özelliklerini kullanarak anlamlı bilgileri ortaya çıkarmaktır (Wu ve diğerleri, 2024).

Grafikler, düğümler arasındaki ilişkilerin ve bu düğümler üzerindeki özelliklerin bir arada işlendiği kompleks veri yapılarıdır. GNN'ler, bu veri yapılarını doğrudan analiz ederek, her düğüm ve kenar üzerinde yüksek seviyeli bilgi öğrenme imkânı sunar. Grafikler, sosyal ağlar, moleküler yapılar, bilgi ağları ve birçok diğer uygulama alanında temel veri yapıları olarak karşımıza çıkmaktadır (Rittig, Gao, Dahmen, Mitsos ve Schweidtmann, 2023). Bu bağlamda, GNN'lerin önemli bileşenleri aşağıdaki gibi tanımlanabilir:

- Düğüm (Node): Grafikteki temel bileşendir. Örneğin, bir sosyal ağda düğüm, bir bireyi temsil eder.

- Kenar (Edge): D ğ mler arasındaki baėlantıyı g sterir. Bu baėlantılar, y nl  (directed) veya y ns z (undirected) olabilir. Sosyal bir aėda,  rneėin, bir kenar, iki birey arasındaki arkadařlıėı g sterebilir.
- Komřuluk Matrisi (Adjacency Matrix): Grafiėin yapısını matematiksel olarak temsil eden bir matristir. Bu matris, $A_{ij} = 1$ ifadesiyle, i ve j d ė mleri arasındaki bir baėlantıyı g sterir.
- D ė m  zellik Matrisi (Feature Matrix, X): Her bir d ė m i in bir  zellik vekt r  i erir. Bu  zellikler,  rneėin bir bireyin yařını, mesleėini veya sosyal aėdaki pop lerliėini temsil edebilir.

GNN'ler, grafik yapısındaki d ė mler arasındaki bilgi alıřveriřini optimize etmek i in mesajlařma (message passing) y ntemini kullanır. Bu s re , her bir d ė m n komřularından gelen mesajları toplayarak  zelliklerini g ncellemesi řeklinde iřler. Bu iřlem birka  ařamadan oluřur:

- Mesajlařma (Message Passing): Her d ė m, komřularından gelen mesajları alır. Bu mesajlar, d ė m  zellikleri ve kenar aėırlıkları dikkate alınarak hesaplanır.
- Toplama (Aggregation): Alınan mesajlar birleřtirilir. Toplama genellikle toplam, ortalama veya maksimum gibi fonksiyonlar ile yapılır.
- G ncelleme (Update): Toplanan bilgiler, d ė m  zelliklerini g ncellemek i in kullanılır.

Bu iřlem, grafik  zerinde iteratif bir řekilde ger ekleřtirilir ve her adımda d ė mler, komřuları ile olan iliřkilerinden  ėrendikleri bilgilere g re g ncellenir. Matematiksel olarak bu s re , Eř. 3.6'daki gibi ifade edilebilir. Burada Eřitliėin solundaki ifade 1'inci katmanda d ė m i 'nin  zellik vekt r , $N(i)$ d ė m i 'nin komřularının k mesi, e_{ij} i ve j d ė mlerinin arasındaki kenar aėırlıėı, f mesaj fonksiyonu, σ ise aktivasyon fonksiyonunu temsil etmektedir.

$$h_i^{(l+1)} = \sigma \left\{ \sum_{j \in N(i)} f(h_i^{(l)}, h_j^{(l)}, e_{ij}) \right\} \quad (3.6)$$

GNN'lerin uygulama alanları olduk a geniřtir. Sosyal aė analizlerinden protein yapısı tahminine, gen etkileřimi analizlerinden řehir i i trafik akıřının modellenmesine kadar bir ok farklı disiplinde kullanılmaktadır. Ayrıca, doėal dil iřleme alanında grafik temelli anlam  ıkarımı ve sosyal bilimlerde toplumsal aė analizi gibi konularda da etkin bir řekilde yer almaktadır. Son yıllarda, EEG motor imajı sinyallerinin sınıflandırılmasında da GNN'lere olan ilgi artmıřtır. Bu y ntem, EEG kanalları arasındaki mekansal iliřkileri daha etkili bir řekilde modelleyerek, geleneksel evriřimli sinir aėlarına kıyasla daha y ksek doėruluk oranları elde edilmesine olanak saėlamaktadır (Aung, Li, An ve Su, 2024).

GNN'ler için iki ana eğitim yöntemi bulunmaktadır: full-batch training ve mini-batch training. Full-batch training, tüm grafiği kullanarak model parametrelerinin tek bir güncelleme ile optimize edilmesini sağlayan bir yöntemdir. Bu yöntem, küresel bir perspektif sunar ve her güncelleme sonrasında daha doğru sonuçlar elde edilmesini sağlar. Ancak, büyük grafiklerde yüksek bellek ve hesaplama gereksinimlerinden ötürü pratikte zorluklar yaşanabilir. Mini-batch training, modeli daha küçük ve yönetilebilir alt grafiklere bölerek her bir güncelleme için yalnızca alt küme üzerinde işlem yapılmasını sağlar. Bu yöntem, büyük grafikler üzerinde daha verimli çalışır ve daha hızlı yakınsama sağlar (Md ve diğerleri, 2021).

Mini-batch training süreci, birkaç temel adımdan oluşur: örnekleme, özellik toplama, veri yükleme ve model hesaplama. Örnekleme, büyük grafiklerden yönetilebilir alt küme seçimi yapar ve bu alt küme, yapısal, semantik ve zamansal bilgiler dikkate alınarak seçilir. Özellik toplama aşamasında, seçilen düğüm ve kenarların özellikleri toplanır. Veri yükleme, bu verileri uygun bir formata dönüştürüp, GPU'lar üzerinde işlem yapmak üzere hazırlanır. Son olarak, model hesaplama adımı parametreler başlatılır, ileri yayılım (forward propagation) yapılır, kayıp hesaplanır, gradyanlar geri yayılım yoluyla hesaplanır ve parametreler güncellenir. Eğer çoklu GPU veya sunucu kullanılıyorsa, geri yayılım işleminden sonra gradyan senkronizasyonu yapılması gerekebilir. Bu döngü, model yakınsamaya ulaşana kadar tekrarlanır. Eğitim süreci tamamlandıktan sonra, eğitilen modelle GNN inference aşaması gerçekleştirilir ve yeni veriler üzerinde tahminler yapılır (Wu ve diğerleri, 2024).

Zaman içinde, GNN algoritmalarının çeşitli versiyonları geliştirilmiştir. Bu versiyonlar arasında GCN, Grafik Dikkat Ağları (Graph Attention Networks, GAT), GraphSAGE, Mesaj Geçiş Sinir Ağları (Message Passing Neural Networks) gibi modeller yer almaktadır. Bu gelişmeler, farklı grafik yapılarına yönelik daha verimli ve etkili çözümler sunmakta, GNN'lerin kullanım alanlarını genişletmektedir.

3.1.5. Grafik evrişimli ağlar (graph convolutional networks, GCN)

CNN modelinin bir türevi olan GCN, özellikle grafik (ağ) verileri üzerinde veri işlemek için kullanılan bir tür derin öğrenme modelidir (Gümüş ve Eyüpoğlu, 2024). Grafikselle veriler, düğümler (nodes) ve bu düğümler arasındaki ilişkileri gösteren bağlantılardan

(edges) oluşur. Geleneksel CNN, grid-benzeri (örneğin, görüntü verisi) yapılarda etkili olsa da, düzensiz grafik yapılarını işlemede yetersiz kalabilmektedir (Zhao ve diğerleri, 2018). GCN'ler, grafiklerdeki düğümler arasındaki yapısal bilgiyi analiz etmek ve öğrenmek için geliştirilmiş özel bir mimaridir. Grafiklerdeki düğümler için özellik çıkarmak ve düğüm sınıflandırma, bağlantı tahmini veya grafik sınıflandırma gibi görevleri çözmek GCN modelinin temel amacıdır. Düğümler arasındaki komşuluk bilgisini kullanarak her bir düğüm için komşularının özelliklerini toplar ve birleştirir. Bu sayede grafik üzerinde dolaşan bilgiyi işler ve belirli bir görev için anlamlı özellikler çıkarır.

GCN modeli, giriş olarak bir grafik/matris almaktadır. Giriş verisi olan bu grafik, düğümlerden (V) ve düğümlerin arasındaki bağlantıların olduğu kenarlardan (E) oluşmaktadır ve Eş. 3.7'deki gibi ifade edilmektedir (Zhang, Tong, Xu ve Maciejewski 2019).

$$G = (V, E) \quad (3.7)$$

GCN algoritmaları; kullanıcılar arasındaki ilişkileri modelleyerek sosyal ağlarda düğüm sınıflandırması ve etkileşim tahmininde, molekül yapısı gibi grafik yapıda veriyle çalışarak molekül sınıflandırmasında, kullanıcı ve ürünler arasındaki bağlantıları grafik şeklinde temsil ederek kişiye özel öneriler yapan tavsiye sistemlerinde, kelimeler arası ilişkileri grafik yapısında temsil ederek ilişki çıkarımı ve anlamsal analiz yapmada vb. geniş bir uygulama alanına sahiptir.

Temel çalışma prensibi, komşuluk tabanlı mesajlaşma olarak bilinir ve her bir düğümün yalnızca komşularıyla etkileşim kurarak özelliklerini güncellemesi ile ilerler. Bu süreçte, komşuluk matrisinden ve düğüm özelliklerinden yararlanır (Shang ve diğerleri, 2018).

- Komşuluk matrisi: Grafik bağlantılarını gösteren bir matristir ve iki düğüm arasında bir bağlantı varsa 1, yoksa 0 değerini içerir (Negi ve Shukla, 2019).
- Düğüm Özellik Matrisi: Her düğümün özelliklerini gösterir ve grafikte N düğüm ve her düğüm için F özellik var ise: X matrisi $N \times F$ boyutundadır (Zhang, Song, Aletras ve Lu 2022).

Grafik tabanlı veri yapılarında yapısal bilgiyi çıkarmak için ideal yöntemlerden biri olan GCN'ler, grafiklerdeki düğümler arasındaki ilişkileri anlamak ve bu yapıyı kullanarak belirli görevler için öğrenme yaparak geleneksel metotlara göre üstünlüğünü ortaya

koymaktadır. Komşuluk bilgisi kullanımı ile düğüm özelliklerinin yanı sıra, komşuların özelliklerini de hesaba katarak grafik verisinde derinlemesine analiz sağlamaktadırlar (Negi ve Shukla, 2019). Komşuluk algoritması bu tez çalışması kapsamında da kullanılmıştır.

3.2. Geleneksel Makine Öğrenmesi Algoritmaları

Makine öğrenmesi, bilgisayarların deneyimlerden öğrenerek ve otomatik olarak gelişerek belirli görevleri yerine getirmesini sağlayan bir yapay zeka dalıdır. Önceden programlanmış kurallardan değil, verilerden anlamlı kalıplar ve ilişkiler çıkararak gerçekleşir. Bu çalışmada kullanılan makine öğrenmesi modelleri dört başlık şeklinde belirtilmiştir ve her başlık altında bu öğrenme modellerinin tanımlarına yer verilmiştir.

3.2.1. Karar ağacı (decision tree)

Karar ağacı, sınıflandırma ve regresyon problemlerinde kullanılan, hiyerarşik yapıya sahip, sezgisel ve anlaşılır bir makine öğrenmesi modelidir. Tıp, finans, ekonomi, pazarlama, biyoinformatik, biyoistatistik, psikoloji, eğitim, çevre bilimleri, havacılık gibi birçok alanda kullanılmaktadır. Veri ön işleme gereksinimi azdır ve genellikle özellik ölçekleme, normalizasyon gibi ön işlemler gerektirmez. Hem etiketli/kategorik hem de etiketsiz/sürekli veriler ile çalışabilmesi sebebiyle esnektir. Ayrıca hesaplaması ve tahmin işlemi diğer makine öğrenmesi algoritmalarına kıyasla hızlıdır. Fakat aşırı öğrenme yapma eğilimindedirler ve bu da performanslarının düşmesine sebep olur.

Karar ağaçları, kök düğümden (root node) yaprak düğümlere (leaf nodes) kadar dallanarak ilerleyen bir yapıdadır. Temel bileşenleri, kök düğüm, iç düğümler (internal nodes) ve yaprak düğümlerdir (Özekes, 2002).

- Kök Düğüm: Ağacın başlangıç noktasıdır ve verinin tamamını içerir.
- İç Düğümler: Veriyi belirli kriterlere göre dallara ayıran düğümlerdir. Her iç düğüm, belirli bir özellik ve eşik değeri kullanarak veriyi iki veya daha fazla alt gruba ayırır. Bu süreç, veri homojen hale gelene veya belirli durma kriterleri karşılanana kadar devam eder.
- Yaprak Düğümler: Nihai sınıflandırma sonucunu veya tahmin sonucunu içerir.

Karar ağaçları, Sınıflandırma Ağaçları (Classification Trees) ve Regresyon Ağaçları (Regression Trees) olmak üzere kullanım amacına göre iki ana kategoriye ayrılır.

Sınıflandırma Ağaçları, girdi verilerini belirli kategorilere ayırmak için kullanılır. Her yaprak düğüm, bir sınıf etiketi içerir. Regresyon Ağaçları ise sürekli bir hedef değişkenin tahmin edilmesi için kullanılır. Her yaprak düğüm, bir sayısal değer içerir.

Karar ağaçlarının temelini, verisetini bölme (splitting) işlemi oluşturur. Bu bölme işlemi, belirli bir ölçüt kullanılarak gerçekleştirilir. Sınıflandırma ağaçları için kullanılan yaygın bölme ölçütleri arasında Gini indexi, bilgi kazancı (information gain), Karşılıklı bilgi (Mutual Information) bulunmaktadır. Regresyon ağaçları için kullanılan yaygın bölme ölçütleri arasında MSE ve Ortalama Mutlak Hata (Mean Absolute Error, MAE) bulunmaktadır.

Karar ağaçlarını oluşturmak için çeşitli algoritmalar geliştirilmiştir; Tekrarlı İkilikçi Ağaç (Iterative Dichotomiser 3, ID3), C4.5, CART (Classification and Regression Trees).

- ID3: Entropi ve bilgi kazancı kullanarak en iyi ayırma noktasını bularak tekrarlayan bölme işlemi ile ağacı oluşturur.
- C4.5: ID3 algoritmasının geliştirilmiş versiyonudur. Sürekli ve kategorik verilerle çalışabilir ve budama (pruning) işlemi ile aşırı öğrenmeyi azaltır.
- CART: Hem sınıflandırma hem de regresyon görevleri için kullanılır. Gini indeksi ve varyans azaltma (variance reduction) gibi ölçütler kullanarak bölme işlemi yapar.

Karar ağacının aşırı öğrenmeyi azaltmak ve genelleme kabiliyetini arttırabilmek için budama optimizasyon tekniği kullanılabilir. Ön budama (pre-pruning) ve Son Budama (post-pruning) adlı 2 adet budama türü vardır. Ön budama yöntemi, ağaç oluşturma işlemi sırasında belirli kriterlere göre (belirli bir derinliğe ulaşıldığında veya belirli bir düğümdeki örnek sayısı azaldığında gibi) dallanma işlemini durdurmaktadır. Son budama, ağaç oluşturulduktan sonra, gereksiz dalları keserek ağacı basitleştirir, doğrulama seti kullanılır ve performansı artırır.

Karar ağaçlarında sık kullanılan bir başka optimizasyon tekniği ise, ensembl yöntemleridir. Ensemble yöntemleri, birden fazla karar ağacını birleştirerek daha güçlü modeller oluşturabilir. Bagging (Bootstrap Aggregating) ve Boosting adlı 2 adet ensembl yöntemi bulunmaktadır. Bagging, örnekleme yaparak birden fazla karar ağacı oluşturur ve sonuçlarını birleştirir. RF algoritması bu yöntemle bir örnektir. Boosting, her ağaç oluşturulduğunda hataları minimize etmeye çalışır. AdaBoost ve Gradient Boosting algoritmaları bu yöntemle birer örnektir.

3.2.2. Destek vektör makineleri (support vector machines, SVM)

SVM, ilk kez Vapnik (1999) tarafından 1990'ların başlarında makine öğrenmesi yöntemi olarak önerilmiştir. Denetimli öğrenme yöntemleri arasında yer alır ve sınıflandırma ile regresyon problemlerini çözmek için kullanılan güçlü bir makine öğrenmesi modelidir (Trigo-González ve diğerleri, 2023). Görüntü işleme, doğal dil işleme, finans, biyoinformatik, biyoistatistik, sinyal işleme, tıp, istatistik, genetik gibi birçok alanda kullanılmaktadır. SVM, iki veya daha fazla sınıfı ayıran en iyi ayırım çizgisini (veya hiperdüzlemi) bulmayı hedefleyen bir sınıflandırma algoritmasıdır. SVM, özellikle yüksek boyutlu veri setlerinde ve sınıflandırma problemlerinde iyi performans gösterir ve marjinal ayırım (margin) kavramını kullanarak karar sınırını (decision boundary) tanımlar.

SVM'nin temel amacı, ayırım çizgisinin marjını maksimize etmektir. Bu bir optimizasyon problemi olarak formülize edilir. Bu problem, genellikle bir Lagrange çarpanı kullanılarak çözülür ve dual formülasyonu kullanılarak daha verimli hale getirilir.

- Hiperdüzlem (Hyperplane), SVM verileri iki sınıfa ayıran bir ayırım çizgisidir. Bu ayırım çizgisi, düşük boyutlu uzaylarda bir çizgi veya düzlem olarak adlandırılırken, yüksek boyutlu uzaylarda ise bir hiperdüzlem olarak adlandırılır (Wu, Li, Yin, Wang ve Zheng, 2023).
- Marj (margin), iki paralel hiperdüzlem arasındaki mesafe olarak tanımlanır ve sınıflar arasındaki ayırımı (hiperdüzlemler arasındaki mesafeyi) en geniş şekilde sağlamayı amaçlar. Algoritma bu hiperdüzlemi yalnızca doğrusal olarak ayrılabilen problemler için bulabilir; çoğu pratik problemde ise algoritma, esnek marjı maksimuma çıkararak az sayıda yanlış sınıflandırmaya izin verir (Trigo-González ve diğerleri, 2023).
- Destek vektörleri, hiperdüzleme en yakın olan veri örnekleridir ve modelin oluşturulmasında kritik rol oynar. Bu vektörler, karar sınırını belirler ve modelin genelleme yeteneğini etkiler.

SVM, lineer olarak ayrılabilir olmayan veriler için kernel fonksiyonları kullanarak veriyi yüksek boyutlu bir uzaya dönüştürür. Bu sayede, lineer ayırım sınırları oluşturulabilir, doğrusal olmayan sınırları öğrenmeye olanak tanır. Kernel seçimleri ve regularizasyon parametreleri, modelin performansını etkileyen önemli faktörlerdir. Polinom Kernel, RBF (Radial Basis Function) veya Gauss Kernel ve Sigmoid Kernel en yaygın Kernel fonksiyonları arasındadır. Fakat büyük veri setlerinde ve karmaşık Kernel fonksiyonları kullanıldığında hesaplama maliyeti yüksek olabilir.

3.2.3. En yakın k tane komşu algoritması (k-nearest neighbour, k-NN)

K-NN algoritması, istatistiksel öğrenmede kullanılan, denetimli öğrenme tekniklerinden biridir. Özellikle sınıflandırma ve regresyon problemlerinde sıklıkla tercih edilir. Eğitim aşamasında herhangi bir model oluşturmaz, eğitim süresi gerekmez ve hesaplamalar doğrudan veri noktaları üzerinden (test aşamasında) yapılır (Mitchell, 1997). Bu sebeple basit ve sezgisel bir yaklaşım sunar. Veri dağılımına veya yapısına dair herhangi bir varsayım gerektirmez. Sınıflandırma veya regresyon yapmak için bir veri noktasının k en yakın komşusuna bakar ve bu komşuların özelliklerine göre karar verir. Sınıflandırma problemlerinde, çoğunluk sınıfına dayalı bir karar verilirken, regresyon problemlerinde ise komşuların ortalaması alınır.

K değerinin seçimi çok kritiktir. Kullanılacak verisetine en uygun k değeri bulunmalıdır. En uygun k değerini belirlemek için çapraz doğrulama (cross-validation) yöntemi kullanılabilir. Çok küçük k değerleri, modele duyarlılık ve aşırı öğrenme risklerinde artış gösterirken, çok büyük k değerleri modelin genelleme yeteneğini artırır ancak potansiyel olarak yetersiz öğrenme (underfitting) riski taşır. Ayrıca farklı ölçeklerdeki özniteliklerin mesafe hesaplamalarını etkilememesi için özniteliklerin normalize edilmesi veya standartlaştırılması da çok önemlidir. k-NN algoritması, temel olarak iki adımda gerçekleştirilir: komşuları bulma ve sınıflandırma veya regresyon yapma.

- Komşuları Bulma: En yaygın olarak kullanılan mesafe metriği, Öklidyen mesafenin yanı sıra Manhattan ve Minkowski formülleri de kullanılmaktadır (Altan ve İnät, 2021). Mesafe metriği seçimi, veri kümesinin yapısına bağlı olarak performansı etkileyebilir.
- Sınıflandırma: Bir veri noktasının sınıfını belirlemek için, k en yakın komşusunun sınıfları kontrol edilir ve en sık rastlanan sınıf seçilir. Bu işlem, çoğunluk oylaması (majority voting) olarak bilinir.
- Regresyon: Bir veri noktasının hedef değerini belirlemek için, k en yakın komşusunun hedef değerlerinin ortalaması alınır.

Veri madenciliği, örüntü tanıma, tıp, finans, makine öğrenmesi eğitiminde başlangıç algoritması olarak ve daha birçok alanda k-NN algoritması kullanılmaktadır. Kolay anlaşılır ve uygulanabilir. Büyük veri kümelerinde yavaş çalışabilir, çünkü her bir test noktası için tüm veri noktaları ile mesafe hesaplaması yapılır ve performansı düşebilir çünkü “mesafe” kavramı anlamını yitirebilir. Genellikle, veri noktalarının yoğun olduğu

bölgelerde performansı daha iyidir, ancak seyrek veri noktalarının olduğu bölgelerde performansı düşebilir.

3.2.4. Çok katmanlı algılayıcı (multilayer perceptron, MLP)

MLP, yapay sinir ağlarının en temel ve yaygın kullanılan türlerinden biridir. Yapay sinir ağları, biyolojik sinir ağlarının işleyişine benzer bir şekilde bilgi işleyen ve öğrenen sistemlerdir. MLP, bir veya daha fazla gizli katmana sahip olan ileri beslemeli (feedforward) sinir ağıdır. Her katman, tam bağlantılı nöronlar içerir ve bir aktivasyon fonksiyonu kullanarak girdileri işler. MLP'nin yapısı aşağıdaki gibidir (Altan ve İnät, 2021):

- Girdi Katmanı (Input Layer): Veri kümesindeki her bir özellik için bir nöron içerir. Bu katman, ham veriyi ağına alır.
- Gizli Katmanlar (Hidden Layers): Bir veya daha fazla gizli katman, girdi katmanından gelen veriyi işler ve ileri katmanlara iletir. Gizli katmanların sayısı ve her katmandaki nöron sayısı, ağın kapasitesini ve karmaşıklığını belirler.
- Çıktı Katmanı (Output Layer): Çıktı katmanı, ağı tahminlerini veya sınıflandırmalarını içerir. Çıktı nöronlarının sayısı, problem türüne bağlı olarak değişir (örneğin, sınıflandırma için sınıf sayısı kadar nöron).

MLP'nin matematiksel modelleri aşağıdaki gibi özetlenebilir:

- Ağırlıklar ve Önyargılar (Weights and Biases): Her bir bağlantı, belirli bir ağırlık (w) ve her bir nöron bir önyargı (b) değeri ile ilişkilidir. Ağırlıklar ve önyargılar, ağı öğrenme sürecinde güncellenir.
- İleri Besleme: Girdi verileri, ağırlıklar ve önyargılar kullanılarak gizli katmanlar boyunca ileri doğru geçirilir. Her bir nöronun çıktısı, bir aktivasyon fonksiyonu (ϕ) kullanılarak hesaplanır. Burada l , katman indeksini temsil eder, W ağırlık matrisi, a aktivasyon değerleri ve b önyargı vektörüdür.

$$z^{(1)} = W^{(l)} \cdot a^{(l-1)} + b^{(1)} \quad (3.8)$$

$$a^{(l)} = \phi(z^{(l)}) \quad (3.9)$$

- Aktivasyon fonksiyonları (activation functions): En çok kullanılan aktivasyon fonksiyonları sigmoid, tanh ve relu fonksiyonlarıdır.
- Kayıp fonksiyonu (loss function): Ağı tahminlerinin doğruluğunu ölçer. En yaygın kayıp fonksiyonları arasında MSE ve çapraz entropi (cross-entropy) bulunur.
- Geri Yayılım: Ağırlıkların ve önyargıların kayıp fonksiyonunun gradyanlarına göre güncellenmesi işlemidir. Bu süreç, hata sinyallerinin çıktı katmanından girdi katmanına doğru geri yayılmasıyla gerçekleştirilir.

MLP, karmaşık veri kümelerinde ve karmaşık ilişkileri modellemek için yeterince güçlüdür. Çeşitli veri türleri ve problemler için uygulanabilir. Geniş bir kullanım alanına sahiptir. Birçok endüstri ve akademik araştırma alanında yaygın olarak kullanılmaktadır. Görüntü işleme, doğal dil işleme, biyomedikal mühendislik ve finansal analiz gibi çeşitli alanlarda başarılı sonuçlar vermektedir.

3.3. Öznitelik Çıkartma Yöntemleri

Öznitelik çıkarma (feature extraction), veri madenciliği ve makine öğrenmesi süreçlerinde, ham verilerden anlamlı ve faydalı özellikleri elde edebilmek için yapılan işlemidir. Bu işlem, özellikle büyük ve karmaşık veri setlerinde, verilerin daha yönetilebilir ve analiz edilebilir hale getirilmesini sağlar.

3.3.1. Zaman tabanlı analiz

Zaman tabanlı çalışan yöntemler, bir sinyalin zaman içinde nasıl değiştiğini analiz etmeyi amaçlayan tekniklerdir. Bu yöntemler, sinyal işleme ve zaman serisi analizi gibi alanlarda kritik bir rol oynar. Zaman tabanlı analizler, sinyallerin zamanla nasıl evrildiğini, belirli olayların ne zaman gerçekleştiğini ve bu olayların zaman içindeki kalıplarını anlamak için kullanılır. Bu yöntemlere örnek olarak şunlar verilebilir: Zaman Alanında Analiz (grafiksel gösterim, ortalama, varyans ve standart sapma gibi istatistiksel ölçümler), Otokorelasyon Analizi, Hareketli Ortalama (Moving Average), Zaman Serisi Modelleme (otoregresif (AR), hareketli ortalama (MA) ve otoregresif entegreli hareketli ortalama (ARIMA) modelleri), Sinyal Dekompozisyonu (dalgaçık dönüşümü, EMD, EEMD gibi yöntemler).

Ampirik ensemble mod ayrıştırma (empirical ensemble mode decomposition, EEMD)

Ampirik Ensemble Mod Ayrıştırma (Empirical Ensemble Mode Decomposition, EEMD), Ampirik Mod Ayrıştırma (Empirical Mode Decomposition, EMD) yönteminin geliştirilmiş bir versiyonudur. EEMD, sinyallerin adaptif ve veri odaklı bir şekilde analiz edilmesini sağlayan güçlü bir tekniktir. EEMD, orijinal EMD yönteminin bazı dezavantajlarını gidermek amacıyla geliştirilmiştir ve özellikle karmaşık ve gürültülü sinyallerin ayrıştırılmasında etkili sonuçlar sağlar.

EEMD, bir sinyali IMF olarak adlandırılan bileşenlere ayıran bir yöntemdir. EEMD'nin temel prensibi, sinyale beyaz gürültü ekleyerek farklı denemeler yapmaktır. Bu sayede, EMD'nin mod karışımı problemleri ve uç değerler (end effects) gibi sorunları minimize edilir. Sinyalin yerel özelliklerine göre adaptif bileşenler oluşturur, bu da sinyalin daha doğru bir şekilde ayrıştırılmasını sağlar. Temel adımları aşağıdaki gibidir:

- Beyaz Gürültü Eklenmesi: Orijinal sinyale beyaz gürültü eklenir. Bu işlem k kez tekrarlanır. Her bir deneme için, sinyale farklı bir beyaz gürültü dizisi eklenir:

$$x_i(t) = x(t) + w_i(t) \quad (3.10)$$

$$i = 1, 2, \dots, k \quad (3.11)$$

$$IMF_{ij}(t) = EMD(x_i(t)) \quad (3.12)$$

- EMD Uygulaması: Her bir gürültü eklenmiş sinyale EMD uygulanarak IMFs elde edilir. Her bir deneme için j -inci IMF Eş. 3.12'deki şekilde elde edilir:
- IMF'lerin Ortalama Alınması: Tüm denemelerden elde edilen aynı sıradaki IMF'lerin ortalaması alınarak nihai IMF'ler elde edilir:
- Sonuçların Birleştirilmesi: Elde edilen nihai IMF'ler, orijinal sinyalin ayrıştırılmış bileşenleri olarak kullanılır.

Biyomedikal sinyallerin analizi (EEG, EKG gibi), arıza tespiti, titreşim analizi, finansal zaman serilerinin analizi, piyasa dalgalanmalarının incelenmesi, trend tespiti, yeraltı yapılarının belirlenmesi, sismik veri analizi, gibi birçok karmaşık ve gürültülü sinyallerin analizinde etkilidir.

3.3.2 Zaman-frekans tabanlı analiz

Zaman-frekans analiz yöntemleri, bir sinyalin hem zaman hem de frekans tabanlı özelliklerini incelemeyi amaçlayan tekniklerdir. Geleneksel sinyal işleme yöntemleri genellikle sadece zaman veya frekans tabanlı analiz yaparken, zaman-frekans analiz yöntemleri sinyalin yerel frekans bileşenlerini zaman içinde takip etmeye olanak tanır. Bu özellik, değişken frekanslı ve zamana bağlı dinamik özellikler sergileyen sinyallerin analizinde büyük bir avantaj sağlar. Bu yöntemlere örnek olarak şunlar verilebilir: Kısa Zamanlı Fourier Dönüşümü (STFT), WT, EWT, Wigner-Ville Dağılımı (WVD), Hilbert-Huang Dönüşümü (HHT).

Ampirik dalgacık dönüşümü (empirical wavelet transform, EWT)

EWT, sinyal işleme ve zaman-frekans analizinde kullanılan modern bir tekniktir. Klasik dalgacık dönüşümü algoritması olan WT'ye alternatif olarak geliştirilmiş olup, sinyalin yerel özelliklerini daha etkili bir şekilde analiz etmeye olanak tanır. EWT, sinyalin kendine özgü özelliklerine uyum sağlayarak daha hassas ve esnek bir dönüşüm sağlar.

EWT, sinyalleri farklı frekans bantlarına ayıran ve her bir bandı analiz eden bir yöntemdir. Klasik dalgacık dönüşümünden farklı olarak EWT, analiz edilen sinyalin spektrumuna dayanarak adaptif dalgacıklar oluşturur. Bu, sinyalin farklı bileşenlerinin daha iyi ayrıştırılmasını ve analiz edilmesini sağlar.

EWT önce sinyalin Fourier spektrumunun yerel maksimumlarını, ardından bölümleri tespit eder. Spektrum, saptanan maksimuma dayanır ve son olarak karşılık gelen bir dalgacık filtre bankası oluşturur. Bu yöntem şu şekilde çalışır (Gürsoy, Üstün ve Yılmaz, 2018):

- Uygulanan sinyalin frekans bileşenlerini FFT kullanarak belirlenir.
- Farklı modlar, Fourier spektrumunun doğru segmentasyonu elde edilerek çıkarılır.
- Algılanan her bölüme karşılık gelen ölçekleme ve dalgacık işlevleri uygulanır. Fourier spektrumunun segmentasyonu, analiz edilen sinyale göre bu tekniğe uyum sağlayan en önemli adımdır.

Ampirik dalgacıklar, bant geçiren filtreler olarak tanımlanır. Littlewood-Paley ve Mayer dalgacıkları, bant geçiren filtreleri olarak kullanılır. Birçok işlev bu özellikleri karşılar, literatürde yaygın olarak kullanılan EWT, klasik dalgacık dönüşümü için tanımlanabilir. Ayrıntılı katsayılar, iç çarpım ile elde edilir (Hu, H. Li, F. Li ve Liu, 2017).

$$B(x) = x^4(35 - 84x + 70x^2 - 20x^3) \quad (3.13)$$

Ampirik ölçekleme işlevi, Eş. 3.14'teki gibidir.

$$W_X(n, t) = x(t)_{,\psi_n} = IFFT(X(w)x_{\psi_n}(v)) \quad (3.14)$$

Yaklaşım katsayıları, Eş. 3.15'te verilen ölçeklendirme fonksiyonu ile iç çarpım ile elde edilir ve burada $X(a)$ bir FFT temsili $x(t)$ sinyaldir (Hu ve diğerleri, 2017).

$$W_X(n, t) = x(t)_{\psi_n} = IFFT(X(w)x_{\psi_n}(v)) \quad (3.15)$$

Makine arıza tespiti, titreşim analizi, biyomedikal sinyal analizi (EEG, EKG, vb.), finansal zaman serilerinin analizi, trend tespiti, ses ve görüntü sinyalleri gibi birçok alanda kullanılmaktadır. Sinyalin yerel özelliklerin, daha iyi yakalar. Adaptif dalgacıklar sayesinde daha hassas analiz sağlar. Fakat hesaplama maliyetleri yüksektir. Uygulama ve adaptasyon süreci karmaşıktır.

3.3.3. İstatistiksel öznitelik çıkarma

İstatistiksel öznitelik çıkarma, veri analizinde ve makine öğrenmesinde önemli bir adımdır. Bu süreç, ham verileri daha anlamlı ve yorumlanabilir hale getirmek için veriden öznitelikler çıkarma işlemidir. İstatistiksel öznitelikler, verilerin yapısını, dağılımını ve temel özelliklerini temsil eden nicel değerlerdir. Bu öznitelikler, verilerin sınıflandırılması, kümeleme, regresyon ve diğer veri analizi tekniklerinde kullanılır.

İstatistiksel öznitelik türleri, temel istatistiksel öznitelikler, şekil ölçüleri, dağılım ölçüleri, zaman serisi özellikleri olarak sınıflandırılabilir.

Temel istatistiksel öznitelikler

- Ortalama: Bir veri kümesinin merkezi eğilimini temsil eder. Tüm veriler toplanır ve toplam veri sayısına bölünerek ortalama değeri bulunur.
- Medyan (ortanca): Verilerin orta noktasıdır. Verileri sıraladıktan sonra ortadaki değeri medyanı değeri bulunur.
- Mod: En sık görülen veri değeridir.
- Standart Sapma: Verilerin ortalama etrafında nasıl dağıldığını gösterir. Standart sapma değerinin bulunması: Verilerin ortalaması bulunur; Her bir veri ile bulunan ortalama arasındaki fark bulunur; Bulunan farkların her birinin karesi alınarak elde edilen sayılar toplanır; Son olarak bu toplam, toplam veri sayısının 1 eksiğine bölünerek, bölümün karekökü elde edilir.
- Varyans: Standart sapmanın karesidir ve verilerin yayılımını ölçer.

Şekil ölçüleri (shape measures)

- Çarpıklık: Verilerin simetrisini ölçer. Negatif çarpıklık sola, pozitif çarpıklık sağa eğilim gösterir.
- Basıklık: Verilerin sivrilğini ve kuyruk kalınlığını ölçer.

Dağılım ölçüleri (dispersion measures)

- Menzıl: Verilerin en büyük ve en küçük değeri arasındaki farktır.
- Çeyrekler Arası Açıklık (IQR): Verilerin %25'lik ve %75'lik dilimleri arasındaki farktır.

Zaman serisi özellikleri

- Otokorelasyon: Zaman serisi verilerinin kendisiyle olan ilişkisini ölçer.
- Dönemlilik: Zaman serisinde düzenli aralıklarla tekrarlanan bileşenleri tanımlar.

İstatistiksel öznitelik çıkarma, veri analizi ve makine öğrenmesinde kritik öneme sahiptir ve iyi seçilmiş öznitelikler, makine öğrenmesi modellerinin performansını artırır. Ham veri yerine özniteliklerin kullanılması, analiz ve modelleme sürecinde veri boyutunu azaltır. Verilerin temel özelliklerini öznitelikler aracılığıyla çıkararak daha anlamlı ve yorumlanabilir hale getirir. İstatistiksel Öznitelik Çıkarma Yöntemleri arasında PCA (Principal Component Analysis), LDA, ICA (Independent Component Analysis) yöntemleri bulunur.

- PCA: Verilerin boyutunu azaltarak, temel bileşenleri çıkarır.
- LDA: Sınıflar arasındaki ayrımı maksimize eden doğrusal bileşenler çıkarır.
- ICA: Verilerin bağımsız bileşenlerini çıkarır.

Entropi

Entropi, bilgi teorisi ve istatistikte önemli bir kavramdır. Bir sistemin belirsizliğini ve düzensizliğini ölçen bir nicelik olarak tanımlanır. Başlıca entropi türleri ve formülleri Eş. 3.16, Eş. 3.17, Eş. 3.18 ve Eş. 3.19'daki gibi örneklendirilebilir.

- Shannon Entropisi: Bilgi teorisinde en yaygın kullanılan entropi türüdür. Bir veri kümesindeki bilgi miktarını ve belirsizliği ölçer.

$$H(X) = -\sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (3.16)$$

- Renyi Entropisi: Shannon entropisinin genel bir formudur ve parametre α ile belirlenen farklı duyarlılıklara sahiptir.

$$H_\alpha(x) = \frac{1}{1-\alpha} \log_2 \left(\sum_{i=1}^n p \cdot (x_i)^\alpha \right) \quad (3.17)$$

- Tsallis Entropisi: Renyi entropisine benzer ve kompleks sistemlerin analizi için kullanılır.

$$H_q(x) = \frac{1}{q-1} (1 - \sum_{i=1}^n p(x_i)^q) \quad (3.18)$$

- Kolmogorov-Sinai (KS) Entropisi: Dinamik sistemlerin karmaşıklığını ve kaotik davranışını ölçer. KS entropisinin hesaplanması karmaşıktır ve genellikle dinamik sistemlerin faz uzayı ve ölçüm teorisi kullanılarak hesaplanır.
- Differansiyel Entropi: Sürekli olasılık dağılımları için kullanılan entropi türüdür.

$$h(X) = -\int_{-\infty}^{\infty} f(x) \log_2 f(x) dx \quad (3.19)$$

Entropi hesaplamak için histogram, Kernel Yoğunluk Tahmini ve parametrik yöntemler kullanılmaktadır. Histogram yöntemi, verilerin histogramını oluşturup, her bir bölmenin olasılıklarını hesaplayarak entropiyi belirler. Kernel Yoğunluk Tahmini, sürekli verilerde olasılık yoğunluk fonksiyonunu tahmin etmek için kullanılır. Parametrik yöntemler ise verilerin belirli bir olasılık dağılımına uyduğu varsayılarak entropi hesaplanır.

3.4. Veriseti

Veriseti, 2020 yılında kaydedilmiştir. Veriseti, her biri sağlıklı bir katılımcıya ait EEG ve Elektrookülografi (EOG) verilerini içeren 18 Matlab (.mat formatlı) dosyasından oluşmaktadır. Her dosya üç ana yapı içermektedir: Subject, eyemov, bciexp.

- Subject: Sağlıklı veri sahibi kişinin yaş, cinsiyet, el tercihi ve anadili gibi bilgilerini içermektedir.
- Eyemov: EOG'den elde edilen göz hareketlerinin ilk kaydından alınan hem EEG hem de EOG verilerinin tümünü içermektedir.
- Bciexp: EEG'den alınan sinyaller, EOG'den alınan dikey ve yatay veriler ile kanal isimlerini içermektedir.

18 sağlıklı bireyden ilk iki denemede herhangi bir talepte bulunulmadan sadece yeşil artı işaretine ve kırmızı çarpı işaretine bakmaları istenmiştir. Üçüncü ve altıncı denemeler arasında katılımcılara nesnel sorular yöneltilmiş ve cevaplamaları istenmiştir. Son denemelerde ise öznel sorular sorulmuştur. Sağlıklı bireyler, sorulara cevap verirken bu iki işarete bakarak doğru veya yanlış olarak cevaplamışlardır. Sorulara cevap verilmeyen

sürelerde katılımcılardan ekranda ortada bulunan büyük çarpı işaretine bakmaları istenmiştir. Toplamda 24 deneme gerçekleştirilmiştir.

Veriler, EEG, yatay ve dikey EOG'nin yanı sıra sağ mastoide karşı referanslanmış 30 Ag/AgCl elektrot kullanılarak bir Brainamp DC amplifikatörü ile kaydedilmiştir. Örnekleme hızı 250 Hz olup, 0.1 Hz yüksek geçiren filtre uygulanmıştır. Veriler 29 farklı EEG kanalı üzerinden toplanmıştır ve bunlardan 29. kanal referans kanalıdır. Kanal isimleri sırasıyla: Fp1, Fp2, F7, F3, Fz, F4, F8, FC1, FC2, T7, C3, Cz, C4, T8, O9, CP1, CP2, O10, P7, P3, Pz, P4, P8, PO7, PO3, Oz, PO4, PO8, LMAST ve IZ'dir.

Verisetinin ilk kullanıldığı çalışmada Reichert ve diğerleri (2020) verisetindeki bu 29 farklı kanaldan O9, O10, CP1, CP2, Pz, P3, P4, P7, P8, PO3, PO4, PO7, PO8, ve Oz adlı 14 kanalı kullanmışlardır. Bu kanallar arasından PO7 ve PO8 (24 ve 28. kanal) adlı kanalın mekansal dikkat kayması üzerinde etkisini ispatlamışlardır. Bu sebeple yaptığımız bu tez çalışmasında çeşitli derin öğrenme ve makine öğrenmesi yöntemleri ile sınıflandırma için üzerinde çalıştığımız kanallar PO7 ve PO8 adlı kanallar olmuştur. Bu iki kanal üzerinde yapılan çalışma detayları “4. Araştırma Bulguları” adlı başlığının altında verilmiştir.

Bu tez çalışmasında 3 farklı strateji ve bu stratejilerin uygulandığı 2 farklı veriseti (zaman tabanlı ve frekans tabanlı) üzerinde uygulamalar yapılmıştır. Bu farklı tabanları baz alan üç farklı strateji oluşturularak hem geleneksel öznitelik çıkarma yöntemleri ile makine öğrenmesi ve derin öğrenme algoritmaları analiz edilmiş, hem de elde edilen öznitelik vektörleri iki boyutlu verilere dönüştürülerek gelişmiş derin öğrenme algoritmaları ile analiz edilmiştir. Strateji ve veriseti çeşitleri aşağıda maddeler halinde verilmiştir:

- Veriseti 1: EEG sinyallerinin EWT kullanılarak elde edilen öznitelik kümesi
- Veriseti 2: EEG sinyallerine EEMD uygulayarak IMF görünümünün 2 boyutlu grafiklere dönüştürülmesi
- Strateji 1: Veriseti-1 kullanılarak makine öğrenmesi yöntemlerinin uygulanması, farklı sınıflandırıcılar üzerindeki eğitim ve test sonuçlarının değerlendirilmesi
- Strateji 2: Veriseti-2 kullanılarak transfer öğrenmesi yöntemlerinin CNN tabanlı çalışan ön eğitilmiş popüler modellerle uygulanarak derin öğrenme üzerinde eğitim ve test sonuçlarının değerlendirilmesi
- Strateji 3: Veriseti-1 kullanılarak kanal bazlı değerlendirmeler yapıp derin öğrenme yaklaşımlarının daha anlamlı olduğunu göstermeye yönelik analizlerin gerçekleştirilmesi

3.5. Veriseti Bölütleme Stratejileri

Veriseti bölütleme, makine öğrenmesi ve istatistiksel modelleme süreçlerinde önemli bir adımdır. Doğru bir bölütleme stratejisi, modelin genelleme yeteneğini değerlendirmek ve modelin performansını doğru bir şekilde ölçmek için kritik öneme sahiptir. Bu stratejiler, veriyi eğitim ve test setlerine ayırarak, modelin eğitilmesini ve değerlendirilmesini sağlar. Bölütleme, modelin veriye ne kadar iyi uyduğunu anlamak ve modelin gerçek dünya verileri üzerinde nasıl performans göstereceğini tahmin etmek için kullanılır.

Veriseti bölütlemenin temel amacı, modelin genel performansını değerlendirmektir. Eğitim ve test setlerine ayırarak, modelin öğrenme yeteneği ve genelleme kapasitesi test edilir. Bu süreç, modelin yeni ve görülmemiş veriler üzerinde nasıl performans göstereceğini tahmin etmek için gereklidir. Ayrıca, modelin aşırı öğrenme veya yetersiz öğrenme gibi problemleri yaşayıp yaşamadığını değerlendirmeye yardımcı olur.

3.5.1. Leave-one-out (LOO) çapraz doğrulama yöntemi

Leave-One-Out (LOO) çapraz doğrulama yöntemi, makine öğrenmesi ve istatistikte veri setlerinin değerlendirilmesi ve model doğruluğunun ölçülmesi için kullanılan bir tekniktir. Verisetinin her bir örneğini test seti olarak kullanıp, geri kalanını eğitim seti olarak kullanan bir çapraz doğrulama tekniğidir. Bu süreç, verisetindeki her bir örnek üzerinde bir model eğitip, modelin başarısını o örnekte test ederek tekrarlanır. Sonuçta, modelin tüm veriseti üzerinde ne kadar genel performans gösterdiği hakkında bilgi sağlar. Hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. LOO yönteminin uygulama aşamaları şu şekildedir:

- Verisetinde N adet örnek bulunur.
- Her bir örneği, bir test seti olarak ayırıp; geri kalan $N-1$ örneği eğitim seti olarak kullanılır.
- Model, eğitim seti üzerinde eğitilir.
- Test setindeki örnek üzerinde modelin tahmin performansı değerlendirilir.
- Bu adımlar tüm N örnek için tekrarlanır.
- Tüm test sonuçları toplanarak ortalama doğruluk veya hata hesaplanır.

LOO çapraz doğrulama doğruluk oranı genellikle Eş. 3.20'deki formülle hesaplanır. Burada başarı, i -inci örneğin test seti olarak kullanıldığı ve modelin tahmin performansının ölçüldüğü doğruluk oranını temsil eder.

$$LOO \text{ Doğruluk} = \frac{1}{N} \sum_{i=1}^N \text{Doğruluk}_i \quad (3.20)$$

LOO yöntemi, verisetindeki her bir örneği test ederek modelin genel performansını değerlendirir ve modelin veriye ne kadar genel bir şekilde uyum sağladığını ölçer. Eğitim setinin her zaman verisetinin büyük bir kısmını içerdiğinden, model eğitimi için daha fazla veri kullanılır. Özellikle büyük veri setlerinde LOO çapraz doğrulama, her bir örnek için ayrı model eğitimi yapıldığından, yüksek hesaplama maliyeti ve süre gerektirebilir.

3.6. Performans Kriterleri ve İstatistiksel Değerlendirme


Farklı model ve algoritmaların (derin öğrenme, makine öğrenmesi, yapay zeka gibi) başarısını ve etkinliğini değerlendirmek için çeşitli performans kriterleri kullanılır. Bu kriterler, modelin doğruluğunu, genelleme yeteneğini, hata oranını ve diğer tüm önemli özelliklerini ölçmek için kullanılır.

3.6.1. Karmaşıklık matrisi (confusion matrix)

Karmaşıklık matrisi, sınıflandırma modellerinin performansını değerlendirmek için kullanılan ve modelin doğru ve yanlış sınıflandırmalarını görsel olarak temsil eden bir tablodur. Dört ana bileşenden oluşur: Doğru Pozitif, Yanlış Pozitif, Doğru Negatif ve Yanlış Negatif. Bu bileşenler, modelin performansını daha detaylı bir şekilde analiz etmeye olanak sağlar. Şekil 3.1’de görseli verilmiştir.

- Doğru Pozitif (True Positives, TP): Modelin doğru olarak pozitif sınıflandırdığı örnekler
- Yanlış Pozitif (False Positives, FP): Modelin yanlış olarak pozitif sınıflandırdığı örnekler
- Doğru Negatif (True Negatives, TN): Modelin doğru olarak negatif sınıflandırdığı örnekler
- Yanlış Negatif (False Negatives, FN): Modelin yanlış olarak negatif sınıflandırdığı örnekler

Karmaşıklık matrisi, bu bileşenlerin sayısal değerlerini göstererek, modelin nerelerde hata yaptığını ve hangi alanlarda başarılı olduğunu analiz etmeyi sağlar.



Şekil 3.1. Karmaşıklık matrisi (confusion matrix)

3.6.2. Doğruluk (accuracy, acc)

Doğruluk, modelin tahminlerinin ne kadarının doğru olduğunu gösterir. Modelin doğru sınıflandırdığı örneklerin toplam örneklere oranını ifade eder. Sınıflandırma problemlerinde yaygın olarak kullanılır ve genel bir performans ölçütüdür. Ancak, özellikle dengesiz veri setlerinde yanıltıcı olabilir.

Bir sınıflandırma probleminde, modelin doğru tahmin ettiği örnek sayısı, toplam örnek sayısına bölünerek bulunur. Doğruluğun yüksek olması, modelin genel olarak iyi performans gösterdiğini belirtir. Ancak, sınıf dengesizliğinin olduğu durumlarda, doğruluğun yanıltıcı olabileceği unutulmamalıdır. Doğruluk oranının 1,0'a (veya %100'e) yakın olması beklenir. Bu sonuç, modelin tüm örnekleri doğru sınıflandırdığı anlamına gelir.

$$\text{Doğruluk} = \frac{\text{Doğru Tahminler}}{\text{Toplam Örnek Sayısı}} \quad (3.21)$$

3.6.3. Hassasiyet (precision)

Hassasiyet, modelin pozitif sınıf olarak tahmin ettiği örneklerin gerçekten pozitif olma oranını gösterir. Bu metrik, yanlış pozitiflerin sayısını minimize etmeye odaklanır. Özellikle yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda (örneğin, hastalık teşhisi) kritiktir.

Yüksek hassasiyet, modelin yanlış pozitiflerden kaçındığını gösterir. Hassasiyetin 1,0'a yakın olması beklenir, bu da modelin pozitif tahminlerinin tamamının doğru olduğu anlamına gelir.

$$Hassasiyet = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Pozitif} \quad (3.22)$$

3.6.4. Duyarlılık (recall)

Duyarlılık, modelin gerçek pozitif örneklerinden kaç tanesini doğru tahmin ettiğini gösterir. Bu metrik, yanlış negatiflerin sayısını minimize etmeye odaklanır. Özellikle yanlış negatiflerin maliyetinin yüksek olduğu durumlarda (örneğin, güvenlik sistemleri) önemlidir.

Yüksek duyarlılık, modelin yanlış negatiflerden kaçındığını gösterir. Duyarlılığın 1,0'a yakın olması beklenir, bu da modelin tüm pozitif örnekleri doğru tahmin ettiği anlamına gelir.

$$Duyarlılık = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Negatif} \quad (3.23)$$

3.6.5. F1 skoru

F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır ve bu iki metriği dengelemeye çalışır. Hem hassasiyet hem de duyarlılığın önemli olduğu durumlarda kullanılır. F1 skoru, modelin genel performansını daha dengeli bir şekilde değerlendirir.

Yüksek bir F1 skoru, modelin hem hassasiyet hem de duyarlılık açısından iyi performans gösterdiğini belirtir. İdeal olarak, F1 skorunun 1,0'a yakın olması beklenir.

$$F1 Skoru = 2 \times \frac{Hassasiyet \times Duyarlılık}{Hassasiyet + Duyarlılık} \quad (3.24)$$

3.6.6. Kayıp fonksiyonu (loss function)

Kayıp fonksiyonu, modelin tahminlerinin gerçek değerlerden ne kadar saptığını ölçer. Eğitim sürecinde modelin optimizasyonu için kullanılır. Modelin tahmin hatasını ölçer ve

optimizasyon algoritmaları (gradient descent gibi) tarafından minimize edilir. Düşük kayıp, modelin iyi öğrenme yaptığına işaret eder.

Regresyon problemlerinde yaygın olarak kullanılan MSE (Mean Squared Error) ve ikili sınıflandırma problemlerinde kullanılan İkili Çapraz Entropi (Binary Cross Entropy) gibi çeşitli kayıp fonksiyonları vardır. İdeal olarak, kayıp değerinin 0'a yakın olması, modelin tahminlerinin gerçek değerlere çok yakın olduğunu gösterir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.25)$$

$$\text{İkili Çapraz Entropi} = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (3.26)$$

3.6.7. R² skoru (R-kare)

R² skoru, regresyon modellerinde kullanılan ve modelin veri varyansını ne kadar açıkladığını gösteren bir ölçüdür. Modelin ne kadar iyi tahmin yaptığını ve veri varyansını ne kadar iyi açıkladığını ölçer. Yüksek bir R² skoru, modelin veri varyansını çok iyi açıkladığını gösterir.

R² skoru, modelin başarısını değerlendiren önemli bir metriktir. Bu skorun 1,0'a yakın olması beklenir, bu da modelin veri varyansını çok iyi açıkladığı anlamına gelir.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.27)$$

3.6.8. Alıcı işletim karakteristiği (receiver operating characteristic, ROC) eğrisi ve eğri altındaki alan (area under curve, AUC)

Alıcı işletim karakteristiği (Receiver Operating Characteristic, ROC) eğrisi, modelin farklı eşik değerlerindeki performansını gösterir. Her bir eşik değeri için Doğru Pozitif Oranı (TPR) ve Yanlış Pozitif Oranı (FPR) değerleri hesaplanır ve bu değerler bir grafik üzerinde görselleştirilir. TPR formülü duyarlılık formülü ile aynıdır ve Eş. 3.23'te verilmiştir.

$$\text{Yanlış Pozitif Oranı} = \frac{\text{Yanlış Pozitif}}{\text{Yanlış Pozitif} + \text{Doğru Negatif}} \quad (3.28)$$

Eğri altındaki alan (Area Under Curve, AUC), ROC eğrisinin altındaki alanı ölçer ve modelin genel sınıflandırma performansını değerlendirir. ROC eğrisi, modelin farklı eşik değerlerinde nasıl performans gösterdiğini görsel olarak anlamayı sağlar.

Yüksek bir AUC, modelin çok iyi performans gösterdiğini belirtir. AUC değeri 0,5 ile 1 arasında değişir. 1'e ne kadar yakınsa, modelin performansı o kadar iyidir.



4. ARAŞTIRMA BULGULARI

Veri sayısının az olması, nörolojik çalışmalarda sıkça karşılaşılan bir sorundur. Bu çalışmada kullanılan ham veriseti, “3.4. Veriseti” başlığı altında detaylı anlatılmıştır. Bu tez çalışmasında, Reichert ve diğerleri (2020) çalışmalarında kullandıkları veriseti üzerinde çeşitli veri arttırma yöntemleri ve özellikle derin öğrenme algoritmaları ile bu sorunun üstesinden gelinmiştir. Veri arttırma (data augmentation) tekniklerini kullanarak, daha büyük veri setleri oluşturulmuş ve bu veriler analiz edilmiştir. Böylece, elde edilen sonuçların güvenilirliği ve genellenebilirliği arttırılmıştır.

4.1. Strateji 1: Veriseti-1 Kullanılarak Makine Öğrenmesi Yöntemlerinin Uygulanması, Farklı Sınıflandırıcılar Üzerindeki Eğitim ve Test Sonuçlarının Değerlendirilmesi

Veriseti-1’i oluşturmak için, ham veriseti üzerinde python tabanlı ön işlemler yapılmıştır. Analiz aralığı uzunluğu saniye başına 0,75 olarak alınmıştır çünkü EEG verileri kayıt altına alınırken verisetini hazırlayan kişiler tarafından bu değer böyle alınmıştır. Veriseti ile bir uyumsuzluk olmaması için 0,75 değeri bu çalışmada da kullanılmaktadır. Bant geçiren filtre uygulanmıştır: Sadece 1 Hz ile 12,5 Hz arası veriler filtreden geçmesine izin verilmiştir. Referanslama için, 30 kanal içerisinden 29. kanal olan ‘LMAST’ kanalı kullanılmıştır. Ardından, öznitelik çıkarma yöntemlerinden biri olan EWT yöntemi kullanılmıştır. Bu veriseti üzerinde daha önce bu EWT yöntemi kullanılmamıştır. Bu yöntem ile tüm varyasyonlar bakılıp istatistiksel olarak öznitelikler çıkarılmıştır. Ayrıca bu yöntem ile veri üzerindeki gürültüler de yok edilmiştir. İncelenen kişideki istenilen kanalın tüm sinyallerindeki EWT sayısına göre her EWT için öznitelik çıkarma yapılmıştır. Toplam 31 öznitelik sayısına ulaşılmıştır. Bu yöntem kullanılırken, incelenen kişideki istenilen kanalın tüm denemelerine (trial) ayrı ayrı EWT uygulanmıştır. Bunun sonucunda, sinyaldeki EWT sonuçları, sinyale uygulanan filtreler (mfb) ve sinyalin EWT için sınırları (boundaries) kaydedilmiştir. Ayrıca 24 ve 28. kanallarda homojen dağılımlı Trial ile analiz edilerek öznitelikler çıkarılmıştır. Veri ön işleme ve öznitelik çıkarma işlemi tamamlandıktan sonra elde edilen verinin yeni hali ile .csv formatında bir dosya oluşturularak, veriler bir boyutlu zaman serisi olarak ele alınmıştır.

Strateji 1 ile, yeni oluşturulan “Veriseti-1” üzerinde makine öğrenmesi algoritmalarından olan SVM, k-NN, MLP, karar ağacı ve Naive Bayes algoritmaları uygulanmıştır. Bu

strateji, 2 farklı bakış açısı ile ele alınmıştır. Bu 2 farklı bakış açısının detayları “4.1.1. Tek kanal ve tek kişi üzerinde strateji 1 uygulanması” ve “4.1.2. PO7 ve PO8 kanalları ve tüm kişiler üzerinde strateji 1 uygulanması” başlıkları altında anlatılmıştır.

4.1.1. Tek kanal ve tek kişi üzerinde strateji 1 uygulanması

18 sağlıklı bireyden birinci olan “P01” adlı kişi ve ona ait EEG sinyallerinin ilk kanalı olan “Fp1” kanalı üzerine yoğunlaşmıştır. Bu veriler üzerinde uygulanan 4 farklı makine öğrenmesi algoritmalarından (SVM, k-NN, MLP ve karar ağacı) her birinin kendine özgü bazı değişkenleri bulunmaktadır. Bu değişkenlerin her biri farklı kombinasyonlarda defalarca kez denenmiştir. Elde edilen sonuçlardan en yüksek başarımlar Çizelge 4.1’de verilmiştir. Çizelgelerde yazılmış olan Ç.D. ifadesi ile, LOO çapraz doğrulama yöntemi kullanıldığı ve “K-katlı” ifadesi ile K değerinin hangi değeri aldığı belirtilmiştir.

Çizelge 4.1. P01 kişisine ait Fp1 adlı EEG kanalı üzerinde uygulanan makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları

	Karar Ağacı	k-NN	MLP	SVM
Veri Bölütleme Yöntemi	15-katlı Ç.D.	%90-%10	%90-%10	10-katlı Ç.D.
Doğru Sınıflandırılmış Örnek Sayısı / Toplam Veri Sayısı	7392/8283	573/828	537/828	5212/8283
Sınıflandırma Performansı (Başarım, %)	89,24	70,10	64,86	62,92
Hata Değeri (MSE, %)	0,13	0,30	0,43	0,37

Karar ağacı sınıflandırma algoritması kendi içinde ilişkisel olarak matematiksel istatistiklere göre verileri sınıflandırma yaptığı için bu algorithmada parametre değişimi yapılmamıştır fakat veri ayırma yöntemleri ve kullanılan ön eğitilmiş modeller değiştirilmiştir ve bunun sonucunda çıkan değerler ile bir karşılaştırmaya gidilmiştir. Karar ağacı modelleri arasından RF, rastgele ağaç (random tree), J48 ve mantıksal model ağacı (Logistic Model Tree, LMT) kullanılmıştır. Veriseti 2 farklı yöntem ile eğitim ve test verilerine ayrılmıştır: K-katlı çapraz doğrulama yönteminde K değerleri 5, 10 ve 15 değerlerini alırken, eğitim-test verileri dağılımı %90-%10, %75-%25, %80-%20 oranlarında denemeleri yapılmıştır. Denemelerinin sonucunda J48 modeli ile en yüksek başarımlar %89,24 elde edilmiştir.

k-NN sınıflandırma algoritması ile veri üzerinde denemeler yapılırken k parametresi üzerinde farklı denemeler yapılmıştır. Veriseti yine K-katlı çapraz doğrulama yönteminde K değerleri 5, 10, ve 15 değerlerini alırken, eğitim-test verileri dağılımı %90-%10, %75-

%25, %80-%20 oranlarında denemeleri yapılmıştır. k-NN algoritması için k değeri 1’den 9’a kadar olan tek sayılar ile sırasıyla denenmiştir. k-NN algoritması için k=1 değeri alındığında en yüksek başarımlar %100 doğruluk elde edilirken, k parametresini arttırdıkça başarımlar yavaş yavaş düşmüştür. Örneğin k=3 değerinde iken, başarımlar %66,79’a düşmüştür. Verisetini farklı bir yöntemle ayrıldığında bu düşüşün değişmediği görülmüştür.

MLP sınıflandırma algoritması ile denemeler yapılırken birçok parametre değişikliği yapılmıştır. Nöron sayıları 50-250 arası, epoch değeri 100-500 arası, katman sayısı 1-3 arası değerlerde denemeler gerçekleştirilmiştir. Rastgelelik yüksek olduğundan dolayı her model 3’er kez denenmiştir. En başarılı bulunan model üzerinde daha fazla denemeler gerçekleştirilmiştir.

SVM sınıflandırma algoritması da değiştirilecek çok parametre bulunmadığından dolayı verisetinin bölünmesi üzerine denemeler yapılmıştır.

4.1.2. PO7 ve PO8 kanalları ve tüm kişiler üzerinde strateji 1 uygulanması

18 sağlıklı birey ve tüm bireylere ait EEG sinyallerinden PO7 ve PO8 adlı 24. ve 28. kanalları üzerine yoğunlaşmıştır. Bu veriler üzerinde uygulanan 5 farklı makine öğrenmesi algoritmalarından her birinin kendine özgü bazı değişkenleri bulunmaktadır. Bu değişkenlerin her biri farklı kombinasyonlarda defalarca kez denenmiştir. Elde edilen sonuçlardan en yüksek başarımlar Çizelge 4.2’de verilmiştir. Çizelge 4.2’de yer alan en yüksek başarımlar, PO7 kanalı üzerinde meydana gelmiştir.

Çizelge 4.2. 18 sağlıklı bireye ait PO7 ve PO8 adlı EEG kanalı üzerinde uygulanan makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları

	Karar Ağacı	k-NN	MLP	SVM	Naive Bayes
Veri Bölütleme Yöntemi	%80-%20	%80-%20	10-katlı Ç.D.	%80-%20	%80-%20
Doğru Sınıflandırılmış Örnek Sayısı / Toplam Veri Sayısı	5115/5115	5115/5115	13180/20781	3041/5115	2810/5115
Sınıflandırma Performansı (Başarımlar, %)	100,0	100,0	63,42	59,45	54,93
Hata Değeri (MAE, %)	0,0	0,0	0,41	0,41	0,48

Karar ağacı sınıflandırma algoritması kendi içinde ilişkisel olarak matematiksel istatistiklere göre verileri sınıflandırma yaptığı için bu algorithmada parametre değişimi

yapılmamıştır fakat veri ayırma yöntemleri ve kullanılan ön eğitilmiş modeller değiştirilmiştir ve bunun sonucunda çıkan değerler ile bir karşılaştırmaya gidilmiştir. Karar ağacı modelleri arasında RF, RT, J48 ve mantıksal model ağacı (Logistic Model Tree, LMT) kullanılmıştır. Veriseti, 2 farklı yöntem ile eğitim ve test verilerine ayrılmıştır: K-katlı çapraz doğrulama yönteminde K değerleri 5, 10, ve 15 değerlerini alırken, eğitim-test verileri dağılımı %90-%10, %75-%25, %80-%20 oranlarında denemeleri yapılmıştır. Veriseti %80 eğitim %20 test verisi şeklinde ayrıldığında PO7 kanalı için: RF algoritması ve RT algoritmasında en yüksek başarımlar %100,0 elde edilirken, LMT modeli ile %98,67 başarımlar, J48 modeli ile %97,42 elde edilmiştir.


k-NN sınıflandırma algoritması ile veri üzerinde denemeler yapılırken k parametresi üzerinde farklı denemeler yapılmıştır. Veriseti yine K-katlı çapraz doğrulama yönteminde K değerleri 5, 10, ve 15 değerlerini alırken, eğitim-test verileri dağılımı %90-%10, %75-%25, %80-%20 oranlarında denemeleri yapılmıştır. k-NN algoritması için k değeri 1'den 9'a kadar olan tek sayılar ile sırasıyla denenmiştir. k=1 değeri alındığında en yüksek başarımlar olan %100 doğruluk elde edilirken, k parametresini arttırdıkça başarımlar yavaş yavaş düşmüştür. Örneğin k=3 değerinde iken, başarımlar %95,11'e düşmüştür. Verisetini farklı bir yöntemle ayrıldığında bu düşüşün değişmediği görülmüştür.

MLP sınıflandırma algoritması ile denemeler yapılırken birçok parametre değişikliği yapılmıştır. Nöron sayıları 50-250 arası, epoch değeri 100-500 arası, katman sayısı 1-3 arası değerlerde denemeler gerçekleştirilmiştir. Rassallık yüksek olduğundan dolayı her model 3'er kez denenmiştir. En başarılı model 100-100-100 nöron sayıları ile 3 gizli katmanlı, 500 epoch değeri, 10 iterasyonlu, 0,001 öğrenme oranı ile %64,86 başarımlar elde edilmiştir. En başarılı bulunan model üzerinde daha fazla denemeler gerçekleştirilmiştir.


SVM sınıflandırma algoritması da değiştirilecek çok parametre bulunmadığından dolayı verisetinin bölünmesi üzerine denemeler yapılmıştır.

4.2. Strateji 2: Veriseti-2 Kullanılarak Transfer Öğrenmesi Yöntemlerinin CNN Tabanlı Çalışan Ön Eğitimli Popüler Modellerle Uygulanarak Derin Öğrenme Üzerinde Eğitim ve Test Sonuçlarının Değerlendirilmesi

Veriseti-2'yi oluşturmak için, ham veriseti üzerinde zaman tabanlı EEMD yöntemi kullanılmıştır. Tek boyutlu sinyaller, grafiğe dönüştürülerek iki boyutlu hale getirilmiş ve resim olarak kaydedilmiştir. PO7 ve PO8 (24. ve 28. kanallar) kanallar üzerinde, IMF değeri 6, 8, 10 ve 12 alınarak farklı modülasyonlar oluşturulmuştur. N2pc (Negatif-Going Potansiyel Component) çalışması ve niyet-geri bildirim (intention-feedback) karşılaştırması yapılmıştır.



Şekil 4.1.Verisetindeki beşinci kişinin PO7 kanalı üzerinde IMF-6 sonucunda kaydedilen birinci denemesi için hayır etiketli bir örnek resim



Şekil 4.2.Verisetindeki beşinci kişinin PO7 kanalı üzerinde IMF-6 sonucunda kaydedilen birinci denemesi için evet etiketli bir örnek resim

Çizelge 4.3. Niyet-geri bildirim karşılaştırması

Kişi Numarası	Hayır (Adet)	Evet (Adet)
Kişi 1	87	9
Kişi 2	118	2
Kişi 3	112	8
Kişi 4	110	10
Kişi 5	116	4
Kişi 6	115	5
Kişi 7	107	13
Kişi 8	102	18
Kişi 9	85	35
Kişi 10	112	8
Kişi 11	94	26
Kişi 12	106	14
Kişi 13	100	19
Kişi 14	118	2
Kişi 15	107	13
Kişi 16	104	16
Kişi 17	89	31
Kişi 18	106	14
Toplam	1878	247

Bu 18 bireyden 2, 3, 5, 7, 8 ve 14. kişiler seçilerek homojen dağılım elde edilmiştir. Kişi bazlı, IMF bazlı ve kanal bazlı olarak veriseti ayrılmıştır. Verilerin homojen dağılımlı olması için, verisetinde “Evet” ve “Hayır” veri sayısı eşit hale getirilmiştir. Veriseti objektif sorular olan #1, #2 (1’in aynı soruları), #3, #4 ve subjektif sorular olmak üzere toplam 5 oturumdan oluşmaktadır. Her oturumda 24 soru bulunmaktadır. "Evet" etiketli, dikkat kayması varsa aynı oturumdan onun karşılığında rastgele bir "Hayır" seçilmiştir. Son olarak elde edilen resimlerin boyutları eşitlenmiştir. Bu verisetinde de toplam 29 kanaldan sadece PO7 ve PO8 adlı 2 adet EEG kanallarına ve IMF değeri 6 ve 10 olarak alındığındaki veriler üzerine odaklanılmıştır.

Çizelge 4. 4. Farklı IMF değerlerindeki homojen dağılımlı veri sayıları

Uygulanan IMF Değeri	Hayır (Adet)	Evet (Adet)
6	2964	2964
8	3952	3952
10	4940	4940
12	5928	5928
Toplam	17784	17784

Gizli katman değerleri 32'den başlatılıp 2'nin katları olacak şekilde 1024'e kadar; Epoch sayısı 100; Dropout 0,1 ve 0,5; Ağırlık modeli imagenet; Öğrenme oranı (learning rate, η) 0,0001; Aktivasyon fonksiyonları reLU, sigmoid, tanh ve softmax olmak üzere denenmiştir. Aşağıdaki Çizelge 4.5, Çizelge 4.6 ve Çizelge 4.7'de başarımlar en yüksek modellere yer verilmiştir. Çizelge sütun isimlendirilmelerinde şu kısaltmalar kullanılmıştır:

- Transfer F: Transfer fonksiyonu
- Eğitim F: Eğitim fonksiyonu

Çizelge 4.5. Veriseti-2 üzerinde yapılan VGG16 modeli ile elde edilen en yüksek analiz sonuçları

Katman	Transfer F.	Epoch	Eğitim F.	Eğitim Başarımı (%)	Test Başarımı (%)
64	reLU	100	Sigmoid	95,98	96,67
1024	reLU	100	reLU	95,54	96,67
64	reLU	100	Tanh	95,09	96,67
1024	reLU	100	reLU	92,86	96,67
1024-1024	reLU	100	reLU	88,46	96,67
64	reLU	100	Sigmoid	94,64	95,83
64	reLU	100	reLU	94,20	95,83
64	reLU	100	tanh	93,30	95,83
64	Sigmoid	100	Softmax	96,88	91,67
64	reLU	100	tanh	96,43	91,67
64	reLU	100	Softmax	96,43	91,67
64	reLU	100	Sigmoid	94,20	91,67
64	reLU	100	reLU	93,75	91,67
64	reLU	100	reLU	91,96	91,67

Çizelge 4.6. Veriseti-2 üzerinde yapılan VGG19 modeli ile elde edilen en yüksek analiz sonuçları

Katman	Transfer F.	Epoch	Eğitim F.	Eğitim Başarımı (%)	Test Başarımı (%)
1024	Softmax	100	Sigmoid	49,26	83,75
1024	Softmax	100	Sigmoid	49,80	76,90
64	Softmax	100	Sigmoid	49,60	62,43
512	Softmax	100	Sigmoid	49,58	62,36
512-512	Softmax	100	Sigmoid	48,13	62,10

Çizelge 4.7. Veriseti 2 üzerinde yapılan RESNET50 modeli ile elde edilen en yüksek analiz sonuçları

Katman	Transfer F.	Epoch	Eğitim F.	Eğitim Başarımı (%)	Test Başarımı (%)
1024	reLU	100	Sigmoid	49,10	93,06
1024	reLU	100	Softmax	48,96	78,81
1024	reLU	100	Tanh	48,58	69,36
512	Softmax	100	Sigmoid	48,37	58,20
1024	reLU	100	reLU	45,31	55,96
64-64	reLU	100	Softmax	45,19	55,03
512	reLU	100	reLU	45,2	54,89

4.3. Strateji 3: Veriseti-1 Kullanılarak Kanal Bazlı Değerlendirmeler Yapılıp Derin Öğrenme Yaklaşımlarının Daha Anlamlı Olduğunu Göstermeye Yönelik Analizlerin Gerçekleştirilmesi

Veriseti-1'i oluşturmak için yapılan uygulama "4.1. Strateji 1: Veriseti-1 Kullanılarak Makine Öğrenmesi Yöntemlerinin Uygulanması" başlığı altında detaylı şekilde anlatılmıştır.

Strateji 3 ile, derin öğrenme algoritmalarından olan DBN, DNN, GNN ve GCN algoritmaları, farklı katmanlar ve farklı epoch sayıları ile veriseti 1 üzerinde denenerek sonuçlara ulaşılmıştır. Strateji 1'de yapılan deneyler sonucunda, en çok başarımı PO7 adlı kanal vermesi sebebiyle bu stratejide bu kanal üzerine yoğunlaşmıştır. Elde edilen sonuçlarda; başarımlar hassasiyet, duyarlılık ve F1 skor değerleri kaydedilmiştir.

DBN ve DNN algoritmaları için gizli katman değerleri 100'den başlatılıp 500'e kadar ve 16'dan başlatılıp 2'nin katları olacak şekilde 2048'e kadar; RBM epoch sayıları 10 ve 20; ANN epoch sayıları 100 ve 200; Dropout 0,1 ve 0,2; Aktivasyon fonksiyonları relu ve sigmoid olmak üzere denenmiştir. Başarım değeri en yüksek modellere aşağıdaki çizelgelerde yer verilmiştir. Gösterilen modeller çizelge sütun isimlendirilmelerinde aşağıdaki gibi kısaltmalar kullanılmıştır:

- η : Öğrenme Oranı (Learning Rate)
- f_aktivasyon : Aktivasyon Fonksiyonu

Çizelge 4.8. Herhangi bir ön işlem yapılmadan tek katmanlı DBN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
500	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
450	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
400	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
350	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
300	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
250	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
200	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
150	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
100	10	0,05	10	0,1	relu	0,2	52,53	0,27	0,52	0,36
470	10	0,05	10	0,1	relu	0,2	47,46	0,22	0,47	0,30

Çizelge 4.9. Normalizasyon ön işlemi yapılarak tek katmanlı DBN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
320	10	0,05	100	0,01	relu	0,1	66,49	0,69	0,66	0,64
360	10	0,05	100	0,1	relu	0,1	64,88	0,69	0,64	0,61
400	10	0,05	100	0,1	relu	0,1	63,83	0,70	0,63	0,59
420	10	0,05	100	0,1	relu	0,1	63,81	0,71	0,63	0,59
280	20	0,05	200	0,1	relu	0,2	63,48	0,66	0,63	0,60
380	20	0,05	200	0,1	relu	0,2	62,89	0,67	0,62	0,58
400	20	0,05	200	0,1	relu	0,2	62,38	0,67	0,62	0,58
210	10	0,05	100	0,1	Sigmoid	0,2	59,90	0,62	0,59	0,56
240	10	0,05	10	0,1	relu	0,2	59,84	0,62	0,60	0,57

Çizelge 4.10. Standardizasyon ön işlemi yapılarak tek katmanlı DBN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
190	10	0,05	100	0,1	reLU	0,2	57,76	0,60	0,62	0,56
180	10	0,05	10	0,1	Sigmoid	0,2	54,27	0,55	0,54	0,48
150	10	0,05	100	0,1	Sigmoid	0,2	54,15	0,57	0,54	0,43
230	20	0,05	200	0,1	reLU	0,2	53,93	0,55	0,54	0,54
340	10	0,05	10	0,1	Sigmoid	0,2	53,66	0,53	0,52	0,40
500	10	0,05	100	0,1	Sigmoid	0,2	53,43	0,54	0,52	0,40
490	10	0,05	100	0,1	reLU	0,2	53,43	0,56	0,59	0,52
210	10	0,05	10	0,1	Sigmoid	0,2	53,35	0,49	0,45	0,39
470	10	0,05	10	0,1	reLU	0,2	52,85	0,51	0,50	0,52
160	10	0,05	100	0,1	reLU	0,2	52,65	0,48	0,42	0,52

Çizelge 4.11. Normalizasyon ön işlemi yapılarak iki katmanlı DBN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
120-120	10	0,05	100	0,01	reLU	0,2	64,83	0,68	0,65	0,62
140-140	10	0,05	100	0,1	reLU	0,2	64,73	0,67	0,64	0,62
180-440	10	0,05	100	0,1	reLU	0,2	64,73	0,69	0,65	0,62
100-250	10	0,05	100	0,1	reLU	0,2	64,47	0,67	0,64	0,62

Çizelge 4.12. Normalizasyon ön işlemi yapılarak üç katmanlı DBN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
100-110-380	10	0,05	100	0,01	reLU	0,2	64,52	0,66	0,65	0,63
100-110-180	10	0,05	100	0,1	reLU	0,2	63,79	0,64	0,64	0,63
100-110-340	10	0,05	100	0,1	reLU	0,2	62,6	0,63	0,63	0,62
100-100-300	10	0,05	100	0,1	reLU	0,2	62,54	0,63	0,63	0,62
100-110-300	10	0,05	100	0,1	reLU	0,2	62,23	0,63	0,62	0,61
100-110-120	10	0,05	100	0,1	reLU	0,2	61,35	0,66	0,61	0,57
100-110-160	10	0,05	100	0,1	reLU	0,2	61,33	0,64	0,61	0,58
100-110-100	10	0,05	100	0,1	reLU	0,2	59,77	0,62	0,60	0,59

Çizelge 4.13. Normalizasyon ön işlemi yapılarak, DNN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
100-150-380	10	0,05	100	0,01	reLU	0,2	64,52	0,66	0,65	0,63
100-210-180	10	0,05	100	0,1	reLU	0,2	63,79	0,64	0,64	0,63
100-310-340	10	0,05	100	0,1	reLU	0,2	62,6	0,63	0,63	0,62
150-100	10	0,05	100	0,1	reLU	0,2	62,54	0,63	0,63	0,62
200-110-300	10	0,05	100	0,1	reLU	0,2	62,23	0,63	0,62	0,61
500-150	10	0,05	100	0,01	reLU	0,1	66,49	0,69	0,66	0,64
350-350	10	0,05	100	0,1	reLU	0,1	64,88	0,69	0,64	0,61

Çizelge 4.14. Standardizasyon ön işlemi yapılarak, DNN analiz sonuçları

Gizli Katman	RBM		ANN				Başarım (%)	Hassasiyet (precision, %)	Duyarlılık (recall, %)	F1 Skor (%)
	Epoch	η	Epoch	η	f_aktivasyon	Dropout				
150-200	10	0,05	100	0,1	reLU	0,2	57,76	0,60	0,62	0,56
100-100-100	10	0,05	10	0,1	reLU	0,2	54,27	0,55	0,54	0,48
110-200	10	0,05	100	0,1	reLU	0,2	54,15	0,57	0,54	0,43
480	20	0,05	200	0,1	reLU	0,2	53,93	0,55	0,54	0,54
110-110-100	10	0,05	10	0,1	reLU	0,2	53,66	0,53	0,52	0,40
100-120-100	10	0,05	100	0,1	reLU	0,2	53,43	0,54	0,52	0,40
100-450-100	10	0,05	100	0,1	reLU	0,2	53,43	0,56	0,59	0,52

GNN ve GCN algoritmalarında, Veriseti-1'in her bir satırı bir düğüm olarak ele alınmıştır. Düğümler arasındaki kenarların oluşturulması ve anlamlı ilişkilerin kurulması amacıyla iki farklı yöntem kullanılmıştır: komşuluk matrisi ve k-NN algoritması. Bazı deneylerde ise k-NN algoritması kenar oluşturmak için, komşuluk matrisi ise özellik çıkarmak için kullanılmıştır.

GNN ve GCN algoritmaları için gizli katman değerleri 100'den başlayarak 500'e kadar ve 16'dan başlayarak 2'nin katları olacak şekilde 2048'e kadar ayarlanmıştır. Epoch sayıları ise 50 ile 250 arasında belirlenmiştir. Dropout oranları 0.1, 0.001 ve 0.0001; aktivasyon fonksiyonları ReLU, sigmoid, tanh ve leaky ReLU; çıkış fonksiyonları ise softmax, logaritmik softmax ve sigmoid olarak denenmiştir. k-NN algoritması için k değeri 3 ve 5

olarak belirlenmiştir. Çizelge 4.15 ve Çizelge 4.16'da GNN algoritmasından elde edilen başarımların en yüksek modellerin analiz sonuçlarına yer verilmiştir.

Çizelge 4.15. Normalizasyon ön işlemi yapılarak, GNN analiz sonuçları

Katman	Transfer F.	Epoch	Eğitim F.	Veri Bölütlemesi Stratejisi	k-NN için k Değeri	Komşuluk Matrisi	Eğitim Başarımı (%)	Test Başarımı (%)
128-128-128	Logaritmik Softmax	60	ReLU	Train test ayrı	5	Var	99,71	99,84
128-128-128	Logaritmik Softmax	60	ReLU	%80-%20	3	Var	98,72	85,57
128-128-128	Logaritmik Softmax	60	ReLU	%80-%20	5	Var	99,85	82,05
128-128-128	Logaritmik Softmax	60	ReLU	%80-%20	5	Var	99,87	81,84
256-256	Logaritmik Softmax	100	ReLU	%80-%20	5	Var	93,59	81,67
128-128-128	Logaritmik Softmax	60	ReLU	%80-%20	5	Var	91,34	81,12
128-128-128	Logaritmik Softmax	60	ReLU	5-katlı Ç.D.	5	Var	89,81	80,22
1024-512	Logaritmik Softmax	100	ReLU	Train test ayrı	3	Var	99,69	57,62
512-256	Logaritmik Softmax	60	ReLU	Train test ayrı	3	Yok	99,69	57,52

Çizelge 4.16. Standardizasyon ön işlemi yapılarak, GNN analiz sonuçları

Katman	Transfer F.	Epoch	Eğitim F.	Veri Bölütlemesi Stratejisi	k-NN için k Değeri	Komşuluk Matrisi	Eğitim Başarımı (%)	Test Başarımı (%)
128-128-128	Logaritmik Softmax	60	ReLU	%80-%20	5	Var	80,96	73,36
128-64	Logaritmik Softmax	100	ReLU	%80-%20	3	Var	78,42	73,36
128-64-32	Logaritmik Softmax	60	ReLU	%80-%20	3	Var	78,14	73,21
256-256	Logaritmik Softmax	60	ReLU	%80-%20	3	Var	78,25	72,69
256-256	Logaritmik Softmax	150	ReLU	%80-%20	5	Var	79,33	72,69
128-128	Logaritmik Softmax	60	ReLU	5-katlı Ç.D.	3	Var	75,98	71,52
128-128	Logaritmik Softmax	60	ReLU	%80-%20	5	Var	75,63	60,36
1024-512-256	Logaritmik Softmax	60	Tanh	%80-%20	5	Var	69,63	60,36

GCN algoritmasındaki tüm denemelere rağmen başarımlar %52,43'ün üzerine çıkartılamadığı için çizelgede yer verilmemiştir. Normalizasyon ön işleme ile, iki katmanlı (512-64), 100 epoch, transfer fonksiyonu logaritmik Softmax, eğitim fonksiyonu Sigmoid, k değeri 5, komşuluk matrisi kullanılarak en yüksek %50,20 eğitim başarımları ve %52,43 test başarımları elde edilmiştir. Standardizasyon ön işleme ile, iki katmanlı (64-1024), 100 epoch, transfer fonksiyonu logaritmik Softmax, eğitim fonksiyonu ReLU, k değeri 3, komşuluk matrisi kullanılarak en yüksek %51,96 eğitim başarımları ve %52,41 test başarımları elde edilmiştir.

Detaylı GCN modelleri ile verinin karakteristiğinin bozulduğu ve buna bağlı olarak da modelin overfit olduğu gözlemlenmiştir. En basit modellerden biri olan VGG16 ile en başarılı CNN yaklaşımı sonuçlarının alınmasının temel sebebi de budur.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, derin öğrenme ve makine öğrenmesi yöntemlerinin mekansal dikkat kayması üzerindeki performanslarını değerlendirmek amacıyla çeşitli deneyler gerçekleştirilmiştir. Deneylerde kullanılan veri setleri ve uygulanan yöntemler detaylı olarak incelenmiş ve sonuçlar karşılaştırılmıştır. Elde edilen bulgular, bu alandaki bilgiyi genişletmekte ve gelecekteki araştırmalar için değerli bir temel oluşturmaktadır.

Strateji-1 ve Strateji-3 kullanılarak gerçekleştirilen deneylerde, makine öğrenmesi ve derin öğrenme algoritmalarının mekansal dikkat kayması üzerindeki etkileri değerlendirilmiştir.

- Strateji 1:
 - İlk bakış açısında, 18 sağlıklı bireyden elde edilen EEG sinyalleri üzerinde SVM, k-NN, MLP ve karar ağacı algoritmaları uygulanmıştır. Her algoritmanın çeşitli kombinasyonları denenmiş ve en yüksek başarımların karar ağacı algoritması ile %89,24 test başarımına ulaştığı gözlemlenmiştir.
 - İkinci bakış açısında, PO7 ve PO8 kanalları üzerinde yapılan denemelerde, karar ağacı ve k-NN algoritmaları en yüksek başarımları elde etmiştir. Karar ağacı algoritmasında RF modeli ile %100,0 test başarımı elde edilirken, k-NN algoritmasında k=1 değeri için aynı başarıma ulaşılmıştır.
- Strateji 3:
 - Derin öğrenme algoritmalarından DBN ve DNN çeşitli katman ve epoch sayıları ile Veriseti-1 üzerinde uygulanmıştır. Veriseti-1 üzerinde herhangi bir ön işleme yapılmadan uygulanan tek katmanlı DBN ile en yüksek test başarımı %52,53 olarak elde edilmiştir.
 - Normalizasyon ön işleme uygulanan veriler ile tek katmanlı DBN algoritması ile %66,49; üç katmanlı DNN algoritması ile %64,52; üç katmanlı GNN algoritması ile %99,84; iki katmanlı GCN algoritması ile %52,43 en yüksek test başarımları sağlanmıştır.
 - Standardizasyon ön işleme uygulanan veriler ile tek katmanlı DBN algoritması ile %57,76; iki katmanlı DNN algoritmaları ile %57,76; üç katmanlı GNN algoritması ile %73,36; iki katmanlı GCN algoritması ile %52,41 en yüksek test başarımları sağlanmıştır.

Strateji-2 kapsamında, CNN tabanlı popüler modeller olan VGG16, VGG19 ve RESNET50 uygulanmıştır. Farklı IMF değerleri (6, 8, 10 ve 12) denenmiş ve en iyi sonuç VGG16 modeli ile IMF=6 için %95,98 eğitim ve %96,67 test başarımı ile elde edilmiştir. VGG19 ve RESNET50 modelleri ise genellikle %55 ile %60 değerleri arasında başarımlarını vermiştir, ancak yüksek test başarımlarına da ulaşılmıştır. VGG19 için %49,26 eğitim ve %83,75 test başarımı, RESNET50 için ise %49,10 eğitim ve %93,06 test başarımı elde edilmiştir.

Deneyler sonucunda, mekansal dikkat kayması üzerine en iyi sonuçları elde eden kanal PO7 olarak belirlenmiştir. Bu kanal hem makine öğrenmesi hem de derin öğrenme algoritmalarında en yüksek performansı gösterdiği için özel bir öneme sahiptir. Yöntem bazında karşılaştırma yapıldığında:

- Makine Öğrenmesi Algoritmaları:
 - Veriseti-1 üzerinde Karar ağacı ve k-NN algoritmaları mekansal dikkat kayması üzerine en iyi sonuçları vermiştir. Karar ağacı algoritmasında RF modeli %100,0 test başarımı ile en yüksek başarıyı sağlarken, k-NN algoritmasında da k=1 değeri için aynı başarıma ulaşılmıştır.
- Derin Öğrenme Algoritmaları:
 - Veriseti-1 üzerinde DBN, DNN, GNN ve GCN algoritmaları arasından, GNN algoritması mekansal dikkat kayması üzerine en iyi sonuçları vermiştir. Üç katmanlı GNN modeli %99,84 en yüksek test başarımı sağlamıştır.
 - Veriseti-2 üzerinde CNN tabanlı modeller arasında VGG16 modeli %96,67 ile en yüksek test başarımını sağlamıştır. Diğer modellerin başarımları daha değişken olmakla birlikte, bazı yüksek test başarımları diğer CNN tabanlı modellerde de elde edilmiştir.

Zaman ve frekans tabanlarından elde edilen sonuçlar, veri analizinde kullanılan algoritmaların performansını anlamada önemli bir rol oynamıştır. Zaman tabanlı analizleri, veri setindeki zaman serisi özelliklerini daha iyi temsil ederken, frekans tabanlı analizleri, özellikle sinyallerin spektral özelliklerini vurgulamıştır. Çalışmada gözlemlenen temel fark, zaman tabanından elde edilen sonuçların belirli durumlarda yüksek çözünürlük sağlarken, frekans tabanından genellikle daha genel bir modelleme yaklaşımı sunduğudur. Bu iki tabanlı arasında yapılan karşılaştırmalar, farklı veri türleri ve analiz senaryoları için hangi tabanın daha uygun olabileceği konusunda çıkarımlar yapılmasına olanak sağlamıştır.

Derin öğrenme algoritmalarının sınıflandırma ve analiz performansı üzerindeki etkileri dikkate alınmıştır. Özellikle CNN, GNN ve diğer makine öğrenme algoritmaları, farklı veri türlerinde test edilmiştir. CNN algoritmalarının zaman tabanlı analizinde daha iyi sonuçlar verdiği gözlemlenirken, GNN'lerin frekans tabanlı analizinde ağ yapısına dayalı özellikleri daha etkin bir şekilde yakalayabildiği ortaya çıkmıştır. Bu farklılık, algoritmaların veri türüne ve uygulama bağlamına göre seçilmesi gerektiğini göstermektedir.

Çeşitli CNN modelleri (ResNet, VGG16 ve VGG19) üzerinde yapılan değerlendirmeler, derin katmanlı mimarilerin daha karmaşık özellikleri öğrenmede üstün olduğunu

göstermiştir. Örneğin, VGG16, zaman tabanında daha başarılı sonuçlar üretmiştir. Genel olarak, VGG16 modeli, hem doğruluk hem de hassasiyet açısından diğer modellerden daha başarılı bulunmuştur. Ancak bu başarı, modelin eğitim süresi ve hesaplama gereksinimlerine bağlı olarak değişkenlik göstermektedir.

Zaman tabanlıda kullanılan CNN modelleri, özellikle kısa süreli değişimlerin analizinde daha başarılı bulunurken, frekans tabanlı analizinde kullanılan GNN ve klasik makine öğrenme algoritmaları (Random Forest ve k-NN) daha iyi sonuçlar vermiştir. Bu durum, sinyalin doğasına ve sınıflandırıcıların veri türüne adaptasyon kabiliyetine bağlıdır. Sonuç olarak, zaman tabanlı analizleri CNN modelleriyle daha etkili bir performans sergilerken, frekans tabanlı analizlerinde GNN, k-NN ve karar ağacı gibi yöntemlerin üstünlüğü gözlemlenmiştir.

Paylaşılan sonuçlarda itere edilen birçok hiperparametre değerleri için elde edilen değerlerden en yüksek sınıflandırma başarımına ulaşılan modeller ve başarımları raporlanmıştır. Çizelge 5.1.'de zaman ve frekans tabanlarından elde edilen en iyi metrikleri, kullanılan modelleri ve algoritmaları özetlemektedir:

Çizelge 5.1. Zaman ile frekans tabanlı açısından ve derin öğrenme ile makine öğrenmesi algoritmalarından elde edilen en yüksek analiz sonuçları

Öznitelik çıkarma Yöntemi	Zaman/frekans	Sınıflandırıcı Adı	Model Yapısı	Veri Bölütleme Stratejisi	Strateji	Eğitim Başarımı (%)	Test Başarımı (%)	AUC Değeri
EWT	Frekans tabanlı	k-NN	K=1	%80-%20	1	%100	%100	1
EWT	Frekans tabanlı	Karar Ağacı	Random forest ve random tree	%80-%20	1	%100	%100	1
EWT	Frekans tabanlı	GNN	128-128-128	Train test ayrı	5	%99,71	%99,84	0,99
EEMD	Zaman tabanlı	CNN	VGG16 (64)	%80-%20	2	95,98	96,67	0,98
EWT	Frekans tabanlı	DBN	120-120	Train test ayrı	3	%66,39	%66,49	0,69
EWT	Frekans tabanlı	MLP	100-100-100	%90-%10	1	%64,70	%64,86	0,68
EWT	Frekans tabanlı	DNN	100-150-380	Train test ayrı	3	%64,48	%64,52	0,67
EWT	Frekans tabanlı	SVM	-	10-katlı Ç.D.	1	%62,90	%62,92	0,63
EWT	Frekans tabanlı	GCN	512-64	Train test ayrı	3	%50,20	%52,43	0,53

- **Algoritma Seçimi:** Mekansal dikkat kayması üzerine yüksek başarımlar elde etmek için, karar ağacı, k-NN ve GNN algoritmaları öne çıkmaktadır. Bu algoritmalar, diğer algoritmalarla kıyasla daha tutarlı ve yüksek başarımlar sunmaktadır.
- **Derin Öğrenme Uygulamaları:** Derin öğrenme yöntemlerinde, veri ön işlemleri (normalizasyon, standardizasyon) başarıyı artırmak için kritik öneme sahiptir. Normalizasyonun daha iyi sonuç sağladığı gözlemlenmiştir.
- **Model Seçimi:** VGG16 modelinin Veriseti-2 üzerinde en yüksek test başarımlarını sağladığı göz önünde bulundurulduğunda, bu modelin mekansal dikkat kayması üzerine daha fazla araştırılması önerilmektedir.
- **Gelecek Çalışmalar:** Farklı veri setleri ve daha çeşitli algoritma kombinasyonları ile yapılacak çalışmalar, bu sonuçları pekiştirebilir ve mekansal dikkat kayması üzerine daha derinlemesine bilgiler sağlayabilir.

Bu tez çalışması, mekansal dikkat kayması üzerine derin öğrenme ve makine öğrenmesi yöntemlerinin etkilerini kapsamlı bir şekilde değerlendirmiş ve çeşitli algoritmaların performanslarını karşılaştırmıştır. Elde edilen bulgular, bu alandaki bilgiyi genişletmekte ve gelecekteki araştırmalar için değerli bir temel oluşturmaktadır.

KAYNAKLAR

- Ahmadi, N., Nilashi, M., Minaei-Bidgoli, B., Farooque, M., Samad, S., Aljehane, N. O., Zogaan, W. A. ve Ahmadi, H. (2022). Eye State Identification Utilizing EEG Signals: A Combined Method Using Self-Organizing Map And Deep Belief Network. *Scientific Programming*, 2022(1), 4439189.
- Alickovic, E., Dorszewski, T., Christiansen, T. U., Eskelund, K., Gizzi, L., Skoglund, M. A. ve Wendt, D. (2023). Predicting EEG Responses To Attended Speech Via Deep Neural Networks For Speech. *2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Avusturalya, (1-4).
- Alotaibi, F. M. ve Fawad, F. (2022). A Multifaceted Deep Generative Adversarial Networks Model For Mobile Malware Detection. *Applied Sciences (Switzerland)*, 12(19), 9403.
- Altan, G. (2022). DeepOCT: An explainable deep learning architecture to analyze macular edema on OCT images. *Engineering Science and Technology, an International Journal*, 34, 101091.
- Altan, G. ve Inat, G. (2021). EEG Based Spatial Attention Shifts Detection Using Time-Frequency Features On Empirical Wavelet Transform. *Journal Of Intelligent Systems With Applications*, 4(2), 144-149.
- Altan, G., Kutlu, Y. ve Allahverdi, N. (2016). A Multistage Deep Belief Networks Application On Arrhythmia Classification. *International Journal of Intelligent Systems And Applications In Engineering*, 4(1), 222-228.
- Altan, G., Kutlu, Y. ve Allahverdi, N. (2016). Deep Belief Networks Based Brain Activity Classification Using EEG From Slow Cortical Potentials İn Stroke. *International Journal Of Applied Mathematics, Electronics And Computers*, 4(1), 205-210.
- Aung, H. W., Li, J. J., An, Y. ve Su, S. W. (2024). EEG_GLT-Net: Optimising EEG Graphs for Real-time Motor Imagery Signals Classification. arXiv preprint arXiv:2404.11075.
- Babu, N. V. Ve Kanaga, E. G. M. (2024). Advanced functional connectivity analysis with integrated EEG signal enhancement and GTW-EEG-GAN for emotion detection. *International Journal of Computers and Applications*, 1-14.
- Barrett, K. E., Barman, S. M., Boitano, S. ve Brooks, H. L. (2010). *Ganong's Review Of Medical Physiology (23. Baskı)*. Meksika: McGraw-Hill Companies, 313.
- Bengio, Y. ve Delalleau, O. (2009). Justifying and Generalizing Contrastive Divergence. *Neural Computation*, 21(6), 1601-1621.
- Ceylan, A. ve Uyar, E. (2024). Beyin Ölümü, *Güven Medical and Health Sciences*, 1(2), 66-70.
- Chen, J., Lin, X., Ma, W., Wang, Y. ve Tang, W. (2024). EEG-based emotion recognition for road accidents in a simulated driving environment. *Biomedical Signal Processing and Control*, 87, 105411.

- Chen, K., Chai, S., Xie, T., Liu, Q. ve Ma, L. (2024). EEG spatial inter-channel connectivity analysis: A GCN-based dual stream approach to distinguish mental fatigue status. *Artificial Intelligence in Medicine*, 157, 102996.
- Cherukuvada, S. ve Kayalvizhi, R. (2023). Feature Selection With Deep Belief Network For Epileptic Seizure Detection On EEG Signals. *Computers, Materials and Continua*, 75(2), 4102-4118.
- Çalışkan, D. ve Demir, Ö. (2022). Derin öğrenme yöntemleri ile şüpheli davranış tespiti. *International Periodical of Recent Technologies in Applied Engineering*, 3(1), 26-43.
- Çeper, S. (2022). Uyku Apnesi İle Uyku Evreleri Arasındaki İlişkinin Tespit Edilmesi, Yayınlanmamış Yüksek Lisans Tezi, *Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*, Konya.
- Dairi, A., Zerrouki, N., Harrou, F. ve Sun, Y. (2022). EEG-Based Mental Tasks Recognition Via A Deep Learning-Driven Anomaly Detector. *Diagnostics*, 12(12), 2984.
- Değirmenciler, A., Cengiz, B. ve İleri, K. (2022). COVID-19'un Yayılmasını Önlemek için CNN ile Yüz Maskesi Tespiti. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(2), 259-265
- Delibalta, T. (2022). Görsel Çeldirici Uyarıların Yenilik Özelliği Ve Sikliğinin Spontan Dikkat Yanıtı Üzerine Etkileri. Yayınlanmamış Yüksek Lisans Tezi, *Mersin Üniversitesi Sağlık Bilimleri Enstitüsü*, Mersin.
- Dhadhania, A., Bhatia, J., Mehta, R., Tanwar, S., Sharma, R. ve Verma, A. (2024). Unleashing the power of SDN and GNN for network anomaly detection: State-of-the-art, challenges, and future directions. *Security and Privacy*, 7(1), e337.
- Dhiman, P., Kukreja, V., Manoharan, P., Kaur, A., Kamruzzaman, M., Dhaou, M., Ben, I. ve Iwendi, C. (2022). A Novel Deep Learning Model For Detection Of Severity Level Of The Disease İn Citrus Fruits. *Electronics (Switzerland)*, 11(3), 495.
- Elsayed, N. E., Tolba, A. S., Rashad, M. Z., Belal, T. ve Sarhan, S. (2021). A Deep Learning Approach For Brain Computer Interaction-Motor Execution Eeg Signal Classification. *IEEE Access*, 9, 101513-101529
- Fadiga, L., Buccino, G., Craighero, L., Fogassi, L., Gallese, V. ve Pavesi, V. (1999). Corticospinal Excitability Is Specifically Modulated By Motor İmagery: A Magnetic Stimulation Study. *Neuropsychologia*, 37(2), 147-158.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*, 36(4), 193-202.
- Gaba, S., Budhiraja, I., Kumar, V., Garg, S., Kaddoum, G. ve Hassan, M. M. (2022). A federated calibration scheme for convolutional neural networks: Models, applications and challenges. *Computer Communications*, 192, 144-162.

- Guhan Seshadri, N. P., Agrawal, S., Kumar Singh, B., Geethanjali, B., Mahesh, V. ve Pachori, R. B. (2023). EEG Based Classification Of Children With Learning Disabilities Using Shallow And Deep Neural Network. *Biomedical Signal Processing and Control*, 82, 104553.
- Gümüş, H. T. ve Eyüpoğlu, C. (2024). Grafik Sinir Ağları Üzerine Bir İnceleme. *Savunma Bilimleri Dergisi*, 20(1), 105-138.
- Gürsoy, M. İ., Ustun, S. V. ve Yilmaz, A. S. (2018). An Efficient Dwt And Ewt Feature Extraction Methods For Classification Of Real Data Pq Disturbances. *Uluslararası Muhendislik Arastirma ve Gelistirme Dergisi*, 10(1), 158-171.
- Hidaka, K., Qin, H., ve Kobayashi, J. (2017). Preliminary Test Of Affective Virtual Reality Scenes With Head Mount Display For Emotion Elicitation Experiment. *17th International Conference on Control, Automation and Systems (ICCAS)*, 325-329.
- Hinton, G. E., Osindero, S., ve Teh, Y. W. (2006). A Fast Learning Algorithm For Deep Belief Nets. *Neural Computation*, 18(7), 1527-1554.
- Hu, Y., Li, F., Li, H., ve Liu, C. (2017). An Enhanced Empirical Wavelet Transform For Noisy And Non-Stationary Signal Processing. *Digital Signal Processing: A Review Journal*, 60, 220-229.
- Kantar, T. ve Erdamar, A. (2017). Detection Of K-Complexes In Sleep EEG With Support Vector Machines. *Signal Processing and Communications Applications Conference (SIU)*, Antalya, 1-4.
- Karamah, F. N., ve Dahleh, M. A. (2000). Automated Classification Of EEG Signals İn Brain Tumor Diagnostics. *Proceedings of the American Control Conference*, 6, 4169-4173.
- Klepl, D., He, F., Wu, M., Blackburn, D. J. ve Sarrianni, P. (2022). EEG-based graph neural network classification of Alzheimer's disease: An empirical evaluation of functional connectivity methods. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 2651-2660.
- Kumaran, D. S. (2018). Using Eeg-Validated Music Emotion Recognition Techniques To Classify Multi-Genre Popular Music For Therapeutic Purposes. *Nanyang Technological University*, Nanyang Ave, Singapore.
- Latreche, I., Slatnia, S., Kazar, O., Harous, S. ve Khelili, M. A. (2024). Identification and diagnosis of schizophrenia based on multichannel EEG and CNN deep learning model. *Schizophrenia Research*, 271, 28-35.
- Md, V., Misra, S., Ma, G., Mohanty, R., Georganas, E., Heinecke, A. ve Avancha, S. (2021). Distgnn: Scalable distributed training for large-scale graph neural networks. In *Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis*, 1-14.
- Michael J. Aminoff. (2012). Aminoff's Electrodiagnosis İn Clinical Neurology: Expert Consult-Online and Print (6. Baskı). Kaliforniya, ABD: Elsevier Saunders.

- Mitchell, T. M. (1997). Machine Learning. *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR*, New York, ABD: McGraw Hill.
- Movahedi, F., Coyle, J. L., ve Sejdic, E. (2018). Deep Belief Networks For Electroencephalography: A Review Of Recent Contributions And Future Outlooks. *IEEE Journal of Biomedical and Health Informatics*, 22(3), 642-652.
- Naskath, J., Sivakamasundari, G., ve Begum, Alif, S. (2023). A Study On Different Deep Learning Algorithms Used İn Deep Neural Nets: MLP SOM And DBN. *Wireless Personal Communications*, 128(4), 2913-2936.
- Negi, C. ve Shukla, A. N. (2019, November). An Approach for Solving the Graph Coloring Problem using Adjacency Matrix. In *2019 8th International Conference System Modeling and Advancement in Research Trends (SMART)*, 10-13.
- Oh, S. L., Hagiwara, Y., Raghavendra, U., Yuvaraj, R., Arunkumar, N., Murugappan, M., ve Acharya, U. R. (2020). A Deep Learning Approach For Parkinson's Disease Diagnosis From EEG Signals. *Neural Computing and Applications*, 32(15), 10927-10933.
- Oltu, B., Akşahin, M. F. ve Kibaroglu, S. (2019). Hafif Bilişsel Bozukluk Ve Alzheimer Hastalığının Teşhisi İçin Eeg Sinyalinin İncelenmesi. *Tiptekno'19: Tıp Teknolojileri Kongresi*, 3-5 Ekim, Kuşadası-Aydın, 231-234.
- Omerhodzic, I., Avdakovic, S., Nuhanovic, A., ve Dizdarevic, K. (2013). Energy Distribution Of EEG Signals: EEG Signal Wavelet-Neural Network Classifier. *World Academy of Science, Engineering and Technology*, 37(2013), 1240-1245.
- Othmani, A., Sabri, A. Q. M., Aslan, S., Chaieb, F., Rameh, H., Alfred, R., ve Cohen, D. (2023). EEG-Based Neural Networks Approaches For Fatigue And Drowsiness Detection: A Survey. *Neurocomputing*, 557(2023), 126709.
- Özekes, S. (2002). Veri Madenciliği Uygulaması. Yayımlanmamış Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Parsa, M., Rad, H. Y., Vaezi, H., Hossein-Zadeh, G. A., Setarehdan, S. K., Rostami, R., Rostami, H., ve Vahabie, A. H. (2023). EEG-Based Classification Of Individuals With Neuropsychiatric Disorders Using Deep Neural Networks: A Systematic Review Of Current Status And Future Directions. *Computer Methods and Programs in Biomedicine*, 240(2023), 107683.
- Raghu, S., Sriraam, N., Temel, Y., Rao, S. V., ve Kubben, P. L. (2020). EEG Based Multi-Class Seizure Type Classification Using Convolutional Neural Network And Transfer Learning. *Neural Networks*, 124, 202-212.
- Ravinder, M., Saluja, G., Allabun, S., Alqahtani, M. S., Abbas, M., Othman, M., ve Soufiene, B. O. (2023). Enhanced Brain Tumor Classification Using Graph Convolutional Neural Network Architecture. *Scientific Reports*, 13(1), 14938.
- Reichert, C., Tellez Ceja, I. F., Sweeney-Reed, C. M., Heinze, H. J., Hinrichs, H., ve Dürschmid, S. (2020). Impact Of Stimulus Features On The Performance Of A Gaze-

Independent Brain-Computer Interface Based On Covert Spatial Attention Shifts. *Frontiers in Neuroscience*, 14, 591777.

Rittig, J. G., Gao, Q., Dahmen, M., Mitsos, A. ve Schweidtmann, A. M. (2023). Graph Neural Networks for the Prediction of Molecular Structure–Property Relationships.

Shang, C., Liu, Q., Chen, K. S., Sun, J., Lu, J., Yi, J. ve Bi, J. (2018). Edge attention-based multi-relational graph convolutional networks. *arXiv preprint arXiv:1802.04944*, 2.

Shim, H. M., An, H., Lee, S., Lee, E. H., Min, H. K., ve Lee, S. (2016). EMG Pattern Classification By Split And Merge Deep Belief Network. *Symmetry*, 8(12), 148.

Siddiqui, F., Mohammad, A., Alam, M. A., Naaz, S., Agarwal, P., Sohail, S. S., ve Madsen, D. Ø. (2023). Deep Neural Network For EEG Signal-Based Subject-Independent Imaginary Mental Task Classification. *Diagnostics*, 13(4), 640.

Suhaimi, N. S., Mountstephens, J., ve Teo, J. (2020). EEG-Based Emotion Recognition: A State-Of-The-Art Review Of Current Trends And Opportunities. *Computational Intelligence and Neuroscience*, 2020(1), 8875426.

Tanaka, K., Matsunaga, K., ve Wang, H. O. (2005). Electroencephalogram-Based Control Of An Electric Wheelchair. *IEEE Transactions on Robotics*, 21(4), 762-766.

Tang, B. B., Wei, X., Guo, G., Yu, F., Ji, M., Lang, H., ve Liu, J. (2019). The Effect Of Odor Exposure Time On Olfactory Cognitive Processing: An ERP Study. *Journal of Integrative Neuroscience*, 18(1), 87-93.

Tatar, A. B. (2023). Biometric Identification System Using EEG Signals. *Neural Computing and Applications*, 35(1), 1009-1023.

Tian, W., Li, M., Ju, X. ve Liu, Y. (2022). Applying multiple functional connectivity features in GCN for EEG-based human identification. *Brain Sciences*, 12(8), 1072.

Trigo-González, M., Cortés-Carmona, M., Marzo, A., Alonso-Montesinos, J., Martínez-Durbán, M., López, G., Portillo, C., ve Batlles, F. J. (2023). Photovoltaic Power Electricity Generation Nowcasting Combining Sky Camera Images And Learning Supervised Algorithms In The Southern Spain. *Renewable Energy*, 206, 251-262.

Ullah, W., Siddique, I., Zulqarnain, R. M., Alam, M. M., Ahmad, I., ve Raza, U. A. (2021). Classification Of Arrhythmia In Heartbeat Detection Using Deep Learning. *Computational Intelligence and Neuroscience*, 2021(1), 2195922.

Uyulan, Ç., Ergüzel, T., ve Tarhan, N. (2019). Elektroensefalografi Tabanlı Sinyallerin Analizinde Derin Öğrenme Algoritmalarının Kullanılması. *The Journal of Neurobehavioral Sciences*, 6(2), 108-124.

Vapnik, V. N. (1999). An Overview Of Statistical Learning Theory. *IEEE transactions on neural networks*, 10(5), 988-999.

- Vasudevan, H., Ganapathy, K., Palaniswamy, H. P., Searchfield, G., ve Rajashekhar, B. (2021). Systematic Review And Meta-Analysis On The Effect Of Continuous Subjective Tinnitus On Attention And Habituation. *PeerJ*, 9, e12340.
- Wang, D., Cao, C., Chen, N., Pan, W., Li, H., ve Wang, X. (2023). A Correlation-Graph-CNN Method For Fault Diagnosis Of Wind Turbine Based On State Tracking And Data Driving Model. *Sustainable Energy Technologies and Assessments*, 56, 102995.
- Wang, D., Lei, C., Zhang, X., Wu, H., Zheng, S., Chao, J. ve Peng, H. (2021, December). Identification of Depression with a Semi-supervised GCN based on EEG Data. In *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2338-2345.
- Wilaiprasitporn, T., Ditthaporn, A., Matchaparn, K., Tongbuasirilai, T., Banluesombatkul, N., ve Chuangsuwanich, E. (2020). Affective EEG-Based Person Identification Using The Deep Learning Approach. *IEEE Transactions on Cognitive and Developmental Systems*, 12(3), 486-496.
- Wu, G., Li, C., Yin, L., Wang, J., ve Zheng, X. (2023). Compared Between Support Vector Machine (SVM) And Deep Belief Network (DBN) For Multi-Classification Of Raman Spectroscopy For Cervical Diseases. *Photodiagnosis and Photodynamic Therapy*, 42(2023), 103340.
- Wu, M., Yan, M., Li, W., Ye, X., Fan, D., Sun, N. ve Xie, Y. (2024). A Comprehensive Survey on GNN Characterization. arXiv preprint arXiv:2408.01902.
- Xiang, T. Y., Zhou, X. H., Xie, X. L., Liu, S. Q., Yang, H. J., Feng, Z. Q. ve Hou, Z. G. (2024). Learning EEG Motor Characteristics via Temporal-Spatial Representations. *IEEE Transactions on Emerging Topics in Computational Intelligence*. Yang, Y., Gao, Q., Song, Y., Song, X., Mao, Z., ve Liu, J. (2022). Investigating Of Deaf Emotion Cognition Pattern By EEG And Facial Expression Combination. *IEEE Journal of Biomedical and Health Informatics*, 26(2), 589-599.
- Yao, X., Li, T., Ding, P., Wang, F., Zhao, L., Gong, A. ve Fu, Y. (2024). Emotion Classification Based on Transformer and CNN for EEG Spatial-Temporal Feature Learning. *Brain sciences*, 14(3), 268.
- Yıldırım, M. ve Yıldız, A. (2017). Farklı zaman ölçekli EEG işaretlerinden epilepsi nöbetinin otomatik tespiti. *Dicle Üniversitesi Mühendislik Dergisi*, 8(4), 745-757.
- Zhang, L., Song, H., Aletras, N. ve Lu, H. (2022). Node-feature convolution for graph convolutional networks. *Pattern Recognition*, 128, 108661.
- Zhang, S., Tong, H., Xu, J. ve Maciejewski, R. (2019). Graph convolutional networks: a comprehensive review. *Computational Social Networks*, 6(1), 1-23.
- Zhang, Y., Liao, Y., Chen, W., Zhang, X. ve Huang, L. (2024). Emotion recognition of EEG signals based on contrastive learning graph convolutional model. *Journal of Neural Engineering*, 21(4), 046060.

Zhao, W., Xu, C., Cui, Z., Zhang, T., Jiang, J., Zhang, Z. ve Yang, J. (2018). When work matters: Transforming classical network structures to graph cnn. arXiv preprint arXiv:1807.02653.





teknoversite AYRICALIĞINDASINIZ

İSTE

