



**T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**SİGARA BAĞIMLILIĞININ BİYOLOJİK SİNYALLER
KULLANARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
ANALİZİ**

TALİP ÇAY

DOKTORA TEZİ

Danışman: Dr. Öğr. Üyesi Cemil ALTIN

İkinci Danışman: Dr. Öğr. Üyesi Emre ÖLMEZ

TEMMUZ – 2024

YOZGAT

T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİLİĞİ ANABİLİM DALI

**SİĞARA BAĞIMLILIĞININ BİYOLOJİK SİNYALLER
KULLANARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
ANALİZİ**

TALİP ÇAY

DOKTORA TEZİ

Danışman: Dr. Öğr. Üyesi Cemil ALTIN

İkinci Danışman: Dr. Öğr. Üyesi Emre ÖLMEZ

TEMMUZ – 2024

YOZGAT



YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ONAY FORMU

T.C.

YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Enstitümüzün Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı öğrencisi Talip ÇAY'ın hazırladığı “**Sigara Bağımlılığının Biyolojik Sinyaller Kullanarak Makine Öğrenmesi Yöntemleri ile Analizi**” başlıklı tezi ile ilgili tez savunma sınavı, Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri gereğince 29/07/2024 Pazartesi günü saat 10:00'da yapılmış, tezin onayına oy birliği ile karar verilmiştir.

Başkan : Prof. Dr. Mehmet SAĞBAŞ

Jüri Üyesi : Dr. Öğr. Üyesi Cemil ALTIN

(Danışman)

Jüri Üyesi : Prof. Dr. Murat UZAM

Jüri Üyesi : Prof. Dr. Orhan ER

Jüri Üyesi : Mücella ÖZBAY KARAKUŞ

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulu'nun/...../..... tarih ve sayılı Enstitü Yönetim Kurulu Kararı ile onaylanmıştır.

...../...../.....

Prof. Dr. Ümit BUDAK

Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan eder, aksi bir durumda aleyhine doğabilecek tüm hak kayıplarını kabullendiğini beyan ederim.

Talip ÇAY

...../...../.....

ÖN SÖZ

Tez çalışmam süresince bana rehberlik eden ve her zaman destek olan Prof. Dr. Orhan ER, Dr. Öğr. Üyesi Cemil ALTIN ve Dr. Öğr. Üyesi Emre ÖLMEZ hocalarıma en içten teşekkürlerimi sunarım. Ayrıca tez çalışmamda değerli bilgilerini bizimle paylaşan Prof. Dr. Nermin TANIK hocama minnettarlığımı sunarım. Kendilerinin yol göstericiliği ve teşvik edici yaklaşımları bu çalışmanın başarısına büyük katkı sağlamıştır.

Beni bugünlere getiren ve haklarını asla ödeyemeyeceğim sevgili aileme, her an yanımda olup beni destekleyen kıymetli eşime ve zamanlarından fedakârlık ederek bu süreçte bana büyük anlayış gösteren sevgili kızlarım Miray Begüm ve Elif Eylül'e sonsuz teşekkürlerimi sunarım.

.

Talip ÇAY

.../.../.....

ÖZET

DOKTORA TEZİ

SİGARA BAĞIMLILIĞININ BİYOLOJİK SİNYALLER KULLANARAK MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ANALİZİ

TALİP ÇAY

YOZGAT BOZOK ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ CEMİL ALTIN

İKİNCİ DANIŞMAN: DR. ÖĞR. ÜYESİ EMRE ÖLMEZ

Sigara bağımlılığı dünya genelinde ciddi bir sağlık sorunu olarak kabul edilmektedir. Nikotin bağımlılığına dayanan sigara kullanımı milyonlarca insanı etkilemekte ve önemli sağlık sorunlarına yol açmaktadır. Sigara kullanımının beyin aktivitelerini etkilediği bilimsel çalışmalarla ortaya konmuştur. Elektroensefalografi (EEG), beyin aktivitesini ölçmek için kullanılan bir yöntemdir. Baş derisi üzerine yerleştirilen elektrotlar aracılığıyla beyin dalgaları kaydedilir. Bu kayıtlar farklı frekans aralıklarında (delta, teta, alfa, beta, gama gibi) beyin aktivitesini görselleştirmeye ve analiz etmeye olanak tanır. Bu tez çalışmasının temel amacı, EEG verilerinin zaman-frekans domen özelliklerini çıkararak, geleneksel yöntemler yerine makine öğrenmesi yöntemleriyle sigara bağımlılığının analiz edilmesidir.

Çalışmanın ilk aşamasında, 30 farklı bireyden görsel uyaranlarla toplanan EEG verileri Fagerström Nikotin Bağımlılığı anketi (FTND) ile etiketlenmiştir. Daha sonra makine öğrenmesi yöntemlerinde az veya dengesiz veri olumsuzluklarının önlenmesi için EEG verisi GAN (Çekişmeli Üretici Ağlar) ile sentetik olarak çoğaltılmıştır. Çoğaltılmış veriler, (DWT) Ayrık Dalgacık Dönüşümü, zaman ve frekans domeninde özellik çıkarımı gibi ön işlemlerden geçirilmiştir. İkinci aşamada ön işlemlerden geçirilen EEG verileri kNN (k-En Yakın Komşuluk), SVM (Destek Vektör Makineleri), YSA (İleri Beslemeli Yapay Sinir Ağları) ve RNN (Tekrarlamalı Sinir Ağları) gibi makine öğrenmesi algoritmalarıyla sınıflandırılmıştır. Sonuçlar sigara uyaranlarına verilen beyin tepkilerinin özellikle temporal ve prefrontal lob bölgelerinde belirgin olduğunu ve teta frekans bandında daha yüksek sınıflandırma başarılarına ulaşıldığını göstermiştir. İleri beslemeli YSA ile yapılan sınıflandırma başarı oranları, % 99 seviyelerine ulaşmıştır. Bu çalışma sigara bağımlılığına yönelik nörofizyolojik belirteçlerin belirlenmesinde EEG tabanlı makine öğrenmesi yöntemleri kullanımının potansiyelini vurgulamaktadır.

2024, ix + 113 Sayfa

Anahtar Kelimeler: Sigara Bağımlılığı, EEG, Makine Öğrenimi, YSA, RNN, GAN

ABSTRACT

DOCTORATE THESIS

ANALYSIS OF SMOKING ADDICTION USING MACHINE LEARNING METHODS WITH BIOLOGICAL SIGNALS

TALİP ÇAY

YOZGAT BOZOK UNIVERSITY

SCHOOL OF GRADUATE STUDIES

DEPARTMENT OF ELECTRICAL AND ELECTRONIC ENGINEERING

SUPERVISOR: ASST. PROF. CEMİL ALTIN

CO-SUPERVISOR: ASST. PROF. EMRE ÖLMEZ

Smoking addiction is considered a serious health problem worldwide. Smoking based on nicotine addiction affects millions of people and causes significant health problems. Scientific studies have shown that smoking affects brain activity. Electroencephalography (EEG) is a method used to measure brain activity. Brain waves are recorded through electrodes placed on the scalp. These recordings allow visualization and analysis of brain activity in different frequency ranges (such as delta, theta, alpha, beta, gamma). The main purpose of this thesis is to analyze smoking addiction with machine learning methods instead of traditional methods by extracting the time-frequency domain features of EEG data. In the first stage of the study, EEG data collected with visual stimuli from 30 different individuals were labeled with the Fagerström Nicotine Dependence Questionnaire (FTND). Later, EEG data was synthetically reproduced with GAN (Adversarial Generative Networks) to prevent the negativities of insufficient or unbalanced data in machine learning methods. The multiplied data were subjected to pre-processing such as Discrete Wavelet Transform (DWT), feature extraction in time and frequency domains. In the second stage, the pre-processed EEG data were classified with machine learning algorithms such as kNN (k-Nearest Neighbor), SVM (Support Vector Machines), ANN (Feed Forward Artificial Neural Networks) and RNN (Recurrent Neural Networks). The results showed that the brain responses to smoking stimuli were especially pronounced in the temporal and prefrontal lobe regions and higher classification success was achieved in the theta frequency band. The classification success rates made with feed forward ANN reached 99%. This study emphasizes the potential of using EEG-based machine learning methods in determining neurophysiological markers for smoking addiction.

2024, ix + 113 Pages

Keywords: Smoking Addiction, EEG, Machine Learning, ANN, RNN, GAN

İÇİNDEKİLER

Sayfa

TEZ ONAY SAYFASI.....	ii
TEZ BEYANI.....	iii
ÖN SÖZ.....	iv
ÖZET	v
ABSTRACT	vi
İÇİNDEKİLER.....	vii
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ.....	xi
KISALTMALAR LİSTESİ	xiii
1. GİRİŞ.....	2
1.1. Literatür Özeti.....	4
1.2. Araştırmanın Önemi	10
2. MATERYAL	12
2.1. EEG Nedir? Tarihçesi, Kullanım Alanları.....	13
2.2. Fagerström Nikotin Bağımlılığı Testi (FNTD).....	15
2.3. Ayırık Dalgacık Dönüşümü (DWT)	16
2.3.1. Ayırık Dalgacık Dönüşümü Analizi.....	16
2.3.2. Ayırık Dalgacık Dönüşümü Sentezi.....	17
2.4. Güç Spektral Yoğunluğu (PSD)	18
2.4.1. Düz Zaman Penceresi Yöntemi.....	19
2.4.2. Parçalı Zaman Penceresi Yöntemi	19
2.4.3. Peditogram Yöntemi	20
2.4.4. Welch Yöntemi	20
2.4.5. Burg Spektral Analizi.....	21

2.5. Özellik Çıkarımı Yöntemleri	21
2.6. Temel Bileşen Analizi (PCA)	25
2.7. Performans Metrikleri	26
2.7.1. Doğruluk (Accuracy)	27
2.7.2. Özgüllük (Specificity)	27
2.7.3. Duyarlılık (Recall)	28
2.7.4. Hassasiyet (Precision)	28
2.7.5. F-Skor (F-Score)	28
2.8. k-En Yakın Komşuluk (kNN)	29
2.9. Destek Vektör Makineleri (SVM)	31
2.10. Yapay Sinir Ağları (YSA)	33
2.10.1. Yapay Sinir Ağlarının Biyolojik Temelleri	34
2.10.2. Tek Katmanlı Sinir Ağları	36
2.10.3. Çok Katmanlı Sinir Ağları	38
2.10.4. Denetimli Öğrenme	41
2.10.5. Denetimsiz Öğrenme	42
2.10.6. YSA’da Öğrenme İşlemi	43
2.10.7. YSA’da Optimizasyon ve Regularizasyon	46
2.11. Tekrarlayan Sinir Ağları (RNN)	55
2.11.1. Uzun-Kısa Süreli Bellek (LSTM)	56
2.11.2. Kapı Kontrollü Tekrarlayan Birim (GRU)	58
2.12. Çekişmeli Üretici Ağlar (GAN)	60
2.12.1. GAN Eğitimi	60
3. YÖNTEM	63
3.1. EEG Veri Alım İşlemleri	63
3.1.1. Fagerström Nikotin Bağımlılığı Anketi (FTND)	64

3.1.2. Veri Alım Öncesi	65
3.1.3. Veri Alımı	65
3.1.4. Katılımcı Seçimi.....	66
3.1.5. EEG Cihazı.....	67
3.1.6. Veri Alım Süreci	69
3.1.7. EEG Verisi Özellikleri	70
3.2. Veri İşleme ve Özellik Çıkarımı	71
3.2.1. Ayrık Dalgacık Dönüşümünün (DWT) Uygulanması	71
3.2.2. Güç Spektral Yoğunluğu (PSD) Analizi	72
3.2.3. Özellik Çıkarımı İşlemleri.....	74
3.3. Makine Öğrenmesi Modellerinin Uygulanması	76
3.3.1. KNN ve SVM.....	76
3.3.2. YSA Modelinin Uygulanması.....	77
3.3.3. Tekrarlayan Sinir Ağları (RNN)	79
3.4. GAN ile Veri Çoğaltma	81
4. BULGULAR	83
4.1. kNN Sınıflandırma Bulguları.....	83
4.2. SVM Sınıflandırma Bulguları.....	86
4.3. YSA Sınıflandırma Bulguları	89
4.4. LSTM Sınıflandırma Bulguları.....	92
4.5. GRU Sınıflandırma Bulguları	95
5. SONUÇ VE DEĞERLENDİRME	99
6. KAYNAKLAR.....	101
EKLER	113

TABLÖLAR LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 3.1. FTND.....	64
Tablo 3.2. Katılımcı özellikleri.....	66
Tablo 4.1. KNN PSD analizi teta frekans bandı sonuçları	83
Tablo 4.2. kNN özellik çıkarımı teta frekans bandı sonuçları	84
Tablo 4.3. kNN PSD analizi alfa frekans bandı sonuçları	85
Tablo 4.4. kNN özellik çıkarımı alfa frekans bandı sonuçları.....	85
Tablo 4.5. kNN sonuçları.....	86
Tablo 4.6. SVM PSD analizi teta frekans bandı sonuçları	86
Tablo 4.7. SVM özellik çıkarımı teta frekans bandı sonuçları	87
Tablo 4.8. SVM PSD analizi alfa frekans bandı sonuçları	88
Tablo 4.9. SVM özellik çıkarımı alfa frekans bandı sonuçları	88
Tablo 4.10. SVM sonuçları.....	89
Tablo 4.11. YSA PSD analizi teta frekans bandı sonuçları	89
Tablo 4.12. YSA özellik çıkarımı teta frekans bandı sonuçları.....	90
Tablo 4.13. YSA PSD analizi alfa frekans bandı sonuçları.....	90
Tablo 4.14. YSA özellik çıkarımı alfa frekans bandı sonuçları.....	91
Tablo 4.15. YSA sonuçları.....	92
Tablo 4.16. LSTM PSD analizi teta frekans bandı sonuçları	92
Tablo 4.17. LSTM özellik çıkarımı teta frekans bandı sonuçları	93
Tablo 4.18. LSTM PSD analizi alfa frekans bandı sonuçları	93
Tablo 4.19. LSTM özellik çıkarımı alfa frekans bandı sonuçları.....	94
Tablo 4.20. LSTM sonuçları.....	94
Tablo 4.21. GRU PSD analizi teta frekans bandı sonuçları.....	95
Tablo 4.22. GRU özellik çıkarımı teta frekans bandı sonuçları	95
Tablo 4.23. GRU PSD analizi alfa frekans bandı sonuçları	96
Tablo 4.24. GRU özellik çıkarımı alfa frekans bandı sonuçları	97
Tablo 4.25. GRU sonuçları	97

ŞEKİLLER LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 2.1. İnsan beyni anatomisi.....	13
Şekil 2.2. 10/20 ölçüm sistemi	15
Şekil 2.3. EEG dalgası frekans bileşenleri	18
Şekil 2.4. Karışıklık matrisi.....	27
Şekil 2.5. kNN k değeri belirleme	30
Şekil 2.6. kNN aşırı ve yetersiz uyum durumu	30
Şekil 2.7. kNN öncesi ve sonrası.....	31
Şekil 2.8. SVM'in 2 boyutlu gösterimi	32
Şekil 2.9. SVM'in 3 boyutlu gösterimi	32
Şekil 2.10. Biyolojik sinir hücresi	34
Şekil 2.11. Yapay sinir hücresinin matematiksel modellemesi.....	35
Şekil 2.12. YSA modeli.....	35
Şekil 2.13. Tek katmanlı sinir ağı ile sınıf ayrımı	36
Şekil 2.14. VE kapısının sinir ağı ile modellenmesi	37
Şekil 2.15. VEYA kapısının sinir ağı ile modellenmesi	38
Şekil 2.16. Derin yapay sinir ağı modeli	39
Şekil 2.17. ÖZEL VEYA kapısının sinir ağı ile modellenmesi	39
Şekil 2.18. Sinir Ağı İşlemleri.....	40
Şekil 2.19. Denetimli öğrenme işlem akışı.....	41
Şekil 2.20. Denetimsiz öğrenme işlem akışı	42
Şekil 2.21. Maliyet fonksiyonunda ağırlıkların güncellenmesi.....	44
Şekil 2.22. Öğrenme oranı (adımı)	45
Şekil 2.23. YSA model eğitim ve test işlemleri	46
Şekil 2.24. Sigmoid fonksiyonu	47
Şekil 2.25. Hiperbolik tanjant fonksiyonu	48
Şekil 2.26. ReLU fonksiyonu	48
Şekil 2.27. Leaky ReLU fonksiyonu	49
Şekil 2.28. Swish fonksiyonu	49
Şekil 2.29. Düşüm seyreltme (Dropout)	50
Şekil 2.30. Optimizasyon algoritmalarının 3 boyutlu gösterimi	54
Şekil 2.31. Aşırı-az uyum ve optimum performans	55
Şekil 2.32. RNN hücre modeli	56

Şekil 2.33. LSTM hücre modeli	58
Şekil 2.34. GRU hücre modeli	59
Şekil 2.35. GAN yapısı	61
Şekil 3.1. Çalışma ana akış diyagramı	63
Şekil 3.2. 10/20 ölçüm sistemi	68
Şekil 3.3. EEG kayıt sistemi.....	68
Şekil 3.4. Veri alımı için direnç değerlerinin düşürülmesi.....	69
Şekil 3.5. Görsel uyaran sunumu	70
Şekil 3.6. EEG veri alım süreci	70
Şekil 3.7. DWT işlemi elde edilen EEG verisi frekans alt bileşenleri	72
Şekil 3.8. Sigara bağımlısı bireyin EEG sinyal değişimi ve PSD analizi	73
Şekil 3.9. Sigara bağımlısı olmayan bireyin EEG sinyal değişimi ve PSD analizi.....	74
Şekil 3.10. PSD analizi sonucu oluşan EEG matrisi	74
Şekil 3.11. Özellik çıkarımı işlemi sonucu oluşan EEG matrisi	76
Şekil 3.12. kNN ve SVM modellerinin uygulanması.....	77
Şekil 3.13. YSA modelinin uygulanması	78
Şekil 3.14. YSA model katmanları.....	79
Şekil 3.15. LSTM ve GRU ağ mimarileri	80
Şekil 3.16. RNN mimarilerinin uygulanması.....	80
Şekil 3.17. GAN ile EEG veri çoğaltma işlemi.....	82

KISALTMALAR LİSTESİ

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

Simgeler	Açıklamalar
----------	-------------

dB	: Desibel
m	: Metre
μ V	: mikrovolt
Hz	: Hertz
kHz	: Kilo Hertz

Kısaltmalar	Açıklamalar
-------------	-------------

ADAM	: (Adaptive Moment Estimation) Uyarlanabilir Moment Tahmini
AR	: Otoregresif
DWT	: (Discrete Wavelet Transform) Ayırık Dalgacık Dönüşümü
EEG	: Elektroensefalografi
FFT	: (Fast Fourier Transform) Hızlı Fourier Dönüşümü
FN	: (False Negative) Yanlış Negatif
FP	: (False Positive) Yanlış Pozitif
FTND	: (Fagerström Test for Nicotine Dependence) Fagerström Nikotin Bağımlılığı Testi
GAN	: (Generative Adversarial Network) Çekişmeli Üretici Ağlar
GD	: (Gradient Descent) Gradyan İniş
GRU	: (Gated Recurrent Unit) Kapı Kontrollü Tekrarlayan Birim
ICA	: (Independent Component Analysis) Bağımsız Bileşenler Analizi
kNN	: (k-Nearest Neighbors) k-En Yakın Komşuluk
LSTM	: (Long Short-Term Memory) Uzun-Kısa Süreli Bellek
PCA	: (Principal Component Analysis) Temel Bileşenler Analizi

PSD	: (Power Spectral Density) Spektral Güç Yoğunluğu
ReLU	: Rectified Linear Unit
RFC	: (Random Forest Classifier) Rastgele Orman Sınıflandırıcısı
RNN	: (Recurrent Neural Network) Tekrarlayan Sinir Ağları
SGDM	: (Stochastic Gradient Descent with Momentum) Momentum-Stokastik Gradyan İniş
STFT	: (Short-Time Fourier Transform) Kısa Zamanlı Fourier Dönüşümü
SVD	: (Singular Value Decomposition) Tekil Değer Ayrıştırması
SVM	: (Support Vector Machine) Destek Vektör Makineleri
TN	: (True Negative) Doğru Negatif
TP	: (True Positive) Doğru Pozitif
VR	: (Validation Rate) Sanal Gerçeklik
WT	: (Wavelet Transform) Dalgacık Dönüşümü
YSA	: Yapay Sinir Ağları

1. GİRİŞ

İnsan beyni, dört ana loba sahip karmaşık bir yapıya ve işlevselliğe sahip bir organdır. Beyin, nöron adı verilen milyarlarca sinir hücresinden oluşmaktadır. Her bir nöron birbiriyle iletişim kurarak vücudun çeşitli işlevlerini kontrol etmektedir. Bu sinir hücreleri, hücre gövdesi, dendrit ve akson adı verilen yapıları içermektedir. Hücre gövdesi, nöronun metabolizmasının gerçekleştiği bölümdür. Dendritler, nöronun diğer nöronlardan gelen bilgileri almasını sağlar. Akson ise bilgiyi (elektriksel sinyali) diğer nöronlara veya hücrelere iletir. Nöronlar arasındaki iletişim sinaps adı verilen bağlantı noktaları aracılığıyla gerçekleşmektedir. Beyindeki bu iletişim ağındaki elektriksel etkileşimler, Elektroensefalografi (EEG) gibi tekniklerle ölçülebilmektedir (Bear vd., 2020).

EEG, beyin aktivitesini non-invaziv bir şekilde ölçmek için kullanılan temel bir yöntemdir. Bu teknik, ilk olarak Alman fizikçi Hans Berger tarafından geliştirilmiştir. 1924'te Berger, insan beynindeki elektriksel aktiviteyi kaydetmek için ilk EEG'yi kaydetmiştir. Bu, insan beyninin elektriksel aktivitesini doğrudan ölçen ilk kayıt olarak kabul edilmektedir. EEG'nin klinik kullanımı 1930'larda hızla yayıldı ve epilepsi gibi beyin hastalıklarının teşhisinde önemli bir araç haline gelmiştir. EEG'nin bilimsel ve klinik uygulamaları 1940'larda genişledi ve beyin fonksiyonları hakkında daha fazla bilgi sağlamak için kullanılan bir araç haline gelmiştir. EEG'nin uyku ve uyanıklık arasındaki farklar gibi çeşitli yönlerinin incelenmesi 1960'larda yaygınlaşmıştır. Bilgisayarların kullanılmasıyla birlikte, EEG verilerinin analizi ve görselleştirilmesi 1970'lerde daha kolaylaşmıştır (Da Silva, 2022; Niedermeyer, 2011). EEG, beyin üzerindeki (kafatasına yerleştirilen) elektrotlar aracılığıyla beyin dalgalarının elektriksel aktivitesini kaydederek çalışmaktadır. Bu dalgalar, beyin hücrelerinin elektriksel aktivitesinin bir yansımasıdır ve farklı durumlarda farklı desenlerde ortaya çıkmaktadır (Blinowska & Durka, 2006). EEG'nin keşfi, beyin fonksiyonlarını anlamak ve araştırmak için önemli bir dönüm noktası olmuştur. Günümüzde, nörobilim araştırmacıları ve klinik uzmanlar EEG'yi beyin aktivitesini incelemenin ve beyin sağlığı ile ilgili bilgi edinmenin ana araçlarından biri olarak kullanmaktadır. Teknolojinin ilerlemesiyle birlikte, EEG cihazları daha taşınabilir, daha hassas ve daha kullanıcı dostu hale gelmiştir. Bu da EEG'nin klinik uygulamalarda ve araştırmalarda daha yaygın olarak kullanılmasını sağlamıştır. EEG'nin sürekli olarak geliştirilmesi, beyin aktivitesini daha ayrıntılı ve hassas bir şekilde analiz etmemizi sağlar ve bu da nörobilim alanında önemli keşiflere ve anlayışlara yol açar. EEG verisinin

analizinde çeşitli sinyal işleme ve makine öğrenmesi teknikleri kullanılmaktadır (Laufs, 2012).

Sinyal işleme ve makine öğrenmesi, bilgisayar bilimleri ve mühendislik alanlarında temel öneme sahip disiplinlerdir. Sinyal işleme, ses, görüntü, video ve biyomedikal veriler gibi çeşitli sinyallerin analizi, işlenmesi ve yorumlanmasıyla ilgilenir. Bu disiplin, 1940'ların sonlarında elektrik mühendisliği alanında ortaya çıkmıştır ve analog sinyal işleme tekniklerinin gelişimiyle başlamıştır. Dijital sinyal işleme tekniklerinin yükselişi, 1960'ların sonlarına doğru ve 1970'lerin başlarında gerçekleşmiş ve sayısal olarak sinyallerin işlenmesinde büyük bir gelişme sağlamıştır (Oppenheim, 1999). Makine öğrenmesi, bilgisayar sistemlerine veri analizi ve kendi kendine öğrenme yeteneği kazandıran algoritmaların geliştirildiği bir alandır (Taylor & Cristianini, 2004). Bu disiplin 1950'lerde başladı ve Arthur Samuel tarafından, bilgisayar programlarının oyun oynamayı öğrenmesiyle bu alandaki çalışmalar tanımlanmıştır (Samuel, 1959). Ancak, önemli ilerleme, 2000'lerin başlarında büyük miktarda veri ve gelişmiş hesaplama gücünün kullanılmasıyla sağlanmıştır (Mitchell, 1997).

Derin öğrenme ise karmaşık yapay sinir ağlarının kullanıldığı makine öğrenmesinin bir alt dalıdır. Bu yöntemler, çok katmanlı sinir ağlarının kullanımıyla bilgiyi işleme ve öğrenme yeteneğini artırır. Derin öğrenme, 1980'lerin sonlarından itibaren geliştirilmeye başlanmış olsa da, hesaplama gücü ve veri miktarı yetersiz olduğundan ilerleme sınırlı kalmıştır. Ancak, 2000'lerin başlarında büyük miktarda veri ve gelişmiş hesaplama gücüne erişim, derin öğrenmenin yol almasını sağlamıştır. Günümüzde, klasik makine öğrenme yöntemleri ve derin öğrenme; görüntü tanıma, doğal dil işleme, tıbbi işlemler ve sinyal analizi gibi birçok alanda yaygın olarak kullanılmaktadır (Lecun vd., 2015).

Bu teknolojik ilerlemeler, biyomedikal araştırmalarda da geniş uygulama alanları bulmuştur. EEG verilerinin analizinde kullanılan modern makine öğrenme yöntemleri, sinyal işleme ve sınıflandırma süreçlerinde önemli başarılar elde edilmesine olanak tanımaktadır. Hem klasik makine öğrenim hem de derin öğrenme algoritmaları, sinyal verilerindeki karmaşık örüntüleri tanımlayarak daha doğru ve güvenilir sonuçlar üretebilmektedir. Bu çalışmada, araştırma sürecinde ilk adım olarak, 30 bireyden EEG verileri toplanmış ve bu verilerin elde edilmesinde görsel uyaranlar kullanılmıştır. EEG verileri alınmadan önce, bireylerden nikotin bağımlılık düzeylerini değerlendirmek amacıyla FTND (Fagerström Nikotin Bağımlılığı Testi) uygulanmış ve FTND sonuçları

daha sonra EEG verileri ile ilişkilendirilmiştir. FTND, nikotin bağımlılık düzeylerini belirlemekte en yaygın olarak kullanılan altı sorudan oluşan bir testtir. Bu test, ilk kez 1978'de Karl-Olov Fagerström tarafından önerilmiş, daha sonra 1991'de Heatherton ve diğerleri tarafından revize edilmiş ve FTND olarak adlandırılmıştır (Heatherton vd., 1991b; Lashgari vd., 2020; Conway, 2020; O'Byrne & Jerbi, 2022).

Daha sonra, FTND ile ilişkilendirilen EEG verileri, farklı sinyal işleme tekniklerinden geçirilerek alt dalgalara (delta, teta, alfa, beta, gama) ayrılmıştır. Ardından, bu işlenmiş veriler makine öğrenmesi yöntemleri ile sınıflandırma işlemlerine tabi tutulmuş ve elde edilen sonuçlar karşılaştırılmıştır. Sınıflandırma sonuçları incelendiğinde, yüksek başarı oranları elde edilmiş ve beyin belirli loblarında ve kanallarında görsel uyaranlara karşı daha belirgin tepkilerin olduğu tespit edilmiştir. Bu çalışmanın özgünlüğü, belirli bir beyin aktivitesinin nikotin bağımlılığı düzeyleri ile ilişkilendirilmesinde ve bu ilişkinin EEG verileri kullanılarak doğrulanmasında yatmaktadır. Görsel uyaranlar kullanılarak toplanan EEG verileri, sigara bağımlılığının beyin bölgeleri üzerindeki olası etkilerinin analiz edilerek tespit edilmesi amacıyla kullanılacaktır. Bu çalışmanın temel hipotezi, sigara bağımlılığının beyin bölgelerinde belirgin nörofizyolojik değişikliklere yol açabileceğidir. Elde edilen EEG verileri, sigara kullanımının beyin fonksiyonları üzerindeki etkilerini anlamak ve bu etkileri bilimsel olarak ortaya koymak amacıyla analiz edilecektir.

1.1. Literatür Özeti

EEG veri analizi üzerine literatürde birçok çalışma bulunmaktadır. Sigara bağımlılığı ve makine öğrenimi temelli bir literatür taraması yapıldığında aşağıdaki çalışmalar listelenmiştir:

Setiawan (2018) yaptığı çalışmada, Endonezya'da sigara içenler üzerine bir araştırma gerçekleştirmiştir. Ülkede sigara içenlerin oranının %46.16 olduğu belirlenmiştir. Çalışmasında, EEG kullanarak sigara içenlerin beyin aktivitesini incelemiştir. Sonuçlar, orbitofrontal korteksteki aktivitenin sigara isteği ile ilişkili olduğunu, prefrontal korteksteki aktivitenin ise sigara içme anında arttığını göstermektedir. Çalışma, bağımlılık seviyelerini belirlemiş ve %52'sinin yüksek bağımlılık kategorisinde olduğunu ortaya koymuştur (Setiawan, 2018).

Hanafiah vd. (2010) çalışmalarının temel odak noktasının teta ve delta frekans bantlarındaki sigara içenlerin EEG desenlerini gözlemlemek olduğunu belirtmektedir. Bu çalışmada 8 erkek sigara içicisi ve 8 sigara içmeyen kişi örneklenmiştir. EEG verileri 3

dakika boyunca kaydedilmiştir. Sonuçlar, sigara içenlerin EEG desenlerinde sigara içmeyenlere göre alfa ve beta Frekans bantlarında bazı farklılıklar olduğunu göstermektedir (Hanafiah, Hj Murat, vd., 2010).

Hasan vd. (2019) çalışmalarında sigaranın EEG verisindeki değişiklikleri incelemişlerdir. Sigara içenler ile içmeyenleri ayırt etmek için bir metodoloji önermişler ve üç YSA algoritması oluşturmuşlardır. Hem zaman hem de frekans domaini özelliklerini kullanan sinir ağı, 6.238×10^{-8} MSE ile en iyi kaliteyi sağlamıştır. Frekans domainine dayalı YSA ise zaman domainine dayalı olanlardan daha iyi performans göstermiştir. Çalışma, PSD ve FFT değerlerinin sigara içenlerin EEG verilerinde içmeyenlere göre daha yüksek olduğunu ortaya koymuştur (M. Hasan vd., 2019).

Abdul Hamid vd. (2011) çalışmalarında, sigara içenler arasında farklı nikotin bağımlılığı seviyelerindeki EEG desenlerini incelemiştir. Araştırmaya 33 erkek sigara içen birey katılmıştır. Sonuçlar orta düzeyde bağımlılığa sahip sigara içicilerinin düşük düzeyde bağımlılığa sahip olanlara göre daha yüksek teta, alfa ve beta band güçlerine sahip olduğunu ortaya koymaktadır (Hanafiah vd., 2011).

Su vd. (2017) çalışmalarında, sigara bağımlılığı olan ergenlerde dinlenme durumundaki EEG sinyallerinin değişimlerini incelemeyi amaçlamışlardır. Çalışmada 21 sigara bağımlılığı olan ergen bireyin EEG sinyalleri, sigara içmeyen kontrol grubuyla karşılaştırılmıştır. Bulgular sigara bağımlılığı olan ergenlerde alfa bandında artış ve delta bandında azalma olduğunu göstermektedir. Frekans alt bantlarındaki değişimler, sigara bağımlılığı süresi ile ilişkili olduğunu kanıtlamıştır. Sonuç olarak sigara içme alışkanlığının kümülatif etkileriyle ilişkili olan dinlenme durumundaki EEG sinyallerindeki değişiklikler belirlenmiştir (Su vd., 2017).

Chin vd. (2019) çalışmalarında, nikotin kullanımı sırasında EEG sinyalinin değişimlerini incelemeyi amaçlamışlardır. Çalışmada, 20 erkek katılımcı (10 sigara içen, 10 sigara içmeyen) seçilmiş ve EEG sinyali gürültülerden arındırılarak alfa, teta, delta ve beta frekanslarına ayrılmıştır. SVM kullanılarak elde edilen sonuçlara göre sigara içenlerde beş kanalda aktivite ve dikkat süresinde artış görülmüştür. Sonuçlar istatistiksel analiz (t-testi) kullanılarak hesaplanmıştır. p-değeri 0.05'ten düşük olan 0.037 olduğundan, null hipotez reddedilmiş ve sigara içenler ile sigara içmeyenler arasında sigara içme aktivitesi öncesinde ve sonrasında önemli farklılıklar olduğu sonucuna varılmıştır (Chin vd., 2019).

Wirapatrungrat vd. (2017) çalışmalarında, 20-50 yaşları arasındaki 20 sağlıklı erkek bireyden EEG verisi toplamışlardır. EEG verisi alınırken sigara uyarını olarak nikotin bandı kullanılmıştır. Katılımcılar nikotin bandı kullanmadan önce iki saat boyunca sigara içmemiştir. Beyin dalgaları, katılımcılara nikotin bandı uygulanmadan önce ve 30 dakika sonra ölçülmüştür. Sonuçlar nikotin bandı uygulandıktan sonra tüm beyin dalgalarının azaldığını özellikle beta beyin dalgasının istatistiksel olarak anlamlı bir düşüş gösterdiğini ($p=0.001$) ortaya koymuştur. Bu çalışma nikotin bandının sigara içme isteğini azaltmada etkili olduğunu ve beyin dalgalarını değiştirdiğini göstermektedir (Wirapatrungrat & Sittiprapaporn, 2017).

Hasan vd. (2021) çalışmalarında, tütün içimi gibi bağımlılıkların beyin dalgalarında önemli değişikliklere neden olduğunu belirtmişlerdir. Çalışmada, EEG desenindeki değişikliklerin incelenerek tütün bağımlılığının teşhis edilmesi amaçlanmıştır. Dört farklı sınıflandırıcı modeli, zaman-frekans alanı özelliklerinin birleşimi kullanılarak eğitilmiş ve test edilmiştir. Sonuçlar, zaman-frekans alanı özelliklerine dayalı sınıflandırıcıların en iyi performansı gösterdiğini ve birlikte kullanıldığında daha iyi sonuçlar elde edildiğini göstermektedir. RFC (Rastgele Orman Sınıflandırıcısı) sigara içenleri %91.30 doğrulukla tanımlamada en başarılı model olarak belirlenmiştir (M. M. Hasan vd., 2021).

Taib vd. (2010) çalışmalarında, sigara içenlerin EEG desenlerini teta, alfa ve beta band güçlerine dayanarak incelemişlerdir. Çalışmanın amacı, sigara içenlerin EEG desenlerini araştırmak ve hipotez olarak onların sigara içmeyenlere göre daha yüksek alfa bant gücüne sahip olacağını varsaymıştır. 33 erkek sigara içen ve 33 sigara içmeyen katılımcı üzerinde gerçekleştirilen çalışma sonuçlarına göre, sigara içenlerin sigara içmeyenlere göre daha yüksek teta ve alfa bant güçlerine sahip olduğu bulunmuştur (Hanafiah, Taib, vd., 2010).

Suteeca vd. (2017) çalışmalarında, 20-50 yaşları arasındaki 15 sağlıklı erkek gönüllünün EEG sinyallerini NeuroSky Mindwave Mobil EEG cihazı kullanılarak incelemişlerdir. Katılımcılar testten önce iki saat boyunca sigara içmemiştir. Sigara içmeden önce ve sonra beyin dalgaları ölçülmüştür. Bulgular sigara içtikten sonra delta ve teta beyin dalgalarının azaldığını alfa, beta ve gamma beyin dalgalarının ise arttığını göstermiştir. Özellikle gamma beyin dalgasında belirgin bir artış gözlemlenmiştir. Bu çalışma ticari olarak temin edilebilen basit EEG cihazlarının sigara içen bireylerin beyin dalgalarını incelemede etkili olduğunu ortaya koymaktadır (Suteeca, 2017).

Sheykhivand vd. (2022) sigara bağımlılığı ile ilgili çalışmaları EEG verileri üzerinde yapmışlardır. EEG verilerinin zaman-frekans özellikleri insan beyin aktivitelerini anlamak için yaygın olarak kullanılmaktadır. Bu çalışmaların çoğu EEG verilerinin frekans özelliklerine odaklanırken zaman-frekans özelliklerine daha az odaklanmıştır. Bu çalışmada, EEG verilerinin zaman-frekans özelliklerinin çıkarılmasından sonra makine öğrenmesi modelleri ile sınıflandırma işlemleri yapılmış yeni bir yaklaşım geliştirilmiştir (Sheykhivand vd., 2022).

Lee vd. (2023) çalışmalarında, uzun süreli sigara içmenin beyin üzerindeki etkilerini incelemişlerdir. 20 yıldan fazla süredir sigara içenler, 20 yıldan fazla süredir sigarayı bırakmış olanlar ve hiç sigara içmeyenler üzerinde dinlenme halindeki EEG verilerini karşılaştırmışlardır. Sigara içenler ve bırakmış olanlar, hiç sigara içmeyenlere kıyasla önemli ölçüde azalmış bağıl teta gücü göstermiştir. Bu çalışma sigara içmenin beyinde kalıcı etkileri olduğunu göstermektedir. Ayrıca alfa frekans bandındaki diğer EEG özellikleri aktif sigara içmeyle ilişkilendirilmiştir. Sigara içenlerde, daha yüksek bağıl güç, EEG reaktivitesi ve kanallar arasında frekans ilişkisinin olduğu gözlemlenmiştir. Bu bulgular sigara içmenin beyin üzerindeki etkilerinin 20 yıl boyunca süren aralığa rağmen kalıcı olduğunu ortaya koymaktadır (Lee vd., 2023).

Tamburin vd. (2021) çalışmalarında, sanal gerçeklik ortamında sigara ile ilişkili dürtülere verilen tepkileri incelemişlerdir. Sigara içenler (20 kişi) ve içmeyenler (20 kişi) sigara ile ilişkili sanal gerçeklik (VR) senaryolarına maruz bırakılmıştır. EEG kayıtları ile sigara içme isteği ve alfa bandı desenkronizasyonu değerlendirilmiştir. Sigara içenlerde sigara ile ilişkili VR senaryosu nötr senaryoya kıyasla önemli ölçüde artmış, sigara içme isteğinde ve EEG alfa bandı gücünde artışa yol açmıştır. Bu bulgular EEG desenkronizasyonunun sigara içme isteği ile ilişkili nörofizyolojik bir belirteç olabileceğini göstermektedir (Tamburin vd., 2021).

Cheng vd. çalışmalarında, nikotin bağımlılığında sigara maruziyetinin ciddiyeti ile dinlenme halindeki EEG mikro durumlarının işlevselliğini araştırmışlardır. Sigara içen (20 kişi) ve içmeyen (21 kişi) katılımcılar üzerinde EEG mikro durum analizi yapmışlardır. Sigara içenlerde mikro durum sınıfı B'nin süresi, sıklığı ve kapsama oranı kontrol grubuna göre önemli ölçüde düşük bulunmuştur. Ayrıca mikro durum B süresi, tütün tüketiminin ciddiyeti ile negatif korelasyon göstermiştir. Bu sonuçlar EEG mikro durumlarının sigara

içme ile ilişkili bilişsel süreçler hakkında önemli bilgiler sunduğunu ortaya koymaktadır (Cheng vd., 2020).

Bu vd. (2019) nikotin bağımlılığına karşı yeni bir kapalı devre sigara uyarılarına dayalı EEG nöro geri besleme protokolünü geliştirip değerlendirmişlerdir. Çalışmada, 60 nikotin bağımlısı katılımcı rastgele seçilerek çift-kör, kontrol gruplu bir klinik deneye dahil edilmiştir. Çift-kör yöntemiyle, hem katılımcılar hem de araştırmacılar hangi grupta olduklarını bilmeden tedavi edilmiştir. Bu yöntem, tedavinin etkinliğini doğru bir şekilde değerlendirmek için kullanılmıştır. Katılımcılar kendi beyin aktivitelerinden ($n = 30$, gerçek geri bildirim grubu) veya eşleştirilmiş bir katılımcının beyin aktivite desenlerinden ($n = 30$, eşleştirilmiş geri besleme grubu) iki nöro geri besleme eğitimi almışlardır. Gerçek geri besleme grubundaki katılımcılar sigara uyarılarına reaktivite gösteren EEG aktivite desenlerini başarılı bir şekilde devre dışı bırakmışlardır. Gerçek geri besleme grubu sigara içme isteğinde ve isteğe bağlı P300 genliklerinde önemli bir azalma göstermiştir. 1 hafta, 1 ay ve 4 aylık takiplerde günlük içilen sigara sayısı gerçek geri besleme grubunda sırasıyla %30.6, %38.2 ve %27.4 azalırken eşleştirilmiş geri besleme grubunda %14.0, %13.7 ve %5.9 azalmıştır. Bu yeni nöro geri besleme eğitimi, sigara içme isteği ve davranışı üzerinde hem kısa hem de uzun vadeli etkiler göstermiştir. Bu durum bağımlılığı tedavi etmek için umut verici bir beyin tabanlı araç olduğunu ortaya koymaktadır (Bu vd., 2019).

Literatür incelendiğinde önceki çalışmaların birçoğunun ham EEG verilerini özellik çıkarma yöntemleri veya klasik makine öğrenimi algoritmaları kullanarak sınıflandırma ve analiz süreçlerini gerçekleştirdiği görülmektedir. Öncelikle, tez çalışmasında DWT kullanılarak EEG verilerinin frekans alt bileşenlerine ayrılması literatürde yaygın olarak kullanılan yöntemlerden biridir. Ancak tez çalışması bu yöntemi frekans bileşenlerinin daha detaylı analizi ve PSD analizi ile birleştirerek daha kapsamlı bir inceleme yapmaktadır. Özellikle EEG verilerinin zaman-frekans temsilleri çıkarılması ve bu temsillerin makine öğrenmesi modelleriyle ilişkilendirilmesi literatürde genellikle daha az rastlanan bir yaklaşımdır.

Literatürdeki birçok çalışma, sınıflandırma ve analiz süreçlerinde klasik makine öğrenimi algoritmaları kullanmışken, bu tez çalışmasında SVM, kNN, GAN, YSA, LSTM ve GRU gibi çeşitli makine öğrenmesi modelleri kullanılarak özneliliklerin daha kapsamlı değerlendirilmesi sağlanmıştır. Bu durum çalışmanın daha ileri düzeyde veri işleme

teknikleri ve kapsamlı makine öğrenmesi yaklaşımları kullanarak literatürdeki önceki çalışmalardan ayrıldığını göstermektedir.

Tez çalışması ayrıca, sigara içme alışkanlığının EEG sinyalleri üzerindeki etkilerini inceleyen literatürle uyumlu bir şekilde, frekans alt bileşenlerinin bağımlılık testi sonuçlarıyla ilişkilendirilmesini amaçlamaktadır. Bu ilişki, bağımlılık düzeylerinin EEG sinyalleri üzerinden tahmin edilebilirliğini araştırmak için önemli bir adımdır ve literatürdeki genel bulguları desteklemektedir. Elde edilen sonuçların, literatürdeki önceki çalışmalara kıyasla daha yüksek doğruluk ve güvenilirlik sağladığı gözlemlenmiştir.

Bu tez çalışmasında, ham EEG verilerinin frekans alt bileşenleri (delta, alfa, teta, beta ve gama dalgaları), DWT gibi yöntemler kullanılarak elde edilmiştir. EEG frekans alt bileşenleri açıklayacak olursak band aralıkları ve görülme durumları şu şekildedir; delta dalgası 0,5-4 Hz frekans aralığında, genellikle derin uyku sırasında ve beyin yaralanmalarında gözlemlenir. Teta dalgası 4-8 Hz frekans aralığında, hafif uyku, rüya görme ve hafif hipnoz durumlarında görülmektedir. Alfa dalgası 8-12 Hz frekans aralığında, zihinsel ve fiziksel rahatlama sırasında görülmektedir. Beta dalgası 12-32 Hz frekans aralığında, aktif düşünme, problem çözme, kaygı, uyanıklık ve aktif zihinsel durumlarda gözlemlenir. Gama dalgası 32-100 Hz frekans aralığında, yüksek seviye bilişsel fonksiyonlar, öğrenme, bellek ve bilgi işleme sırasında aktif hale gelir. DWT işlemi sonucu frekans alt bileşenlerine ayrılan EEG verileri, PSD analizi ve özellik çıkarma yöntemleri kullanılarak işlenmiştir. PSD ve özellik çıkarımı ile elde edilen sonuçlar ayrı ayrı FTND sonuçlarıyla ilişkilendirilerek etkili sınıflandırma yapmak için tasarlanmış makine öğrenmesi modellerine sunulmuştur. Bu metodoloji, literatür ile kıyaslandığında farklı yaklaşımlar sunmaktadır. Ayrıca elde edilen başarı oranları metodolojinin doğruluğunu ispatlamıştır.

Tez çalışması EEG verilerinin detaylı analizi için gelişmiş yöntemlerin kullanımını önermektedir. Geleneksel yaklaşımların aksine zaman-frekans temsilleri üzerinde odaklanarak daha derinlemesine bir inceleme yapılmıştır.

DWT zaman-frekans analizinde sıklıkla kullanılan bir yöntemdir. Bu yöntem, sinyalin farklı frekans bileşenlerini zamana göre nasıl dağıldığını gösteren ayrıntılı bir spektral analiz sağlamaktadır. Özellikle, delta, alfa, teta, beta ve gama gibi belirli frekans bantları üzerinde yapılan analizler beyin aktivitesinin farklı yönlerini ve bunların nasıl değiştiğini anlamak için kritik öneme sahiptir.

DWT ile elde edilen frekans alt bileşenleri, PSD analizi ve özellik çıkarma adımlarıyla işlenmiştir. PSD analizi sinyalin hangi frekans bölgelerinde yoğunlaştığını ve bu bölgelerdeki enerji dağılımını gösterir. Bu adımların kombinasyonu ile EEG verilerinden derinlemesine ve öznetelik açısından zengin bilgilerin çıkarılması amaçlanmıştır.

Elde edilen bu öznetelikler FTND gibi bağımlılık testi sonuçları ile ilişkilendirilmiştir. Bu ilişki bağımlılık düzeylerinin EEG sinyalleri üzerinden tahmin edilebilirliğini araştırmak amacıyla önemlidir. Makine öğrenimi modelleri bu öznetelikler kullanılarak eğitilmiş ve test edilmiştir. SVM, kNN, YSA, LSTM ve GRU gibi çeşitli modeller bu amaçla kullanılmıştır.

Zaman-frekans temsilleri ve PSD analizi, özellik çıkarımı gibi ön işlemlerin kullanımının geleneksel sınıflandırma yöntemlerine kıyasla daha doğru, güvenilir sınıflandırma sonuçları verdiği gözlemlenmiştir. Bu bulgular EEG tabanlı biyomedikal araştırmalarda ileri düzeyde veri işleme tekniklerinin nasıl kullanılabileceğini ve bu tekniklerin sağlık alanında nasıl değerli bilgiler sunabileceğini göstermektedir.

1.2. Araştırmanın Önemi

Sigara bağımlılığı dünya genelinde yaygın bir sağlık sorunu olup ölümcül hastalıkların ve sağlık sorunlarının başlıca nedenlerinden biridir. Sigara kullanımı kardiyovasküler hastalıklar, kanser, solunum yolu hastalıkları gibi ciddi sağlık sorunlarına yol açmaktadır. Bu nedenle sigara bağımlılığının erken tespiti ve müdahalesi, halk sağlığı açısından büyük önem taşımaktadır (Witschi, 2005). Bu tez çalışmasının önemi birkaç temel noktada öne çıkmaktadır: Sigara bağımlılığının erken tespiti bireylerin bağımlılıkla mücadele etme süreçlerinde kritik bir rol oynayabilir. EEG verilerine dayalı bir tespit yöntemi bireylerin bağımlılık seviyelerini belirlemede uygun tedavi ve müdahale yöntemlerinin geliştirilmesinde yardımcı olabilir. Sigara bağımlılığının değerlendirilmesinde geleneksel yöntemler genellikle öznel beyanlara dayanmaktadır. Bu çalışma nörofizyolojik belirteçleri kullanarak daha objektif ve güvenilir sonuçlar elde etmeyi amaçlamaktadır. EEG verileri beyin aktivitelerinin doğrudan ölçülmesiyle bağımlılığın nörofizyolojik temellerini anlamada önemli bir araçtır. Çalışmada kullanılan makine öğrenmesi algoritmaları, sigara bağımlılığının analizinde yüksek doğruluk oranları sunarak geleneksel yöntemlerin ötesine geçmeyi hedeflemektedir. Bu algoritmalar karmaşık veri setlerini analiz etme ve bağımlılık seviyelerini sınıflandırma yetenekleriyle tespit süreçlerini daha etkili hale getirebilir. EEG verilerinin zaman-frekans özellikleri çıkarılarak sigara bağımlılığının analizinde daha

detaylı ve spesifik veriler elde edilmiştir. Özellikle temporal ve prefrontal lob bölgelerinde teta frekans bandındaki beyin aktiviteleri sigara uyaranlarına verilen tepkileri daha iyi anlamaya olanak tanımaktadır. Bu tez çalışması sigara bağımlılığının nörofizyolojik belirteçlerinin analizine katkıda bulunarak halk sağlığı politikalarının ve önleyici tedbirlerin geliştirilmesine yardımcı olabilir. Sigara kullanımının ve bağımlılığının erken tespiti bireylerin daha sağlıklı yaşam tarzlarına yönlendirilmesi için önemli bir adım olabilir. EEG verileri ve makine öğrenmesi algoritmalarının birleşimi sigara bağımlılığının analizinde daha objektif, güvenilir ve yüksek doğruluk oranlarına sahip bir yaklaşım sunmaktadır. Bu da sigara bağımlılığı ile mücadelede önemli bir ilerleme sağlayabilmektedir.



2. MATERYAL

Bu bölümde, tez çalışmasında kullanılan materyallerin teorik bilgileri ayrıntılı bir şekilde ele alınmıştır. İlk olarak, Elektroensefalografi (EEG) nedir, tarihçesi ve kullanım alanları hakkında bilgi verilmiştir. EEG'nin temel prensipleri, beyin dalgalarının kaydedilmesi ve analiz edilmesi süreçleri açıklanmıştır. EEG'nin klinik ve araştırma alanlarındaki uygulamaları gibi konular üzerinde durulmuştur.

Ardından çalışmada kullanılan Fagerström Nikotin Bağımlılığı Anketi (FTND) hakkında detaylı bilgi verilmiştir. FTND'nin sigara bağımlılığını değerlendirmede nasıl kullanıldığı, anketin geçerliliği ve güvenilirliği konuları ele alınmıştır. Anketin maddeleri, puanlama sistemi ve bağımlılık düzeylerinin nasıl belirlendiği açıklanmıştır.

Sonrasında ham EEG verilerini Ayırık Dalgacık Dönüşümü (DWT) ile frekans alt bileşenlerine ayırma yöntemleri hakkında bilgiler verilmiştir.


Daha sonra, zaman ve frekans domainlerinde özellik çıkarımı yöntemleri ve performans metrikleri ele alınmıştır. Zaman ve frekans domaininde özellik çıkarımı işlemlerinden bahsedilmiştir. EEG verilerinden anlamlı özelliklerin nasıl çıkarılacağı, zaman domaininde 15 farklı özellik çıkarımı yöntemi ve frekans domaininde Spektral Güç Yoğunluğu (PSD) analizi kullanılarak detaylandırılmıştır.

Son olarak, sınıflandırma ve veri çoğaltmak için kullanılan makine öğrenmesi yöntemleri hakkında bilgiler verilmiştir. k-Nearest Neighbors (kNN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (YSA) ve Tekrarlamalı Sinir Ağları (RNN) gibi makine öğrenmesi algoritmalarının temel prensipleri, avantajları ve dezavantajları ele alınmıştır. Ayrıca, Çekişmeli Üretici Ağlar (GAN) kullanarak veri çoğaltma süreci detaylandırılmış ve bu yöntemin veri setlerinin genişletilmesinde nasıl kullanıldığı açıklanmıştır. Performans metrikleri olarak doğruluk, kesinlik, özgüllük ve f1 skoru gibi ölçütler açıklanmış ve bu metriklerin sınıflandırma algoritmalarının değerlendirilmesinde nasıl kullanıldığı belirtilmiştir.

Bu bölüm, çalışmada kullanılan yöntem ve araçların teorik temellerini kapsamlı bir şekilde ele alarak, okuyucunun araştırmanın metodolojik yapısını ve bilimsel arka planını anlamasına yardımcı olmayı amaçlamaktadır.

2.1. EEG Nedir? Tarihçesi, Kullanım Alanları

İnsan beyni merkezi sinir sisteminin en karmaşık ve merak uyandıran bileşenidir. Beyin, beyincik, beyin sapı ve büyük beyin (serebrum) olmak üzere ana üç bölümden oluşmaktadır (Hudspeth vd., 2013). Beyin sapı yaşamsal fonksiyonları düzenlerken, beyincik koordinasyon ve dengeyi sağlar, büyük beyin ise düşünme, algılama, hafıza ve duygular gibi karmaşık işlevleri kontrol etmektedir. Büyük beyinde Şekil 2.1’de görüleceği üzere frontal, parietal, temporal ve oksipital loblar gibi farklı bölgeler bulunmaktadır. Frontal lob üst düzey bilişsel işlevleri düzenlerken, parietal lob dokunsal duyuları işler ve temporal lob işitme ile hafıza işlevlerini kontrol etmektedir (Damasio, 2005).




Şekil 0.1. İnsan beyni anatomisi (Kaynak: Bear vd., 2016)

Elektroensefalografi (EEG) beyin aktivitesini ölçmek için kullanılan bir tıbbi görüntüleme tekniğidir. Bu yöntem sinir hücrelerinin elektriksel aktivitelerini algılayarak beyin dalgalarını ölçer. EEG, beyin dalgalarının genel desenlerini analiz ederek çeşitli zihinsel durumların ve nörolojik rahatsızlıkların değerlendirilmesine yardımcı olur. EEG'nin kökeni, 1920'lerin başında Alman nörolog Hans Berger'in çalışmalarına dayanmaktadır. Berger, insan beyninin elektriksel aktivitelerini kafa derisi üzerinde yerleştirilmiş elektrotlar aracılığıyla ölçerek ilk EEG kayıtlarını almıştır. Berger'in buluşu nöroloji

alanında ıęır aan bir olay olmuř ve beyin aktivitesini incelemek iin temel bir yntem olarak kabul edilmiřtir (Luck, 2014).

EEG'nin temel amacı beyin aktivitesini izlemek olsa da farklı alanlarda daha geniř bir kullanım alanına sahiptir. Tıbbi alanda, epilepsi teřhisi ve nbetlerin tipini belirleme gibi durumların yanı sıra uyku bozukluk analizinde ve beyin hasarı gibi durumların izlenmesinde sıka kullanılmaktadır. Nrolojik bozuklukların tanısında ve takibinde EEG'nin kullanımı kritiktir. Ancak EEG'nin kullanım alanları sadece tıbbi alanla sınırlı deęildir. Nrobilim arařtırmalarında beyin aktivitesinin incelenmesi ve anlařılması iin geniř bir řekilde kullanılmaktadır. Son yıllarda, EEG'nin ticari kullanımları da hızla artmıřtır. rneęin, dikkat seviyelerini deęerlendirmek, stres dzeylerini izlemek ve beyin-bilgisayar arayzleri geliřtirilmesi gibi alanlarda EEG teknolojisi yaygın bir řekilde kullanılmaktadır (Silva & Niedermeyer, 2005).

EEG, beyin aktivitesini incelemek iin kullanılan birok teknikten biridir. Bu teknik beyin dalgalarını elektrotlar aracılıęıyla kaydederek beyin aktivitesinin belirli zelliklerini analiz eder. řekil 2.2'de EEG lm iin elektrotların 10/20 lm sistemine gre yerleřimi grlmektedir. Beyin dalgaları tipik olarak frekans ve morfoloji zelliklerine gre kategorize edilmektedir. rneęin, alfa dalgaları, gzler kapalıyken uyku durumunda veya gevřeme sırasında yaygın olarak grlrken, beta dalgaları zihinsel olarak uyanık durumlarda grlr. Bu dalgaların karakteristikleri, beyin aktivitesinin belirli ynlerini anlamak iin kullanılmaktadır. EEG'nin avantajları arasında kolay uygulanabilirlik, gerek zamanlı izleme imkanı ve non-invaziv olması bulunmaktadır. Ancak EEG'nin bazı sınırlamaları da vardır. zellikle, derin beyin yapılarının aktivitesini lmede sınırlıdır ve bazı durumlarda doęruluk dřktr (Bařar vd., 2001).



Şekil 0.2. 10/20 ölçüm sistemi (Kaynak: Bos, 2006)

2.2. Fagerström Nikotin Bağımlılığı Testi (FNTD)

FTND, sigara içen bireylerde nikotin bağımlılığı seviyesini belirlemek için sıkça kullanılan bir ölçüm aracıdır. Bu test bağımlılık seviyesini belirlemek için çeşitli soruları içerir ve bireyin sigara içme alışkanlığı, içilen sigara miktarı ve içme sıklığı gibi faktörleri değerlendirir. Bu test ilk olarak 1978 yılında geliştirilmiştir (Fagerström, 1978). Temel amacı sigara içme alışkanlığının ve bağımlılığının derecesini objektif bir şekilde belirlemektir. FNTD 6 sorudan oluşmaktadır ve bu sorular arasında genellikle sabah ilk sigara içme alışkanlığı, içilen sigara sayısı, gün içindeki sigara içme sıklığı, rahatsız edici durumda sigara içme eğilimi gibi konular bulunmaktadır. Soruların yanıtları bireyin bağımlılık düzeyini belirlemek için önceden belirlenmiş bir puanlama sistemine göre değerlendirilmektedir (Fagerstrom & Schneider, 1989; Uysal vd., 2004).

FTND klinik ortamlarda sigara bırakma programlarında, araştırmalarda ve bağımlılık çalışmalarında yaygın olarak kullanılmaktadır. Test sonuçları, sigara içen bireylerin bağımlılık seviyelerini değerlendirirken önemli bir rehber sağlar ve sigara bırakma tedavisi için uygun stratejilerin belirlenmesine yardımcı olur (Heatherton vd., 1991b).

2.3. Ayırık Dalgacık Dönüşümü (DWT)

Dalgacık dönüşümü (WT), sinyal işleme ve analizinde kullanılan önemli bir tekniktir. Bu yöntem, bir sinyalin zaman-frekans alanında incelenmesini sağlar ve farklı zamanlarda farklı frekans bileşenlerinin nasıl davrandığını anlamamıza olanak tanır (Zhang, 2019). DWT, WT'nin bir türevidir ve genellikle sinyali daha küçük parçalara böler ve her bir parçayı ayrı ayrı işleyerek çalışmaktadır. Sinyalin küçük parçalara bölünmesi zaman ve frekans uzayındaki davranışlarını daha detaylı bir şekilde inceleme imkânı sağlamaktadır. DWT, bir sinyalin frekans bileşenlerini belirlemek için kullanılan matematiksel bir işlemdir ve genellikle sinyalin yüksek ve düşük frekans bileşenlerini ayırmak için kullanılmaktadır. Bu ayrıştırma işlemi, sinyalin belirli bir zaman aralığında hangi frekanslarda etkili olduğunu göstermekte ve böylece sinyalin özelliklerini daha ayrıntılı bir şekilde analiz etmemize olanak tanımaktadır (S. G. Mallat, 1989) (Strang & Nguyen, 1996). DWT'nin birçok uygulaması vardır ve sinyal işleme alanında yaygın olarak kullanılmaktadır. Özellikle görüntü işleme, ses işleme, sinyal sıkıştırma ve veri analizi gibi alanlarda sıklıkla kullanılmaktadır (Ocak, 2009). Veri sıkıştırmada, DWT'nin önemi büyüktür. Çünkü yüksek frekans bileşenlerinin büyük bir kısmı çıkarılabilir ve böylece sinyalin boyutu önemli ölçüde azaltılabilir. DWT'nin biyomedikal sinyallerin analizinde de etkili olduğu birçok araştırma tarafından gösterilmiştir. Özellikle, elektrokardiyografi (EKG) ve EEG gibi biyomedikal sinyallerin analizinde DWT'nin etkili bir şekilde kullanıldığı görülmüştür. (Hamad vd., 2017; Sundararajan, 2016).

DWT için tam bir denklem seti sunmak oldukça karmaşıktır. Çünkü DWT farklı ölçekler ve konumlarda sinyalin ayrıştırılması ve sentezlenmesi için bir dizi farklı filtre kullanmaktadır (Percival & Walden, 2000).

2.3.1. Ayırık Dalgacık Dönüşümü Analizi

Ayrık dalgacık dönüşümünün analiz işlemi girdi sinyalinin farklı ölçeklerde ve konumlarda dalga fonksiyonları ile temsil edilmesini sağlamaktadır. Bu sinyalin ayrıştırılması işlemidir. Analiz işlemi sonucunda elde edilen analiz katsayıları, sinyalin ölçek-frekans uzayında temsilini sağlar (Daubechies, 1992).

Ayrıştırma işlemi için genel denklem:

$$C_{j,k} = f, \psi_{j,k}$$

Denklem 2.1. DWT işlemi

Denklem 2.1’de $C_{j,k}$, j ölçeği ve k konumu temsil eden analiz katsayısıdır.

f , ayrıştırılacak girdi sinyalidir.

$\Psi_{j,k}$, ölçek ve konum parametreleri j ve k ile belirlenen analiz dalgacıdır.

2.3.2. Ayrık Dalgacık Dönüşümü Sentezi

Ayrık dalgacık dönüşümünün sentez işlemi, analiz işleminden elde edilen ayrıştırılmış katsayıların birleştirilerek orijinal sinyalin yeniden oluşturulmasını sağlar (S. Mallat, 1999).

Sentez işlem için genel denklem:

$$f(t) = \sum_{j,k} C_{j,k} \cdot \Psi_{j,k}(t)$$

Denklem 2.2. DWT sentezi

Denklem 2.2’de $f(t)$, yeniden oluşturulacak olan orijinal sinyaldir.

$C_{j,k}$, analiz işleminden elde edilen analiz katsayılarıdır.

$\Psi_{j,k}(t)$, ölçek ve konum parametreleri j ve k ile belirlenen sentez dalgacıdır.


Alternatif olarak sentez işlemi için farklı bir denklem:

$$f(t) = \sum_n d_n \phi_n(t) + \sum_{j,k} c_{j,k} \cdot \Psi_{j,k}(t)$$

Denklem 2.3. DWT alternatif sentezi

$\phi_n(t)$, d_n katsayıları ve dalgacıklarıdır

.



Şekil 0.3. EEG dalgası frekans bileşenleri

Ham EEG verisinin DWT işlemi sonucu frekans bileşenleri Şekil 2.3.'te görülmektedir.

2.4. Güç Spektral Yoğunluğu (PSD)

Güç Spektral Yoğunluğu (PSD) bir sinyalin frekans bileşenlerinin güç dağılımını gösteren bir ölçümdür. Yani, bir sinyalin farklı frekans bileşenlerinin hangi düzeyde güce sahip olduğunu belirtmektedir. Özellikle bir sinyalin belirli frekanslardaki güç değişimlerini incelenmek istendiğinde PSD kullanılmaktadır. Bu yöntem sinyalin frekans alanındaki özelliklerini analiz etmek için yaygın olarak kullanılmaktadır (Onay & Kose, 2019; Türk vd., 2015).

PSD'nin kullanım alanları şunlardır: EEG, EKG ve EMG gibi biyomedikal sinyallerin frekans bileşenlerinin güç spektrumlarının nasıl değiştiğini incelemekte kullanılmaktadır. Görüntü işleme ve sinir ağlarında ise görüntülerin frekans alanında analizi, gürültü giderme ve görüntü sıkıştırma işlemlerinde faydalıdır. Ayrıca telekomünikasyon ve haberleşme alanında kanal kapasitesi, sinyal kalitesi ve spektral verimlilik gibi faktörlerin değerlendirilmesinde de PSD kullanılır. Akustik ve ses sinyallerinin incelemesinde de önemli bir rol oynamaktadır.

PSD hesaplama yöntemleri şunlardır:

2.4.1. Düz Zaman Penceresi Yöntemi

Düz Zaman Penceresi Yöntemi bir sinyalin belirli bir zaman aralığı boyunca analiz edilmesini içerir. Bu yöntemde sinyalin belirli bir süre boyunca bölümlere ayrılması ve her bir bölümün ayrı ayrı incelenmesi gerekmektedir. Daha sonra her bir bölüm üzerinde FFT (Hızlı Fourier Dönüşümü) gibi bir dönüşüm uygulanarak sinyalin frekans bileşenleri elde edilir. Bu frekans bileşenleri, sinyalin hangi frekanslarda hangi güçte olduğunu gösterir. Son olarak, bu frekans bileşenlerinin genlikleri kullanılarak güç spektral yoğunluğu (PSD) hesaplanır. Bu yöntem zaman penceresi boyutu ve örtüşme gibi parametrelerin dikkatlice seçilmesini gerektirir. (Oppenheim, 1999)

$$S(\omega) = \frac{1}{T} |X(\omega)|^2$$

Denklem 2.4. PSD işlemi

$S(\omega)$, ω frekans için güç spektral yoğunluğudur.

T , zaman aralığıdır.

$X(\omega)$, sinyalin Fourier dönüşümüdür.

2.4.2. Parçalı Zaman Penceresi Yöntemi

Parçalı Zaman Penceresi Yöntemi, zaman serisini belirli parçalara böler ve her parça için ayrı ayrı PSD hesaplar. Bu yöntemde genellikle FFT kullanılarak PSD hesaplanır. Denklemi aşağıdaki gibidir:

$$S_i(f) = \frac{1}{T_i} \left| \sum_{n=0}^{N-1} x_i[n] e^{-j2\pi f n} \right|^2$$

Denklem 2.5. Parçalı zaman penceresi yöntemi

$S_i(f)$, i numaralı parça için frekans f için PSD'dir.

T_i , i numaralı parçanın zaman aralığıdır.

$x_i[n]$, i numaralı parçanın n indeksli örneğidir.

Parçalı Zaman Penceresi Yöntemi, özellikle uzun süreli sinyallerin analizi için kullanışlıdır. Çünkü zaman serisini parçalara ayırarak her parça için ayrı ayrı spektral içeriği analiz etme imkânı sağlar. Bu yöntem, sinyalin zaman içindeki değişimlerini daha

iyi anlamak ve zamanla değişen frekans bileşenlerini izlemek için kullanılmaktadır (Stoica & Moses, 2005).

2.4.3. Peditogram Yöntemi

Peditogram bir sinyalin zamanla değişen spektral yoğunluğunu görsel olarak gösteren bir grafik türüdür. Bu yöntemde spektral analiz, sinyalin STFT'sini (Kısa Zamanlı Fourier dönüşümü) kullanılarak elde edilmektedir. STFT sinyali belirli zaman aralıklarında pencereleyerek ve her bir pencere için ayrı ayrı FFT hesaplayarak gerçekleştirilmektedir. Sonuçlar zaman ve frekans düzlemlerindeki değişimleri gösteren bir 2B grafik olarak sunulur. Peditogramlar sinyalin zaman-frekans karakteristiğini incelemek için kullanılır ve zaman ve frekans arasındaki ilişkileri görselleştirmek için güçlü bir araçtır (S. Mallat, 1999).

Denklemini şu şekildedir:

$$S_i(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) \omega(\tau - t) e^{-j2\pi f\tau} d\tau \right|^2$$

Denklem 2.6. Peditogram yöntemi

$S_i(t, f)$, t zaman ve f frekans için peditogramdır.

$x(\tau)$, orijinal zaman serisidir.

$\omega(\tau - t)$, pencere fonksiyonudur.

$e^{-j2\pi f\tau}$, harmonik bir sinyaldir.

Bu denklem, her zaman penceresi için sinyalin STFT'sinin karesini alarak peditogramı elde etmek için kullanılır.

2.4.4. Welch Yöntemi

Welch yöntemi, farklı parçalara bölünmüş sinyal parçalarının PSD'sinin hesaplanmasıyla karakterize edilir. Her parça için hesaplanan PSD'lerin ortalaması alınarak nihai tahmin elde edilmektedir.

$$P_{\text{Welch}}(f) = \frac{1}{M} \sum_{m=1}^M |X_m(f)|^2$$

Denklem 2.7. Welch yöntemi

$P_{\text{Welch}}(f)$, f frekans için Welch yöntemiyle tahmin edilen güç spektral yoğunluğudur.

$X_m(f)$, m numaralı parça için FFT sonucudur.

M , toplam parça sayısıdır.

Welch yöntemi özellikle gürültülü veri setleri veya kısa süreli sinyaller için daha güvenilir bir tahmin sağlamaktadır. Parçalara ayrılmasıyla spektral kaçış azaltılarak daha pürüzsüz bir tahmin elde edilmektedir (Welch, 1967).

2.4.5. Burg Spektral Analizi

Burg spektral analizi, AR (Otoregresif) modelleme kullanarak PSD tahminini sağlar. AR model parametrelerinden PSD tahmin edilir. Burg spektral analizi, spektral analizin daha hassas bir tahminini sağlamak için kullanılır ve özellikle AR modelleme konusunda derin bilgi gerektirir (Kay, 1988).

$$P_{\text{Burg}}(f) = \frac{1}{\left| 1 - \sum_{k=1}^p \hat{a}_k e^{-j2\pi f k} \right|^2}$$

Denklem 2.8. Burg spektral analiz

$P_{\text{Burg}}(f)$, f frekans için Burg spektral analiz ile tahmin edilen güç spektral yoğunluğudur.

$\hat{a}_k$, AR model katsayılarıdır.

p , AR model derecesidir.

2.5. Özellik Çıkarımı Yöntemleri

Sinyal işleme, zamanla değişen veya mekânsal verilerin analizi için kullanılan bir dizi tekniktir. EEG, EKG ve EMG gibi biyomedikal sinyaller insan vücudunun elektriksel aktivitesi hakkında karmaşık veriler içermektedir. Sinyal işlemede özellik çıkarma ham verilerden anlamlı bilgiler elde etme sürecidir ve genellikle veri analizi, sınıflandırma işlemleri için bir ön adımdır. Özellik çıkarma, doğrudan ham sinyalleri işlemek yerine sinyalleri temsil eden ve analiz için daha kullanışlı olan ölçümleri belirleme ve çıkarma işlemidir.

Sinyal işlemede yaygın olarak kabul edilen sinyallerin temel istatistiksel özelliklerini (ortalama, standart sapma, çarpıklık, kurtosis vb.), enerji özelliklerini (oto korelasyon katsayıları, Wilson genliği) ve zaman alanı özelliklerini (sıfır geçiş sayısı, eğimde işaret

değişiklikleri) içermektedir. Bu tür özelliklerin çıkarılması sinyallerin karmaşık yapısını basitleştirir, verileri daha anlaşılır hale getirir ve beyin durumları arasındaki farklılıkları vurgulayabilir. Özellik çıkarma sınıflandırma ve tanıma sistemlerinin performansını doğrudan etkilemektedir. İyi seçilmiş özellikler modelin doğruluğunu ve güvenilirliğini artırabilirken daha az bilgilendirici veya yanıltıcı özellikler modelin performansını azaltabilir.

Belirlenen 15 adet özellik seti aşağıda tanımlarıyla birlikte verilmiştir:

1. Ortalama (Mean): Bu özellik sinyal örneklerinin genliklerini toplayıp örnek sayısına bölerek elde edilir. İstatistikte bu özellik birinci derece moment olarak adlandırılmaktadır. Ortalama sinyale genel bir bakış ve sinyalin davranışı hakkında bilgi edinmemizi sağlar. Bu nedenle ortalama alma sinyal işleme ve analizinde önemli bir yere sahiptir.

$$\text{mean} = \frac{1}{N} \sum_{n=1}^N x_n$$

Denklem 2.9. Ortalama

N, veri sayısı

2. Ortalama Mutlak Sapma (Mean Absolute Deviation): Ortalama Mutlak Sapma veri noktalarının ortalamadan uzaklıklarının mutlak değerlerinin toplamıdır (McFarland & Wolpaw, 2011).

$$\text{MAD} = \frac{1}{N} \sum_{n=1}^N |x_n - \text{mean}|$$

Denklem 2.10. Ortalama mutlak sapma

3. Varyans (Variance): Varyans verinin ortalamaya göre dağılımını verir. Her değer için veri setindeki ortalama değerden uzaklığının karesinin aritmetik ortalaması alınarak hesaplanmaktadır (Strahler, 1954).

$$\text{varyans} = \frac{1}{N-1} \sum_{n=1}^N (x_n - \text{mean})^2$$

Denklem 2.11. Varyans

4. Standart Sapma (Standard Deviation): Standart sapma bir veri setindeki örneklerin ortalamaya ne kadar yakın olduğunu belirlemek ve verinin ne kadar yayıldığını ölçmek için kullanılmaktadır. Standart sapma, varyansın kareköküdür (Porter vd., 2009).

$$sd = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - \text{mean})^2}$$

Denklem 2.12. Standart sapma

5. Çarpıklık (Skewness): Dağılımın ortalama etrafındaki simetriden ne kadar sapma yaptığını belirtmektedir.

$$\text{skewness} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \text{mean})^3}{sd^3}$$

Denklem 2.13. Çarpıklık

sd, standart sapma

6. Kurtosis: Verinin zirve değerlerinin düz mü yoksa sivri mi olduğu hakkında bilgi vermektedir (Peter & Westfall ; R, 2014).

$$\text{kurtosis} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \text{mean})^4}{sd^4}$$

Denklem 2.14. Kurtosis

7. Otokorelasyon Katsayıları (Autocorrelation Coefficients): Otokorelasyon katsayıları sinyal işlemede yaygın olarak kullanılan yöntemlerden biridir (Shannon & Paliwal, 2006).

$$x[n] = - \sum_{k=1}^p a_k x[n-k] + e[n]$$

Denklem 2.15. Otokorelasyon katsayısı

Burada, p modelin derecesini, x[n] n adet örneğinden oluşan veri sinyalini, a_k reel değerli otokorelasyon katsayılarını ve e[n] önceki örneklerden bağımsız beyaz gürültünün hata terimini temsil etmektedir. Buradaki amaç bir veri noktasının önceki birkaç nokta ile ilişkisini incelemek ve buna dayalı bir model oluşturmaktır (Brockwell & Davis, 2002).

8. Sıfır Geçiş Oranı (Zero-Crossing Rate): Bu yöntemde sinyalin sıfır olduğu noktalar sayılıp kaydedilmektedir.

$$zcr = \sum_{N=1}^{N-1} [\text{sgn}(x_n \cdot x_{n+1})] \cap |x_n - x_{n+1}| \geq \text{threshold}$$

Denklem 2.16. Sıfır geiř oranı

9. Wilson Genlięi (Wilson Amplitude): Sinyaldeki ardışık örneklerin önceden belirlenmiş bir eşik deęerini kaç kez aştığını gösteren bir deęerdir (Alday & Roiban, 2008).

$$wa = \sum_{n=1}^{N-1} [\text{sgn}(|X_n - X_{n+1}|)]$$

$$f(x) = 1 \Rightarrow f(x) \geq \text{threshold}$$

$$f(x) = 0 \Rightarrow \text{other_situations}$$

Denklem 2.17. Wilson genlięi

10. Eğim İşaret Deęiřimi (Slope Sign Change): Sinyalin eğimi pozitiften negatife ve negatiftten pozitifte deęiřtięi noktalar sayılıp kaydedilir.

$$ssc = \sum_{n=2}^{N-1} [f[(x_n - x_{n-1})x(x_n - x_{n+1})]]$$

$$f(x) = 1 \Rightarrow f(x) > \text{threshold}$$

$$f(x) = 0 \Rightarrow \text{other_situations}$$

Denklem 2.18. Eğim işaret deęiřimi

11. Tekil Deęer Ayırıştırması (Singular Value Decomposition): Tekil deęer ayırıştırması, bir matris ayırıştırma işlemidir. Verilen matrisin öz deęerlerini ve öz vektörlerini hesaplayarak elde edilmektedir. SVD matristeki bilgiyi sıkıştırıp ve matrisin boyutunu deęiřtirmeden önemli özelliklerini vurgulayabilmektedir. Bu nedenle SVD veri analizi, boyut azaltma, matris yaklaşımı ve öneri sistemleri gibi alanlarda yaygın olarak kullanılmaktadır (Klema & Laub, 1980).

$$M = U.d.V^T$$

Denklem 2.19. Tekil deęer ayırıştırması

Burada M, mxn boyutunda bir matris; U, mxm boyutunda bir ortonormal matris; d, mxn boyutunda bir diyagonal matris ve d'nin elemanları sıfır olmayan tekil deęerlerdir. V^T , nxn boyutunda transpoze bir ortonormal matristir.

12. Medyan (Median): Bir veri setindeki örnekler sıralandığında ortaya düşen deęerdir.

Eđer veri setindeki örnek sayısı tek ise;

$$\text{median} = x_{\frac{(n+1)}{2}}$$

Denklem 2.20. Medyan veri seti 0

Eğer veri setindeki örnek sayısı çift ise;

$$\text{median} = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2}$$

Denklem 2.21. Medyan veri seti

13. Minimum Değerler (Minimum Values): Bir veri setindeki örneklerin en küçük değerleridir.

$$\min = [x_1, x_2, \dots, x_n]$$

Denklem 2.22. Minimum değerler

14. Maksimum Değerler (Maximum Values): Bir veri setindeki örneklerin en büyük değerleridir.

$$\max = [x_1, x_2, \dots, x_n]$$

Denklem 2.23. Maksimum değerler

15. Toplam (Sum): Bir veri setindeki örneklerin toplamıdır.

$$\text{sum} = \sum_{i=1}^n x_i$$

Denklem 2.24. Toplam değer

2.6. Temel Bileşen Analizi (PCA)

PCA, özellikle yüksek boyutlu veri setlerinde özellik çıkarımı yapmak için kullanılan güçlü bir yöntemdir. Yüksek boyutlu verilerde, orijinal özelliklerin birçoğu genellikle gereksiz veya fazla bilgi içerir. Bu modelin performansını olumsuz yönde etkileyebilir ve modelin aşırı karmaşık hale gelmesine yol açabilir. PCA, bu durumu çözmek için veri setindeki gereksiz veya fazla bilgi içeren özellikleri azaltarak daha anlamlı ve daha az sayıda yeni özellikler (temel bileşenler) oluşturur.

PCA, veri setindeki özellik sayısını azaltırken verideki toplam varyansın büyük bir kısmını korur. Bu verideki bilginin kaybolmaması ve aynı zamanda daha sade ve kullanışlı bir veri seti oluşturulması anlamına gelir. Orijinal veri setindeki yüksek boyutlu verilerin, veri setindeki varyansın en büyük kısmını açıklayan birkaç doğrusal bileşenle temsil edilmesi, veri boyutunu önemli ölçüde azaltmaktadır.

PCA, orijinal özelliklerin doğrusal kombinasyonlarını kullanarak yeni bileşenler oluşturur. Bu bileşenler, orijinal veri setindeki en fazla varyansı ifade etmektedir. Böylece orijinal verinin karmaşıklığı ve yüksek boyutluluğu, daha az sayıda ancak bilgi açısından zengin bileşenlerle ifade edilmektedir. Bu bileşenler, modelin daha iyi performans göstermesi için gereken en önemli bilgileri içerir.

Verilerde, aynı bilgiyi taşıyan özellikler (yani, yüksek korelasyonlu özellikler) genellikle fazladır ve modelde gereksiz bir karmaşıklık yaratmaktadır. PCA, bu gereksiz bilgileri elemek için kullanılır. Yüksek korelasyonlu özellikler, PCA ile tek bir bileşen altında toplanır, bu da modelin gereksiz bilgiyle yüklenmesini önler ve daha anlamlı sonuçlar elde edilmesini sağlar.

Sonuç olarak PCA, veri setlerindeki gereksiz özellikleri azaltarak daha anlamlı ve kullanışlı bileşenler oluşturur. Bu sayede modelin daha hızlı, daha sade ve daha performanslı çalışmasını sağlar. Özellikle yüksek boyutlu verilerle çalışırken PCA, model performansını artıran önemli bir araç olarak öne çıkmaktadır.

2.7. Performans Metrikleri

Bilimsel çalışmalarda önerilen sistemlerin performansını izlemek için değerlendirme metrikleri gereklidir. Sınıflandırma problemlerinde değerlendirme metrikleri bir karışıklık matrisi kullanılarak kolayca hesaplanmaktadır. Algoritma tarafından üretilen çıktıların doğru olduğu durumlar karışıklık matrisinde doğru pozitif (TP) hücreleri ve doğru negatif (TN) hücreleri olarak yazılır. Bir çıktı negatif olarak üretilmişse ancak aslında pozitifse, bu yanlış negatif (FN) hücrelerine ve bir çıktı pozitif olarak üretilmiş ancak aslında negatifse bu yanlış pozitif (FP) hücrelerine yazılmaktadır (Powers, 2020). Şekil 2.4'te karışıklık matrisi görülmektedir.

		Hedef Sınıf	
		0	1
Çıkış Sınıfı	0	Doğru Negatif (TN)	Yanlış Negatif (FN)
	1	Yanlış Pozitif (FP)	Doğru Pozitif (TP)

Şekil 0.4. Karışıklık matrisi

2.7.1. Doğruluk (Accuracy)

Bir sınıflandırma modelinin doğru tahmin ettiği örneklerin toplam örnekler içindeki oranını ifade etmektedir. Genellikle tüm sınıfların eşit derecede önemli olduğu durumlarda kullanılmaktadır. Bir modelin doğruluğu ne kadar yüksekse o kadar iyi performans gösterdiği kabul edilir. Ancak dengesiz sınıflandırma problemlerinde doğruluk yanıltıcı olmaktadır. Örneğin, nadir olan bir sınıfın doğru tahmin edilmesi, genel doğruluk oranını yanıltıcı şekilde artırabilir. Bu nedenle, doğruluk metriğini yorumlarken sınıf dengesine dikkat etmek önemlidir. Doğruluk metriği modelin genel performansını değerlendirmek için faydalıdır ancak tek başına yeterli değildir.

$$\text{accuracy} = \frac{tp + tn}{tp + tn + fp + fn}$$

Denklem 2.25. Doğruluk metriği

tp, doğru pozitif

tn, doğru negatif

fp, yanlış pozitif

fn, yanlış negatif

2.7.2. Özgüllük (Specificity)

Negatif sınıfların doğru bir şekilde tanımlandığı orandır. Özellikle modelin gerçek negatifleri ne kadar doğru bir şekilde belirlediğini değerlendirmek için kullanılmaktadır. Özgüllük gerçek negatifleri doğru bir şekilde tanımlama yeteneğini ölçer ve yanlış pozitif sonuçları minimize etmek için önemlidir. Örneğin, bir tıbbi testin özgüllüğü sağlıklı olan kişileri doğru bir şekilde tespit etme yeteneğini ifade etmektedir.

$$\text{specificity} = \frac{tn}{tn + fp}$$

Denklem 2.26. Özgüllük metriği

2.7.3. Duyarlılık (Recall)

Pozitif sınıfların doğru bir şekilde tanımlandığı orandır. Modelin gerçek pozitifleri ne kadar doğru bir şekilde belirlediğini değerlendirmek için kullanılmaktadır. Duyarlılık gerçek pozitifleri tespit etme yeteneğini ölçer ve yanlış negatif sonuçları minimize etmek için önemlidir. Örneğin, bir tıbbi testin duyarlılığı hastalığı olan kişileri doğru bir şekilde tespit etme yeteneğini ifade etmektedir.

$$\text{recall} = \frac{tp}{tp + fn}$$

Denklem 2.27. Duyarlılık metriği

2.7.4. Hassasiyet (Precision)

Modelin pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma olasılığını ifade etmektedir. Modelin yanlış pozitifleri ne kadar az ürettiğini değerlendirmek için kullanılmaktadır. Hassasiyet pozitif tahminlerin doğruluğunu ölçer ve modelin yanlış alarm verme eğilimini belirler. Özellikle yanlış pozitiflerin maliyeti yüksek olduğunda veya modelin yanlış alarm verme olasılığı önemli olduğunda hassasiyet önemlidir.

$$\text{precision} = \frac{tp}{tp + fp}$$

Denklem 2.28. Hassasiyet metriği

2.7.5. F-Skor (F-Score)

Hassasiyet ve duyarlılık arasındaki dengeyi sağlamak için kullanılan bir performans metriğidir. Özellikle dengesiz sınıflandırma problemlerinde kullanışlıdır. F-Skor hassasiyet ve duyarlılığın harmonik ortalamasını olarak hesaplanmaktadır. Böylece her iki metriğin de eşit derecede önemli olduğu bir değer elde edilir. Özellikle doğruluk metriği yanıltıcı olduğunda veya sınıf dengesi dikkate alındığında F-Skor daha güvenilir bir değerlendirme sağlamaktadır (Sokolova vd., 2006).

$$f_score = 2 \times \frac{(\text{hassasiyet}) \times (\text{duyarlılık})}{(\text{hassasiyet}) + (\text{duyarlılık})}$$

Denklem 2.29. F-skor metriği

2.8. k-En Yakın Komşuluk (kNN)

k-En Yakın Komşuluk (kNN) bir gözlemi sınıflandırmak veya bir değeri tahmin etmek için kullanılan basit ve etkili bir makine öğrenmesi algoritmasıdır. Temel prensibi yeni bir gözlemle ilişkilendirilen veri noktasının k en yakın komşusunu inceleyerek tahmin yapmaktır. Sınıflandırma için gözlemin k en yakın komşusu içindeki sınıfların çoğunluğunu kullanarak sınıf belirlenmektedir. Regresyon analizi için k en yakın komşunun hedef değişken değerlerinin ortalamasını kullanarak tahmin yapılmaktadır (Hastie vd., 2009) (James vd., 2013).

Mesafe metriğini belirlemek için ilk olarak yeni bir gözlem ile eğitim veri setindeki her bir gözlem arasındaki mesafeyi hesaplamak gereklidir. En sık tercih edilen mesafe ölçütü Öklid mesafesidir ve iki nokta arasındaki uzaklığı hesaplamak için kullanılmaktadır.


$$d(x_i, x_j) = \sqrt{\sum_{p=1}^n (x_{ip} - x_{jp})^2}$$

Denklem 2.30. kNN

Burada x_i ve x_j sırasıyla yeni gözlem ve eğitim veri setindeki bir gözlemi temsil eder.


Komşuların belirlenmesinin ardından yeni gözlem ve k en yakın komşuyu bulmak için bu mesafeler sıralanır. Sınıflandırma tahmini yapmak için k en yakın komşunun etiketleri incelenerek yeni gözlemin sınıfı belirlenmektedir. Regresyon için ise k en yakın komşunun hedef değişken değerlerinin ortalaması kullanılarak tahmin yapılmaktadır.

kNN'nin avantajları arasında basitlik, esneklik ve kolayca uygulanabilir olması yer almaktadır. Ancak büyük veri setleriyle çalışırken hesaplama maliyeti artabilir ve veri setindeki gereksiz özelliklerin performansı olumsuz etkileme riski vardır.




Şekil 0.5. kNN k değeri belirleme

Şekil 2.5'te görüleceği üzere k değeri 5 ve 11 alındığında metrik ölçümler değişmektedir. Burada k değerinin değişmesiyle yeni verinin sınıfı da değişebilir.



Şekil 0.6. kNN aşırı ve yetersiz uyum durumu

Şekil 2.6'da kNN modelinde k değeri yüksek olduğunda model yetersiz uyum durumuna girecektir. Bu durumda model verileri doğru bir şekilde tahmin edemeyecektir. K değeri düşük olduğunda model aşırı uyum durumuna girecektir. Bu durumda ise gürültüler dahil tüm eğitim verileri bölünecektir ve test verilerinde modelin başarı oranı düşük olacaktır.



Şekil 0.7. kNN öncesi ve sonrası

Şekil 2.7’de iki farklı kategoriye yeni bir veri atanmış ve kNN kullanılarak yeni verinin kategorisi belirlenmiştir. Burada bir k değeri girilerek yeni veriye en yakın komşu verilere (k değeri kadar komşu veri) mesafeler ölçülmüş ve yeni verinin kategorisi belirlenmiştir.

2.9. Destek Vektör Makineleri (SVM)

SVM, sınıflandırma ve regresyon problemlerinde etkili bir şekilde kullanılan güçlü bir makine öğrenimi algoritmasıdır. Vapnik tarafından 1960'larda geliştirilmiş sonrasında SVM özellikle sınıflandırma problemlerinde etkili olduğu kanıtlanmış bir yöntem haline gelmiştir (Cortes vd., 1995).

SVM, veri noktalarını vektörler olarak algılar ve bu vektörleri bir veya daha fazla sınıfa atamak için bir karar sınırı belirlemektedir. Temel prensibi veri noktalarını ayırmak için en iyi ayrıştırıcı düzlemi (hiper düzlemi) bulmaktır. Bu hiper düzlemi sınıflar arasındaki boşluğu (marjı) maksimize ederek belirlemektedir (Schölkopf & Smola, 2002).

SVM'nin belirgin bir özelliği veri boyutunun artmasıyla performansının düşmemesidir. Bu özellik, özellikle yüksek boyutlu veri kümeleriyle çalışırken avantaj sağlamaktadır. SVM farklı kernel fonksiyonları kullanarak doğrusal olmayan problemleri de çözebilir. Bu fonksiyonlar verileri daha yüksek boyutlu bir uzaya eşleştirerek doğrusal olarak ayrılabilir hale getirmektedir (C. C. Chang & Lin, 2011b) (K.-W. Chang vd., 2008).


Destek vektör makinelerinin denklemi veri noktalarını en iyi şekilde ayırt eden bir hiper düzlemi tanımlayan bir karar sınıfıdır. SVM sınıflandırma Denklemi şu şekildedir;

$$w \cdot x + b = 0 \quad y_i = \text{sign}(w \cdot x_i + b)$$


Denklem 2.31. SVM hiper düzlemi

Burada w ağırlıkları, x girdileri ve b bias değerlerini temsil etmektedir.

Denklem 2.31’de hiper düzlemi, denklem 2.32’de ise SVM karar sınıfı belirtilmektedir.



Şekil 0.8. SVM’in 2 boyutlu gösterimi



Şekil 0.9. SVM’in 3 boyutlu gösterimi

Şekil 2.8'de SVM'nin 2 boyutlu gösterimi verilmektedir. Burada SVM tarafından ayrılan 2 sınıf görülmektedir. İki sınıf arasındaki en yakın noktalar destek vektörleri olarak tanımlanır. Bu destek vektörlerinin maksimum marjını belirlendikten sonra, iki sınıfı ayıran hiper düzlemin konumu belirlenir. Şekil 2.9'da ise iki sınıfı ayıran SVM'in 3 boyutlu gösterimi verilmiştir. Yine burada aynı şekilde hiper düzlemin konumu belirlenmektedir.

SVM'nin bir diğer önemli özelliği genelleme yeteneğinin güçlü olmasıdır. Bu durumda SVM eğitim verileri dışındaki veriler üzerinde de iyi performans gösterebilmektedir. Ancak SVM modelinin aşırı uydurmaya gitmemesi için parametrelerinin uygun bir şekilde ayarlanması gerekmektedir. SVM'nin dezavantajlarından biri büyük veri kümeleri üzerinde eğitilirken hesaplama açısından maliyetlidir. Özellikle doğrusal olmayan problemlerde ve yüksek boyutlu veri kümelerinde kernel hesaplama maliyetini arttırmaktadır. SVM'nin bir diğer kısıtlayıcı faktörü modelin karmaşıklığıdır. Özellikle çoklu sınıf problemleri için uygulandığında SVM'nin karmaşıklığı artmaktadır. SVM'nin birçok uygulama alanı vardır. Özellikle tıp, ekonomi, görüntü tanıma ve metin sınıflandırma gibi alanlarda sıkça kullanılmaktadır (C. C. Chang & Lin, 2011a).

SVM etkili sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenimi algoritmasıdır. Doğrusal ve doğrusal olmayan problemleri çözmede ve birçok uygulama alanında başarıyla kullanılmaktadır.


2.10. Yapay Sinir Ağları (YSA)

Yapay sinir ağları günümüzde hemen hemen her sektörde kullanılmaktadır. Görüntü işleme alanında, nesne tanıma ve yüz tanıma teknolojileriyle güvenlik sistemlerinin güçlendirilmesi ve otomasyon sistemlerinin geliştirilmesi mümkün olmaktadır. Tıp alanında YSA, tıbbi görüntüleme cihazlarından elde edilen verileri analiz ederek hastalık teşhisi ve tedavi planlaması süreçlerinde önemli bir rol oynamaktadır. Enerji sektöründe enerji talebi tahmini ve yenilenebilir enerji üretim optimizasyonu gibi alanlarda kullanılarak enerji verimliliği artırılır. Otomotiv, havacılık endüstrilerinde otonom araç teknolojileri ve uçuş güvenliği gibi kritik konularda YSA önemli bir rol oynar. Üretim endüstrisinde üretim süreçlerinin izlenmesi ve verimliliğin artırılması için makine arızası tahmini ve bakım optimizasyonu gibi alanlarda kullanılmaktadır. Doğal dil işleme alanında ise dil çevirisi gibi uygulamalarla iletişim ve hizmet alanlarında büyük bir katkı sağlar. Bu

örnekler, yapay sinir ağlarının çok çeşitli alanlarda ne kadar yaygın bir şekilde kullanıldığını ve potansiyellerinin genişliğini göstermektedir.


2.10.1. Yapay Sinir Ağlarının Biyolojik Temelleri

YSA biyolojik sinir sistemlerinden ilham alarak tasarlanmış matematiksel modellerdir. YSA biyolojik sinir sistemlerinin işleyişini taklit ederek derin öğrenme ve yapay zekâ gibi alanlarda çeşitli uygulamalara olanak sağlamaktadır. Yapay sinir ağlarının bu biyolojik temelleri bilgisayar bilimi, nörobilim ve yapay zekâ alanları arasında önemli bir köprü oluşturmaktadır. YSA insan zekâsını ve öğrenme yeteneklerini anlamak ve taklit etmek için güçlü bir araçtır.




Şekil 0.10. Biyolojik sinir hücresi (Kaynak: Ma & Tang, 2017)

Şekil 2.10’da görüleceği üzere sinir hücresinde çekirdek bulunmaktadır. Çekirdekten çıkan veri akson boyunca devam etmekte ve başka bir sinir hücresinin dendritlerine bağlı olan akson terminalleri vasıtasıyla veri aktarımı gerçekleşmektedir. Akson terminalleri ve dendritlerin bağlı olduğu noktalara sinaps denilmektedir. Çekirdeğe diğer sinir hücrelerinden iletilen veriler çekirdekte işlenerek diğer sinir hücrelerine aktarılmaktadır.



Şekil 0.11. Yapay sinir hücresinin matematiksel modellemesi

Biyolojik sinir hücresinin veri işleme ve aktarım sürecini matematiksel modellemesi Şekil 2.11’de gösterilmektedir. Burada başka bir yapay sinir hücresinden gelen giriş bilgileri ağırlıklarla çarpılarak sinir hücresine iletilmektedir. Buradaki ağırlıkların biyolojik sinir hücresindeki karşılığı dentritlerdir. Ağırlıklarla çarpılan giriş bilgileri toplanarak bir bias değeri eklenmektedir. Daha sonra toplam değer bir aktivasyon fonksiyonundan geçirilerek bir sonraki katmandaki yapay sinir hücresine veri aktarılmaktadır. Yapay sinir hücresi bu şekilde çalışmaktadır.




Şekil 0.12. YSA modeli

Her sinir hücresinin veri değeri hesaplanır ve Şekil 2.12’de görüleceği üzere sinir hücreleri seri ve paralel olacak şekilde bağlanmaktadır. Sinir ağı giriş, çıkış ve gizli katmanlardan oluşmaktadır. Birden fazla gizli katmandan oluşan sinir ağlarına çok katmanlı sinir ağı (derin sinir ağları) denilmektedir. Eğer sinir ağının bir adet gizli katmanı bulunuyorsa sinir ağına tek katmanlı sinir ağı denilmektedir.

2.10.2. Tek Katmanlı Sinir Ağları

Yapay sinir ağlarının en basit türü mantık devrelerindeki kapılarla benzerlik gösterir. Bu ağlar genellikle bir veya daha fazla giriş alır ve tek bir çıkış üretir. Girişler biyolojik sinir hücrelerinde olduğu gibi sinapslar boyunca iletilir ve ağırlıklarla çarpılarak bir eşik değerinden geçirilmektedir. 1995’te Vladimir Vapnik, sınıf dağılımlarını tahmin etmenin sınırlarını belirlemekten daha zor olduğunu ve basit bir problemi çözmek için daha karmaşık bir problemi çözmenin gereksiz olduğunu öne sürmüştür. İki sınıf olduğunda bu sınıfların dış çevresini belirlemek yerine bir sınıfı diğerinden ayıran bir sınırı tanımlamak daha kolay ve doğrusal bir problem olarak kabul edilebilmektedir.




Şekil 0.13. Tek katmanlı sinir ağı ile sınıf ayrımı

Şekil 2.13’te görüleceği üzere iki sınıfı tek bir doğruyla ayırmak mümkündür. Bu da tek katmanlı bir sinir ağıyla gerçekleştirilir.

Mantık kapıları tek katmanlı ve çok katmanlı sinir ağları ile modellenmektedir. VE-VEYA kapıları iki sınıflı çıkış üreten tek ayraçla modellenebilen tek katmanlı sinir ağı problemleridir. VE kapısında iki giriş vardır ve çıkışlar girişlere göre 0 ve 1 değerlerini almaktadır. Şekil 2.14’te görüleceği üzere sinir hücresine bir eşik değeri verilmiştir. Bu eşik değeri 1,5 olarak verilmiştir. Eğer giriş değerleri toplamı 1,5’in üzerinde olursa çıkış

1, 1,5'in altında olursa çıkış 0 olacaktır. Burada girişler x_1 ve x_2 görülmektedir. Girişlerin değerlerine göre çıkışta 4 adet farklı sınıf oluşmaktadır. Bu sınıflar (0,0), (0,1), (1,0), (1,1) olarak çıkmaktadır. Bu modelleme tek katmanlı sinir ağının (perceptron) çalışma şeklidir.



Şekil 0.14. VE kapısının sinir ağı ile modellenmesi

$$y = e(x_1 + x_2 - 1.5)$$

Denklem 2.32. YSA sınıflandırma


$$x = [1, x_1, x_2]^T$$

Denklem 2.33. YSA giriş transpozu

$$w = [-1.5, 1, 1]^T$$

Denklem 2.34. YSA ağırlık transpozu

Şekil 2.14'te eşik değeri 1,5 olarak alındığında siyah çizgi sınıf ayırıcı olmaktadır. Burada eşik değeri 1'den küçük olduğunda ayıraç kırmızı olacaktır. Bu durumda sınıf ayrımları hatalı olacaktır. Denklem 2.33, 2.34 ve 2.35'te giriş, çıkış ve ağırlıkların vektörel karşılıkları görülmektedir.



Şekil 0.15. VEYA kapısının sinir ağı ile modellenmesi

Şekil 2.15'te benzer durumda 'VEYA' kapısının tek katmanlı sinir ağında gösterimi görülmektedir. Burada eşik değeri 0,5 seçilmiştir. Sadece girişlerin (0,0) olduğu durumda çıkış 0'dır. Diğer durumlarda çıkış 1'dir.


Tek katmanlı sinir ağlarıyla 'VE' kapısı ve 'VEYA' kapısı modellenmesi yapılmaktadır. Fakat 'ÖZELVEYA' kapısının modellenmesi tek katmanlı sinir ağı ile yapılamaz. Bu sorun giriş ve çıkış katmanı arasına gizli katman ekleyerek çözülmektedir.

2.10.3. Çok Katmanlı Sinir Ağları

Çok katmanlı sinir ağları yapay sinir ağları içindeki özel bir yapıdır. Algılayıcı ve sınıflandırma görevlerinde kullanılmaktadır. Tek katmanlı sinir ağından farklı olarak çok katmanlı sinir ağları birden fazla katmana sahiptir ve genellikle daha karmaşık problemleri çözmek için kullanılmaktadırlar. Bu yapıdaki amaç insan beynindeki sinir ağlarının çalışma şeklini taklit ederek çeşitli problemlere çözümler üretmektir. Bu nedenle çok katmanlı sinir ağları genellikle daha derin ve karmaşık bir model oluşturarak daha iyi sonuçlar elde etmeye yöneliktir (Agrawal vd., 2014).


İnsan beyni ve bilgisayarlar arasında temel farklar bulunmaktadır. Beyin çok sayıda sinir hücresinden oluşan karmaşık bir ağa sahiptir. Bilgisayarlar genellikle tek bir işlemciye sahipken insan beyninde ortalama 100 milyar adet bulunmaktadır. Nöronlar bilgisayar işlemcilerinden daha basit ve yavaştır ancak aralarındaki bağlantılar sayesinde yüksek

hesaplama gücüne sahiptirler. Bir nöron ortalama olarak 10.000 nöronla bağlantılıdır. Beyindeki işlemler bu bağlantılar aracılığıyla dağıtılmış bir şekilde gerçekleşmektedir. İnsan beyindeki bu sistem belleğin işlemlerle birlikte ağ üzerinde dağıtıldığı ve bellek bilgilerinin bağlantılar aracılığıyla taşındığı anlamına gelmektedir (Searle, 1990).




Şekil 0.16. Derin yapay sinir ağı modeli (Kaynak: Bahi & Batouche, 2018)

Şekil 2.16’da görüleceği üzere giriş ve çıkış katmanlarının arasına gizli katmanların eklenmesiyle çok katmanlı sinir ağı oluşmaktadır.



Şekil 0.17. ÖZEL VEYA kapısının sinir ağı ile modellenmesi

Şekil 2.17’de görüleceği üzere gizli katman eklenerek ÖZEL VEYA kapısının modellenmesi yapılmaktadır. Burada gizli katman sayesinde bir adet ayıraç eklenmektedir. Bu sayede sınıflandırma doğru bir şekilde yapılmaktadır. Sınıflandırma işlemlerinde tek katmanlı sinir ağlarıyla çözülemeyen problemler çok katmanlı sinir ağlarıyla katman sayılarının artmasıyla rahatlıkla çözülmektedir.



Şekil 0.18. Sinir Ağı İşlemleri (Kaynak: Rumelhart vd., 1986)

$$y_i = v_i^T z = \sum_{h=1}^H v_{ih} z_h + v_{i0}$$

Denklem 2.35. YSA çıkış değeri

$$z_h = \text{sigmoid}(w_h^T x) = \frac{1}{1 + \exp[-(\sum_{j=1}^d w_{hj} x_j + w_{h0})]}$$


Denklem 2.36. YSA aktivasyon fonksiyonu çıkışı

Şekil 2.18’de sinir ağı işlemleri görülmektedir. Burada giriş katmanından gelen bilgiler ağırlıklarla çarpılarak toplanmaktadır. Daha sonra ağırlıklarla girdilerin çarpımlar toplamı bir aktivasyon fonksiyonundan geçirilerek bir sonraki katmanın girdisi olarak aktarılmaktadır. Bu işlem adımına ileri besleme denilmektedir. Denklem 2.35’te çarpımlar toplamı ve denklem 2.36’da aktivasyon fonksiyonu işlemleri görülmektedir.

2.10.4. Denetimli Öğrenme

Denetimli öğrenme, makine öğrenmesinin bir alt dalıdır. Önceden etiketlenmiş veri kümesini kullanarak girişler ile çıktılar arasındaki ilişkiyi öğrenir. Denetimli öğrenme veriye dayalı örüntüleri tanımlamak ve gelecekteki girişler için tahminler yapmak için kullanılmaktadır. Denetimli öğrenme, sınıflandırma ve regresyon olarak iki ana kategoride incelenmektedir. Sınıflandırma bir girişin bir dizi kategoriden hangisine ait olduğunu belirlemeyi amaçlamaktadır. Regresyon ise bir girişin sürekli bir çıktıyla nasıl eşleştirileceğini belirlemeyi amaçlamaktadır (Domingos, 2012). Denetimli öğrenme algoritmaları arasında çok çeşitli teknikler bulunmaktadır. Bunlar arasında en yaygın olanları şunlardır:

- Lineer Regresyon
- Destek Vektör Makineleri (SVM)
- Karar Ağaçları
- Rastgele Ormanlar
- Yapay Sinir Ağları




Şekil 0.19. Denetimli öğrenme işlem akışı

Şekil 2.19’da denetimli öğrenme modelinin işlem akışı görülmektedir. Etiketli veriler giriş verisi olarak alınır ve algoritmada etiketli veriler işlenmektedir. Bir gözetimci eğitim işlemi istenilen çıktıya ulaşmaya kadar işlemi denetlemektedir. Daha sonra etiketli veriler haricinde test verileri ile algoritmanın başarısı ölçülmektedir. Denetimli öğrenme bu şekilde çalışmaktadır.

2.10.5. Denetimsiz Öğrenme

Denetimsiz öğrenme, denetimli öğrenme gibi makine öğrenmesinin bir alt dalıdır. Genellikle etiketlenmemiş veri kümelerinden kalıpları ve yapıları çıkarmak için kullanılmaktadır. Denetimsiz öğrenmede modelin eğitim verisi üzerinde önceden tanımlanmış hedef çıkışları (etiketler) yoktur. Bunun yerine model, veri setindeki yapıları algılayarak ve öznitelikleri keşfederek öğrenme işlemini gerçekleştirmektedir (Hinton & Sejnowski, 1999).

Denetimsiz öğrenme algoritmaları genellikle kümeleme, boyut indirgeme ve özellik çıkarma gibi görevlerde kullanılmaktadır. Kümeleme algoritması belirli bir özellik uzayındaki veri noktalarını gruplara ayırır. Boyut indirgeme algoritmaları yüksek boyutlu veri kümesinden önemli öznitelikleri koruyarak boyutu azaltır. Özellik çıkarma algoritmaları ise veri setindeki önemli özellikleri tanımlamak için kullanılmaktadır. K-Means kümelemede, PCA (Temel Bileşenler Analizi) boyut indirgemedede, ICA (Bağımsız Bileşenler Analizi) özellik çıkarmada başlıca kullanılan denetimsiz öğrenme algoritmalarıdır (Murphy, 2012).



Şekil 0.20. Denetimsiz öğrenme işlem akışı

Şekil 2.20’de denetimsiz öğrenme modelinin işlem akışı görülmektedir. Burada veri seti etiketlenmeden özellikler çıkarılmaktadır. Daha sonra özelliklere ve veri setinin yapısına göre sınıflar belirlenmektedir. Çıkışta ise belirlenen sınıflara göre veri seti ayrıştırılmaktadır.

2.10.6. YSA'da Öğrenme İşlemi

YSA'da öğrenme ileri yayılım ve geriye yayılım algoritmaları ile gerçekleşmektedir. Sinir ağlarında giriş verilerinin ağ boyunca ilerleyerek çıktı üretme süreci ileri yayılım algoritmasıdır. Bu süreçte girişler ve ağırlıkların çarpımlar toplamı alınarak bir bias değeri eklenir. Daha sonra bias değeri eklenen değer, aktivasyon fonksiyonlarına sokularak katmanlar arasında iletilmektedir (Lecun vd., 2015).

$$z = \sum_{i=1}^n (w_i x_i) + b$$

Denklem 2.37. YSA nihai çıkış

w, ağırlık değerleridir.

x, giriş değerleridir.

$$a = f(z)$$

Denklem 2.38. YSA aktivasyon fonksiyonu çıkışı

Denklem 2.38'de ağırlıklar (w_i) ile girişlerin (x_i) çarpımları toplamı alınmaktadır. Denklem 2.39'da ise z değeri bir aktivasyon fonksiyonuna tabi tutulmaktadır. Aktivasyon fonksiyonunun çıktısı bir sonraki katmanın girişini oluşturmaktadır. Aktivasyon fonksiyonunun kullanılmasının sebebi daha karmaşık verileri çözmek için sistemi doğrusallıktan çıkarmaktır. Bu işlemler son katmanda bir çıktı üretilinceye kadar devam etmektedir. Nihai çıktı üretildikten sonra bir kayıp (loss) fonksiyonu üretilerek ileri yayılım algoritmasının tam tersi olacak şekilde geriye yayılım algoritması uygulanmaktadır (I. Goodfellow vd., 2016).

Geriye yayılım algoritması YSA'nın eğitimlerinde kullanılan önemli bir algoritmadır. Burada ağın çıkışında hata değerine göre ileri yayılımın tam tersi olacak şekilde geri yayılım yapılarak ağırlıklar ve bias değerlerinin güncellenmesi sağlanmaktadır.

Geriye yayılımda ilk olarak çıkış hata değeri hesaplanır. Hata değeri genellikle bir kayıp fonksiyonu kullanılarak ölçülmektedir. Ortalama karesel hata veya çapraz entropi sık kullanılan kayıp fonksiyonlarıdır (Rumelhart vd., 1986; Nielsen, 2015).

Denklem 2.39'da çapraz entropi kayıp fonksiyonu Denklemi görülmektedir. İki olasılık arasındaki fark alınmaktadır. İki sınıf dağılımı birbirine yakınsa çapraz entropi değeri düşük, sınıf dağılımı uzaksa çapraz entropi değeri yüksektir.

$$H(y, \hat{y}) = -\sum_{i=1}^n y_i \log(\hat{y}_i)$$

Denklem 2.39. Çapraz entropi

y , çıkış değerleridir.

Denklem 2.40'ta ortalama karesel hata denklem görülmektedir. Gerçek değer ile tahmin edilen değer arasındaki farkın karesi alındıktan sonra hata değeri hesaplanmaktadır.

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$


Denklem 2.40. Karesel hata

Hata değeri hesaplandıktan sonra her ağırlık ve bias için hata fonksiyonunun gradyan eğimi hesaplanmaktadır. Bu işlem zincir kuralı kullanılarak gerçekleştirilmektedir. Öncelikle çıktı katmanından başlayarak geriye doğru ilerlemektir ve her katmandaki gradyanlar hesaplanmaktadır. Gradyan hesaplama denklem 2.41'de görülmektedir.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial z_j} \frac{\partial z_j}{\partial w_{ij}}$$

Denklem 2.41. Gradyan hesabı

Her ağırlık ve bias değerlerinin hata fonksiyonuna göre gradyanları alındıktan sonra öğrenme oranıyla gradyanlar çarpılarak ağırlıklar ve bias değerleri güncellenmektedir. Denklem 2.43'de öğrenme oranı ile gradyan çarpımı görülmektedir.



Şekil 0.21. Maliyet fonksiyonunda ağırlıkların güncellenmesi


$$w_{ijnew} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}}$$

Denklem 2.42. Ağırlık güncelleme

η , öğrenme oranıdır.

E, toplam hatadır.

Şekil 2.21’de optimizasyon algoritması kullanılarak minimum hatanın olduğu bölge bulunmaktadır. Minimum hatanın olduğu bölgedeki ağırlıklar o ağ modelinin en iyi sonuç verdiği ağırlıklardır. Denklem 2.42’deki gradyanların çarpımında kullanılan öğrenme oranı (η) ağırlıkların güncellenmesinde kullanılan önemli bir parametredir. Öğrenme oranı (adımı) 0-1 arasında bir sayıdır. Eğer yüksek alınırsa optimizasyon algoritmasıyla yerel minimuma gidilirken yerel minimumun kaçırılmasına neden olabilir. Çok düşük alınması ise ağırlık işlem yükünü artırdığı için en optimum şekilde ayarlanması gerekmektedir. Şekil 2.22’de öğrenme adımıyla maliyet fonksiyonunda minimum noktaya inilmesi gösterilmektedir.




Şekil 0.22. Öğrenme oranı (adımı)

Bu adımlar takip edilerek geriye yayılım algoritması giriş katmanına kadar devam eder ve güncellenen ağırlıklar ve bias değerlerine göre ileri yayılım algoritması tekrar başlamaktadır. Ağırlık iterasyon sayısı kadar bu güncelleme işlemleri devam etmektedir.

2.10.7. YSA'da Optimizasyon ve Regularizasyon

Makine öğrenmesinde öz nitelik çıkarmak ve seçmek oldukça kritik bir süreçtir. Model eğitim sırasında gösterdiği performansla belirlediği önemli ve önemsiz nitelikler arasından önemsiz olanları elemek ve eğitimde yalnızca önemli olanları kullanmak suretiyle öz nitelik seçme sürecini gerçekleştirmektedir. Derin öğrenmede ise katmanlar boyunca öz nitelikler otomatik olarak seçilip çıkarılmaktadır. Katmanlar boyunca öz nitelikleri belirlenen ağ modellerinde kullanıcı sadece mimariyi belirler. Burada mimariyi tasarlarken katman sayısı, nöron sayısı, optimizasyon algoritmaları ve öğrenme oranı gibi hiper parametrelerin belirlenmesi gerekmektedir.



Şekil 0.23. YSA model eğitim ve test işlemleri

Şekil 2.23'te görüleceği üzere veri setinin sisteme verilmesiyle eğitim ve test hatalarının sürekli düştüğü ancak test hatasının aniden arttığı durum eğitim ve test işlemlerinde sıkça karşılaşılan bir durumdur. Bu durumu düzeltmek için doğru hiper parametrelerin seçilmesi ve güncellenmesi gerekmektedir.


Hiper parametreler veri seti, donanım ve problem özelliklerine bağlı olarak değişen koşulların etkileşimiyle oluşur ve bu etkileşim sonucunda modelin yapısı belirlenmektedir. Derin öğrenme modelleri için bol ve çeşitli verilere sahip olmak çok önemlidir. Ancak aynı zamanda gerçek dünyayı da yansıtmaları gerekmektedir. Eğitim süresi ve optimizasyon yöntemleri modelin başarısını etkileyebilir. Dolayısıyla farklı yaklaşımlarla deneme yapılmasına gerek duyulmaktadır. Çeşitli optimizasyon algoritmalarını ve ağ mimarilerini denemek model performansını değiştirmektedir.

2.10.7.1. Aktivasyon Fonksiyonları

Sinir ağlarında öğrenmeyi sağlamak için uygun aktivasyon fonksiyonu seçimi oldukça önemlidir. Geriye yayılım işlemi sırasında türevin sıfır olduğu noktalarda işlem yükü azalır. Ancak bu noktalarda öğrenme gerçekleşmez. Bu da YSA eğitimde istenmeyen bir durumdur. Şekil 2.24'te görüldüğü gibi sigmoid aktivasyon fonksiyonu 0 ile 1 arasında değer almaktadır. Ancak türevin maksimum değeri oldukça düşük olup bazı bölgelerde sıfıra yakındır .(Hastie vd., 2001)

$$f(x) = \frac{1}{1 + e^{-x}}$$

Denklem 2.43. Sigmoid




Şekil 0.24. Sigmoid fonksiyonu

Hiperbolik tanjant fonksiyonu -1 ile 1 arasında değerler almakta olup sigmoid fonksiyonu gibi üstel fonksiyondur. Şekil 2.25'de görüldüğü gibi hiperbolik tanjantın türevinin alacağı maksimum değer 1'dir ve sıfıra yakın olan değerler de almaktadır. Sigmoid fonksiyonunda olduğu gibi sıfıra yakın olan değerlerde öğrenme işlemi daha düşük olmaktadır (Chollet, 2017).

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Denklem 2.44. Hiperbolik tanjant




Şekil 0.25. Hiperbolik tanjant fonksiyonu

ReLU (Rectified Linear Units) fonksiyonu basamak fonksiyonudur. Şekil 2.26’da görüldüğü gibi giriş pozitif olduğunda doğrudan giriş değerini çıkışa verirken, giriş negatif olduğunda çıkış sıfır olmaktadır. Geriye yayılımında türevide 1 olarak çıkmaktadır (He vd., 2015).

$$\text{ReLU}(x) = \max(0, x)$$

Denklem 2.45. ReLU




Şekil 0.26. ReLU fonksiyonu

Leaky ReLU 0’dan büyük olan değerlerde ReLU gibi çıkış vermektedir. Şekil 2.27’de görüldüğü gibi 0’dan küçük olan değerlerde bir çıkış olmaktadır. Bu durumda öğrenme oranı artacaktır. Fakat işlem yükü de artacaktır. 0’dan büyük olan değerlerde türevi 1, 0’dan küçük olan değerlerde 0’a yakın küçük bir değer almaktadır. (Xu vd., 2015)

$$f(x) = \max(0.1x, x)$$

Denklem 2.46. Leaky ReLU




Şekil 0.27. Leaky ReLU fonksiyonu

Swish Fonksiyonu Google Brain araştırmacıları tarafından tanıtılmıştır. Şekil 2.28’de görüldüğü gibi 0’dan büyük ve küçük olan değerlerde çıkış vermektedir. Aynı şekilde 0’dan büyük ve küçük olduğu değerlerde türevlenebilmektedir. Swish, giriş değeri ile sigmoid fonksiyonu arasındaki çarpım yoluyla tanımlanır (Misra, 2019).

$$f(x) = x \frac{1}{1 + e^{-x}}$$

Denklem 2.47. Swish




Şekil 0.28. Swish fonksiyonu

2.10.7.2. D ğ m Ekleme ve Seyreltme

Makine  ğreniminde d ğ m ekleme karmařık modellerin  ğrenme kapasitesini artırmak i in sinir ağındaki n ronların sayısını artırmayı i ermektedir. Bu durum modelin eđitim verileri  zerindeki performansını artırabilir. Ancak aynı zamanda ařırı uyum riskini de artırabilmektedir. Sinir ağılarına n ron eklenmesi iřlem y k n  artırmakla birlikte performansı da olumlu etkilemektedir. Bu durumun tam tersi d ğ m seyreltme (dropout) iřlemi de sinir ağılarında yapılan bir iřlemdir. Katmanlardaki d ğ m seyreltme iřlemi bir eřik deđeri belirleyerek eřik deđerinin altındaki n ronların silinmesidir. D ğ m seyreltme ile gereksiz n ronlar ortadan kaldırılarak yeni verilere daha iyi genelleme sađlanır ve verimi y ksek bir model ortaya  ıkar. Bu sayede ařırı uyum azalır ve daha d ř k bellek kullanımıyla sonu lanır (Han vd., 2015; Molchanov vd., 2016).

řekil 2.29'da sinir ağılarında d r m seyreltme iřlemi g r lmektedir.



řekil 0.29. D ğ m seyreltme (Dropout)

2.10.7.3. Gradyan İniř (Gradient Descent) Algoritmaları

Gradyan iniř (gradient descent) makine  ğrenmesi modellerinin eđitiminde yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Maliyet fonksiyonunu minimize etmek i in gradyan iniř algoritmaları kullanılmaktadır. Kendine  zg  avantajları ve dezavantajları olan gradyan iniř algoritmaları bulunmaktadır (Ruder, 2016b). Yaygın olarak kullanılan gradyan iniř algoritmaları řunlardır;

Temel gradyan iniş, bir fonksiyonun en düşük değerini bulmak için kullanılan bir yöntemdir ve genellikle makine öğrenimi modellerini optimize etmek için kullanılan algoritmalarındandır. Bu yöntemde model parametreleri (ağırlıklar ve bias değerleri) rastgele bir başlangıç değerleriyle başlamaktadır. Tüm eğitim veri seti kullanılarak kayıp fonksiyonunun gradyanları hesaplanır ve bu gradyanlara göre parametreler güncellenmektedir. Bu süreç belirli bir süre boyunca (epoch sayısı) veya modelden istenilen performansa ulaşana kadar tekrarlanmaktadır. Gradyan iniş, her adımda eğime göre parametreleri güncelleyerek minimum noktaya yaklaşmayı hedefler. Ancak büyük veri setlerinde hesaplama maliyeti diğer gradyan iniş algoritmalarına göre yüksektir (Ruder, 2016a).

$$x = x - \alpha \nabla f(x)$$

Denklem 2.48. Gradyan iniş

SGD (Stokastik Gradyan İniş), makine öğrenimi modellerinin eğitiminde sıkça kullanılan bir optimizasyon algoritmasıdır. Her iterasyonda yalnızca bir eğitim örneği kullanılarak kayıp fonksiyonunun gradyanı hesaplanıp model parametreleri güncellenmektedir. Bu yaklaşım büyük veri setleri için uygun hesaplama maliyeti sağlamaktadır. SGD genellikle hızlı bir başlangıç yakınsaması sunmaktadır. Ancak gradyanların gürültülü ve değişken olması nedeniyle optimizasyon sürecinde kararsızlık (harmonikler) yaşanmaktadır (Kingma & Ba, 2014).

SGDM (Momentumlu Stokastik Gradyan İniş), SGD algoritmasının bir türevidir ve genellikle momentum terimiyle birlikte kullanılmaktadır. SGDM gradient inişin gürültülü ve değişken doğasıyla başa çıkmak için gradyan güncellemelerini biraz düzelten ve daha kararlı bir optimizasyon süreci sağlayan bir yöntemdir. Her iterasyonda SGD'den farklı olarak SGDM'in son gradyan güncellemesini kullanarak yeni gradyan güncellemelerini hızlandıran bir momentum terimi bulunur. Bu momentum gradyanın önceki güncellemeleriyle birlikte hesaplanan bir vektördür ve güncel gradyanı bir tür ortalama olarak düzgünleştirir. Bu düzgünleştirme, gradyanın daha tutarlı bir yön belirlemesine ve daha hızlı bir şekilde minimuma doğru ilerlemesine yardımcı olmaktadır. Sonuç olarak SGDM standart SGD'ye kıyasla daha hızlı ve daha kararlı bir optimizasyon süreci sağlamakta ve derin öğrenme modellerinin eğitiminde yaygın olarak tercih edilen bir optimizasyon algoritmasıdır (Sutskever vd., 2013; Qian, 1999).

$$v = \beta v + \alpha \nabla f(x)$$

Denklem 2.49. SGD

$$x = x - v$$

Denklem 2.50. SGD ağırlık güncelleme

Mini-batch gradyan inişi, bir fonksiyonun (hata-kayıp fonksiyonu) en düşük değerini bulmak için kullanılan ve makine öğrenimi modellerinin eğitiminde yaygın olarak tercih edilen bir optimizasyon yöntemidir. Bu yöntemde diğer yöntemlere benzer şekilde model parametreleri başlangıçta rastgele seçilmektedir. Tüm veri seti yerine veri setinden küçük bir örnek grubu (mini-batch) seçilir ve bu mini-batch üzerinde kayıp fonksiyonunun eğimi hesaplanmaktadır. Bu eğime göre parametreler güncellenir ve bu adımlar belirli bir süre boyunca veya model istenilen performansa ulaşana kadar tekrarlanmaktadır. Mini-batch gradyan inişi hesaplamaları hızlandırır ve daha dengeli güncellemeler yaparak optimizasyon sürecini verimli hale getirmektedir (Hinton vd., 2012).

RMSProp (Kök Ortalama Kare Yayılım), optimizasyon sürecinde öğrenme oranını adaptif hale getirmek için kullanılan bir yöntemdir. Bu yöntem her parametre güncellemesinde gradyanların karelerinin ortalamasını kullanarak her adımda öğrenme oranını ayarlamaktadır. Bu sayede sık karşılaşılan gradyan patlaması ve sönümlenmesi sorunlarını azaltarak daha dengeli ve hızlı bir yakınsama sağlamaktadır. RMSProp özellikle derin öğrenme modellerinde dalgalı veya gürültülü gradyanlara sahip karmaşık kayıp fonksiyonlarında etkili bir performans sunmaktadır (Tieleman, 2012; Dauphin vd., 2014).

$$v = \beta v + (1 - \beta)(\nabla f(x))^2$$

Denklem 2.51. RMSProp

$$x = x - \alpha \frac{\nabla f(x)}{\sqrt{v} + \epsilon}$$

Denklem 2.52. RMSProp ağırlık güncelleme

Adam (Adaptive Moment Estimation), makine öğreniminde yaygın olarak kullanılan bir gradyan tabanlı farklı bir optimizasyon algoritmasıdır. Adam momentum ve RMSProp algoritmalarının birleşimidir ve her bir parametre için adaptif bir öğrenme oranı sağlamaktadır. İki önemli özellikle dikkat çeker; ilk olarak hareketli ortalamaların kullanımıyla gradyanlar düzgünleşmektedir ve ikinci olarak momentum terimi ile

gradyanlarda bir ivme sağlanmasıdır. Böylece Adam daha hızlı ve daha güvenilir bir optimizasyon süreci sağlamaktadır. Adam özellikle büyük veri setleri veya karmaşık model yapıları gibi zorlu optimizasyon senaryolarında etkili bir şekilde çalışmaktadır (Tieleman, 2012).

$$v = \beta_2 v + (1 - \beta_2)(\nabla f(x))^2$$

Denklem 2.53. Adam

$$m_{\text{hat}} = \frac{m}{1 - \beta_1^t} \quad v_{\text{hat}} = \frac{v}{1 - \beta_1^t}$$

Denklem 2.54. Adam momentleri

$$x = x - \alpha \frac{m_{\text{hat}}}{\sqrt{v_{\text{hat}} + \epsilon}}$$

Denklem 2.55. Adam ağırlık güncelleme

2.53-2.55'deki denklemlerde kullanılan sembollerin anlamları şu şekildedir:

$\nabla f(x)$, $f(x)$ fonksiyonun gradyanıdır.


α , öğrenme oranı temsil etmektedir.

β ve β_2 Adam algoritmasında kullanılan eksponansiyel azalma oranlarıdır.

m ve v moment değerleridir.

t , iterasyon değeridir.

ϵ , sıfıra bölme hatasını azaltmak için kullanılan sıfıra yakın bir sayıdır.




Şekil 0.30. Optimizasyon algoritmalarının 3 boyutlu gösterimi

Şekil 2.30’da optimizasyon algoritmalarının belirli bir öğrenme oranı ile nasıl çalıştığı görülmektedir. Burada J maliyet fonksiyonu olup amaç yerel minimumuma inerek en düşük hata oranındaki ağırlıklar ve bias değerlerini (θ_1 ve θ_0) bulmaktır.

2.10.7.4. Aşırı ve Az Uyum (Overfitting-Underfitting)

Aşırı uyum (Overfitting) bir modelin eğitim veri setine yüksek derecede uyum sağlaması ve genelleme yeteneğini kaybetmesidir. Bu durumda model, eğitim verilerine çok iyi uyum sağlamaktadır. Fakat eğitim veri setinin dışında görünmemiş farklı verilere uygulandığında performans düşüklüğü olmaktadır. Aşırı uyum genellikle modelin aşırı karmaşık olması veya eğitim verisinin az olması gibi durumlarda ortaya çıkmaktadır. Model bazı durumlarda eğitim veri setindeki verilerde bulunan gürültülere kadar ezberleyecek duruma gelebilmektedir. Bu durumda gerçek dünyadaki verilerle test edildiğinde modelin başarısı oldukça düşük çıkmaktadır (Ng, 1997).

Az uyum (Underfitting) ise modelin eğitim veri setine düşük derecede uyum sağlaması ve veri setindeki özelliklerin yeterince bulunamaması durumunda ortaya çıkmaktadır. Bu durumda model hem eğitim hem de test verilerine karşı düşük performans göstermektedir. Genellikle model parametrelerinin yeterince iyi seçilememesi ve veri seti yetersiz olduğunda az uyum sorunuyla karşılaşılır (Dietterich, 1995).



Şekil 0.31. Aşırı-az uyum ve optimum performans

Makine öğrenmesinde modelin aşırı ve az uyuma giderken bias ve Varyans değerleri de dikkate alınmalıdır. Bias değeri modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğinin bir ölçüsüdür. Yüksek bias modeli az uyuma götürmektedir. Varyans ise modelin farklı eğitim verileriyle eğitildiğinde tahminlerinin ne kadar değişken olduğunun bir ölçüsüdür. Yüksek varyans modelin eğitim verisine çok iyi uyum sağlaması yani aşırı uyuma gitmesi demektir. Şekil 2.31’de düşük-yüksek bias ve varyans değerlerinde modelin durumları görülmektedir. Düşük bias ve varyans değerlerinde model optimum öğrenme durumunda olacaktır.

Aşırı uyum ve az uyum, modelin uygun karmaşıklık seviyesini belirleyemediği durumlarda ortaya çıkmaktadır. Bu durumlarla karşılaşmamak için model karmaşıklığını ayarlamak, veri setini güçlendirmek, eğitim sürecini izlemek ve uygun doğrulama teknikleri kullanılabilir. Eğitim süreci validasyon seti kullanılarak takip edilebilir. Validasyon seti eğitim ve test setinden farklı olarak veri setinin bir kısmının bölünmesiyle oluşmaktadır. Validasyon seti eğitim sürecinde her epoch işleminden sonra aşırı veya az uyuma gitmemesi için veri setinin başarı oranını izlemek için kullanılmaktadır.

2.11. Tekrarlayan Sinir Ağları (RNN)

RNN, zaman serisi verilerini veya ardışık verileri işleyebilen bir tür yapay sinir ağıdır. İleri beslemeleri ve evrişimli sinir ağları (CNN) gibi RNN’lerde öğrenmek için eğitim verilerini kullanmaktadır. Ancak RNN’ler önceki girdilerden gelen bilgileri alarak mevcut girdi ve çıktıyı etkiledikleri için hafıza özelliği ile ayırt edilmektedir. Geleneksel sinir ağları girdi ve çıktının birbirinden bağımsızken RNN’ler çıktısı dizideki önceki öğelere bağlıdır (Lipton vd., 2015).

Denklem 2.56'te ve 2.57'da gizli durum ve bir sonraki katman için çıkış hesaplanmaktadır.

$$h_t = \tanh(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi})$$


Denklem 2.56. RNN hafıza çıkışı

h , hafıza çıkışıdır.

w , ağırlık değerleridir.

$$o_t = \tanh(W_{oh}h_t + b_{oh})$$

Denklem 2.57. RNN çıkışı



Şekil 0.32. RNN hücre modeli (Kaynak: Yılmaz & Yıldıztepe, 2024)

Şekil 2.32'de basit RNN hücre modeli görülmektedir. Burada aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmaktadır. Klasik RNN modelleri dışında en çok kullanılan modeller; LSTM (Uzun-Kısa Süreli Bellek) ve GRU (Kapı Kontrollü Tekrarlayan Birim)'dur.

2.11.1. Uzun-Kısa Süreli Bellek (LSTM)

LSTM, zaman serisi ve dizilim verilerini modellemek için yaygın olarak kullanılan RNN mimarisidir. LSTM'ler uzun vadeli bağımlılıkları öğrenme ve hatırlama yeteneğine sahip sinir ağlarıdır. Bu özellik klasik RNN'lerin yaşadığı "uzun dönem bağımlılığı" sorununu çözmektedir. LSTM hücresinin çalışma şekli şöyledir;

Unutma kapısı hücre durumundan gereksiz bilgilerin unutulacağına karar veren kapıdır. Denklem 2.58’de unutma kapısı, geçmiş gizli durum (h_{t-1}) ve mevcut giriş kullanılarak hesaplanmaktadır.

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

Denklem 2.58. LSTM

Burada W_f ve b_f sırasıyla ağırlık matrisi ve bias vektörüdür. σ sigmoid fonksiyonudur.

Denklem 2.59 ve 2.60’ta giriş kapısı yeni bilginin ne kadarının hücre durumuna ekleneceği belirlemektedir.

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

Denklem 2.59. LSTM hücre durumu

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Denklem 2.60. LSTM unutma durumu

Hücre durumu denklem 2.61’de unutma kapısı ve giriş kapısı ile güncellenmektedir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

C , unutulmuş değerlerdir.

Denklem 2.61. LSTM unutma ve giriş güncelleme

Çıkış kapısı hücre durumunda hangi bilginin çıktı olarak verileceğine karar veren kapıdır.


Denklem 2.62 ve 2.63’te yeni gizli durum ve çıkış kapısının güncellenmesi görülmektedir.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

Denklem 2.62. LSTM çıkış güncelleme

$$h_t = o_t * \tanh(C_t)$$

Denklem 2.63. LSTM gizli durum güncelleme



Şekil 0.33. LSTM hücre modeli (Kaynak: Yang vd., 2020a)

LSTM hücresi, mevcut giriş (x_t) ve önceki gizli durum (h_{t-1}) değerlerini alarak çalışmaya başlamaktadır. Unutma kapısı geçmiş hücre durumunun hangi kısmının unutulacağına karar verirken giriş kapısı yeni hücre durumu adayını oluşturmaktadır. Daha sonra hücre durumu, unutma ve giriş kapısı bilgileriyle güncellenir. En sonunda çıkış kapısı ise güncellenmiş hücre durumundan hangi bilgilerin çıktıya ve yeni gizli duruma dahil edileceğini belirlemektedir (Graves vd., 2013). Şekil 2.33’de LSTM hücre modelinde unutma kapısı, giriş kapısı ve çıkış kapısı görülmektedir.

2.11.2. Kapı Kontrollü Tekrarlayan Birim (GRU)

GRU, LSTM’e benzer şekilde tekrarlayan sinir ağlarının bir türüdür ve uzun vadeli bağımlılıkları öğrenmede kullanılmaktadır. LSTM’ye göre daha basit bir yapıya sahiptirler ve genellikle daha hızlı ve daha az işlem yükü gerektirir. GRU’da güncelleme kapısı ve resetleme kapısı olmak üzere iki kapı bulunmaktadır.

Güncelleme kapısı, hücre durumunun ne kadarının güncellenebileceğini belirlemektedir. Denklem 2.64’de giriş (x_t) ve önceki gizli durum (h_{t-1}) kullanılarak güncelleme kapısının hesaplanması görülmektedir. W_z ve b_z ağırlık ve bias vektörüdür.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z)$$

Denklem 2.64. GRU güncelleme kapısı

Resetleme kapısı önceki gizli durumun ne kadarının unutulacağını belirlemektedir. Denklem 2.65'te giriş (x_t) ve önceki gizli durum (h_{t-1}) kullanılarak resetleme kapısının hesaplanması görülmektedir.

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) + b_r$$

Denklem 2.65. GRU resetleme kapısı


Denklem 2.66'te gizli durumun ve denklem 2.69'de gizli durum güncellenmesinin hesaplanması görülmektedir. Burada aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonunun kullanıldığı görülmektedir.

$$\tilde{h}_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t]) + b_h$$

Denklem 2.66. GRU gizli durum

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t$$

Denklem 2.67. GRU gizli durum güncelleme



Şekil 0.34 GRU hücre modeli (Kaynak: Yang vd., 2020b)

GRU hücresi, LSTM gibi mevcut giriş ve önceki gizli durum değerlerini alarak çalışmaya başlamaktadır. Şekil 2.34'de GRU modelinin güncelleme ve resetleme kapısı görülmektedir. Güncelleme kapısı, hücre durumunun ne kadarının güncelleneceğini tespit etmektedir. Daha sonra resetleme kapısı önceki gizli durumun ne kadarının unutulacağını belirlemektedir. Son olarak resetleme kapısının önceki gizli duruma uygulanmasıyla

oluşturulan gizli durum adayı, önceki gizli durum ve yeni gizli durum adayının ağırlıklı kombinasyonu ile güncellenmektedir (Graves vd., 2013; Gers vd., 2000).

2.12. Çekişmeli Üretici Ağlar (GAN)

GAN, derin öğrenme alanında önemli bir model türüdür. Bu modelde birbirleriyle rekabet halinde çalışan, biri üretici (generator) diğeri ise ayırt edici (discriminatör) olmak üzere iki ağ mevcuttur. Bu ikili yapı GAN'ların veri üretimi ve modelleme konularında oldukça etkili olmasını sağlamaktadır.

2.12.1. GAN Eğitimi

GAN eğitimi üretici ve ayırt edici ağlarının belirli bir iterasyonla birbirleriyle rekabet ettiği bir yapıya sahiptir. Öncelikle gerçek veri örneklerinden oluşan bir mini batch ve rastgele gürültü vektörlerinden üretici ağ tarafından üretilen sahte veri örnekleri kullanılmaktadır. Ayırt edici ağ bu gerçek ve sahte verileri ayırt etmeyi öğrenir ve ağırlıkları gerçek veri için çıktılarının 1, sahte veri için ise 0 olmasını sağlayacak şekilde güncellenmektedir. Ardından üretici ağ eğitilerek her iterasyonda sahte veriler üretmektedir. Ayırt edici ağ, sahte verileri gerçek (etiket: 1) olarak sınıflandırmaya çalışmaktadır. Üretici ağın ağırlıkları, ayırt edici ağın sahte verileri gerçek olarak sınıflandırma başarısını artıracak şekilde güncellenmektedir. Bu adımlar üretici ve ayırt edici ağın belirli bir performans seviyesine ulaşana kadar tekrarlanmaktadır. Böylece üretici ağ daha gerçekçi veriler üretmeyi öğrenirken ayırt edici ağ bu verileri ayırt etmede daha etkili hale gelmektedir (I. J. Goodfellow vd., 2014).

$$\text{Obj}^D(\theta_D, \theta_G) = -\frac{1}{2} E_{x \sim P_{\text{data}}} [\log D(x)] - \frac{1}{2} E_{x \sim P_Z(z)} [1 - \log D(G(x))]$$

Denklem 2.68. GAN hata hesabı

Denklem 2.70'te ayırt edici ağın kayıp fonksiyonu ifade edilmektedir. θ_D ayırt edici ağın parametrelerini, θ_G üretici ağın parametrelerini temsil etmektedir. $\log D(x)$ ayırt edici ağın gerçek veriyi doğru sınıflandırma olasılığı, $1 - \log D(G(x))$ ayırt edicinin üretici ağ tarafından üretilen sahte veriyi yanlış olarak sınıflandırma olasılığıdır. $E_{x \sim P_{\text{data}}} [\log D(x)]$ ilk terimde gerçek veri dağılımının x örneklerinin ayırt edici ağ tarafından doğru sınıflandırma olasılığının logaritmasını, $E_{x \sim P_Z(z)} [1 - \log D(G(x))]$ rastgele değişken z dağılımından gelen z

örneklerinden üretilen sahte verilerin ayırt edici ağ tarafından yanlış olarak sınıflandırma olasılığının logaritmasını temsil etmektedir (Gonog & Zhou, 2019b).

$$\text{Obj}^D(\theta_D, \theta_G) = -\frac{1}{2} \int_{\mathbf{x}} p_{\text{data}}(\mathbf{x}) \log(D(\mathbf{x})) d_{\mathbf{x}} - \frac{1}{2} \int_{\mathbf{z}} p_{\mathbf{z}}(\mathbf{z}) \log(1 - D(g(\mathbf{z}))) d_{\mathbf{z}}$$

Denklem 2.69. GAN sürekli zaman dilimi

$$\text{Obj}^D(\theta_D, \theta_G) = -\frac{1}{2} \int_{\mathbf{x}} p_{\text{data}}(\mathbf{x}) \log(D(\mathbf{x})) d_{\mathbf{x}} + \frac{1}{2} \int_{\mathbf{z}} p_{\mathbf{g}}(\mathbf{z}) \log(1 - D(g(\mathbf{z}))) d_{\mathbf{z}}$$


Denklem 2.70. GAN sürekli zaman dilimi

Denklem 2.68'in sürekli zaman diliminde yazılışı denklem 2.69 ve 2.70'de görülmektedir. Burada ayırt edici ağın kayıp fonksiyonunun integrali verilmiştir.

$$D^*_G(\mathbf{x}) = \frac{p_{\text{data}}(\mathbf{x})}{p_{\text{data}}(\mathbf{x}) + p_{\mathbf{g}}(\mathbf{x})}$$

Denklem 2.71. GAN optimal

Denklem 2.71'te ayırt edici ağın $\mathbf{x}$ örneğinin gerçek veriden mi yoksa üretilen veriden mi geldiğini optimal fonksiyonla ($D^*_G(\mathbf{x})$) belirlemeye çalışmaktadır. Eğer $\mathbf{x}$ gerçek veri dağılımından geliyorsa bu oran 1'e yakın olacaktır. Aksi durumda oran 0'a yakın olacaktır.




Şekil 0.35. GAN yapısı (Kaynak: Gonog & Zhou, 2019a)

Şekil 2.35'te GAN'ların genel yapısı görülmektedir. Rastgele gürültüler üretici ağı veriliyor ve üretici ağ tarafından rastgele gürültülerle sahte veriler oluşturulmaktadır. Daha sonra sahte verilerle gerçek veriler ayrıştırıcı ağı verilerle gerçek ve sahte verilerin ayrıştırılması istenmektedir. Bu algoritma, iterasyon sayısı kadar tekrarlanarak üretici ağın ayırt edici ağ ile rekabet etmesi ve gerçek verilere en yakın verileri üretmesi amacıyla çalışır. GAN'ların genel olarak çalışması bu şekildedir.



3. YÖNTEM

Bu bölümde çalışmada veri alım işlemleri, veri özellikleri, hangi yöntemleri kullanıldığı ve uygulanan yöntemlerin sonucu veri çıktılarına değinilmiştir. Çalışmada sigara bağımlısı olan ve olmayan bireylerin EEG verileriyle sınıflandırmasının yapılması amaçlanmıştır. Öncelikle Şekil 3.1’de çalışmanın akış diyagramında görüleceği üzere ham EEG verileri, GAN ile çoğaltılmıştır. Daha sonra DWT ile EEG verileri frekans alt bileşenlerine ayrılmıştır. Her bir frekans alt bileşeninin, (delta, teta, alfa, beta ve gama) zaman ve frekans domaininde özellik çıkarımı işlemleri yapılmıştır. Frekans domaininde özellik çıkarımı için Spektral Güç Yoğunluğu (PSD) analizi yapılmıştır. Zaman domaininde ise özellik çıkarımı yöntemi olarak 15 farklı özellik (ortalama, varyans, Wilson genliği vb.) çıkarılmıştır. Bu işlemler sonucu değişen EEG verisi matris boyutlarının çıktıları, şekilsel olarak gösterilmiştir. En sonunda, sınıflandırma için kullanılan makine öğrenmesi algoritmalarına değinilmiştir. Algoritmaların yapıları ve parametreleri hakkında ayrıntılı bilgiler sunulmuştur.



Şekil 0.1. Çalışma ana akış diyagramı

3.1. EEG Veri Alım İşlemleri

EEG verilerinin toplanması, bağımlılık tespiti için kritik bir adımdır. Veri toplama sürecine başlamadan önce, Yozgat Bozok Üniversitesi Klinik Araştırmalar Etik Kurulu'ndan gerekli onaylar alınmıştır. Onay alındıktan sonra, veri alım işlemlerine başlanılmıştır. Bu bölümde,

veri alım işlemleri sırasında dikkat edilen hususlar, kullanılan EEG cihazının özellikleri ve veri toplama sürecinin detayları hakkında bilgiler verilmiştir.

Ayrıca katılımcıların seçimi, veri alım işlemi ve veri alım teknikleri gibi işlemlere başlamadan önce sürecin bilimsel ve etik doğruluğunu sağlamak amacıyla nöroloji uzmanı görüşlerine başvurulmuştur. Uzman hekim katkıları, çalışmanın metodolojisinin daha sağlam bir temele oturmasını ve elde edilecek verilerin güvenilirliğini artırmayı hedeflemiştir. Bu sayede çalışmada izlenecek yöntemlerin uygunluğu ve geçerliliği konusunda uzman görüşleri doğrultusunda hareket edilmiştir.

3.1.1. Fagerström Nikotin Bağımlılığı Anketi (FTND)

FTND, nikotin bağımlılığını belirlemede uluslararası düzeyde kabul görmüş 6 soruluk bir ankettir. 1991’de Heatherton ve arkadaşları tarafından düzenlenmiştir. Pomerleau ve arkadaşları FTND, içerdiği altı madde ile nikotin bağımlılık düzeyini belirlemede iyi düzeyde güvenilirliğe sahip olduğunu belirtmişlerdir (Pomerleau vd., 1994). Avrupa Sigara ve Sağlık Tabipleri Birliği (EMASH) tarafından sağlık profesyonelleri için yayınlanan sigarayı bırakma kılavuzunda, FTND’nin nikotin bağımlılık düzeyini göstermeye yeterli olduğu belirtilmiştir (Kunze vd., 1998). Her bireyden veri alımı öncesinde FTND doldurulması istenilmiştir. Anket sonuçlarına göre bireylerden alınan EEG verileri sigara bağımlısı olan ve olmayan olarak etiketlenmiştir. Tablo 3.1.’de FTND görülmektedir.

Tablo 0.1. FTND

1-Bir günde kaç sigara içiyorsunuz?	
10 taneden az (0 puan)	11-20 (1 puan)
21-30 (2 puan)	31 ve daha fazla (3 puan)
2-İlk sigaranızı sabah kalktıktan ne kadar sonra içersiniz?	
İlk 5 dakika içerisinde (3 puan)	6-30 dakika içerisinde (2 puan)
31-60 dakika içerisinde (1 puan)	1 saatten sonra (0 puan)
3-Sigara içilmesi yasak olan yerlerde bu yasağa uymakta zorlanıyor musunuz?	
Evet (1 puan)	Hayır (0 puan)
4-En fazla vazgeçmek istemediğiniz sigara hangisidir?	
Sabah içilen sigara (1 puan)	Diğerleri (0 puan)
5-Sigarayı günün ilk saatlerinde, daha sonraki saatlere kıyasla daha sık içiyor musunuz?	
Evet (1 puan)	Hayır (0 puan)
6-Günün büyük bir bölümü yataкта geçirmenize neden olacak kadar ağır hasta olsanız yine de sigara içer misiniz?	
Evet (1 puan)	Hayır (0 puan)

Tablo 3.1. (Devam) FTND

Bağımlılık değerlendirme puanları;	
0-2 Çok düşük	3-4 düşük
5 orta düzeyde	6-7 yüksek,
8-10 çok yüksek	

(Kaynak: Heatherton vd., 1991a)

3.1.2. Veri Alım Öncesi

Veri alım öncesinde aşağıda sıralanan hususlara dikkat edilmiştir;

- 1-Sigara bağımlısı ise en az 2 saat öncesine kadar sigara kullanılmaması istenilmiştir.
- 2-Bireylerin saç temizliğine özen göstermeleri istenmiştir.
- 3-Veri alımı gerçekleştirilen odada artefakt yapacak bütün cihazlar (telefon vb.) kapatılmıştır.
- 4-Şehir şebeke artefaktını azaltmak için veri alımı DC bataryalı dizüstü bilgisayar ile yapılmıştır.
- 5-Veri alımından en az 2 saat öncesine kadar bireylerin yemek yememesi ve ilaç/kafein almaması talep edilmiştir.

3.1.3. Veri Alımı

Veri alım esnasında dikkat edilen hususlar;

- 1-Bireylerin hareket etmemesine özen gösterilmiştir.
- 2-Elektrotlar için kullanılan iletken jelin kullanımına dikkat edilmiştir. (Bir elektrotun jeli başka bir elektroda temas etmemiştir.)
- 3-EEG cihazı elektrot kepi ve elektrot temizliği her bireyin EEG işlemi sonrası yapılmıştır.
- 4-Elektrotların sabitleme işlemleri özenle yapılmış ve elektrot empedans değerleri 10 Kohm altına düştükten sonra EEG alım işlemi yapılmıştır.
- 5-EEG alım esnasında sinyallerden olağandışı değişimler görüldüğünde işlem durdurulmuştur.
- 6-Veri alım saatleri tüm bireylerde aynı saatlerde (14.30-16.30 arası) alınmıştır.

3.1.4. Katılımcı Seçimi

18-45 yaş arası, sağlıklı ve nörolojik rahatsızlığı bulunmayan 30 erkek bireyden veri toplama işlemi yapılmıştır. Tıp alanındaki çalışmalarda, uluslararası literatüre göre çalışmalara katılımcı sayısı minimum 17 olarak bilinmektedir. Tıp alanı dışındaki çalışmalarda böyle bir sınırlama bulunmamaktadır. Literatürdeki benzer çalışmalarda da bireyler genellikle erkek seçilmiştir. Bunun nedenleri arasında; kültürel faktörler, homojen örneklem grubu ve hormonal faktörler yer almaktadır (Organization, 2019). Katılımcılar sigara kullanan ve kullanmayan bireyler olmak üzere iki gruba ayrılmıştır. Sigara kullanan bireyler farklı bağımlılık düzeylerinde olabilirken, sigara kullanmayan bireyler tamamen nikotin bağımlılığından uzak bireyler olarak seçilmiştir. Katılımcıların seçiminde yaş aralığı, sağlık durumu, sigara kullanım geçmişi (3 yıldan daha fazla sigara kullanan) ve nörolojik sağlık kriterleri göz önünde bulundurulmuştur. Bu seçim kriterleri elde edilen verilerin güvenilirliğini ve doğruluğunu artırmak amacıyla titizlikle uygulanmıştır. Nörolojik rahatsızlığı olan bireylerden veri alımı yapılmamıştır. Çünkü bu tür rahatsızlıklar EEG verilerini etkileyebilir ve çalışmanın sonuçlarını yanıltabilir. Tablo 3.2’de katılımcıların boy- kilo, cinsiyet ve sigara kullanma durumları gibi özellikleri görülmektedir.

Tablo 0.2 Katılımcı özellikleri

SN	Yaş	Boy (cm)	Kilo (kg)	E/K	Durum
1	28	172	85	E	Sigara İçen
2	27	174	80	E	Sigara İçen
3	29	178	74	E	Sigara İçmeyen
4	35	176	76	E	Sigara İçen
5	38	177	80	E	Sigara İçen
6	41	182	70	E	Sigara İçen
7	33	174	72	E	Sigara İçmeyen
8	22	170	62	E	Sigara İçmeyen
9	34	171	82	E	Sigara İçen
10	23	180	110	E	Sigara İçmeyen
11	39	181	93	E	Sigara İçmeyen
12	23	193	105	E	Sigara İçen
13	28	187	130	E	Sigara İçen
14	25	182	76	E	Sigara İçen
15	23	170	70	E	Sigara İçmeyen
16	34	173	120	E	Sigara İçmeyen
17	44	179	91	E	Sigara İçmeyen
18	22	178	78	E	Sigara İçmeyen
19	45	175	65	E	Sigara İçen

Tablo 3.2. (Devam) Katılımcı özellikleri


20	40	176	83	E	Sigara İçmeyen
21	23	185	76	E	Sigara İçen
22	25	180	79	E	Sigara İçen
23	45	179	71	E	Sigara İçmeyen
24	32	177	80	E	Sigara İçen
25	39	176	84	E	Sigara İçen
26	42	175	86	E	Sigara İçen
27	37	187	81	E	Sigara İçen
28	40	172	83	E	Sigara İçen
29	34	179	79	E	Sigara İçmeyen
30	27	182	70	E	Sigara İçmeyen

3.1.5. EEG Cihazı

Veri alımı için kullanılan cihaz 32 kanallıdır. EEG ölçüm sistemi kuvvetlendirici katına (1600 $\mu\text{V}/\text{cm}$) sahiptir. Ayrıca, (fc) kesim frekansı (0,008-2000 Hz) arasında ayarlanabilmektedir. Şebeke gürültüsünü bastırmak için çentik filtre (50 Hz) ayarı mevcuttur. 4096 Hz maksimum örnekleme frekansına ve 16 bit çözünürlükte bir ADC yapısına sahiptir. Bununla beraber sistem, EEG kanalları için bipolar ve unipolar ölçüm modu seçeneği sunmaktadır.

Kullanılan elektrot jeli EEG kepi için üretilmiştir ve empedans ayarlamakta iletkenlik sağlamaktadır. EEG ölçüm sistemi içinde sunulan bu özellikler, Micromed firmasının ürettiği (System Plus Evaluation) arayüzü kullanılarak değiştirilebilmektedir

Şekil 3.2’de uluslararası kabul görmüş 10/20 ölçüm sistemine göre elektrot yerleşimleri görülmektedir. Şekil 3.3’te ise çalışmada kullanılan uluslararası 10/20 ölçüm sistemine ait her elektrot için ayrı yuvalar ve kep bağlantı girişi için ayrı bir soket yuvası bulunmaktadır. 10/20 sistem, EEG uygulamalarında elektrot yerleştirme için kabul edilmiş varsayılan standarttır ve yarım yüzyıldır kullanılmaktadır. Bu sistem, kafa yüzeyi üzerindeki kranial işaretler arasındaki göreceli mesafeleri kullanarak kafa yüzeyindeki konumları tanımlar (Klem, 1999).




Şekil 0.2. 10/20 ölçüm sistemi (Kaynak: Oostenveld & Praamstra, 2001)

Gürültüleri ve istenmeyen sinyalleri filtrelemek için kullanılan bant geçiren filtreler (0.3-50 Hz) kullanılmıştır. Elektrotların temas noktalarındaki iletkenliği arttırmak için iletken jel kullanılmıştır.



Şekil 0.3. EEG kayıt sistemi




Şekil 0.4. Veri alımı için direnç değerlerinin düşürülmesi

Elektrotların bulunduğu kep takıldıktan sonra iletken ile dirençlerin düşürülmesi hedeflenmiştir. Elektrot kepi ilk takıldığında dirençler 20 Kohm'un üzerindedir. Daha sonra her elektrota jel uygulanarak dirençler Şekil 3.4'te görüldüğü gibi 10 Kohm'un altına düşürülmüştür. Böylece bireylerden alınan EEG verilerindeki istenmeyen gürültüler azaltılarak veri işleme teknikleri daha kolay bir hal almıştır.


3.1.6. Veri Alım Süreci

Veri alım sürecinde görsel uyaranlar kullanılmıştır. Bireylerin Şekil 3.5'te gösterilen görsel uyaranlara verdikleri tepkiler elektrot kepi ile alınarak EEG verisi olarak kaydedilmiştir. EEG kayıt alma işlemi görsel uyaranların sunumu ile eş zamanlı olarak başlatılmıştır.

Şekil 3.6'te, görsel uyaranların ve kayıt işleminin akış diyagramı gösterilmektedir. Bu diyagrama göre her 2 saniyede bir farklı bir görsel gösterilmiştir. Görsel uyaranlar sigara görselleri ve rastgele nesne görsellerinden oluşmaktadır. Her iki görsel arasındaki geçişlerde siyah resimler eklenerek görsel değişiklikler arasında net bir ayrım sağlanmıştır.



Şekil 0.5. Görsel uyarar sunumu



Şekil 0.6. EEG veri alım süreci

Çalışmada kullanılan EEG verileri, yalnızca sigara görsellerinin gösterildiği süreleri kapsamaktadır. Bu şekilde sigara görsellerine verilen tepkiler diğer uyarılardan izole edilerek analiz edilmiştir.

3.1.7. EEG Verisi Özellikleri

Bireylerden toplanan EEG verisi 4096 Hz örnekleme frekansı ile kaydedilmiştir. Kullanılan cihaz 32 kanallı olmasına rağmen elektrot kepi 10/20 sistemine göre konumlandırıldığı için 19 kanaldan veri toplanmıştır. Çalışma kapsamında 30 bireyden farklı zaman dilimlerinde ortalama 4'er adet veri seti elde edilmiştir. Bu süreç sonucunda toplamda 110 adet EEG verisi edf formatında kaydedilmiştir.

Toplanan edf formatındaki bu veriler farklı formatlara dönüştürülmüş ve çeşitli ön işleme tekniklerinden geçirilmiştir. Ön işleme adımları arasında artefakt temizleme, bant geçiş filtreleme ve sinyal normalizasyonu gibi işlemler yer almıştır. Bu işlemlerden geçen EEG verileri zaman-frekans alanında analiz edilmiş ve daha sonra makine öğrenmesi algoritmalarıyla sınıflandırma işlemleri için kullanılmıştır.

3.2. Veri İşleme ve Özellik Çıkarımı

EEG verilerinin sınıflandırılmadan önce ayrıştırılması ve özellik çıkarımı sinyal işleme sürecinin temel adımlarını içermektedir. İlk olarak ham EEG sinyalleri DWT kullanılarak alt frekans bileşenlerine ayrıştırılmıştır. Bu işlem sinyali daha yönetilebilir ve analitik hale getirmektedir. Ardından her bir frekans bileşeninin güç yoğunluğunu belirlemek için Welch PSD yöntemi uygulanmıştır. Bu işlem farklı frekans bantlarındaki önemli özellikleri ortaya çıkarmaktadır. PSD işleminden ayrıca alt frekans dallarına ayrılan EEG sinyallerinin (ortalama, varyans, sıfır geçiş katsayısı vb.) 15 farklı özelliği çıkarılmıştır. Özellik çıkarımı ve PSD analizi yapılan EEG verileri sınıflandırma modellerinde ayrı ayrı kullanılmıştır.


3.2.1. Ayrık Dalgacık Dönüşümünün (DWT) Uygulanması

Ham EEG verisinin DWT işlemi beyin aktivitesinin analizinde ve sinyal işleme alanında güçlü bir yöntem olarak kabul edilmektedir. Bu yöntem sinyalin frekans ve zaman alanlarındaki özelliklerini ayrıştırarak beyin sinyalinin karmaşıklığını daha iyi anlamamıza yardımcı olmaktadır. DWT işlemi frekans ve zaman değişikliklerini hassas bir şekilde analiz ederek beyin sinyalinin içerdiği bilgiyi ortaya çıkarmaktadır.

DWT işlemi örnekleme frekansı gibi temel parametrelerin belirlenmesiyle başlamaktadır. Ardından seçilen bir dalgacık fonksiyonu kullanılarak ham EEG verisi dalgacık dönüşümüne tabi tutulmaktadır. Bu işlem sonucunda veriyi, farklı ölçeklerde ve zamanlarda temsil eden alt bileşenler elde edilmektedir. Bu alt bileşenler sinyalin farklı frekans bileşenlerini ve zaman içindeki değişimlerini temsil eder. Bu sayede sinyalin frekans ve zaman alanlarındaki özellikleri daha iyi anlaşılmaktadır.

DWT sonucu elde edilen katsayılar sayesinde beyin aktivitesinin farklı frekans bileşenleri ve zaman aralıklarındaki dağılımı görsel olarak gösterilebilir. Bu görselleştirmeler beyin aktivitesinin zamanla nasıl değiştiğini anlamak için önemlidir.

DWT işlemi nörobilim araştırmalarında ve klinik uygulamalarda beyin sinyalinin daha derinlemesine analizini sağlamaktadır. Elde edilen frekans alt bileşenleri beyin aktivitesinin özelliklerini daha iyi anlamak, belirli beyin hastalıklarını veya durumlarını tanımlamak için kullanılmaktadır. Bu frekans bileşenleri (delta, teta, alfa, beta) sınıflandırma veya tanıma algoritmaları için giriş olarak da kullanılmaktadır. Böylece beyin sinyalinin anlamlandırılması ve yorumlanması kolaylaştırmaktadır. Şekil 3.7’de görüleceği üzere çalışmamızda elde edilen ham EEG verisine DWT işlemi uygulanmış ve EEG verisinin frekans alt bileşenleri elde edilmiştir. Elde edilen frekans alt bileşenleri analiz ve özellik çıkarımı gibi ön işlemlere ayrı ayrı sokulmuş ve daha sonra sınıflandırma işlemleri yapılmıştır.



Şekil 0.7. DWT işlemi elde edilen EEG verisi frekans alt bileşenleri

3.2.2. Güç Spektral Yoğunluğu (PSD) Analizi


DWT işlemi sonrasında elde edilen EEG sinyali frekans alt bileşenlerinin analizi için Welch yöntemi kullanılarak detaylı bir şekilde incelenmiştir. Welch yöntemi sinyali örtüşen pencerelere (veya segmentlere) bölmektedir. Her bir pencere belirli bir uzunlukta seçilir ve genellikle önceki pencere ile %50 örtüşme payıyla belirlenmektedir.

Çalışmada kullanılan EEG verisinin örnekleme frekansı 4096 Hz olarak belirlenmiştir. Bu durumda 4096 noktalı sinyal 4 eşit parçaya bölünerek her biri 1024 noktadan oluşan 4


pencere elde edilmektedir. Her bir pencere FFT (Hızlı Fourier Dönüşümü) ile işlenmekte ve her bir FFT işlemi sonucunda frekans bileşenleri elde edilmektedir. FFT işlemi her bir pencere için $(1024/2) + 1 = 513$ frekans bileşeni üretir ve burada +1 DC bileşenini ifade etmektedir.

Her bir pencere için elde edilen frekans bileşenlerinin PSD analizi yapılmaktadır. Bu adım her pencere için elde edilen FFT sonuçlarından güç spektrumunu hesaplamak suretiyle gerçekleştirilir. Yani her pencere için PSD hesaplaması yapılır ve sonuçlar frekans alanındaki güç dağılımını göstermektedir.


Son olarak tüm pencereleme işlemi boyunca elde edilen güç spektrumlarının ortalaması alınarak genel EEG sinyalinin frekans alanındaki karakteristikleri analiz edilmektedir. Bu analiz EEG sinyalinin farklı zaman dilimlerindeki spektral özelliklerini incelemek için kullanılır ve belirli frekans bantlarının aktivitelerini belirlemede önemli bir rol oynamaktadır. Şekil 3.8 ve Şekil 3.9'da sigara bağımlısı ve sigara bağımlısı olmayan bireylerin PSD işlemi sonucu EEG sinyal genlik değişimi ve spektral yoğunluğunun logaritmik değişimi gösterilmektedir. Burada çalışmada kullanılan ham EEG verisinin DWT işlemi sonucu alt frekanslara ayrılmış delta frekans bandında temporal lobdaki değişimi gözlemlenmiştir.



Şekil 0.8. Sigara bağımlısı bireyin EEG sinyal değişimi ve PSD analizi (Kaynak: Delorme & Makeig, 2004b)



Şekil 0.9. Sigara bağımlısı olmayan bireyin EEG sinyal değişimi ve PSD analizi (Kaynak:Delorme & Makeig, 2004a)



Şekil 0.10. PSD analizi sonucu oluşan EEG matrisi

Şekil 3.10’da görüleceği üzere frekans alt bileşenlerine ayrılmış EEG verisinin boyutu 4096x3210 iken Welch yöntemiyle oluşan PSD analizi sonucu ile 513x3210 boyutuna indirgenmektedir. Bu çıktı sonrası sınıflandırma işlemleri yapılmıştır.

3.2.3. Özellik Çıkarımı İşlemleri

EEG verisinden çıkarılan özellikler her bir saniyenin zaman diliminde sinyalin çeşitli istatistiksel özniteliklerini temsil etmektedir. Bu özellikler EEG sinyalinin zaman içindeki değişimlerini yakalamak ve sinyalin genel özelliklerini analiz etmek için kullanılmaktadır.


Özelliklerin çıkarılması süreci her bir saniyenin EEG sinyalinden belirli özelliklerin hesaplanmasıyla gerçekleştirilmektedir. Bu özelliklerin her biri sinyalin belirli yönlerini veya karakteristiklerini ölçmektedir. Ortalama özellik sinyalin genel seviyesini yansıtırken, varyans özellik sinyalin ne kadar değişken olduğunu göstermektedir. Standart sapma ise sinyalin dağılımını ifade ederken, çarpıklık, kurtosis gibi özellikler sinyalin simetrisi hakkında bilgi verebilmektedir (Chua vd., 2010).

Ayrıca EEG sinyalinin dinamiklerini yansıtan özellikler de mevcuttur. Sıfır geçiş katsayısı sinyalin zaman içindeki geçişlerini ölçerken, Wilson genliği büyük değişiklikleri yakalamak için kullanılmakta ve tekil değer ayrıştırılması ise sinyalin karmaşıklığını ve içsel yapısını ifade etmektedir (Edfors vd., 1998).

Bu özellikler her bir saniyenin EEG sinyalinden elde edilir ve sonuçlar 15 özellikten oluşan vektörler halinde saklanır. Bu vektörler EEG verisinin karmaşıklığını azaltarak ve önemli bilgileri öne çıkararak makine öğrenimi modelleri için ideal girdi olarak kullanılmaktadır. Özelliklerin bu şekilde önceden işlenmesi sınıflandırma veya regresyon gibi görevlerde EEG sinyallerinin anlamlı desenlerini ve özelliklerini keşfetmek için temel oluşturur.

Çalışmada kullanılan 15 özellik, Temel Bileşenler Analizi (PCA) tekniği ile boyut azaltma işlemi gerçekleştirilerek optimize edilmiştir. Bu süreçte orijinal veri setindeki 15 özellik, bilgi kaybı minimize edilerek 13 özelliğe indirgenmiştir. Bu boyut azaltma işlemi sayesinde veri setindeki gereksiz veya fazla bilgi içeren özellikler elenmiş böylece işlem yükü hafifletilmiştir. Sonuç olarak modelin daha verimli çalışması ve analizlerin daha hızlı gerçekleştirilmesi sağlanmıştır. PCA ile elde edilen bu yeni bileşenler veri setindeki en anlamlı bilgiyi taşıyan yönleri temsil eder ve bu sayede analizlerin kalitesi de artırılmıştır.

EEG sinyalinin her bir saniyesinin temsil edildiği bu özellik vektörleri sağlık durumlarının tespiti, bilişsel durumların analizi veya beyin-bilgisayar arayüzü gibi uygulamalarda önemli bir rol oynar. Bu özelliklerin doğru seçilmesi ve hesaplanması EEG verisinden elde edilen bilgilerin değerlendirilmesinde kritik öneme sahiptir. Şekil 3.11’de özellik çıkarımı işlemleri görülmektedir. EEG verisinin boyutu 4096x3210 iken özellik çıkarımı ile 13x3210 boyutuna indirgenmektedir.



Şekil 0.11. Özellik çıkarımı işlemi sonucu oluşan EEG matrisi

3.3. Makine Öğrenmesi Modellerinin Uygulanması

EEG verisine sınıflandırma öncesi başarı oranlarını artırmak amacıyla ilk olarak DWT kullanılarak veriler alt frekans bileşenlerine ayrılmıştır. Bu bileşenlerin her biri için ayrı ayrı özellik çıkarımı ve PSD analiz işlemleri uygulanarak EEG verisinin ön işleme süreci tamamlanmıştır. Sınıflandırma aşamasında klasik makine öğrenmesi algoritmalarının yanında ANN ve RNN gibi daha gelişmiş modeller de kullanılmıştır. Model performansını artırmak için veri çoğaltma tekniklerine başvurulmuş ve bu amaçla GAN kullanılarak verilerin sayısı artırılmıştır. GAN'lar orijinal verilerin dağılımını taklit ederek yeni ve benzer örnekler üretebildiğinden sınıflandırma modellerinin daha geniş ve çeşitli bir veri seti ile eğitilmesine olanak sağlamış ve böylece genel başarı oranını yükseltmiştir.

3.3.1. KNN ve SVM


Özellik çıkarımı ve PSD analizinden elde edilen EEG verileri, sınıflandırma işlemleri için iki farklı klasik makine öğrenme modeli olan KNN ve SVM algoritmalarına ayrı ayrı verilmiştir. EEG sinyallerinin analizi özellikle çeşitli nörolojik ve psikiyatrik durumların teşhisi ve izlenmesi için kritik öneme sahiptir. Bu bağlamda derin öğrenme modelleri kullanmadan elde edilen başarı oranlarının incelenmesi klasik makine öğrenme yöntemlerinin bu tür biyomedikal veriler üzerindeki etkinliğini değerlendirmek için önemlidir.

Öncelikle özellik çıkarımı sürecinde EEG sinyallerinin zaman ve frekans domainlerinde belirgin olan özellikleri seçilmiştir. Bu süreç, sinyalin özniteliklerinin daha anlamlı hale getirilmesi ve modelleme işlemlerinde daha iyi performans sağlanması için gereklidir. PSD analizi, sinyalin enerji dağılımını frekans bileşenleri üzerinde değerlendirerek önemli

frekans bantlarını belirler. Bu frekans bantları çeşitli beyin aktivitelerinin ve nörolojik durumların göstergeleri olarak kullanılmaktadır (Wang vd., 2015).

KNN algoritması özellik çıkarımı ve PSD analizinden elde edilen veriler üzerinde uygulandığında veri noktalarının en yakın komşularına bakarak sınıflandırma işlemini gerçekleştirmektedir. KNN basit, sezgisel bir yöntem olmasına rağmen özellikle yüksek boyutlu veri setlerinde ve özelliklerin iyi ayrıştırıldığı durumlarda oldukça etkili olabilir. EEG verilerinde, farklı sınıflara ait örneklerin uzayda belirli bölgelerde yoğunlaşması durumunda KNN algoritması bu bölgeler arasındaki sınırları belirlemede başarılı olabilmektedir.

SVM, veri noktalarını bir hiper düzlem ile ayırarak sınıflandırmayı gerçekleştirmeye çalışır ve optimal ayırma hiper düzlemini bulmayı hedeflemektedir. EEG verileri gibi karmaşık ve gürültülü veri setlerinde SVM algoritması sınıflar arasındaki ayrımı daha net bir şekilde yaparak yüksek başarı oranları elde edebilir.




Şekil 0.12. kNN ve SVM modellerinin uygulanması

Şekil 3.12’de özellik çıkarımı sonucu çıkan 15x3210 boyutundaki ve PSD analizi sonucu çıkan 513x3210 boyutundaki EEG veri matrislerine KNN ve SVM modellerinin uygulanması görülmektedir. kNN için en iyi komşuluk değeri 11 (k değeri) olarak belirlenmiştir.

3.3.2. YSA Modelinin Uygulanması

Özellik çıkarımı ve PSD analizinden elde edilen veriler klasik makine öğrenmesi algoritmalarında olduğu gibi sınıflandırma için tasarlanan YSA modeline verilmiştir. Şekil 3.13’te özellik çıkarımı ve PSD analizinden elde edilen verilere YSA modelinin uygulanma işlemi görülmektedir. Tasarlanan YSA modeli EEG verisi her kanalına ayrı ayrı uygulanmış ve başarı oranları analiz edilmiştir. Kullanılan YSA modelinde klasik

makine öğrenmesi algoritmalarına kıyasla daha yüksek başarı oranlarına ulaşılmıştır. YSA modelinin ağ eğitimleri ve test işlemleri titizlikle takip edilerek ağ parametreleri en optimum düzeyde ayarlanmıştır. Bu süreçte modelin genel performansını artırmak için çeşitli optimizasyon teknikleri uygulanmış ve farklı hiperparametre kombinasyonları denenmiştir.



Şekil 0.13. YSA modelinin uygulanması

Tasarlanan modelin özelliklerine ve parametrelerine gelince; modelde gradyan iniş algoritması olarak Adam optimizasyon algoritması kullanılmış ve ağ 1000 epoch boyunca eğitilmiştir. Mini-batch boyutu 16 olarak belirlenmiş ve her epoch sonrası doğrulama yapılmıştır. Eğitim sırasında öğrenme oranı 0.001 (10^{-3}) olarak ayarlanmıştır. Veri seti %70 eğitim ve % 30 test veri seti olarak bölünmüştür. Modelde giriş katmanı ardından Şekil 3.14'te görüldüğü gibi modelde altı tane sırasıyla 32, 64, 64, 128, 128 ve 256 nörona sahip tam bağlantılı katmanlar ve her tam bağlantılı katmandan sonra bir ReLU aktivasyon fonksiyonu bulunmaktadır. 128 nöronlu katmandan sonra birer tane dropout katmanı eklenmiştir. Modelin son katmanı ise iki sınıfa sahip bir sınıflandırma katmanı, softmax katmanı içermektedir. Bu yapı modelin hem karmaşık verileri öğrenebilmesini hem de aşırı öğrenmeyi azaltmak için dropout katmanlarını kullanarak daha genel bir performans sergilemesini amaçlamaktadır.

Giriş Katmanı
Tam Bağlantılı Katman (32)
ReLU Katmanı
Tam Bağlantılı Katman (64)
ReLU Katmanı
Tam Bağlantılı Katman (64)
ReLU Katmanı
Tam Bağlantılı Katman (128)
ReLU Katmanı
Dropout Katmanı
Tam Bağlantılı Katman (128)
ReLU Katmanı
Dropout Katmanı
Tam Bağlantılı Katman (256)
ReLU Katmanı
Dropout Katmanı
Tam Bağlantılı Katman (2)
Softmax Katmanı
Sınıflandırma Çıkış Katmanı

Şekil 0.14. YSA model katmanları

3.3.3. Tekrarlayan Sinir Ağları (RNN)


YSA modelinden sonra aynı şekilde özellik çıkarımı ve PSD analizi sonuçlarına tasarlanan RNN ağ mimarileri sınıflandırma için uygulanmıştır. RNN'lerin klasik YSA'lardan farkı zamanla ilişkili verileri işleyebilme yetenekleridir. Klasik YSA'lar her bir girdi setini bağımsız olarak işlerken RNN'ler geçmişteki girdileri ve çıktıları hatırlayarak bunları mevcut hesaplamalarda kullanmaktadırlar. Bu, RNN'lerin dil işleme, zaman serisi analizi gibi ardışık verilerde önemli olan görevlerde daha etkili olmasını sağlar. RNN'lerde her düğüm bir önceki zamandaki düğümden bilgi alır ve böylece veri sırasındaki bağımlılıkları öğrenebilir. Bu özellik RNN'leri zaman bağımlı ve sekans verilerini işleyen uygulamalar için ideal kılmaktadır. Kullanılan RNN ağ mimarileri LSTM ve GRU olarak seçilmiştir.

Şekil 3.15'ten görüleceği üzere LSTM ve GRU ağ mimarileri şu özelliklere sahiptir; Ağ mimarilerinde 4'er adet 64 hücreli LSTM ve GRU katmanları bulunmaktadır. Her katman arası aşırı öğrenmeyi ve parametre sayısını azaltmak için dropout katmanları kullanılmıştır.

Öğrenme oranı 0,001 olarak girilmiştir. LSTM ve GRU katmanlarından sonra tam bağlantılı katman ve sınıf olasılıkları için softmax katmanı kullanılmıştır. Minimum hata değerine ulaşmak için gradyan iniş algoritması olarak ‘adam’ optimizasyon algoritması kullanılmıştır.

Giriş Katmanı
LSTM-GRU Katmanı 1 (64)
Dropout Katmanı (0,5)
LSTM-GRU Katmanı 2 (64)
Dropout Katmanı (0,5)
LSTM-GRU Katmanı 3 (64)
Dropout Katmanı (0,5)
LSTM-GRU Katmanı 4 (64)
Dropout Katmanı (0,5)
Tam Bağlantılı Katman (2)
Softmax Katmanı
Sınıflandırma Çıkış Katmanı

Şekil 0.15. LSTM ve GRU ağ mimarileri



Şekil 0.16. RNN mimarilerinin uygulanması

Şekil 3.16'dan görüldüğü üzere EEG verileri üzerinde özellik çıkarımı ve PSD analizi yapılmıştır. EEG verisi zaman serisi özelliği gösterdiği için RNN mimarileri kullanılarak sınıflandırma yapılmıştır. RNN mimarileri klasik makine öğrenmesi algoritmaları ve tasarlanan YSA modelleri gibi alternatif yöntemlerle karşılaştırılmış ve başarı oranları analiz edilmiştir. Özellikle LSTM ve GRU gibi RNN türleri EEG gibi zaman serisi verilerine farklı bir bakış açısı getirmiştir. Bu ağ mimarileri zaman bağımlılıklarını ve uzun vadeli ilişkileri yakalama yetenekleriyle bilinmektedirler.


3.4. GAN ile Veri oğaltma

GAN'lar gerek verilere ok yakın olacak ekilde sentetik veri reten derin ğrenme ađ mimarileridir. Bu yaklařımın temel amacı sınıflandırma modelinin genel performansını artırmak iin daha fazla veri eřitliliđi sađlamaktır. Sentetik veriler modelin genelleme yeteneđini artırabilir. GAN'lar zellikle sınırlı veri setlerinde alıřırken gl bir yntemdir. nk gerek verilere benzerliklerini korurken veri eřitliliđini artırırılar.

Ham EEG verilerinin sınıflandırma bařarı oranlarını artırmak iin kullanılan bir yntem GAN ile veri artırımıdır. Tez alıřmasında EEG verileri n analizler ve zellik ıkarımı gibi iřlemlerden nce sınıflandırma bařarı oranlarını arttırmak iin GAN ile veri oğaltmaya gidilmiřtir. GAN ile her bir EEG kanalı iin ayrı ayrı olarak kullanılarak sentetik veri retilmiřtir.

GAN'lar kullanılarak EEG verilerinin sentetik olarak oğaltılması, sınıflandırma modelinin performansını iyileřtirmek ve genelleme yeteneđini glendirmek iin etkili bir yntem olarak deđerlendirilmektedir.

řekil 3.17'de grldđ gibi GAN kullanarak ham EEG verilerinin oğaltılması iřlemi řu ekilde iřler: retici ađ rastgele grlt veya bařlangı verisinden gerek EEG verilerine benzeyen sentetik veriler retmeye alıřır. Ayrıřtırıcı ađ ise gerek EEG verisiyle retilen sentetik veriyi karřılařtırarak bir hata oranı hesaplar. Bu hata oranı retici ađın sentetik veriyi gerek veriye yaklařtırmasını teřvik eder. Eđitim srecinde retici ve ayrıřtırıcı ađlar birbirleriyle rekabet eder ve zamanla retici ađ daha gereki veriler retmeyi ğrenir. Bu yntem sınıflandırma modellerinin performansını artırmak iin veri eřitliliđini artırırken aynı zamanda modelin genelleme yeteneđini glendirmeyi hedeflemektedir.



Şekil 0.17. GAN ile EEG veri çoğaltma işlemi

4. BULGULAR

Bu tez çalışmasında, sigara bağımlılığının EEG verileri kullanılarak tespit edilmesinde makine öğrenmesi yöntemlerinin potansiyeli detaylı bir şekilde incelenmiştir. Sigara bağımlılığı, dünya genelinde yaygın ve ciddi sağlık sorunlarına yol açan bir durumdur. Bu bağımlılığı tespit etmek ve önlemek için yenilikçi ve etkili yöntemlerin geliştirilmesi büyük bir önem taşımaktadır.

Çalışma kapsamında 30 farklı erkek bireyden 10/20 ölçüm sistemine göre alınan EEG verileri analiz edilmiştir. EEG verilerinin değerlendirme işlemleri, 19 kanal üzerinden yapılmıştır. EEG verileri alınmadan önce bireylere nikotin bağımlılığı anketi (FTND) uygulanmıştır. EEG verileri üzerinde gerçekleştirilen Ayrık Dalgacık Dönüşümü (DWT) işlemi sonucu EEG verileri frekans alt bileşenlerine (delta, teta, alfa, beta ve gama) ayrılmıştır. Daha sonra her frekans alt bileşenlerinin zaman ve frekans domaininde özellik çıkarımı işlemleri ayrı ayrı yapılmıştır. Zaman domaininde özellik çıkarımı yöntemi için 15 adet özellik belirlenmiştir. Frekans domaininde özellik çıkarımı için Spektral Güç Yoğunluğu (PSD) analizi kullanılmıştır. Nihai olarak elde edilen veriler klasik makine öğrenmesi (kNN ve SVM) algoritmaları ve derin sinir ağları (YSA ve RNN) ile sınıflandırma işlemlerine tabi tutulmuştur. Sınıflandırma etiketleri sigara içen ve içmeyen (1-0) olacak şekilde FTND sonuçlarına göre etiketlenmiştir.

Çalışmamızda kullanılan algoritmaların performans metrikleri doğruluk, özgüllük, duyarlılık, kesinlik ve f-skor parametreleri üzerinden karşılaştırılmıştır.

4.1. kNN Sınıflandırma Bulguları

Tablo 4.1’de teta frekans bandında 19 kanalın PSD analizi çıktılarının kNN ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, kNN ile PSD analizi sınıflandırma başarı oranı % 81’e ulaşmıştır. Burada başarı oranlarına bakıldığında T6, T3, F4, Fp1, Fz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, temporal ve frontal lob kanalları öne çıkmaktadır.

Tablo 0.1. KNN PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8026	0,7897	0,7698	0,7753	0,7729	0,7821
Fp1	0,8011	0,7947	0,7946	0,7947	0,799	0,7968
F8	0,8007	0,7897	0,7769	0,7343	0,7574	0,7718
F4	0,7864	0,7846	0,812	0,8002	0,8172	0,8001
Fz	0,7989	0,7997	0,7968	0,7803	0,7936	0,7939

Tablo 0.2. (Devam) KNN PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
F3	0,7849	0,7694	0,7569	0,7648	0,769	0,769
F7	0,7922	0,7795	0,8114	0,7688	0,7929	0,789
T4	0,7861	0,7744	0,8058	0,7886	0,8018	0,7913
C4	0,7831	0,7592	0,7862	0,7797	0,7871	0,7791
Cz	0,7906	0,7744	0,7569	0,7423	0,7526	0,7634
C3	0,7705	0,734	0,7875	0,7701	0,7797	0,7684
T3	0,7975	0,8048	0,8101	0,8034	0,8037	0,8039
T6	0,8084	0,8050	0,8116	0,8179	0,8114	0,8109
P4	0,7904	0,7947	0,8149	0,7328	0,7522	0,777
Pz	0,7975	0,7846	0,7994	0,7831	0,7824	0,7894
P3	0,802	0,7846	0,7598	0,7794	0,7933	0,7838
T5	0,7778	0,7897	0,8124	0,7831	0,799	0,7924
O2	0,7936	0,7492	0,8065	0,7537	0,7574	0,7721
O1	0,7926	0,7556	0,7865	0,7848	0,7948	0,7829

Tablo 4.2’de teta frekans bandında 19 kanalın özellik çıkarımı çıktıların kNN ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, kNN ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 74’e ulaşmıştır. T4, T3, F4, Pz, O1 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ temporal ve sağ frontal lob kanalları öne çıkmaktadır.

Tablo 0.3. kNN özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7664	0,5707	0,7658	0,6991	0,7346	0,7073
Fp1	0,7044	0,4424	0,7494	0,6454	0,6962	0,6476
F8	0,7171	0,4988	0,7381	0,6649	0,7028	0,6643
F4	0,7721	0,612	0,751	0,7144	0,7373	0,7174
Fz	0,6487	0,4215	0,7065	0,6002	0,6527	0,6059
F3	0,6544	0,442	0,7236	0,6111	0,6702	0,6202
F7	0,7164	0,4936	0,7381	0,6627	0,7034	0,6628
T4	0,791	0,6529	0,7548	0,7335	0,7508	0,7366
C4	0,719	0,5551	0,7065	0,6827	0,6991	0,6725
Cz	0,7044	0,4833	0,7261	0,6567	0,694	0,6529
C3	0,6726	0,454	0,741	0,6248	0,6827	0,635
T3	0,6989	0,6303	0,7848	0,735	0,7637	0,7226
T6	0,6599	0,5783	0,7456	0,7065	0,7266	0,6834
P4	0,7684	0,4385	0,6902	0,6085	0,6493	0,631
Pz	0,6953	0,6767	0,716	0,7491	0,7353	0,7145
P3	0,729	0,4544	0,754	0,6628	0,7196	0,664
T5	0,6763	0,625	0,733	0,726	0,7325	0,6986
O2	0,7649	0,5422	0,7701	0,6947	0,7342	0,7012
O1	0,7291	0,625	0,7456	0,7295	0,7358	0,713

Tablo 4.3’te alfa frekans bandında 19 kanalın PSD analizi çıktıların kNN ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, kNN ile PSD analizi sınıflandırma başarı oranı % 80’e ulaşmıştır. Burada başarı oranlarına bakıldığında Fp1,

Fz, O1, T4, P3 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sol frontal ve sağ Perietal lob kanalları öne çıkmaktadır.

Tablo 0.4. kNN PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7713	0,7787	0,8092	0,8034	0,803	0,7931
Fp1	0,8099	0,8049	0,8105	0,8072	0,8020	0,8069
F8	0,7369	0,6406	0,7738	0,732	0,7554	0,7278
F4	0,7871	0,7394	0,797	0,7811	0,7928	0,7795
Fz	0,8164	0,7747	0,8163	0,801	0,818	0,8053
F3	0,7509	0,7135	0,7577	0,7656	0,765	0,7505
F7	0,7871	0,7135	0,811	0,7696	0,7944	0,7751
T4	0,7986	0,755	0,8056	0,7893	0,8011	0,7899
C4	0,7774	0,7394	0,7856	0,7804	0,7865	0,7739
Cz	0,7344	0,667	0,7577	0,743	0,7539	0,7312
C3	0,7585	0,7182	0,7685	0,7688	0,7723	0,7573
T3	0,7925	0,7644	0,7933	0,7929	0,7966	0,7879
T6	0,8193	0,6453	0,7819	0,7401	0,7589	0,7491
P4	0,7371	0,7492	0,7905	0,7903	0,7883	0,7711
Pz	0,779	0,739	0,8157	0,7867	0,7992	0,7839
P3	0,7925	0,7442	0,8151	0,787	0,8074	0,7892
T5	0,8051	0,6916	0,7699	0,761	0,7633	0,7582
O2	0,7438	0,7492	0,8157	0,7923	0,8009	0,7804
O1	0,7958	0,7489	0,8155	0,792	0,8006	0,7906

Tablo 4.4'te alfa frekans bandında 19 kanalın özellik çıkarımı çıktıların kNN ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, kNN ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 76'e ulaşmıştır. P4, Pz, T4, T5, Fz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, perietal ve sağ temporal lob kanalları öne çıkmaktadır.

Tablo 0.5. kNN özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7069	0,5781	0,7766	0,7079	0,7388	0,7017
Fp1	0,6506	0,4479	0,76	0,6537	0,7012	0,6427
F8	0,6628	0,5050	0,7486	0,6734	0,7074	0,6594
F4	0,5987	0,4269	0,7166	0,6081	0,6569	0,6015
Fz	0,7123	0,6196	0,7617	0,7235	0,7409	0,7116
F3	0,6045	0,4477	0,7339	0,6191	0,6705	0,6151
F7	0,6610	0,5000	0,7486	0,6713	0,7062	0,6574
T4	0,7297	0,6611	0,7655	0,7429	0,7523	0,7303
C4	0,7007	0,6347	0,7511	0,7294	0,7363	0,7104
Cz	0,6898	0,5190	0,7808	0,7052	0,7397	0,6869
C3	0,6421	0,3922	0,7734	0,6511	0,7073	0,6332
T3	0,6874	0,5824	0,7425	0,7164	0,7279	0,6913
T6	0,6298	0,6087	0,7782	0,7338	0,7519	0,7005
P4	0,7235	0,6624	0,8205	0,7637	0,7902	0,7521
Pz	0,6952	0,7119	0,7485	0,778	0,7613	0,7390
P3	0,729	0,4779	0,7882	0,6891	0,7458	0,6860

Tablo 4.4. (Devam) kNN özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
T5	0,6764	0,6568	0,7662	0,7547	0,7602	0,7229
O2	0,7296	0,5699	0,8051	0,7227	0,7613	0,7177
O1	0,7332	0,3761	0,7214	0,6322	0,6710	0,6268

Tablo 4.5 incelendiğinde, özellik çıkarımı ve PSD analizi çıktıların kNN sınıflandırma bulguları karşılaştırılmıştır. Burada frekans bantlarına göre kanallar baz alınarak en yüksek başarı oranları görülmektedir. PSD analizi çıktıların sınıflandırma başarı oranları, görüleceği üzere daha yüksektir. kNN sınıflandırıcı ile sağ arka temporal ve sol frontal lob kanalları daha belirgin bir şekilde sigara bağımlılık analizinde öne çıkmaktadır.

Tablo 0.6. kNN sonuçları

		Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
PSD	Delta 0-4 Hz	T6	0,8038	0,7880	0,8025	0,7918	0,8107	0,7994
	Teta 4-8 Hz	T6	0,8084	0,8050	0,8116	0,8179	0,8114	0,8109
	Alfa 8-16 Hz	Fp1	0,8099	0,8049	0,8105	0,8072	0,8020	0,8069
	Beta 16-32 Hz	Fz	0,7791	0,7384	0,796	0,7801	0,7918	0,7771
Özellik Çıkarımı	Delta 0-4 Hz	O1	0,689	0,6299	0,7815	0,7273	0,7526	0,7161
	Teta 4-8 Hz	T4	0,791	0,6529	0,7548	0,7335	0,7508	0,7366
	Alfa 8-16 Hz	P4	0,7235	0,6624	0,8205	0,7637	0,7902	0,7521
	Beta 16-32 Hz	Fp1	0,7203	0,6545	0,7065	0,7022	0,7099	0,6987

4.2. SVM Sınıflandırma Bulguları

Tablo 4.6’da teta frekans bandında 19 kanalın PSD analizi çıktıların SVM ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, SVM ile PSD analizi sınıflandırma başarı oranı % 83’e ulaşmıştır. Burada başarı oranlarına bakıldığında T6, T3, T4, F4, Fz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ temporal ve frontal lob kanalları öne çıkmaktadır.

Tablo 0.7. SVM PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8124	0,7993	0,7792	0,7848	0,7823	0,7916
Fp1	0,8109	0,8044	0,8043	0,8044	0,8088	0,8065
F8	0,8105	0,7993	0,7863	0,7433	0,7666	0,7812
F4	0,796	0,7941	0,8219	0,8099	0,8272	0,8098
Fz	0,8087	0,8095	0,8065	0,7898	0,8033	0,8036
F3	0,7945	0,7788	0,7662	0,7741	0,7784	0,7784
F7	0,8019	0,7890	0,8213	0,7782	0,8026	0,7986
T4	0,7956	0,8139	0,8156	0,7982	0,8116	0,8069
C4	0,7927	0,7685	0,7958	0,7892	0,7967	0,7886
Cz	0,8003	0,7839	0,7662	0,7513	0,7618	0,7727
C3	0,7799	0,7429	0,7971	0,7795	0,7892	0,7777
T3	0,8072	0,8146	0,82	0,8132	0,8135	0,8137
T6	0,8239	0,8249	0,8214	0,8272	0,8219	0,8238

Tablo 0.8. (Devam) SVM PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
P4	0,8000	0,8044	0,8249	0,7418	0,7614	0,7865
Pz	0,8072	0,7941	0,8092	0,7927	0,792	0,7990
P3	0,8117	0,7941	0,7691	0,7889	0,8029	0,7934
T5	0,7873	0,7993	0,8223	0,7927	0,8088	0,8020
O2	0,8033	0,7583	0,8163	0,7629	0,7666	0,7815
O1	0,8023	0,7648	0,7961	0,7944	0,8045	0,7924

Tablo 4.7’de teta frekans bandında 19 kanalın özellik çıkarımı çıktılarının SVM ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, SVM ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 75’e ulaşmıştır. T4, Fp2, T3, F4, Pz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ temporal ve ön frontal lob kanalları öne çıkmaktadır.

Tablo 0.9. SVM özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7757	0,6577	0,7751	0,7077	0,7435	0,7319
Fp1	0,7130	0,4478	0,7585	0,6533	0,7047	0,6555
F8	0,7258	0,5049	0,7471	0,6730	0,7114	0,6724
F4	0,7815	0,6194	0,7602	0,7231	0,7463	0,7261
Fz	0,6566	0,3436	0,7151	0,6076	0,6607	0,5967
F3	0,6623	0,3644	0,7324	0,6185	0,6784	0,6112
F7	0,7251	0,4997	0,7471	0,6708	0,712	0,6709
T4	0,8006	0,6608	0,7640	0,7424	0,7599	0,7456
C4	0,7277	0,5618	0,7151	0,691	0,7077	0,6807
Cz	0,7130	0,4892	0,7350	0,6647	0,7024	0,6609
C3	0,6808	0,3765	0,7501	0,6324	0,6911	0,6262
T3	0,7074	0,638	0,7944	0,7439	0,7731	0,7314
T6	0,668	0,5854	0,7547	0,7151	0,7355	0,6917
P4	0,7778	0,3608	0,6986	0,6159	0,6572	0,6221
Pz	0,7038	0,685	0,7248	0,7582	0,7443	0,7232
P3	0,7379	0,46	0,7632	0,6709	0,7283	0,6721
T5	0,6846	0,6326	0,7419	0,7349	0,7414	0,7071
O2	0,7742	0,5488	0,7795	0,7032	0,7432	0,7098
O1	0,738	0,6326	0,7547	0,7384	0,7448	0,7217

Tablo 4.8’te alfa frekans bandında 19 kanalın PSD analizi çıktılarının SVM ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, SVM ile PSD analizi sınıflandırma başarı oranı % 82’e ulaşmıştır. Burada başarı oranlarına bakıldığında Fp1, Fz, O1, T4, O2 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, frontal ve oksibital lob kanalları öne çıkmaktadır.

Tablo 0.10. SVM PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7807	0,7882	0,819	0,8132	0,8128	0,8028
Fp1	0,8183	0,8148	0,8215	0,8278	0,8213	0,8208
F8	0,7459	0,6484	0,7833	0,7409	0,7646	0,7366
F4	0,7967	0,7484	0,8067	0,7906	0,8024	0,7890
Fz	0,8263	0,7841	0,8263	0,8107	0,828	0,8151
F3	0,7600	0,7222	0,7669	0,7749	0,7743	0,7597
F7	0,7967	0,7222	0,8209	0,779	0,8041	0,7846
T4	0,8083	0,7642	0,8154	0,799	0,8108	0,7995
C4	0,7869	0,7484	0,7951	0,7899	0,7961	0,7833
Cz	0,7433	0,6751	0,7669	0,7521	0,7631	0,7401
C3	0,7678	0,727	0,7779	0,7781	0,7817	0,7665
T3	0,8022	0,7737	0,8029	0,8025	0,8063	0,7975
T6	0,8293	0,6532	0,7914	0,7491	0,7682	0,7582
P4	0,7461	0,7583	0,8001	0,8	0,7979	0,7805
Pz	0,7885	0,7480	0,8257	0,7963	0,8089	0,7935
P3	0,8022	0,7532	0,8250	0,7966	0,8172	0,7989
T5	0,8149	0,7000	0,7793	0,7702	0,7726	0,7674
O2	0,7629	0,7983	0,8257	0,8019	0,8107	0,7999
O1	0,8055	0,7580	0,8254	0,8016	0,8104	0,8002

Tablo 4.9’da alfa frekans bandında 19 kanalın özellik çıkarımı çıktıların SVM ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, SVM ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 73’e ulaşmıştır. T4, P4, Pz, Fz, C4 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, parietal ve frontal lob kanalları öne çıkmaktadır.

Tablo 0.11. SVM özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7069	0,5781	0,7766	0,7079	0,7388	0,7017
Fp1	0,6506	0,4479	0,76	0,6537	0,7012	0,6427
F8	0,6628	0,5050	0,7486	0,6734	0,7074	0,6594
F4	0,5987	0,3439	0,7166	0,6081	0,6569	0,5849
Fz	0,7123	0,6196	0,7617	0,7235	0,7409	0,7116
F3	0,6045	0,3647	0,7339	0,6191	0,6705	0,5985
F7	0,661	0,5000	0,7486	0,6713	0,7062	0,6574
T4	0,7297	0,6611	0,7655	0,7429	0,7523	0,7303
C4	0,7007	0,6347	0,7511	0,7294	0,7363	0,7104
Cz	0,6506	0,4895	0,7365	0,6652	0,6977	0,6479
C3	0,6197	0,3786	0,7464	0,6284	0,6826	0,6111
T3	0,6634	0,5621	0,7166	0,6914	0,7025	0,6672
T6	0,6078	0,5875	0,7511	0,7082	0,7257	0,6760
P4	0,6983	0,6393	0,7919	0,737	0,7626	0,7258
Pz	0,671	0,6871	0,7224	0,7509	0,7347	0,7132
P3	0,7036	0,4612	0,7607	0,6651	0,7198	0,6621
T5	0,6528	0,6339	0,7394	0,7284	0,7337	0,6976
O2	0,7042	0,5500	0,7770	0,6974	0,7347	0,6927
O1	0,7076	0,363	0,6962	0,6101	0,6476	0,6049

Tablo 4.10 incelendiğinde, özellik çıkarımı ve PSD analizi çıktılarının SVM sınıflandırma bulguları karşılaştırılmıştır. Burada frekans bantlarına göre kanallar baz alınarak en yüksek başarı oranları görülmektedir. PSD analizi çıktılarının sınıflandırma başarı oranları, görüleceği üzere daha yüksektir. SVM sınıflandırıcıda da, kNN sınıflandırıcıda olduğu gibi benzer beyin lob kanallarının daha aktif olduğu görülmektedir. Sağ arka temporal ve sol frontal lob kanalları daha belirgin bir şekilde sigara bağımlılık analizinde öne çıkmaktadır.

Tablo 0.12. SVM sonuçları

		Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
PSD	Delta 0-4 Hz	T6	0,8038	0,7880	0,8025	0,7918	0,8107	0,7994
	Teta 4-8 Hz	T6	0,8139	0,8149	0,8115	0,8172	0,8120	0,8139
	Alfa 8-16 Hz	Fp1	0,8183	0,8148	0,8215	0,8278	0,8213	0,8208
	Beta 16-32 Hz	Fz	0,7791	0,7384	0,7960	0,7801	0,7918	0,7771
Özellik Çıkarımı	Delta 0-4 Hz	O1	0,6890	0,6299	0,7815	0,7273	0,7526	0,7161
	Teta 4-8 Hz	T4	0,8006	0,6608	0,764	0,7424	0,7599	0,7456
	Alpha 8-16 Hz	P4	0,6899	0,6316	0,7824	0,7282	0,7534	0,7171
	Beta 16-32 Hz	Fp1	0,7203	0,6545	0,7065	0,7022	0,7099	0,6987

4.3. YSA Sınıflandırma Bulguları

Tablo 4.11’de teta frekans bandında 19 kanalın PSD analizi çıktılarının YSA ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, YSA ile PSD analizi sınıflandırma başarı oranı % 99’a ulaşmıştır. Burada başarı oranlarına bakıldığında T6, T3, F4, Fp1, Fz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ-sol temporal ve sağ frontal lob kanalları öne çıkmaktadır.

Tablo 0.13. YSA PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,9788	0,9630	0,9388	0,9455	0,9425	0,9537
Fp1	0,9770	0,9691	0,9690	0,9691	0,9744	0,9717
F8	0,9765	0,9630	0,9474	0,8955	0,9236	0,9412
F4	0,959	0,9568	0,9902	0,9758	0,9966	0,9757
Fz	0,9743	0,9753	0,9717	0,9516	0,9678	0,9681
F3	0,9572	0,9383	0,9231	0,9327	0,9378	0,9378
F7	0,9661	0,9506	0,9895	0,9376	0,9670	0,9622
T4	0,9586	0,9444	0,9827	0,9617	0,9778	0,9650
C4	0,9550	0,9259	0,9588	0,9508	0,9599	0,9501
Cz	0,9642	0,9444	0,9231	0,9052	0,9178	0,9309
C3	0,9396	0,8951	0,9604	0,9392	0,9509	0,9370
T3	0,9725	0,9815	0,9879	0,9798	0,9801	0,9804
T6	0,9926	0,9938	0,9896	0,9966	0,9902	0,9926
P4	0,9639	0,9691	0,9938	0,8937	0,9173	0,9476
Pz	0,9725	0,9568	0,9749	0,9550	0,9542	0,9627
P3	0,9780	0,9568	0,9266	0,9505	0,9674	0,9559
T5	0,9485	0,9630	0,9907	0,955	0,9744	0,9663
O2	0,9678	0,9136	0,9835	0,9192	0,9236	0,9415
O1	0,9666	0,9215	0,9592	0,9571	0,9693	0,9547

Tablo 4.12’de teta frekans bandında 19 kanalın özellik çıkarımı çıktılarının YSA ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, YSA ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 90’ ulaşmıştır. T4, T3, F4, O1, Pz kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, perietal, sağ frontal ve oksibital lob kanalları öne çıkmaktadır.

Tablo 0.14. YSA özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,9346	0,6960	0,9339	0,8526	0,8958	0,8626
Fp1	0,8590	0,5395	0,9139	0,7871	0,849	0,7897
F8	0,8745	0,6083	0,9001	0,8108	0,8571	0,8102
F4	0,9416	0,7463	0,9159	0,8712	0,8992	0,8748
Fz	0,7911	0,4140	0,8616	0,7320	0,7960	0,7189
F3	0,7980	0,4390	0,8824	0,7452	0,8173	0,7364
F7	0,8736	0,6020	0,9001	0,8082	0,8578	0,8083
T4	0,9646	0,7962	0,9205	0,8945	0,9156	0,8983
C4	0,8768	0,6769	0,8616	0,8325	0,8526	0,8201
Cz	0,8590	0,5894	0,8855	0,8009	0,8463	0,7962
C3	0,8202	0,4536	0,9037	0,7619	0,8326	0,7544
T3	0,8523	0,7687	0,9571	0,8963	0,9314	0,8812
T6	0,8048	0,7053	0,9093	0,8616	0,8861	0,8334
P4	0,9371	0,4347	0,8417	0,7421	0,7918	0,7495
Pz	0,8479	0,8253	0,8732	0,9135	0,8967	0,8713
P3	0,889	0,5542	0,9195	0,8083	0,8775	0,8097
T5	0,8248	0,7622	0,8939	0,8854	0,8933	0,8519
O2	0,9328	0,6612	0,9392	0,8472	0,8954	0,8552
O1	0,8892	0,7622	0,9093	0,8896	0,8973	0,8695

Tablo 4.13’te alfa frekans bandında 19 kanalın PSD analizi çıktılarının YSA ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, YSA ile PSD analizi sınıflandırma başarı oranı % 98’e ulaşmıştır. Burada başarı oranlarına bakıldığında Fp1, Fz, Fp2, T4, P3 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, frontal, sağ perietal ve sağ temporal lob kanalları öne çıkmaktadır.

Tablo 0.15. YSA PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,9406	0,9496	0,9868	0,9797	0,9793	0,9672
Fp1	0,9859	0,9817	0,9898	0,9974	0,9895	0,9889
F8	0,8987	0,7812	0,9437	0,8927	0,9212	0,8875
F4	0,9599	0,9017	0,9719	0,9525	0,9668	0,9506
Fz	0,9956	0,9447	0,9955	0,9768	0,9976	0,982
F3	0,9157	0,8701	0,9240	0,9336	0,9329	0,9153
F7	0,9599	0,8701	0,9890	0,9385	0,9688	0,9453
T4	0,9739	0,9207	0,9824	0,9626	0,9769	0,9633
C4	0,9481	0,9017	0,958	0,9517	0,9592	0,9437
Cz	0,8956	0,8134	0,924	0,9061	0,9194	0,8917
C3	0,925	0,8759	0,9372	0,9375	0,9418	0,9235

Tablo 0.16. (Devam) YSA PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
T3	0,9665	0,9322	0,9674	0,9669	0,9715	0,9609
T6	0,9992	0,7870	0,9535	0,9025	0,9255	0,9135
P4	0,8989	0,9136	0,9640	0,9638	0,9613	0,9403
Pz	0,95	0,9012	0,9948	0,9594	0,9746	0,9560
P3	0,9665	0,9075	0,9940	0,9598	0,9846	0,9625
T5	0,9818	0,8434	0,9389	0,9280	0,9309	0,9246
O2	0,9071	0,9136	0,9948	0,9662	0,9767	0,9517
O1	0,9605	0,9133	0,9945	0,9658	0,9764	0,9621

Tablo 4.14'ta alfa frekans bandında 19 kanalın özellik çıkarımı çıktılarının YSA ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, YSA ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 88'e ulaşmıştır. T4, P4, Pz, Fz, C4 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ perietal, sağ temporal ve orta frontal lob kanalları öne çıkmaktadır.

Tablo 0.17. YSA özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8517	0,6965	0,9357	0,8529	0,8901	0,8454
Fp1	0,7839	0,5396	0,9157	0,7876	0,8448	0,7743
F8	0,7985	0,6084	0,9019	0,8113	0,8523	0,7945
F4	0,7213	0,4143	0,8634	0,7327	0,7915	0,7046
Fz	0,8582	0,7465	0,9177	0,8717	0,8927	0,8574
F3	0,7283	0,4394	0,8842	0,7459	0,8078	0,7211
F7	0,7964	0,6024	0,9019	0,8088	0,8509	0,7921
T4	0,8791	0,7965	0,9223	0,895	0,9064	0,8799
C4	0,8442	0,7647	0,9049	0,8788	0,8871	0,8559
Cz	0,7839	0,5898	0,8873	0,8014	0,8406	0,7806
C3	0,7466	0,4561	0,8993	0,7571	0,8224	0,7363
T3	0,7993	0,6772	0,8634	0,833	0,8464	0,8039
T6	0,7323	0,7078	0,9049	0,8532	0,8743	0,8145
P4	0,8413	0,7702	0,9541	0,8880	0,9188	0,8745
Pz	0,8084	0,8278	0,8704	0,9047	0,8852	0,8593
P3	0,8477	0,5557	0,9165	0,8013	0,8672	0,7977
T5	0,7865	0,7637	0,8909	0,8776	0,8840	0,8405
O2	0,8484	0,6627	0,9362	0,8403	0,8852	0,8346
O1	0,8525	0,4373	0,8388	0,7351	0,7802	0,7288

Tablo 4.15 incelendiğinde, özellik çıkarımı ve PSD analizi çıktılarının YSA sınıflandırma bulguları karşılaştırılmıştır. Burada frekans bantlarına göre kanallar baz alınarak en yüksek başarı oranları görülmektedir. PSD analizi çıktılarının sınıflandırma başarı oranları, görüleceği üzere daha yüksektir. YSA sınıflandırıcı ile temporal, sağ frontal lob ve perietal kanalları daha belirgin bir şekilde sigara bağımlılık analizinde öne çıkmaktadır.

Tablo 0.18. YSA sonuçları

		Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
PSD	Delta 0-4 Hz	T6	0,9802	0,9610	0,9787	0,9656	0,9887	0,9748
	Teta 4-8 Hz	T6	0,9926	0,9938	0,9896	0,9966	0,9902	0,9926
	Alfa 8-16 Hz	Fp2	0,9406	0,9496	0,9868	0,9797	0,9793	0,9672
	Beta 16-32 Hz	Fz	0,9501	0,9005	0,9707	0,9513	0,9656	0,9476
Özellik Çıkarımı	Delta 0-4 Hz	O1	0,8403	0,7682	0,9531	0,8870	0,9178	0,8733
	Teta 4-8 Hz	T3	0,8523	0,7687	0,9571	0,8963	0,9314	0,8812
	Alfa 8-16 Hz	P4	0,8413	0,7702	0,9541	0,888	0,9188	0,8745
	Beta 16-32 Hz	Fp1	0,8784	0,7982	0,8616	0,8563	0,8657	0,852

4.4. LSTM Sınıflandırma Bulguları

Tablo 4.16’da teta frekans bandında 19 kanalın PSD analizi çıktılarının LSTM ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, LSTM ile PSD analizi sınıflandırma başarı oranı % 90’a ulaşmıştır. Burada başarı oranlarına bakıldığında T6, T3, F4, T4, Fp1 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ-sol temporal ve sol frontal lob kanalları öne çıkmaktadır.

Tablo 0.19. LSTM PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8907	0,8763	0,8543	0,8604	0,8577	0,8679
Fp1	0,8891	0,8819	0,8818	0,8819	0,8867	0,8843
F8	0,8886	0,8763	0,8621	0,8149	0,8405	0,8565
F4	0,8727	0,8707	0,9011	0,8880	0,9069	0,8879
Fz	0,8866	0,8875	0,8842	0,8660	0,8807	0,881
F3	0,8711	0,8539	0,8400	0,8488	0,8534	0,8534
F7	0,8792	0,865	0,9004	0,8532	0,8800	0,8756
T4	0,8723	0,8994	0,8943	0,8751	0,8898	0,8861
C4	0,8691	0,8426	0,8725	0,8652	0,8735	0,8646
Cz	0,8774	0,8594	0,8400	0,8237	0,8352	0,8472
C3	0,855	0,8145	0,8740	0,8547	0,8653	0,8527
T3	0,885	0,8932	0,8990	0,8916	0,8919	0,8921
T6	0,9033	0,9044	0,9005	0,9069	0,9011	0,9032
P4	0,8771	0,8819	0,9044	0,8133	0,8347	0,8623
Pz	0,885	0,8707	0,8872	0,8691	0,8683	0,8760
P3	0,89	0,8707	0,8432	0,8650	0,8803	0,8698
T5	0,8631	0,8763	0,9015	0,8691	0,8867	0,8794
O2	0,8807	0,8314	0,8950	0,8365	0,8405	0,8568
O1	0,8796	0,8386	0,8729	0,8710	0,8821	0,8688

Tablo 4.17’de teta frekans bandında 19 kanalın özellik çıkarımı çıktılarının LSTM ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, LSTM ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 82’ye ulaşmıştır. T4, T3, F4, Pz, O1 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ temporal ve sağ frontal lob kanalları öne çıkmaktadır.

Tablo 0.20. LSTM özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8505	0,6334	0,8498	0,7759	0,8152	0,7849
Fp1	0,7817	0,4909	0,8316	0,7163	0,7726	0,7186
F8	0,7958	0,5536	0,8191	0,7378	0,7800	0,7372
F4	0,8569	0,6791	0,8335	0,7928	0,8183	0,7961
Fz	0,7199	0,3767	0,7841	0,6661	0,7244	0,6542
F3	0,7262	0,3995	0,8030	0,6781	0,7437	0,6701
F7	0,7950	0,5478	0,8191	0,7355	0,7806	0,7356
T4	0,8778	0,7245	0,8377	0,8140	0,8332	0,8174
C4	0,7979	0,6160	0,7841	0,7576	0,7759	0,7463
Cz	0,7817	0,5364	0,8058	0,7288	0,7701	0,7246
C3	0,7464	0,4128	0,8224	0,6933	0,7577	0,6865
T3	0,7756	0,6995	0,8710	0,8156	0,8476	0,8019
T6	0,7324	0,6418	0,8275	0,7841	0,8064	0,7584
P4	0,8528	0,3956	0,7659	0,6753	0,7205	0,682
Pz	0,7716	0,7510	0,7946	0,8313	0,8160	0,7929
P3	0,809	0,5043	0,8367	0,7356	0,7985	0,7368
T5	0,7506	0,6936	0,8134	0,8057	0,8129	0,7752
O2	0,8488	0,6017	0,8547	0,7710	0,8148	0,7782
O1	0,8092	0,6936	0,8275	0,8095	0,8165	0,7913

Tablo 4.18’te alfa frekans bandında 19 kanalın PSD analizi çıktıların LSTM ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, LSTM ile PSD analizi sınıflandırma başarı oranı % 90’a ulaşmıştır. Burada başarı oranlarına bakıldığında Fp1, Fz, O2, O1, T4, kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sol frontal, oksibital ve sağ temporal lob kanalları öne çıkmaktadır.

Tablo 0.21. LSTM PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8559	0,8641	0,8980	0,8915	0,8912	0,8802
Fp1	0,8972	0,8933	0,9007	0,9076	0,9004	0,8999
F8	0,8178	0,7109	0,8588	0,8124	0,8383	0,8076
F4	0,8735	0,8205	0,8844	0,8668	0,8798	0,8650
Fz	0,9060	0,8597	0,9059	0,8889	0,9078	0,8937
F3	0,8333	0,7918	0,8408	0,8496	0,8489	0,8329
F7	0,8735	0,7918	0,9000	0,8540	0,8816	0,8602
T4	0,8862	0,8378	0,8940	0,8760	0,8890	0,8766
C4	0,8628	0,8205	0,8718	0,8660	0,8729	0,8588
Cz	0,8150	0,7402	0,8408	0,8246	0,8367	0,8114
C3	0,8418	0,7971	0,8529	0,8531	0,857	0,8404
T3	0,8795	0,8483	0,8803	0,8799	0,8841	0,8744
T6	0,9093	0,7162	0,8677	0,8213	0,8422	0,8313
P4	0,818	0,8314	0,8772	0,8771	0,8748	0,8557
Pz	0,8645	0,8201	0,9053	0,8731	0,8869	0,8700
P3	0,8795	0,8258	0,9045	0,8734	0,8960	0,8759
T5	0,8934	0,7675	0,8544	0,8445	0,8471	0,8414
O2	0,8655	0,8514	0,9053	0,8792	0,8888	0,8780
O1	0,8832	0,8311	0,905	0,8789	0,8885	0,8773

Tablo 4.19’da alfa frekans bandında 19 kanalın özellik çıkarımı çıktılarının LSTM ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, LSTM ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 80’e ulaşmıştır. T4, P4, Pz, C4, Fp2 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, parietal, frontal ve sağ temporal lob kanalları öne çıkmaktadır.

Tablo 0.22. LSTM özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7750	0,6338	0,8515	0,7761	0,8100	0,7693
Fp1	0,7133	0,4910	0,8333	0,7167	0,7688	0,7046
F8	0,7266	0,5536	0,8207	0,7383	0,7756	0,7230
F4	0,6564	0,3770	0,7857	0,6668	0,7203	0,6412
Fz	0,7810	0,6793	0,8351	0,7932	0,8124	0,7802
F3	0,6628	0,4999	0,8046	0,6788	0,7351	0,6762
F7	0,7247	0,5482	0,8207	0,7360	0,7743	0,7208
T4	0,8000	0,7248	0,8393	0,8145	0,8248	0,8007
C4	0,7682	0,6959	0,8235	0,7997	0,8073	0,7789
Cz	0,7133	0,5367	0,8074	0,7293	0,7649	0,7103
C3	0,6794	0,4151	0,8184	0,6890	0,7484	0,6700
T3	0,7274	0,6163	0,7857	0,7580	0,7702	0,7315
T6	0,6664	0,6441	0,8235	0,7764	0,7956	0,7412
P4	0,7656	0,7009	0,8682	0,8081	0,8361	0,7958
Pz	0,7356	0,7533	0,7921	0,8233	0,8055	0,7820
P3	0,7714	0,5057	0,8340	0,7292	0,7892	0,7259
T5	0,7157	0,6950	0,8107	0,7986	0,8044	0,7649
O2	0,7720	0,6031	0,8519	0,7647	0,8055	0,7594
O1	0,7758	0,3979	0,7633	0,6689	0,7100	0,6632

Tablo 4.20 incelendiğinde, özellik çıkarımı ve PSD analizi çıktılarının LSTM sınıflandırma bulguları karşılaştırılmıştır. Burada frekans bantlarına göre kanallar baz alınarak en yüksek başarı oranları görülmektedir. PSD analizi çıktılarının sınıflandırma başarı oranları, görüleceği üzere daha yüksektir. LSTM sınıflandırıcı ile temporal ve sol frontal lob kanalları daha belirgin bir şekilde sigara bağımlılık analizinde öne çıkmaktadır.

Tablo 0.23. LSTM sonuçları

		Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
PSD	Delta 0-4 Hz	T6	0,8920	0,8745	0,8906	0,8787	0,8997	0,8871
	Teta 4-8 Hz	T6	0,9033	0,9044	0,9005	0,9069	0,9011	0,9032
	Alfa 8-16 Hz	Fp1	0,8972	0,8933	0,9007	0,9076	0,9004	0,8999
	Beta 16-32 Hz	Fz	0,8646	0,8195	0,8833	0,8657	0,8787	0,8624
Özellik Çıkarımı	Delta 0-4 Hz	O1	0,7647	0,6991	0,8673	0,8072	0,8352	0,7947
	Teta 4-8 Hz	T4	0,8778	0,7245	0,8377	0,8140	0,8332	0,8174
	Alfa 8-16 Hz	P4	0,7656	0,7009	0,8682	0,8081	0,8361	0,7958
	Beta 16-32 Hz	Fp1	0,7993	0,7264	0,7841	0,7792	0,7878	0,7754

4.5. GRU Sınıflandırma Bulguları

Tablo 4.21’de teta frekans bandında 19 kanalın PSD analizi çıktıların GRU ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, GRU ile PSD analizi sınıflandırma başarı oranı % 89’a ulaşmıştır. Burada başarı oranlarına bakıldığında T6, Fp2, P3, Fp1, F8 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ arka temporal, sol parietal ve frontal lob kanalları öne çıkmaktadır.

Tablo 0.24. GRU PSD analizi teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8619	0,8402	0,8462	0,8435	0,8536	0,8760
Fp1	0,8673	0,8673	0,8673	0,8721	0,8697	0,8744
F8	0,8619	0,8479	0,8015	0,8266	0,8424	0,8740
F4	0,8563	0,8862	0,8733	0,8920	0,8732	0,8583
Fz	0,8729	0,8697	0,8517	0,8662	0,8665	0,8720
F3	0,8398	0,8262	0,8348	0,8393	0,8393	0,8567
F7	0,8508	0,8856	0,8392	0,8655	0,8611	0,8647
T4	0,8452	0,8795	0,8607	0,8751	0,8637	0,8579
C4	0,8287	0,8581	0,8510	0,8591	0,8503	0,8547
Cz	0,8452	0,8262	0,8102	0,8214	0,8332	0,8630
C3	0,8011	0,8596	0,8406	0,8511	0,8387	0,8409
T3	0,8784	0,8842	0,8769	0,8772	0,8774	0,8704
T6	0,8895	0,8857	0,8920	0,8862	0,8883	0,8884
P4	0,8673	0,8895	0,7999	0,8210	0,8481	0,8627
Pz	0,8563	0,8725	0,8547	0,8540	0,8616	0,8704
P3	0,8563	0,8293	0,8507	0,8658	0,8555	0,8753
T5	0,8619	0,8867	0,8547	0,8721	0,8649	0,8489
O2	0,8177	0,8802	0,8227	0,8266	0,8427	0,8662
O1	0,8247	0,8585	0,8566	0,8675	0,8545	0,8651

Tablo 4.22’de teta frekans bandında 19 kanalın özellik çıkarımı çıktıların GRU ile sınıflandırma bulguları görülmektedir. Teta frekans bandında, GRU ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 81’e ulaşmıştır. T4, F4, T3, Pz, O1 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sol-sağ temporal ve oksibital lob kanalları öne çıkmaktadır.

Tablo 0.25. GRU özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8365	0,6229	0,8358	0,7631	0,8017	0,7720
Fp1	0,7688	0,4829	0,8179	0,7045	0,7599	0,7068
F8	0,7827	0,5444	0,8056	0,7257	0,7671	0,7251
F4	0,8427	0,6679	0,8197	0,7797	0,8048	0,7830
Fz	0,7080	0,3705	0,7711	0,6551	0,7124	0,6435
F3	0,7142	0,3929	0,7897	0,6670	0,7315	0,6591
F7	0,7819	0,5388	0,8056	0,7233	0,7677	0,7235
T4	0,8633	0,7126	0,8238	0,8006	0,8195	0,8040
C4	0,7847	0,6058	0,7711	0,7451	0,7631	0,7340

Tablo 0.26. (Devam) GRU özellik çıkarımı teta frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Cz	0,7688	0,5275	0,7925	0,7168	0,7574	0,7126
C3	0,7341	0,4060	0,8088	0,6819	0,7452	0,6752
T3	0,7628	0,6880	0,8566	0,8022	0,8336	0,7886
T6	0,7203	0,6312	0,8138	0,7711	0,7931	0,7459
P4	0,8387	0,3891	0,7533	0,6642	0,7087	0,6708
Pz	0,7589	0,7386	0,7815	0,8176	0,8025	0,7798
P3	0,7957	0,4960	0,8230	0,7234	0,7854	0,7247
T5	0,7382	0,6822	0,8000	0,7924	0,7995	0,7625
O2	0,8349	0,5918	0,8406	0,7582	0,8014	0,7654
O1	0,7958	0,6822	0,8138	0,7962	0,8031	0,7782

Tablo 4.23'te alfa frekans bandında 19 kanalın PSD analizi çıktılarının GRU ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, GRU ile PSD analizi sınıflandırma başarı oranı % 89'a ulaşmıştır. Burada başarı oranlarına bakıldığında Fp1, Fz, Fp2, O1, T4 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, ön frontal ve sağ temporal lob kanalları öne çıkmaktadır.

Tablo 0.27. GRU PSD analizi alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,8418	0,8499	0,8832	0,8768	0,8765	0,8656
Fp1	0,8824	0,8786	0,8859	0,8927	0,8856	0,8850
F8	0,8043	0,6992	0,8446	0,799	0,8245	0,7943
F4	0,8591	0,8070	0,8699	0,8525	0,8653	0,8508
Fz	0,8911	0,8455	0,8910	0,8742	0,8929	0,8789
F3	0,8196	0,7787	0,8270	0,8356	0,8349	0,8192
F7	0,8591	0,7787	0,8852	0,8400	0,8671	0,8460
T4	0,8716	0,8240	0,8792	0,8615	0,8743	0,8622
C4	0,8485	0,8070	0,8574	0,8518	0,8585	0,8446
Cz	0,8016	0,728	0,827	0,8110	0,8229	0,7981
C3	0,8279	0,7839	0,8388	0,8391	0,8429	0,8265
T3	0,8650	0,8343	0,8658	0,8654	0,8695	0,8600
T6	0,8943	0,7044	0,8534	0,8077	0,8283	0,8176
P4	0,8045	0,8177	0,8628	0,8626	0,8604	0,8416
Pz	0,8503	0,8066	0,8903	0,8587	0,8723	0,8556
P3	0,8650	0,8122	0,8896	0,8590	0,8812	0,8614
T5	0,8787	0,7548	0,8403	0,8306	0,8332	0,8275
O2	0,8119	0,8177	0,8903	0,8647	0,8741	0,8518
O1	0,8686	0,8174	0,8901	0,8644	0,8739	0,8629

Tablo 4.24'te alfa frekans bandında 19 kanalın özellik çıkarımı çıktılarının GRU ile sınıflandırma bulguları görülmektedir. Alfa frekans bandında, GRU ile özellik çıkarımı yöntemleri ile sınıflandırma başarı oranı % 79'e ulaşmıştır. T4, P4, Pz, C4, Fp2 kanallarındaki oranlar diğer kanallara göre daha yüksek çıkmıştır. Bu durumda, sağ perietal ve sağ temporal ve sağ ön frontal lob kanalları öne çıkmaktadır.

Tablo 0.28. GRU özellik çıkarımı alfa frekans bandı sonuçları

Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
Fp2	0,7623	0,6234	0,8375	0,7633	0,7966	0,7566
Fp1	0,7016	0,4829	0,8196	0,7049	0,7561	0,6930
F8	0,7147	0,5445	0,8072	0,7261	0,7628	0,7111
F4	0,6456	0,3708	0,7727	0,6558	0,7084	0,6307
Fz	0,7681	0,6681	0,8213	0,7802	0,7990	0,7673
F3	0,6518	0,3933	0,7914	0,6676	0,7230	0,6454
F7	0,7128	0,5391	0,8072	0,7239	0,7616	0,7089
T4	0,7868	0,7129	0,8255	0,8010	0,8112	0,7875
C4	0,7556	0,6844	0,8099	0,7865	0,794	0,7661
Cz	0,7016	0,5279	0,7941	0,7173	0,7523	0,6986
C3	0,6682	0,4082	0,8049	0,6776	0,736	0,659
T3	0,7154	0,6061	0,7727	0,7455	0,7575	0,7195
T6	0,6554	0,6335	0,8099	0,7636	0,7825	0,729
P4	0,753	0,6893	0,8539	0,7948	0,8223	0,7827
Pz	0,7235	0,7409	0,779	0,8097	0,7923	0,7691
P3	0,7587	0,4974	0,8203	0,7172	0,7761	0,7139
T5	0,7039	0,6835	0,7974	0,7855	0,7912	0,7523
O2	0,7593	0,5931	0,8379	0,7521	0,7923	0,7469
O1	0,763	0,3914	0,7507	0,6579	0,6983	0,6523

Tablo 4.25 incelendiğinde, özellik çıkarımı ve PSD analizi çıktılarının GRU sınıflandırma bulguları karşılaştırılmıştır. Burada frekans bantlarına göre kanallar baz alınarak en yüksek başarı oranları görülmektedir. PSD analizi çıktılarının sınıflandırma başarı oranları, görüleceği üzere daha yüksektir. GRU sınıflandırıcı ile temporal, perietal ve frontal lob kanalları daha belirgin bir şekilde sigara bağımlılık analizinde öne çıkmaktadır.

Tablo 0.29. GRU sonuçları

		Kanal	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F-Skor	Ort.
PSD	Delta 0-4 Hz	T6	0,8773	0,8601	0,8759	0,8642	0,8849	0,8525
	Teta 4-8 Hz	T6	0,8884	0,8895	0,8857	0,8920	0,8862	0,8883
	Alfa 8-16 Hz	Fp1	0,8824	0,8786	0,8859	0,8927	0,8856	0,8850
	Beta 16-32 Hz	Fz	0,8503	0,8059	0,8688	0,8514	0,8642	0,8481
Özellik Çıkarımı	Delta 0-4 Hz	O1	0,7521	0,6875	0,8530	0,7939	0,8214	0,7716
	Teta 4-8 Hz	T3	0,7628	0,6880	0,8566	0,8022	0,8336	0,7886
	Alfa 8-16 Hz	T4	0,7868	0,7129	0,8255	0,8010	0,8112	0,7875
	Beta 16-32 Hz	Fp1	0,7862	0,7144	0,7711	0,7664	0,7748	0,7626

Genel olarak tüm algoritmalar arasında karşılaştırma yapıldığında YSA ve LSTM algoritmalarının en yüksek performansı sergilediği görülmektedir. YSA alfa ve teta frekans bandında en yüksek doğruluk ve duyarlılık oranlarına ulaşırken, LSTM ise teta frekans bandında en iyi sonuçları elde etmiştir. kNN ve SVM algoritmalarının performansları ise belirli frekans bantlarında ve kanallarda değişiklik göstermektedir. GRU algoritması ise genel olarak iyi performans sergilemekle birlikte, belirli frekans bantlarında YSA ve LSTM kadar yüksek performans göstermemiştir. RNN modellerinin ileri beslemeli

YSA'lardan daha düşük sonuçlara ulaşmasının sebepleri arasında, Veri çeşitliliği, RNN'lerin eğitim ve hiperparametre ayarlarının daha karmaşık olması ve YSA'nın daha basit bir ağ mimarisi ile daha stabil performans göstermesi sayılabilir.

Çalışmanın sonuçları ve analizlerini görmek için tez çalışması ile ilgili yazılmış bilimsel makaleyi araştırarak daha detaylı bilgi edinmek mümkündür (Çay vd., 2024). Araştırma çalışmanın bulgularını daha geniş bir perspektiften değerlendirmeye olanak tanıyacak ve elde edilen verilerin geçerliliği hakkında daha derinlemesine bilgi sunacaktır.



5. SONUÇ VE DEĞERLENDİRME

Sigara bağımlılığı, dünya genelinde ciddi sağlık sorunlarına yol açan yaygın bir problemdir. Bağımlılığın tespiti ve tedavisi için çeşitli yöntemler kullanılmakla birlikte, son yıllarda Elektroensefalografi (EEG) tabanlı yaklaşımlar dikkat çekmektedir. EEG, beyin dalgalarının elektriksel aktivitesini ölçen ve bu aktiviteleri çeşitli frekans bantlarında inceleyen bir yöntemdir. Sigara bağımlılığı durumunda, beyin aktivitelerindeki değişiklikler gözlemlenebilir. Bu çalışma, sigara bağımlılığının EEG verileri ile tespit edilmesinde makine öğrenmesi algoritmalarının etkinliğini araştırmaktadır.

Çalışmanın sonuçları, sigara bağımlılığının EEG verileri ile tespit edilmesinde makine öğrenmesi algoritmalarının yüksek doğruluk oranları sunduğunu göstermektedir. Bu durum, geleneksel yöntemlere kıyasla daha objektif ve hızlı bir bağımlılık tespiti sağlamaktadır. EEG verilerinin analiz edilmesi, bağımlılık derecelerinin belirlenmesi açısından önemli ipuçları sunmaktadır. Kullanılan yöntemler arasında en yüksek başarı oranları ileri beslemeli YSA (% 99) ve sinyal işlemede sıkça kullanılan RNN modellerinden LSTM'dir (% 92). Bu algoritmaların özellikle alfa ve teta frekans bantlarında prefrontal ve temporal loblardaki kanalların EEG verileri sınıflandırma başarıları dikkat çekicidir. Özellikle teta frekans bandındaki yüksek başarı oranları, bu frekans aralığının bağımlılık tespiti için kritik olduğunu göstermektedir. Prefrontal ve temporal loblardaki kanalların beyin aktivitelerinin sigara bağımlılığı ile doğrudan ilişkili olduğu ortaya konmuştur. Literatür taraması, EEG ile sigara bağımlılığı üzerine yapılan çalışmalarda benzer beyin bölgelerinin ve frekans bileşenlerinin daha aktif olduğunu göstermektedir. Bu bulgular sigara bağımlılığının beyin üzerindeki etkilerini anlamada önemli bilgiler sunmakta ve EEG tabanlı bağımlılık tespiti çalışmalarının gelecekteki yönünü belirlemektedir.

Ayrıca, kullanılan makine öğrenmesi algoritmalarının parametre ayarlarının optimizasyonu da sonuçları etkileyebilmektedir. Bu nedenle gelecekteki çalışmalarda daha detaylı parametre optimizasyonları yapılabilir. Bunun yanı sıra, farklı bağımlılık türleri için de benzer EEG tabanlı yöntemlerin uygulanması, genel bir bağımlılık tespit modeli geliştirilmesine katkı sağlayabilir.

Elde edilen bulgular, bu alanda yapılan araştırmaların önemini vurgulamakta ve gelecekteki çalışmalar için sağlam bir temel oluşturmaktadır. EEG verilerinin analizi ve makine öğrenmesi algoritmalarının kullanımı, bağımlılık tespiti ve tedavisi için yeni

alternatifler sunmaktadır. Çalışmanın sonuçları, sigara bağımlılığının tespiti konusunda EEG tabanlı yöntemlerin etkinliğini kanıtlamaktadır. Bu bağlamda, EEG ve makine öğrenmesi kombinasyonunun bağımlılık tespiti ve tedavisinde kullanılması, hem klinik uygulamalar hem de bireysel sağlık yönetimi açısından önemli bir ilerleme kaydedebilir. Gelecekteki çalışmalar, bu bulguları daha geniş ve çeşitli veri setleri ile desteklemeli ve EEG tabanlı bağımlılık tespiti modellerinin doğruluğunu artırmak için yeni algoritmalar ve özellik çıkarım yöntemleri geliştirilmelidir. Bu çalışmalar, sigara bağımlılığı gibi ciddi sağlık sorunlarının erken tespiti ve önlenmesi açısından büyük bir önem taşımaktadır. EEG verilerinin kullanımı, bağımlılık tespiti konusunda sadece sigara bağımlılığı ile sınırlı kalmamalı, alkol ve diğer madde bağımlılıkları gibi farklı bağımlılık türlerinde de uygulanmalıdır. Buna ek olarak, bağımlılık tespiti çalışmalarında bireylerin beyin aktivitelerinin yanı sıra psikolojik ve davranışsal verilerin de entegre edilmesi, daha kapsamlı ve güvenilir sonuçlar elde edilmesine katkı sağlayabilir. Bu tür multidisipliner yaklaşımlar, bağımlılık tedavisi ve önleyici sağlık hizmetleri alanında daha etkili stratejilerin geliştirilmesine olanak tanıyabilir. Sonuç olarak, bu çalışma, EEG tabanlı makine öğrenmesi yöntemlerinin sigara bağımlılığını tespit etme konusundaki potansiyelini açıkça ortaya koymakta ve bu alandaki gelecekteki araştırmalar için önemli bir temel oluşturmaktadır.

6. KAYNAKLAR

- Agrawal, P., Girshick, R., & Malik, J. (2014). Analyzing the Performance of Multilayer Neural Networks for Object Recognition. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8695 LNCS(PART 7), 329–344. https://doi.org/10.1007/978-3-319-10584-0_22
- Alday, L. F., & Roiban, R. (2008). Scattering amplitudes, Wilson loops and the string/gauge theory correspondence. *Physics Reports*, 468(5), 153–211. <https://doi.org/10.1016/j.physrep.2008.08.002>
- Bahi, M., & Batouche, M. (2018). Deep Learning for Ligand-Based Virtual Screening in Drug Discovery. *Proceedings - PAIS 2018: International Conference on Pattern Analysis and Intelligent Systems*. <https://doi.org/10.1109/PAIS.2018.8598488>
- Başar, E., Başar-Eroglu, C., Karakaş, S., & Schürmann, M. (2001). Gamma, alpha, delta, and theta oscillations govern cognitive processes. *International Journal of Psychophysiology*, 39(2–3), 241–248. [https://doi.org/10.1016/S0167-8760\(00\)00145-8](https://doi.org/10.1016/S0167-8760(00)00145-8)
- Bear, M., Connors, B., & Paradiso, M. (2016). *Neurosciences: à la découverte du cerveau*. John Libbey Eurotext.
- Blinowska, K., & Durka, P. (2006). *Electroencephalography (EEG)*. John Wiley & Sons, Inc.
- Bos, D. O. (2006). EEG-based Emotion Recognition The Influence of Visual and Auditory Stimuli. *The Influence of Visual and Auditory Stimuli*, 56(3), 1–17. <http://en.wikipedia.org/wiki/Robert>
- Brockwell, P., & Davis, R. (2002). *Introduction to time series and forecasting*. New York, NY: Springer New York. https://link.springer.com/content/pdf/10.1007/0-387-21657-X_8.pdf
- Bu, J., Young, K. D., Hong, W., Ma, R., Song, H., Wang, Y., Zhang, W., Hampson, M., Hendler, T., & Zhang, X. (2019). Effect of deactivation of activity patterns related to smoking cue reactivity on nicotine addiction. *Brain*, 142(6), 1827–1841. <https://doi.org/10.1093/BRAIN/AWZ114>

- Çay, T., Ölmez, E., Tanık, N., & Altın, C. (2024). EEG Based Cigarette Addiction Detection with Deep Learning. *Traitement Du Signal*, 41(3), 1183–1192. <https://doi.org/10.18280/TS.410308>
- Chang, C. C., & Lin, C. J. (2011a). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3). <https://doi.org/10.1145/1961189.1961199>
- Chang, C. C., & Lin, C. J. (2011b). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3). <https://doi.org/10.1145/1961189.1961199>
- Chang, K.-W., Hsieh, C.-J., & Lin, C.-J. (2008). LIBLINEAR: A Library for Large Linear Classification Rong-En Fan Xiang-Rui Wang. *Journal of Machine Learning Research*, 9, 1871–1874.
- Cheng, Y., Bu, J., Li, N., Li, J., Gou, H., Sun, S., Liu, C., Jin, Z., He, C., Fan, C., Liu, C., & Zhang, X. (2020). Dysfunctional resting-state EEG microstate correlated with the severity of cigarette exposure in nicotine addiction. *Science China Information Sciences*, 63(7), 1–3. <https://doi.org/10.1007/S11432-019-2819-Y/METRICS>
- Chin, L. C., Zazid, A. M., Fook, C. Y., Vijean, V., Awang, S. A., Affandi, M., & Chee, L. S. (2019). Differentiate Characteristic EEG Tobacco Smoking and Non-smoking. *Journal of Physics: Conference Series*, 1372(1), 012055. <https://doi.org/10.1088/1742-6596/1372/1/012055>
- Chollet, F. (2017). *Xception: Deep Learning With Depthwise Separable Convolutions*. [conference session]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Chua, K. C., Chandran, V., Acharya, U. R., & Lim, C. M. (2010). Application of higher order statistics/spectra in biomedical signals—A review. *Medical Engineering & Physics*, 32(7), 679–689. <https://doi.org/10.1016/J.MEDENGPHY.2010.04.009>
- Conway, C. M. (2020). How does the brain learn environmental structure? Ten core principles for understanding the neurocognitive mechanisms of statistical learning. *Neuroscience & Biobehavioral Reviews*, 112, 279–299. <https://doi.org/10.1016/J.NEUBIOREV.2020.01.032>

- Cortes, C., Vapnik, V., & Saitta, L. (1995). Support-vector networks. *Machine Learning* 1995 20:3, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Da Silva, F. L. (2022). EEG: Origin and Measurement. *EEG-FMRI: Physiological Basis, Technique, and Applications, Second Edition*, 23–48. https://doi.org/10.1007/978-3-031-07121-8_2
- Damasio, H. (2005). *Human brain anatomy in computerized images*. Oxford university press.
- Daubechies, I. (1992). *Ten lectures on wavelets*. Society for industrial and applied mathematics.
- Dauphin, Y. N., Pascanu, R., Gulcehre, C., Cho, K., Ganguli, S., & Bengio, Y. (2014). Identifying and attacking the saddle point problem in high-dimensional non-convex optimization. In *Advances in Neural Information Processing Systems* (Vol. 27).
- Delorme, A., & Makeig, S. (2004a). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1), 9–21. <https://doi.org/10.1016/J.JNEUMETH.2003.10.009>
- Delorme, A., & Makeig, S. (2004b). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1), 9–21. <https://doi.org/10.1016/J.JNEUMETH.2003.10.009>
- Dietterich, T. (1995). Overfitting and Undercomputing in Machine Learning. *ACM Computing Surveys (CSUR)*, 27(3), 326–327.
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78–87. <https://doi.org/10.1145/2347736.2347755>
- Edfors, O., Sandell, M., Van Beek, J. J. De, Wilson, S. K., & Börjesson, P. O. (1998). OFDM channel estimation by singular value decomposition. *IEEE Transactions on Communications*, 46(7), 931–939. <https://doi.org/10.1109/26.701321>
- Fagerström, K. O. (1978). Measuring degree of physical dependence to tobacco smoking with reference to individualization of treatment. *Addictive Behaviors*, 3(3–4), 235–

241. [https://doi.org/10.1016/0306-4603\(78\)90024-2](https://doi.org/10.1016/0306-4603(78)90024-2)

- Fagerstrom, K. O., & Schneider, N. G. (1989). Measuring nicotine dependence: A review of the Fagerstrom Tolerance Questionnaire. *Journal of Behavioral Medicine*, 12(2), 159–182. <https://doi.org/10.1007/BF00846549/METRICS>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>
- Gonog, L., & Zhou, Y. (2019a). A review: Generative adversarial networks. *Proceedings of the 14th IEEE Conference on Industrial Electronics and Applications, ICIEA 2019*, 505–510. <https://doi.org/10.1109/ICIEA.2019.8833686>
- Gonog, L., & Zhou, Y. (2019b). A review: Generative adversarial networks. *Proceedings of the 14th IEEE Conference on Industrial Electronics and Applications, ICIEA 2019*, 505–510. <https://doi.org/10.1109/ICIEA.2019.8833686>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT press.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Proceedings.Neurips.CcI Goodfellow, J Pouget-Abadie, M Mirza, B Xu, D Warde-Farley, S Ozair, A CourvilleAdvances in Neural Information Processing Systems, 2014•proceedings.Neurips.Cc.* <https://proceedings.neurips.cc/paper/5423-generative-adversarial-nets>
- Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 6645–6649. <https://doi.org/10.1109/ICASSP.2013.6638947>
- Hamad, A., Hassanien, A. E., Houssein, E. H., & Fahmy, A. A. (2017). Feature extraction of epilepsy EEG using discrete wavelet transform. *2016 12th International Computer Engineering Conference, ICENCO 2016: Boundless Smart Societies*, 190–195. <https://doi.org/10.1109/ICENCO.2016.7856467>
- Han, S., Pool, J., Tran, J., & Dally, W. J. (2015). Learning both Weights and Connections for Efficient Neural Network. *Advances in Neural Information Processing Systems*,

- Hanafiah, Z. M., Hamid, N. H. A., & Taib, M. N. (2011). Theta, alpha and beta band frequencies of different nicotine dependency level among smokers. *Proceedings - 2011 IEEE 7th International Colloquium on Signal Processing and Its Applications, CSPA 2011*, 80–83. <https://doi.org/10.1109/CSPA.2011.5759847>
- Hanafiah, Z. M., Hj Murat, Z., Taib, M. N., & Lias, S. (2010). Initial investigation of the Alpha and Beta bands for smokers using EEG. *Proceedings - CSPA 2010: 2010 6th International Colloquium on Signal Processing and Its Applications*, 246–249. <https://doi.org/10.1109/CSPA.2010.5545288>
- Hanafiah, Z. M., Taib, M. N., & Hamid, N. H. A. (2010). EEG pattern of smokers for Theta, Alpha and Beta Band frequencies. *Proceeding, 2010 IEEE Student Conference on Research and Development - Engineering: Innovation and Beyond, SCOReD 2010*, 320–323. <https://doi.org/10.1109/SCORED.2010.5704025>
- Hasan, M., Hasan, N., ... A. R.-2019 I., & 2019, undefined. (2019). Effect of Smoking in EEG Pattern and Time-Frequency Domain Analysis for Smoker and Non-Smoker. *Ieeexplore.Ieee.OrgMM Hasan, N Hasan, A Rahman, MM Rahman2019 International Conference on Computer, Communication, Chemical, 2019•ieeexplore.Ieee.Org*. <https://doi.org/10.1109/IC4ME247184.2019.9036492>
- Hasan, M. M., Hasan, N., Alsubaie, M. S. A., & Komol, M. M. R. (2021). Diagnosis of tobacco addiction using medical signal: An EEG-based time-frequency domain analysis using machine learning. *Advances in Science, Technology and Engineering Systems*, 6(1), 842–849. <https://doi.org/10.25046/AJ060193>
- Hastie, T., Friedman, J., & Tibshirani, R. (2001). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-21606-5>
- Hastie, T., Tibshirani, R., Friedman, J., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction. *New York: Springer*, 2, 1–758.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification*. 1026–1034.
- Heatherton, T. F., Kozlowski, L. T., Frecker, R. C., & Fagerstrom, K. -O. (1991a). The Fagerström Test for Nicotine Dependence: a revision of the Fagerstrom Tolerance

- Questionnaire. *British Journal of Addiction*, 86(9), 1119–1127.
<https://doi.org/10.1111/J.1360-0443.1991.TB01879.X>
- Heatherton, T. F., Kozlowski, L. T., Frecker, R. C., & Fagerstrom, K. -O. (1991b). The Fagerström Test for Nicotine Dependence: a revision of the Fagerstrom Tolerance Questionnaire. *British Journal of Addiction*, 86(9), 1119–1127.
<https://doi.org/10.1111/J.1360-0443.1991.TB01879.X>
- Hinton, G., & Sejnowski, T. (1999). *Unsupervised learning: foundations of neural computation*. MIT press.
[https://books.google.com/books?hl=tr&lr=&id=yj04Y0lje4cC&oi=fnd&pg=PR7&dq=Hinton,+G.,+%26+Sejnowski,+T.+J.,+\(Eds.\).+\(1999\).+Unsupervised+learning:+foundations+of+neural+computation.+MIT+press&ots=b0pDVVc1fB&sig=aWjw6l6Z4tK0CgX3xsKsgCTek5o](https://books.google.com/books?hl=tr&lr=&id=yj04Y0lje4cC&oi=fnd&pg=PR7&dq=Hinton,+G.,+%26+Sejnowski,+T.+J.,+(Eds.).+(1999).+Unsupervised+learning:+foundations+of+neural+computation.+MIT+press&ots=b0pDVVc1fB&sig=aWjw6l6Z4tK0CgX3xsKsgCTek5o)
- Hinton, G., Srivastava, N., On, K. S.-C., & 2012, U. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cs.Toronto.Edu*, 14(8), 2.
- Hudspeth, A. J., Jessell, T. M., Kandel, E. R., Schwartz, J. H., & Siegelbaum, S. A. (2013). Principles of Neural Science. *Health Professions Division*.
https://scholar.google.com/scholar?hl=tr&as_sdt=0%2C5&q=E.+Kandel+et+al.%2C+%22Principles+of+Neural+Science%2C%22+McGraw-Hill+Education%2C+2013&btnG=
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning. *New York: Springer.*, 112, 18.
- Kay, S. M. (1988). *Modern Spectral Estimation*. Pearson Education India.
- Kingma, D. P., & Ba, J. L. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- Klem, G. H. (1999). The ten-twenty electrode system of the international federation. The international federation of clinical neurophysiology. In *cir.nii.ac.jp* (Vol. 52, pp. 3–6). The international federation of clinical neurophysiology. Electroencephalogr. Clin. Neurophysiol. Suppl.

- Klema, V. C., & Laub, A. J. (1980). The Singular Value Decomposition: Its Computation and Some Applications. *IEEE Transactions on Automatic Control*, 25(2), 164–176. <https://doi.org/10.1109/TAC.1980.1102314>
- Kunze, U., Schmeiser-Rieder, A., & Schoberberger, R. (1998). [European Medical Association Smoking or Health (EMASH)--consensus on smoking cessation: guidelines for physicians]. *Sozial- Und Praventivmedizin*, 43(3), 167–172. <https://doi.org/10.1007/BF01359725>
- Lashgari, E., Liang, D., & Maoz, U. (2020). Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 346, 108885. <https://doi.org/10.1016/J.JNEUMETH.2020.108885>
- Laufs, H. (2012). Functional imaging of seizures and epilepsy: Evolution from zones to networks. *Current Opinion in Neurology*, 25(2), 194–200. <https://doi.org/10.1097/WCO.0B013E3283515DB9>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Lee, H., Jeon, Y., Yoo, C., Seon, H. Y., Park, J., Hwang, M., Baek, K., & Chung, D. (2023). Persistent impacts of smoking on resting-state EEG in male chronic smokers and past-smokers with 20 years of abstinence. *Scientific Reports 2023* 13:1, 13(1), 1–11. <https://doi.org/10.1038/s41598-023-29547-3>
- Lipton, Z. C., Berkowitz, J., & Elkan, C. (2015). *A Critical Review of Recurrent Neural Networks for Sequence Learning*. <https://arxiv.org/abs/1506.00019v4>
- Luck, S. (2014). *An introduction to the event-related potential technique*. MIT press.
- Ma, J., & Tang, J. (2017). A review for dynamics in neuron and neuronal network. *Nonlinear Dynamics*, 89(3), 1569–1578. <https://doi.org/10.1007/S11071-017-3565-3/METRICS>
- Mallat, S. (1999). *A wavelet tour of signal processing*. Elsevier.
- Mallat, S. G. (1989). A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674–693. <https://doi.org/10.1109/34.192463>
- McFarland, D. J., & Wolpaw, J. R. (2011). Brain-computer interfaces for communication

- and control. *Communications of the ACM*, 54(5), 60–66.
<https://doi.org/10.1145/1941487.1941506>
- Misra, D. (2019, August 23). Mish: A Self Regularized Non-Monotonic Activation Function. *31st British Machine Vision Conference, BMVC 2020*.
<https://arxiv.org/abs/1908.08681v3>
- Mitchell, T. M. (1997). *Machine Learning*. New York: McGraw-Hill, 1(9).
- Molchanov, P., Tyree, S., Karras, T., Aila, T., & Kautz, J. (2016, November 19). Pruning Convolutional Neural Networks for Resource Efficient Inference. *5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings*. <https://arxiv.org/abs/1611.06440v2>
- Murphy, K. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Neuroscience: Exploring the Brain, Enhanced Edition: Exploring the Brain ...* - Mark Bear, Barry Connors, Michael A. Paradiso - Google Kitaplar. (n.d.). Retrieved June 28, 2024, from https://books.google.com.tr/books?hl=tr&lr=&id=m-PcDwAAQBAJ&oi=fnd&pg=PP1&dq=Neuroscience:+Exploring+the+Brain&ots=Ez7xGfSbBS&sig=1A4ulxTjQ9M4f7zlluVz0Hs9VZg&redir_esc=y#v=onepage&q=Neuroscience%3AExploringtheBrain&f=false
- Ng, A. Y. (1997). Preventing "overfitting" of cross-validation data. *ICML*, 97, 245–253.
- Niedermeyer, E. (2011). *Niedermeyer's Electroencephalography: Basic Principles, Clinical*. Lippincott Williams & Wilkins.
- Nielsen, M. (2015). *Neural networks and deep learning*. USA: Determination press.
- O'Byrne, J., & Jerbi, K. (2022). How critical is brain criticality? *Trends in Neurosciences*, 45(11), 820–837. <https://doi.org/10.1016/J.TINS.2022.08.007>
- Ocak, H. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 36(2), 2027–2036. <https://doi.org/10.1016/J.ESWA.2007.12.065>
- Onay, F. K., & Kose, C. (2019). Power spectral density analysis in alfa, beta and gamma frequency bands for classification of motor EEG signals. *27th Signal Processing and Communications Applications Conference, SIU 2019*.
<https://doi.org/10.1109/SIU.2019.8806385>

- Oostenveld, R., & Praamstra, P. (2001). The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*, 112(4), 713–719. [https://doi.org/10.1016/S1388-2457\(00\)00527-7](https://doi.org/10.1016/S1388-2457(00)00527-7)
- Oppenheim, A. V. (1999). Discrete-time signal processing. *Pearson Education India*.
- Organization, W. H. (2019). *WHO report on the global tobacco epidemic, 2019: offer help to quit tobacco use*. <https://apps.who.int/iris/bitstream/handle/10665/326043/9789240029545-rus.pdf>
- Percival, D., & Walden, A. (2000). *Wavelet methods for time series analysis*. Cambridge university press.
- Peter, H., & Westfall ; R, I. P. (2014). Kurtosis as Peakedness, 1905–2014. R.I.P. *The American Statistician*, 68(3), 191–195. <https://doi.org/10.1080/00031305.2014.917055>
- Pomerleau, C. S., Carton, S. M., Lutzke, M. L., Flessland, K. A., & Pomerleau, O. F. (1994). Reliability of the fagerstrom tolerance questionnaire and the fagerstrom test for nicotine dependence. *Addictive Behaviors*, 19(1), 33–39. [https://doi.org/10.1016/0306-4603\(94\)90049-3](https://doi.org/10.1016/0306-4603(94)90049-3)
- Porter, D. C., Burr Ridge, B., Dubuque, I., New York San Francisco St Louis Bangkok Bogotá Caracas Kuala Lumpur Lisbon London Madrid Mexico City Milan Montreal New Delhi Santiago Seoul Singapore Sydney Taipei Toronto, I., & Gujarati, D. N. (2009). *Basic econometrics*. McGraw-hill.
- Powers, D. M. W. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *ArXiv Preprint ArXiv:2010.16061*. <https://arxiv.org/abs/2010.16061v1>
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural Networks*, 12(1), 145–151. [https://doi.org/10.1016/S0893-6080\(98\)00116-6](https://doi.org/10.1016/S0893-6080(98)00116-6)
- Ruder, S. (2016a, September). *An overview of gradient descent optimization algorithms*.
- Ruder, S. (2016b, September 15). *An overview of gradient descent optimization algorithms*.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature* 1986 323:6088, 323(6088), 533–536.

<https://doi.org/10.1038/323533a0>

- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3), 210–229. <https://doi.org/10.1147/RD.33.0210>
- Schölkopf, B., & Smola, A. (2002). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press.
- Searle, J. R. (1990). Is the Brain a Digital Computer? *Proceedings and Addresses of the American Philosophical Association*, 64(3), 21. <https://doi.org/10.2307/3130074>
- Setiawan, H. (2018). Measurement of Brain Activity Rate Based on Electroencefalographical Signals on Smokers. *Jurnal Inotera*, 3(1), 15–22. <https://doi.org/10.31572/INOTERA.VOL3.ISS1.2018.ID40>
- Shannon, B. J., & Paliwal, K. K. (2006). Feature extraction from higher-lag autocorrelation coefficients for robust speech recognition. *Speech Communication*, 48(11), 1458–1485. <https://doi.org/10.1016/J.SPECOM.2006.08.003>
- Sheykhivand, S., Rezaii, T. Y., Mousavi, Z., Meshgini, S., Makouei, S., Farzamnia, A., Danishvar, S., & Teo Tze Kin, K. (2022). Automatic Detection of Driver Fatigue Based on EEG Signals Using a Developed Deep Neural Network. *Electronics* 2022, Vol. 11, Page 2169, 11(14), 2169. <https://doi.org/10.3390/ELECTRONICS11142169>
- Silva, F. L. da, & Niedermeyer, E. (2005). *Electroencephalography, basic principles, clinical applications and related fields*. <https://dare.uva.nl/record/210389>
- Sokolova, M., Japkowicz, N., & Szpakowicz, S. (2006). Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation. *AAAI Workshop - Technical Report*, WS-06-06, 1015–1021. https://doi.org/10.1007/11941439_114
- Stoica, P. P., & Moses, R. L. (2005). Spectral Analysis of Signals | Request PDF. *Upper Saddle River, NJ: Pearson Prentice Hall*, 452, 25–26.
- Strahler, A. N. (1954). Statistical Analysis in Geomorphic Research. <https://doi.org/10.1086/626131>, 62(1), 1–25. <https://doi.org/10.1086/626131>
- Strang, G., & Nguyen, T. (1996). *Wavelets and filter banks*. SIAM.

- SU, S., YU, D., BU, L., MA, Y., CHEN, Y., ZHANG, X., & YUAN, K. (2017). The changes of EEG signals during resting state in adolescents with smoking addiction. *Chinese Journal of Behavioral Medicine and Brain Science*, 1021–1024. <https://doi.org/10.3760/CMA.J.ISSN.1674-6554.2017.11.012>
- Sundararajan, D. (2016). *Discrete wavelet transform: a signal processing approach*. John Wiley & Sons.
- Suteeca, R. (2017). Frameworks of the relations of the “Customer Value” for the “Start-Up” business through “e-service” in the North of Thailand. *2nd Joint International Conference on Digital Arts, Media and Technology 2017: Digital Economy for Sustainable Growth, ICDAMT 2017*, 142–145. <https://doi.org/10.1109/ICDAMT.2017.7904951>
- Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013). On the importance of initialization and momentum in deep learning. *Proceedings of Machine Learning Research*, 28(3), 1139–1147.
- Tamburin, S., Dal Lago, D., Armani, F., Turatti, M., Saccà, R., Campagnari, S., & Chiamulera, C. (2021). Smoking-related cue reactivity in a virtual reality setting: association between craving and EEG measures. *Psychopharmacology*, 238(5), 1363–1371. <https://doi.org/10.1007/S00213-020-05733-3/FIGURES/7>
- Taylor, J. S., & Cristianini, N. (2004). *Kernel Methods for Pattern Analysis*. Cambridge University Press.
- Tieleman, T. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. In *cir.nii.ac.jp* (Vol. 4, Issue 2, p. 26). COURSERA: Neural networks for machine learning.
- Türk, Ö., Siraç ÖZERDEM, M., & Akpolat, N. (2015). Dicle Üniversitesi Mühendislik Fakültesi mühendislik dergisi Gözler açık/kapalı durumunda EEG bantlarındaki frekans değişiminin Güç Spektral Yoğunluğu ile belirlenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 6(2), 131–138.
- Uysal, M. A., Kadakal, F., Karşıdağ, C., Bayram, N. G., Uysal, O., & Yilmaz, V. (2004). Fagerstrom test for nicotine dependence: reliability in a Turkish sample and factor analysis. *Tuberk Toraks*, 52(2), 115–121.

- Wang, R., Wang, J., Yu, H., Wei, X., Yang, C., & Deng, B. (2015). Power spectral density and coherence analysis of Alzheimer's EEG. *Cognitive Neurodynamics*, 9(3), 291–304. <https://doi.org/10.1007/S11571-014-9325-X/TABLES/3>
- Welch, P. D. (1967). The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. *IEEE Transactions on Audio and Electroacoustics*, 15(2), 70–73. <https://doi.org/10.1109/TAU.1967.1161901>
- Wirapatrungsri, S., & Sittiprapaporn, P. (2017). Alteration of human brainwaves to the single dose of nicotine patch. *2nd Joint International Conference on Digital Arts, Media and Technology 2017: Digital Economy for Sustainable Growth, ICDAMT 2017*, 360–363. <https://doi.org/10.1109/ICDAMT.2017.7904992>
- Witschi, H. (2005). Tobacco smoking. *Toxicology of the Lung, Fourth Edition*, 23(2), 623–647. <https://doi.org/10.29309/tpmj/2015.22.04.1329>
- Xu, B., Wang, N., Kong, H., Chen, T., & Li, M. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network. *ArXiv Preprint ArXiv:1505.00853*.
- Yang, S., Yu, X., & Zhou, Y. (2020a). LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example. *Proceedings - 2020 International Workshop on Electronic Communication and Artificial Intelligence, IWECAI 2020*, 98–101. <https://doi.org/10.1109/IWECAI50956.2020.00027>
- Yang, S., Yu, X., & Zhou, Y. (2020b). LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example. *Proceedings - 2020 International Workshop on Electronic Communication and Artificial Intelligence, IWECAI 2020*, 98–101. <https://doi.org/10.1109/IWECAI50956.2020.00027>
- Yilmaz, F. M., & Yildiztepe, E. (2024). Statistical Evaluation of Deep Learning Models for Stock Return Forecasting. *Computational Economics*, 63(1), 221–244. <https://doi.org/10.1007/S10614-022-10338-3/FIGURES/8>
- Zhang, D. (2019). Wavelet Transform. *Classification and Retrieval*, 35–44. https://doi.org/10.1007/978-3-030-17989-2_3

EKLER

Ek-1 Etik Kurul Onayı/İzni



T.C.
YOZGAT BOZOK ÜNİVERSİTESİ REKTÖRLÜĞÜ
KLİNİK ARAŞTIRMALAR ETİK KURULU

KLİNİK ARAŞTIRMALAR ETİK KURULU KARARI

TOPLANTI TARİHİ : 19.12.2023
TOPLANTI SAYISI : 19
DOSYA KAYIT NUMARASI : 2022-08-82
KARAR NUMARASI : 2017-KAEK-189_2023.12.19_04
SORUMLU ARAŞTIRMACI : Dr. Öğr. Üyesi Cemil Altın
YARDIMCI ARAŞTIRMACILAR : Talip Çay, Dr. Nermin Tanık.

Yozgat Bozok Üniversitesi Mühendislik Fakültesi öğretim üyesi Dr. Öğr. Üyesi Cemil Altın sorumluluğunda yürütülecek olan 2022-08-82 kayıt numaralı “Sigara Bağımlılığı Seviyesinin Biyolojik Sinyaller Kullanarak Makine Öğrenmesi Yöntemleri ile Tespiti” başlıklı çalışma dosyasında yapılacak olan düzeltme/değişiklikler “İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik”, “İyi Klinik Uygulamaları Kılavuzu” ve “Bozok Üniversitesi Klinik Araştırmalar Etik Kurulu Yönergesi” ne göre değerlendirilmiştir. Çalışmada yapılacak olan değişikliklerin etik ve bilimsel açıdan uygun olduğuna oy birliği ile karar verilmiştir.

Dr. Öğr. Üyesi Ayça ÇAKMAK AYDIN (Başkan)Üye :
Doç. Dr. Demet AYDOĞAN KIRMIZI (Başkan yardımcısı) Üye:
Uzm. Dr. Ayşen SÜRMEN (bildirimlerden sorumlu)Üye :
Doç. Dr. Yavuz Selim INTEPE Üye :
Dr. Öğr. Üyesi Levent ALBAYRAK Üye :
Doç. Dr. Mehmet HAMAMCI Üye :
Doç. Dr. Yunus HACIMUSALAR Üye :
Doç. Dr. Yaşar TURAN Üye :
Dr. Öğr. Üyesi Alaaddin COŞKUN Üye :
Dr. Öğr. Üyesi Dilşad YILDIZ MİNIKSAR Üye :
Dr. Öğr. Üyesi Sevgi ULUSOY TANGÜL Üye :
Uzm. Dr. Zeynep ÇİLSAL Üye :
Av. Fatih DEMİRCİ Üye :
Ziraat Yük. Müh. Harun ASLAN Üye :

Talip ÇAY

Doktora Tezi

YOZGAT 2024



**T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**