

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EEG SİNYALLERİNDE MAKİNE ÖĞRENMESİ İÇİN YENİ ÖZELLİKLERİN
ELDE EDİLMESİ VE UYGULAMASININ GERÇEKLEŞTİRİLMESİ

DOKTORA TEZİ

Mücahit KARADUMAN

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Ali KARCI

OCAK 2023

**T.C
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EEG SİNYALLERİNDE MAKİNE ÖĞRENMESİ İÇİN YENİ ÖZELLİKLERİN
ELDE EDİLMESİ VE UYGULAMASININ GERÇEKLEŞTİRİLMESİ**

DOKTORA TEZİ

**Mücahit KARADUMAN
(36173619014)**

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Ali KARCI

OCAK 2023

İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

**EEG Sinyallerinde Makine Öğrenmesi için Yeni Özelliklerin Elde Edilmesi ve
Uygulamasının Gerçekleştirilmesi**

Tezi Hazırlayan: Mücahit KARADUMAN
Doktora Tezi

TEŞEKKÜR VE ÖNSÖZ

Bu tez çalışmasının her aşamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemedi beni her konuda yönlendiren danışman hocam Sayın Prof. Dr. Ali KARCI 'ya,

Tüm hayatım boyunca olduğu gibi bu çalışmalarım süresince her türlü desteklerini esirgemeyen aileme,

Tezin uygulama aşamasında vermiş oldukları maddi ve manevi destekten dolayı, İnönü Üniversitesi BAP birimine,

Veriler için Brooklyn'deki New York Eyalet Üniversitesi Sağlık Merkezi'ndeki Nörodinamik Laboratuvarı'ndan Henri Begleiter'a,

teşekkür ederim.



ONUR SÖZÜ

Doktora veya yüksek lisans tezi olarak sunduğum “EEG Sinyallerinde Makine Öğrenmesi için Yeni Özelliklerin Elde Edilmesi ve Uygulamasının Gerçekleştirilmesi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Mücahit KARADUMAN



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ.....	i
ONUR SÖZÜ.....	ii
İÇİNDEKİLER	iii
ÇİZELGELER DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
SEMBOLLER VE KISALTMALAR	viii
ÖZET	x
ABSTRACT.....	xi
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı	2
1.2. Literatür.....	3
1.3. Tezin Yenilikçi Yönü.....	7
1.4. Tezin Organizasyonu	8
2. EEG SİNYALLERİ VE BEYİN YAPISI.....	9
2.1. Beyin Yapısı.....	9
2.2. Elektroensefalografi (EEG) Sinyalleri	12
2.3. EEG Ölçüm Yöntemleri.....	14
3. KULLANILAN YÖNTEMLER	17
3.1. VMD ile Sinyal Gürültü Giderme.....	17
3.2. Sinyal Özelliklerini Çıkarma	17
3.3. Kısa Zamanlı Fourier Dönüşümü.....	19
3.4. Sınıflandırma Yöntemleri	21
3.4.1. Destek vektör makineleri	21
3.4.2. K en yakın komşu	21
3.4.3. Karar ağaçları.....	22
3.4.4. Doğrusal ayırım analizi.....	23
3.4.5. Lojistik regresyon analizi.....	23
3.4.6. Naive bayes	23
3.4.7. K ortalama.....	23
3.4.8. Yapay sinir ağları	24
3.4.9. AlexNet derin öğrenme mimarisi.....	25
3.5. Performans Değerlendirme	26
3.6. Veri Setleri	27
4. ÖNERİLEN YÖNTEMLER	28
4.1. Beyin Bilgisayar Arayüzü Tasarımı.....	28
4.2. EEG Sinyali ve Göz-Kol İşbirliği Kullanarak Araçların Kontrol Edilmesi	29
4.3. Engellilerin Taleplerinin Yapay Zeka Yöntemleriyle Belirlenmesi	32
4.3.1. İstatistiksel özelliklerin hesaplanması.....	34
4.3.2. Özellik sınıflandırması.....	36
4.4. EEG Sinyalleri İçin Derin ve İstatistiksel Özellikler Sınıflandırma Modeli	36
4.4.1. VMD ile sinyal gürültü giderme	36

4.4.2. Sinyal istatistiksel özelliklerini çıkarma	37
4.4.3. Derin özelliklerin hesaplanması	37
4.4.4. Sınıflandırma yöntemleri	38
4.5. Moment Özelliklerini Kullanarak AUD EEG Sinyallerinin Sınıflandırılması	39
4.5.1. Moment özelliklerinin çıkarılması	40
4.6. EEG Sinyallerinin Elektrot Korelasyonlarının Araştırılması.....	41
5. UYGULAMA SONUÇLARI.....	44
5.1. EEG Sinyali ve Göz-Kol İşbirliği Kullanarak Araçların Kontrol Edilmesi Sonuçları	44
5.2. Engellilerin Taleplerinin Yapay Zeka Yöntemleriyle Belirlenmesi Sonuçları	48
5.3. EEG Sinyalleri İçin Derin ve İstatistiksel Özellikler Sınıflandırma Modeli Sonuçları	57
5.4. Moment Özelliklerini Kullanarak AUD EEG Sinyallerinin Sınıflandırılması Sonuçları	66
6. BULGU VE ÖNERİLER.....	71
7. SONUÇ VE ÖNERİLER.....	73
KAYNAKLAR	74

ÇİZELGELER DİZİNİ

Çizelge 2.1	: Beyin dalga özellikleri ve gerçekleştikleri bölgeler	14
Çizelge 3.2	: Kullanılan performans değerlendirme ölçütleri	26
Çizelge 4.1	: Elektrotların korelasyon değerleri.	42
Çizelge 4.2	: Elektrotlar ve en yüksek ve en düşük korele oldukları elektrotların korelasyon değerleri	43
Çizelge 5.1	: K ortalama Küme Verileri	46
Çizelge 5.2	: Özellikler ve hesaplanan ortalamaları.....	46
Çizelge 5.3	: Özelliklerin karşılaştırılması ile elde edilen durumlar.....	47
Çizelge 5.4	: Önerilen yöntem için hata oranı.....	47
Çizelge 5.5	: Karşılaştırmalı hata oranları.....	47
Çizelge 5.6	: Her bir özelliğe göre sinyallerin sınıflandırılması	53
Çizelge 5.7	: İkili kombinasyon halinde şekil verileri için sınıflandırıcı doğruluk oranları	54
Çizelge 5.8	: EEG sinyallerinin sınıflandırma sonuçları.....	55
Çizelge 5.9	: Literatürdeki diğer çalışmalarla karşılaştırma	56
Çizelge 5.10	: İstatistiksel özellikler için hesaplanan örnek değerler	58
Çizelge 5.11	: Ayır ıstatistiksel özelliklere göre sınıflandırma sonuçları	62
Çizelge 5.12	: İstatistiksel özelliklerin farklı sınıflandırma algoritması sonuçları	63
Çizelge 5.13	: Spektrogram görüntüleri ile elde edilen DL sonuçları.....	63
Çizelge 5.14	: Hibrit özellik değerleri ile EEG sinyallerinin sınıflandırılması.....	64
Çizelge 5.15	: DSFC için Literatür karşılaştırması	66
Çizelge 5.16	: Kullanılan tüm sınıflandırma yöntemlerinin karşılaştırılması	70
Çizelge 5.17	: Moment özellikleri için aynı veri seti ile literatür karşılaştırması	70

ŞEKİLLER DİZİNİ

Şekil 2.1	: Beyin yapısı ve bölümleri [41]	9
Şekil 2.2	: Beynin katman yapısı [42]	10
Şekil 2.3	: Sinir hücresinin yapısı [43]	11
Şekil 2.4	: Motor korteksi haritası [44]	12
Şekil 2.5	: Bir bireyin göz açması sırasında oluşan EEG sinyalinin yapısı	13
Şekil 2.6	: Alfa, Beta, Teta ve Delta dalgaları [49]	14
Şekil 2.7	: Uluslararası standarda göre 10-20 sistemindeki elektrot yerleşimi [47]	15
Şekil 2.8	: 10/20 sistemine göre yerleştirilen elektrotlar ve veri iletim kaliteleri	16
Şekil 3.1	: Sinyal için STFT gösterimi [57]	20
Şekil 3.2	: SVM simülasyonu	21
Şekil 3.3	: KNN simülasyon gösterimi	22
Şekil 3.4	: K ortalama algoritması için verilerden oluşabilecek sınıf yapısı	24
Şekil 3.5	: Yapay nöron yapısı	24
Şekil 3.6	: YSA örnek tasarımı	25
Şekil 3.7	: AlexNet temel mimarisi	25
Şekil 4.1	: BBA temel tasarımı	28
Şekil 4.2	: Önerilen yöntemin sistem tasarımı	29
Şekil 4.3	: Ham EEG sinyal grafiği	29
Şekil 4.4	: Filtrelenmiş sinyaller	30
Şekil 4.5	: FFT uygulanan veri paketi	30
Şekil 4.6	: YSA giriş ve çıkışının yapısı	31
Şekil 4.7	: K ortalama durum kümeleri	31
Şekil 4.8	: EEG sinyal sistemi diyagramından şekil sınıflandırması	32
Şekil 4.9	: Uygulama için adım adım gösterim şeması	33
Şekil 4.10	: Bant geçiren filtre tasarımı bant grafiği	34
Şekil 4.11	: Oluşturulan EEG şekil verilerinin kaydı	34
Şekil 4.12	: Şekillerin EEG sinyalleri için entropi hesaplama adımları	35
Şekil 4.13	: Üçgen şeklinden kaydedilen EEG sinyali için örnek histogram grafiği	35
Şekil 4.14	: Yeni DSFC modeli için blok diyagram.	36
Şekil 4.15	: Spektrogram oluşturma adımları	38
Şekil 4.16	: Önerilen yöntemin akış şeması	39
Şekil 4.17	: EEG sinyallerinin moment değerlerine göre sınıflandırılması	41
Şekil 4.18	: Kafatasına yerleştirilmiş elektrotlar	41
Şekil 4.19	: EEG sinyal grafikleri	42
Şekil 5.1	: Çıkarılan özelliklerin veri grafikleri	44
Şekil 5.2	: YSA eğitim grafiği	45
Şekil 5.3	: YSA performansı ve hata grafiği	45
Şekil 5.4	: YSA test grafiği	45
Şekil 5.5	: EEG sinyalleri için kullanılan şekil görüntüleri	48
Şekil 5.6	: Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için ortalama özellik sonuçları	49
Şekil 5.7	: Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için medyan özellik sonuçları	50
Şekil 5.8	: Daire, Kare, Üçgen ve Yıldız şekillerin EEG verileri için standart sapma özellik sonuçları	51
Şekil 5.9	: Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için Moment 5 özellik sonuçları	52

Şekil 5.10 : Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için entropi özelliği sonuçları.....	53
Şekil 5.11 : Özelliklere göre kare, daire, üçgen ve yıldız şekillerinin SVM sınıflandırması için karışıklık matrisi	55
Şekil 5.12 : Özellik için kare, daire, üçgen ve yıldız şekillerinin tahmini için SVM ROC grafiği.....	56
Şekil 5.13 : EEG Sinyalinin 9 mod için VMD grafikleri.....	57
Şekil 5.14 : Orijinal ve gürültüden arındırılmış EEG sinyal grafikleri	58
Şekil 5.15 : Ortalama özellik için hesaplanan veriler	59
Şekil 5.16 : Çarpıklık özelliği için hesaplanan veriler	59
Şekil 5.17 : EEG sinyalinin grafiği ve spektrogram grafiği.....	60
Şekil 5.18 : AUD spektrogramlarına sahip bireylere örnekler.....	61
Şekil 5.19 : Kontrol spektrogram örnekleri.....	61
Şekil 5.20 : AlexNet doğruluk ve kayıp grafikleri.....	62
Şekil 5.21 : AlexNet DL algoritmasının karışıklık matrisi	64
Şekil 5.22 : DSFC için SVM algoritmasının karışıklık matrisi	65
Şekil 5.23 : SVM algoritmasının ROC grafiği.....	65
Şekil 5.24 : Üretilen özellik vektörlerinin gösterimi.....	66
Şekil 5.25 : DT, LDA, LR, NB, SVM ve KNN'nin m1-m120 aralığı için aralıklar seçilerek elde edilen sınıflandırma sonuçları	67
Şekil 5.26 : Karışıklık matrisi a) DT b) NB c) SVM d) KNN e) LDA f) LR	69

SEMBOLLER VE KISALTMALAR

ANN	: Artificial Neural Network
EEG	: Elektroansefalografi
BBA	: Beyin Bilgisayar Arayüzü
Hz	: Hertz
μV	: Mikrovolt
Fp	: Frontal Kutup
F	:Frontal
C	:Sentral
P	:Parietal
O	:Opsipital
Z	: Merkezi
KNN	: K en yakın komşu
SVM	: Destek vektör makinesi
fMRI	: Fonksiyonel manyetik rezonans görüntülemesi
PET	: Pozitron emisyon tomografisi
MEG	: Magnetoensefalografi
GUP	: Görsel uyartılmış potansiyeller
YKP	: Yavaş kortikal potansiyeller
P300	: Tetiklenen potansiyeller
HMM	: Gizli markov modeli
LDA	: Lineer diskriminant analizi
YSA	: Yapay sinir ağı
DNN	: Derin yapay sinir ağı
DBN	: Derin inanç ağı
DELM	: Derin aşırı öğrenme makinesi
AUD	: Alkol Kullanım Bozukluğu
VMD	: Varyasyon Modu Ayrışımı
DSFC	: Derin - İstatistiksel Özellikler Sınıflandırması
DL	: Derin Öğrenme
CNN	: Konvolüsyonel Sinir Ağları
LSTM	: Uzun Kısa Süreli Bellek ağları

PCA	: Temel bileşenler Analizi
NN	: Sinir ağı
LLE	: Büyük Lyapunov Üssü
ApEn	: Yaklaşık Entropi
SampEn	: Örnek Entropi
HOS	: Yüksek Dereceli Spektrumlar
SRC	: Seyrek Ekran
NNLS	: Negatif Olmayan En Küçük Kareler Sınıflandırıcı
FC	: Tam Bağlı
FFT	: Hızlı Fourier Dönüşümü
STFT	: Kısa Süreli Fourier Dönüşümü
DT	: Karar ağaçları
LDA	: Doğrusal Ayırma Analizi
CoHOG	: Yönlendirilmiş Koruyucuların Histogramlarının Birlikte Oluşturulması
RMS	: Karekök Ortalama

ÖZET

Doktora Tezi

EEG SINYALLERİNDE MAKİNE ÖĞRENMESİ İÇİN YENİ ÖZELLİKLERİN ELDE EDİLMESİ VE UYGULAMASININ GERÇEKLEŞTİRİLMESİ

MÜCAHİT KARADUMAN

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

XI+82 sayfa

2023

Danışman: Prof. Dr. Ali KARCI

Bu tez ile beyin bilgisayar arayüzü (BBA) kullanılarak cihazların veya sistemlerin kontrol edilebilmesi amacıyla sinyallerin alınması ve analiz edilmesi ele alınmaktadır. Beyin fonksiyonları sırasında ortaya çıkan sinyallerin analizi elektroensefalografi(EEG) denilmektedir. EEG sinyalleri alınarak analiz edilmekte ve sınıflandırılarak hangi duruma ait oldukları belirlenmektedir. Bu amaçla yapılan çalışmalardan biri görsel uyaran potansiyel kullanan şekil tahmin uygulaması olmaktadır. Bu uygulama ile bakılan 4 farklı şekil için kaydedilen EEG sinyallerine ait özellikler çıkarılmakta ve sınıflandırılmaktadır. Hareket üzerine yapılan çalışmada ise göz ve kolların birlikte hareket ettirilerek koordine bir şekilde EEG sinyalleri alınarak hangi duruma ait olduklarının kararının verilmesi amacıyla özellikler çıkarılmakta ve sınıflandırma gerçekleştirilmektedir. Hazır alkolik veri seti kullanılarak gerçekleştirilen çalışmalarımızda ise önce istatistiksel özellikler çıkarılmakta ve bunların yanısıra derin öznitelikler çıkarılarak hibrit bir özellik vektörü oluşturulmaktadır. Bu oluşturulan özellik vektörü sınıflandırılarak kişinin hangi gruptan olduğuna karar verilmektedir. Diğer bir alkolik veri seti çalışmamızda ise moment özellikleri çıkarılmakta ve anlamı bilinen ilk 4 momentin yanısıra daha yüksek dereceli momentler de hesaplanmakta ve bunların sınıflandırma üzerindeki etkilerine bakılmaktadır. Şekiller için yapılan çalışmada EEG sinyallerinin sınıflandırılması hangi şeklin görüntülediğini yüzde 99,99 doğrulukla belirlemiştir. Bu sonuçlar, görüntülenen şeklin yapısına göre beyinde farklı sinyaller üretildiğini göstermektedir. Alkolik veri seti kullanılan uygulamada yalnızca istatistiksel özelliklerin sınıflandırılması için doğruluk oranı yüzde 81,2 olarak elde edilirken yalnızca derin öğrenme için yüzde 95,71 olmasına rağmen, önerilen Derin - İstatistiksel Özellikler Sınıflandırması (DSFC) kullanılarak türetilen hibrit özellikler için doğruluk oranı yüzde 99,2 olarak elde edilmiştir. Diğer alkolik çalışması için Moment 1'den 120'ye kadar tüm özellikler kullanıldığında en yüksek sınıflandırma doğruluğu yüzde 99,60 iken, Moment 1'den 20'ye kadar yüzde 99,80 olmakta ve daha iyi sonuç verdiği görülmektedir. Buna göre EEG sinyallerinin 20. dereceden bir polinom ile temsil edilebileceği sonucuna varılmıştır. Sonuç olarak alkol kullanım bozukluğunun (AUD) görsel uyaranlara maruz kalan kişilerde normal insanlara göre farklı EEG sinyallerine neden olduğu görülmektedir.

Anahtar Kelimeler: Elektroensefalografi, Alkol kullanım bozukluğu, Hibrit Özellik, Sınıflandırma, Spektrogram, Moment

ABSTRACT

Phd. Thesis

ACQUISITION AND IMPLEMENTATION OF NEW FEATURES FOR MACHINE LEARNING IN EEG SIGNALS

Mücahit KARADUMAN

Inonu University
Graduate School of Nature and Applied Sciences
Department of Computer Engineering

XI+82 page

2023

Supervisor: Prof. Dr. Ali KARCI

In this thesis, the reception and analysis of signals in order to control devices or systems using the brain computer interface (BCA) is discussed. The analysis of signals that occur during brain functions is called electroencephalography (EEG). EEG signals are taken, analyzed and classified to determine which state they belong to. One of the studies carried out for this purpose is the shape prediction application using visual stimulus potential. With this application, the features of the recorded EEG signals for 4 different shapes are extracted and classified. In the study on movement, the features are extracted and classification is carried out in order to decide which state they belong to by taking the EEG signals in a coordinated way by moving the eyes and arms together. In our studies carried out using a ready-made alcoholic data set, statistical features are extracted first, and a hybrid feature vector is created by extracting deep features. By classifying this created feature vector, it is decided which group the person belongs to. In our study of another alcoholic data set, moment properties are extracted and higher order moments are calculated as well as the first 4 moments whose meanings are known, and their effects on classification are examined. In the study for shapes, the classification of EEG signals determined which shape was displayed with 99.99 percent accuracy. These results show that different signals are produced in the brain according to the structure of the image displayed. In the application using the alcoholic data set, the accuracy rate was 81.2 percent for only the classification of statistical features, and 95.71 percent for deep learning only, but 99.2 percent for hybrid features derived using the recommended Deep - Statistical Features Classification (DSFC). For the other alcoholic study, the highest classification accuracy is 99.60 percent when all features from Moment 1 to 120 are used, while it is 99.80 percent from Moment 1 to 20, and it seems to give better results. Accordingly, it was concluded that EEG signals can be represented by a 20th-order polynomial. As a result, it is seen that alcohol use disorder (AUD) causes different EEG signals in people exposed to visual stimuli compared to normal people.

Keywords: Electroencephalography, Alcohol use disorder, Hybrid feature, Classification, Spectrogram, Moment

1. GİRİŞ

Bilimin gelişmesi her geçen gün insan hayatında yeniliklerin ortaya çıkmasını sağlamaktadır. Özellikle insan sağlığı sorunlarının giderilmesi alanında birçok çalışma yapılmıştır. Bilimsel çalışmalar genellikle daha önceki deneyimler ve bireylerden elde edilen veriler kullanılarak gerçekleştirilir. Özellikle geçmişten günümüze beyin yapısını öğrenmek ve beyinde meydana gelen olayları tanımlamak için bu çalışmalar yapılmış ve günümüzde de bu çalışmalar devam etmektedir. Nöroaktivitenin ilk tespit edilmesinden sonra beyindeki aktivitelerin saptanması [1], bunların anlamlandırılması ve dış ortama aktarılması ve cihazların kontrolü bu alanda yapılan önemli çalışmalar arasındadır.

Beyin işleyişini anlamlandırma, 100 milyar nöron ve aralarındaki bağlantıyı sağlayan yapıların işleyişi ve yapılarının bilinmesi ve tepkilerinin ölçülmesi ile mümkün olmaktadır. Bu karmaşık yapı ile normal beyinler incelenerek tepkileri ölçülmektedir ve anormal beyin aktiviteleri ile karşılaştırılarak anomali tespitine zemin hazırlanmaktadır. Böylece hem normal beyin aktiviteleri anlamlandırılmakta hem de anormal beyin aktiviteleri tespit edilmektedir [2].

Beynin elektriksel aktiviteleri ilk zamanlarda hayvanlar üzerinde yapılan deneyler ile tespit edilmiştir, daha sonra insan beyin aktivitelerinin deri üzerinden tespitinin mümkün olduğunu gösteren çalışmalar ile devam etmiştir. Teknolojinin gelişmesi ile beyin sinyalleri ve görüntüleme yapan sistemler artmış ve yeni teknik ve teknolojiler geliştirilmiştir [3].

Beyindeki elektriksel aktivitelerin anlamlandırılması ile beyin bilgisayar arayüzü (BBA) tasarımları gerçekleştirilerek alınan sinyallerin analizi gerçekleştirilmeye çalışılmaktadır. Bu amaçla elektrotlardan oluşan ve kafa derisinden sinyallerin alınmasını sağlayan cihazlar geliştirilmiştir. Bu sayede beyin düşüncelerinden insanların niyetleri anlaşılmaya çalışılmaktadır. Ayrıca birçok hastalık durumunun tespiti aşamasında da destek bir sistem oluşturulmuştur [4].

Teknolojinin gelişmesi ve beyin sinyallerinin alınmasını sağlayan cihazların portatif olmaları ile birlikte kullanım kolaylığı sayesinde 2000'li yıllardan itibaren

elektroensafalografi (EEG) alanında yapılan alıřmaların sayısı ve bilim insanlarının ilgisi artarak devam etmektedir [1-4].

1.1. Tezin Amacı ve Kapsamı

Bu tez kapsamında EEG sinyallerinin kaydedilmesi ve kaydedilen sinyallerin farklı oznitelikler ıkarılarak ve makine renmesi yntemleri kullanılarak sınıflandırılması ve anlamlandırılması amalanmaktadır.

alıřmalarda elde edilen oznitelikler istatistiksel ve derin oznitelikler olarak iki farklı yntem ile elde edilmektedir. İstatistiksel oznitelikler olarak bilinen ortalama, medyan, standart sapma, arpıklık, basıklık gibi ozniteliklerin yanı sıra istatistiksel momentin 5 ve zeri deėerleri iin moment deėerleri hesaplanmakta ve hesaplanan ozniteliklerin sınıflandırma yntemlerindeki performansına bakılmaktadır. Derin oznitelikler olarak, nceden eėitilmiş hazır bir derin renme modeli kullanılarak tam baėlı katmandan oznitelikler alınmaktadır. Bu oznitelikler sonraki ařamalarda istatistiksel oznitelikler ile birleřtirilmekte ve sınıflandırma performansına bakılmaktadır.

Kaydedilen EEG sinyallerinin yanısıra hazır veri seti de kullanılmaktadır. Bu hazır veri seti alkol kullanım bozukluėu olan kiřiler ve normal kiřilerden kaydedilen verileri iermektedir. Bu veri setindeki sinyaller analiz edilerek sınıflandırılmakta, bylece hangilerinin AUD ve hangilerinin normal olduėunu belirleyen bir yntem geliřtirilmektedir. Kaydedilen EEG sinyallerinde ise bir ekrandaki řekillere bakan kiřinin farklı řekillere bakması esnasında kaydedilen sinyallerin nerilen yntem doėrultusunda sınıflandırılarak sinyallerin hangi řekle ait olduėunun belirlenmesi amalanmıřtır. Bylece řekiller yardımı ile kas sistemi bozuk bir insanın ihtiyalarını grsellere bakarak iletmesinin saėlayan bir sistemin ilk ařaması geliřtirilmiřtir. Bunlarla birlikte gzlerin hareketinin tespiti ařamasında kaydedilen EEG sinyalleri kullanılarak gzn aılma ve kapanma durumlarının tespiti saėlanmaya alıřılmaktadır. Bu amala kaydedilen sinyallerin oznitelikleri ıkarılmakta ve sınıflandırma yntemleri ile karar mekanizması oluřturulmaktadır.

Yapılan alıřmalar daha nceki benzer veri setleri ile yapılan alıřmalar ile karřılařtırılmaktadır.

1.2. Literatür

EEG sinyalleri üzerinde birçok çalışma yapılmış ve bu sinyaller sınıflandırılarak hangi durumda nasıl oluştukları belirlenmeye çalışılmıştır. Fetz bu alanda ilk çalışmaları yapmıştır. Yaptıkları çalışmada bir uyarana maruz kalan kişide nöron aktivitelerinin oluştuğunu tespit etmişlerdir [1]. Yine aynı dönemlerde, Sutton ve arkadaşları bireylerin bir uyarana dikkat kesildikten 300 ms sonra beyinde pozitif bir potansiyel oluştuğunu tespit etmişlerdir [5]. Hwang ve arkadaşları yaptıkları araştırmada EEG ile ilgili çalışmaların gün geçtikçe arttığını tespit etmişlerdir. Özellikle yapılan çalışmalarda P300 potansiyellerinin kullanılarak EEG analizlerinin yapılmasının arttığını belirtmişlerdir [6]. Lotte ve arkadaşları araştırmalarında EEG sınıflandırılması için kullanılan yöntemleri 4 ana kategoriye toplamışlardır. Bunlar uyarlanabilir sınıflandırıcılar, matris ve tensör sınıflandırıcılar, transfer öğrenme yöntemleri ve derin öğrenme şeklindedir. Son olarak derin öğrenmenin diğer alanlardaki başarısını bu alanda gösteremediğine değinmişlerdir [7]. Aydemir ve arkadaşları EEG tabanlı BBA yapısını incelemiş ve karşılaştırdıkları k en yakın komşu (KNN) ve destek vektör makinesi (SVM) algoritmalarından, küçük boyutlu veriler için KNN etkili sonuç verirken, büyük boyutlu verilerde SVM'nin daha etkin sonuç verdiğini tespit etmişlerdir [20]. Vidal'ın gerçek zamanlı beyin özelliklerini EEG sinyallerinden çıkarmak için oluşturduğu BBA sistemi bu sistemin ilk kurucularında biridir [8]. Acar ve arkadaşları EEG sinyali alınırken elektrot yerleşiminden kaynaklanan hataları tespit etmişlerdir [9]. Şeker ve arkadaşları EEG sinyali üzerinde Welch metodunu uygulayarak özellik çıkarmışlardır. Çalışmada iyi koku ve kötü koku ayrımını yapmaya çalışmışlardır. Beynin sol kısmında iyi kokular ile aktivite artarken sağ kısmında ise kötü kokular ile aktivite arttığını tespit etmişlerdir [10]. McFarland ve arkadaşları kontrol amacıyla geliştirdikleri BBA sistemi ile motor korteksten aldıkları sinyalleri değerlendirerek tahmin yapmış ve kontrol sağlamışlardır [11]. Fakhruzzaman ve arkadaşları hareket düşüncesi ile beyinde oluşan sinyallerin kullanılması ile hareketlerin tespitini yapmaya çalışmışlardır [12]. Kaya ve arkadaşları 60 saatlik kayıt ile 13 kişiden aldıkları EEG sinyallerini bir araya getirerek büyük bir EEG veri seti oluşturmuşlardır [13]. Kumar ve arkadaşları bilgilerin elde edilmesi için frekans bandı seçim yöntemi önermişlerdir. Ortak uzamsal örüntülerin üst üste gelen bantlarda tespit edildiğini belirtmişler. Her filtre özelliklerine LDA uygulanmaktadır. Elde edilen skorlar bir araya getirilmiş ve SVM ile sınıflandırmışlardır. Bu çalışmalarında en düşük hata değeri ile sınıflandırma yapan diğer çalışmalardan daha iyi sonuç aldıklarını

belirtmişlerdir [14] . Bazı çalışmalarda ise Alzheimer ve Epilepsi gibi beyin hastalıklarının tespiti yapılmıştır [15].

EEG sinyalleri incelendiğinde, P300 olaya bağlı beyin potansiyelinin, dikkat dağınıklığı ve anında hafıza aktivasyonu gibi bilişsel süreçlerle ilişkili nöroelektrik aktiviteyi gösterdiği düşünülmektedir. Bununla birlikte, son araştırmalar, P300'ün genellikle deneklerin uyarılma durumundaki dalgalanmalar gibi biyolojik süreçlerden etkilendiğini göstermiştir [16]. Li ve ark. yeni bir konvolüsyonel sinir ağıları (CNN) modeli önerdi ve bu amaçla gürültüyü en aza indirmek ve hızı artırmak için esas olarak temel bileşen analizi yaklaşımını kullandı. Böylece yüzde 95 doğrulukla sonuç elde ettiklerini belirtmişlerdir [17]. Zheng ve ark. yöntemlerinde EEG sinyali kategorisine bağlı temsiller türetmek için Uzun Kısa Süreli Bellek ağıları (LSTMS-B) ve birleşik DL ve toplu öğrenme yaklaşımını önerdi. Orijinal görüntüyü ve daha önce öğrenilen ilgili EEG temsillerini kullanarak, uygulama anlamını doğrulamak için ResNet tabanlı regresyon eğitildi. Sınıflandırma için genel olarak yüzde 90,16'lık bir doğruluk elde ettiler [18].

Alkolik veri seti birçok çalışmada kullanılmıştır. Sun ve ark. [19], EEG verilerine PCA uygulamışlar ve daha sonra Wavelet transform ile sinyalleri 5 frekans bandına ayırmışlardır. Alkoliklerin ve kontrollerin güç spektrumunu beş ana frekans bandında karşılaştırarak, alkoliklerde artan teta ve delta gücünün açıkça görülebildiğini, alkoliklerin alfa gücünün önemli ölçüde azaldığını, gama ve beta bantlarında, kontrollerin gücü alkoliklerinkinden biraz daha fazla olduğunu bulmuşlardır. Nazari ve ark. [20], Haar ana dalgacığının güç spektrumu ve PCA ile azaltılmış öznitelik ile öznitelikleri çıkarmışlardır. SVM ve NN ile sınıflandırarak sırasıyla yüzde 94,67 ve yüzde 98,83 doğruluk elde ettiler. Acharya ve ark.[21], alkolik beyin sinyallerini doğrusal olmayan yöntemler kullanarak normal sinyallerden sınıflandıran bir teknik sundular. En Büyük Lyapunov Üssü (LLE), Yaklaşık Entropi (ApEn), Örnek Entropi (SampEn) ve diğer dört Yüksek Dereceli Spektrum (HOS) özelliği gibi doğrusal olmayan özelliklerimizi kullanarak normal ve alkollü EEG sinyallerinin dinamik özelliklerinde net farklılıklar göstermişler ve SVM ile sınıflandırarak yüzde 91,7 doğruluk oranına ulaşmışlardı. Bajaj ve ark. [22], zaman-frekans temsilini, Yönlendirilmiş Muhafızların (CoHOG) histogramlarının birlikte oluşturulmasını ve sınıflandırıcı tabanlı Seyrek Ekran (SRC) içeren bir EEG sinyal sınıflandırma sistemi önerdiler. Sınıflandırıcı olarak negatif olmayan en küçük kareler sınıflandırıcısını (NNLS) kullanarak yüzde 95,83 oranında doğru sonuçlar elde ettiler. Zubair [23] Kayan Tekil Spektrum Analizi yöntemiyle EEG sinyallerini analiz etmek için bir yöntem geliştirdi. Bu

yöntemle önce EEG sinyallerini gürültüden temizlemişler, sonra ayırtmışlardır. Bu işlemlerden sonra sınıflandırma yöntemlerini kullanarak AUD sinyallerini belirlediler.

Biyomedikal sinyaller üzerine yapılan çalışmalar, günlük hayatta kullanılabilecek ürünlere dönüşmektedir. Özellikle bu çalışmanın konusu içinde yer alan ve hastalık ve bağımlılıkların tespitinde kullanılan EEG sinyalleri, epilepsi, alzheimer, alkol bağımlılığı gibi beyni etkileyen tüm hastalıkların tespitinde kullanılmaktadır. Özellikle bu çalışmanın kapsamına giren EEG sinyalleri, hastalıklar ve bağımlılıklar gibi beyni etkileyen birçok durumda tespitler yapmak için kullanılabilir. Bazı çalışmalarda görsel uyaranlardan, hastalık belirtilerinden, insan hareketlerinden ve düşüncelerinden kaynaklanan EEG sinyalleri üzerinde yapılmıştır. Bu aşamada yapılan çalışmalardan bazıları aşağıdaki gibidir. Jiang ve ark. [24], bir inceleme çalışmasında EEG sinyallerindeki artefaktların giderilmesine yönelik çalışmaları incelemişler ve Kör Kaynak Ayırma (BSS) veya Wavelet gibi bazı yöntemler ile istenmeyen sinyalleri büyük bir doğrulukla kaldırmış ancak yüksek hesaplama karmaşıklığı ile çalışan bu yöntemlerin çevrimiçi uygulamalarının uygun olmayacağını bulmuştur. Sazgar ve ark. [25], epilepsinin semptomlarını ve özelliklerini tanımlama ve EEG sinyallerinin yapısını belirleme konusunda ayrıntılı bir kaynak sağlamıştır.

Hastalık ve bağımlılık tespiti ile ilgili çalışmalar; Tuncer ve ark. [26], epilepsi hastalığının tespiti için yerel senaryo örüntüsü (LSP) algoritması önermiş ve elde ettikleri 256 özelliği kullanarak hastalığı %93 doğruluk oranı ile tespit etmişlerdir. Singh ve ark. [27], ayırık dalgacık dönüşümü (DWT) ile EEG sinyallerinden Zaman-frekans (TF) alanı özelliklerini elde etmiş ve CNN tabanlı bir epilepsi saptama algoritması önermiş ve hastalığın %97,74 doğruluk oranıyla saptanmasını sağlamıştır. San Segundo ve ark. [28], derin sinir ağı (DNN) için girdi olarak epileptik EEG veri sinyalleri için Fourier, dalgacık ve ampirik mod ayrıştırmasını kullandı. Epilepsi nöbetlerini nöbetsiz olan durumlar ile karşılaştırmış ve elde ettikleri sonuçlar ile %99,5 doğruluk oranı yakalamışlardır.

Görsel uyaranla ilgili çalışmalar; Namazi ve ark. [29], görsel uyaranlar kullanarak karmaşık fraktal görseller ile göz hareketlerinin görsel uyaranlara göre esnekliğini ortaya koymaktadır. Görsel uyaran için 3 farklı fraktal kullanarak EEG sinyallerini kaydettiriler ve analiz ettiler. Sonuç olarak, daha yüksek karmaşıklığa sahip görüntülerin, daha düşük fraktalite ile sabit göz hareketlerine neden olduğunu gözlemlediler. Chowdhury ve ark. [30], ikili sınıflandırma için %94 doğruluk sağlayan 48 katılımcılı görsel bir uyaran-tepki deneyinde tek denemeli EEG temsiliyi kullanarak reaksiyon süresini (RT) tahmin etmek için DNN tabanlı bir yaklaşım sundu. Martisius ve Damasevicius [31], beyin sinyalleriyle grafik oyunların oynanması üzerine bir çalışma yürüttüler ve bunu OpenViBE ortamında

uygulanan bir çevrimiçi hedef vurma oyunu için kullandılar. Öznitelikler için dalga atomu dönüşümünü kullandılar ve bunları %80,5 doğrulukla SVM ile sınıflandırdılar. Sreeja ve Samanta [32], yaptıkları çalışmada seyrek özellik çıkarma yöntemi olarak motor görüntü verilerinden dalgacık enerjisini hesaplamışlar ve bir sözlük oluşturmuşlardır. Tek bir öznitelik kullanarak hesaplama süresini kısaltmayı ve doğruluk oranını yüksek tutmayı amaçladıkları çalışmalarında, 4 farklı sınıf EEG verisi için ortalama %91.84 doğruluk oranı ile sonuçları sınıflandırmışlardır. Zhou ve ark. [33], SSVEP'in EEG'ye ve göz kırpmayla ilişkili elektrookülografi (EOG) sinyallerine dahil edildiği hibrit bir BBA önerdiler. Kullandıkları 12 karaktere karşılık gelen görsellerin sınıflandırılmasında ortalama %95,42 doğruluk oranına ulaştılar. Shao ve ark. [34], tasarladıkları BCI ile duvarda yürüyen temizlik robotunu EEG sinyalleri ile ön ödemeli hale getirmeyi hedeflemiştir. Çalışmaları için 7 sağlıklı kişiden alınan sinyalleri kanonik korelasyon analizi (CCA) algoritması ile sınıflandırarak temizlik robotunun kontrolünü ve hareketini %89,92 doğrulukla sağladılar. Murugappan ve ark. [35], görsel ve işitsel-görsel olmak üzere iki farklı şekilde beş farklı sağlıklı insandan oluşturdukları BBA sistemi ile kaydettikleri 5 farklı duygu için EEG sinyallerinin sınıflandırılmasını çalışmışlardır. Çalışmalarında elde ettikleri sonuçlar değerlendirildiğinde, görsel-işitsel uyaranların birlikte kullanılmasıyla elde edilen sonuç, yalnızca görsel uyaranla elde edilen sonuçtan daha iyi olup, %66,67 doğruluk oranına ulaşan bir sonuç vermektedir. Bu sonuca göre görsel uyaranların işitsel uyaranlarla birlikte kullanılmasının çalışmalarda sonucun iyileştirilmesi için önerilebilecek yöntemler olduğunu göstermektedir. Kapeller ve ark. [36], kararlı durum VEP (SSVEP) veya kod modülasyonlu VEP (c-VEP) ile elde edilen EEG sinyallerinin robotların sürekli kontrolünde etkili olup olmadığı konusunda bir çalışma yapmıştır. Bu amaçla robotu bilgisayar ekranında 4 hareket için kontrol etmek üzere 11 sağlıklı kişiden EEG sinyallerini kaydettiler. Yaptıkları uygulama ve değerlendirmeler sonucunda c-VEP yönteminin hem görev tamamlama süresi hem de doğruluk oranı hesaplaması açısından daha iyi sonuçlar verdiğini belirlemişlerdir. c-VEP ile alınan EEG sinyallerinin sınıflandırılması %98.18 doğrulukla gerçekleştirildi. Böylece robot kontrolü için c-VEP yönteminin SSVEP yöntemine göre daha uygun olduğunu belirtmişlerdir. Faiz ve Al-Hamadani [37], Otoregresif (AR) katsayıları ve Ortak Mekansal Model (CSP) yöntemlerini kullanarak EEG sinyallerinden öznitelikler çıkarmış ve bunları sınıflandırarak insansı robot elinin kontrolünü sağlamıştır. Sınıflarını 5'e ayırdıkları sonuçlardan %97,5 doğruluk oranı elde ederek robot kolunun kontrolünü sağladılar. Zgallai ve ark. [38], tasarladıkları beyin kontrollü tekerlekli sandalyenin kontrolü için belirledikleri yönler olan sola, sağa, ileri ve geri hareket etme konusundaki düşünceleri

sırasında kaydettikleri EEG sinyallerini sınıflandırarak hareket etme üzerine bir çalışma yapmıştır. Uygulama için analiz edilen EEG sinyalleri, 10 sağlıklı kişiden belirlenen hareketleri düşünürken kaydedilmiştir. Alınan EEG sinyallerini %96 doğrulukla sınıflandırdılar ve tekerlekli sandalyenin kontrolünü sağladılar. Chen ve ark. [39], kablosuz EEG cihazı ile bakış tabanlı SSVEP sistemi ile 7-DOF robotik kol kontrolünü tasarladı. Yaptıkları çalışmada 12 sağlıklı kişiden alınan EEG sinyallerini 4 saniye boyunca işleyip analiz ettiler. Analiz edilen EEG sinyalinin 2 saniyelik bölümünü görsel uyaran için, diğer 2 saniyelik bölümü bakışı değiştirmek için ayırdılar ve sonuç olarak %92,78 doğrulukla kontrol sağladılar. Er ve ark. [40], EEG sinyallerini kaydederek insanların farklı müzik türleri dinlerken hissettikleri duyguları tahmin etmeye yönelik bir çalışma yürütmüştür. Tanımladıkları her duygu için EEG sinyallerini pencereleyerek spektrogramlar elde ettiler. Çalışmalarında, bilinen iki hazır eğitilmiş derin öğrenme mimarisi olan AlexNet ve VGG16'yı kullanarak derin öznitelikleri tam bağlantılı katmanda birleştirmişler ve ardından bunları sınıflandırarak duygu kestirimi yapmışlardır. 4 farklı duyguyu %73,8 doğruluk oranı ile belirlediler.

1.3. Tezin Yenilikçi Yönü

Tez çalışması kapsamında farklı yenilikler içeren çalışmalar gerçekleştirilmektedir. Bu çalışmalardan ilki istatistiksel öznitelikler çıkarılırken Moment 5 ve sonrası değerlerin hesaplanarak kullanılmasıdır. Önerilen yöntemde Moment 1 ile Moment 120 arasındaki değerler incelenmiş ve bu değerlerin EEG sinyallerinin ayırt edilmesi üzerindeki etkilerine bakılarak literatüre katkı sunulmaya çalışılmış ve EEG sinyallerinin modellenmesi üzerine polinom önerilmiştir.

Hibrit öznitelik vektörünün kullanılması önerilen diğer bir yöntemin en önemli yönüdür. Hibrit vektör, istatistiksel özellik hesaplaması sonucunda alınan değerlerin, DL modelindeki tam bağlantılı (FC) katmandan çıkarılan derin öznitelikler ile tek bir vektörde birleştirilmesiyle oluşturulan bir vektördür.

Görsel uyaranlar ile yapılan çalışmada ise EEG sinyallerinden görsellerin tahmini gerçekleştirilmektedir. Bu alandaki yapılan çalışma ile kas sistemi problemlili olan ve konuşma yetisini kaybetmiş kişilerin görsellere odaklanarak isteklerini EEG sinyalleri ile ifade etmeleri amaçlanmıştır. Bu yönüyle bu çalışma, iskelet ve kas sistemindeki problemler nedeniyle hareket edemeyen bireylerin ihtiyaçlarını görsellere bakarak ya da görselleri

düşünerek istediklerini talep etmelerini sağlamak için bilime ve insan yaşamına değer katmayı amaçlamaktadır.

Hareketler sonucunda oluşan EEG sinyalleri üzerine yapılan çalışmada ise Göz ve Kol hareketlerinin koordinasyonu ile bir cihazın kontrolünün sağlanması ve insan hareketlerinin beyindeki EEG sinyallerine etkisinin tespiti açısından bir çalışma gerçekleştirilmektedir.


1.4. Tezin Organizasyonu

Tez çalışması yedi bölümden oluşmaktadır. Birinci bölümde temel konular ve kavramlar ile ilgili bilgi verilmiş olup literatürdeki aynı alanda yapılmış çalışmalara değinilmektedir. Tezin amacı, kapsamı ve yenilikçi yönü de yine bu bölümde yer almaktadır. İkinci bölümde beynin genel yapısı hakkında bilgi verilmiştir. Tezin yöntem aşamasında kullanılan EEG sinyallerinin elde edilme yöntemleri ve yapıları bu bölümde anlatılmaktadır. Üçüncü bölümde tez kapsamında kullanılan yöntemler anlatılmıştır. EEG sinyallerinin gürültüden arındırılması için kullanılan yöntemler ile sınıflandırılmasında kullanılan yöntemler bu bölümde ayrıntılı olarak anlatılmaktadır. Dördüncü bölümde tez kapsamında önerilen yöntemler anlatılmaktadır. Önerilen yöntemlerin akış diyagramları ve ayrıntıları bu bölümde yer almaktadır. Beşinci bölümde önerilen yöntemler sonucunda elde edilen sonuçlar verilmektedir. Farklı uygulamalar ve farklı sınıflandırma sonuçları bu bölümde verilmiş ve karşılaştırılmıştır. Altıncı bölümde bulgu ve önerilerden bahsedilmektedir. Yedinci son bölümde ise önerilen yöntem doğrultusunda elde edilen sonuçlar ve öneriler verilmektedir.

2. EEG SİNYALLERİ VE BEYİN YAPISI

2.1. Beyin Yapısı


İnsan beyni, yapısal olarak üç kat zar ile kaplı boz ve buruşuk bir yapıya sahip bir organımızdır. Beden hareketlerinin kontrol edilmesi, öğrenme, düşünme gibi aktivitelerin yanı sıra diğer organların da gerektiği şekilde çalışmasını sağlayan özellikleri bulunmaktadır. Sinir sistemimizin önemli bir parçası olarak bu sistemin merkezinde yer almaktadır [41]. Birçok görevi bulunan beyin ortalama 100 milyar civarında, nöron adı verilen sinir hücrelerine sahip olmaktadır. Beyin, yetişkin bir bireyde yaklaşık 1400 gr civarında bir ağırlığa sahiptir. Beyin büyük ölçüde proteinden meydana gelmektedir. Beyin bilgisayar arayüzü sisteminin incelediği organ olan beyin ve beynin temel hücresi nöronlar bu çalışmalarda üzerinde durulan önemli yapılar olmaktadır. Beyin ön lob, parietal lob, oksipital lob, temporal lob olmak üzere iki yarım küreden ve bunların yanısıra beyincik, beyin kökü ve omurilikten oluşmaktadır. Beyin yapısı Şekil 2.1’de yer almaktadır.



Şekil 2.1 : Beyin yapısı ve bölümleri [41]


Beyin katmanları incelendiğinde en üstte kafa derisi yer almaktadır [42]. Kafa derisinin altında kafatası zarı ve kafatası kemiği yer almaktadır. Onun altında ise sert zar ve örümceksi zar bulunurken, beyni bir arada tutan beyin zarı bunun altında yer almaktadır.

İnce zarın hemen altında ak madde ve boz maddeler yer almaktadır. Beynin asıl yapısını bu alandaki boz madde oluşturmaktadır. Beyin katmanlarına ait görsel Şekil 2.2’de verilmektedir. Beyin temelde sert zar, örümceksi orta zar ve ince zar ile kaplanmıştır. Sert zar beyin zarlarının en dışta olanı ve en sert olanı olmaktadır. Bu zar çok kalın ve sağlam bir yapıya sahip olmaktadır. Orta kısımda yer alan örümceksi zar ise lifsi yapıya sahip ve kolay tahrip olabilecek bir yapıya sahip bir zardır. En içte yer alan beyin ve omurilik ile direkt temasta olan ince zar da diğer zarlar gibi lifsi bir yapıya sahiptir [42].




Şekil 2.2 : Beynin katman yapısı [42]

Sinir hücreleri dentrit, akson, akson ucu, hücre çekirdeği ve hücre gövdesi gibi yapılardan oluşmaktadırlar. Bir sinir hücresinin yapısı Şekil 2.3’de yer almaktadır.



Şekil 2.3 : Sinir hücresinin yapısı [43]

Bir sinir hücresi dentritler ile aldığı bilgileri akson üzerinden ileterek diğer hücrelere aktarmaktadır. Bu hücrelerdeki elektrik potansiyeli sinapslara gelen uyarılar ve bu uyarıların süresi ile ölçülmektedir. Gelen ileti sinir hücresinde toplanmakta ve belirli bir potansiyeli aştıktan sonra iletimi sağlanmaktadır [41]. Tek tek nöron aktiviteleri belirlenememekte ancak belirli gruplar halinde davranış gösteren beyin bölümleri bulunduğu bilinmektedir. EEG sinyallerinin ölçümü sırasında özellikle yapılan hareketin etkilediği beyin bölümlerindeki sinyaller incelemektedir. Şekil 2.4 motor korteksi haritasını göstermektedir. Bu sayede hangi bölgenin hangi durumlarda uyarıldığı ve elektriksel tepki verdiği belirlenebilmektedir. Böylece kafatasına yerleştirilen elektrotlar aracılığıyla alınan sinyaller hareket bazlı incelenebilmekte ve daha doğru sonuçlar alınması sağlanabilmektedir.




Şekil 2.4 : Motor korteksi haritası [44]

2.2. Elektroensefalografi (EEG) Sinyalleri

Canlılarda gerçekleşen aktiviteler sinir hücrelerinde elektriksel sinyallerin oluşmasına sebep olmaktadır. Beyinde, kaslarda ve daha birçok vücut organlarında bu sinyallere rastlanabilmektedir. Bu sinyallerin beyinde tespit edilenleri Elektroensefalografi (EEG) sinyalleri olarak isimlendirilmektedir. Bu sinyaller uyku esnasında ve uyanık durumda ölçülebilmektedir. Bu sinyaller Hans Berger tarafından kaydedilmiştir [45]. Bu sinyallerin ölçümü kafatasına yerleştirilen elektrotlar ile gerçekleştirilmektedir. Günümüzde bu elektrotlar ıslak çalışan elektrotlar olmakla birlikte kuru olarak sinyal alan elektrotlar da mevcuttur. Bu sinyallerin incelenmesi ve analiz edilmesi ile birçok beyin hastalığı tespit edilebilirken bunun yanı sıra kas ve uzuv kaybı olan insanlar için beyin ile kontrol ve protez geliştirilmesi yapılabilmektedir. Bu bilgilerin sınıflandırılması amacıyla günümüzde birçok çalışma gerçekleştirilmektedir. Bu çalışmaların geçmişi Fetz ve arkadaşlarının 1960'lı yıllarda gerçekleştirdikleri çalışmalara dayanmaktadır [1]. Yine bu konu üzerinde çalışmalar yapan Sutton ve arkadaşlarının tespit ettiği ve bu çalışmaları önemli ölçüde etkileyen bir canlının uyarıcıya dikkatini verdikten 300 ms civarında bir süre sonra EEG sinyalinde pozitif yönde bir hareket gözlemlendiği bilgisi olmaktadır [5], [46]. Klinik ortamında göz ile kontrolü

ve analizi zor olan bu sinyallerin çok daha ayrıntılı incelenmesi ve analiz edilmesi için bilgisayar sistemlerine aktarılması ve burada analiz edilmesi gerekliliği doğmuştur. Bu verilerin analizindeki başarının yükselmesi ile daha uzun süreli veriler incelenebilecek ve daha tutarlı sonuçların rapor edilmesi sağlanabilecektir.


İnsan beyninden alınan EEG sinyalleri incelenirken frekanslarına ayrılarak incelenmektedir. Bu sinyallerin yapısı çoğu zaman göz ile ayırt edilemeyecek yapıda olmaktadır. EEG sinyallerinin dalga tipleri incelenerek gerçekleşen uyarının sebebi ve ne olabileceği hakkında karar verilmektedir. EEG sinyalleri 0,5 ile 100 Hz arasında değişebilmektedir [47]. Bu sinyaller frekans aralıklarına göre isimlendirilmektedirler. Bu dalgalar alfa, beta, teta, delta, gama ve mü dalgalarından oluşmaktadırlar. Bir bireyden alınmış 4 sn'lik göz açılmasına ait EEG sinyalleri Şekil 2.5'te verilmektedir.



Şekil 2.5 : Bir bireyin göz açması sırasında oluşan EEG sinyalinin yapısı

EEG dalga tiplerinden Alfa bandı 8-13 Hz arasındaki bandı kapsamaktadır. Bu dalgalar kişi uyanık ve dinlenme konumunda iken gözler kapalı olduğu esnada kafatasının arka tarafında meydana gelen EEG sinyalleri olarak tanımlanmaktadırlar. Beta bandı 13 Hz üzerindeki bandı kapsamaktadır. Aktif düşünme, problem çözme veya dış dünya sorunları üzerinde kafa yorma esnasında beynin her iki yarım küresinde ve ön tarafında ortaya çıkan EEG sinyalleri olmaktadır [48]. Teta bandı 4-8 Hz arasındaki frekans bandına sahip stres sonucu ortaya çıkan EEG sinyalleri olmaktadır. Delta bandı ise 4 Hz altında kalan dalgalar. Derin uyku halinde gözlemlenmektedirler. Gama dalgaları 35 Hz üzerindeki dalga boylarında izlenirken Mü dalgaları ise alfa ile aynı dalga boyunda gözlemlenmektedirler. Gözlemlendikleri beyin kısımlarının farklı olması ayırt edilmeleri

için önem teşkil etmektedir. Bu dalgalar motor korteks üzerinde görülmektedir [48]. Alfa, Beta, Teta ve Delta dalgaları Şekil 2.6’da yer almaktadırlar.



Şekil 2.6 : Alfa, Beta, Teta ve Delta dalgaları [49]

Beyindeki tüm dalga boyları için frekans, genlik ve oluştukları yerlere ait bilgiler çizelge 2.1’de verilmektedir.

Çizelge 2.1 : Beyin dalga özellikleri ve gerçekleştikleri bölgeler


Bant	Frekans (Hz)	Genlik(μV)	Yer
Alfa	8-13	10-150	Opsipital/Parietal
Mü	9-12	Sınır Yok	Motor Korteks
Beta	>13	25	Ön taraf
Teta	4-8	Sınır Yok	Değişken
Delta	<4	Sınır Yok	Değişken
Gama	>35	Düşük	Değişken

2.3. EEG Ölçüm Yöntemleri

Amplifikatörlere bağlanan elektrotlar kafatasından mikro volt düzeyinden gelen sinyalleri kaydetmek için kullanılmaktadır. Uluslararası standart kabul edilen 10 – 20 sistemine göre elektrotların yerleşimi gerçekleştirilmektedir. Bu sistemde 2 referans noktası bulunmaktadır. Bunlardan biri burnun üst tarafında bulunan ‘Ön’ ve diğeri ise kafatasının

Elektrotlar yerleştirilirken isimlendirilme şekilleri yerleştirildikleri beyin bölgesi ile belirlenmektedir. Bu bölgeler beş tane olup frontal kutup (Fp), frontal (F), sentral (c), parietal (p), opspital (O) şeklinde isimlendirilmektedirler. Bunların yanlarına konulacak sayılar ile beynin sağ yarım küresinde mi yoksa sol yarım küresinde mi oldukları belirlenmektedir. Bu açıklama doğrultusunda sağ taraf için çift sayılar, sol taraf için tek sayılar kullanılmaktadır [47]. Merkezdeki elektrotlar ise Z ile temsil edilmektedirler.

15



Şekil 2.8 : 10/20 sistemine göre yerleştirilen elektrotlar ve veri iletim kaliteleri

3. KULLANILAN YÖNTEMLER

3.1. VMD ile Sinyal Gürültü Giderme

EEG veri setindeki sinyaller, ön işleme adımında ilk olarak VMD tarafından gürültüden arındırılır. VMD yöntemi, gerçek değerli bir sinyali sınırlı sayıda alt sinyale ve faza ayırıştırır [14] [50]. Her bir alt sinyal, bu yinelemesiz sinyal ayırma işleminde merkez frekansın etrafında üretilir. Her modun bant genişliği üç adımda değerlendirilir. Her modun frekans spektrumu, ilk aşamada Hilbert dönüşümü kullanılarak elde edilir. Her modun frekans spektrum özelliği, onu ikinci aşamada temel merkez frekansına kaydırmak için kullanılır. Modun bant genişliği, demodüle edilmiş sinyalin Gauss düzgünlüğü [50] kullanılarak üçüncü adımda belirlenir. Sonuçların gerekliliği varyasyonel bir problem olarak tanımlanabilir. VMD, aşağıda özetlenen kısıtlı optimizasyon sorununu ele alarak uygulanır:

$$\min_{\{s_k\}\{w_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\partial(t) + \frac{j}{\pi t} \right) * s_k(t) \right] e^{-jw_k} \right\|_2^2 \right\} \quad (3.1)$$

$$\sum_k u_k = f \quad (3.2)$$

burada u_k , k'inci ayırıştırılmış modu belirtir ve w_k , k'inci mod sinyalinin merkez frekansını belirtir.

$f(t)$, giriş sinyali ve $\left[\left(\partial(t) + \frac{j}{\pi t} \right) * M_k(t) \right]$ ise $u_k(t)$ 'nin hilbert dönüşümü olmaktadır. Üstel terim e^{-jw_k} her modun frekans spektrumunu merkez frekansa iter [51], [52]. Artırılmış Lagrangian, Denklem 3.1'deki kısıtlı optimizasyon sorununu çözmek için aşağıdaki gibi kullanılabilir;

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\partial(t) + \frac{j}{\pi t} \right) * M_k(t) \right] e^{-jw_k} \right\|_2^2 + \|f(t) - \sum_k u_k(t)\| + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (3.3)$$

Ayrıştırma için başlangıç parametreleri belirlenmelidir. Ayrıştırma sayısı w_k , veri uygunluk tutarlılıkları parametresi α söz konusu parametrelerdir [51].

3.2. Sinyal Özelliklerini Çıkarma

Gürültüden arındırılmış sinyal özellikleri her örnek için ayrı ayrı hesaplanır ve bir özellik vektörü oluşturulur. Denklem 3.4, sinyalin ortalama özelliğini hesaplamak için kullanılır.

$$a = \frac{1}{n} \sum_{k=1}^n x_k \quad (3.4)$$

Denklem 3.4'te, a ortalamayı gösterir, n sinyal örneklerinin sayısını temsil eder, x sinyaldeki örneğin değeridir ve k örnek sayısıdır.

Bir sinyaldeki değerler artan düzende sıralandığında, medyan sinyali ikiye bölen değerdir. Dizin numarası tek olduğunda, sıralanan dizideki medyan değer ortadaki değerdir; indeks numarası çift olduğunda, medyan değer ortadaki iki değerlerin ortalamasıdır. Hesaplama adımları şu şekildedir;

- Sinyali artan düzende sıralayın
- Sinyalin boyutunu hesaplayın
- Medyan değeri bulun ve medyan olarak atayın.

Her bir sinyal için sinyal değerleri minimumdan maksimuma doğru sıralanır ve ilk indeksteki değer alınır ve minimum değer özelliği olarak özellik vektörüne eklenir. Özelliğin değeri, sinyalin en düşükten en yükseğe doğru sıralanan son indeksindeki değerle temsil edilir. Belirlenen bu değer, özellik vektörünün maksimum değer alanına eklenir.

Olasılık teorisi ve istatistikte, çarpıklık, gerçek değerli bir rasgele değişkenin simetrik olmayan olasılık dağılımının ölçümüdür. Çarpıklık üçüncü standartlaştırılmış momenttir ve matematiksel notasyon [53] kullanılarak denklem 3.5'te belirlenir.

$$s = \frac{E(x-a)^3}{\sigma^3} \quad (3.5)$$

Grafik temsilinden tanımlanarak kurulan bir terim olan gerçek değerli bir rastgele değişken için olasılık dağılımının keskinlik veya basıklık özelliğinin ölçüsü basıklık olarak adlandırılır. Dördüncü standartlaştırılmış moment, denklem 3.6 [53] kullanılarak belirlenen basıklıktır.

$$ku = \frac{E(x-a)^4}{\sigma^4} \quad (3.6)$$

Denklem 3.5 ve 3.6'da $E(x)$ 'in beklenen değeri; a ortalamadır; σ standart sapmadır; s çarpıklığı gösterir ve ku basıklığı gösterir.

Denklem 3.7, standart sapmayı, sinyal değeri ile ortalama arasındaki farkın karelerinin toplamının karekökü olarak hesaplar.

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - a)^2} \quad (3.7)$$

Denklem 3.7'de σ standart sapmadır; a ortalamadır; n , sinyaldeki örnek sayısıdır; x , sinyaldeki örneğin değeri ve k , örneğin sayısıdır.

Sinyal, enerji özelliğini hesaplamak için önce hızlı bir Fourier dönüşümüne tabi tutulur. Yeni sinyal ve eşleniği daha sonra nokta nokta çarpılır ve enerji, bunların toplanmasıyla hesaplanır. Denklem 3.8, hesaplamaların yapıldığı yerdir.

$$e = \sum_{k=1}^n \text{fft}(\mathcal{X}_k) \cdot \text{conj}(\text{fft}(\mathcal{X}_k)) \quad (3.8)$$

Denklem 3.8'de e enerjidir; n, sinyaldeki örnek sayısıdır; x, sinyaldeki örneğin değeri ve k, örneğin sayısıdır.

Veri seti için kayıt yaparken Snodgrass ve Vanderwart resim setinden seçtikleri resimleri herkese göstererek beyinde oluşan EEG sinyallerini kaydettiler. Bu veri seti ilk olarak özellik çıkarma adımına geçilerek işlenir. Öznitelikler çıkarılırken istatistiksel momentler kullanılır ve denklem 3.9 [54] ile hesaplamalar yapılır.

$$m_r = \frac{\sum_{i=1}^N (x_i - \mu_x)^r}{N} \quad (3.9)$$

m_r , r. momenti ifade eder, N sinyalin değer sayısı, x sinyal değeri, μ_x sinyalin ortalamasıdır.

Hesaplamalar Moment1'den Moment120'ye kadar yapılmıştır. Moment1, Moment2, Moment3 ve Moment4 anlamları bilinmekte ve birçok istatistiksel çalışmada kullanılmaktadır.

- Moment1= Ortalama
- Moment2= Varyans
- Moment3= Çarpıklık
- Moment4= Basıklık
- Moment5 - Moment120= Anlamları bilinmiyor.


Son olarak, entropi bir diğer sinyal özelliği olarak kullanılmaktadır. Entropi, sistemdeki farklı bilgilerin miktarı olarak bilinir ve birim sıcaklık başına sistemin termal enerjisinin toplamının bir ölçüsü olarak tanımlanır [55]. Entropi, denklem 3.10 ile hesaplanır [56].

$$H_p = - \sum_{i=1}^n p_i \log_2(p_i) \quad (3.10)$$

3.3. Kısa Zamanlı Fourier Dönüşümü

Bu aşamada öncelikle sinyal örneklerinin spektrogramı oluşturulur. Spektrogram, anlık sinyalin frekansı hesaplanarak oluşturulan zaman-frekans eksenli grafiği ile temsil edilir.

Burada değeriendirilecek sinyal $x(t)$ 'dir ve $w(t)$ penceresi kullanılır. Pencere tercihen zaman-frekans düzleminde bir impuls olmalıdır. Şekil 3.1'de işaret önce pencerelere ayrılmış ve daha sonra Hızlı Fourier dönüşümü (FFT) uygulanarak frekans tanım kümesine aktarılmıştır.



Şekil 3.1 : Sinyal için STFT gösterimi [57]


Daha sonra zaman frekans grafiği çizilerek sinyalin spekreogramı elde edilmiştir. Pencereleme aşamasında, gürültüsüz sinyallerden spektrogramları çıkarmak için sinyalleri çerçevelemek önemlidir. 25 ms çerçevelere bölünmüş EEG sinyalleri için, çerçeveler yüzde 50 örtüşecek şekilde ayarlanır. Her çerçevenin başındaki ve sonundaki süreksizliği önceliklendirmek için Hamming Penceresi kullanılarak merkez bölge daha belirgin hale getirilmiş ve sinyalin uç bölgesindeki istenmeyen ışımaların en aza indirilmesi amaçlanmıştır [58]. Bu pencereleme işleminden sonra sinyal FFT için kullanılabilir hale getirilir. Bu adımlar sonucunda elde edilen spektrogram grafikleri DL aşamasında yorumlanmak istenmektedir.

3.4. Sınıflandırma Yöntemleri

İstatistiksel yöntemlerden ve DL adımlarından elde edilen özellik vektörleri bu aşamada birleştirilir. Elde edilen yeni özellik vektörü, EEG sinyalinin sınıflandırılmasında kullanılır. Bu aşamada 4 farklı sınıflandırma yöntemi kullanılmaktadır. Bunlar SVM, k en yakın komşu (KNN), karar ağaçları (DT), doğrusal ayırım analizidir (LDA), Lojistik Regresyon Analizi (LR) ve Naive Bayes olmaktadır.

3.4.1. Destek vektör makineleri

Sınıflandırma, regresyon ve aykırı değer tespiti için kullanılan denetimli öğrenme teknikleri, destek vektör makineleridir (SVM). Nokta ile tanımlanan giriş alanı, genel sınıflandırma yönteminde çıkış uzayına kategorize edilir. Sınıflandırma, y ve x özellikleri arasındaki ilişkiyi bularak eşleştirmek ve hangi sınıfa ait olduğunu belirlemektir [59]. Verileri sınıflandırmak için SVM, olası tüm ayırıcı düzlemler arasında en uygun ayırma alt düzlemini bulmaya çalışmaktadır. SVM simülasyonu görseli Şekil 3.2’de olduğu gibi olmaktadır.




Şekil 3.2 : SVM simülasyonu

3.4.2. K en yakın komşu

Sınıflandırma ve regresyon problemlerinin çözümünde kullanılan denetimli bir öğrenme yöntemi olan k-en yakın komşuluk (KNN) algoritması, mesafeleri hesaplar. Öklid, Manhattan veya Minkowski mesafelerini kullanabilir. Öklid uzaklığı ile her bir vektör arasındaki uzaklık değerleri hesaplanarak hangi değerin hangi sınıfta olacağı belirlenir.

Hesaplanan mesafeler d sonucunda yeni değere dahil edilecek sınıf belirlenmektedir [60]. KNN ile ilgili sınıflandırma simülasyonuna Şekil 3.3’de yer verilmektedir.



Şekil 3.3 : KNN simülasyon gösterimi

3.4.3. Karar ağaçları

Denetimli öğrenme algoritmalarından biri olan ağaç tabanlı yöntemler, sınıflandırma ve regresyon problemlerinde sıklıkla kullanılmaktadır. Yukarıdan aşağıya doğru inen bir yapıya sahiptirler. Alt düğümlere inmek için Entropy, Gini ve en küçük kareler yöntemi algoritmaları kullanılır. Gini indeksinin değerine bakılarak öncelikle hangi özelliğe bölünebileceğine karar verilir. Bu Gini değeri, veri setindeki değişkenlerin oranını göstermektedir [61]. Gini değeri, sağ ve sol Gini değerleri hesaplandıktan sonra elde edilir. Denklem 3.11 ve 3.125, sağ ve sol Gini değerlerinin nasıl hesaplandığını gösterir.

$$\text{Gini}_l = 1 - \sum_{k=1}^n \left(\frac{L_k}{T_l} \right)^2 \quad (3.11)$$

$$\text{Gini}_r = 1 - \sum_{k=1}^n \left(\frac{R_k}{T_r} \right)^2 \quad (3.12)$$

Bu denklemde n sınıf sayısı, T düğümdeki örnek sayısı, T_l sol koldaki örnek sayısı, T_r sağ koldaki örnek sayısı, L_k ise düğümdeki örnek sayısıdır. Sol koldaki k kategorisi, R_k sağ koldaki k kategorisindeki örneklem sayısıdır [61]. Hesaplamalar yapıldıktan sonra denklem 3.13 ile Gini değeri hesaplanır. Her bir özellik için hesaplama yapılır ve en küçük değere sahip olan özelliğe bölme işlemi yapılır.

$$\text{Gini}_j = \frac{1}{n} (T_l \text{Gini}_l + T_r) \quad (3.13)$$

3.4.4. Doğrusal ayırım analizi

Doğrusal ayırım analizi (LDA), önceden belirlenmiş n sayıda özellik ile yapıların gerçek sınıflarına en yakın atamayı amaçlayan çok değişkenli bir istatistiksel yöntemdir. Sınıflandırma aşamasında sınıflar belirlenir ve kovaryans hesaplanmaktadır [62].

3.4.5. Lojistik regresyon analizi


LR, makine öğrenmesinde sıklıkla karşılaştığımız bir yöntemin yanı sıra veri sınıflandırma, istatistiksel çalışmalar ve örüntü tanımda kullanılabilen bir yöntemdir. LR, çoklu kategorik sonuçlara sahip veriler üzerinde regresyon sonuçlarının sınıflandırmasını gerçekleştirmektedir [63].

3.4.6. Naive bayes

NB veri setindeki özniteliklerin her birinin birbiriyle olasılıksal olduğu zaman çizelgesini temel alır ve bu amaçla Bayes teoremini kullanarak sınıfların belirlenmesini sağlayan olasılık tabanlı bir yöntemdir. Ayrıca bu çalışmada EEG sinyallerinden elde edilen özellikleri sınıflandırmak için de kullanılmaktadır [64].

3.4.7. K ortalama


K ortalama algoritması kümeleme yapmak için özellikleri çıkarılmış verileri kullanmaktadır. Küme merkezi belirlenir ve küme dışındaki verilerin merkeze olan mesafeleri göz önüne alınarak hesaplama yapılmaktadır. Oluşan yeni sınıf için tekrar merkez hesaplanmakta ve yeni sınıfın merkezi belirlenmektedir. Böylece tüm veri için bu işlemler gerçekleştirilerek sınıflandırma tamamlanmaktadır [65]. K ortalama algoritması için oluşabilecek iki sınıflı yapı Şekil 3.4'te verilmektedir.



Şekil 3.4 : K ortalama algoritması için verilerden oluşabilecek sınıf yapısı

3.4.8. Yapay sinir ağları


Yapay sinir ağları (YSA) kullanılarak da sinyallerin sınıflandırılması gerçekleştirilmektedir. YSA’larda nöronlar ve nöronların birbirleri ile olan bağlantıları matematiksel olarak tanımlanmakta ve bir sinir ağı yapısına benzeyen sistem oluşturulmaktadır. İnsan beyninin çalışması ve öğrenmesini taklit eden bir sistemdir [66]. YSA’nın genel yapısı giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Bu katmanlarda nöron yapısına benzeyen girişi, çıkışı ve aktivasyon fonksiyonu olan bir yapı bulunmaktadır. Yapay nöron yapısı Şekil 3.5’de verilmektedir.



Şekil 3.5 : Yapay nöron yapısı

Yapay nöron yapısında girişler X sembolleri ile temsil edilirken W değerleri her giriş için ağırlık değerini belirlemektedir. Toplam fonksiyonu ile toplanan tüm girişler f aktivasyon fonksiyonu ile işleme alınırlar ve Y çıkışı elde edilir. Aktivasyon fonksiyonu olarak lineer, signum, sigmoid ve tanjant hiperbolik fonksiyonları örnek verilebilir. Yapay

nöronların bir araya getirerek oluşturdukları sinir ağına yapay sinir ağı adı verilmektedir. Yapay sinir ağının yapısı Şekil 3.6’de verilmektedir.




Şekil 3.6 : YSA örnek tasarımı

YSA tasarlandıktan sonra eldeki sonucu bilinen veriler ile eğitilir ve bu eğitim sonucunda w ağırlık değerleri hesaplanır. Buna bağlı olarak diğer veriler ile test gerçekleştirilir. Böylece girişler için çıkışlar elde edilir. Bu tip YSA’lar eğitici olarak isimlendirilmektedir. Belirli bir çıkışa ait hesaplanan w değerleri için çıkış elde ediliyorsa bu YSA’lar eğitici olarak isimlendirilmektedir.

3.4.9. AlexNet derin öğrenme mimarisi

Bu fonksiyon için AlexNet kullanılmaktadır. AlexNet, 2012 ImageNet yıllık yarışmasını kazanan evrimsel sinir ağıdır [67].



Şekil 3.7 : AlexNet temel mimarisi

ImageNet veri tabanında, mimari önceden eğitilmiştir ve 1000 farklı görüntüyü ayırt etme kapasitesine sahiptir. Bu ağın mimarisi temel olarak 5 konvolüsyonel katmandan ve bir fonksiyon çıkarıcı olarak kullanılabilen 3 FC katmanından oluşur. Derin özellik çıkarımı için, Şekil 3.7'de gösterildiği gibi AlexNet mimarisinin FC katmanı kullanılır. AlexNet, spektrogram görüntüleri kullanılarak önceden eğitilmiş ağlar halinde sınıflandırılır. Hibrit vektör için sınıflandırma sonuçlarının yanı sıra kullanılmak üzere FC adımıyla derin öznitelikler elde edilir.

3.5. Performans Değerlendirme

Verilerden elde edilen sonuçlar analiz edilirken verinin yapısına göre kullanılan farklı performans metrikleri bulunmaktadır. M'nin sınıflandırma performansını karşılaştırmak için çizelge 3.2 'de özetlenen altın standart değerlendirme kriterlerini kullanıyoruz. Performans metrikleri için gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) sayıları hesaplanmıştır.

Çizelge 3.1 : Kullanılan performans değerlendirme ölçüleri

Performans Ölçüsü	Kısaltma	Formül
Pozitif Tahmini Değer	PPV	$\frac{TP}{TP + FP}$
Negatif Tahmini Değer	NPV	$\frac{TN}{TN + FN}$
Gerçek Pozitif Oran	TPR	$\frac{TP}{TP + FN}$
Gerçek Negatif Oran	TNR	$\frac{TN}{TN + FP}$
Yanlış Pozitif Oranı	FPR	$\frac{FP}{TN + FP}$
Yanlış Negatif Oranı	FNR	$\frac{FN}{TP + FN}$
Doğruluk	ACC	$\frac{TP + TN}{TP + TN + FP + FN}$
Dengelenmiş Hata Oranı	BER	$\frac{1}{2} \times (FPR + FNR)$
F1-Puanı	F1	$2 \times \frac{PPV * TPR}{PPV + TPR}$

3.6. Veri Setleri


Bu çalışmadaki EEG verileri, New York Eyalet Üniversitesi Sağlık Merkezi'nin açık bir EEG veri tabanından elde edildi. Bu veriler, alkolizme genetik duyarlılığın EEG ile ilişkilerini incelemek için yapılan büyük bir çalışmadan kaynaklanmaktadır. 256 Hz'de bir saniye boyunca örneklenen kafa derisi üzerine yerleştirilmiş 64 elektrottan alınan ölçümleri içeren kontrol ve alkolik deneklerin zaman serisi EEG kayıtlarını içeren bir veri seti kullanılır [68]. Veri seti 235 alkollü ve 233 kontrol EEG sinyali içermektedir. Bu EEG sinyalleri 10 alkolik ve 10 normal kişiden alınan ve görseller gösterilerek kaydedilen sinyallerdir.



4. ÖNERİLEN YÖNTEMLER

4.1. Beyin Bilgisayar Arayüzü Tasarımı

İnsanlar makineleri kontrol ve kumanda etmek için sürekli yeni sistemler ve ekipmanlar geliştirmektedirler. Bu sistemler genellikle el veya ayak ile kullanılabilen yapılardan oluşmaktadırlar. Örneğ verecek olursak bilgisayar kullanımı için klavye ve fare kullanılması olabilir. Ayrıca kumanda, dokunmatik yüzeyler ve giyilebilir teknolojiler ile de kontroller sağlanabilmektedir. Ama bu tür kontrol ve kumanda ekipmanlarının büyük çoğunluğu kas sisteminin hareket etmesini gerektirmektedir. Bu durum özellikle uzuv kaybı yaşamış engelli veya kas hastalığı yaşayan bireyler için sorun teşkil etmektedir. Bu tür olumsuz durumların ortadan kaldırılması ve beyin fonksiyonları düzgün çalışan her bireyin cihazları kumanda edebilmesini, dış dünya ile iletişim kurması, sanal ve gerçek cihazlar ile etkileşim kurması ve diğer bireyler ile bağlantı kurabilmesinin sağlanması amacıyla bir beyin bilgisayar arayüzü (BBA) tasarımı gereksinim haline gelmektedir. Bir BBA yapısı Şekil 4.1’de yer almaktadır.




Şekil 4.1 : BBA temel tasarımı

Günümüzde bu alandaki çalışmalar yoğun bir şekilde devam etmektedir. Beyin sinyalleri ile yazı yazdırılması, bilgisayar kullanılması, robot ve arabaların kontrol edilmesi, hastalıkların ve bağımlılıkların tespiti gibi birçok sistem üzerine çalışmalar yapılmaktadır. Bu sistemler gelişen teknoloji ile her geçen gün daha kullanılabilir hale gelmektedir. Bu BBA sisteminin EEG sinyallerini kullanması insan sağlığına zarar vermemesi ve giyilebilir bir sistem olması sebebiyle kullanılabilir olduğu görülmektedir. EEG'nin yanı sıra fonksiyonel manyetik rezonans görüntülemesi (fMRI), pozitron emisyon tomografisi (PET),

magnetoensefalografi (MEG) gibi yöntemlerde mevcut olmaktadır [47]. EEG sistemi hem acısız hem de düşük maliyetli olmaktadır.


4.2. EEG Sinyali ve Göz-Kol İşbirliği Kullanarak Araçların Kontrol Edilmesi



Şekil 4.2 : Önerilen yöntemin sistem tasarımı

Bu çalışmada insan beyninden alınan sinyallerin anlaşılması amaçlanmaktadır. Cihazın bu sinyallerle kontrol edilmesi arzu edilir. Bu amaçla oluşturulan sistem şeması Şekil 4.2'de verilmiştir.


EEG sinyallerini alan cihaz 14 elektrotlu olup AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 olarak isimlendirilmiştir ve sayısal değerler içermektedir. Bu sinyaller kablosuz olarak bilgisayar ortamına iletilir ve veriler etiketlenir. Ham sinyal görüntüleri Şekil 4.3'te gösterilmiştir.



Şekil 4.3 : Ham EEG sinyal grafiği


Bu çalışmada iki hareket belirlenecektir. Bu amaçla uluslararası 10-20 sistemine uyacak şekilde elektrotlar yerleştirildikten sonra gözlerin açılıp kapanmasını algılamak için AF3, AF4 kanalları, diğer kanallar ise kolun yukarı ve aşağı hareketini algılamak için kullanılmaktadır. Bu sinyaller alındıktan sonra bilgisayar ortamında verilerin ön işleme

aşamasına geçilir. Bu adımda, önce ham veriler filtrelenir. Filtrelenmiş sinyaller Şekil 4.4'te gösterilmiştir.




Şekil 4.4 : Filtrelenmiş sinyaller

Filtrelenen gürültüsüz veriler daha sonra 256 ms veri içerecek şekilde paketlenir. Daha sonra, veri paketlerini çalışır hale getirmek için hızlı fourier dönüşümü (fft) uygulanır. Uygulanan fft sinyali Şekil 4.5'de gösterilmiştir.




Şekil 4.5 : FFT uygulanan veri paketi

Veri paketlerine dönüştürüldükten sonra her veri paketi için karekök ortalama (RMS), entropi, varyans, ortalama, maksimum, minimum değerler ve standart sapma değerleri hesaplanır ve böylece sinyalimizin nitelikleri belirlenir. Nitelikler, sinyalin yapısını belirlemeye yardımcı olur. Ham sinyallerden anlam çıkarmak zordur. Bu hesaplamalar her veri kanalı için ayrı ayrı yapılır ve kaydedilir. Bu işlemler tüm sinyaller için ayrı ayrı hesaplandıktan sonra her bir veri paketinin hangi harekete ait olduğunu belirlemek için sınıflandırma adımına geçilir. Bu aşamada kullanılan sınıflandırma yöntemlerinden biri de yapay sinir ağlarıdır (YSA). Bu yöntemle, nitelikler girdi için kullanılırken, etiketlenen veriler çıktı için kullanılır. Toplam verinin %70'i YSA eğitimi için kullanılırken kalan veriler test için kullanılır. YSA yapısı Şekil 4.6'da verilmiştir. Kullanılan YSA 7 giriş ve 1 çıkışa sahip olup, gizli katmanda 10 nörona sahiptir.



Şekil 4.6 : YSA giriş ve çıkışının yapısı

Diğer bir sınıflandırma yöntemi olarak k ortalamaları kullanılmaktadır. Bu durum için 2 sınıf vardır. Bu sınıflar göz ve kol hareketlerinin durumunu temsil eder. Bu sayede veri paketinin hangi sınıfa ait olduğu belirlenir. Şekil 4.7'de ise 2 sınıf için verilerin hangi sınıfa ait olduğu belirlenmektedir.




Şekil 4.7 : K ortalama durum kümeleri

Son olarak, işlemlerin hızlı bir şekilde gerçekleştirilebilmesi için deneyimle belirlenen öznitelik değerleri dikkate alınarak bir yöntem önerilmiş ve veri paketinin durumu belirlenmeye çalışılmıştır. Önerilen algoritmada hızlı çözüm üretebilmek için belirlenen kritere göre testler yapılmakta ve sonuçlara göre kararlar verilmektedir.

Algoritmadaki tanımsız durumları tespit etmek için göz hareketlerinin algılandığı kanallar ile kol hareketlerinin algılandığı kanallar karşılaştırılır. Herhangi bir kanalda hareket yoksa tanımsız kabul edilir. Daha sonra tüm kol ve göz durumlarının özniteliklerinin ayrı ayrı ortalamaları alınır. Ortalamanın altında ve üstünde olan vakalarda göz ve kolun durumuna kanala göre karar verilir. AF3 ve AF4 kanallarındaki verilerin yapısına göre, gözlerin kapalı olması durumunda ortalamanın altındaki özellikler, açık olması durumunda ise ortalamanın üzerindeki özellikler kabul edilmektedir. Aynı şekilde kol hareketi için diğer kanalların durumu kontrol edilir. Nitelikler ortalamanın altındaysa kol aşağıda, aksi takdirde kol yukarıdadır. Nitelikler ortalamanın altındaysa kol aşağıda, aksi takdirde kol yukarıdadır. Bu aşamada eş zamanlı kol ve göz kondisyonu için drone kaldırma ve iniş talimatı gönderilir.


4.3. Engellilerin Taleplerinin Yapay Zeka Yöntemleriyle Belirlenmesi

Bu çalışmada görsel uyaranlar kullanılarak EEG sinyalleri kaydedilmiş ve sınıflandırılmıştır. Bu amaçla önerilen sistemin genel akış diyagramı Şekil 4.8'de verilmiştir.



Şekil 4.8 : EEG sinyal sistemi diyagramından şekil sınıflandırması


Önerilen sistemde öncelikle EEG sinyallerinin alınacağı elektrotlar 10/20 sistemi ile jel sürülerek denegin kafatasına yerleştirildi. Bu işlem için elektrotların doğru yerlere yerleştirilmesi için kapakta açılan deliklere elektrotlar yerleştirildi ve kafatasına takıldı.



Şekil 4.9 : Uygulama için adım adım gösterim şeması

Bu aşamadan sonra öncelikle elektrotların veri iletimi kontrol edildi. Doğru temas ve veri iletimi sağlandığında sinyallerin kaydı başlatılmaktadır. Sinyal kaydı ve diğer işlemlerin gerçekleştirilmesi için izlenen adımlar Şekil 4.9'da gösterilmiştir. Şekil 4.9'da öncelikle oluşturulan veri setinden sınıfları belirlemek için eğitim gerçekleştirilir. Test adımlarında kaydedilen sinyalin hangi şekle ait olduğuna karar verilir.

Ekranda farklı anlarda 4 farklı şekil gösterildi. Bu işlem için kare, daire, üçgen ve yıldız şekilleri kullanılmıştır. Her şekil için beyaz şekil rengi ve siyah zemin rengi kullanılmıştır. Kayıt, şeklin görüntülenmesi ile başlar ve kayıt, 128 hz frekansında 1 saniyelik sinyaller olarak veri setinde serbest bırakılır. Böylece her rakam için ayrı kayıtlar yapılmış ve sinyaller kaydedilmiştir. Bu işlemden sonra sinyaller filtrelendirir. Filtreleme aşamasında 0,50 hz ile 50 hz arasındaki sinyalleri geçiren bir bant geçiren filtre kullanılmış ve EEG sinyali dışında gürültü olarak değerlendirilen sinyaller çıkarılarak temiz sinyale dönüştürülmüştür. Bant geçiren filtre Şekil 4.10'daki gibi tasarlanmıştır.



Şekil 4.10 : Bant geçiren filtre tasarımı bant grafiği


Ön işlemler tamamlandıktan sonra, sınıflandırma aşamasında kullanılacak veri seti hazır buruma getirilmektedir. Bu aşamada özellik çıkarma aşaması gerçekleştirilmiştir. Üretilen verilerin görsel yapısı Şekil 4.11'de verilmiştir. Şekil 4.11'de V üretilen sinyal vektörlerini, E değerleri ise elektrotlardan alınan sinyalleri temsil etmektedir.

V1	E1	E2	E3		E32
V2	E1	E2	E3		E32
⋮					
Vn	E1	E2	E3		E32

Şekil 4.11 : Oluşturulan EEG şekil verilerinin kaydı


4.3.1. İstatistiksel özelliklerin hesaplanması

Öznitelikler çıkarılırken 5 farklı öznitelik belirlenmiştir. Bu özellikler ortalama, medyan, standart sapma, moment 5 ve entropidir. Hesaplamalar 1'er saniyelik veriler için yapılarak öznitelik değerleri elde edilmektedir. Ortalama hesabı için denklem 3.4 kullanılmaktadır. Medyan hesaplama için tüm değerler artan düzende sıralanmakta ve ortadaki değer medyan değeri olarak hesaplanmaktadır. Standart sapma için denklem 3.7 kullanılarak hesaplama yapılmaktadır. Moment 5 değerinin hesaplanması için denklem 3.9 kullanılmaktadır. Bu denklemde geometrik moment değerleri için m_r hesaplanırken r değeri denkleme girilerek istenen derecedeki moment hesaplanabilmektedir. Değerin 5 olarak girilmesi ile Moment 5 hesabı yapılmakta ve özellik olarak vektörde yerini almaktadır. Bu çalışmada kullanılan son özellik ise entropi olmakta ve denklem 3.10 ile hesaplanmaktadır. Hesaplama yapılırken izlenen adımlar Şekil 4.12'de verildiği gibi olmaktadır.



Şekil 4.12 : Şekillerin EEG sinyalleri için entropi hesaplama adımları

Entropiyi hesaplamak için öncelikle sinyalin histogramı hesaplanır. Hesaplanan örnek sinyal için histogram grafiği Şekil 4.13'te verilmiştir.



Şekil 4.13 : Üçgen şeklinden kaydedilen EEG sinyali için örnek histogram grafiği

Daha sonra her bir histogram değeri için olasılıklar hesaplanmıştır. Olasılıklar hesaplandıktan sonra, Entropi denklem 3.10 kullanılarak hesaplanmıştır.


Son olarak elde edilen özellikler bir araya getirilerek öznitelik vektörleri olarak kaydedilmiş ve ait oldukları şekil yazılarak veri setinin ikinci aşaması tamamlanmıştır.

4.3.2. Özellik sınıflandırması

Bu aşamada kaydedilen her sinyal için 5 farklı özellik hesaplanarak oluşturulan vektörlerin sınıflandırılması gerçekleştirilmektedir. Böylece kaydedilen sinyalin hangi şekle ait olduğu belirlenmektedir. Kullanılan sınıflandırma yöntemleri SVM, KNN ve DT yöntemleri olmaktadır. Her bir yöntem için ayrı ayrı sonuçlar elde edilmekte ve performans değerlendirmesi yapılmaktadır. Daha sonra diğer benzer çalışmalar ile karşılaştırılmaktadır.

4.4. EEG Sinyalleri İçin Derin ve İstatistiksel Özellikler Sınıflandırma Modeli

Bu çalışmada, EEG sinyal sınıflandırması için DSFC yaklaşımı önerilmiştir. Mevcut teknik, Şekil 4.14'teki blok diyagramda gösterildiği gibi, hem DL hem de istatistiksel yöntemlerden elde edilen özellik vektörlerinin birleştirilmesini ve sınıflandırılmasını içerir. Bu yöntemde öncelikle her elektrottan kaydedilen sinyaller tek bir sinyalde birleştirilir.



Şekil 4.14 : Yeni DSFC modeli için blok diyagramı.

4.4.1. VMD ile sinyal gürültü giderme

EEG veri setindeki sinyaller, ön işleme adımında ilk olarak VMD tarafından gürültüden arındırılır. VMD yöntemi, gerçek değerli bir sinyali sınırlı sayıda alt sinyale ve faza ayırır [50]. Her bir alt sinyal, bu yinelemesiz sinyal ayırma işleminde merkez


frekansın etrafında üretilir. Her modun bant genişliği üç adımda değerlendirilir. Her modun frekans spektrumu, ilk aşamada Hilbert dönüşümü kullanılarak elde edilir. Her modun frekans spektrum özelliği, onu ikinci aşamada temel merkez frekansına kaydırmak için kullanılır. Modun bant genişliği, demodüle edilmiş sinyalin Gauss düzgünlüğü kullanılarak üçüncü adımda belirlenir.

4.4.2. Sinyal istatistiksel özelliklerini çıkarma

Gürültüden arındırılmış sinyalin özellikleri her örnek için ayrı ayrı hesaplanır ve bir özellik vektörü üretilir. Özelliklerden 8 tanesi istatistiksel özellikler olmakta ve hesaplamaları yapılmaktadır. Bu özelliklerden ortalama, denklem 3.4 ile hesaplanmaktadır. Sinyaldeki değerler sıralanır ve ortanca değer alınarak ikinci özellik olan medyan değeri hesaplanmaktadır. Sıralanan sinyalin ilk ve son değerleri alınarak ikinci ve üçüncü özellikler olarak en küçük ve en büyük değerler olarak ele alınarak kullanılmaktadırlar. Beşinci özellik olarak çarpıklık özelliği kullanılmakta ve denklem 3.5 ile hesabı yapılmaktadır. Sinyalin basıklık değeri de altıncı özellik olarak denklem 3.6 ile hesaplanmaktadır. Standart sapma yedinci özellik olmakta ve hesaplaması denklem 3.7 ile yapılmaktadır. Sekizinci özellikte enerji olarak alınmakta ve denklem 3.8 hesabın yapılması için kullanılmaktadır. Böylece istatistiksel olarak belirlenmiş özelliklerin hesaplamaları tamamlanmış olmaktadır.

4.4.3. Derin özelliklerin hesaplanması

Bu aşamada öncelikle sinyal örneklerinin spektrogramı oluşturulur. Spektrogram, anlık sinyalin frekansı hesaplanarak oluşturulan zaman-frekans eksenli grafiği ile temsil edilir. Spektrogram örneği Şekil 4.15'te verilmiştir.



Şekil 4.15 : Spektrogram oluşturma adımları

Sinyaller pencerelenmekte ve daha sonra FFT uygulanarak frekans tanım kümesine aktarılmaktadır. Daha sonra zaman frekans grafiği çizilerek sinyalin spektrumu elde edilmiştir. Pencereleme aşamasında, gürültüsüz sinyallerden spektrogramları çıkarmak için onları çerçevelemek önemlidir. 25 ms çerçevelere bölünmüş EEG sinyalleri için, çerçeveler yüzde 50 örtüşecek şekilde ayarlanır. Her çerçevenin başındaki ve sonundaki süreksizliği önceliklendirmek için Hamming Penceresi kullanılarak merkez bölge daha belirgin hale getirilmiş ve sinyalin uç bölgesindeki istenmeyen ışımaların en aza indirilmesi amaçlanmıştır. Bu pencereleme işleminden sonra sinyal FFT için kullanılabilir hale getirilir. Bu adımlar sonucunda elde edilen spektrogram grafikleri DL aşamasında yorumlanmak istenmektedir. Bu fonksiyon için AlexNet derin öğrenme mimarisi kullanılmaktadır. Bu ağın mimarisi temel olarak 5 konvolüsyonel katmandan ve bir fonksiyon çıkarıcı olarak kullanılabilen 3 FC katmanından oluşur. Derin özellik çıkarımı için AlexNet mimarisinin FC katmanı kullanılır. Hibrit vektör için FC adımında derin öznitelikler elde edilir ve istatistiksel özellikler ile birleştirilmektedir.


4.4.4. Sınıflandırma yöntemleri

İstatistiksel yöntemlerden ve DL adımlarından elde edilen özellik vektörleri bu aşamada birleştirilir. Elde edilen yeni özellik vektörü, EEG sinyalinin sınıflandırılmasında

kullanılır. Bu aşamada 4 farklı sınıflandırma yöntemi kullanılmaktadır. Bunlar SVM, k en yakın komşu (KNN), karar ağaçları (DT) ve doğrusal ayırım analizidir (LDA).

4.5. Moment Özelliklerini Kullanarak AUD EEG Sinyallerinin Sınıflandırılması

Alkol bağımlılığının EEG sinyalleri üzerinde bir etkisi olup olmadığını araştırmak için bir çalışma yürütülmektedir. Bu amaçla hazır bir EEG veri seti kullanılmaktadır. Önerilen sistemin yapısı Şekil 4.16'da verilmiştir. Alkolik ve Kontrol için verilerin alındığı bireylere New York Eyalet Üniversitesi Sağlık Merkezinde görseller gösterilerek elde edilen EEG sinyalleri kaydedilerek hazır veri seti oluşturmuşlardır. Şekil 4.16'daki gibi hem alkoliklere hem de kontrol grubundaki bireylere aynı görüntü gösterilmiş ve bu süre zarfında veri setini oluşturan kişiler tarafından EEG sinyalleri kaydedilmiştir. Beyindeki faaliyetler elektrotlar aracılığıyla kaydedilebilir. Bu elektrotlar Şekil 4.16'da E1'den En'e kadar sembollerle temsil edilmiş ve kullanılan veri setinde 64 elektrot bulunan bir EEG cihazı ile kaydedilmiştir. Uygulamada kullanılacak veri seti, New York Eyalet Üniversitesi Sağlık Merkezi'nde Henri Begleiter tarafından kaydedilmiştir [68];




Şekil 4.16 : Önerilen yöntemin akış şeması

Veri setini oluşturan Henri Begleiter ve ekibi kayıt aşamasında 64 elektrotlu ve 256 Hz frekansında kayıt yapan cihaz kullanmışlardır. Kaydettikleri veri seti için 10 AUD ve 10 normal kontrol grubu bireyinden EEG sinyallerini kaydetmişlerdir. Kaydettikleri veri setine Büyük Veri Kümesi adını verdiler. Veri seti için kayıt yaparken Snodgrass ve Vanderwart resim setinden seçtikleri resimleri herkese göstererek beyinde oluşan EEG sinyallerini kaydettiler. Bu veri seti ilk olarak özellik çıkarma adımına geçilerek işlenir.

4.5.1. Moment özelliklerinin çıkarılması

Öznitelikler çıkarılırken istatistiksel momentler kullanılır ve denklem 3.9 ile değerler hesaplanmaktadır. Hesaplamalar Moment1'den Moment120'ye kadar yapılmaktadır. Moment1, Moment2, Moment3 ve Moment4, anlamları bilindiği ve birçok istatistiksel çalışmada kullanıldığı için göz ardı edilmiştir. Moment120'den sonraki değerler çok büyüdüğü için hesaplama hataları yaşanmaktadır. Bu nedenle üst limit Moment120 olarak belirlenmiştir. Bu hesaplama sonucunda her bir EEG kaydı için 120 özellik değeri elde edilmiştir. Bu öznitelik değerleri bir vektör olarak saklanır. Daha sonra bu öznitelik değerlerinin sınıflandırılmasına geçilir. Bu aşamada birçok farklı sınıflandırma yöntemi denenmiş ve en iyi sonuca ulaşmaya çalışılmıştır. Sınıflandırma için kullanılan yöntemler DT, LDA, LR, NB, SVM ve KNN olarak belirlenmiş ve özellik değerlerine göre sonuçlar elde edilmiştir.


Hesaplanan her Moment özelliği, sınıflandırma yöntemlerini eğitmek için kullanılır. Her sınıflandırma yöntemi için sonuçlar elde edilir ve elde edilen sonuçlar karşılaştırılarak sınıflandırma yöntemlerinden hangisinin en iyi performansa sahip olduğu belirlenir. Böylece EEG sinyallerinin sınıflandırılması için hangi yöntemin uygun olduğu belirlenmiş olur. Sınıflandırma aşamasında Şekil 4.17'deki gibi bir yol izlenir.



Şekil 4.17 : EEG sinyallerinin moment değerlerine göre sınıflandırılması


4.6. EEG Sinyallerinin Elektrot Korelasyonlarının Araştırılması

EEG sinyalleri alınırken yerleştirilen elektrotların hangilerinin birbirleri ile korelasyonlarının yüksek olduğu üzerine yapılan araştırma ile elektrotların birlikte kullanılabilirliği araştırılmaktadır. Şekil 4.18’de elektrotların kafa üzerine yerleşimi ve isimleri yer almaktadır.



Şekil 4.18 : Kafatasına yerleştirilmiş elektrotlar

Elektrotlardan alınan verilerin grafikleri şekil 4.19’da yer almaktadır. Sinyallerin korelasyon değerleri hesaplandığında çizelge 4.1’deki gibi değerler elde edilmektedir.



Şekil 4.19 : EEG sinyal grafikleri

Çizelge 4.1 : Elektrotların korelasyon değerleri.

	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
AF3	1	0,5853	0,7552	0,6065	0,3489	0,2306	0,3183	0,2245	0,3191	0,5012	0,6497	0,7973	0,7584	0,9430
F7	0,5853	1	0,5653	0,7499	0,4912	0,3293	0,2592	0,1056	0,1434	0,1772	0,2500	0,3768	0,2485	0,4137
F3	0,7552	0,5653	1	0,7653	0,6440	0,5952	0,4907	0,5456	0,5631	0,6404	0,6673	0,8332	0,6243	0,7077
FC5	0,6065	0,7499	0,7653	1	0,6798	0,5441	0,3957	0,3567	0,3684	0,4007	0,4066	0,5649	0,3607	0,4731
T7	0,3489	0,4912	0,6440	0,6798	1	0,8346	0,6624	0,6552	0,6396	0,6294	0,5331	0,5331	0,3605	0,2986
P7	0,2306	0,3293	0,5952	0,5441	0,8346	1	0,6568	0,7206	0,7083	0,6532	0,4952	0,5079	0,3099	0,2144
O1	0,3183	0,2592	0,4907	0,3957	0,6624	0,6568	1	0,6446	0,6673	0,5739	0,5126	0,5827	0,3852	0,3340
O2	0,2245	0,1056	0,5456	0,3567	0,6552	0,7206	0,6446	1	0,8666	0,7240	0,5942	0,5916	0,4146	0,2855
P8	0,3191	0,1434	0,5631	0,3684	0,6396	0,7083	0,6673	0,8666	1	0,8280	0,6782	0,6692	0,5372	0,3891
T8	0,5012	0,1772	0,6404	0,4007	0,6294	0,6532	0,5739	0,7240	0,8280	1	0,8012	0,7643	0,7138	0,5886
FC6	0,6497	0,2500	0,6673	0,4066	0,5331	0,4952	0,5126	0,5942	0,6782	0,8012	1	0,8357	0,8432	0,7411
F4	0,7973	0,3768	0,8332	0,5649	0,5331	0,5079	0,5827	0,5916	0,6692	0,7643	0,8357	1	0,8230	0,8381
F8	0,7584	0,2485	0,6243	0,3607	0,3605	0,3099	0,3852	0,4146	0,5372	0,7138	0,8432	0,8230	1	0,8643
AF4	0,9430	0,4137	0,7077	0,4731	0,2986	0,2144	0,3340	0,2855	0,3891	0,5886	0,7411	0,8381	0,8643	1

Sonu olarak her bir elektrotun en yksek ve en dřk korelasyon deęerine sahip olduęu elektrotlar ve korelasyon deęerleri izelge 4.2’de yer almaktadır.


izelge 4.2 : Elektrotlar ve en yksek ve en dřk korele oldukları elektrotların korelasyon deęerleri

Elektrot	En Yksek Korelasyon	Korelasyon Deęeri	En Dřk Korelasyon	Korelasyon Deęeri
AF3	AF4	0,9430	O2	0,2245
F7	FC5	0,7499	O2	0,1056
F3	F4	0,8332	O1	0,4907
FC5	F3	0,7653	O2	0,3567
T7	P7	0,8346	AF4	0,2986
P7	T7	0,8346	AF4	0,2144
O1	P8	0,6673	F7	0,2592
O2	P8	0,8666	F7	0,1056
P8	O2	0,8666	F7	0,1434
T8	P8	0,8280	F7	0,1772
FC6	F8	0,8432	F7	0,2500
F4	AF4	0,8381	F7	0,3768
F8	AF4	0,8643	F7	0,2485
AF4	AF3	0,9430	P7	0,2144

5. UYGULAMA SONUÇLARI

5.1. EEG Sinyali ve Göz-Kol İşbirliği Kullanarak Araçların Kontrol Edilmesi Sonuçları


EEG sinyallerinin ön işlenmesinden sonra elde edilen özellikler ayrı ayrı çizilir. EEG kanallarından alınan veriler için elde edilen özellikler Şekil 5.1'de verilmiştir.




Şekil 5.1 : Çıkarılan özelliklerin veri grafikleri

Özellikler elde edildikten sonra YSA için verilerin %70'i eğitim, %30'u test için kullanılır. YSA tasarımında her bir özellik giriş olacak şekilde 7 girişli olarak tasarlanmaktadır. Daha sonra gizli katmandaki nöron sayısı belirlenir. YSA için gizli katmanda 10 adet nöron kullanılmaktadır. Sonuç olarak 1 çıktı elde edilir. YSA 1000


iterasyonu çalıştırılarak Şekil 5.2'deki eğitim grafiği, Şekil 5.3'deki performans grafiği ve Şekil 5.4'teki test grafiği elde edilir.



Şekil 5.2 : YSA eğitim grafiği



Şekil 5.3 : YSA performansı ve hata grafiği



Şekil 5.4 : YSA test grafiği

Hedeflenen hata oranı binde 1 olarak belirlenirken sonuç %1,55 ve eğitim süresi 19 saniyedir. K ortalama algoritması kullanılarak, veriler iki kümeye bölünür. Kol ve göz hareketinin aynı anda gerçekleşmediği durumlardan sonra kalan veriler iki kümeye ayrılır. Bu süreçte 120 veri kullanılmaktadır. Her veri 7 öznitelik içerir. Bu verilerin k ortalama ile kümelenmesi için 7 iterasyona ulaşılmıştır. Çizelge 5.1, kümelerin veri örneklerini göstermektedir. K ortalaması sonucunda veriler %37,5 hata ile kümelenmektedir.

Çizelge 5.1 : K ortalama Küme Verileri

Kümeler	Veriler
Küme 0	0-62,458-41,093-194,49-8,0659-47,766-2281,6
Küme 1	0-51,085-37,405-139,17-5,7747- 35,332-1248,4

Son olarak önerilen algoritmada kullanılmak üzere çizelge 5.2'de öznitelikler ve bu özniteliklerin ortalaması hesaplanmıştır. Ayrıca tüm özniteliklerin ortalama değeri kapalı göz ve açılmış kol durumu için ayrı ayrı hesaplanmıştır.

Çizelge 5.2 : Özellikler ve hesaplanan ortalamaları

Özellikler	Genel Ortalama	Açık Gözler - Kaldırılmış Kol	Kapalı Gözler-İndirilmiş Kol
Rms	65,5809	69,4333	62,0954
Ortalama	44,7473	47,0069	42,7028
En Büyük	177,0134	191,4685	163,9349
En Küçük	5,9722	6,1578	5,8043
Standart Sapma	48,1894	53,5369	45,3269
Varyans	2694,9876	2973,7100	2442,8102

Hesaplama sonucunda elde edilen veriler incelendiğinde, göz açık ve kol kaldırılmış durum özelliklerinin ortalaması genel ortalamanın üzerinde iken, göz kapalı ve kol indirilmiş durum özelliklerinin ortalaması genel ortalamanın altındadır. Bu gözlenen özelliğe dayanarak, algoritma önerildi ve tasarlandı. Daha sonra karşılaştırma yapılarak karar verilir.

Bu algoritmanın yapısı gereği karşılaştırma adımında entropi hata değeri kullanılmamıştır. Veriler için bireysel karşılaştırmalar sonucunda elde edilen göz ve kol koordinasyon sayısı çizelge 5.3'te verilmiştir.

Çizelge 5.3 : Özelliklerin Karşılaştırılması İle Elde Edilen Durumlar

Özellikler	Küme 0	Küme 1
Rms	51	69
Ortalama	53	67
En Büyük	54	66
En Küçük	51	69
Standart Sapma	52	68
Varyans	44	76

Gözler açık ve kaldırılmış kollar seti için 55 mevcut durum vardır. Kapalı gözler ve indirilmiş kol için 65 vaka mevcuttur. Karşılaştırma algoritmasından elde edilen sonuçlar ve hata oranları çizelge 5.4'te verilmiştir.

Çizelge 5.4 : Önerilen Yöntem için Hata Oranı

Durumlar	Mevcut Durumlar	Hesaplanan Durumlar	Hata Oranı
Açık Gözler - Kaldırılmış Kol	55	41	%25,45
Kapalı Gözler-İndirilmiş Kol	65	79	%21,54


Toplam veriler için hata değeri %23,33 olarak hesaplanmıştır. Tüm sonuçlar çizelge 5.5'te karşılaştırılmıştır.

Çizelge 5.5 : Karşılaştırmalı hata oranları

Yöntem	Veri Paketi	Doğru Sayısı	Hata Oranı
YSA	360	-	%1,55
K Ortalama	120	75	%37,50
Karşılaştırmak	120	106	%23,33

5.2. Engellilerin Taleplerinin Yapay Zeka Yöntemleriyle Belirlenmesi Sonuçları


Bu çalışmada kullanılan veriler Emotiv EPOC Flex kullanılarak kaydedilmiştir. Şekil 5.5'deki görüntüler, EEG sinyalleri kaydedilirken kullanılan görüntülerdir.



Şekil 5.5 : EEG sinyalleri için kullanılan şekil görüntüleri


Her bir görsel ayrı bir ekranda tam ekran olarak deneğe gösterilmiş ve EEG sinyalleri kaydedilmiştir. EEG sinyalleri 32 kanaldan 128 Hz'de kaydedildi. Kayıt aşamasında 1 saniyelik kayıtlar yapılarak veri seti oluşturulmuştur. Her 1 saniyede bir veriler gürültüden arındırılmış ve bu konuda bir bant geçiren filtre tasarlanmıştır. Bu aşamada artık 0.5 Hz ile 50 Hz frekans aralığındaki sinyallere ait veriler dahil edilmiştir.

Özellik çıkarma aşamasında öncelikle ortalama özellik için hesaplamalar yapılmıştır. Yapılan hesaplamalar Şekil 5.6'da grafiksel olarak gösterilmiştir. Şekil 5.6'daki grafikler kare, daire, üçgen ve yıldız şekilleri verilerindeki tüm sinyallerden hesaplanan ortalama değerlerin grafiksel gösterimidir.




Şekil 5.6 : Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için ortalama özellik sonuçları

Diğer özellik olarak medyan hesabı yapılmıştır. Veri setindeki tüm sinyaller için ayrı ayrı medyan hesaplaması yapıldıktan sonra elde edilen değerler saklanmıştır. Her bir görsel için hesaplanan kaydedilen değerlerin grafiksel sonuçları Şekil 5.7'de verilmiştir.




Şekil 5.7 : Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için medyan özellik sonuçları

Hesaplama sonuçları, Şekil 5.8'deki grafiklerde verilen standart sapma özelliğinde her bir şekil için kaydedilen sinyallerden ayrı ayrı yapılmıştır.




Şekil 5.8 : Daire, Kare, Üçgen ve Yıldız şekillerin EEG verileri için standart sapma özellik sonuçları

Benzer şekilde diğer bir özellik olan Moment 5 için yapılan hesaplamalar sonucunda elde edilen sonuçların grafikleri Şekil 5.9'da, entropi için yapılan hesaplamalar sonucunda elde edilen sonuçların grafikleri de Şekil 5.10'da verilmiştir.



Şekil 5.9 : Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için Moment 5 özellik sonuçları



Şekil 5.10 : Daire, Kare, Üçgen ve Yıldız şekillerinin EEG verileri için entropi özelliği sonuçları

Özelliklerin hesaplanması tamamlandıktan sonra bu 5 özelliğin sınıflandırılması aşamasına geçilir. Bu aşamada sınıfların belirlenmesi için eğitim aşamasına geçilir. Her sınıf için öznitelik vektörünün hangi sınıfa ait olduğu belirlendikten sonra SVM, KNN ve DT ile sınıflandırma işlemi gerçekleştirilir.

Çizelge 5.6 : Her bir özelliğe göre sinyallerin sınıflandırılması

Yöntem	Ortalama	Medyan	Standart Sapma	Moment 5	Entropi
SVM	75,5 %	65,9 %	60,0 %	60,1 %	60,7 %
KNN	76,8 %	65,5 %	59,9 %	70,6%	62,7 %
DT	74,8 %	65,3 %	60,5 %	70,1 %	60,8 %

Öncelikle şekillerin sınıflandırılma sürecinde her bir özellik kullanılarak ayrı ayrı değerlendirilmiştir. Ayrı ayrı yapılan sınıflandırma sonuçları çizelge 5.6'da yer almaktadır. Çizelge 5.6 incelendiğinde ayrı ayrı değerlendirmeler yapıldığında en iyi sınıflandırma

sonuçlarının ortalama özellik için elde edildiği görülmektedir. İkinci sırada ise Moment 5 özelliği ile elde edilen sonuçlar yer alıyor.

Bu aşamadan sonra öznitelikler (Kare-Daire, Kare-Üçgen vb.) bir arada kullanılarak şekillere ait sinyallerin sınıflandırılması yapılmıştır. İkili kombinasyonlardaki şekiller üzerinde elde edilen sınıflandırma sonuçları çizelge 5.7'de verilmiştir.

Çizelge 5.7 : İkili kombinasyon halinde şekil verileri için sınıflandırıcı doğruluk oranları


Şekil	DT	SVM	KNN
Kare-Daire	99,2 %	100 %	100 %
Kare-Üçgen	98,8 %	99,9 %	100 %
Kare-Yıldız	99,8 %	100 %	100 %
Daire-Üçgen	99,3 %	99,9 %	99,9 %
Daire-Yıldız	99,9 %	100 %	99,9 %
Üçgen-Yıldız	100 %	100 %	100 %

Sınıflandırmaların ikili kombinasyonlarda karşılaştırılarak elde edildiği çizelge 5.7'deki sonuçlar incelendiğinde, SVM ve KNN, Kare-Daire kombinasyonu için %100 doğruluk oranı vermektedir. Kare-Üçgen kombinasyonu için KNN %100 doğruluğa sahiptir. Kare-Yıldız kombinasyonu, SVM ve KNN ile %100 doğruluk oranına sahiptir. Daire-yıldız kombinasyonu, %100 ile SVM tarafından sınıflandırılmaktadır. Üçgen-Yıldız kombinasyonu ise kullanılan tüm sınıflandırma algoritmalarında %100 doğruluk sağlamıştır. Çalışmanın son aşamasında ise tüm şekillerdeki sinyallerin performans oranları aynı anda ve tüm özellikler kullanılarak incelenecektir. Bu aşamada tüm sinyallerin verilerinden elde edilen öznitelikler KNN, SVM, DT algoritmaları kullanılarak sınıflandırılır. Bu sınıflandırmaların sonuçları çizelge 5.8'de verilmiştir.


Çizelge 5.8 : EEG sinyallerinin sınıflandırma sonuçları

Sınıflandırıcı	Doğruluk (%) (Kare, Daire, Üçgen, Yıldız)
SVM	99,99
KNN	99,99
DT	99,30

Çizelge 5.8 incelendiğinde EEG sinyalleri ile tüm şekillerin %99,99 doğrulukla ayırt edilebildiği görülmektedir. Bu, insan beyninin farklı görsel uyaranlara farklı tepkiler verdiğini gösterir. Sınıflandırma sonucunda elde edilen doğruluk oranının karışıklık matrisi Şekil 5.11'de verilmiştir. Yalnızca 3 numaralı Yıldız şekli, 0 numaralı daire olarak yanlış bir şekilde sınıflandırılmıştır. Bunun dışında diğer tüm sinyal verileri doğru bir şekilde sınıflandırılmıştır. Şekil 5.12'de ROC eğrisi ile grafikte verilmiştir.



Şekil 5.11 : Özelliklere göre kare, daire, üçgen ve yıldız şekillerinin SVM sınıflandırması için karışıklık matrisi



Şekil 5.12 : Özellik için kare, daire, üçgen ve yıldız şekillerinin tahmini için SVM ROC grafiği

Literatürde benzer görsel uyaran yönteminin kullanıldığı diğer çalışmalarla karşılaştırılması çizelge 5.9'de verilmiştir. Çizelge 5.9 incelendiğinde farklı veri seti ve verileri kullanan çalışmalar bulunmaktadır. Bu çalışmaların çoğu, görsel uyaranlara dayalı olarak kaydedilen veriler üzerinde gerçekleştirilmektedir.

Çizelge 5.9 : Literatürdeki diğer çalışmalarla karşılaştırma


Kaynaklar	Yöntem	Doğruluk Oranı
[21]	NNLS	91,70 %
[30]	DNN	94,00 %
[18]	ResNet	90,16 %
[31]	SVM	80,50 %
[33]	CCA	95,42 %
[34]	CCA	89,92 %
[35]	NN	66,67 %
[36]	LDA	98,18 %
Önerilen Yöntem	SVM	99,99 %
	KNN	99,99 %

5.3. EEG Sinyalleri İçin Derin ve İstatistiksel Özellikler Sınıflandırma Modeli

Sonuçları

Bu araştırmada, bu çalışmadaki EEG verileri, New York Eyalet Üniversitesi Sağlık Merkezi'nin açık bir EEG veri tabanından elde edildi [4]. Bu veriler, alkolizme genetik duyarlılığın EEG ile ilişkilerini incelemek için yapılan büyük bir çalışmadan kaynaklanmaktadır. Kontrol ve alkolik deneklerin zaman serisi EEG kayıtlarını içeren, 256 Hz'de bir saniye örneklenen kafa derisi üzerine yerleştirilmiş 64 elektrottan alınan ölçümleri içeren bir veri seti kullanılır. Veri seti 235 alkollü ve 233 kontrol EEG sinyali içermektedir. Bu EEG sinyalleri 10 alkolik ve 10 normal kişiden alınan ve görseller gösterilerek kaydedilen sinyallerdir [68];


Bu sonuçlar, AUD ile EEG'ye genetik yatkınlığın korelasyonunu araştırmak için yapılan geniş bir çalışmaya dayanmaktadır. Her bir elektrottan alınan 256 bilgi birbirine eklenerek $64 \times 256 = 16384$ değer içeren bir sinyale dönüştürülmüştür. Daha sonra işlemler bu sinyal üzerinden gerçekleştirildi.



Şekil 5.13 : EEG Sinyalinin 9 mod için VMD grafikleri

Çizelge 5.10 : İstatistiksel özellikler için hesaplanan örnek değerler


Örnek	Ortalama (a)	Medyan (m)	Standart Sapma(σ)	Enerji (e)	Basıklık (ku)	Çarpıklık (s)	En Büyük (ma)	En Müçük (mi)
1	1,98	1,22	7,50	$16,18 \times 10^9$	6,46	0,84	51,90	-39,82
2	1,89	1,17	10,90	$32,88 \times 10^9$	34,13	3,36	146,26	-63,37
3	-6,83	-5,43	8,39	$31,46 \times 10^9$	6,32	-1,16	28,07	-90,62
4	0,20	-1,77	15,69	$66,12 \times 10^9$	38,13	4,42	202,25	-64,35
5	-0,32	-0,29	6,73	$12,19 \times 10^9$	6,57	0,19	35,84	-56,44
6	-1,45	-1,2	8,61	$20,50 \times 10^9$	20,99	1,15	98,63	-78,30



Şekil 5.14 : Orijinal ve gürültüden arındırılmış EEG sinyal grafikleri

DSFC modelimizdeki tüm hesaplama sonuçları Matlab R2020a kullanılarak elde edilmiştir. İlk aşamada, seçilen $w_k = 5$, $\alpha = 120$ ve $tol = 10^{-7}$ parametreleri ile VMD kullanılarak sinyalin gürültüsü giderilir. Verimli sinyal ayrışımı için, yukarıdaki parametreler birçok araştırmada kullanılan sabit değerlerdir [15]. 9 modlu ayrıştırılmış EEG sinyalleri Şekil 5.13'te verilmiştir. Ayrıca orijinal EEG sinyali ve VMD uygulanarak giderilen gürültü Şekil 5.14'te verilmiştir.


İstatistiksel özellikler hesaplanırken her sinyal örneği için ayrı ayrı hesaplanır. Ortalama özellik için Şekil 5.15'teki grafik elde edilmiştir. Grafik incelendiğinde ortalama değerlerinin -12 ile 15 arasında değiştiği görülmektedir. Bu değerler, sınıflandırma için kullanılacak hesaplanmış ortalama sonuçlardır.




Şekil 5.15 : Ortalama özellik için hesaplanan veriler

Ortanca özellik için hesaplanan değerlerin -13 ile 10 arasında değiştiği gözlemlendi. Standart sapma hesaplandı. Her sinyal için hesaplanan diğer bir özellik ise minimum değerdir. Bu özelliği kullanırken değer değişim aralığı -10 ile -150 arasındadır. Maksimum özellik değerleri 2 ile 450 arasında değişir.

Çarpıklık özelliğinde yapılan hesaplama sonucunda -6 ile 8 arasında değişim olduğu görülmüş ve tüm veriler için hesaplanan sonuçlar Şekil 5.16'da verilmiştir. Basıklık değeri bir diğer özellik olup değer aralığı 1 ile 140 arasında değişmektedir.




Şekil 5.16 : Çarpıklık özelliği için hesaplanan veriler




Şekil 5.17 : EEG sinyalinin grafiği ve spektrogram grafiği

Her EEG sinyal örneği için, derin özelliklerin çıkarılması için hesaplamalar yapılmadan önce başlangıçta spektrogramlar oluşturulur. Spektrogramlar, sinyalin frekans alanındaki değeri ile zaman alanındaki değeri eşleştirilerek oluşturulan görsel grafiklerdir. Şekil 5.17, örnek bir EEG girişi için oluşturulmuş bir spektrogram grafiğini göstermektedir. AUD ve kontrol sinyalleri olan tüm bireylerin spektrogram grafiklerinden AUD'li bireyler için rastgele seçilenler Şekil 5.18'de, kontrol grubu için rastgele seçilenler ise Şekil 5.19'da verilmiştir.




Şekil 5.18 : AUD spektrogramlarına sahip bireylere örnekler



Şekil 5.19 : Kontrol spektrogram örnekleri

Derin özellikler bu noktada hesaplanmalıdır. Bu amaçla Spektrogram grafiklerini sınıflandırmak için AlexNet kullanılmaktadır. Derin özellikler olarak AlexNet FC katmanında oluşturulan 4096 çıkış değerleri kullanılacaktır. Her sinyal spektrogram grafiği

için bu derin özellikler kaydedilir. Şekil 5.20, AlexNet'in eğitim ve doğrulama aşamalarından sonra oluşturulan doğruluk ve kayıp grafiğini göstermektedir. DL aşaması için yüzde 70 eğitim sırasında kullanılan spektrogram grafiklerinin kalan yüzde 30'u doğrulama için kullanılır. Uygulama her ağ için 1000 iterasyon ilerletilir.



Şekil 5.20 : AlexNet doğruluk ve kayıp grafikleri

Çizelge 5.11 : Ayrı istatistiksel özelliklere göre sınıflandırma sonuçları

Sınıflandırma Yöntemi	Ortalama	Medyan	En Küçük	En Büyük	Çarpıklık	Basıklık	Enerji	Standart Sapma
LDA	45,9%	48,9%	50,0%	48,3%	45,9%	55,3%	55,8%	45,7%
DT	58,1%	60,5%	65,6%	57,3%	57,7%	56,2%	62,0%	56,6%
KNN	57,7%	57,5%	61,1%	57,5%	54,9%	59,2%	60,3%	56,2%
SVM	58,3%	60,7%	66,0%	59,6%	57,5%	60,7%	62,4%	59,4%

Her bir özellik ayrı ayrı kullanıldığında sadece istatistiksel özelliklerin kullanıldığı sınıflandırma sonuçları çizelge 5.11'de gösterilmektedir. Çizelge 5.11'e bakıldığında en iyi sonuçları SVM'nin verdiği görülmektedir. Sınıflandırma algoritması bazında çizelge 5.11

incelendiğinde LDA sınıflandırması için en etkili özellik yüzde 55,8 ile Enerji özelliğidir. DT için en baskın özellik yüzde 65,6 ile Minimum oldu. KNN için en fazla ağırlık verilen özelliğin yüzde 61,1 ile Minimum olduğu görülmektedir. Diğer tüm SVM sınıflandırıcı yöntemlerine göre çarpıklık özelliği hariç her özellik için en iyi sonucun elde edildiği görülmektedir. Bu yöntemler arasında en iyi sonuç yüzde 66,0 ile en küçük değer özelliğinden elde edildi. Bu durum dikkate alındığında istatistiksel özellikler arasında en küçük değer en etkili olarak öne çıktığı görülmektedir.

Çizelge 5.12 : İstatistiksel özelliklerin farklı sınıflandırma algoritması sonuçları

Sınıflandırıcı	Sonuç
LDA	66,5 %
DT	68,4 %
KNN	76,3 %
SVM	81,2 %

Çizelge 5.12'de tüm istatistiksel özellikler bir arada kullanılarak sınıflandırma yapılmış ve AUD'li bireylere ve kontrol grubuna ait sinyaller tahmin edilmeye çalışılmıştır. Bu aşamada Çizelge 5.12'deki sonuçların Çizelge 5.11'deki sonuçlara göre daha iyi sonuçlara sahip olduğu görülmektedir.

Bu noktada tüm niteliklerin toplu olarak incelenmesinin ayrı ayrı değerlendirilmesinden daha faydalı olduğu tespit edilmiştir. SVM, yalnızca istatistiksel bilgilerle en iyi sınıflandırma sonuçlarını üretse de, yüzde 18,8'lik hata oranı düşük performans gösterir ve düşürülmesi gerekir.


DL sonuçlarını oluşturmak için yalnızca spektrogram verileri kullanıldığında, AlexNet DL modelinin yüzde 95,71 doğruluk oranına sahip olduğu keşfedildi.

Çizelge 5.13 : Spektrogram görüntüleri ile elde edilen DL sonuçları

Model	Öğrenme Türü	Eğitim ve Test Görüntüleri	Sınıflar / Görüntü Sayıları	İterasyon	Doğruluk (%)	Geçen Süre (dk)
AlexNet	DL	Eğitin 70% Test 30%	AUD / 235 görüntü	1000	95,71	14,25
			Kontrol / 233 görüntü			

Çizelge 5.13, DL yönteminin sonuçlarını göstermektedir. Bu sonuçlar istatistiksel özellikler kullanılarak elde edilen doğruluk oranından daha iyi olmasına rağmen yetersiz kabul edilmektedir. Sonuç olarak hata oranı yüzde 4,29’dur.

Şekil 5.21, AlexNet modelinin yüzde 30 doğrulama prosedürü sonuçları için karışıklık matrisini göstermektedir. Önerilen hibrit DSFC yaklaşımının bu aşamada elde edilen doğruluğu artırması ve daha kesin bulgular sağlaması beklenmektedir.




Şekil 5.21 : AlexNet DL algoritmasının karışıklık matrisi

4104 özellikli hibrit öznitelik vektörleri üretilmiş ve sınıflandırılmıştır. Çizelge 5.14'e bakıldığında doğruluk oranlarının iyileştiği ve SVM sınıflandırıcı ile önceki sonuçlara göre daha kabul edilebilir bir değerde sonuç elde edilirken, diğer sınıflandırma yöntemlerinin önceki uygulamalara göre daha iyi sonuçlar verdiği görülmektedir. Hata oranı, son noktada yüzde 0,8'e düşürüldü ve bu ilk senaryoya göre daha kabul edilebilir bir hata oranı oldu.


Çizelge 5.14 : Hibrit özellik değerleri ile EEG sinyallerinin sınıflandırılması

Sınıflandırıcı	DSFC Sonuçları (%)
	AlexNet + İstatistiksel Özellikler
LDA	93,60
DT	76,10
KNN	92,30
SVM	99,20



Şekil 5.22 : DSFC için SVM algoritmasının karışıklık matrisi

Şekil 5.22'deki SVM algoritmasının karışıklık matrisine bakıldığında, AUD grubuna sahip bireylerin 234, kontrol grubunun ise 230 doğru tahmin aldığı görülmektedir.



Şekil 5.23 : SVM algoritmasının ROC grafiği

Şekil 5.23, en iyi sonuçları üreten SVM yöntemi için ROC grafiğini göstermektedir. Bu noktada yöntemler karşılaştırıldığında önerilen hibrit yöntemin diğer yöntemlere göre daha yüksek doğruluk oranına sahip olduğu görülmektedir. Bu durumda, hibrit vektör sınıflandırmasının önceki test değerleriyle karşılaştırıldığında daha yüksek geçerli doğruluk oranı ile kanıtlandığı gibi, yöntemin başarısı kesinlikle üstündür. DSFC yaklaşımının bulguları, istatistiksel özellik sınıflandırmasından yüzde 18, DL yönteminden yüzde 3,49

daha iyi bulundu. Çizelge 5.15, literatürde aynı veri setini kullanan araştırmaların karşılaştırmasını göstermektedir.

Çizelge 5.15 : DSFC için Literatür karşılaştırması

Kaynaklar	Veri Seti	Yöntem	Sınıflandırıcı	Doğruluk(%)
[19]	Alkolik	PCA+Wavelet Transform	-	-
[20]	Alkolik	PCA+Wavelet Transform	SVM NN	94,67 98,83
[21]	Alkolik	LLE, ApEn, SampEn, and four HOS	SVM	91,70
[22]	Alkolik	CoHOG and Eig(Hess)-CoHOG	NNLS	95,83
[23]	Alkolik	SSA-ICA - PCA	XGBoost	98,97
Önerilen Yöntem (DSFC)	Alkolik	Derin Özellikler + İstatistiksel Özellikler	SVM	96,80
		VMD + Derin Özellikler + İstatistiksel Özellikler	SVM	99,20

5.4. Moment Özelliklerini Kullanarak AUD EEG Sinyallerinin Sınıflandırılması

Sonuçları

Özellikler, kullanılan veri setinden çıkarılır. Bu özellikler istatistiksel moment değerleridir ve denklem 3.9 ile hesaplanır. Moment1 ile Moment120 arasındaki tüm değerler için hesaplamalar yapılır.


Oluşturulan öznitelik vektörlerinin yapısı Şekil 5.24'te verilmiştir. Şekil 5.24'te m ile ifade edilenler moment değerini, EEG ile ifade edilen değerler ise her bir EEG sinyali için elde edilen ve momentlerden oluşan vektörleri temsil etmektedir. Özellik vektörleri oluşturulduktan sonra sıra bu değerlerin sınıflandırılmasına gelmektedir.

EEG1	m1	m2	m3		m120
EEG2	m1	m2	m3		m120
⋮					
EEG n	m1	m2	m3		m120

Şekil 5.24 : Üretilen özellik vektörlerinin gösterimi

Sınıflandırma aşamasında DT, LDA, LR, NB, SVM ve KNN sınıflandırma algoritmaları uygulanır. Bu sınıflandırma algoritmalarının uygulanması aşağıdaki gibidir.

Öncelikle Moment1 için tüm algoritmaların doğruluk oranları hesaplanmıştır. Daha sonra moment1 ve moment10 aralığında sınıflandırma doğruluğu sonuçları hesaplanır. Sonraki her sınıflandırma adımında momentler 5 artırılarak kümülatif olarak toplanır ve sınıflandırma doğruluk oranları hesaplanır. DT, LDA, LR, NB, SVM ve KNN ile yapılan sınıflandırma sonucunda elde edilen doğruluk oranları Şekil 5.25'deki grafikte verilmiştir.



Şekil 5.25 : DT, LDA, LR, NB, SVM ve KNN'nin m1-m120 aralığı için aralıklar seçilerek elde edilen sınıflandırma sonuçları

Tüm değerler toplandığında, LDA için sınıflandırma sonucu %50,20 olarak hesaplanır. LDA için en iyi sonuç m1-m10 aralığı kullanılarak yapılan sınıflandırmadır ve %99,4'tür. LR sınıflaması için yapılan çalışma incelendiğinde en iyi sonucun m1-m10

aralığında elde edildiği ve doğruluk oranının %84,6 olduğu görülmektedir. Diğer tüm sonuçlar Şekil 5.25'te yer almaktadır.

SVM sınıflandırma algoritması incelendiğinde elde edilen sonuçların tatmin edici bir doğruluk düzeyine sahip olduğu görülmektedir. Tüm değerleri içeren sınıflandırma sonucu %99,6'dır. m1-m10 ve m1-m20 aralıklarında SVM için %99,8 doğruluk elde edildiği Şekil 5.25'te verilmiştir. SVM m1 tekil değeri için düşük doğrulukta sonuçlar verirken m1- m10 aralığı dahil diğer tüm aralıklar için çok iyi sonuçlar vermektedir.

DT için tüm momentleri içeren değerler için sapmalı sınıflandırma sonucunda elde edilen doğruluk oranı %97 olarak hesaplanmıştır. Bu değer aralıkları için konfüzyon matrisi Şekil 5.26'da verilmiştir. Konfüzyon matrisindeki gerçek değerler ve tahmin edilen değerler incelendiğinde kontrol grubunda 3 alkolik değer yer alırken, 11 kontrol grubunun EEG sinyalleri alkolik olarak sınıflandırılmıştır.

NB için yapılan sınıflandırma m1 için en yüksek sonuç hesaplanırken ve %90'lık bir oran elde edilirken, diğer momentlerin eklenmesiyle doğruluk giderek azalmaktadır. Tüm sonuçlara ait grafikler Şekil 5.25'te gösterilmektedir. NB için tüm moment değerlerinin dikkate alındığı ve %79,10 doğruluk oranının elde edildiği sonuca ait karışıklık matrisi Şekil 5.26'daki gibidir. Şekil 5.26'daki karışıklık matrisi incelendiğinde, alkollü EEG sinyallerinin sınıflandırmaları tamamen doğrudur, kontrol grubu için yüksek oranda yanlış sınıflandırma vardır. Bu, NB'nin doğruluğunu azaltır. Tüm değerler için hesaplanan SVM sonucunun karışıklık matrisi Şekil 5.26'da verilmiştir. Karışıklık matrisi incelendiğinde 468 EEG sinyalinden sadece 2 tanesinin yanlış sınıflandırıldığı görülmektedir. Kontrol grubu için hatasız sınıflandırma yapılırken, alkolik grupta sadece 2 EEG sinyalinin özellik vektörlerinin yanlış sınıflandırıldığı görüldü.

KNN tarafından sınıflandırılan moment vektörlerinin sonuçları Şekil 5.26'da verilmiştir. Sonuçlar incelendiğinde m1 tekil değeri için %89,7 doğruluk oranı elde edilirken, diğer aralıklar için en yüksek doğruluk oranı %98,1 ile sınıflandırma yapmaktadır. Tüm değerleri içeren aralık için karışıklık matrisi, Şekil 5.26'da verilmiştir. Şekil 5.26'daki KNN karışıklık matrisinde, yanlış sınıflandırılmış alkollü EEG moment vektörlerinin sayısı, yanlış sınıflandırılmış kontrol EEG moment vektörlerinin sayısının yarısı kadar görünmektedir. Diğer tüm sınıflandırma algoritmaları için karışıklık matrisleri Şekil 5.26'da verilmiştir.

Gerçek Sınıf	AUD	232	3
	Kontrol	11	222
		AUD	Kontrol
Tahmini Sınıf			
(a)			

Gerçek Sınıf	AUD	235	0
	Kontrol	100	133
		AUD	Kontrol
Tahmini Sınıf			
(b)			

Gerçek Sınıf	AUD	233	2
	Kontrol	0	233
		AUD	Kontrol
Tahmini Sınıf			
(c)			

Gerçek Sınıf	AUD	232	3
	Kontrol	6	227
		AUD	Kontrol
Tahmini Sınıf			
(d)			

Gerçek Sınıf	AUD	119	116
	Kontrol	117	116
		AUD	Kontrol
Tahmini Sınıf			
(e)			

Gerçek Sınıf	AUD	124	111
	Kontrol	124	109
		AUD	Kontrol
Tahmini Sınıf			
(f)			

Şekil 5.26 : Karışıklık matrisi a) DT b) NB c) SVM d) KNN e) LDA f) LR

Tüm yöntemler uygulandıktan sonra elde edilen genel sonuçlar dikkate alındığında m1-m120 aralığı için elde edilen sonuçlar çizelge 5.16 'da verilmiştir. Çizelge 5.16 incelendiğinde %99,6 doğrulukla en iyi sonuç SVM yönteminde elde edilirken zaman açısından en iyi sonuç DT ile 0.32 sn olarak esaplanmaktadır.

Çizelge 5.16 : Kullanılan tüm sınıflandırma yöntemlerinin karşılaştırılması

Performans Ölçüsü	Sınıflandırıcı					
	DT	LDA	LR	NB	SVM	KNN
PPV	0,955	0,504	0,500	0,702	1	0,975
NPV	0,987	0,500	0,496	1	0,992	0,987
TPR	0,987	0,506	0,528	1	0,992	0,987
TNR	0,953	0,498	0,468	0,571	1	0,974
FPR	0,047	0,502	0,532	0,429	0	0,026
FNR	0,013	0,494	0,472	0	0,009	0,013
ACC	0,970	0,502	0,498	0,786	0,996	0,981
BER	0,030	0,498	0,502	0,215	0,005	0,020
F1	0,971	0,505	0,514	0,825	0,996	0,981
Eğitim Süresi (sn)	0.32	0,78	2.40	8.92	0.85	0.73

Bu çalışmanın literatürde aynı veri seti ile yapılmış diğer çalışmalarla karşılaştırılması çizelge 5.17'te verilmiştir. Çizelge 5.17 incelendiğinde diğer çalışmalara göre iyi bir doğruluk oranı elde edildiği görülmektedir. Bu sonuçlar sonucunda %99,60 doğruluk oranı elde edilmesi Moment özellik değerlerinin bu EEG veri seti için etkin sonuçlar verdiğini göstermektedir. Bu sonuçlara bakıldığında Moment 1 ve Moment 20 öznitelik aralığı kullanılarak yapılan sınıflandırma sonucunun %99,80 ile SVM'nin en yüksek doğruluk oranını verdiği görülmektedir. Buna dayanarak ve denklem 3.9 göz önüne alındığında, EEG sinyallerinin 20. dereceden bir polinom ile ifade edilebileceği sonucuna varılmıştır.

Çizelge 5.17 : Moment özellikleri için aynı veri seti ile literatür karşılaştırması

Kaynaklar	Veri Seti	Yöntem	Sınıflandırıcı	Doğruluk
[19]	Alkolik	PCA+ Dalgacık dönüşümü	-	-
[20]	Alkolik	PCA+ Dalgacık dönüşümü	SVM-NN	94,67% - 98,83%
[21]	Alkolik	LLE, ApEn, SampEn, and four HOS	SVM	91,7%
[22]	Alkolik	CoHOG and Eig(Hess)-CoHOG	NNLS	95,83%
[23]	Alkolik	SSA-ICA - PCA	XGBoost	98,97%
Önerilen Yöntem	Alkolik	İstatistiksel Moment Özellikleri	SVM	99,60%

6. BULGU VE ÖNERİLER

Moment değerleri özellik olarak kullanılırken sınıflandırma algoritmalarının sonuçları incelendiğinde sonuçların doğruluğu noktasında olumlu katkıların olduğu görülmektedir. Özellikle Moment 1'den 120 ye kadar yapılan hesaplamaların sonuçları incelendiğinde doğruluk oranının 20. Moment noktasında en yüksek seviyeye ulaştığı görülmekte ve daha sonra belirli bir düzeyde ilerlemektedir. Bu noktada EEG sinyallerinin modellenmesi üzerine bir yorum yapacak olursak iki farklı temel öneride bulunmaktayız. Bu öneriler 20. dereceden polinoma işaret etmektedir. Beyin sinyallerinin ifade edilmesi üzerine gerçekleşen birinci öneri olan 20. dereceden polinom denklem 6.1 ile ifade edilebilmektedir.

$$\begin{aligned}
 P(x) &= a_1x + a_0 \\
 P(x) &= a_2x^2 + a_1x + a_0 \\
 P(x) &= a_3x^3 + a_2x^2 + a_1x + a_0 \\
 &\vdots \\
 P(x) &= a_{20}x^{20} + a_{19}x^{19} + a_{18}x^{18} + a_{17}x^{17} + \dots + a_3x^3 + a_2x^2 + a_1x \\
 &\quad + a_0
 \end{aligned} \tag{6.1}$$

Denklem 6.1 önerilen beyin sinyali için muhtemel 20. dereceden polinomun genel bir ifadesini vermektedir.

İkinci öneride ise yine 20 dereceden polinom üst dereceyi ifade etmek üzere 1. dereceden polinomdan başlayarak 20. dereceden polinomun hesaplanması ve elde edilen sonuçların toplamı ile ifade edilmesi olmaktadır. Bu hesaplama sonucu denklem 6.2'de verilmektedir.

$$Q(x) = \sum_{i=1}^{20} \sum_{j=0}^i a_j x^j \tag{6.2}$$

Yirminci moment;

$$\begin{aligned}
 f(x) &= \sum_{i=1}^{20} (x_i - \mu_x)^{20} P(x_i) \\
 &= \binom{20}{0} x_i^{20} \cdot \mu_x^0 - \binom{20}{1} x_i^{19} \cdot \mu_x^1 + \binom{20}{2} x_i^{18} \cdot \mu_x^2 - \binom{20}{3} x_i^{17} \cdot \mu_x^3 + \dots - \binom{20}{19} x_i^1 \cdot \mu_x^{19} + \\
 &\quad \binom{20}{20} x_i^0 \cdot \mu_x^{20}
 \end{aligned}$$

şeklinde ifade edilmektedir ve bunun anlamı verilerin bir parametrenin limit olarak yakınsadığı değere göre olan uzaklık olarak ifade edilebilir. Yirminci moment Taylor serisi ile de elde edilebilir.

Taylor serisi;

$$f(x) = f(x_0) + \frac{f'(x_0)}{1!}(x-a) + \frac{f''(x_0)}{2!}(x-a)^2 + \dots + \frac{f^{(n)}(x_0)}{n!}(x-a)^n + \dots \quad (6.3)$$

a=0 özel durumu için MacLaurian serisi olarak adlandırılmakta ve denklem 4 ile ifade edilmektedir.

$$f(x) = f(x_0) + \frac{f'(x_0)}{1!}x + \frac{f''(x_0)}{2!}x^2 + \frac{f^{(3)}(x_0)}{3!}x^3 + \dots + \frac{f^{(n)}(x_0)}{n!}x^n + \dots \quad (6.4)$$

Moment Denklemi;

$$m_r = \frac{\sum_{i=1}^N (x_i - \mu_x)^r}{N}$$

Moment denkleminin Taylor serisi açılımı;

$f(x) = P(x_0)(x - \mu_x)^{20}$ ve polinom ilk sabit terimi $a_0 = P(x_0)(x - \mu_x)^{20}$ şeklinde olur.

$$f'(x) = 20. (x - \mu_x)^{19} P(x_0) \frac{(x - x_c)}{1!} \quad a_1 = 20. (x - \mu_x)^{19} P(x_0)$$

$$f''(x) = 20. 19. (x - \mu_x)^{18} P(x_0) \frac{(x - x_c)^2}{2!} \quad a_2 = 20. 19. (x - \mu_x)^{18} P(x_0)$$

$$f^{(3)}(x) = 20. 19. 18. (x - \mu_x)^{17} P(x_0) \frac{(x - x_c)^3}{3!} \quad a_3 = 20. 19. 18. (x - \mu_x)^{17} P(x_0)$$

.

.

.

$$f^{(20)}(x) = 20!. (x - \mu_x)^0 P(x_0) \frac{(x - x_c)^{20}}{20!} \quad a_{20} = 20!. (x - \mu_x)^0 P(x_0)$$

$$f^{(21)}(x) = 0$$

MacLaurian serisinin 20 dereceden açılımı yapılarak sınırlandırıldığında denklem 6.4 kullanılarak elde edilen sonuç denklem 6.5'te verilmekte ve önerilen EEG sinyalinin ifade edilmesi üzerine ikinci denklem ifadesi olmaktadır.

$$f(x) = f(x_0) + \frac{f'(x_0)}{1!}x + \frac{f''(x_0)}{2!}x^2 + \frac{f^{(3)}(x_0)}{3!}x^3 + \dots + \frac{f^{(20)}(x_0)}{20!}x^{20} \quad (6.5)$$

Sonuç olarak EEG sinyallerinin modellenmesi noktasında öneriler 20 dereceden $P(x)$, $Q(x)$ veya $f(x)$ ile hesaplanabileceği öngörüsü oluşmaktadır.

7. SONUÇ VE ÖNERİLER

İnsan beyninin nöroaktiviteleri ve bunların yorumlanması bilimsel açıdan önemli araştırma konuları arasında olmaktadır. Bu tez çalışmasında önerilen yöntemler doğrultusunda elde edilen sonuçlar incelendiğinde öncelikle hareket sisteminin beyin sinyalleri üzerinde etkisinin olduğu tespit edilmiştir. Bu durum göz ve kol hareketleri sırasında alınan EEG sinyallerinin sınıflandırılması ile belirlenmiş ve sonuçlandırılmıştır. Farklı görsellerin beyin sinyalleri üzerindeki etkileri noktasında ise farklı görsellere bakılması esnasında alınan EEG sinyalleri ile yapılan çalışma bir çözüm sunmaktadır. Bu çalışma ile 4 farklı görsel için sinyaller alınarak sınıflandırılmakta ve sonuçlar elde edilmektedir. Bu bağlamda çalışmanın kas sistemi ve konuşma yetisinin olmaması durumundaki hastalıkların isteklerinin görsellere bakarak talep etmelerinin sağlanması amacıyla sistem kurulabileceği görülmektedir. Farklı görsellerin EEG sinyallerinin başarılı şekilde ayırt edilebildiği görülmektedir. Ayrıca hazır alkolik adındaki veri seti üzerine yapılan çalışmalardan ilki istatistiksel ve derin özelliklerin bir araya getirilerek sınıflandırılması üzerine gerçekleştirilmektedir. Bu oluşturulan hibrit özellik vektörü sınıflandırılırken başarı oranının ayrı ayrı sınıflandırmalara göre daha yüksek olduğu görülmektedir. Diğer AUD çalışmasında ise Moment özelliklerinin kullanılması noktası önem arz etmektedir. Bu moment değerleri 1. dereceden 120. dereceye kadar hesaplanmış ve sınıflandırılmaları gerçekleştirilmiştir. Literatürde anlamları bilinmeyen moment 5 ve sonrası dereceler için sonuçların olumlu ve başarılı olduğu görülmektedir. Özellikle moment 20 noktasında en iyi sonucun elde edildiği görülmektedir. Bu durum ile AUD bireylerin görsel uyarana maruz bırakıldıklarında EEG sinyallerinin normal bireylerden farklı olduğu ve ayırt etmek için 20. Dereceye kadar moment değerlerinin kullanımının uygun olduğu görülmektedir. Bu durum göz önüne alındığında karmaşık EEG sinyallerinin 20. dereceden bir polinom ile ifade edilebilirliği sonucu doğmaktadır.

Bu tez kapsamında yapılan çalışmalar ile gerçek hayatta hastaların EEG sinyalleri ile yapılan tespitlerin kolaylaştırılması ve yaşam konforlarının artırılması için destek sistemlerinin geliştirilmesinin ilk adımlarının atılması hedeflenmiştir.

KAYNAKLAR

- [1] Fetç, E.E. (1969), “Operant conditioning of cortical unit activity”, *Science*, 163(3870), 955-958.
- [2] Tlay, E. E. (2019), “Beyinde Dinamik Baęlantıların EEG Osilasyonları ile Haritalanması”, İstanbul Üniversitesi, Sağlık Bilimleri Enstitüsü, İstanbul.
- [3] Sayın, A. (2008), “Beyin Bilgisayar Arayüzü Tasarımı”, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [4] Sevgili Z. and Akın, M. (2020), “İmleç Hareketlerine Ait EEG Sinyallerinin Sınıflandırılmasında Adaptif ve Adaptif Olmayan Filtrelerin Uygulamaları,” *DMF Mhendislik Dergisi*, vol. 11, no. 1, pp. 57–67, doi: 10.24012/dumf.584345.
- [5] Sutton, S., Braren, M., Zubin, J. and John, E. R. (1965), “Evoked-potential correlates of stimulus uncertainty,” *Science*, vol. 150, no. 3700, pp. 1187–1188, doi: 10.1126/science.150.3700.1187.
- [6] Hwang, H. J., Kim,S., Choi, S. and Im, C. H. “EEG-based brain-computer interfaces: A thorough literature survey,” *International Journal of Human-Computer Interaction*, vol. 29, no. 12, pp. 814–826, 2013, doi: 10.1080/10447318.2013.780869.
- [7] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., and Yger, F. (2018). A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. *Journal of neural engineering*, 15(3), 031005.
- [8] Aydemir, ., and Kayıkoęlu, T. (2009). EEG tabanlı beyin bilgisayar arayüzleri. *Akademik Bilişim*, 9, 11-13.
- [9] Akalin Acar, Z., & Makeig, S. (2013). “Effects of forward model errors on EEG source localization,” *Brain Topography*, vol. 26, no. 3, pp. 378–396, doi: 10.1007/s10548-012-0274-6.
- [10] Şeker, M. and zerdem, M. S. “İyi – kötü koku uyarılarının EEG aktivitesine etkisinin Welch metodu ile incelenmesi,” *Dicle Üniversitesi Mhendislik Fakltesi Mhendislik Dergisi*, vol. 8, no. 3, pp. 547–553, 2017, [Online]. Available: <https://dergipark.org.tr/tr/pub/dumf/issue/33629/408318>.
- [11] McFarland, D. J. and Wolpaw, J. R. “Brain-Computer Interfaces for Communication and Control BRAIN ACTIVITY PRODUCES electrical sign,”

Communications of the ACM, vol. 54, no. 5, pp. 60–66, 2011.

- [12] **Fakhruzzaman, M. N., Riksakomara, E. and Suryotrisongko, H.** “EEG Wave Identification in Human Brain with Emotiv EPOC for Motor Imagery,” *Procedia Computer Science*, vol. 72, pp. 269–276, 2015, doi: 10.1016/j.procs.2015.12.140.
- [13] **Kaya, M., Binli, M. K., Ozbay, E. Yanar, H. and Mishchenko, Y.** “Data descriptor: A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces,” *Scientific Data*, vol. 5, no. August, pp. 1–16, 2018, doi: 10.1038/sdata.2018.211.
- [14] **Kumar, S. Sharma, A. and Tsunoda, T.** “An improved discriminative filter bank selection approach for motor imagery EEG signal classification using mutual information,” *BMC Bioinformatics*, vol. 18, no. Suppl 16, 2017, doi: 10.1186/s12859-017-1964-6.
- [15] **Fiscon, G., Weitschek, E., Cialini, A., Felici, G., Bertolazzi, P., De Salvo, S., Bramanti, A., Bramanti, P. and De Cola, M. C.** (2018). “Combining EEG signal processing with supervised methods for Alzheimer’s patients classification,” *BMC Medical Informatics and Decision Making*, vol. 18, no. 1, pp. 1–10, doi: 10.1186/s12911-018-0613-y.
- [16] **Polich, J. and Kok, A.** (1995), “Cognitive and biological determinants of P300: an integrative review,” *Biological Psychology*, vol. 41, no. 2, pp. 103–146, doi: 10.1016/0301-0511(95)05130-9.
- [17] **Li, F., Li, X., Wang, F., Zhang, D., Xia, Y. and He, F.** “A novel P300 classification algorithm based on a principal component analysis-convolutional neural network,” *Applied Sciences (Switzerland)*, vol. 10, no. 4, pp. 1–15, 2020, doi: 10.3390/app10041546.
- [18] **Zheng, X., Chen, W., You, Y., Jiang, Y., Li, M. and Zhang, T.** “Ensemble deep learning for automated visual classification using EEG signals,” *Pattern Recognition*, vol. 102, p. 107147, 2020, doi: 10.1016/j.patcog.2019.107147.
- [19] **Sun, Y., Ye, N. and Xu, X.** “EEG analysis of alcoholics and controls based on feature extraction,” *International Conference on Signal Processing Proceedings, ICSP*, vol. 1, pp. 6–9, 2006, doi: 10.1109/ICOSP.2006.344501.
- [20] **Nazari Kousarrizi, M. R., Asadi Ghanbari, A., Gharaviri, A., Teshnehlal, M.**

- and Aliyari, M.** “Classification of alcoholics and non-alcoholics via EEG using SVM and neural networks,” *3rd International Conference on Bioinformatics and Biomedical Engineering, iCBBE 2009*, pp. 1–4, 2009, doi: 10.1109/ICBBE.2009.5162504.
- [21] **Acharya, U. R. Sree, S. V. Chattopadhyay, S. and Suri, J. S.** “Automated diagnosis of normal and alcoholic EEG signals,” *International Journal of Neural Systems*, vol. 22, no. 3, 2012, doi: 10.1142/S0129065712500116.
- [22] **Bajaj, V., Guo, Y., Sengur, A., Siuly, S. and Alcin, O. F.** “A hybrid method based on time–frequency images for classification of alcohol and control EEG signals,” *Neural Computing and Applications*, vol. 28, no. 12, pp. 3717–3723, 2017, doi: 10.1007/s00521-016-2276-x.
- [23] **Zubair, M.** “Classification of Alcoholic and Non-Alcoholic EEG Signals Based on Sliding-SSA and Independent Component Analysis,” *IEEE SENSORS JOURNAL*, vol. XX, p. 1, 2021, Accessed: Aug. 27, 2021. [Online]. Available: https://www.techrxiv.org/articles/preprint/Classification_of_Alcoholic_and_Non-Alcoholic_EEG_Signals_Based_on_Sliding-SSA_and_Independent_Component_Analysis/14837226.
- [24] **Jiang, X., Bin Bian, G., and Tian, Z.** “Removal of artifacts from EEG signals: A review,” *Sensors (Switzerland)*, vol. 19, no. 5, pp. 1–18, 2019, doi: 10.3390/s19050987.
- [25] **Sazgar, M. and Young, M. G.,** *Absolute Epilepsy and EEG Rotation Review: Essentials for trainees*, Springer, Berlin, Germany, 2019.
- [26] **Tuncer, T. Dogan, S. and Akbal, E.** “A novel local senary pattern based epilepsy diagnosis system using EEG signals,” *Australasian Physical and Engineering Sciences in Medicine*, vol. 42, no. 4, pp. 939–948, 2019, doi: 10.1007/s13246-019-00794-x.
- [27] **Singh, A., Pusarla, N., Sharma, S. and Kumar, T.** “CNN-based Epilepsy detection using image like features of EEG signals,” *International Conference on Electrical and Electronics Engineering, ICE3 2020*, pp. 280–284, 2020, doi: 10.1109/ICE348803.2020.9122874.
- [28] **San-Segundo, R., Gil-Martín, M., D’Haro-Enríquez, L. F. and Pardo, J. M.**

- “Classification of epileptic EEG recordings using signal transforms and convolutional neural networks,” *Computers in Biology and Medicine*, vol. 109, no. March, pp. 148–158, 2019, doi: 10.1016/j.compbiomed.2019.04.031.
- [29] **Namazi, H., Kulish, V. V. and Akrami, A.** “The analysis of the influence of fractal structure of stimuli on fractal dynamics in fixational eye movements and EEG signal,” *Scientific Reports*, vol. 6, no. March, pp. 1–8, 2016, doi: 10.1038/srep26639.
- [30] **Chowdhury, M. S. N., Dutta, A., Robison, M. K., Blais, C., Brewer, G. A. and Bliss, D. W.** “Deep neural network for visual stimulus-based reaction time estimation using the periodogram of single-trial eeg,” *Sensors (Switzerland)*, vol. 20, no. 21, pp. 1–20, 2020, doi: 10.3390/s20216090.
- [31] **Martišius, I. and Damaševičius, R.** “A prototype SSVEP based real time BCI gaming system,” *Computational Intelligence and Neuroscience*, vol. 2016, 2016, doi: 10.1155/2016/3861425.
- [32] **Sreeja, S. R. and Samanta, D.** “Classification of multiclass motor imagery EEG signal using sparsity approach,” *Neurocomputing*, vol. 368, pp. 133–145, 2019, doi: 10.1016/j.neucom.2019.08.037.
- [33] **Zhou, Y. He, S. Huang, Q. and Li, Y.** “A Hybrid Asynchronous Brain-Computer Interface Combining SSVEP and EOG Signals,” *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 10, pp. 2881–2892, 2020, doi: 10.1109/TBME.2020.2972747.
- [34] **Shao, L., Zhang, L., Belkacem, A. N., Zhang, Y., Chen, X., Li, J., and Liu, H.** (2020), “EEG-Controlled Wall-Crawling Cleaning Robot Using SSVEP-Based Brain-Computer Interface,” *Journal of Healthcare Engineering*, vol. 2020, 1–11. doi: 10.1155/2020/6968713.
- [35] **Murugappan, M., Juhari, M. R. B. M., Nagarajan, R. and Yaacob, S.** “An investigation on visual and audiovisual stimulus based emotion recognition using EEG,” *International Journal of Medical Engineering and Informatics*, vol. 1, no. 3, pp. 342–356, 2009, doi: 10.1504/IJMEI.2009.022645.
- [36] **Kapeller, C., Hintermuller, C., Abu-Alqumsan, M., Pruckl, R., Peer, A. and Guger, C.** (2013), “A BCI using VEP for continuous control of a mobile robot,” *Proceedings of the Annual International Conference of the IEEE Engineering in*

Medicine and Biology Society, EMBS, pp. 5254–5257, doi: 10.1109/EMBC.2013.6610734.

- [37] **Al Faiz, M. Z. and Al-Hamadani, A. A.** (2019), “Online brain computer interface based five classes EEG to control humanoid robotic hand,” *42nd International Conference on Telecommunications and Signal Processing, TSP 2019*, pp. 406–410, 2019, doi: 10.1109/TSP.2019.8769072.
- [38] **Zgallai, W., Brown, J. T., Ibrahim, A., Mahmood, F., Mohammad, K., Khalfan, M., Mohammed, M., Salem, M. and Hamood, N.** (2019), “Deep Learning AI Application to an EEG driven BCI Smart Wheelchair,” *2019 Advances in Science and Engineering Technology International Conferences, ASET 2019*, pp. 14–18, 2019, doi: 10.1109/ICASET.2019.8714373.
- [39] **Chen, X., Zhao, B., Wang, Y., Xu, S. and Gao, X.** “Control of a 7-DOF Robotic Arm System with an SSVEP-Based BCI,” *International Journal of Neural Systems*, vol. 28, no. 8, p. 1850018, Oct. 2018, doi: 10.1142/S0129065718500181.
- [40] **Er, M. B., Çiğ, H. and Aydilek, İ. B.** “A new approach to recognition of human emotions using brain signals and music stimuli,” *Applied Acoustics*, vol. 175, 2021, doi: 10.1016/j.apacoust.2020.107840.
- [41] **Keleş, E., and Çepni, S.** (2006). Beyin ve öğrenme. *Journal of Turkish Science Education*, 3(2), 66-82.
- [42] **Özdaş, M.** “Travmatik Beyin Hasarı, Nedenleri ve Etkileri.” <https://www.bilgiustam.com/travmatik-beyin-hasari-nedenleri-ve-etkileri/> (accessed Nov. 27, 2022).
- [43] “Sinir Hücresinin (Nöronun) Yapısı, Görevleri ve Nöron Çeşitleri.” <https://www.yenibiyoloji.com/sinir-hucresinin-noronun-yapisi-gorevleri-ve-noron-cesitleri-1556/> (accessed Nov. 27, 2022).
- [44] **Kaku, M.** “Zihnini Kilidini Açmak.” <https://liberteryen.org/2016/12/zihnini-kilidini-acmak/> (accessed Nov. 27, 2022).
- [45] **Millett, D.** “Hans Berger: From psychic energy to the EEG,” *Perspectives in Biology and Medicine*, vol. 44, no. 4, pp. 522–542, 2001, doi: 10.1353/pbm.2001.0070.
- [46] **Kaya, M. Cömert, M. and Mishchenko, Y.** “Beyin Bilgisayar Arayüzü İçin Dvm Makine Öğrenme Yöntemi Kullanılarak Eeg Verilerinden Sağ Ve Sol El Hareket

- Düşüncelerinin,” *dergipark.org.tr*, vol. 3, no. 10, pp. 1–20, 2017, Accessed: Nov. 26, 2022. [Online]. Available: <https://dergipark.org.tr/en/pub/tubav/issue/31124/337901>.
- [47] **Özmen N. G.**, (2010) “Beyin bilgisayar arayüzü tasarımı için farklı zihinsel aktiviteler esnasında oluşan EEG sinyallerinin analiz edilmesi ve sınıflandırılması,” Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- [48] “EEG Nedir?” https://eeguzerine.com/i_eeg-nedir.html (accessed Nov. 27, 2022).
- [49] **Çam, F. H.** “Beyin Dalgaları.” <https://biyoenerjim.wordpress.com/> (accessed Nov. 27, 2022).
- [50] **Dragomiretskiy, K. and Zosso, D.** “Variational mode decomposition,” *IEEE Transactions on Signal Processing*, vol. 62, no. 3, pp. 531–544, Feb. 2014, doi: 10.1109/TSP.2013.2288675.
- [51] **Deb, S., Dandapat, S. and Krajewski, J.** “Analysis and classification of cold speech using variational mode decomposition,” *IEEE Transactions on Affective Computing*, vol. 11, no. 2, pp. 296–307, 2020, doi: 10.1109/TAFFC.2017.2761750.
- [52] **Karan, B., Mahto, K., and Sahu, S. S.** (2018). “Detection of Parkinson disease using variational mode decomposition of speech signal,” In *2018 International Conference on Communication and Signal Processing (ICCSP)* (pp. 0508-0512). IEEE, doi: 10.1109/ICCSP.2018.8524445.
- [53] **Anuragi, A., and Sisodia, D. S.** (2019). “Alcohol use disorder detection using EEG Signal features and flexible analytical wavelet transform,” *Biomedical Signal Processing and Control*, 52, 384-393.
- [54] **Kilicoglu, T.** “Astroistatistik Momentler Carpiklik ve Basiklik,” 2020. [Online]. Available: https://acikders.ankara.edu.tr/pluginfile.php/107751/mod_resource/content/0/Astroistatistik_Konu_05_Momentler_Carpiklik_ve_Basiklik.pdf.
- [55] **Karci, A.** “Fractional order entropy: New perspectives,” *Optik*, vol. 127, no. 20, pp. 9172–9177, 2016, doi: 10.1016/j.ijleo.2016.06.119.
- [56] **Ellerman, D.** “An introduction to logical entropy and its relation to shannon entropy,” *International Journal of Semantic Computing*, vol. 7, no. 2, pp. 121–145, 2013, doi: 10.1142/S1793351X13400059.
- [57] **Gao, R. X. and Yan, R.** “Non-stationary signal processing for bearing health

- monitoring,” *International Journal of Manufacturing Research*, vol. 1, no. 1, pp. 18–40, 2006, doi: 10.1504/IJMR.2006.010701.
- [58] **Gupta, S. Jaafar, J. Wan Ahmad, W. F. and Bansal, A.** “Feature Extraction Using Mfcc,” *Signal & Image Processing : An International Journal*, vol. 4, no. 4, pp. 101–108, 2013, doi: 10.5121/sipij.2013.4408.
- [59] **Çomak, E. Arslan, A. and Türkoğlu, İ.** “A decision support system based on support vector machines for diagnosis of the heart valve diseases,” *Computers in Biology and Medicine*, vol. 37, no. 1, pp. 21–27, 2007, doi: 10.1016/j.compbiomed.2005.11.002.
- [60] **Guo, G. Wang, H. Bell, D. Bi, Y. and Greer, K.** “KNN model-based approach in classification,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 2888, no. June 2015, pp. 986–996, 2003, doi: 10.1007/978-3-540-39964-3_62.
- [61] **Adak, M. F. and Yurtay, N.** (2013), “Gini Algoritmasını Kullanarak Karar Ağacı Oluşturmayı Sağlayan Bir Yazılımın Geliştirilmesi,” *Bilişim Teknolojileri Dergisi*, 6(3), pp. 1–6.
- [62] **Tharwat, A., Gaber, T., Ibrahim, A., and Hassanien, A. E.** “Linear discriminant analysis: A detailed tutorial,” *AI communications*, vol. 30, no. 2, pp. 169–190, 2017.
- [63] C. M. Dayton, “Logistic Regression Analysis,” *Dictionary of Statistics & Methodology*, no. January 1992, 1992.
- [64] **Rish, I.** “An empirical study of the naive Bayes classifier,” *cc.gatech.edu*, 2001, Accessed: Aug. 28, 2021. [Online]. Available: <https://www.cc.gatech.edu/~isbell/reading/papers/Rish.pdf>.
- [65] **Şeker, Ş. E.** “K-Ortalama Algoritması (K-Means Algorithm) – Bilgisayar Kavramları.” <https://bilgisayarkavramlari.com/2008/12/15/k-ortalama-algoritmasi-k-means-algorithm/> (accessed Nov. 27, 2022).
- [66] **Sarıkaya, B.** (2018), “Sürücü benzetim sistemi ile sürücülerden elde edilen EEG sinyallerinden acil fren durumunun Yapay Sinir Ağları ile tahmin edilmesi,” Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya.
- [67] **Simonyan, K. and Zisserman, A.** (2015), “Very deep convolutional networks for large-scale image recognition,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–14.

- [68] **Begleiter, H.** (1999) “UCI Machine Learning Repository: EEG Database Data Set,”
[https://archive.ics.uci.edu/ml/datasets/EEG Database](https://archive.ics.uci.edu/ml/datasets/EEG+Database) (accessed Nov. 27, 2022).



ÖZGEÇMİŞ

Ad-Soyad

: Mücahit KARADUMAN

ÖĞRENİM DURUMU:

- **Lisans** : 2006, Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölüm
- **Yüksek Lisans** : 2016, Fırat Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Yazılım Bilim Dalı
- **Doktora** : 2023, İnönü Üniversite, Bilgisayar Mühendisliği A.B.D, Bilgisayar Bilimleri Bilim Dalı

MESLEKİ DENEYİM:

- 2018-Devam Ediyor: Malatya Turgut Özal Üniversitesi Arapgir Meslek Yüksek Okulu Bilgisayar Programcılığı Programı Öğretim görevlisi olarak çalışıyor.
- 2013-2018: İnönü Üniversitesi Arapgir Meslek Yüksek Okulu Bilgisayar Programcılığı Programı Öğretim görevlisi olarak Çalıştı.

DOKTORA TEZİNDEN TÜRETİLEN ÇALIŞMALAR

- **Karaduman, M. and Karci, A.**, “Controlling Vehicles Using EEG Signal And Eye-Arm Collaboration”, In *ISERD 180th International Conference. Macca* (pp. 19-24), 2020.
- **Karaduman, M. and Karci, A.**, “Determining the Demands of Disabled People by Artificial Intelligence Methods”, *Computer Science, 5th International Artificial Intelligence and Data Processing symposium* , 226-241 . DOI: 10.53070/bbd.990485, 2021.
- **Karaduman, M. and Karci, A.**, “Deep and Statistical Features Classification Model for Electroencephalography Signals”, *Traitement du Signal*, 1517-1525 <https://doi.org/10.18280/ts.390508>, 2022.