

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

EEG SİNYALLERİNİN SINIFLANDIRMA PERFORMANSINI YENİ BİR
RASTGELE ALT KÜME KANAL SEÇİM YAKLAŞIMIYLA GELİŞTİRME:
TAT, KOKU VE MOTOR HAYALİNE DAYALI VERİ KÜMELERİNDE
UYGULAMALAR

DOKTORA TEZİ

Amir NASER

EKİM 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**EEG SİNYALLERİNİN SINIFLANDIRMA PERFORMANSINI YENİ BİR
RASTGELE ALT KÜME KANAL SEÇİM YAKLAŞIMIYLA GELİŞTİRME:
TAT, KOKU VE MOTOR HAYALİNE DAYALI VERİ KÜMELERİNDE
UYGULAMALAR**

Amir NASER

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 20/ 09 / 2024

Tezin Savunma Tarihi : 21 / 10 / 2024

Tez Danışmanı : Prof. Dr. Önder AYDEMİR

Trabzon 2024

ÖNSÖZ

"EEG Sinyal Sınıflandırmasını Yeni Bir Rastgele Alt Küme Kanal Seçim Yaklaşımıyla Geliştirme: Tat, Koku ve Motor Hayali Analizlerinde Uygulamalar" başlıklı bu tez, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı kapsamında hazırlanmıştır. Tez kapsamında gerçekleştirilen tüm deneysel çalışmalar ve süreçler, 118EE241 numaralı TÜBİTAK 1002 projesi kapsamında, Prof. Dr. Önder AYDEMİR'in yürütücülüğünde ve danışmanlığında gerçekleştirilmiştir.

Tez çalışmam süresince, değerli bilgileri, tecrübeleri, hiçbir zaman esirgemediği desteği, laboratuvar çalışmaların gerçekleştirilmesi süreçlerindeki yakın takibi ile bana rehberlik eden, yapıcı eleştirileri ve önerileriyle tezime önemli katkılarda bulunan kıymetli danışman hocam Sayın Prof. Dr. Önder Aydemir'e en içten teşekkürlerimi sunarım. Ayrıca, tez izleme süresince yapmış oldukları yapıcı eleştiri ve önerileri için sayın Prof. Dr. Ali GANGAL, Dr. Öğr. Üyeleri Murat AYKUT ve Mehmet ÖZTÜRK hocalarıma müteşekkirim. Eğitim hayatımda katkısı ve emeği olan tüm hocalarıma ve çalışma arkadaşlarıma teşekkür ederim.

Tez sürecimde bana büyük destek sağlayan ve her aşamada yardımlarını esirgemeyen değerli arkadaşım Dr. Öğr. Üyesi Ercüment ÖZTÜRK'e en içten teşekkürlerimi sunarım. Son olarak doğduğum günden beri elimi hiç bırakmayan ve bugünlere gelmemde en büyük paya sahip olan anne ve babama, hayatıma girdiği günden bu yana beni tamamlayan, sevgisini her daim yüreğimde hissettiğim ve zor zamanlarımda en büyük destekçim olan kıymetli eşime, akademik çalışmalarım nedeniyle bazen ihmal ettiğim ancak sevgisini daima yüreğimde hissettiğim kızıma teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Amir NASER

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “EEG Sinyal Sınıflandırmasını Yeni Bir Rastgele Alt Küme Kanal Seçim Yaklaşımıyla Geliştirme: Tat, Koku Ve Motor Hayali Analizlerinde Uygulamalar” başlıklı bu çalışmayı baştan sona kadar doktora tez danışmanım Prof. Dr. Önder AYDEMİR’in kontrolünde tamamladığımı, verileri / örnekleri kendim topladığımı, deneyleri / analizleri ilgili laboratuvarlarda yaptığımı / yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 21/10/2024

Amir NASER

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Beyin Temel Yapısı.....	3
1.1.1. Beynin Bölümleri ve Görevleri.....	3
1.1.2. Sinir Hücrelerinin (Nöronların) Genel Yapısı	5
1.1.3. Beynin Nöral çalışmasını Görüntüleme Yöntemleri.....	6
1.2. Elektroensefalografi ve Özellikleri	9
1.2.1. EEG İşaretlerinin Ölçüm Yöntemi.....	11
1.2.2. İşaretlerini Etkileyen Gürültüler	13
1.3. Tat Alma Duyusunun Tanımı ve Önemi	16
1.4. Beynin Koku Anatomisi.....	17
1.4.1. Kokuyu Yakalamak.....	17
1.4.2. Beyindeki Koku Merkezleri.....	18
1.4.3. Koku Algılanması ve İşlenmesi	18
1.5. Beynin Tat Anatomisi	19
1.5.1. Tat Alan ve Koklayan Beyin.....	19
1.6. Beyin Bilgisayar Arayüzü	20
1.6.1. BBA Teknolojisi Uygulamaları	21
1.6.2. Motor Hayaline Dayalı BBA	21
1.7. Beynin Koku, Tat ve Motor Hayaline Dayalı Etkileşimlerine Verdiği Cevapların Sınıflandırılmasına Ait Temel Bileşenler	22
1.7.1. Sinyalin Alınması.....	22
1.7.2. Ön işleme	23
1.7.3. Öznitelik Çıkarma	23
1.7.4. Sınıflandırma.....	24
1.8. Literatür Araştırması	24

2. YAPILAN ÇALIŞMALAR.....	32
2.1. Tat Veri Kümesi	32
2.2. Deney Ortamı ve Diğer Bileşenleri	32
2.2.1. EEG İşaretlerin Kaydı İçin Hazırlanan Bilgisayar Destekli Arayüz.....	33
2.2.2. EEG Verilerinin Kaydedilmesi ve Veri Seti Tanıtımı	35
2.3. Koku Veri Kümesi.....	40
2.4. Hayale Dayalı Veri Kümesi	41
2.5. Yöntem	41
2.5.1. Önerilen RAKS Yöntemi	41
2.5.2. Sıralı İleri Kanal Seçme Yöntemi	44
2.5.3. Geriye Dönük Kanal Seçme Yöntemi.....	45
2.6. Öznitelik Çıkarma Yöntemleri	45
2.6.1. Hilbert Dönüşümü Öznitelikleri.....	45
2.6.2. Hızlı Walsh Hadamard Dönüşümü	47
2.6.3. Bant Gücü Öznitelikleri	47
2.6.4. Spektrogram Öznitelikleri.....	48
2.6.5. Dalgacık Paket Ayırıştırma	51
2.7. Sınıflandırma	52
2.7.1. Destek Vektör Makineleri.....	53
2.7.2. K- En Yakın Komşuluk.....	55
2.7.3. Doğrusal Ayırım Analizi.....	57
2.7.4. Rastgele Ormanlar Metodu	58
3. BULGULAR.....	61
3.1. Burun Kapalı ve Açık Durumunda Tada Dayalı Veriler.....	62
3.1.1. Burun Kapalı Durumunda Tada Dayalı Veri Setinin HD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	62
3.1.2. Burun Açık Durumunda Tada Dayalı Veri Setinin HD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	64
3.1.3. Burun Kapalı Durumunda Tada Dayalı Veri Setinin BG Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	67
3.1.4. Burun Açık Durumunda Tada Dayalı Veri Setinin BG Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	68
3.1.5. Burun Kapalı Durumunda Tada Dayalı Veri Setinin HWHD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	69
3.1.6. Burun Açık Durumunda Tada Dayalı Veri Setinin, HWHD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	70

3.1.7.	Burun Kapalı Durumunda Tada Dayalı Veri Setinin PO Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	71
3.1.8.	Burun Açık Durumunda Tada Dayalı Veri Setinin PO Tabanlı Öznitelikler ile Sınıflandırma Sonuçları	72
3.1.9.	Burun kapalı Durumunda Tada Dayalı Veri Setinin, Önerilen Yöntem (RAKS) ile Sınıflandırma Sonuçları	73
3.1.10.	Burun Açık Durumunda Tada Dayalı Veri Setinin, Önerilen Yöntem (RAKS) ile Sınıflandırma Sonuçları	75
3.1.11.	Burun Kapalı Durumunda Tada Dayalı Veri Setinin, Geriye Dönük (GDE) Yöntem ile Sınıflandırma Sonuçları.....	77
3.1.12.	Burun Açık Durumunda Tada Dayalı Veri Setinin, GDE Yöntem ile Sınıflandırma Sonuçları	78
3.1.13.	Burun Kapalı Durumunda Tada Dayalı Veri Setinin, Sıralı İleri (Sİ) Kanal Seçme Yöntemi ile Sınıflandırma Sonuçları	79
3.1.14.	Burun Açık Durumunda Tada Dayalı Veri Setinin, Sıralı İleri (Sİ) Kanal Seçme Yöntemi ile Sınıflandırma Sonuçları	80
3.1.15.	Önerilen Yöntem ve Literatürde Bulunan GDE ve Sİ Kanal Seçme Yöntemlerinin Performans Karşılaştırılması	81
3.2.	Kokuya dayalı Veri Setinin Sınıflandırma Sonuçları.....	83
3.3.	Hayale Dayalı Veri Setinin Sınıflandırma Sonuçları	84
4.	TARTIŞMA	87
5.	SONUÇLAR.....	92
6.	ÖNERİLER.....	94
7.	KAYNAKLAR	96
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

EEG SİNYALLERİNİN SINIFLANDIRMA PERFORMANSINI YENİ BİR RASTGELE ALT KÜME KANAL SEÇİM YAKLAŞIMIYLA GELİŞTİRME: TAT, KOKU VE MOTOR HAYALİNE DAYALI VERİ KÜMELERİNDE UYGULAMALAR

Amir NASER

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Önder AYDEMİR
2024, 106 Sayfa

Beyin-bilgisayar arayüzü (BBA) sistemlerinin performansını artırmak ve nörolojik hastalıkların erken teşhisini mümkün kılmak, günümüz nörobilim ve sinir mühendisliği alanlarında kritik bir araştırma konusu haline gelmiştir. Bu çalışmada, EEG sinyalleri için öznitelik çıkarma ve sınıflandırma yöntemlerinin performansı çeşitli veri kümeleri kullanılarak değerlendirilmiştir. Üç farklı veri kümesi üzerinde inceleme yapılmıştır: 10 denekle tat temelli, 5 denekle koku temelli ve 29 denekle motor hayali EEG verileri. Tat verileri için Hilbert Dönüşümü (HD), koku verileri için Dalgacık Paket Ayrıştırması (DPA) ve motor hayali verileri için HD yöntemleri uygulanmıştır. Önerilen Rastgele Alt Küme Kanal Seçimi (RAKS) yöntemi, sıralı arama yöntemleriyle karşılaştırılmış ve en etkili kanallar belirlenmiştir. RAKS yöntemi, tat veri setinde %82 doğruluk sağlarken %37,9 oranında işlem karmaşıklığını azaltmıştır. Koku veri setinde %98,38 doğruluk ve %89.09 işlem karmaşıklığı azalması elde edilmiştir. Motor hayali veri setinde ise %81,56 doğrulukla sıralı yöntemlerden daha üstün performans sergileyip işlem karmaşıklığını %75 oranında azaltmıştır. Sonuç olarak, önerilen RAKS yöntemi, geleneksel sıralı yöntemlere kıyasla hem sınıflandırma doğruluğunu artırmakta hem de işlem karmaşıklığını azaltmaktadır. Bu yöntem, EEG sinyalleri başta olmak üzere BBA sistemlerinin performansını iyileştirme potansiyeline sahip olup, nörolojik hastalıkların tespiti ve erken teşhisinde önemli katkılar sunmaktadır.

Anahtar Kelimeler: EEG, BBA, Sınıflandırma, Öznitelik çıkarma, Kanal seçimi

PhD. Thesis

SUMMARY

IMPROVING THE CLASSIFICATION PERFORMANCE OF EEG SIGNALS WITH A NOVEL RANDOM SUBSET CHANNEL SELECTION APPROACH: APPLICATIONS ON TASTE, OLFACTORY, AND MOTOR IMAGERY DATASETS

Amir NASER

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Önder AYDEMİR
2024, 106 Pages

Improving the performance of Brain-Computer Interface (BCI) systems and enabling the early diagnosis of neurological diseases have become critical research topics in contemporary neuroscience and neural engineering. This study uses various datasets to evaluate the performance of feature extraction and classification methods for EEG signals. Three different datasets were examined: taste-based EEG signals from 10 subjects, odor-based EEG signals from 5 subjects, and motor imagery EEG data from 29 subjects. Hilbert Transform (HT) was applied for taste data, Wavelet Packet Decomposition (WPD) for odor data, and HT for motor imagery data. The proposed Random Subset Channel Selection (RSCS) method was compared with sequential search methods, and the most effective channels were identified. The RSCS method achieved 82% accuracy for the taste dataset while reducing computational complexity by 37.9%. For the odor dataset, 98.38% accuracy was achieved, with an 89.09% reduction in computational complexity. RSCS achieved 81.56% accuracy for the motor imagery dataset, outperforming sequential methods and reducing computational complexity by 75%. In conclusion, the proposed RSCS method enhances classification accuracy while reducing computational complexity compared to traditional sequential methods. This method holds the potential for improving the performance of BCI systems, particularly for EEG signals, and offers significant contributions to the detection and early diagnosis of neurological disorders.

Key Words: EEG, BCI, Classification, Feature Extraction, Channel Selection

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Beynin bölümleri.....	4
Şekil 2. Nöronun yapısı	6
Şekil 3. İlk EEG işareti	9
Şekil 4. Aksiyon potansiyeli evreleri.....	10
Şekil 5. Standart 10–20 sistemine (A), 10–10 sistemine (B) ve 10–5 sistemine (C) ait EEG elektrot montajı	12
Şekil 6. (A): Frekans bölgesinde gösterilen nöral dalgalar. (B): Zaman bölgesinde gösterilen nöral dalgalar	12
Şekil 7. Gözün kırılması ile ortaya çıkan gürültülü EEG	15
Şekil 8. Dişin sıkılmasıyla ortaya çıkan gürültülü EEG	15
Şekil 9. Beyindeki koku merkezleri	18
Şekil 10. Koku Algılanması ve İşlenmesinde iş birliği yapan bölgeler	19
Şekil 11. Tat Algılanması ve İşlenmesinde iş birliği yapan bölgeler	20
Şekil 12. Beynin koku ve tat etkileşimine verdiği cevapların sınıflandırılmasına ait temel bileşenler.....	22
Şekil 13. EEG sistemi, (a) Sistemin genel görünüşü, (b) Yükselteç, (c) İzolasyon katı, (d) Elektrot jeli, (e) Enjektör, (f) Elektrot şapkası.....	32
Şekil 14. Elektrotların saç derisine yerleşim düzeni.....	33
Şekil 15. Tat için hazırlanan bilgisayar destekli arayüz evreleri a) geri sayımın başlaması, b) geri sayımın sonlanma aşaması, c) tatma komutunun ekranda belirmesi, d) rahatlama aşamasına geçiş	34
Şekil 16. EEG verilerinin tat alma işlemi sırasında kaydedilme düzeni: 1) LCD ekran, 2) Tatma sırasında kullanılan spre, 3) EEG şapkası, 4) EEG cihazı, 5) EEG kayıt cihazı ve ekranı	35
Şekil 17. Kullanılan gıda maddeleri	37
Şekil 18. Püskürtme şişeleri.....	38
Şekil 19. Burun mandalı	38
Şekil 20. Tat dayalı EEG kayıt prosedürü	39
Şekil 21. Deney öncesi sonrası ve esnasında çekilen fotoğraflar	39
Şekil 22. EEG veri kümesinden rasgele seçilmiş EEG	40
Şekil 23. Kokuya dayalı EEG kayıt prosedürü.....	40
Şekil 24. Kokuya dayalı EEG kayıt prosedürü.....	41
Şekil 25. Farklı tatlara ait spektrogram görüntüsü	50
Şekil 26. Farklı tatlara ait gri seviyeli görüntüsü.....	51

Şekil 27. İki seviyeli DPA ağaç yapısı	52
Şekil 28. DVM ile iki etiketli sınıflandırma örneğini göstermektedir.....	55
Şekil 29. <i>k</i> -EYK yöntemi için veri sınıflandırması	57
Şekil 30. Rasgele Orman Algoritması genel yapısı.....	60
Şekil 31. Burun kapalı durumunda D3'te S1-S2 ikilisi için 1 Hz. hassasiyetle bant geçiren filtrenin tüm aralıkları üzerinden elde edilen SD sonuçları göstermektedir.	67
Şekil 32. Tat verisinde burun kapalı durumunda yöntemlerin SD karşılaştırılması.....	82
Şekil 33. Tat verisinde burun açık durumunda yöntemlerin SD karşılaştırılması.....	82
Şekil 34. Burun açık durumunda önerilen yöntem ve tüm kanallar ile SD sonuçları	83
Şekil 35. Burun açık durumunda önerilen yöntem ve tüm kanallar ile SD sonuçları	84
Şekil 36. Hayale dayalı Veri Setinin önerilen yöntem ile SD sonuçları.....	85
Şekil 37. 29 denek için üç farklı yöntemin sınıflandırma sonuçları.....	86
Şekil 38. Önerilen yöntem ile seçilen kanalların ısı haritası	88
Şekil 39. Kanalların beyin üzerinde konumları	89

TABLolar DİZİNİ

Sayfa No

Tablo 1. Tat deneylerinde gönüllü bireyler ile yapılan anket sonuçları (burun açık)	36
Tablo 2. Tat deneylerinde gönüllü bireyler ile yapılan anket sonuçları (burun kapalı)	36
Tablo 3. Tat deneylerinde HD öznitelikleri kullanarak SD sonuçları (burun kapalı)	62
Tablo 4. Tat deneylerinde HD öznitelikleri kullanarak SD sonuçları (burun açık)	65
Tablo 5. Tat verilerinde BG öznitelikleri ile Sınıflandırmasının sonuçları (burun kapalı)	68
Tablo 6. Tat verilerinde BG öznitelikleri ile SD sonuçları (burun açık)	69
Tablo 7. Tat verilerinde HWHD öznitelikleri ile SD sonuçları (burun kapalı)	70
Tablo 8. Tat verilerin HWHD öznitelikleri ile SD Sonuçları (burun açık)	71
Tablo 9. Tat verilerinde PO öznitelikleri ile SD Sonuçları (burun kapalı)	72
Tablo 10. Tat verilerinde PO öznitelikleri ile SD Sonuçları (burun açık)	73
Tablo 11. Tat verisinde önerilen RAKS yöntemi ile SD sonuçları (burun kapalı)	74
Tablo 12. Tat verisinde önerilen RAKS yöntemi ile SD sonuçları (burun açık)	76
Tablo 13. Tat verisinde önerilen GDE yöntemi ile SD sonuçları (burun kapalı)	78
Tablo 14. Tat verisinde GDE yöntemi ile sınıflandırma sonuçları (burun açık)	79
Tablo 15. Tat verisinde Sİ yöntemi ile SD sonuçları (burun kapalı)	80
Tablo 16. Tat verisinde Sİ yöntemi ile sınıflandırma sonuçları (burun açık)	81
Tablo 17. Tat koku ve hayal için elde edilen sonuçları	92

SEMBOLLER VE KISALTMALAR DİZİNİ

RAKS	: Rastgele Alt Küme Kanal Seçimi
SD	: Sınıflandırma Doğruluğu
HD	: Hilbert Dönüşümü
DPA	: Dalgacık Paket Ayırıştırması
EEG	: Elektroensefalografi
TDA	: Tekil Değer Ayırışımı
BBA	: Beyin-Bilgisayar Arayüzü
k-EYK	: <i>k</i> -En Yakın Komşu
ÖM	: Öklid Mesafesi
RO	: Rastgele Ormanlar
DVM	: Destek Vektör Makineleri
PO	: Piksel Ortalaması
GDE	: Geriye Dönük Eleme
ICA	: Bağımsız Bileşen Analizi
Sİ	: Sıralı İleri
BG	: Bant Gücü
BP	: Bant Geçirici (Band Pass)
HFD	: Hızlı Fourier Dönüşümü
SNR	: Signal-to-Noise Ratio (Sinyal-Gürültü Oranı)
EKG	: Elektrokardiyogram
DAA	: Discriminant Analysis Algorithm
PLV	: Phase-Locking Value (Faz Kilitlenme Değeri)
HWH	: Hızlı Walsh-Hadamard
PSD	: Güç Spektral Yoğunluğu
ApEn	: Approximate Entropy (Yaklaşık Entropi)
LLE	: Largest Lyapunov Exponent (En Büyük Lyapunov Üssü)
LZC	: Lempel-Ziv Complexity (Lempel-Ziv Karmaşıklığı)
CWT	: Sürekli Dalgacık Dönüşümü
RBF	: Radial Basis Function Support
LDA	: Linear Discriminant Analysis

HFD: : Higuchi Fraktal Boyutu



1. GENEL BİLGİLER

Son yıllarda, tıp alanındaki donanım teknolojilerinin hızla gelişmesiyle birlikte, insanlardan elde edilen biyolojik sinyallerin ve görüntülerin çözünürlüğü önemli ölçüde artmıştır. Bu gelişmeler, tanısal ve tedavi edici uygulamalarda daha ayrıntılı ve doğru bilgiler sağlayarak, sağlık hizmetlerinin kalitesini ve etkinliğini artırmaktadır. Özellikle beyin görüntüleme teknolojilerindeki ilerlemeler, nöronal aktivitelerin daha detaylı bir şekilde incelenmesine olanak tanımaktadır (Yen vd., 2023). Beyinle ilgili yapılan araştırmalarda epilepsi (Maimaiti vd., 2022), Alzheimer (Modir vd., 2023), Parkinson (Li vd., 2023) ve uykusuzluk (Sharma vd. 2023) (Kumar vd. 2024) gibi nörolojik hastalıkların erken ve kolay teşhisiyle birlikte, özellikle felçli hastaların yaşamlarını kolaylaştırmaya yönelik beyin-bilgisayar arayüzü sistemlerinin performansının artırılması (Dong vd. 2023) (Blankertz vd., 2002) gibi konular sıklıkla işlenmektedir. Üzerine yapılan çalışmalar her geçen gün artsa da dünyadaki belki de en karmaşık sistem olan insan beyni merak konusu olmayı sürdürmektedir.

Milyarlarca sinir hücresi ve çok daha fazlası destek hücresiyle birlikte insan beyninin görevlerinden biri de duyu organlarından gelen uyarıları alıp değerlendirmesidir (Borisoff vd., 2004). Duyu organlarından gelen uyarılara beynin verdiği tepkiler, sinir sisteminin karmaşık yapısı ve işleyişi hakkında önemli bilgiler sunmaktadır. Bu tepkilerin analizi, bilişsel süreçleri ve algı mekanizmalarını anlamada kritik bir rol oynamaktadır. Beynin bu tepkilerini incelemek için birçok farklı biyomedikal ölçme ve görüntüleme teknikleri kullanılmaktadır. Bunlar arasında fonksiyonel manyetik rezonans (fMRI) görüntüleme, yerel alan potansiyelleri (YAP), yakın kızılötesi spektroskopisi (YKS), elektrokortikografi (ECOG), magnetoensefalografi (MEG) ve elektroensefalografi (EEG) gibi çeşitli biyomedikal ölçme ve görüntüleme teknikleri kullanılmaktadır.

EEG, beynin elektriksel aktivitesini kaydeden bir teknik olup, genellikle kafaya yerleştirilen elektrotlar aracılığıyla beyin dalgalarının ölçülmesini sağlar. EEG, zaman çözünürlüğünün yüksek olması, invazif olmaması ve nispeten düşük maliyeti gibi avantajları nedeniyle beyin araştırmalarında ve klinik uygulamalarda yaygın olarak tercih edilmektedir. Bu teknik, beyin fonksiyonlarını anlık olarak izleyebilme yeteneği sayesinde, duyu uyarılara verilen tepkilerin milisaniyelik hassasiyetle incelenmesine olanak tanır (Simmatitis vd., 2023) (Ahire vd., 2023).

Genel olarak insan beyninin hangi bölgesinin hangi duylara cevap verdiđi netleřtirilmiř olsa da farklı tatlara verdiđi cevaplar ve cevaplar arasındaki farklılıklar yeteri kadar incelenmemiřtir. Özellikle, deneysel uygulamaların yetersizliđi, elde edilen bulguların farklılık göstermesi ve farklı tatlar ile yapılan alıřmaların azlıđı, beynin farklı tatlara verdiđi tepkinin nasıl olduđu konusunda kesin bir yargıya varılmasını zorlařtırmaktadır. Literatür bilgisi incelendiđinde bu tür alıřmaların aynı tür tatlar üzerinde yapıldıđı gözlemlenmiř fakat bu tatlar basit ve beynin rahatlıkla ayırt edebileceđi tatlardır. Ancak birbirine daha yakın, benzer ve ayırt edilebilirlikleri zor olan tatlar ile ilgili bir alıřma bulunamamıřtır. Bu nedenle, birbirine yakın ve ayırt edilebilirliđi zor olan tatlar ile alıřılmıř ve bařarılı sonuçlar elde edilmiřtir. Bu alıřma ile beyin/sinir hücresi kaynaklı hastalıkların erken teřhisinde önemli rol oynayacađı düşünölmektedir. Nitekim bu alıřmada tat verileri, 118E241 numaralı bařarıyla tamamlanan TÜBİTAK 1001 projesinin etik kurul onayı alındıktan sonra nörolojik rahatsızlıđı bulunmayan 10 sađlıklı denekten toplanmıřtır. Bu alıřmada, dört farklı gıda maddesinin (Portakal, Nane, Kekik ve Karanfil maddelerinin yađları) tadıldıđında insan beyninin verdiđi tepki (EEG sinyalleri) incelenmiřtir.

Tat veri kümesi, burun açık ve kapalı durumlarda beřer kiřiden alınmıřtır. Bu alıřmada, her bir farklı tada ait 40'ar kayıt alınmıřtır. Tat deneyinde, her kiři ile 4 seans gerekleřtirilmiř olup her seansta 40, toplamda 160 tat katılımcıya tattırılmıřtır. Burun açık ve kapalı durumlarında test veri kümesinde sırasıyla beřer kiři için ortalama %82.5 ve %81.88 Sınıflandırma Doğruluđu (SD) elde edilmiřtir. Bu alıřmada, tüm kanalları kullanmak yerine en etkili kanalları tespit ederek konuya özgü bir yöntem önerilmiřtir. Bu yöntem sayesinde, sadece etkili kanallarla sınıflandırma doğruluđunu artırmakla kalmayıp, aynı zamanda hesaplama karmařıklıđı büyük ölçüde düşürölmüřtür. Önerilen yöntemin sađlamlıđını ve etkinliđini doğrulamak için tat veri kümesi dahil 3 tür EEG tabanlı veri kümesi kullanılmıřtır. Bunlardan ikinci veri kümesi koku duyusuna dayalı, üçüncü veri kümesi el açma ve kapama hayaline dayalı EEG tabanlı veri kümeleridir. Önerilen yöntem ile koku veri kümesinde, burun açık durumunda beř kiři için ortalama %99.28 sınıflandırma doğruluđu (SD) elde edilirken, burun kapalı durumda beř kiři için test veri kümesinde ortalama %97.49 sınıflandırma doğruluđu (SD) elde edilmiřtir. Üçüncü veri kümesinde, 29 denek için test veri kümesinde ortalama %81.56 sınıflandırma doğruluđu (SD) elde edilmiřtir. Buna ek olarak hesaplama karmařıklıđı birinci, ikinci ve üçüncü veri kümeleri için sırasıyla ortalama %63.03, %89.09 ve %75 oranında azaltılmıřtır.

Elde edilen bu başarılı sonuçlar sadece veri toplama ve analizi ile değil geliştirilen yeni yöntemle doğrudan alakalıdır. Önerilen yöntem, zaman içerisinde tekrarlar yaparak rastgele seçilen kanalların SD'nu hesaplamaktadır. Bu aşamadan sonra kanalların sınıflandırma doğruluğuna göre uygunluk değerleri hesaplanır. Ardından en yüksek uygunluk değerlerine sahip olan kanallar seçilir. Son olarak iterasyonlar sırasında güncellemelere dayalı tekrarlar yapılarak en iyi alt küme kanalları bulunmuştur. Bu çalışma ile eğitim verisi üzerindeki en iyi kanallar bulunmaya çalışılmış ve ardından test verisi üzerinde test edilmiştir. Test sonuçları yöntemin başarılı olduğunu göstermiştir.


1.1. Beyin Temel Yapısı

Vücudumuzdaki merkezi sinir sisteminin kritik merkezi işlevi yapan beyin nerdeyse tüm vücut sistemlerini karmaşık sinir ağları aracılığıyla kontrol etmektedir. İnsan beyni bilinç, öğrenme, hafıza, duygusal tepkiler, hareket koordinasyonu ve temel yaşamsal fonksiyonlar gibi birçok işlevi düzenlemektedir. Bu işlevlerin yapılması için beyin özelleşmiş yapıların etkileşimi ile çalışılmaktadır. Beyin kafatası, beyin-omurilik sıvısı ve kan-beyin bariyeri gibi çeşitli yapılarla korunmaktadır. Kan-beyin bariyeri, zararlı maddelerin beyne girmesini engelleyerek beynin biyokimyasal dengesini korumaktadır. Bu yapı, beyne gerekli besin maddelerinin geçişini sağlarken aynı zamanda toksinlerin ve patojenlerin beyne girişini engellemektedir. Beyin ayrıca bilişsel işlevler için gerekli olan sinyallerin işlenmesi ve aktarılması süreçlerinde nöronlar arasında karmaşık bir iletişim ağı oluşturmaktadır (Sultana vd., 2024) (Genon vd., 2018).

1.1.1. Beynin Bölümleri ve Görevleri

Beyin anatomik olarak farklı katmanlardan oluşmaktadır (Donnelly, 2011). En dış katman olan beyin korteksi (cerebral cortex), düşünme, algı ve istemli hareket gibi yüksek düzeydeki beyin fonksiyonlarından sorumludur (Armstrong, 2021). Korteksin altında bulunan subkortikal yapılar, duyuşal işleme ve hareket düzenlenmesi için kritik olan talamus ve bazal ganglionları içerir (DeSesso, 2009). Daha derinde yer alan limbik sistem ise duyguların ve hafızanın yönetiminden sorumludur (Armstrong, 2021). Beyin sapı, kalp atışı ve solunum gibi hayati işlevleri kontrol etmektedir. Beyni saran meninksler, beyni koruyan üç katmanlı bir zar (dura mater, araknoid mater ve pia mater) olarak bulunur (DeSesso,

2009). Beynin yüzeyi dört loba ayrılmıştır ve her biri farklı işlevlere ve duyuşal işlem görevlerine sahiptir. Beynin bölümleri şekil 1’de gösterilmiştir.



Şekil 1. Beynin bölümleri

Frontal Lob: Beynin ön kısmında yer alır ve karar verme, problem çözme ve planlama gibi bilişsel işlevler için hayati öneme sahiptir. Ayrıca istemli kas hareketlerini kontrol eden motor korteksini barındırır. Frontal lob, doğrudan herhangi bir duyuşal organla ilişkilendirilmese de bu yüksek bilişsel görevlerle ilgili duyuşal bilgilerin işlenmesinde rol oynar (Otero & Barker, 2013).

Parietal Lob: Frontal lobun arkasında yer alır ve deri üzerindeki dokunma, basınç ve ağrı gibi duyuşal bilgileri somatosensory korteksi aracılığıyla işler. Ayrıca duyuşal girdileri birleştirerek mekânsal yönelim ve vücut navigasyonuna yardımcı olur (Souza-Couto, Bretas, & Aversi-Ferreira, 2023).


Oksipital Lob: Beynin arka kısmında yer alır ve görsel işlemle sorumludur. Oksipital lobdaki birincil görsel korteks, gözlerden gelen sinyalleri yorumlayarak görme merkezini oluşturur (Uysal, 2023).

Temporal Lob: Frontal ve parietal lobların altında bulunur, işitsel bilgileri kulaklardan işler. Ayrıca hafıza oluşumu, dil anlama ve duyuşal tepkilerde rol oynar (Husain & Schott, 2016).

1.1.2. Sinir Hücrelerinin (Nöronların) Genel Yapısı

İnsanlarda sinir sistemi, iç ve dış çevreden gelen uyarıların algılayarak organizmanın çevresine uyum sağlamasına yardımcı olur. Canlının çevresinde bulunan ışık, sıcaklık, basınç ve kimyasal maddeler gibi uyarıcılar, duyu organlarındaki özelleşmiş hücreler tarafından algılanır. Bu hücrelere reseptör (algılayıcı hücreler) adı verilir ve bu hücreler, gelen uyarılara yanıt olarak sinir sistemi içinde bir sinyal başlatır. Oluşan bu sinyaller, sinir hücreleri aracılığıyla merkezi sinir sistemine, yani beyin ve omuriliğe iletilir. Burada sinyaller işlenir ve organizmanın uygun bir tepki vermesi sağlanır. Sinir hücreleri, diğer adıyla nöronlar, bu uyarıların alır, değerlendirir ve sonuçta oluşan yanıtları kaslara ve bezlere iletir. Nöronlar, merkezi sinir sistemi ve periferik sinir sisteminde yer alır ve sinir ağları oluşturarak vücut içindeki iletişimi sağlar. Sinir hücresinin zarına nörolemma, sitoplazmasına ise nöroplazma denir. Bir sinir hücresi Şekil 2’de görüldüğü gibi hücre çekirdeği, geniş bir hücre gövdesi ve bu gövdeden çıkan dentrit ve akson uzantılarından oluşur.

Hücre gövdesi, mitokondri, ribozom, endoplazmik retikulum gibi organellerin yanı sıra hücre çekirdeğinin bulunduğu bölgedir. Bu çekirdek, belirgin ve iyi gelişmiş bir çekirdekçik içerir. Dentritler ise hücre gövdesinden çıkan çok sayıda kısa uzantılardır. Bunlar, duyu hücrelerinden veya diğer nöronlardan gelen uyarıların alır ve bu uyarıların hücre gövdesine iletir. Hücre gövdesinden gelen sinyali taşıyan uzun ve ince tek bir uzantı ise akson olarak adlandırılır. Aksonun sonlandığı ve dallanarak genişlediği bölgeye akson ucu denir. Bu akson uçlarından, bir nörondan diğerine ya da tepki organına sinyallerin iletimini sağlayan nörotransmitter olarak bilinen kimyasal maddeler salgılanır. Nörotransmitterler, uyarıların diğer sinir hücresine veya tepki organına (efektör) ileterek sinirsel iletişimi gerçekleştirir (Lovinger, 2008).



Şekil 2. Nöronun yapısı

Sinir hücreleri, işlevlerine göre üç ana kategoriye ayrılır: duyu nöronları, motor nöronları ve ara nöronlar. Duyu nöronları, duyu organlarından gelen uyarıları alarak merkezi sinir sistemine ileten nöronlardır. Motor nöronlar, merkezi sinir sisteminden gelen uyarıları kaslara ve bezlere taşıyan hücrelerdir. Ara nöronlar ise duyu nöronları ile motor nöronları arasındaki bağlantıyı sağlayarak sinir sistemi içinde bilgi akışını düzenler (Uchida vd., 2000). Beyindeki nöronal fonksiyon birimleri olan çekirdekler belirli görevler sırasında aktif hale geldiğinde, nöronlar arasında durağan olmayan elektriksel sinyaller iletilir. Bu elektriksel sinyaller, nöronların toplu olarak oluşturduğu elektriksel aktivitenin bir sonucudur ve kafatasının üzerine yerleştirilen elektrotlar aracılığıyla ölçülebilir (Nunez & Srinivasan, 2006).

1.1.3. Beynin Nöral Çalışmasını Görüntüleme Yöntemleri

Beynin nöral aktivitesini görüntüleme, beyin faaliyetlerinin dinamik olarak izlenmesini sağlayan tekniklerin genel adıdır. Bu teknikler, beyindeki sinir hücrelerinin (nöronlar) aktivitesini doğrudan veya dolaylı olarak gözlemleyerek, beynin nasıl çalıştığını anlamamıza yardımcı olur. Nöral aktiviteyi görüntüleme hem klinik uygulamalarda hem de bilimsel araştırmalarda kritik role sahiptir. Duyu organlarından gelen uyarılara beynin

verdiği tepkiler fonksiyonel manyetik rezonans (fMRI) görüntüleme, Tek Foton Emisyon Bilgisayarlı Tomografi (SPECT), bilgisayarlı tomografi (BT), yakın kızılötesi spektroskopisi (YKS), elektrokortikografi (ECOG), pozitron emisyon tomografi (PET) ve elektroensefalografi (EEG) gibi çeşitli biyomedikal ölçme ve görüntüleme teknikleri ile yapılabilmektedir. Bu yöntemlerin her birinin, nöral aktivitenin kaydedilmesinde kendine özgü avantajları ve dezavantajları bulunmaktadır.

fMRI görüntüleme tekniği, kandaki oksijenlenmiş hemoglobin ile oksijenlenmemiş hemoglobin arasındaki manyetik özellik farklılıklarını temel alarak beyin görüntülemesi sağlar. Bu teknik, beyin aktivitelerinin haritalanmasında yaygın olarak kullanılmakla birlikte, bazı dezavantajları da beraberinde getirmektedir. Özellikle, vücudunda protez, implant gibi metalik objeler bulunan bireylerde fMRI uygulaması, önemli zorluklar teşkil etmektedir. Metalik objelerin manyetik alanla etkileşimi, tıbbi cihazların bozulmasına ve vücuda başka metallerin çekilmesine neden olabilir. Bu durum hem hasta güvenliği hem de görüntüleme kalitesi açısından ciddi riskler doğurabilir. Ayrıca fMRI, iyi bir mekansal çözünürlüğe sahip olmasına rağmen, zamansal çözünürlüğü sınırlıdır. Bu durum, hızlı sinirsel olayları diğer yöntemler kadar kesin bir şekilde yakalayamamasına neden olur (Matthews vd., 2006).

SPECT, beyne radyoaktif bir izotopun enjekte edilmesiyle çalışarak, bu izotopun yaydığı gama ışınlarını tespit eder ve beyin aktivitelerinin üç boyutlu görüntülerini oluşturur. Bu teknik, özellikle beyin kan akışı, metabolizma ve nörotransmitter reseptörlerinin değerlendirilmesinde kullanılır ve epilepsi, inme, Alzheimer gibi nörolojik bozuklukların tanısında yaygın olarak uygulanır. SPECT, beynin fonksiyonel durumu hakkında detaylı bilgi sağlama yeteneğiyle öne çıkar. Ancak, diğer görüntüleme yöntemlerine göre daha düşük çözünürlük sunması ve radyoaktif madde kullanımı nedeniyle sık tekrarlanan taramalarda hasta güvenliği açısından risk oluşturması, bu tekniğin başlıca sınırlamalarıdır (Karssemakers vd., 2024).

BT taramaları, vücut içindeki yapıların yüksek çözünürlüklü ve ayrıntılı görüntülerini sunarak, özellikle kanser gibi ciddi hastalıkların teşhisinde hayati bir rol oynar. Ayrıca, BT taramaları hızlıdır ve acil durumlarda hızlı karar verilmesine olanak tanır. Ancak, BT'nin bazı önemli dezavantajları da bulunmaktadır. En önemli dezavantajlarından biri, yüksek dozda radyasyon yaymasıdır, bu da özellikle tekrarlayan taramalarda kanser riskini artırabilir. Ayrıca, BT'nin yüksek maliyeti ve kullanılan ekipmanın karmaşıklığı, bu teknolojinin yaygın kullanımını kısıtlayabilir (Inamoto vd., 2024).

YKS, non-invaziv ve hızlı bir analiz yöntemi olarak beyin oksijenlenmesi ve kan akışı gibi fizyolojik parametrelerin değerlendirilmesinde etkin bir şekilde kullanılmaktadır. Taşınabilirliği ve kolay uygulanabilirliği hem klinik hem de araştırma ortamlarında yaygın olarak tercih edilmesini sağlar. Ayrıca, çevre dostu bir yöntem olması, kimyasal madde kullanımını en aza indirmesiyle de dikkat çeker. Ancak NIRS, düşük sinyal-gürültü oranı, sinyalin dokularda zayıflaması ve dağılması, düşük duyarlılık ve heterojen doku etkisi gibi dezavantajlarına sahiptir (Kappacher vd., 2024).

ECoG, beyin yüzeyine yerleştirilen elektrotlarla beyin aktivitelerinin yüksek zamansal ve mekansal çözünürlükte doğrudan kaydedilmesini sağlayan invaziv bir nörofizyolojik izleme yöntemidir. Bu teknik, özellikle epilepsi cerrahisi gibi nörolojik müdahalelerde kritik beyin bölgelerinin hassas bir şekilde haritalanmasına olanak tanır. ECoG'nin en büyük avantajı, beyin yüzeyine yakın nöral aktiviteleri hassas bir şekilde ölçebilmesidir; ancak invaziv olması, cerrahi riskler taşır ve derin beyin bölgelerinden gelen sinyalleri tespit etmekte yetersiz kalabilir (Sarnthein & Neidert, 2024).


Pozitron Emisyon Tomografisi (PET), yüksek hassasiyet ve çözünürlük sunarak derin dokuların metabolik aktivitelerini ve hastalık durumlarını görüntülemeye önemli avantajlar sağlar. PET, özellikle kanser teşhisi, tedavi takibi ve nörolojik rahatsızlıkların değerlendirilmesinde etkin bir rol oynar. Bununla birlikte, PET'in bazı dezavantajları da bulunmaktadır. Yöntem, radyoaktif izotopların kullanımı nedeniyle radyasyon maruziyeti yaratır, bu da hasta güvenliği açısından dikkate alınması gereken bir faktördür. Ayrıca, PET taramalarının yüksek maliyeti ve sınırlı erişilebilirliği, yöntemin yaygın kullanımını kısıtlayabilir. Anatomik detayların yeterince belirgin olmaması nedeniyle, PET genellikle diğer görüntüleme teknikleriyle birlikte kullanılır, bu da ek maliyet ve zaman gerektirebilir (Sarcen & Özer, 2023).

EEG, beyin aktivitelerini kaydetmek için kafa derisine yerleştirilen elektrotları kullanır. Beynin elektriksel aktivitelerini milisaniye düzeyinde yüksek zaman çözünürlüğü ile ölçer. Genellikle uyku çalışmaları, epilepsi teşhisi ve bilişsel süreçlerin araştırılması gibi alanlarda kullanılır (Lopes da Silva & Niedermeyer, 2005). EEG, diğer beyin görüntüleme yöntemlerine göre önemli avantajlara sahiptir. Birincisi, yüksek zamansal çözünürlüğe sahip olması sayesinde beyin aktivitelerini milisaniyeler düzeyinde ölçebilir, bu da anlık nöral olayların izlenmesini sağlar. İkincisi, EEG non-invaziv ve güvenli bir yöntemdir, bu nedenle özellikle çocuklar ve hassas popülasyonlar için idealdir. Ayrıca, EEG ekipmanları taşınabilir ve kullanımı kolaydır, bu da klinik dışı ortamlarda bile uygulanmasını mümkün kılar.

Üçüncüsü, EEG, maliyet açısından diğer görüntüleme yöntemlerine göre çok daha ekonomiktir, bu da onu geniş bir kullanım alanına sahip kılar. Bu avantajlar, EEG'yi hızlı, güvenli ve etkili beyin fonksiyonu izlemeleri için tercih edilen bir yöntem haline getirir (Short vd., 2021).

1.2. Elektroensefalografi ve Özellikleri


Beyindeki elektriksel faaliyetlerin varlığı, ilk olarak 1875 yılında Caton adlı bilim insanının hayvanlar üzerinde gerçekleştirdiği deneylerle ortaya konmuştur. İnsan beynindeki elektriksel aktivitenin varlığı ise 1929 yılında nörolog ve psikiyatrist Hans Berger tarafından ilk kez gösterilmiştir. Berger, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre aracılığıyla EEG verilerini kaydetmiş, bu sayede nöronların ürettiği beyin dalgalarının kaynağı olan küçük elektrik potansiyellerini ölçebilmiştir (Britton vd., 2016). İlk kaydedilen EEG örneği, Hans Berger tarafından elde edilmiş olup, bu örnek Şekil 3'te gösterilmiştir. Berger, 1930 yılında, EEG dalgalarının gözün açılıp kapanması gibi durumlarla değişiklik gösterdiğini de saptamıştır. Bu buluş, EEG'nin beyin fonksiyonlarının incelenmesinde önemli bir araç olarak kullanılmasının yolunu açmıştır.



Şekil 3. İlk EEG işareti

Edgar Douglas Adrian ve Brian Matthews elektronik bilimindeki gelişmelerden faydalanarak 1934 yılında elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. Pauline Davis 1939 yılında, sese karşı uyarılan yanıtların (Evoked Potentials) olduğunu uyanık bir insanın EEG'sinde bulmuştur. Aynı yıl içinde Hallowell Davis ve arkadaşları uyuyan insanda da aynı olayın meydana geldiğini göstermişlerdir (Lopes da Silva & Niedermeyer, 2005). Gelişen teknolojiyle birlikte, EEG işaretlerinde çok miktarda bilgi gizlendiği, yapılan çalışmalarla ortaya çıkmaktadır. Tıbbi tanılarda, nörolojik rahatsızlıkların çözümünde bu bilgilere çokça başvurulur. Günümüze gelindiğinde EEG, tıpta, başta epilepsi (sara hastalığı) olmak üzere birçok beyin

rahatsızlıklarının teşhisinde hastaya acı vermeyen ve nispeten ucuz bir yöntem olduğu için yaygın olarak kullanılır. EEG, kafatası üzerine yerleştirilen sensörler aracılığıyla, nöronal aktivite sonucu oluşan elektriksel potansiyel değişimlerini milisaniye düzeyinde zaman çözünürlüğü ile ölçebilen bir tekniktir (Cohen, 2014). Kafatası üzerinden ölçülen voltaj sinyalleri, genellikle paralel geometrik yönelime sahip nöronlar tarafından üretilen elektriksel potansiyellerin toplamını yansıtır. Nöronlar dinlenme halinde iken hücre zarında belirli bir potansiyel farkı bulunur. Bu, hücre içi ile hücre dışı arasındaki iyonların dağılımından kaynaklanmaktadır. Hücre dışı ortamda yüksek konsantrasyonda sodyum (Na^+) ve klorür (Cl^-) iyonları bulunurken, hücre içinde potasyum (K^+) iyonları ve çeşitli negatif yüklü moleküller yer alır. Dinlenme durumunda, hücre içi negatif, hücre dışı ise pozitif bir yük taşır, bu da zar boyunca bir potansiyel fark yaratır. Bu potansiyel, iyon kanallarının voltaj değişikliklerine yanıt vererek açılması ve kapanması ile korunur. Dışsal uyarıcılar bu iyon dengesini bozduğunda, hücre zarında elektriksel bir değişim meydana gelir ve bu da potansiyel farkın değişmesine neden olur. Bu durum, hücrenin elektriksel aktivitesini tetikleyerek sinyallerin iletimini sağlar (Marino & Mantini, 2024). Bu sinyallerin iletim süreci, "aksiyon potansiyeli" olarak adlandırılmaktadır. Aksiyon potansiyelinin aşamaları Şekil 4'te gösterilmektedir.




Şekil 4. Aksiyon potansiyeli evreleri

Şekil 4'te gösterildiği gibi, bir nöron dinlenme halindeyken hücre içi, hücre dışına göre yaklaşık 70 mili volt (mV) daha negatiftir, bu nedenle hücre içi potansiyeli -70 mV olarak

tanımlanır. Bu dinlenme potansiyeli, hücreye herhangi bir uyarı gelmediği sürece korunur. Dinlenme durumundaki bir nörona bir uyarı ulaştığında, voltaj bağımlı sodyum (Na^+) kanalları açılır ve bu aşamada, hücre içine büyük miktarda Na^+ iyonu girer, bu süreç depolarizasyon olarak adlandırılır. Depolarizasyonun ardından, Na^+ kanalları kapanır ve voltaj bağımlı potasyum (K^+) kanalları açılır. Bu aşama, repolarizasyon başlangıcı olarak bilinir ve K^+ iyonları hücre dışına çıkar. Voltajın yeniden düşmesiyle K^+ kanalları kapanır ve hücre dinlenme potansiyeline geri döner.


1.2.1. EEG İşaretlerinin Ölçüm Yöntemi

EEG ölçümleri tipik olarak 1 ila 256 arasında değişen sayıda elektrot kullanılarak yapılmakta olup, bu elektrotlar genellikle elastik bir başlıkla sabitlenmektedir (Rajinikanth vd., 2023). Geleneksel bir EEG montajı, 10–20 sistemi olarak bilinir. Bu sistem, 21 elektrotun kafa derisi üzerinde eşit şekilde yerleştirilmesini sağlamak için belirli anatomik işaret noktalarına (nasion, inion ve sol ve sağ preauriküler noktalar) dayanır Şekil 5 (A). Daha ince mekansal örneklemeleri desteklemek amacıyla, 10–10 sistemi Şekil 5 (B) ve 10–5 sistemi Şekil 5 (C) önerilmiştir (Oostenveld & Praamstra, 2001). Bu sistemler, 10–20 sistemindeki elektrotlar arasındaki boşluklardan faydalanarak yüksek çözünürlüklü EEG (hdEEG) kayıtlarına olanak tanır (Jurcak vd., 2007). Geleneksel EEG'ye kıyasla daha uzun hazırlık süresine rağmen, nöral kaynakların güvenilir bir şekilde lokalize edilmesinin önemli olduğu deneylerde hdEEG tercih edilir (Jurcak vd., 2007). EEG elektrotları, genellikle altın veya gümüşle kaplanmış gümüş klorür gibi iletken malzemelerden yapılmıştır. Elektrot ile kafa derisi arasındaki empedansı en aza indirmek ve sinyal iletiminin stabilitesini ve kalitesini artırmak amacıyla, elektrotlar ile kafa derisi arasına elektrolit jel veya tuzlu su çözeltisi uygulanır. Her elektrottan algılanan sinyal, elektrotun kendisindeki voltaj ile fiziksel bir referans elektrotundaki voltaj arasındaki farka karşılık gelir. Bu referans elektrot genellikle başın tepe noktasında, bilateral mastoidlerde veya kulak memesindedir. Referans elektrottaki mutlak EEG genliği sıfırdır ve diğer elektrotlarda genellikle 50 μV 'a kadar çıkabilir (Marino & Mantini, 2024).



Şekil 5. Standart 10–20 sistemine (A), 10–10 sistemine (B) ve 10–5 sistemine (C) ait EEG elektrot montajı

EEG işaretleri, beyin yüzeyinden elektrotlarla algılanan düşük genlikli biyoelektrik işaretlerdir. Bu işaretlerin genliği tepeden tepeye 1-400 μ V aralığında bulunmaktadır. EEG sinyaline gömülü olan dalgalar hem zamansal hem de mekânsal olarak değişiklik gösteren ve beyin fonksiyonel durumlarını yansıtan kritik bir özelliktir. Bu dalgalar, beyin çeşitli bilişsel ve nörofizyolojik aktivitelerini temsil eden farklı bant aralıklarına ayrılır. EEG sinyalinin spektral analizi ile bu frekans bantları belirlenir ve genellikle delta (1–4 Hz), theta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) ve gamma (>30 Hz) olarak sınıflandırılır (Marino & Mantini, 2024). Bu dalgaların, frekans ve zaman dümenlerinde Şekil 6 (A) ve 6 (B)’de gösterilmiştir.



Şekil 6. (A): Frekans bölgesinde gösterilen nöral dalgalar. (B): Zaman bölgesinde gösterilen nöral dalgalar

Bu frekans bantlarının her biri, beynin farklı durum ve süreçlerle ilişkili spesifik aktivitelerini yansıtır:

- Delta dalgaları genellikle derin uyku, uyku-uyanıklık geçiş evreleri ve düşük bilinç düzeyleri ile ilişkilidir. Ayrıca, beyin hasarları ve çeşitli patolojik durumlarda artış gösterebilir. Bu dalgaların frekansları 0-4 Hz, genlikleri 20-400 μ V arasında değişir (Siddharth, Jung & Sejnowski, 2019).

- Theta dalgaları, yaratıcı düşünme, meditasyon, hafif uyku evreleri ve hafıza ile bağlantılıdır. Dikkat gerektiren görevler sırasında artan theta aktivitesi, dikkatin yoğunlaştığı durumlarda yaygındır. Bu dalgaların frekansları 4-8 Hz, genlikleri 5-100 μ V arasında değişir (Snipes vd., 2022).

- Alfa dalgaları, özellikle gözler kapalıyken dinlenme durumunda görülen, beynin uyanıklıkla rahatlatma arasında bir denge kurduğu durumları temsil eder. Stresin azaltılması ve zihinsel gevşeme ile ilişkili olup, stres yönetimi ve meditasyon çalışmalarında önemli bir role sahiptir. Bu dalgaların frekansları 8-13 Hz, genlikleri 2-10 μ V arasında değişir (Dobrakowski vd., 2020).

- Beta dalgaları ise, aktif düşünme, problem çözme, karar verme, motor hareketlerin planlanması ve yürütülmesi sırasında baskın hale gelir. Bu frekans bandı, yüksek bilişsel yük veya anksiyete durumlarında da görülebilir. Bu dalgaların frekansları 13-30 Hz, genlikleri 1-5 μ V arasında değişir (Attar, 2022).

- Gamma dalgaları, en yüksek frekanslı bant olarak, karmaşık bilişsel işlemler, öğrenme, bellek birleştirme ve bilinçli farkındalıkla ilişkilidir. Gamma aktivitesi, beynin farklı bölgeleri arasındaki yüksek seviyeli entegrasyonun bir göstergesi olarak kabul edilir. Bu dalgaların frekansları 30-100 Hz, genlikleri 5-20 μ V arasında değişir (Ali vd., 2022).

1.2.2. EEG İşaretlerini Etkileyen Gürültüler

EEG sinyallerinin düşük genlikte olması, bu sinyalleri hem fizyolojik hem de fizyolojik olmayan çeşitli gürültü kaynaklarından kolayca etkilenebilir hale getirmekte ve bu durum, sinyallerin istatistiksel analizlerini daha zor ve karmaşık bir süreç haline getirmektedir. EEG sinyallerine etki edebilecek başlıca gürültü kaynakları şunlardır:

- Biyolojik gürültüler: Kas hareketleri, göz hareketleri, elektrokardiyogram (EKG), terleme ve pulsasyon gibi biyolojik süreçlerden kaynaklanan gürültüler, EEG sinyallerinin analizini zorlaştıran önemli faktörlerdir.

- Harekete bağılı gürültüler: Kayıt sırasında deneğin hareketlerinden kaynaklanan gürültüler, elektrot-sinir ilişkisini bozarak sinyal kalitesini düşürebilir.


- Elektrot kaynaklı gürültüler: Elektrotların kafa derisine uygun şekilde yerleştirilememesi, temas direncinin yüksek olması veya elektrotların hareket etmesi sonucunda oluşan gürültüler.

- Şebeke kaynaklı gürültüler: Radyo dalgaları, elektrostatik gürültü ve şehir cereyanı gibi şebeke girişimlerinden kaynaklanan gürültüler, EEG sinyallerinde yüksek frekanslı interferanslara yol açabilir.


- Kayıt cihazı kaynaklı gürültüler: EEG kayıt cihazının teknik bozukluklarından veya düşük kaliteli bileşenlerinden kaynaklanan gürültüler, sinyalin doğruluğunu etkileyebilir.

- Çevresel gürültüler: Çevredeki elektromanyetik alanlar, elektrikli cihazlardan kaynaklanan gürültüler ve diğer çevresel faktörler EEG sinyallerini olumsuz yönde etkileyebilir.

EEG kayıtlarında en yaygın karşılaşılan gürültülerden biri, göz kırpması sonucu oluşan artefaktır. Bu tür gürültünün genliği, tipik bir EEG sinyalinden daha yüksek olabilir. Deney sırasında sık sık gerçekleşen göz kırpmaları, EEG sinyalinde belirgin bozulmalara yol açar ve bu durum Şekil 7'de gösterilmiştir. İstemli veya istemsiz kas hareketlerinden kaynaklanan gürültüler ise geniş bir frekans aralığına sahiptir ve hareket eden kasın yakınındaki EEG kanallarında daha belirgin hale gelir. Örneğin, dişlerin sıkılması sırasında oluşan EEG sinyali Şekil 8'de gösterilmiştir. Ayrıca, çevredeki elektriksel düzeneklerden kaynaklanan şebeke gürültüsü de EEG sinyallerine karışabilir. Bu tür gürültüler, notch filtresi kullanılarak temizlenebilir (Knight, 2003).



Şekil 7. Gözün kırılması ile ortaya çıkan gürültülü EEG



Şekil 8. Dişin sıkılmasıyla ortaya çıkan gürültülü EEG

1.3. Tat Alma Duyusunun Tanımı ve Önemi

Tat alma duyusu, insanın beş temel duyusundan biridir ve yiyeceklerin lezzetini algılamada hayati bir rol oynar. Bu duyunun temel bileşeni olan tat tomurcukları, dilin yanı sıra damak, epiglottis ve özofagus gibi bölgelerde bulunur. Tat alma, kimyasal, hormonal ve sinirsel süreçlerin bir araya gelmesiyle oluşur. Tat tomurcukları, tatlı, tuzlu, acı, ekşi ve umami gibi temel tatları algılayarak yiyeceklerin tadını belirler. Tat alma duyusunun önemi sadece gıdaların lezzetini algılamayla sınırlı değildir; aynı zamanda bireylerin beslenme alışkanlıklarını, yiyecek tercihlerini ve genel yaşam kalitesini de etkiler (Kurtuldu vd., 2018).

Tat alma duyusu, zehirli veya bozulmuş gıdaların ayırt edilmesi gibi hayati fonksiyonlar için kritik bir öneme sahiptir. Bu duyunun yardımıyla insanlar, tehlikeli yiyecekleri tüketmekten kaçınabilir. Ayrıca tat alma duyusu, yemek yeme eylemini keyifli bir deneyime dönüştürür ve insanların beslenme tercihlerini etkiler. Tat alma duyusu, koku, dokunma, görme ve duyma gibi diğer duyularla iş birliği içinde çalışarak, yiyeceklerin tam anlamıyla algılanmasını sağlar. Bu nedenle, tat alma duyusu sadece beslenme açısından değil, aynı zamanda kültürel ve sosyal bağlamda da önem taşır (Çeltek & Altun, 2023).

Tat alma duyusunun incelenmesi, yaş, cinsiyet, kültürel geçmiş ve sağlık durumu gibi değişkenler nedeniyle karmaşık ve zorluklarla dolu bir süreçtir. Tat algısı, dil üzerindeki tat tomurcukları aracılığıyla gerçekleşir ve bu tomurcukların sayısı ile duyarlılığı yaşlanma sürecinde azalabilir, bu da tat algısında bozulmalara yol açar. Bireyler arasındaki bu çeşitlilik, tat duyusunun objektif olarak ölçülmesini zorlaştırır. Bu zorlukları aşmak için EEG (Elektroensefalografi) gibi nörofizyolojik yöntemler kullanılarak, tat algısının beyin üzerindeki etkileri daha objektif bir şekilde incelenebilir ve derinlemesine anlaşılabilir (Ogawa vd., 2017).

Tat alma bozukluklarının teşhisinde kullanılan testler, kimyasal ve elektriksel uyarıcılar yardımıyla gerçekleştirilir. Kimyasal testlerde tatlı, ekşi, acı ve tuzlu gibi temel tatlar kullanılarak bireylerin bu tatlara verdiği tepkiler ölçülür (Boyacı & İçigen, 2021). Elektrogustometri gibi elektriksel testler ise tat alma duyarlılığını belirlemek için kullanılır. Bu testler, tat alma duyusunun nicel ve nitel değerlendirmelerini yapmayı sağlar. EEG testleri de bu süreçte kullanılarak, tat alma duyusunun beyin üzerindeki etkileri incelenir. EEG ile yapılan bu tür testler, tat algısının beyindeki işlenişini anlamak için değerli bilgiler sunar (Songsamoe vd., 2019).

Tat testlerinde kültürel uyumluluk oldukça önemlidir, çünkü tat algısı kültürel ve coğrafi faktörlere bağlı olarak değişiklik gösterebilir. Her toplumun kendine özgü tatları ve beslenme alışkanlıkları olduğundan, tat testlerinin bu faktörlere uygun olarak tasarlanması gereklidir. Kültürel uyumluluk, tat testlerinin doğruluğunu ve geçerliliğini artırır, bu da bireylerin tat algılarının doğru bir şekilde değerlendirilmesini sağlar. EEG testleri de bu bağlamda kullanılarak, kültürel farklılıkların beyindeki tat algısına etkisi araştırılabilir. Bu, tat algısının nörofizyolojik temellerine yönelik daha derin bir anlayış kazandırır (Kurtuldu vd., 2018).

Subjektif testler, klinik olarak kişilerin tat kaybının değerlendirilmesinde kullanılırken, objektif testler öncelikli olarak araştırma amaçlı kullanılmaktadır. Herhangi bir tat algısının değerlendirilmesi sırasında beyinde oluşan elektriksel aktivitenin ölçülmesi ile yapılan objektif testler, tıbbi alanda daha yüksek güvenilirlik sunabilecek yöntemlerin geliştirilmesine olanak sağlayabilir (Xia vd., 2024).

1.4. Beynin Koku Anatomisi


Beynin koku anatomisi, koku duyusunu işlemekten sorumlu olan yapıları içerir. Koku alma sistemi (olfaktör sistem), burundan beyne iletilen koku moleküllerinin algılanması ve işlenmesi sürecini kapsar. Görme duyusu insanlar için en baskın algılayıcı sistem olarak kabul edilse de koku duyusu (olfaksiyon) hayati bir role sahiptir, çünkü çevremizdeki zararlı maddeleri algılayarak bizi tehlikelerden korur. Koku ve tat alma duyuları ise birbirleriyle sıkı bir şekilde ilişkilidir, bu iki sistem genellikle birlikte çalışır (Carter, 2019).

1.4.1. Kokuyu Yakalamak

Koku, tat gibi kimyasal bir duydur ve burun boşluğundaki özelleşmiş reseptörler, burna giren ve bu reseptör hücrelere bağlanan molekülleri algılar. Koklama işlemi, koku moleküllerinin burun içine daha fazla çekilmesine yol açarak bu moleküllerin birikmesine neden olur. Bir koku dikkat çektiğinde refleks olarak meydana gelen bu eylem, yanık ya da bozulmuş gıdaların kokusunu algılayarak tehlikeye karşı hızlı bir uyarı mekanizması işlevi görür. Burun boşluğunda yer alan olfaktör reseptörler, burun boşluğunun üst kısmında bulunur ve bu reseptörler tarafından algılanan sinyaller, limbik sistemin bir parçası olan olfaktör soğana elektriksel sinyaller şeklinde iletilir (Carter, 2019).

1.4.2. Beyindeki Koku Merkezleri


Olfaktör soğan, koku bilgilerini beyne ileten ilk durağı oluşturur. Burada (sarı alan) işlenen koku sinyalleri, ön beyinde daha ileri düzeyde analiz edildikten sonra, hipokampusun (kırmızı alan) yakınında yer alan olfaktör korteks gibi çeşitli beyin bölgelerine dağıtılır (Carter, 2019). Bu sürecin işleyişine ilişkin beyin bölgeleri Şekil 9'da gösterilmiştir.



Şekil 9. Beyindeki koku merkezleri

1.4.3. Koku Algılanması ve İşlenmesi

Kokular, burun boşluğundaki reseptör hücreler tarafından algılanır. Bu reseptörler, olfaktör soğana (her burun deliği bir olfaktör soğana bağlıdır) giden yollar boyunca elektriksel sinyaller gönderir. Olfaktör soğan, limbik sistemin bir bileşeni olup, limbik sistem duygularımızın, isteklerimizin ve içgüdülerimizin merkezidir; bu nedenle koku, insanda güçlü duygusal tepkiler uyandırır. Olfaktör soğanda işlenen koku verisi, farklı işlemler için beynin daha üst merkezlerine üç olfaktör yol üzerinden iletilir. Bu süreç, kokunun burun yoluyla algılandığı "ortho-nazal" koku alma olarak adlandırılır. "Retro-nazal" koku almada ise koku, ağız yoluyla giren tat bileşeninin de yer aldığı olfaktör yollara iletilir. Diğer duyu organların toplanan bilginin aksine, kokular beynin burna girdiği tarafta, çaprazlaşmadan işlenir (Carter, 2019). Koku algılama ve işleme sürecine katılan bölgeler, Şekil 10'da kırmızı ve mavi oklarla gösterilmiştir.



Şekil 10. Koku Algılanması ve İşlenmesinde iş birliği yapan bölgeler


1.5. Beynin Tat Anatomisi

Tat duyusu, kimyasal bir algı süreci olarak tanımlanır ve temel olarak dildeki tat tomurcukları tarafından gerçekleştirilir. Tat tomurcukları, dil ve ağız boşluğunda bulunan özelleşmiş hücre gruplarından meydana gelir. Bu hücreler, besinlerde bulunan kimyasal bileşiklerle etkileşime girerek bu bileşiklerin tat özelliklerini algılar. Tat duyusu, beş temel tat kategorisi olan tatlı, tuzlu, ekşi, acı ve umami tat üzerinden sınıflandırılır (Schwartz vd., 1991).

1.5.1. Tat Alan ve Koklayan Beyin

Tat ve koku duyuları kimyasal algılardır; burun ve ağızdaki reseptörler gelen molekülleri bağlar ve beyne iletilmek üzere elektriksel sinyaller oluşturur. Bu sinyaller, kafatası sinirleri boyunca taşınır. Koku ile ilgili (olfaktör) sinyaller, burundan olfaktör soğana ve oradan da olfaktör sinir yoluyla temporal lobdaki olfaktör kortekse iletilir. Tat ile ilgili bilgiler ise, ağızdan trigeminal ve glossofaringeal sinirler aracılığıyla medullaya,

ardından talamus üzerinden serebral korteksin birincil tat alma bölgelerine gönderilir (Carter, 2019). Tat algılaması sürecinde beyinde etkin olan bölgeler Şekil 11’de gösterilmiştir.



Şekil 11. Tat Algılanması ve İşlenmesinde iş birliği yapan bölgeler

Beyin, tat algısını hem tat duyusuna hem de retronazal kokuya dayanarak oluşturur. Retronazal koku, ağızdan solunan havayla birlikte yiyeceklerden yayılan uçucu moleküllerin burun boşluğuna ulaşmasıyla algılanır. Beyin görüntüleme çalışmaları, retronazal kokunun ortonazal kokuya kıyasla farklı beyin bölgelerini aktive ettiğini göstermektedir, ancak retronazal kokunun daha fazla beyin bölgesini aktive ettiğine dair genelleme her durumda geçerli olmayabilir. Aktivasyonun boyutu kokunun türüne ve bağlama göre değişiklik gösterebilir (Bear vd., 2020).

1.6. Beyin Bilgisayar Arayüzü

Beyin-bilgisayar arayüzleri (BBA), insan beyninin ürettiği elektrik sinyallerini kullanarak çevre ile etkileşimi sağlayan teknolojik sistemlerdir. Bu sistemler, beyin sinyallerini kontrol sinyallerine çevirerek felçli ve anarthria gibi iletişim yetilerini kaybetmiş bireylerin iletişimini yeniden kurma potansiyeline sahiptir. BBA'lar, kullanıcıların beyin aktivitelerini, periferik sinirler veya kaslar tarafından kontrol edilmeyen dış cihazları çalıştırmak için kullanmalarına olanak tanır. Bu sistemler, özellikle ciddi motor engelli bireylere yardım etmede, çeşitli alanlarda önemli umut vaat ediyor.

1.6.1. BBA Teknolojisi Uygulamaları

- Tıbbi Rehabilitasyon: BBA'lar, ALS veya omurilik yaralanmaları gibi rahatsızlıkları olan hastalarda iletişimi yeniden sağlamak için çok önemlidir ve cihazları kas müdahalesi olmadan beyin sinyalleri aracılığıyla kontrol etmelerini sağlamaktadır (Velasco-Alvarez vd., 2021).

- Akıllı Cihaz Kontrolü: Bu sistemler, akıllı evler ve işyerleri gibi ortamlarda, bireylerin günlük yaşamlarına daha fazla güvenlik, konfor ve fizyolojik kontrol sağlamak amacıyla kullanılmaktadır. Ayrıca, video oyunları ve multimedya uygulamaları gibi alanlarda, kullanıcılarla etkileşimi artırmak için de bir araç olarak hizmet vermektedir (Tiwari & Chaturvedi, 2021).

- Daha Geniş Etkiler: Sağlık hizmetlerinin ötesinde, BBA'lar eğitim, askeri, finans ve eğlence alanlarında araştırılıyor ve bu da onların geniş ticari potansiyellerini göstermektedir (Luo vd., 2022).

BBA'ler çıkır açan çözümler sunarken, kullanıcı adaptasyonu ve doğrudan beyin arayüzünün etik etkileri açısından zorluklar devam ediyor. Devamlı araştırma, bu sorunları ele almayı ve BBA'lerin günlük hayata güvenli ve etkili bir şekilde entegre edilmesini sağlamayı amaçlamaktadır.


1.6.2. Motor Hayaline Dayalı BBA

Motor hayaline dayalı BBA'ler, beyin-bilgisayar arayüzü (BCI) sistemlerinin önemli bir uygulama alanı olarak belirli alanlarda kullanılmaya başlanmış ve bu alandaki teknolojik ilerlemelerle birlikte daha geniş bir kullanım potansiyeline sahip olmuştur. Motor hayalleri, bireyin fiziksel bir hareketi gerçekleştirmeksizin yalnızca zihninde canlandığı motor aktivitelerini ifade eder. Bu zihinsel aktiviteler, elektroensefalografi (EEG) sinyallerinde belirgin desenler oluşturur ve bu desenler BCI sistemleri tarafından algılanarak sınıflandırılabilir. Sınıflandırılan bu sinyaller, kullanıcının niyet ettiği hareketlerin bir bilgisayar veya protez cihaz üzerinde gerçekleştirilmesi amacıyla kullanılmaktadır (Baig vd., 2017) (Oikonomou vd., 2017) (Padfield vd., 2019). Bu teknoloji, özellikle felçli bireyler için yenilikçi rehabilitasyon ve iletişim yöntemleri sunmakta olup, diğer çeşitli uygulama alanlarında da kullanım potansiyeline sahiptir (Al-Qaysi vd., 2023). Motor hayaline dayalı EEG sinyallerinin BCI sistemlerine entegrasyonu, kullanıcıların beyin sinyalleri aracılığıyla

doğal ve sezgisel bir kontrol sağlamalarına imkân tanıyarak, beyin-bilgisayar arayüzleri alanında önemli bir ilerlemeyi temsil etmektedir.

1.7. Beynin Koku, Tat ve Motor Hayaline Dayalı Etkileşimlerine Verdiği Cevapların Sınıflandırılmasına Ait Temel Bileşenler

EEG sinyaline dayalı beynin koku, tat ve motor hayalinin etkileşimlerine verdiği cevapların sınıflandırılması dört aşamadan oluşmaktadır. Birinci aşamada sinyallerin kaydedilmesi sonra ön işleme yapılması, ardından öz nitelik çıkarılması ve son olarak sınıflandırılmasıdır. Bu aşamalar Şekil 12’de gösterilmektedir.



Şekil 12. Beynin koku ve tat etkileşimine verdiği cevapların sınıflandırılmasına ait temel bileşenler

1.7.1. Sinyalin Alınması

Elektroensefalografi (EEG) cihazı, beyin elektriksel aktivitelerini ölçmek amacıyla kafa derisine yerleştirilen EEG elektrotları adı verilen küçük sensörler aracılığıyla veri toplar. Bu elektrotlar, beynin elektriksel sinyallerini tespit eder ve kaydeder. Elde edilen EEG sinyalleri, amplifikasyon ve dijitalleştirme süreçlerinden geçirilir ve ardından depolama ile veri işleme için bir bilgisayara veya mobil cihaza iletilir. EEG sinyalleri düşük genlikli oldukları için kas hareketlerinden etkilenme riski taşır; bu nedenle, EEG kayıtları sırasında deneğin hareketsiz kalması gereklidir. Ayrıca, EEG verilerinin çevresel gürültü kaynaklarından etkilenmesini önlemek için kayıtların izole edilmiş bir ortamda yapılması önemlidir. EEG sinyallerinin güvenilirliğini artırmak için, bu tür sinyallerin kaydı sırasında yüksek kaliteli sinyal işleme tekniklerinin kullanılması gereklidir (Saber, 2022).

1.7.2. Ön işleme

Ön işleme süreci, ham verileri temizlemek, sinyal/gürültü oranını artırmak ve ileri analizler için hazırlamak amacıyla kritik bir aşamadır. Bu süreç, EEG sinyallerinin çeşitli fizyolojik ve fizyolojik olmayan artefaktlardan arındırılmasını ve sinyallerin güçlendirilmesini içerir. Özellikle, göz kırpması ve kalp atışı gibi biyolojik artefaktlar ile çevresel gürültü kaynakları, sinyalin kalitesini olumsuz etkileyebileceğinden, bu unsurların elimine edilmesi büyük önem taşır. Gereksiz/gürültülü kanalların düzeltilmesi, zamansal filtreleme ve artefakt giderme gibi yöntemler bu doğrultuda uygulanmakta olup, bağımsız bileşen analizi (ICA) gibi kör kaynak ayırma teknikleri, nöral sinyallerin artefaktlardan ayrıştırılmasında yaygın olarak kullanılmaktadır. Bu ön işleme adımları, EEG verilerinin güvenilirliğini artırarak, sinyallerin doğru ve anlamlı bir şekilde analiz edilmesine olanak tanır (Mantini vd., 2007).

1.7.3. Öznitelik Çıkarma

Öznitelik çıkarma, farklı koku, tat ve düşünce durumlarında kaydedilen EEG işaretlerinin önemli özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Bu aşama araştırmanın önemli ve kritik bir aşamadır. Çünkü çıkarılan özniteliklerin kullanışlılığı direkt olarak sınıflandırıcının performansını, dolayısıyla da önerilecek metodun çalışma performansını etkiler (Pahuja vd., 2022) (Shakshi & Jaswal, 2016). Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabildiği için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiçbirisi yüzde yüz doğruluk vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımı elde etmek için farklı özniteliklerin birlikte kullanımı gerekli olmuştur (Liu vd., 2023). Çoklu elektrot kullanılarak elde edilen EEG verileri analiz edilirken, hangi elektrottan elde edilen verilerin öznitelik çıkarımı için daha uygun olduğu konusu önemli bir husustur. Beynin farklı bölgeleri, belirli görevler için daha yüksek hassasiyet göstermektedir. Örneğin, dokunma duyuları, beyin parietal lobunda yer alan somatosensoriyel korteks tarafından algılanır ve işlenir. Benzer şekilde, koklama, tat alma, işitme, hayal kurma ve matematiksel işlemler gibi çeşitli görevler, beyin farklı bölgelerinde daha belirgin bir etki yaratır. Bu nedenle, çoklu elektrotlu EEG verilerinde tüm elektrotlardan elde edilen veriler yerine, ilgili uygulamaya bağlı olarak beyindeki aktivitenin yoğun olduğu bölgelerden alınan verilerin kullanılması, en uygun özniteliklerin

çıkarılmasına ve sınıflandırma sürecinin hızlandırılmasına katkı sağlar (Aydemir & Kayıkcıoğlu, 2009).

1.7.4. Sınıflandırma

Sınıflandırma EEG işaretinin bir önceki adımda elde edilen öznitelik vektörü ışığında hangi sınıfa ait olduğuna karar verme aşamasıdır. Çeşitli sınıflandırma yöntemleri kullanarak elde edilen bu sınıf atama işleminin hızlı ve yüksek doğrulukla gerçekleşmesi istenir. Sınıflandırma aşamasının amacı deneğin düşüncesine karar vermektir. Bu aşamada doğruluk oranı yüksek ve hızlı olmalıdır. Bu nedenle çalışmalarda farklı sınıflandırma yöntemleri çeşitli yaklaşımlarla önerilmektedir. Farklı problemler için farklı sınıflandırma yöntemi tercih edilmektedir. Bunun sebebi türlü problem için her zaman en iyi sınıflandırma sonucunu veren bir sınıflandırma yöntemi olmamasıdır. Ancak, öznitelik verisinin genel dağılımı bilindiğinde birtakım öngörülerde bulunabilmek mümkündür. Beyin sinyallerinin sınıflandırılmasında makine öğrenimi (ML) teknikleri, genellikle denetimli (supervised) ve denetimsiz (unsupervised) öğrenme yöntemlerinin uygulanmasını içerir. Bu yöntemler arasında Naive Bayes (NB), karar ağaçları (KA), en yakın komşu (*k*-EYK), destek vektör makineleri (DVM) ve Rastgele Orman (RO) gibi algoritmalar yer almaktadır (Chaddad vd., 2023).

1.8. Literatür Araştırması

Son yıllarda tıp alanındaki donanım teknolojilerinin gelişmesi, biyolojik sinyallerin ve görüntülerin çözünürlüğünü artırarak tanı ve tedavi süreçlerinde daha doğru bilgiler sunmuştur. Bu bağlamda, EEG teknolojisi, yüksek zaman çözünürlüğü ve güvenliği ile beyin görüntülemeye önemli bir yere sahiptir (Ahire vd., 2023) (Chaddad vd., 2023). EEG, farklı alanlarda geniş bir uygulama alanına sahiptir. Tıbbi alanda, epilepsi, uyku bozuklukları, Alzheimer, Parkinson, şizofreni gibi nörolojik ve psikiyatrik hastalıkların tanısı, izlenmesi ve tedavi süreçlerinde kullanılmaktadır. Bu alanda yapılmış çalışmalar aşağıda özetlenmiştir:

Epilepsi, tekrarlayan nöbetlerle karakterize bir beyin bozukluğudur. Literatürdeki bu çalışmalarda EEG sinyallerini kullanarak epileptik nöbetlerin varlığını belirlemek için kullanılmıştır (Brari & Belghith, 2021) (Deivasigamani vd., 2021) (Mir vd., 2023) (Ahmad vd., 2024). Epilepsi tanısında, beynin elektriksel aktivitelerindeki anormal desenler (örneğin,

ani yüksek frekanslı deşarjlar) tespit edilmiştir. Uyku bozuklukları konusunda, bu çalışmalarda uyku sırasında beyin EEG sinyallerini kullanarak uyku apnesi gibi uyku bozukluklarının tanısı incelenmiştir (Behzad & Behzad, 2021; Peter-Derex vd., 2021; Runnova vd., 2021; Wadichar vd., 2023). Bu bozukluk, uykuda solunumun geçici olarak durması ile karakterizedir. Literatürde bulunan bu çalışmalar (Tait vd., 2020) (Wang vd., 2022) (Ajra vd., 2023) (Perez-Valero vd., 2023), EEG sinyallerini Alzheimer gibi demans türlerinin erken tanısında yardımcı olabileceğini göstermişler. Bu hastalıklarda, beynin belirli bölgelerinde azalmış elektriksel aktivite gözlemlenebilir.

EEG sinyallerini kullanarak, bu çalışmalarda Parkinson hastalığı gibi hareket bozukluklarının tanı ve takibinde kullanılmıştır (De Oliveira vd., 2020) (Li vd., 2023) (Nour vd., 2023) (Allahbakhshi vd., 2024). Bu hastalıkta, beyin dalgalarının belirli paternlerinde değişiklikler gözlemlenmiştir. Şizofreni hastalarında, EEG sinyallerini kullanılarak beyin dalgalarındaki anormalliklerin (örneğin, belirli frekans bantlarında değişiklikler) tespiti için bu çalışmalar yapılmıştır (De Miras vd., 2023) (Shor vd., 2023) (Jafari vd., 2024) (Ranjan vd., 2024). Bu çalışmalara dayanarak şizofreni tanısında EEG sinyallerinin katkı sağladığı görülmüştür.

EEG'nin en önemli kullanım alanlarından biri de Beyin-Bilgisayar Arayüzleri (BBA) teknolojileridir. Çeşitli amaçlar ve kullanıcı gruplar için BBA sistemleri büyük fayda sunmaktadır. Bu sistemler yardım ile felci hastalar ve hareket kısıtlılığı olan insanlar tekerlekli sandalyeler veya robotik kolları kontrol edebilmektedirler (Hochberg vd., 2012). Bu teknoloji sayesinde iletişim kurma kabiliyeti Amyotrofik Lateral Skleroz (ALS) hastaları için sağlanmaktadır (Vansteensel vd., 2016). Nöroprotezi kullanıcıları, beyin sinyalleri ile robotik uzuvlarını kontrol edebilmektedirler (Ortiz-Catalan vd., 2014). Epilepsi hastalarda nöbet tespiti ve kontrolü bu teknoloji sayesinde sağlanabilmektedir (Usman vd., 2019). BBA sistemleri sağlık ve rehabilitasyon uygulamalarında beyin motor becerilerini geliştirmek ve tedavi süreçlerini optimize etmek için kullanılmaktadır (Ma vd., 2024). Bu çalışmaların ana başlık alanı BBA sistemlerinde motor hayaline dayalı çalışmalardır. Literatürde bu sistemlerin performansı artırmak için birçok çalışma mevcuttur.

Genel olarak insan beyninin hangi bölgesinin hangi duylara cevap verdiği netleştirilmiş olsa da farklı koku ve tatlara verdiği cevaplar ve cevaplar arasındaki farklılıklar yeteri kadar incelenmemiştir. Özellikle tat ile ilgili, deneysel uygulamaların yetersizliği, elde edilen bulguların farklılık göstermesi ve farklı kokular ve tatlar ile yapılan çalışmaların azlığı, beynin kokulara ve tatlara verdiği tepkinin nasıl olduğu konusunda kesin bir yargıya

varılmasını zorlaştırmaktadır. Literatürde kişilerin çeşitli kokuları ve maddelerin koklaması ve tatmaları esnasında kaydedilen EEG sinyallerinin sınıflandırılması incelenmiş ve elde edilen bulgular irdelenmiştir.

Koku ile ilgili bir çalışmada Yazdani ve çalışma arkadaşları, katılımcılardan gözleri kapalı durumda dört farklı kokuyu koklamalarını istemiş ve bu süreçte EEG sinyallerini kaydetmişlerdir. Katılımcılardan hoşlandıkları ve hoşlanmadıkları kokuları belirtmeleri istenmiş, bu doğrultuda iki farklı hoş olan ve hoş olmayan grup oluşturulmuş ve ilgili EEG sinyalleri bu gruplara göre sınıflandırılmıştır. Çalışmada, öznitelik olarak EEG sinyallerinin bant güçleri kullanılmış olup, beş katılımcı için elde edilen sınıflandırma doğruluğunun ortalaması (SD) %79,91 olarak rapor edilmiştir (Yazdani vd., 2012).

Kokuya dayalı EEG çalışmalarına dair bir diğer çalışmada, Kroupi ve çalışma arkadaşları, beş katılımcıya gözleri açık ve kapalı durumlarda dört farklı koku (kediotu, nilüfer, peynir, gül suyu) koklatarak EEG verilerini kaydetmişlerdir. Her iki durumda katılımcılardan en beğendikleri ve en az beğendikleri kokuları belirtmeleri istenmiş, bu veriler ışığında EEG sinyalleri hoşlanılan ve hoşlanılmayan kokulara göre sınıflandırılmıştır. Her katılımcı için ayrı öznitelik çıkarma ve sınıflandırma modelleri kullanılmış olup, iki sınıflı bu problemde ortalama %85 SD elde edilmiştir (Kroupi vd., 2014).

Aydemir tarafından yapılan bir çalışmada, Kroupi ve çalışma arkadaşları tarafından kaydedilmiş kokularını EEG sinyallerini sınıflandırmıştır. Bu çalışmada öznitelik çıkarımı için sürekli dalgacık dönüşümü (SDD) kullanılmış ve Morlet dalgacığı seçilmiştir. Sınıflandırma işlemi için k -en yakın komşu (k -EYK) algoritması uygulanmış ve 4 sınıflı bir sınıflandırma yapılmıştır. Çalışma sonucunda, gözler açıkken %87,5 ve gözler kapalıyken %94,12 SD ortalaması elde edilmiştir (Aydemir, 2017).

Başka bir çalışmada, Chaichanasittikarn ve arkadaşları tarafından otuz bir sağlıklı kadın katılımcı üzerinde EEG tabanlı koku dayalı duygusal tepki sınıflandırması gerçekleştirilmiş. Çalışmada, dört farklı koku (katılımcıların en aşına oldukları iki koku ve en az aşına oldukları iki koku) kullanılmıştır. EEG sinyallerinden güç spektral yoğunluk (PSD) öznitelikleri çıkarılmış ve üç farklı makine öğrenme algoritması (k -EYK, lineer-DVM, RBF-DVM) ile sınıflandırma yapılmıştır. En yüksek doğruluk oranı %86,1 ile RBF-DVM algoritması tarafından elde edilmiştir. Bu çalışma, EEG sinyalleri kullanılarak pozitif ve negatif duyguların ikili sınıflı olarak başarılı bir şekilde sınıflandırılabileceğini göstermiştir (Chaichanasittikarn vd., 2023).

Ezzatdoost ve arkadaşları tarafından kokuya dayalı kaotik ve doğrusal olmayan öznitelik çıkarma yöntemi önerilmiş ve EEG sinyallerinin sınıflandırması yapılmıştır. Çalışmada Kroupi ve arkadaşları tarafından kayıt yapılan (Eleni Kroupi) kokular kullanılmıştır. EEG sinyallerinin öznitelik çıkarımı için kaotik ve doğrusal olmayan özellikler kullanılmıştır; bu özellikler arasında Higuchi'nin fraktal boyutu (HFD), en büyük Lyapunov üssü (LLE), yaklaşık entropi (ApEn) ve Lempel-Ziv karmaşıklığı (LZC) bulunmaktadır. Sınıflandırma işlemi için Doğrusal Ayrım Analizi (DAA) kullanılmıştır. Çalışmada, 4 sınıflı bir sınıflandırma yapılmış ve gözler açıkken %96,71 SD, gözler kapalıyken %88,79 SD elde edilmiştir. Bu sonuçlar, kokuların EEG sinyalleri aracılığıyla başarılı bir şekilde sınıflandırılabilirliğini göstermektedir (Ezzatdoost vd., 2020). Bu çalışmada kullanılan kokular, Kroupi ve meslektaşları tarafından halka açık bir veri setinden alınmıştır.

Bir diğer kokuya dayalı çalışmada, Sedghizadeh ve çalışma arkadaşları, Alzheimer hastalığının erken teşhisi amacıyla kokuya dayalı EEG sinyallerini analiz etmişlerdir. Çalışmada katılımcılara iki farklı koku sunulmuştur: limon (standart uyarıcı) ve gül (nadir uyarıcı). EEG sinyallerinin analizinde öznitelik çıkarma yöntemi olarak farklı frekans bantları arasındaki uyum analizi kullanılmıştır. Özellikle gamma ve beta frekans bantlarındaki uyum değerleri öznitelik olarak seçilmiş, bu değerler Alzheimer hastalarını sağlıklı bireylerden ayırmak amacıyla destek vektör makineleri (DVM) sınıflandırıcısına girdi olarak verilmiştir. Çalışmada EEG verileri 24 katılımcıdan (11 Alzheimer hastası ve 13 sağlıklı birey) toplanmış ve SD ortalama olarak %91,7 olarak rapor edilmiştir (Sedghizadeh vd., 2020).

Xia ve çalışma arkadaşları tarafından gerçekleştirilen bir araştırmada, katılımcılara sekiz farklı koku (nane şurubu, gül şurubu, portakal suyu, çilek suyu, karides ezmesi, ekşi bambu filizi, durian püresi ve sarımsak ezmesi) sunulmuş ve EEG verileri kaydedilmiştir. Bu çalışmada, 12'si erkek ve 4'ü kadın olmak üzere toplam 16 katılımcıdan EEG verisi toplanmıştır. Öznitelik çıkarma sürecinde, mutual information (karşılıklı bilgi) yöntemi ile işlevsel beyin ağları oluşturulmuş ve bu ağların topolojik özellikleri çıkarılarak analiz edilmiştir. Sınıflandırma işlemi için destek vektör makineleri (DVM) kullanılmış ve koku tanıma için ortalama %95,78 SD, hoşlanma tanıma için ise %98,21 SD oranı elde edilmiştir (Xia vd., 2023).

Naser ve Aydemir tarafından koku hayaline dayalı BBA çalışması yapılmıştır. Yapılan çalışmada, EEG sinyalleri, portakal, karanfil, kekik ve nane gibi dört çeşit kokunun en hoş

ve en hoş olmayan kokularının hayal edilmesi sırasında beyin tepkilerini belirlemek için kullanılmıştır. Hilbert dönüşümü, Fast Walsh–Hadamard dönüşümü, bant gücü ve spektrogram özellikleri kullanılarak beyin tepkilerinin ayırt edilebilirliği test edilmiştir. k -en yakın komşu (k -EYK) sınıflandırıcısı ile yapılan test verileri bakımından 10 denek için sınıflandırma doğruluğu ortalaması %87,75 olarak elde edilmiştir (Naser & Aydemir, 2023).

Tat duyusu üzerine yapılan bir çalışmada, Hashida ve çalışma arkadaşları EEG sinyalleri aracılığıyla tatlı ve tuzlu tatların ayırımını incelemek amacıyla bir dizi deney gerçekleştirmişlerdir. Deneylerde katılımcılara üç farklı tat sunulmuştur: tatlı (sukroz), tuzlu (NaCl) ve tatsız su (kontrol). Çalışma, yaşları 23 ile 38 arasında değişen 8 sağlıklı katılımcı (3 kadın, 5 erkek) üzerinde yürütülmüştür. EEG verilerinden öznitelik çıkarma işlemi için adaptif Gabor dönüşümü (AGR) yöntemi kullanılmıştır. AGR, zaman-frekans analizi yoluyla sinyallerin detaylı incelenmesine olanak sağlamıştır. Ancak bu çalışmada yazarlar sınıflandırma işlemi yapmamış, sadece tatlı ve tuzlu tatlara ait EEG sinyallerinin zaman-frekans özelliklerini analiz etmişlerdir (Hashida vd., 2005).

Başka bir tat ile ilgili çalışmada, Park ve çalışma arkadaşları, tatların insan duygusal tepkileri üzerindeki etkilerini EEG verileri ile değerlendirmişlerdir. Bu çalışmada, katılımcılara sükröz çözeltisi, sütlü çikolata, tuzlu çözeltisi, hardal ve içme suyu gibi farklı tatlar sunulmuş ve bu tatların EEG ile izlenerek duygusal tepkileri nasıl tetiklediği incelenmiştir. Çalışmaya 7 sağlıklı katılımcı katılmış ve veriler Common Spatial Pattern (CSP) yöntemiyle işlenmiştir. Sınıflandırma için destek vektör makineleri (DVM) kullanılmış ve sonuç olarak, tat ile ilişkili duygusal tepkilerin SD ortalama olarak %70 rapor etmişler (Park vd.,2011).

Başka bir çalışmada, Crouzet ve arkadaşları farklı tatların (tuzlu, tatlı, ekşi ve acı) EEG sinyalleri aracılığıyla nasıl beyinde kodlandığını incelemişlerdir. Çalışmada 16 katılımcıdan EEG verileri toplanmış ve zaman çözünürlüklü çok değişkenli modelleme (MVPA) yöntemi ile öznitelik çıkarılmıştır. Sınıflandırıcı olarak L2 düzenlemeli lojistik regresyon kullanılmış ve tatları ayırt etmede ortalama %86 doğruluk elde edilmiştir (Crouzet vd.,2015).

Başka bir çalışmada Atzingen ve arkadaşları tarafından EEG'ye dayalı tat sınıflandırma işlemi gerçekleştirilmiştir. Yapılan çalışmada, tatlandırıcı olarak sukroz (şeker), sukraloz ve aspartam kullanılmıştır. Öznitelik çıkarımı ve sınıflandırma işlemi için derin öğrenme tabanlı Konvolüsyonel Sinir Ağı (CNN) kullanılmıştır. Ham EEG sinyalleri kullanılarak CNN'e giriş verilmiş ve sınıflandırma sonucunda dört sınıflı (sukroz, sukraloz,

aspartam ve su) bir sınıflandırma yapılmıştır. Çalışma, 11 sağlıklı katılımcı ile gerçekleştirilmiş ve CNN modeli, %82,3 SD elde edilmiştir (Atzingen vd., 2022).

Tat duyusunun incelenmesi bakımından Gao ve arkadaşları bir çalışma yapmışlardır. Yaptıkları çalışmada, temel tat duyularını tanımak amacıyla 6 farklı tat (boş, ekşi, tatlı, acı, tuzlu ve umami) kullanmışlardır. Öznitelik çıkarımı ve sınıflandırma işlemi için çok ölçekli konvolüsyonel sinir ağı (CNN) tabanlı EEG-MSRNet modeli geliştirilmiştir. EEG-MSRNet, EEG sinyallerinin farklı frekanslarda özelliklerini çıkarmak için çok ölçekli zamansal konvolüsyon ve çapraz kanal temsiliyi sağlamak için çok ölçekli mekânsal konvolüsyon kullanmaktadır. Çalışma, 6 katılımcı ile gerçekleştirilmiş ve 6 sınıflı bir sınıflandırma yapılmıştır. Önerilen yöntem, %49,95 doğruluk oranı ile temel tat duyularını tanımada yüksek performans göstermiştir (Gao vd., 2023).

Bu alandaki bir başka çalışmada, Yang ve arkadaşları tarafından çeşitli tat kalitelerinin (acı, tuzlu, ekşi ve tatlı) ve yoğunluklarının (düşük, orta ve yüksek) beyin üzerindeki etkilerini incelemek için EEG kullanarak gerçekleştirilmiştir. Kullanılan tat örnekleri arasında şeker ve glikoz (tatlı), kahve ve kinin (acı), sitrik asit (ekşi) ve tuz bulunmaktadır. Öznitelik çıkarımı için EEG sinyallerinin güç spektral yoğunluğu (PSD) analizi ve kaynak lokalizasyonu kullanılmıştır. Sınıflandırma için destek vektör makineleri (DVM) kullanılmış ve SD yüksek duyuşal yoğunluk seviyelerinde toplam 26 denek için ortalama %87,6 olarak rapor edilmiştir (Yang vd., 2023).

Diğer taraftan çok kanallı EEG tabanlı BBA sistemleri, sınıflandırma performansını iyileştirme (Abdullah & Faye, 2022), beynin farklı bölgelerinden daha fazla veri toplama (Figuerola-García vd., 2018), yüksek uzaysal çözünürlük elde etme ve nörolojik bozuklukların daha doğru tespiti ve izlenmesi amacıyla araştırmacılar tarafından tercih edilmektedir. Ancak, bu sistemlerin yüksek maliyet ve karmaşıklık, artan gürültü ve büyük veri hacmi nedeniyle işleme zorlukları gibi dezavantajları bulunmaktadır (Figuerola-García vd., 2018). Ayrıca, birçok durumda kullanılacak kanal sayısı ve kanalların uygun konumu hakkında nihai bir karara varılamamıştır. Dolayısıyla, BBA sistemlerinde özellikle sınıflandırma doğruluğu (SD) ve hesaplama karmaşıklığı açısından yüksek performans elde etmek için gereksiz kanalları ortadan kaldıracak kanal seçme yöntemlerinin geliştirilmesi gereklidir.

EEG tabanlı BBA sistemlerinde gereksiz kanalları elemek için çeşitli kanal seçimi yöntemleri kullanılmaktadır. Son yıllarda, ardışık ileri besleme ve geri besleme yöntemlerinin kullanımı oldukça yaygın hale gelmiştir. Bu konu ile ilgili olarak, Aydemir

ve arkadaşı tarafından yapılan çalışmada, BBA sistemlerinde etkili kanal seçimi için sağlam ve kişiye özgü ardışık ileri arama (RSS-SFSM) yöntemi önerilmiştir. Önerilen yöntem İki farklı EEG veri seti üzerinde test edilmiştir. Bunlardan birincisi, 29 sağlıklı bireyin sol veya sağ el açma ve kapama hayali (Dataset 1), diğeri ise 6 kanal kullanılarak kaydedilen BCI Competition 2003 dataset Ia (Dataset 2)'dır. Veri kümesi 1'de, ortalama sınıflandırma doğruluğu tüm kanallar kullanıldığında %57,93 iken, etkili kanallar kullanıldığında bu oran %80,35'e yükselmiştir. Böylece %22,42'lik bir doğruluk artışı sağlanmıştır. Veri kümesi 2'de ise, sınıflandırma doğruluğu tüm kanallar kullanıldığında %81,57 iken, etkili kanallar kullanıldığında %91,12'ye çıkmıştır, bu da %9,55'lik bir artış olduğunu göstermektedir. Her iki veri kümesi için ortalama doğruluk artışı %15,98 olarak hesaplanmıştır. Bu çalışmada veri kümeleri bir ve iki için işlem karmaşıklığı sırası ile %88,89 ve %54,16 oranında azaltmıştır. Bu yöntemle, daha az sayıda kanal kullanılarak daha yüksek doğruluk oranları elde edilmiş ve böylece işlem süresi ve hesaplama yükü önemli ölçüde azaltılmıştır (Aydemir & Ergün, 2019).

Lee ve arkadaşı tarafından motor hayali BBA için geliştirilmiş optimal EEG kanal seçimi (Generalized Optimal EEG Channels Selection) yöntemi önerilmiştir. Bu yöntem, EEG kanal seçiminde geliştirilmiş bir yaklaşım sunarak farklı bireyler için uygun EEG kanallarını belirlemeyi amaçlamaktadır. Bu çalışmada, BBA Competition IV 2a ve OpenBMI veri setleri kullanılmıştır. BBA Competition IV 2a veri seti, 22 kanaldan oluşmaktadır ve motor imgeleme görevlerini içermektedir. OpenBMI veri seti ise 62 kanaldan oluşmaktadır. Elde edilen OpenBMI veri setinde, 20 motor korteks kanalı kullanıldığında DVM sınıflandırıcısı ile ortalama doğruluk %67,3 iken, tüm 62 kanal kullanıldığında %65,7 sınıflandırma oranı elde edilmiştir. Önerilen geliştirilmiş EEG kanal seçimi yöntemi ile bu doğruluk oranı %78,5'e yükselmiştir. Bu yöntemle, kanal sayısı ortalama beş kanala düşürülmüştür, bu da kanal sayısında %91,94 oranında bir azalma sağlamaktadır (Lee & Lee, 2023).

Literatüre bakıldığında hem kanal sayısı hem de hayale dayalı veriler kullanılmıştır. Bu noktada koku, tat ve hayal verileri kullanılarak çoklu kanallar içerisinde seçim yapılması işlemleri hem hesaplama hem de karmaşıklık bakımından ciddi oranda süreci zorlaştırmaktadır. Ancak reel sonuçların alınması ve sistem doğruluğunun/güvenilirliğinin sağlanabilmesi bakımından bu üç veri üzerinde çalışmalar yapılmış ve yeni bir yöntem önerilmiştir.

Bu çalışmada, tüm kanalları kullanmak yerine en etkili kanalları tespit ederek konuya özgü bir yöntem önerilmiştir. Ayrıca, literatüre (ardışık ileri besleme ve geri besleme yöntemleri) kıyasla, bu çalışma ile çok daha iyi sınıflandırma doğruluğu elde edilmiştir. Bu yöntem sayesinde, sadece etkili kanallarla sınıflandırma doğruluğunu artırmakla kalmayıp, aynı zamanda hesaplama karmaşıklığı büyük ölçüde düşürülmüştür. Önerilen yöntemin sağlamlığını ve etkinliğini doğrulamak için üç tür EEG tabanlı veri seti kullanılmıştır. Bunlardan ilk veri kümesi tatma duyusuna dayalı, ikinci veri kümesi koku duyusuna dayalı, üçüncü veri kümesi el açma ve kapama hayaline dayalı EEG tabanlı veri kümeleridir. Tat duyusu ve el açma ve kapama hayaline dayalı veri kümeleri için Hilbert Dönüşümü (HT), koku duyusu veri kümesi için Dalgacık Paket Ayırıştırma (DPA) öznitelikleri kullanılmıştır. Tat veri kümesinde, DVM, *k*-EYK, DAA ve RO sınıflandırıcıları ile burun açık ve kapalı durumlarında test veri kümesinde sırasıyla beşer kişi için ortalama %82,5 ve %81,88 sınıflandırma doğruluğu (SD) elde edilmiştir. Koku veri kümesinde, burun açık durumunda beş kişi için ortalama %99,28 sınıflandırma doğruluğu (SD) elde edilirken, burun kapalı durumda beş kişi için test veri kümesinde ortalama %97,49 sınıflandırma doğruluğu (SD) elde edilmiştir. Üçüncü veri kümesinde, DVM sınıflandırıcı ile 29 denek için test veri kümesinde ortalama %81,56 sınıflandırma doğruluğu (SD) elde edilmiştir. Buna ek olarak hesaplama karmaşıklığı sırasıyla birinci, ikinci ve üçüncü veri kümeleri için sırasıyla %63,03, %89,09 ve %75 oranında azaltılmıştır.

2. YAPILAN ÇALIŞMALAR


Bu çalışmada, aşağıdaki bölümlerde ayrıntılı olarak tanımlanan üç veri seti üzerinde önerilen yöntem değerlendirilmiştir. Kullanılan veri setleri içerisinde tat ve koku veri kümeleri dolaylı olarak, hayale dayalı veri kümesi doğrudan BCI ile ilgilidir. Tat ve koku veri kümelerinde dışarıdan fiziksel olarak verilen uyarıcıların beyin fonksiyonlarında meydana getirdiği değişikliklerin EEG aktivitelerinin alınması ile ilgiliyken, hayale dayalı veri kümesinde doğrudan hayale dayalı EEG sinyallerini barındırmaktadır.

2.1. Tat Veri Kümesi

Bu tez çalışmasında tat verileri, 118E241 numaralı başarıyla tamamlanan TÜBİTAK 1001 projesinin etik kurul onayı alındıktan sonra nörolojik rahatsızlığı bulunmayan sağlıklı deneklerden Karadeniz Teknik Üniversitesi / Elektrik Elektronik mühendisliği bölümü öğrencilerden toplanmıştır. Bu deneye yaşları 19-32 arasında değişen 10 sağlıklı katılımcı (bay/bayan) katılmıştır. Deneyden önce, katılımcıların haklarını ve çıkarlarını korumak için gönüllü olduklarına dair yazılı rızası alınmıştır.


2.2. Deney Ortamı ve Diğer Bileşenleri

EEG verileri, Elektrik Elektronik mühendisliği bölümünde bulunan Micromed marka BrainQuick model cihaz ile EEG Araştırma Laboratuvarı'nda kaydedilmiştir. Bu cihaz ve ekipmanları Şekil 13'te gösterilmektedir.



Şekil 13. EEG sistemi, (a) Sistemin genel görünüşü, (b) Yükselteç, (c) İzolasyon katı, (d) Elektrot jeli, (e) Enjektör, (f) Elektrot şapkası

EEG elektrotları Uluslararası 10-20 Sistemi'ne göre olmak üzere sentral, temporal ve oksipital bölgelere yerleştirilmiştir. Bunun için Cz referans olmak üzere 19 elektrot kullanılacaktır. Elektrotların yerleşimleri ve isimleri Şekil 14'te gösterilmiştir.



Şekil 14. Elektrotların saç derisine yerleşim düzeni

Örnekleme frekansı 512 Hz seçilmiştir. Deneyler esnasında, birey rahat bir koltukta oturarak, elleri serbest bir şekilde önündeki masanın üstünde durarak ve kendisinden yaklaşık 1 metre uzaklıkta karşısındaki LCD monitöre bakmıştır. Deneyin denemelerinin başlaması ve bitirilmesi komutları bu ekran üzerinden hazırlanan yazılımla verilmiştir. Katılımcılar başını en fazla 24 saat öncesinden yıkamış, uykularını tam olarak almış şekilde deneye katılmışlardır. EEG kayıt sistemi verileri ASCII formatında bellekte tutmaktadır. Deneyden sonra EEG verileri ASCII formatında taşınabilir belleğe kaydederek EEG cihazının çalışması için kullanılan bilgisayardan alınmıştır. ASCII formatındaki verilerin MATLAB'da işlenebilmesine imkan verecek format dönüştürücü (ASCII'den .mat dosyasına) yazılım hazırlanmıştır.

2.2.1. EEG İşaretlerin Kaydı İçin Hazırlanan Bilgisayar Destekli Arayüz

Bu proje çalışmasında, tat deneyleri esnasında alınan işaretlerin kaydı için bilgisayar destekli arayüz hazırlanmıştır. Bu arayüzde öncelikle bilgisayar ekranında 5 saniyelik geri

sayım başlamakta geri sayım bittikten sonra tatma komutu “TAT” yazısı ile ekrana gelmekte ve katılımcıya o andan itibaren ağızına 1 mililitre sıvı tat sprej ile püskürtülüyor ve bu sıvıyı 2,5 saniye tatmasını isteniliyor. Daha sonra “rahatla” yazısı ekranda yazdırılmakta ve katılımcı için 15 saniyelik dinlenme zamanı verilmiştir. Tat deneyine ait evreler Şekil 15’te gösterilmektedir.



Şekil 15. Tat için hazırlanan bilgisayar destekli arayüz evreleri a) geri sayımın başlaması, b) geri sayımın sonlanma aşaması, c) tatma komutunun ekranda belirmesi, d) rahatlama aşamasına geçiş

Kayıt işlemi öncesinde, sırasında ve sonrasında dikkate alınması gereken temel noktalar şunlardır:

1. Elektrotların Yerleşimi ve İletkenlik Kontrolü: Elektrotların saç derisine doğru şekilde yerleştirildiğinden ve iletkenliğin jel kullanımı ile sağlandığından emin olunmalıdır. Bu işlem, cihazın "elektrot empedansını kontrol et" (check the electrode impedance) fonksiyonu ile gözlemlenebilir. Güvenilir ve yüksek sinyal-gürültü oranına (SNR) sahip veriler elde edebilmek için elektrot dirençlerinin birbirine yakın olması kritik öneme sahiptir. Elektrot empedansı 20 k Ω 'un altında olmalıdır.

2. Şebeke Gürültüsünün Azaltılması: Kaydedilen verilere şebeke gürültüsünün karışmaması için, kullanılan yazılımın "çentik filtresi" (notch filter) özelliği aktif edilmelidir.


3. Elektrot Montaj Seçimi: Kayıt öncesinde, hangi elektrot yerleşim düzeninin kullanılacağı belirlenmelidir.

4. Veri Kayıt İşlemi: EEG verilerinin kaydedilmesi "Kaydet" komutu ile başlatılır ve kayıt işlemi sona erdirildiğinde "Kaydetmeyi durdur" (stop recording) fonksiyonu kullanılır.

5. Ekipman Temizliği: Kayıt işlemleri tamamlandıktan sonra, kullanılan tüm ekipmanların (şırınga, elektrotlar, elektrot başlığı vb.) temizliği ihmal edilmemelidir. Temizlik yapılmadığı takdirde, elektrotlara uygulanan jel kuruyabilir ve elektrotların verimli çalışmasını engelleyebilir.

2.2.2. EEG Verilerinin Kaydedilmesi ve Veri Seti Tanıtımı

Bu çalışmaya yaşları 19 ile 32 arasında değişen 10 sağlıklı gönüllü katılımcı (bay/bayan) dahil edilmiştir. Katılımcılar, Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü öğrencileri arasından gönüllülük esasına dayalı olarak seçilmiştir. Gönüllülükleri talep edilmeden önce, yapılan araştırma ve deneyin tüm detayları kendilerine kapsamlı bir şekilde açıklanmıştır. Deneyler, katılımcıların rahat bir koltukta oturdukları, ellerini önlerindeki masanın üzerine serbestçe yerleştirdikleri ve yaklaşık 1 metre mesafedeki bir LCD ekrana baktıkları bir düzen içinde gerçekleştirilmiştir. Deney oturumunu gösteren görsel Şekil 16'da sunulmaktadır.



Şekil 16. EEG verilerinin tat alma işlemi sırasında kaydedilme düzeni: 1) LCD ekran, 2) Tatma sırasında kullanılan sprey, 3) EEG şapkası, 4) EEG cihazı, 5) EEG kayıt cihazı ve ekranı

Deneye başlamadan önce, gönüllü katılımcılara yaş, cinsiyet, açlık/tokluk durumu gibi kişisel parametreleri içeren ve deney sonrasında hangi tat ve kokulardan hoşlandıklarını belirten kısa bir anket uygulanmıştır. Bu anketin amacı, söz konusu kişisel parametrelerin

kaydedilen EEG verileri üzerindeki olası etkilerini incelemektir. Katılımcılara ait anket sonuçları ve diğer demografik bilgiler burun açık ve kapalı durumlarında sırası ile Tablo 1 ve 2'de sunulmuştur. Katılımcıların hiçbiri nörolojik bir rahatsızlığa sahip değildir ve daha önce nörolojik bir ilaç kullanmamıştır. Ayrıca, katılımcılardan deneylere tok karnına katılmaları istenmiştir. Bu önlem, tat duyularının optimal düzeyde çalışmasını sağlamak amacıyla tıp hekiminin tavsiyesine uygun olarak alınmıştır.

Tablo 1. Tat deneylerinde gönüllü bireyler ile yapılan anket sonuçları (burun açık)

Denek	Yaş	Aç/Tok	Hoşlandığı Tat	Hoşlanmadığı Tat
D1	21	Tok	Portakal	Kekik
D2	24	Tok	Portakal	Kekik
D3	20	Tok	Portakal	Kekik
D4	30	Tok	Portakal	Kekik
D5	28	Tok	Nane	Karanfil

Tablo 2. Tat deneylerinde gönüllü bireyler ile yapılan anket sonuçları (burun kapalı)

Denek	Yaş	Aç/Tok	Hoşlandığı Tat	Hoşlanmadığı Tat
D1	21	Tok	Portakal	Kekik
D2	27	Tok	Portakal	Kekik
D3	32	Tok	Nane	Karanfil
D4	20	Tok	Portakal	Kekik
D5	23	Tok	Portakal	Kekik

Katılımcılar saçlarını en fazla 24 saat öncesinden yıkamış ve uykularını tam olarak almış şekilde deneye katılmışlardır. Deneylerde sağlık bakanlığı onaylı portakal, nane, kekik ve karanfil maddelerin yağları kullanılmıştır. Yağlar %100 doğal olarak ve soğuk pres

yöntemi ile elde edilmiş katıksız saf yağlardır. Kullanılan ürünler Şekil 17’de gösterilmektedir.



Şekil 17. Kullanılan gıda maddeleri

Tada ait veriler 2 oturumda alınmıştır. Bu oturumların deneysel işleyişi şu şekilde yapılmıştır:

1. Oturum: Burun Kapalı iken tat almaya dayalı EEG verilerinin kaydedilmesi:

Bu oturumda yukarıda belirtilen 4 gıda maddesi püskürtme usulü ile kişinin diline gönderilmiştir. 4 maddeye ait püskürtme şişeleri Şekil 18’de gösterilmiştir.



Şekil 18. Püskürtme şişeleri

Her denemede 1 püskürtme yaklaşık 1 mililitredir. Bu oturumda kişinin burnu Şekil 19’da gösterilen burun mandalı ile koku alamayacak şekilde kapatılmıştır.



Şekil 19. Burun mandalı

Bu prosedür ile EEG işaretleri 2,5 saniye boyunca kaydedilmiştir. Her bir tada ait 40’ar kayıt alınmıştır, kayıtlar arası 15 saniye ara verilmiş ve bu süre içerisinde kişinin su ile ağzını çalkalaması istenmiştir. Tat alma deneyinin prosedürü şekil 20’de gösterilmiştir. Bu

oturumda da her kiři ile 4 seans gerekleřtirilmiř olup her seansta 40, toplam 160 tat rastgele olarak katılımcıya tattırılmıřtır.




řekil 20. Tat dayalı EEG kayıt prosedürü

2. Oturum: Burun açık iken tat almaya dayalı EEG verilerinin kaydedilmesi: birinci oturumda anlatılan deney prosedürü deneklerin burnu açık durumunda tekrarlanmıřtır. Her kiři ile toplam 160 deneme kaydı yapılmıřtır. Tat dayalı EEG sinyallerin alınmasından önce, sonrası ve esnasında ekilen fotoęraflar řekil 21’de gösterilmiřtir.



řekil 21. Deney öncesi sonrası ve esnasında ekilen fotoęraflar

Tat dayalı EEG verileri alındıktan sonra MATLAB’a aktarılmıřtır. Matlab programında portakal, nane, kekik ve karanfil maddelerin yaęlarına ait alınan EEG verileri izdirilmiřtir ve řekil 22’de gösterilmiřtir. řekil 22’de birinci deneęe ait 4 maddenin birer EEG sinyallerinin rastgele 160 denemeden ve seilen denemenin birinci kanallarından gösterilmiřtir. Burada her bir grafikte x ekseni zamanı, y ekseni ise iřaretin genlięini ifade etmektedir.



Şekil 22. EEG veri kümesinden rasgele seçilmiş EEG

2.3. Koku Veri Kümesi


Kokuya dayalı EEG verisi, İsviçre Federal Teknoloji Enstitüsü'nde Kroupi ve arkadaşları (Kroupi vd., 2014) tarafından beş sağlıklı erkek katılımcıdan toplanmıştır. Örnekleme frekansı 250 Hz. olup, 256 elektrot kafa derisi üzerinde uluslararası standart pozisyonlara yerleştirilmiştir. EEG sinyalleri, katılımcılar gözleri açık ve kapalı durumdayken dört kokuyu (Kedi otu, lotus çiçeği, peynir ve gül suyu) koklarken kaydedilmiştir. Koku veri setinde deneysel prosedür, Şekil 23'te gösterildiği gibi gerçekleştirilmiştir. Her bir durum (gözleri açık ve gözleri kapalı) için deney dört oturumdan oluşmaktadır. Her oturumda katılımcılar belirli bir kokuyu koklamış ve EEG sinyalleri kaydedilmiştir. Her bir deneme, 'kokla' komutu ile başlamaktadır. Sonra katılımcı, koku içeren şişeyi yaklaşık 2 saniye koklamıştır. Ardından 4 saniyelik bir dinlenme süresi verilmiştir. Bu protokol, aynı koku ile 20 ila 30 kez tekrarlanmış ve her seferinde bir deneme gerçekleştirilmiştir. Veri setinin yaklaşık yarısı eğitim ve geri kalanı test seti olarak rastgele seçilmiştir.



Şekil 23. Kokuya dayalı EEG kayıt prosedürü

2.4. Hayale Dayalı Veri Kümesi

Üçüncü veri seti, Shin ve arkadaşları (Shin vd., 2016) tarafından 29 sağlıklı kişiden toplanan veriler kullanılmıştır. Denekler, 1 Hz hızında bir topu tutarken sol (sınıf a) veya sağ (sınıf b) ellerini açıp kapama hayali kurduklarında veriler 1000 Hz örnekleme frekansında toplanmıştır. Daha sonra, veri 200 Hz'e alt-örnekleme yapılmıştır. Verileri kaydetmek için uluslararası 10-5 standardına göre otuz EEG elektrodu yerleştirilmiştir. Şekil 24'te, deney prosedürünü göstermektedir. Deney aşaması 3 oturumdan meydana gelmektedir. Her oturumun başında 60 saniyelik bir ara verilmiştir. Her deneme, ekranın ortasında sola veya sağa işaret eden siyah bir okla gösterilen 2 saniyelik görsel talimatla başlatılmıştır. Okun ardından kısa bir bip sesi, sol veya sağ el için motor becerinin gerçekleştirildiği görev periyodunun başladığını işaret etmiştir. Her deneme 15-17 saniyelik bir ara ile sona ermiştir. Her oturumda toplam 20 deneme olup ve sonuçta 3 oturumda 60 deneme kaydedilmiştir. 250 ms'lik kısa bir bip sesi, görev süresinin başlangıcını ve sonunu işaret etmiştir. Bu çalışmada denemelerin %50'si test için kullanırken geri kalan kısmı sınıflandırmanın eğitimi için kullanılmıştır.



Şekil 24. Hayale dayalı EEG kayıt prosedürü

2.5. Yöntem

2.5.1. Önerilen RAKS Yöntemi

EEG sinyalleri genel olarak çok kanallı bir sistem kullanılarak kafatasına yerleştirilen sensörler yardımıyla elde edilir. Ancak bu gereksiz bilgiye ve artan hesaplama karmaşıklığına yol açabilmektedir. Bu çalışmada, en etkili kanalları belirlemek ve ilgisiz olanları elemek için kişiselleştirilmiş (kişiden kişiye değişebilen) bir rastgele alt küme kanal seçim yöntemi (RAKS) önerilmiştir. Bu yöntem, literatürde en etkili özellikleri belirlemek için sıklıkla kullanılan Rastgele Alt Küme Özellik Seçimi yönteminden esinlenmiştir. Bu yöntem diğer yöntemlere kıyasla daha fazla boyut azaltımı sağladığını ve daha etkili

öznitelik seçimi yaparak sınıflandırma doğruluğunu artırdığını göstermiştir (SabbaghGol vd., 2024).

Önerilen yöntem, zaman içerisinde tekrarlar yaparak rastgele seçilen kanalların sınıflandırma doğruluğunu hesaplamaktadır. Bu aşamadan sonra kanalların sınıflandırma doğruluğuna göre uygunluk değerlerini hesaplanır. Son olarak en yüksek uygunluk değerlerine sahip olan kanallar seçilir. Bu çalışma ile eğitim verisi üzerindeki en iyi kanallar bulunmaya çalışılmıştır ve ardından test verisi üzerinde test edilmiştir. Böylece güncellemelere dayalı tekrarlar yaparak en iyi altküme kanalını bulmaya çalışmaktadır. Her bir iterasyon sırasında (önerilen RAKS algoritması ile) aşağıdaki adımlar gerçekleştirir:

İlk adımda düzgün dağılım ile n taneli kanaldan oluşan bir altküme kanalı seçilmiştir. Sonra seçilen altküme kanal ile sınıflandırma işlemi yapılır ve ikinci adımda kriter fonksiyon rastgele seçilen altküme kanalı için hesaplanır. Üçüncü adımda seçilen alt küme kanalı için uygunluk değeri hesaplanır ve sonra altküme kanalın uygunluk değerlerinin güncellenmesi yapılır. Bu güncelleme işlemi her tekrarda yapılarak her bir kanalın sınıflandırma performansında katılım oranını belirler. Uygunluk değeri Denklem (1)'de verilmiştir. Bu denklemde altküme kanalın uygunluk değeri r_x , i . iterasyondaki kriter fonksiyon değeri c_i , önceki iterasyonlardaki kriter fonksiyonların ortalaması ise $E\{C\}$ ile gösterilmiştir.

$$r_j = r_x + c_i - E\{C\} \quad (1)$$

$$P(r_j > r_{rand}) \geq \delta, \forall f_j \in B, F \quad (2)$$

$$P(r_j > r_{rand}) = \frac{1}{\sigma_g \sqrt{2\pi}} \int_{-\infty}^{r_j} \exp\left(-\frac{(x - \mu_g)^2}{2\sigma_g^2}\right) dx \quad (3)$$

Denklem (1), (2) ve (3)'ün parametreleri şunlardır:

- r_j : Gerçek bir alt küme kanalın uygunluk değeri.
- r_{rand} : Rastgele sanal bir kanalın uygunluk değeri.
- δ : Kullanıcı tarafından belirlenen olasılık eşiği.
- f_j : Rastgele seçilmeyen belirli bir kanal.
- $B \subseteq F$: En iyi kanalların alt kümesi.
- σ_g : Sanal (sahte) kanalların uygunluk değerlerinin standart sapması.
- μ_g : Sanal kanalların uygunluk değerlerinin ortalaması.

Denklem (2) ve (3), gerçek kanalların, sanal (sahte) kanallara göre ne kadar daha iyi performans gösterdiğini belirlemek için kullanılır. r_{rand} değeri sahte kanalların uygunluk değerlerinin normal dağılımı olarak modellenir ve bu modelle gerçek kanalların uygunluk değerleri karşılaştırılır. Amaç, belirli bir olasılık eşiğinin (δ : **delta**) üzerindeki, seçilen gerçek kanallardan en iyi performans gösterenleri seçmektir.

Kanal seçimi, sınıflandırma algoritmalarının performansını optimize etmede kritik bir rol oynar. Zaman içinde, görevle ilgili ve yararlı olan kanallar, yüksek katılım oranları ve uygunluk değerleri gösterirken, etkisiz kanallar daha düşük uygunluk değerleri sergileyecektir. Nihai amaç, uygunluğu en yüksek olan kanalların belirlenmesi ve seçilmesidir. Ancak, bu süreçte bazı zorluklar ortaya çıkmaktadır. İlgisiz veya gürültülü kanallar, görevle ilgili kanallarla birlikte seçildiğinde, yüksek uygunluk değerleri gösteriyor gibi görünebilirler. Ne var ki, bu kanallar sınıflandırma performansını iyileştirmez; aksine, sadece işlem karmaşıklığını artırarak verimliliği düşürürler. Bu sorunu çözmek amacıyla, rastgele oluşturulan (sahte) kanallar kullanılmaktadır. Sahte kanallar, işlevsel açıdan hiçbir etkiye sahip değildir ve yalnızca gerçek kanalların uygunluk değerlerini belirlemek için bir referans noktası oluştururlar. Gerçek kanalların uygunluk değerleri belirlendikten sonra, sahte kanallara da aynı uygunluk değerleri atanır. Bu yöntem, yüksek uygunluk değerine sahip en iyi kanal alt kümesinin seçilmesine yardımcı olur. Kanal seçimi sürecinin son aşamasında, sahte kanalların yüksek uygunluk değerlerine sahip kanalların normal dağılımının dışına çıkma olasılığı değerlendirilir. Bu çalışmada, sahte kanalların normal dağılımının dışında kalma olasılığı %99'u aşan yüksek uygunluk değerlerine sahip kanallar seçilmiştir. Bu, sahte kanalların belirli bir güven düzeyi içinde yer aldığı ve bu nedenle seçilen gerçek kanalların güvenilir olduğu anlamına gelmektedir.

Kanal uygunluğu, bir kanalın sınıflandırma görevine ne kadar katkıda bulunduğunu belirleyen bir ölçüttür. Yüksek uygunluk değerine sahip kanallar, sınıflandırma algoritmasının doğruluğunu artırma potansiyeline sahiptir. Ancak, uygunluk değerlerinin belirlenmesi sürecinde, sadece bireysel kanalların değil, kanallar arasındaki etkileşimlerin de dikkate alınması gerekmektedir. Sahte kanalların kullanımı, kanal uygunluğunun belirlenmesinde önemli bir yeniliktir. Sahte kanallar, tamamen rastgele seçilir ve gerçek kanallarla aynı koşullarda değerlendirilir. Bu yaklaşım, sahte kanalların uygunluk değerlerinin, gerçek kanalların uygunluk değerleriyle karşılaştırılabilir olmasını sağlar. Sahte kanalların uygunluk değerleri, gerçek kanalların uygunluk değerleri için bir temel

oluşturur. Böylece, gerçek kanalların uygunluk değerleri daha doğru bir şekilde değerlendirilebilir.

Son aşamada, sahte kanalların uygunluk değerleri analiz edilir. Bu analiz, sahte kanalların normal dağılımının dışına çıkma olasılığını değerlendirir. Eğer sahte kanalların uygunluk değerleri, normal dağılımın dışında kalıyorsa, bu kanalların uygunluk değerleri güvenilir olarak kabul edilmez. Bu nedenle, sahte kanalların normal dağılımının dışında kalma olasılığı %99'u aşan yüksek uygunluk değerlerine sahip kanallar seçilir. Bu seçim kriteri, kanal uygunluğunun belirlenmesinde yüksek bir güven düzeyi sağlar. Bu metodoloji, sınıflandırma algoritmalarının performansını artırmak için etkili bir araçtır. Görevle ilgili ve yararlı kanalların seçilmesi, sınıflandırma doğruluğunu artırırken, ilgisiz ve gürültülü kanalların işleme dahil edilmemesi, işlem karmaşıklığını azaltır. Sonuç olarak, sahte kanalların kullanımı, kanal uygunluğunun belirlenmesinde önemli bir yenilik sunar ve sınıflandırma performansını optimize etmek için etkili bir yöntem olarak öne çıkar. Önerilen yöntem aşamalı olarak aşağıdaki işlemleri yapmaktadır;

1. n taneli kanaldan oluşan bir altküme kanalı seçilir,
2. Kriter fonksiyon rastgele seçilen altküme kanalları için hesaplanır,
3. Seçilen alt küme kanalı için uygunluk değeri hesaplanır,
4. Kanalların uygunluk değerlerinin güncellenmesi yapılır,
5. Sahte kanalların yüksek uygunluk değerlerine sahip kanalların normal dağılımının dışına çıkma olasılığı değerlendirilir,
6. Sonuç değerleri döndürülür.

2.5.2. Sıralı İleri Kanal Seçme Yöntemi

Sıralı İleri (Sİ) yöntemi, kanal seçimi sırasında en uygun kanal alt kümesini belirlemek için kullanılan aşamalı bir yaklaşımdır. Bu yöntemde, başlangıçta boş bir kanal seti ile başlanır ve her adımda sınıflandırma doğruluğunu en fazla artıran kanal mevcut kümeye eklenir. Her ekleme sonrasında sınıflandırma performansı değerlendirilir ve en uygun kombinasyon belirlenene kadar işlem tekrarlanır. İleri seçim yöntemi, özellikle EEG gibi çok sayıda kanalın bulunduğu veri setlerinde, gereksiz kanalları elimine ederek işlem maliyetini azaltmada önemli bir rol oynar. Motor imgeleme (MI) EEG sinyallerinde bu yöntem sıkça tercih edilmektedir. Motor imgeleme görevleri sırasında belirli beyin bölgelerinden gelen sinyaller analiz edilerek bilgi taşıyan kanallar seçilir. İleri seçim

yöntemi, genellikle karşılıklı bilgi (mutual information) gibi ölçütlerle desteklenir ve özellik çıkarma adımlarıyla birleştirildiğinde sınıflandırma hatalarını azaltarak modelin genel doğruluğunu artırır (Kumar vd., 2017).

2.5.3. Geriye Dönük Kanal Seçme Yöntemi

Geriye dönük eleme (GDE) yöntemi, başlangıçta tüm kanalların kullanıldığı bir set ile başlar ve her adımda, sınıflandırma doğruluğuna en az katkı sağlayan kanal çıkarılarak işlem sürdürülür. Bu yöntem, özellikle büyük veri setlerinde daha az bilgi taşıyan kanalları belirlemek ve hesaplama maliyetini düşürmek amacıyla yaygın olarak kullanılır. Geriye dönük eleme, sınıflandırma doğruluğunu artırırken hesaplama maliyetlerini azaltmak gerektiğinde oldukça etkilidir. İlk aşamada tüm kanalların dahil edilmesiyle başlar ve her adımda sınıflandırma doğruluğuna en az katkı sağlayan kanallar aşamalı olarak çıkarılır. Özellikle motor imgeleme EEG sinyallerinde, gereksiz kanalların çıkarılmasıyla daha küçük ve optimize edilmiş bir kanal kümesi elde edilir. Bu yöntem, farklı türev yöntemlerle de sıkça uygulanmaktadır (Alotaiby vd., 2015). Tang ve arkadaşlarının (2022) yaptığı çalışmada, SBFS (Sequential Backward Floating Search) yöntemi kullanılarak motor imgeleme verilerinde daha az sayıda kanal ile sınıflandırma doğruluğunun artırıldığı gösterilmiştir (Tang vd., 2022).

2.6. Öznitelik Çıkarma Yöntemleri

Öznitelik çıkarma sınıflandırma performansını doğrudan etkilemektedir. Bu işlem, örüntü tanıma ve makine öğrenmesi uygulamalarında önemli bir rol oynamaktadır. Etkin öznitelik çıkarma yöntemleri sinyallerdeki önemli ve ayırt edici özelliklerin belirlenmesine yardımcı olur ve veri işleme karmaşıklığını azaltmaktadır (Naser & Aydemir, 2023).

2.6.1. Hilbert Dönüşümü Öznitelikleri

Hilbert Dönüşümü (HD), ilk olarak Hilbert tarafından 1905'te Riemann-Hilbert problemi kapsamında ortaya konmuştur ve minimum faz yanıtını elde etmek amacıyla spektral analizlerde kullanılır (Chen & Hao, 2017). HD, biyomedikal sinyallerin dinamik yapılarında önemli bir yöntem olarak öne çıkar. Bu tür sinyaller durağan olmadığından, HD frekansın zamanla nasıl değiştiğini faz bilgisi üzerinden temsil ederek sinyallerin analizini

kolaylaştırır (Gupta vd., 2020). Hilbert dönüşümü, gerçek ve hayali bileşenleri ilişkilendirerek frekans yanıtlarının anlaşılmasında kritik bir rol oynar. Dijital sinyal işlemeye katkıları arasında, büyüklük verilerinden faz bilgisinin yeniden yapılandırılması ve çeşitli sinyal modülasyon analizleri önemli yer tutmaktadır (Matsuki vd., 2023).

Hilbert Dönüşümü, sinyal işlemede zaman-frekans analizleri yapmak için kullanılan güçlü bir tekniktir. Bu yöntem, özellikle EEG sinyallerinin analizinde öne çıkmaktadır. HD, durağan olmayan sinyallerin spektral özelliklerini analizi ve yorumlaması için sıkça kullanılan bir yöntemdir (Peng vd., 20220) (Agarwal & Kumar, 2024). Hilbert dönüşümündeki temel prensip sinyalin genliğini değiştirmeden sadece fazını $\pi/2$ kaydırmaktır. Bu matematiksel dönüşümün tanımına göre $Q(t)$ giriş işaretinin $h(t) = 1/\pi t$ ile konvolüsyon sonucu hesaplanarak çıkış $\hat{Q}(t)$ sinyali elde edilmiştir ve Denklem 4'te gösterilmiştir.

$$HT\{Q(t)\} = \hat{Q}(t) = Q(t) * \frac{1}{\pi t} \int_{-\infty}^{\infty} \frac{Q(\tau)}{t - \tau} d\tau \quad (4)$$

Bu formülde, HT, Hilbert dönüşümünü ifade etmektedir. $Q(t)$, zamanla değişen bir sinyaldir ve Hilbert dönüşümü bu sinyale uygulandığında $\hat{Q}(t)$ elde edilir. Formülde bulunan integral, $Q(t)$ sinyalini $1/\pi t$ fonksiyonu ile konvolüsyona sokarak, sinyalin fazını 90 derece kaydırır ve bu sayede yeni bir bileşen oluşturur. Dönüştürülmüş sinyalin gerçek kısmı a , sanal kısmı ise b ile temsil edilmektedir.

$$\hat{Q}(t) = a(\hat{Q}(t)) + b(\hat{Q}(t)) \quad (5)$$

Bu çalışmada $\hat{Q}(t)$ işaretinin gerçek kısmının ortalama değerleri bir özellik olarak kullanılmış ve Denklem 6'da verilmiştir.

$$HTF = \frac{\sum_{i=1}^N a(\hat{Q}_i(t))}{k} \quad (6)$$

Burada k , gerçek kısmının uzunluğudur.

2.6.2. Hızlı Walsh Hadamard Dönüşümü

Hızlı Walsh-Hadamard (HWHT) Dönüşümü, sinyal işleme uygulamalarında kullanılan dönüşüm türlerinden biridir (Saraiva vd., 2020). Bu dönüşüm, ortonormal ve kayıpsız bir yapıya sahiptir. HWHT algoritması, uygulamayı basitleştirip hesaplama yükünü minimize eden bir blok diyagonal yapı kullanarak, çarpma ve toplama işlemlerinde önemli azalmalar sağlar (Göker & Tosun, 2023). Bu dönüşümün temel özelliği, frekans bileşenlerinin yalnızca iki değer (+1, -1) almasıdır. HWHT genellikle $2^m \times 2^m$ boyutlarındaki Hadamard matrislerine uygulanır. Hadamard matrisi W_m , aşağıdaki gibi satır ve sütun transpozisyonları ile düzenlenir:

$$W_m = \frac{1}{\sqrt{2}} \begin{bmatrix} W_{m-1} & W_{m-1} \\ W_{m-1} & -W_{m-1} \end{bmatrix} \quad (7)$$

Bu tanımlamada, rekürsif işlemin başladığı nokta olan bitiş koşulu ise $W_0 = 1$ şeklindedir. Bu çalışmada, her EEG denemesi 1280 örnek içerdiğinden, m değeri $1280 \leq 2^m$ şartına göre $m = 11$ olarak seçilmiştir. Bir giriş sinyali S 'nin HWHTC katsayıları (HWHTC) aşağıdaki gibi hesaplanır:

$$HWHTC = W_m \cdot S \quad (8)$$

Bu çalışmada S bir EEG denemesini temsil etmektedir. Bir sonraki adım $HWHTC$ 'nin tekil değer ayrışımı (TDA) aşağıdaki gibi $HWHTC \cdot HWHTC^T$ özdeğerlerin karekökü alınarak elde edilmiştir:

$$HWHTC_{tda} = \sqrt{\text{eigen}(HWHTC \cdot HWHTC^T)} \quad (9)$$

Burada **eigen**, özdeğerleri bulan fonksiyonu temsil etmektedir. Bu çalışmada $HWHTC_{tda}$ değerleri öznitelik olarak kullanılmıştır.

2.6.3. Bant Gücü Öznitelikleri

Bant gücü (BG) özneliğin elde edilmesi, bir sinyalin belirli bir frekans aralığında bant geçiş filtresi uygulanarak işlenmesi, ardından filtrelenmiş sinyalin karelenmesi ve son olarak

bu işlemde elde edilen sonuçların belirli bir zaman dilimi boyunca ortalamasının alınmasıyla gerçekleştirilir (Naser & Aydemir, 2023). BG öznitelikleri, özellikle motor hayali gibi zihinsel görevlerin sınıflandırılmasında oldukça etkilidir. Zihinsel aktiviteler ile belirli EEG frekans bantlarındaki güç değişimleri arasında bağlantılar kurulabilmektedir (Uktveris & Jusas, 2015). Sinyal analizinde en popüler ve en iyi bilinen öznitelik çıkarma yöntemlerinden biri olan hızlı Fourier dönüşümü (HFD) uygulayarak BG öznitelikleri hesaplanmıştır. BP özniteliklerini elde etmek için öncelikle HFD katsayılarını bu şekilde hesaplanmıştır:

$$S(k) = \frac{1}{N} \sum_{n=0}^{N-1} S(n) e^{-\frac{jnk\pi}{N}}, \quad k = 0, 1, 2 \dots N-1 \quad (10)$$

Burada $S(n) = \{s(1), s(2), \dots, s(N)\}$ bir EEG sinyali ve N bir EEG denemesinin uzunluğudur. Ardından BP Denklem 11’de hesaplanmıştır:

$$BG|_L^H = \sum \|S(k)_L^H\|^2 \quad (11)$$

Burada $S(k)_L^H$, alt kesim frekansı (L) ve üst kesim frekansı (H) arasındaki HFD katsayılarını belirtmektedir.

2.6.4. Spektrogram Öznitelikleri

Spektrogram öznitelikleri, EEG sinyallerinden öznitelik çıkarmak için kullanılan güçlü bir tekniktir. Spektrogram, zaman-frekans düzleminde bir sinyalin enerji dağılımını temsil eden bir görüntüdür (Yuan & Cao, 2018) (Ramos-Aguilar vd., 2020). Bir EEG denemesinin spektrogram görüntüsü, Denklem 10’da olduğu gibi HFD kullanılarak hesaplanır ve matris formunda şu şekilde yazılabilir:

$$\hat{S} = \bar{M}S \quad (12)$$

Burada $\bar{M}$, M ’nin karmaşık eşleniğidir ve M , $m \times m$ boyutunda bir Fourier matrisidir:

$$M = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & e^{j\frac{2\pi}{N}} & e^{j\frac{4\pi}{N}} & \dots & e^{j\frac{2\pi(N-1)}{N}} \\ 1 & e^{j\frac{4\pi}{N}} & e^{j\frac{8\pi}{N}} & \dots & e^{j\frac{4\pi(N-1)}{N}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1e^{j\frac{2\pi(N-1)}{N}} & 1e^{j\frac{4\pi(N-1)}{N}} & \dots & e^{j\frac{2\pi(N-1)^2}{N}} \end{bmatrix} \quad (13)$$

S sinyalinin pencere boyutu P ile hesaplanan spektrogramı, $\bar{D}$ matrisidir ve bu matrisin sütunları, D 'nin sütunlarının HFD'sını içerir. Bu nedenle


$$\bar{D} = \bar{M}D \quad (14)$$

$$D = \frac{1}{p} M \bar{D} \quad (15)$$


Burada $\hat{D}$ satırları frekansı, sütunları ise zamanı gösterir. Bu çalışmada pencere boyutu ve örtüşme miktarı sırasıyla 60 ve 35 olarak deneysel olarak belirlenmiştir. Farklı tatlara ait spektrogram görüntüleri Şekil 25'te gösterilmiştir. Renkli görüntülerden gri seviyeli görüntülerin piksel ortalamaları, özellik olarak kullanılmıştır. Farklı tatlara ait gri seviyeli görüntüleri Şekil 26'da gösterilmiştir. Piksel ortalamaları şu şekilde hesaplanmıştır:

$$PO = \frac{1}{B} \sum_{i=1}^B P_i \quad (16)$$

Bu denklemde P_i , D matrisinin i . piksel değerini, B ise toplam piksel sayısını gösterir. Burg yöntemi tabanlı spektrogram görüntülerinden elde edilen piksel ortalamaları, EEG sinyallerini temsil etmek için kullanılmıştır. Bu tez çalışmasında belirtildiği gibi, her tat EEG denemesi 2,5 saniye süreyle 17 elektrot ile kaydedilmiştir (512 Hz örnekleme frekansı ile). Bu nedenle, her deneme için 12-15'inci Denklemleri kullanılarak 17 spektrogram görüntüsü elde edilmiştir ve her spektrogram görüntüsünün ortalama piksel değerleri hesaplanmıştır. Son olarak, her tat sınıfı için 40×17 boyutunda bir özellik matrisi elde edilmiştir.



Şekil 25. Farklı tatlılara ait spektrogram görüntüsü



Şekil 26. Farklı tatlarla ait gri seviyeli görüntüsü


2.6.5. Dalgacık Paket Ayrıştırma

Dalgacık Paket Ayrıştırma (DPA), sinyallerin işlenmesinde ve analizinde kullanılan güçlü bir tekniktir ve son zamanlarda EEG sinyallerinin analizi için yaygın olarak kullanılmaktadır (Zhang vd., 2017) (Ting vd., 2008). Dalgacık Paket Ayrıştırma, ayrık dalgacık dönüşümünün (DWT) bir uzantısı olup, sinyalin farklı frekans bileşenlerini daha ayrıntılı bir şekilde analiz etmektedir. Bu dönüşüm, sinyalin hem düşük frekans hem de yüksek frekans bileşenlerine iteratif olarak ayrılmasını sağlar ve her frekans aralığında bu işlemi tekrarlamaktadır. Bu sayede, sinyalin çok çözünürlüklü bir temsili elde edilmektedir.

DWT işlemi sırasında sinyal, her seviyede yalnızca yaklaşık katsayılar kullanılarak analiz edilmektedir. Buna karşılık, DPA bir ikili ağaç yapısı oluşturarak hem ayrntı hem de yaklaşık katsayıların ayrıştırılması yapılır ve sinyalin daha kapsamlı ve ayrıntılı bir analizine imkân tanımaktadır (Zheng vd., 2023). İki seviyeli DPA, Şekil 27’de gösterilmiştir. Burada x giriş sinyalini, A_j yaklaşık katsayıları ve D_j detay katsayılarını temsil etmektedir. Bu yöntem x sinyali alçak ve yüksek geçiren filtreden geçirdikten sonra alt örnekleme tabi tutmaktadır. Bu işlemler istenilen m seviyeli bir ayrıştırma için 2^m katsayı seti üretmektedir. Her seviyedeki alt bant sinyallerin DPA ile elde edilen A_j ve D_j katsayıları Denklem (17) ve (18)’de verilmiştir. Denklem 17 ve 18’de; 1 ’den 2^m ’ye kadar i değerleri ve j ile temsil edilen DPA seviyesi için h yüksek geçiren filtreyi, l ise alçak geçiren filtreyi temsil eder.

$$A_j[i] = \sum_{k=0}^{\infty} x[k] l[2i - K] \quad (17)$$

$$D_j[i] = \sum_{k=0}^{\infty} x[k] h[2i - K] \quad (18)$$



Şekil 27. İki seviyeli DPA ağaç yapısı

2.7. Sınıflandırma

Bu tez çalışmasında, tat, koku ve motor hayaline dayalı olmak üzere üç farklı veri seti sınıflandırılmıştır. Tat verilerinin toplanmasında 10 kişi katılım sağlamıştır. Bu veri setinde, her bir denek dört farklı tadı deneyimleyerek, her tada ait eşit sayıda olmak üzere toplamda 160 deneme kaydedilmiştir. Bu çalışmada, tatlar ikili kombinasyonlar halinde sınıflandırılmıştır. İlgili ikili kombinasyonlar şu şekildedir:

1. Kombinasyon: S1-S2
2. Kombinasyon: S1-S3
3. Kombinasyon: S1-S4
4. Kombinasyon: S2-S3
5. Kombinasyon: S2-S4
6. Kombinasyon: S3-S4

Bu çalışmada, S1 portakal, S2 nane, S3 kekik ve S4 karanfil yağlarının tatlarını temsil etmektedir. Böylece, her kişi için her bir yöntem ile 6 farklı sınıflandırma sonucu elde edilmiştir. Sınıflandırma işlemi sırasında, eğitim ve test veri setleri eşit şekilde kullanılmıştır. Tada dayalı elde edilen EEG sinyaller Destek vektör makineleri (DVM), K-en yakın komşuluk (k -EYK), Doğrusal ayırım analizi (DAA) ve Rastgele ormanlar (RO) sınıflandırma algoritmaları kullanılarak sınıflandırılmıştır.

Koku veri setinde, EEG sinyalleri katılımcılar gözleri açık ve kapalı durumdayken dört farklı kokuyu (valerian, lotus çiçeği, peynir ve gül suyu) koklarken kaydedilmiştir. Bu çalışmada, S1 valerian, S2 lotus çiçeği, S3 peynir ve S4 gül suyu kokularını temsil etmektedir. Koku veri setinde, her bir koku için 20 ila 30 deneme bulunmaktadır. Sınıflandırma aşamasında, test ve eğitim kümeleri yaklaşık olarak eşit şekilde bölünerek sınıflandırma gerçekleştirilmiştir. Bu veri seti 10 denekten elde edilmiştir ve bu tez çalışmasında her bir denek için 4 sınıflı sınıflandırma yapılmıştır. Kokuya dayalı EEG sinyaller, DVM sınıflandırma algoritması kullanılarak sınıflandırılmıştır.

Hayale dayalı EEG sinyalleri 29 denekten toplanmıştır. Bu çalışmada, deneklerden, bir topu tutarken sol (sınıf A) veya sağ (sınıf B) ellerini açıp kapama hayali kurlmaları istenmiştir. Bu EEG verileri ikili sınıflandırmaya tabi tutulmuştur. Her bir denekten, her bir sınıf için 30 deneme, toplamda 60 deneme elde edilmiştir. Sınıflandırma aşamasında, veri kümesi eşit şekilde eğitim ve test kümelerine ayrılarak değerlendirilmiştir. Hayale dayalı EEG sinyaller DVM sınıflandırma algoritması kullanılarak ikili sınıflandırma işlemi yapılmıştır.


2.7.1. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), 1995 yılında Vladimir Vapnik ve Corinna Cortes tarafından geliştirilmiştir. Bu algoritma, istatistiksel öğrenme teorisine dayanan ve sınıflandırma problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenme

yöntemidir. İlk başta ikili sınıflandırma problemlerini çözmek amacıyla geliştirilen DVM, zamanla çoklu sınıflandırma problemlerine de uyarlanmıştır (Zhang, 2012) (Saccá vd., 2018). DVM hem doğrusal hem de doğrusal olmayan veri kümeleri üzerinde çalışabilir. Doğrusal ayrılabilir verilerde en uygun hiper düzlemi bulurken, doğrusal olmayan verilerde ise çekirdek fonksiyonları (kernel functions) kullanılarak yüksek boyutlu uzayda sınıflandırma gerçekleştirilir (Bhuvaneswari & Kumar, 2013). DVM, Şekil 28'de gösterildiği gibi, iki sınıfı ayıran bir doğru (hiper düzlem) oluşturarak sınıflandırma yapar ve bu doğrunun, her iki sınıfın veri noktalarına maksimum uzaklıkta olması sağlanır. Sınır çizgileri, iki sınıfı ayıran orta sınırı ve her iki sınıfa en yakın olan kesikli çizgiler ise sınır düzlemlerini temsil eder. Sınır düzlemleri üzerindeki veri noktaları, destek vektörleri olarak adlandırılır. Başka bir deyişle, bu sınıflandırıcı, veri noktalarını en büyük marjini sağlayacak şekilde ayırarak sınıflandırma gerçekleştirir. DVM, eğitim verilerini kullanarak bu hiper düzlemi öğrenir ve test verilerinin hangi sınıfa ait olduğunu tahmin eder (Zhang, 2012). Sınıflandırma işleminde amaç, etiketi bilinmeyen bir test verisini doğru bir şekilde sınıflandırmaktır. Bu doğrultuda, iki sınıfı ayıran bir hiper düzlem oluşturulur. Hiper düzlemin her iki tarafındaki ± 1 aralığında kalan bölgeye "marjin" denir. Marjin ne kadar geniş olursa, sınıfların birbirinden ayrılması o kadar başarılı olur. Hiper düzlem, her iki sınıf için de Denklem 19'da verilen eşitsizlik koşulunu yerine getirecek şekilde yapılandırılır:

$$\hat{z} = \begin{cases} 0, & \omega^T \cdot g + s < 0 \\ 1, & \omega^T \cdot g + s \geq 0 \end{cases} \quad (19)$$

Bu denklemde, ω ağırlık vektörünü, g girdi vektörünü ve s sapmayı temsil eder. Bir test verisinin sonucu 0'dan küçükse, veri negatif sınıfa (örneğin, yuvarlak işaretli sınıfa), 0'dan büyükse ise pozitif sınıfa (kare işaretli sınıfa) daha yakın olduğu kabul edilir. Bu çalışmada, DVM'nin performansını artırmak amacıyla sigma parametresi her veri kümesi için rastgele alt örnekleme yöntemiyle ideal olarak seçilmiştir.



Şekil 28. DVM ile iki etiketli sınıflandırma örneğini göstermektedir


2.7.2. *k*-En Yakın Komşuluk

k-en Yakın Komşu (*k*-EYK) algoritması, denetimli öğrenmeye dayalı non-parametrik bir sınıflandırma algoritmasıdır. Algoritmanın temel prensibi, sınıflandırma yapılacak test örneğinin sınıfını, eğitim verisindeki en yakın komşuların sınıflarına dayanarak belirlemektir. *k*-EYK, hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Ancak, sınıflandırma problemlerinde daha yaygın olarak uygulanır. Algoritma, benzer veri noktalarının uzayda birbirine yakın bulunduğu varsayımına dayanır. *k*-EYK algoritmasında, test örneği ile eğitim verisi arasındaki mesafeler çeşitli mesafe ölçütleri kullanılarak hesaplanır. Bu mesafe ölçütleri, sınıflandırma sonucunun belirlenmesinde kritik bir rol oynar. Literatürde en yaygın kullanılan mesafe metriği Öklid mesafesi olmasına rağmen, Minkowski, Manhattan (Şehir Bloğu), Chebyshev, Kosinüs ve Korelasyon gibi farklı mesafe metrikleri de kullanılmaktadır (Syriopoulos vd., 2023) (Abu Alfeilat vd., 2019). *k*-EYK algoritmasının temel kavramları ilk olarak 1951 yılında Fix ve Hodges tarafından geliştirilmiş ve daha sonra 1967 yılında Cover ve Hart tarafından genişletilmiştir (Abu Alfeilat vd., 2019). Algoritma, bir veri noktasının sınıfını belirlemek için o noktanın en yakın komşuları olan *k* veri noktasının sınıflarına bakar. Algoritmanın temel varsayımı, benzer veri noktalarının uzayda birbirine yakın olduğu yönündedir.

Algoritmanın en önemli parametrelerinden biri olan K , test verisi sınıflandırılırken dikkate alınacak komşu sayısını ifade eder. K değeri çok küçük seçildiğinde, model aşırı uyum (overfitting) yapabilir ve gürültülü verilere duyarlı hale gelebilir. Buna karşılık, çok büyük k değerleri modelin yetersiz uyum (underfitting) göstermesine ve sınıf sınırlarının düzgün belirlenememesine yol açabilir. Bu nedenle, optimum k değerinin seçilmesi, sınıflandırma performansı açısından büyük önem taşır (Syriopoulos vd., 2023). Bu tez çalışmasında, uzaklık ölçütleri olarak Öklid, Kosinüs ve Korelasyon metrikleri kullanılmıştır. Elde edilen sonuçlar doğrultusunda, en iyi performansın Öklid mesafesi ile sağlandığı tespit edilmiştir. İki veri noktası arasındaki Öklid mesafesi, aşağıdaki formül ile hesaplanmıştır:

$$\text{ÖklidO}(e, t) = \sqrt{\sum_{i=1}^n (p_{ei} - p_{ti})^2} \quad (20)$$

Burada e ve t noktaları arasındaki Öklid mesafesi, her bir boyuttaki (özellik) farkın karesinin toplamının karekökü ile elde edilir. Şekil 29'da k -EYK algoritması için bir sınıflandırma örneği gösterilmiştir. Bu örnekte, mesafe ölçütü olarak Öklid Mesafesi (ÖM) kullanılmıştır. Sınıflandırma, $k = 3$ (düz çizgi ile gösterilen daire) ve $k = 5$ (kesikli çizgi ile gösterilen daire) komşular dikkate alınarak yapılmıştır. Her bir üçgen, iki özelliğe (x , y) sahip ve 1. sınıfa ait olan bir eğitim verisini temsil ederken; her bir kare, iki özelliğe sahip ve 2. sınıfa ait olan eğitim verilerini göstermektedir. Mavi daire, iki özelliğe sahip olup sınıfı bilinmeyen test verisini temsil etmektedir. k -EYK algoritması, bu test örneğinin sınıfını, en yakın komşular arasındaki mesafelere dayanarak tahmin etmektedir.



Şekil 29. k -EYK yöntemi için veri sınıflandırması

2.7.3. Doğrusal Ayrım Analizi

Doğrusal ayrım analizi (DAA), sınıflandırma problemlerini çözmek için Ronald A. Fisher tarafından 1936 yılında önerilmiştir. Fisher, DAA'ı çoklu sınıflar arasındaki farkı modellemek için yüksek boyutlu verileri, sınıfların en iyi şekilde ayrıldığı daha düşük boyutlu bir uzaya yansıtmak amacıyla geliştirmiştir (Balakrishnama & Ganapathiraju, 1998) (Garrett vd., 2003). DAA, her sınıfın verilerinin normal dağıldığını ve aynı kovaryans matrisine sahip olduğunu varsayar. Bu sayede, sınıflar arasında doğrusal karar sınırları oluşturarak verilerin en iyi ayrılmasını sağlar (Balakrishnama & Ganapathiraju, 1998) (Hasan vd., 2015).

DAA, doğası gereği doğrusal bir sınıflandırma tekniğidir çünkü sınıflar arasındaki karar sınırları doğrusal hiper düzlemler ile belirlenir (Balakrishnama & Ganapathiraju, 1998) (Garrett vd., 2003). DAA 'inde sınıflandırma işlemi, her sınıfın ortalaması ve kovaryansı hesaplandıktan sonra, test verilerinin saçılım matrislerinden elde edilen özvektörler kullanılarak daha düşük boyutlu bir uzaya yansıtılması ile yapılır. Test verileri, genellikle Öklid mesafesi kullanılarak, en yakın ortalama ile karşılaştırılır ve sınıflandırma gerçekleştirilir (Balakrishnama & Ganapathiraju, 1998) (Hasan vd., 2015). İkili sınıflandırma senaryosunda amaç, iki sınıfı en iyi ayıran optimal hiper düzlemi bulmak ve

sınıf dağılımları arasındaki mesafeyi en üst düzeye çıkarırken hatayı en aza indirmektir (Saa & Gutierrez, 2010) (Garrett vd., 2003). İki den fazla sınıflı bir problem durumunda, birkaç hiper düzlem kullanılır. Karar düzlemi matematiksel olarak şu şekilde temsil edilebilir:

$$g(x) = W^t x + W_0 \quad (21)$$

Burada W , ağırlık vektörü; x , giriş öznitelik vektörü ve W_0 , eşik değeridir. Girdi olarak sunulan öznitelik vektörü, $g(x)$ fonksiyonuna göre bir sınıfa atanır. Ağırlık vektörü W 'yi hesaplamak için kullanılan yöntemlerden biri şudur:

$$W = \sum_c^{-1} (\mu_1 - \mu_2) \quad (22)$$

Burada, (μ_i) , i sınıfının ortalamasını; $\Sigma_c = 1/2 (\Sigma_1 + \Sigma_2)$ matrisini ifade eder. Kovaryans matrisi şu şekilde hesaplanır:

$$\Sigma_c = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (23)$$

Ortalama ise şu şekilde hesaplanır:

$$\mu_c = \frac{1}{n} \sum_{i=1}^n x_i \quad (24)$$


Burada x , n adet öznitelik vektörü içeren bir matristir. Σ kovaryans matrisi ve μ ise öznitelik vektörlerinin ortalamasını gösterir.

2.7.4. Rastgele Ormanlar

Rastgele Ormanlar (RO), Leo Breiman ve Adele Cutler tarafından geliştirilmiş, yaygın olarak kullanılan bir makine öğrenmesi yöntemidir. Bu algoritma, birden fazla karar ağacının sonuçlarını birleştirerek daha doğru tahminler yapmayı hedefleyen bir topluluk yöntemidir. Hem sınıflandırma hem de regresyon problemlerinde kullanılan bu algoritma, yüksek boyutlu veri kümeleriyle çalışırken gösterdiği esneklik ve güvenilir tahmin yeteneği

sayesinde tercih edilmektedir (Ahmad vd.,2024) (Fraïwan vd., 2012). ROA'nın en önemli bileşenlerinden biri olan *torbalama* yöntemi, veriyi yeniden örnekleyerek birden fazla eğitim veri seti oluşturur ve her bir veri seti için bir karar ağacı inşa edilir. Bu süreçte, her ağacın eğitiminde veri kümesindeki tüm özellikler yerine rastgele seçilmiş bir alt küme kullanılır. Bu yöntem, ağaçlar arasındaki ilişkiyi minimize ederek modelin genelleme kabiliyetini artırır ve aşırı öğrenmeyi (overfitting) önler (Fraïwan vd., 2012). Geleneksel karar ağaçlarının tüm özellikleri dikkate almasına karşın, ROA yalnızca rastgele seçilen bazı özelliklerle karar verir (Wei vd., 2020) (Ahmad vd., 2024). ROA'da, belirlenmesi gereken önemli parametrelerden biri ağaç sayısıdır. Daha fazla ağaç genellikle modelin doğruluğunu artırır, ancak belirli bir noktadan sonra bu artış durur ve daha fazla ağaç eklemek hesaplama maliyetini gereksiz şekilde artırır (Ahmad vd., 2024). Bu tez çalışmasında, veri setleri için ağaç sayısı, çapraz doğrulama (cross-validation) yöntemi ile optimize edilmiştir. Sınıflandırma problemi bağlamında, örneğin EEG verilerinin analizinde, ROA çeşitli veri ve özellik alt kümeleri kullanarak her bir ağaç için ayrı sınıflandırma yapar. Her ağaç bir sınıf tahmini yapar ve tüm ağaçlar arasında en çok oy alan sınıf nihai sonuç olarak atanır. Bu çoğunluk oylama mekanizması, modelin varyansını azaltarak daha kararlı ve doğru tahminler elde edilmesini sağlar. Örneğin, EEG verilerinin sınıflandırılması üzerine yapılan çalışmalarda ROA, özellikle çoklu sınıflandırma sorunlarında yüksek doğruluk oranları elde ederek etkili bir performans göstermiştir (Edla vd., 2018). ROA'nın nihai çıktısı, karar ağaçlarından gelen tahminlerin oylanmasıyla belirlenir. Her ağacın ürettiği sınıflandırma sonucuna dayanan bu mekanizma, özellikle EEG verilerinin epilepsi nöbeti tespiti gibi karmaşık sınıflandırma problemlerinde üstün performans sergilemiştir (Ahmad vd., 2024).

Rastgele Orman Algoritmasının genel yapısı Şekil 30'da gösterilmektedir. Şekilde de görüldüğü üzere, her bir deneme için ilk olarak bir karar ağacı oluşturulmakta ve bu ağaçların her biri için öngörülen sınıf etiketleri hesaplanmaktadır. Elde edilen bu öngörülen etiketler, oylama yöntemiyle birleştirilir. Oylama sonucunda, en fazla oy alan sınıf nihai etiket olarak belirlenir.



Şekil 30. Rasgele Orman Algoritması genel yapısı

3. BULGULAR

Bu çalışmada, EEG sinyalleri için öznitelik çıkarma ve sınıflandırma yöntemlerinin performansını değerlendirmek amacıyla çeşitli veri setleri kullanılmıştır. Araştırmada analiz edilen EEG sinyalleri tat, koku ve motor hayali (düşünsel hareket etme) temellidir. Bu karmaşık sinyalleri doğru bir şekilde yorumlamak amacıyla yeni yöntemler uygulanarak etkili sonuçlar elde edilmiştir. Çalışmada portakal, nane, kekik ve karanfil yağlarına dayalı dört farklı gıda maddesinin tatlarına ilişkin EEG veri seti kaydedilmiştir. Bu veri seti, Karadeniz Teknik Üniversitesi bünyesinde yürütülen ve TÜBİTAK tarafından 118E241 numaralı 1001 Projesi kapsamında desteklenen çalışmalar sonucunda oluşturulmuştur. Koku ve imgeleme temelli çalışmalar için literatürde açık erişime sunulan veri kümeleri kullanılmıştır.

Tat veri setinde her bir denek için, verilerin %50'si eğitim, geriye kalan kısmı ise test kümesi için ayrılmıştır. Bu veri kümesinden HD, BG, HWHD ve PO tabanlı öznitelikler çıkarıldıktan sonra *k*-EYK, DVM, DAA ve RO tabanlı algoritmalar kullanılarak sınıflandırma işlemi gerçekleştirilmiş ve bilinmeyen test verileri etiketlenmiştir. Bant geçiren filtre olmak üzere 0-40 Hz aralığında 1 Hz çözünürlükte ilgili aralıktaki tüm olası bant geçiren filtreler test edilmiştir. Eğitim kümesinde en yüksek SD sağlayan filtreler aralıkları en uygun bant geçiren filtre kesim frekansları (parametreleri) olarak belirlenmiştir. Tat veri kümesi, burun açık ve kapalı koşullarında gerçekleştirilen ölçümlerden elde edilen, 10 katılımcıya ait verilerden oluşmaktadır. Veri kümeleri, her katılımcı için dört farklı tadı ikili kombinasyonlara (toplamda 6 ikili kombinasyon) bölerek analiz edilmiştir. Bu kombinasyonların %50'si eğitim, kalan kısmı ise test kümesi olarak ayrıldıktan sonra, iki veri kümesinden HD, BG, HWHD ve PO tabanlı öznitelikler çıkarılmıştır. Bir sonraki aşamada *k*-EYK, DVM, DAA ve RO tabanlı algoritmalar kullanılarak sınıflandırma işlemi gerçekleştirilmiş ve bilinmeyen test denemeleri etiketlenmiştir. Bu çalışmada önerilen kanal seçme yöntemleri eğitim kümelerine uygulanmış, ardından seçilen kanallar kullanılarak test kümesinde sınıflandırma işlemi yapılmıştır.

Kokuya dayalı EEG veri setinde, dört sınıflı bir sınıflandırma işlemi gerçekleştirilmiştir. Bu veri seti, gözler açık ve kapalı durumda kaydedilen 10 katılımcıdan oluşmaktadır. Veri setinin %50'si eğitim, geri kalan kısmı ise test kümesi olarak ayrılmıştır. DPA tabanlı öznitelik çıkarma işlemi her iki grup için gerçekleştirilmiş, ardından *k*-EYK sınıflandırıcı ile bilinmeyen test denemeleri etiketlenmiştir. Eğitim kümesinde önerilen

yöntem kullanılarak en iyi kanallar seçilmiş ve bu kanallar test kümesinde uygulanarak sınıflandırma işlemi gerçekleştirilmiştir.

Motor hayaline dayalı çalışma, iki sınıflı ve 29 katılımcıdan oluşmaktadır. Veri setinin %50'si rastgele olarak eğitim, geri kalan kısmı ise test kümesi olarak iki gruba ayrılmıştır ve bu işlem 50 kez tekrarlanmıştır. Her iki gruptan HD öznitelikleri çıkarıldıktan sonra DVM sınıflayıcı ile test denemeleri etiketlenmiştir. Son olarak, eğitim kümesine kanal seçme algoritmaları uygulanmış ve seçilen kanallar kullanılarak test kümesi DVM sınıflayıcı ile sınıflandırılmıştır; sonuçların ortalaması da 50 tekrarla elde edilmiştir.

3.1. Burun Kapalı ve Açık Durumunda Tada Dayalı Veriler

3.1.1. Burun Kapalı Durumunda Tada Dayalı Veri Setinin HD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun kapalı durumunda Tada dayalı veri setinden çıkarılan HD tabanlı öznitelikler, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları kullanılarak SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Her kombinasyonda en yüksek performansı gösteren algoritmanın burun kapalı duruma ait SD sonuçları Tablo 3'te sunulmuştur. Burun kapalı durumunda gerçekleştirilen analizler sonucunda, tüm denekler ve bunların kombinasyonları için ortalama %79 SD elde edilmiştir.

Tablo 3. Tat deneylerinde HD öznitelikleri kullanarak SD sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	75	80	80	77,5	75
D2	77,5	80	77,5	80	77,5	77,5
D3	77,5	77,5	77,5	82,5	77,5	85
D4	85	77,5	77,5	77,5	80	80
D5	80	80	85	77,5	77,5	77,5
Ort.			79			

Burun kapalı durumunda D1'de, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 20-24 Hz bant aralığında DAA yöntemiyle %80 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 23-26 Hz bant aralığında %75 SD olarak RO yöntemiyle belirlenmiştir. S1-S4 ikilisi için ise, 20-24 Hz bant aralığında DAA yöntemiyle %80 SD sınıflandırma performansı kaydedilmiştir. S2-S3 çiftlerinde, 13-14 Hz bant aralığında *k*-EYK yöntemiyle %80 SD sınıflandırma başarısına ulaşılmıştır. S2-S4 çifti için, en yüksek sınıflandırma performansı 37-38 Hz bant aralığında RO yöntemiyle %77,5 SD olarak elde edilmiştir. Son olarak, S3-S4 ikilisi için en iyi sınıflandırma başarısı, 13-14 Hz bant aralığında *k*-EYK, DAA ve RO sınıflandırıcılarıyla %75 SD olarak belirlenmiştir.

D2'de, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 2-17 Hz ve 23-27 Hz bant aralıklarında sırasıyla DAA ve RO yöntemleriyle %77,5 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 16-17 Hz ve 9-10 Hz bant aralıklarında sırasıyla RO ve DAA sınıflandırıcılarıyla %80 SD olarak belirlenmiştir. S1-S4 ikilisi için, 30-37 Hz bant aralığında RO yöntemiyle %77,5 SD kaydedilmiştir. S2-S3 çiftlerinde, 30-32 Hz bant aralığında DVM yöntemiyle %80 SD'ye ulaşılmıştır. S2-S4 çifti için en yüksek sınıflandırma performansı, 7-8 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD olarak elde edilmiştir. Son olarak, S3-S4 ikilisi için en iyi sınıflandırma başarısı, 1-2 Hz bant aralığında *k*-EYK sınıflandırıcılarıyla %75 SD olarak belirlenmiştir.

D3'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 13-18 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 2-8 Hz ve 31-33 Hz bant aralıklarında sırasıyla *k*-EYK ve RO yöntemleri ile %77,5 SD olarak belirlenmiştir. S1-S4 ikilisi için, 25-31 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD sınıflandırma performansı kaydedilmiştir. S2-S3 çiftlerinde, 1-12 Hz bant aralığında DAA yöntemiyle %82,5 SD sınıflandırma başarısına ulaşılmıştır. S2-S4 çifti için en yüksek sınıflandırma performansı, 31-38 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD olarak elde edilmiştir. Son olarak, S3-S4 ikilisi için en iyi sınıflandırma başarısı, 18-23 Hz bant aralığında RO sınıflandırıcısı ile %85 SD olarak belirlenmiştir.

D4'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 11-18 Hz bant aralığında DAA yöntemiyle %85 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, sırasıyla 12-13 Hz, 19 Hz ve 20-32 Hz bant aralıklarında DVM, *k*-EYK ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. S1-S4 ikilisi için, sırasıyla 16-17 Hz ve 10-11 Hz bant aralıklarında DVM, *k*-EYK ve RO yöntemleriyle %77,5 SD

kaydedilmiştir. S2-S3 çiftlerinde, 16-17 Hz ve 22-35 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD elde edilmiştir. S2-S4 çifti için, 22-31 Hz ve 18-21 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %80 SD olarak belirlenmiştir. Son olarak, S3-S4 çifti için, 31-32 Hz ve 35-37 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %80 SD sınıflandırma performansı kaydedilmiştir.

D5'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 27-33 Hz ve 6-28 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %80 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 35-40 Hz bant aralığında RO yöntemiyle %80 SD olarak belirlenmiştir. S1-S4 ikilisi için, 6-30 Hz bant aralığında RO yöntemiyle %85 SD kaydedilmiştir. S2-S3 çiftlerinde, 4-9 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD elde edilmiştir. S2-S4 çifti için en yüksek sınıflandırma performansı, 2-27 Hz bant aralığında RO yöntemiyle %77,5 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için, 30-31 Hz bant aralığında *k*-EYK yöntemiyle %80 SD sınıflandırma performansı kaydedilmiştir.

3.1.2. Burun Açık Durumunda Tada Dayalı Veri Setinin HD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun açık durumunda Tada dayalı veri setinden çıkarılan HD tabanlı öznitelikler, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları kullanılarak SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Her kombinasyonda en yüksek performansı gösteren algoritmanın burun açık durumuna ait SD sonuçları Tablo 4'te sunulmuştur. Burun açık durumunda gerçekleştirilen analizler sonucunda, tüm denekler ve bunların kombinasyonları için ortalama %79,41 SD değeri elde edilmiştir.

Tablo 4. Tat deneylerinde HD öznitelikleri kullanarak SD sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	77.5	80	82.5	75	80
D2	85	80	80	80	77,5	82,5
D3	77,5	80	80	82.5	75	80
D4	80	77,5	80	77,5	77,5	80
D5	77,5	77,5	77,5	85	80	77,5
Ort.			79,41			

Burun açık durumunda yapılan analizlere göre, D1'de S1-S2 çiftleri için en yüksek sınıflandırma performansı, 0-15 Hz bant aralığında RO yöntemiyle %80 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, sırasıyla 30-37 Hz ve 22-24 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. S1-S4 ikilisi için, 36-38 Hz bant aralığında RO yöntemiyle %80 SD kaydedilmiştir. S2-S3 çiftlerinde, 2-12 Hz bant aralığında *k*-EYK yöntemiyle %82,5 SD elde edilmiştir. S2-S4 çifti için, 10-13 Hz, 31 Hz ve 15-26 Hz bant aralıklarında *k*-EYK, DAA ve RO yöntemleriyle %75 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için 0-16 Hz bant aralığında *k*-EYK yöntemiyle %80 SD sınıflandırma performansı kaydedilmiştir.

D2'de, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 30-35 Hz bant aralığında RO yöntemiyle %85 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 4-6 Hz ve 1-7 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %80 SD olarak belirlenmiştir. S1-S4 ikilisi için, 2-21 Hz bant aralığında *k*-EYK yöntemiyle %80 SD kaydedilmiştir. S2-S3 çiftlerinde, 3-8 Hz bant aralığında *k*-EYK yöntemiyle %80 SD elde edilmiştir. S2-S4 çifti için en yüksek sınıflandırma performansı, 24-25 Hz, 31 Hz ve 33-37 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için en iyi sınıflandırma başarısı, 1-32 Hz ve 21-26 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %82,5 SD olarak belirlenmiştir.


D3'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 13-16 Hz ve 22-24 Hz

bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 4-6 Hz ve 29-30 Hz bant aralıklarında RO yöntemiyle %80 SD olarak belirlenmiştir. S1-S4 ikilisi için, sırasıyla 8-81 Hz, 8-11 Hz ve 8-12 Hz bant aralıklarında DVM, *k*-EYK ve RO yöntemleriyle %80 SD kaydedilmiştir. S2-S3 çiftlerinde, 28-33 Hz ve 29-31 Hz bant aralıklarında DVM ve *k*-EYK yöntemleriyle %82,5 SD elde edilmiştir. S2-S4 çifti için en yüksek sınıflandırma performansı, sırasıyla 33-40 Hz, 34-35 Hz ve 29-30 Hz bant aralıklarında DVM, *k*-EYK ve RO yöntemleriyle %75 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için, 1-32 Hz ve 31-32 Hz bant aralıklarında RO yöntemiyle %80 SD sınıflandırma performansı kaydedilmiştir.

D4'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 10-17 Hz ve 5-31 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %80 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 11-16 Hz ve 36-38 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. S1-S4 ikilisi için, 14-21 Hz bant aralığında *k*-EYK yöntemiyle %80 SD kaydedilmiştir. S2-S3 çiftlerinde, 39-40 Hz ve 12-31 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD elde edilmiştir. S2-S4 çifti için en yüksek sınıflandırma performansı, 8-10 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için en iyi sınıflandırma başarısı, 15-24 Hz bant aralığında RO yöntemiyle %80 SD olarak kaydedilmiştir.

D5'te, S1-S2 çiftleri için en yüksek sınıflandırma performansı, 22-25 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD olarak elde edilmiştir. S1-S3 çiftleri için en yüksek sınıflandırma doğruluğu, 3-19 Hz ve 21-23 Hz bant aralıklarında *k*-EYK ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. S1-S4 ikilisi için, 23-35 Hz bant aralığında *k*-EYK yöntemiyle %80 SD kaydedilmiştir. S2-S3 çiftlerinde, 30-31 Hz bant aralığında *k*-EYK yöntemiyle %85 SD elde edilmiştir. S2-S4 çifti için en yüksek sınıflandırma performansı, 9-10 Hz ve 16-23 Hz bant aralıklarında DAA ve RO yöntemleriyle %77,5 SD olarak belirlenmiştir. Son olarak, S3-S4 ikilisi için, 28-31 Hz bant aralığında *k*-EYK yöntemiyle %77,5 SD sınıflandırma performansı kaydedilmiştir.

Tat veri kümesinde, bant geçiren filtre kullanılarak 0-40 Hz aralığında 1 Hz çözünürlükteki tüm olası bant geçiren filtreler test edilmiştir. En yüksek test sınıflandırma doğruluğunu (SD) sağlayan noktalar, en uygun bant geçiren filtre kesim frekansları olarak belirlenmiştir. Bu konuya ilişkin daha ayrıntılı bilgi vermek amacıyla, Tablo 3'teki en yüksek SD değerine sahip ikililerden biri olan D3'ün S3-S4 kombinasyonu için tüm olası filtre aralıklarından elde edilen SD sonuçları Şekil 31'de gösterilmiştir.



Şekil 31. Burun kapalı durumda D3'te S1-S2 ikilisi için 1 Hz. hassasiyetle bant geçiren filtrenin tüm aralıkları üzerinden elde edilen SD sonuçları göstermektedir.

3.1.3. Burun Kapalı Durumunda Tada Dayalı Veri Setinin BG Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun kapalı durumda, tada veri setinden elde edilen BG tabanlı öznitelikler kullanılarak, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, k -EYK, DAA ve RO algoritmalarıyla SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Yapılan analizler sonucunda, tüm denekler ve bunların kombinasyonları BG öznitelikleri kullanılarak ortalama %79,49 SD değeri elde edilmiştir. BG tabanlı öznitelikler ve DVM, k -EYK, DAA ve RO algoritmaları ile elde edilen sonuçlar, her kombinasyonda en yüksek performansı gösteren algoritmaların burun kapalı durumundaki SD sonuçları Tablo 5'te sunulmuştur.

Tablo 5. Tat verilerinde BG öznitelikleri ile Sınıflandırmasının sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	77,5	80	80	80	82,5	82,5
D2	77,5	80	77,5	80	77,5	82,5
D3	77,5	80	77,5	77,5	77,5	80
D4	77,5	82,5	77,5	82,5	80	80
D5	75	80	82,5	80	82,5	77,5
Ort.			79.49			

BG öznitelikleri ile Burun kapalı durumda EEG verileriyle elde edilen en yüksek sınıflandırma doğruluğu %82,5 SD ile D1'de S2-S4 ayrımında RO algoritması, S3-S4 ayrımında ise *k*-EYK ve RO algoritmaları ile elde edilmiştir. Ayrıca, D2'de S3-S4 ayrımında, D4'te S1-S3 ayrımında ve D5'te S1-S4 ve S2-S4 ayrımlarında sırasıyla RO ve *k*-EYK algoritmaları en iyi performansı göstermiştir.

3.1.4. Burun Açık Durumunda Tada Dayalı Veri Setinin BG Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun açık durumunda ise tada veri setinden elde edilen BG tabanlı öznitelikler kullanılarak, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmalarıyla SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Yapılan analizler sonucunda, tüm denekler ve bunların kombinasyonları BG öznitelikleri kullanılarak ortalama %80,66 SD değeri elde edilmiştir. BG tabanlı öznitelikler ve algoritmalarla elde edilen en yüksek performans gösteren sonuçlar Tablo 6'da sunulmuştur.

Tablo 6. Tat verilerinde BG öznitelikleri ile SD sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	80	82,5	80	77,5	82,5
D2	80	80	77,5	85	82,5	82,5
D3	82,5	82,5	80	80	80	82,5
D4	77,5	82,5	82,5	82,5	82,5	82,5
D5	80	82,5	75	77,5	77,5	80
Ort.	80,66					

BG öznitelikleri ile burun açık durumunda EEG verileri ile en yüksek sınıflandırma doğruluğu %85 SD ile D2'de S2-S3 ikilisi için *k*-EYK algoritması kullanılarak elde edilmiştir

3.1.5. Burun Kapalı Durumunda Tada Dayalı Veri Setinin HWHD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun kapalı durumunda tada veri setinden elde edilen HWHD tabanlı öznitelikler, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları kullanılarak SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Yapılan analizler sonucunda, tüm denekler ve bunların kombinasyonları HWHD öznitelikleri kullanılarak ortalama %79,85 SD değeri elde edilmiştir. HWHD tabanlı öznitelikler ve DVM, *k*-EYK, DAA ve RO algoritmaları ile elde edilen sonuçlar, her kombinasyonda en yüksek performansı gösteren algoritmaların burun kapalı durumundaki SD sonuçları Tablo 7'da sunulmuştur.

Tablo 7. Tat verilerinde HWHD öznitelikleri ile SD sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	80	77,5	77,5	80	85
D2	80	80	80	80	77,5	85
D3	77,5	77,5	77,5	77,5	80	77,5
D4	77,5	82,5	85	77,5	82,5	82,5
D5	82,5	80	77,5	80	80	80
Ort.			79,85			

HWHD yöntemi ile burun kapalı durumda EEG verileriyle elde edilen en yüksek sınıflandırma doğruluğu, birinci denekte S2-S4 ayrımında %85 ile RO sınıflandırıcısı ve S3-S4 ayrımında %85 ile *k*-EYK sınıflandırıcısı kullanılarak elde edilmiştir. Aynı şekilde, D2’de S3-S4 ayrımında RO sınıflandırıcısı %85 doğruluğa ulaşmıştır.

3.1.6. Burun Açık Durumunda Tada Dayalı Veri Setinin, HWHD Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun açık durumunda da Tada veri setinden elde edilen HWHD tabanlı öznitelikler, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları kullanılarak SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Yapılan analizler sonucunda, tüm denekler ve bunların kombinasyonları HWHD öznitelikleri kullanılarak ortalama %79,65 SD elde edilmiştir. HWHD tabanlı öznitelikler ve sınıflandırıcı algoritmalarla elde edilen en yüksek performans gösteren sonuçlar Tablo 8’de sunulmuştur.

Tablo 8. Tat verilerin HWHD öznitelikleri ile SD Sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	77,5	80	80	77,5	77,5	85
D2	80	82,5	80	87,5	80	85
D3	77,5	80	77,5	80	80	80
D4	80	77,5	80	82,5	80	80
D5	77,5	77,5	77,5	75	80	75
Ort.			79,65			

HWHD yöntemi ile burun açık durumda EEG verileriyle elde edilen en yüksek sınıflandırma doğruluğu, D1 ve D2'de S3-S4 ayrımında %85 olarak sırasıyla *k*-EYK ve RO sınıflandırıcıları kullanılarak elde edilmiştir.

3.1.7. Burun Kapalı Durumunda Tada Dayalı Veri Setinin PO Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun kapalı durumunda, tada veri setinden elde edilen PO tabanlı öznitelikler kullanılarak, tüm denekler ve bu deneklerin ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları ile SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Her kombinasyonda en yüksek performans gösteren algoritmanın burun kapalı duruma ait SD sonuçları Tablo 9'da sunulmuştur. Yapılan analizler sonucunda, PO öznitelikleri kullanılarak burun kapalı durumda ortalama %79,85 SD değeri elde edilmiştir. PO tabanlı öznitelikler ve DVM, *k*-EYK, DAA ve RO algoritmaları ile elde edilen sonuçlar, her kombinasyonda en yüksek performansı gösteren algoritmaların burun kapalı duruma ait SD sonuçları Tablo 9'da verilmiştir.

Tablo 9. Tat verilerinde PO öznitelikleri ile SD Sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	77,5	80	80	80	80	77,5
D2	82,5	82,5	82,5	80	80	82,5
D3	77,5	80	82,5	77,5	80	80
D4	82,5	80	80	80	80	80
D5	77,5	80	82,5	80	77,5	77,5
Ort.			80			

PO öznitelikleri ile burun kapalı durumunda EEG veriler En yüksek sınıflandırma sonucu %82,5 SD olarak D2’de sınıf S1-S2 ve ayrımı DAA sınıflandırıcı ile aynı kişi S1-S4 ayrımı için RO sınıflandırıcı ile ve tekrar aynı kişi için sınıf S3 -S4 ayrımı için *k*-EYK ve RO ile elde edilmiştir. Aynı sonucu üçüncü kişide S1-S4 ayrımı için *k*-EYK ve dördüncü kişide S1-S2 ayrımı için *k*-EYK, DAA ve RO sınıflandırıcıları ile elde edilmiştir.

3.1.8. Burun Açık Durumunda Tada Dayalı Veri Setinin PO Tabanlı Öznitelikler ile Sınıflandırma Sonuçları

Burun açık durumunda ise Tada veri setinden elde edilen PO tabanlı öznitelikler, tüm denekler ve bunların ikili sınıflandırma kombinasyonları için DVM, *k*-EYK, DAA ve RO algoritmaları kullanılarak SD ortalamaları test kümeleri üzerinde hesaplanmıştır. Yapılan analizler sonucunda, PO öznitelikleri kullanılarak burun açık durumda ortalama %79,83 SD değeri elde edilmiştir. PO tabanlı öznitelikler ve sınıflandırıcı algoritmalarla elde edilen en yüksek performansı gösteren sonuçlar Tablo 10’da verilmiştir.

Tablo 10. Tat verilerinde PO öznitelikleri ile SD Sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	77,5	80	82,5	80	77,5	80
D2	75	80	80	80	80	80
D3	80	77,5	77,5	85	80	80
D4	77,5	80	87,5	80	80	80
D5	80	80	77,5	80	80	80
Ort.			79,83			

Burun açık durumunda, EEG verilerinden elde edilen PO öznitelikleri yöntemi ile yapılan analizlerde en yüksek sınıflandırma doğruluğu %87,5 SD ile D4'te S1-S4 ayrımı için RO algoritması ile elde edilmiştir.

3.1.9. Burun kapalı Durumunda Tada Dayalı Veri Setinin, Önerilen Yöntem (RAKS) ile Sınıflandırma Sonuçları

Tat verisine dayalı çalışmada, burun kapalı durumundaki 4 sınıflı veri seti, ikili sınıflandırmalar yapılmak üzere ikili kombinasyonlara ayrılmıştır. Bu aşamada, veri setinin %50'si eğitim, geri kalan %50'si ise test seti olarak ayrılmıştır. Her iki gruptan HD kullanılarak öznitelikler çıkarılmış, ardından eğitim setine önerilen RAKS algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar, test seti üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcıları kullanılarak test edilmiştir. En yüksek sınıflandırma doğruluğu veren sonuçlar, burun kapalı durumu için Tablo 11'de gösterilmiştir. Yapılan analizler sonucunda, burun kapalı durumunda tüm denekler ve kombinasyonlarında, HD öznitelikleri ve önerilen kanal seçimi yöntemini kullanarak ortalama %82,5 SD elde edilmiştir.

Tablo 11. Tat verisinde önerilen RAKS yöntemi ile SD sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	87,5	82,5	82,5	82,5	82,5	82,5
D2	82,5	80	82,5	82,5	85	80
D3	80	80	82,5	80	82,5	82,5
D4	85	82,5	82,5	80	87,5	82,5
D5	82,5	85	87,5	77,5	82,5	80
Ort.			82,5			

Burun kapalı durumunda D1’de, S1-S2 çifti en yüksek sınıflandırma doğruluğunu 11 etkin kanal seçilerek DAA yöntemiyle %87,5 SD ile elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 7 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD olarak belirlenmiştir. S1-S4 çifti 5 etkin kanal seçilerek DAA yöntemiyle %82,5 SD doğruluğa ulaşmıştır. S2-S3 çifti için 7 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD doğruluk elde edilmiştir. S2-S4 çifti için 7 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluğa ulaşılmıştır. Son olarak, S3-S4 çifti için 5 etkin kanal seçilerek *k*-EYK, DAA ve RO yöntemleriyle %82,5 SD doğruluğu sağlanmıştır.

D2’de, S1-S2 çifti 4 etkin kanal ile DAA ve RO yöntemleriyle %82,5 SD doğruluğu elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 10 etkin kanal seçilerek RO ve DAA yöntemleriyle %80 SD olarak belirlenmiştir. S1-S4 çifti 6 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluğa ulaşmıştır. S2-S3 çifti için 9 etkin kanal seçilerek DVM yöntemiyle %82,5 SD doğruluk sağlanmıştır. S2-S4 çifti için 4 etkin kanal seçilerek *k*-EYK yöntemiyle %85 SD doğruluğa ulaşılmıştır. S3-S4 çifti için en yüksek doğruluk, 8 etkin kanal seçilerek *k*-EYK yöntemiyle %80 SD olarak elde edilmiştir.

D3’te, S1-S2 çifti en yüksek sınıflandırma doğruluğunu 3 etkin kanal seçilerek *k*-EYK yöntemiyle %80 SD olarak elde etmiştir. S1-S3 çifti için 7 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %80 SD doğruluğa ulaşılmıştır. S1-S4 çifti için en yüksek doğruluk, 3 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD olarak belirlenmiştir. S2-S3 çifti 6 etkin

kanal ile DAA yöntemi kullanılarak %80 SD doğruluk elde etmiştir. S2-S4 çifti için 8 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD doğruluğa ulaşılmıştır. S3-S4 çifti için ise 2 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluğu sağlanmıştır.

D4'te, S1-S2 çifti en yüksek sınıflandırma performansını 4 etkin kanal seçilerek DAA yöntemiyle %85 SD ile elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 6 etkin kanal seçilerek DVM, *k*-EYK ve RO yöntemleriyle %82,5 SD olarak belirlenmiştir. S1-S4 çifti ise 7 etkin kanal ile DVM, *k*-EYK ve RO yöntemleriyle %82,5 SD doğruluğa ulaşmıştır. S2-S3 çifti için 5 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %80 SD doğruluk elde edilmiştir. S2-S4 çifti için 6 etkin kanal seçilerek *k*-EYK yöntemiyle %87,5 SD doğruluk sağlanmıştır. S3-S4 çifti için ise 4 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD doğruluğa ulaşılmıştır.

D5'te, S1-S2 çifti 11 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD doğruluk sağlamıştır. S1-S3 çifti için en yüksek doğruluk, 7 etkin kanal seçilerek RO yöntemiyle %85 SD olarak elde edilmiştir. S1-S4 çifti 5 etkin kanal seçilerek RO yöntemiyle %87,5 SD doğruluğa ulaşmıştır. S2-S3 çifti 7 etkin kanal ile *k*-EYK yöntemi kullanılarak %77,5 SD doğruluğa ulaşmıştır. S2-S4 çifti için 7 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluk sağlanmıştır. Son olarak, S3-S4 çifti için en yüksek doğruluk 5 etkin kanal seçilerek *k*-EYK yöntemiyle %80 SD olarak kaydedilmiştir.

3.1.10. Burun Açık Durumunda Tada Dayalı Veri Setinin, Önerilen Yöntem (RAKS) ile Sınıflandırma Sonuçları

Tada dayalı veri setinde burun açık durumunda, 4 sınıflı verilerden oluşmaktadır ancak bu veriler ikili kombinasyonlara bölünerek ikili sınıflandırma işlemi yapılmıştır. Bu çalışmada, veri setinin %50'si eğitim ve geri kalan kısmı test seti olarak iki guruba bölünmüştür ve bir sonraki aşamada her iki gruptan HD ile öz nitelikler çıkarılmıştır. Sonra eğitim setine önerdiğimiz RAKS algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar test verisi üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcılar ile test edilmiştir. Burun açık durumundaki en yüksek sınıflandırma doğruluğu sonuçları Tablo 12'de sunulmuştur ve tüm denekler için ortalama %81,88 SD değeri elde edilmiştir.

Tablo 12. Tat verisinde önerilen RAKS yöntemi ile SD sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	85	80	82,5	82,5	85
D2	82,5	80	82,5	82,5	82,5	85
D3	80	82,5	82,5	85	80	80
D4	82,5	82,5	82,5	82,5	82,5	82,5
D5	77,5	80	77,5	85	77,5	80
Ort.			81,88			

Burun açık durumunda D1’de, S1-S2 çifti en yüksek sınıflandırma performansını 9 etkin kanal seçilerek RO yöntemiyle %80 SD ile elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 5 etkin kanal seçilerek *k*-EYK yöntemiyle %85 SD olarak belirlenmiştir. S1-S4 çifti 6 etkin kanal seçilerek RO yöntemiyle %80 SD doğruluğa ulaşmıştır. S2-S3 çifti 4 etkin kanal ile *k*-EYK yöntemi kullanılarak %82,5 SD doğruluk elde etmiştir. S2-S4 çifti için 4 etkin kanal seçilerek *k*-EYK, DAA ve RO yöntemleriyle %82,5 SD doğruluğa ulaşılmıştır. S3-S4 çifti ise 6 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %85 SD doğruluğu sağlamıştır.

D2’de, S1-S2 çifti 7 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluğa ulaşmıştır. S1-S3 çifti için en yüksek doğruluk, 6 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %80 SD olarak elde edilmiştir. S1-S4 çifti 7 etkin kanal ile *k*-EYK yöntemi kullanılarak %82,5 SD doğruluğa ulaşmıştır. S2-S3 çifti 5 etkin kanal ile *k*-EYK yöntemiyle %82,5 SD doğruluk sağlamıştır. S2-S4 çifti için en yüksek doğruluk, 8 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD olarak kaydedilmiştir. S3-S4 çifti için ise 6 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %85 SD doğruluğa ulaşılmıştır.

D3’te, S1-S2 çifti en yüksek sınıflandırma doğruluğunu 4 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %80 SD olarak elde etmiştir. S1-S3 çifti için 7 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluğa ulaşılmıştır. S1-S4 çifti 3 etkin kanal ile DVM, *k*-EYK ve RO yöntemleri kullanılarak %82,5 SD doğruluk sağlamıştır. S2-S3 çifti için 6 etkin kanal

seçilerek RO yöntemiyle %85 SD doğruluğa ulaşılmıştır. S2-S4 çifti 9 etkin kanal ile DVM, *k*-EYK ve RO yöntemleri kullanılarak %80 SD doğruluğa ulaşmıştır. S3-S4 çifti için 3 etkin kanal seçilerek RO yöntemiyle %80 SD doğruluk kaydedilmiştir.

D4'te, S1-S2 çifti en yüksek sınıflandırma performansını 6 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD ile elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 3 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD olarak belirlenmiştir. S1-S4 çifti 4 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD doğruluğa ulaşmıştır. S2-S3 çifti için 8 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %82,5 SD doğruluk sağlanmıştır. S2-S4 çifti için 10 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD doğruluk elde edilmiştir. S3-S4 çifti için ise 4 etkin kanal seçilerek RO yöntemiyle %82,5 SD doğruluk kaydedilmiştir.

D5'te, S1-S2 çifti en yüksek sınıflandırma doğruluğunu 8 etkin kanal seçilerek *k*-EYK yöntemiyle %77,5 SD ile elde etmiştir. S1-S3 çifti için en yüksek doğruluk, 8 etkin kanal seçilerek *k*-EYK ve RO yöntemleriyle %80 SD olarak belirlenmiştir. S1-S4 çifti için 6 etkin kanal seçilerek *k*-EYK yöntemiyle %77,5 SD doğruluğa ulaşılmıştır. S2-S3 çifti için 7 etkin kanal seçilerek RO yöntemi ile %85 SD doğruluk sağlanmıştır. S2-S4 çifti için en yüksek sınıflandırma doğruluğu, 6 etkin kanal seçilerek DAA ve RO yöntemleriyle %77,5 SD olarak elde edilmiştir. Son olarak, S3-S4 çifti için en yüksek doğruluk, 4 etkin kanal seçilerek *k*-EYK yöntemiyle %82,5 SD olarak kaydedilmiştir.

3.1.11. Burun Kapalı Durumunda Tada Dayalı Veri Setinin, Geriye Dönük Eleme (GDE) Yöntem ile Sınıflandırma Sonuçları

Tat verisine dayalı çalışmada, burun kapalı durumundaki 4 sınıflı veri seti, ikili sınıflandırmalar yapılmak üzere ikili kombinasyonlara ayrılmıştır. Bu aşamada, veri setinin %50'si eğitim, geri kalan %50'si ise test seti olarak ayrılmıştır. Her iki gruptan HD kullanılarak öznitelikler çıkarılmış, ardından eğitim setine GDE algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar, test seti üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcıları kullanılarak test edilmiştir. En yüksek sınıflandırma doğruluğu veren sonuçlar, burun kapalı durum için Tablo 13'te gösterilmiştir. Yapılan analizler sonucunda, burun kapalı durumunda tüm denekler ve kombinasyonlarında, HD öznitelikleri ve GDE kanal seçimi yöntemini kullanarak ortalama %82,5 sınıflandırma doğruluğu (SD) elde edilmiştir.

Tablo 13. Tat verisinde önerilen GDE yöntemi ile SD sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	82,5	80	80	80	80	85
D2	82,5	82,5	82,5	77,5	85	80
D3	80	82,5	82,5	82,5	82,5	82,5
D4	80	80	82,5	82,5	85	82,5
D5	82,5	77,5	85	82,5	82,5	82,5
Ort.			81.77			

Burun kapalı durumunda D1’de, S3-S4 çifti en yüksek sınıflandırma doğruluğunu 11 etkin kanal ve *k*-EYK, D2’de, S2-S4 çifti en SD için 8 kanal ve ROM, D4’te S2-S4 çifti için 9 kanal ve DVM, D5’te S1-S4 çifti için 8 kanal ve *k*-EYK yöntemleriyle %85 SD elde etmiştir.

3.1.12. Burun Açık Durumunda Tada Dayalı Veri Setinin, GDE Yöntem ile Sınıflandırma Sonuçları

Tat verisine dayalı çalışmada, burun açık durumundaki 4 sınıflı veri seti, ikili sınıflandırmalar yapılmak üzere ikili kombinasyonlara ayrılmıştır. Bu aşamada, veri setinin %50’si eğitim, geri kalan %50’si ise test seti olarak ayrılmıştır. Her iki gruptan HD kullanılarak öznitelikler çıkarılmış, ardından eğitim setine GDE algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar, test seti üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcıları kullanılarak test edilmiştir. En yüksek sınıflandırma doğruluğu veren sonuçlar, burun kapalı durumu için Tablo 14’te gösterilmiştir. Yapılan analizler sonucunda, burun kapalı durumunda tüm denekler ve kombinasyonlarında, HD öznitelikleri ve GDE kanal seçimi yöntemini kullanarak ortalama %81,66 sınıflandırma doğruluğu (SD) elde edilmiştir.

Tablo 14. Tat verisinde GDE yöntemi ile sınıflandırma sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	80	80	82,5	80	82,5
D2	82,5	80	82,5	87,5	77,5	80
D3	82,5	82,5	82,5	85	82,5	82,5
D4	80	82,5	82,5	85	80	85
D5	77,5	80	82,5	77,5	82,5	82,5
Ort.			81,66			

Burun açık durumunda en iyi sonuç D2'nin S2-S3 çiftinde 5 kalan seçilerek ve *k*-EYK, RO yöntemleriyle %87,5 SD elde etmiştir.

3.1.13. Burun Kapalı Durumunda Tada Dayalı Veri Setinin, Sıralı İleri (Sİ) Kanal Seçme Yöntemi ile Sınıflandırma Sonuçları

Tat verisine dayalı çalışmada, burun kapalı durumundaki 4 sınıflı veri seti, ikili sınıflandırmalar yapılmak üzere ikili kombinasyonlara ayrılmıştır. Bu aşamada, veri setinin %50'si eğitim, geri kalan %50'si ise test seti olarak ayrılmıştır. HD kullanılarak öznitelikler çıkarılmış, ardından eğitim setine Sİ algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar, test seti üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcıları kullanılarak test edilmiştir. En yüksek sınıflandırma doğruluğu veren sonuçlar, burun kapalı durumu için Tablo 15'te gösterilmiştir. Yapılan analizler sonucunda, burun kapalı durumunda tüm denekler ve kombinasyonlarında, HD öznitelikleri ve Sİ kanal seçimi yöntemini kullanarak ortalama %81,74 SD elde edilmiştir.

Tablo 15. Tat verisinde Sİ yöntemi ile SD sonuçları (burun kapalı)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	82,5	82,5	80	80	85	80
D2	82,5	80	82,5	80	80	82,5
D3	82,5	82,5	82,5	80	82,5	85
D4	77,5	80	80	85	82,5	85
D5	82,5	82,5	80	80	87,5	77,5
Ort.			81,74			

Sİ kanal seçme yöntemiyle en iyi sonu burun kapalı durumunda D5'te, S2-S4 çifti için 9 etkin kanal ve *k*-EYK ve LDA yöntemleri kullanılarak %87,5 SD elde etmiştir.

3.1.14. Burun Açık Durumunda Tada Dayalı Veri Setinin, Sıralı İleri (Sİ) Kanal Seçme Yöntemi ile Sınıflandırma Sonuçları

Tat verisine dayalı çalışmada, burun açık durumundaki 4 sınıflı veri seti, ikili sınıflandırmalar yapılmak üzere ikili kombinasyonlara ayrılmıştır. Bu aşamada, veri setinin %50'si eğitim, geri kalan %50'si ise test seti olarak ayrılmıştır. Her iki gruptan HD kullanılarak öznitelikler çıkarılmış, ardından eğitim setine Sİ algoritması uygulanarak en iyi kanallar seçilmiştir. Seçilen kanallar, test seti üzerinde DVM, *k*-EYK, DAA ve RO sınıflandırıcıları kullanılarak test edilmiştir. En yüksek sınıflandırma doğruluğu veren sonuçlar, burun kapalı durumu için Tablo 16'da gösterilmiştir. Yapılan analizler sonucunda, burun kapalı durumunda tüm denekler ve kombinasyonlarında, HD öznitelikleri ve Sİ kanal seçimi yöntemini kullanarak ortalama %81,03 SD elde edilmiştir.


Tablo 16. Tat verisinde Sİ yöntemi ile sınıflandırma sonuçları (burun açık)

Kombinasyon	S1-S2	S1-S3	S1-S4	S2-S3	S2-S4	S3-S4
Denek	CA	CA	CA	CA	CA	CA
D1	80	80	82,5	85	80	80
D2	82,5	82,5	82,5	77,5	80	80
D3	82,5	82,5	85	80	80	85
D4	80	80	82,5	82,5	77,5	85
D5	75	80	80	82,5	80	80
Ort.	81,03					


Sİ kanal seçme yöntemiyle en iyi sonuç burun açık durumunda D1’de, S2-S3 çifti için 5 etkin kanal, D3’te S1-S4 çifti için 4 etkin kanal ve S3-S4 çifti için 4 etkin kanal, D4’te S3-S4 çifti için 6 etkin kanal ve sırasıyla D1’de *k*-EYK ve LDA, D3’te RO ve D4’te *k*-EYK yöntemleri kullanılarak %85 SD elde edilmiştir.

3.1.15. Önerilen Yöntem ve Literatürde Bulunan GDE ve Sİ Kanal Seçme Yöntemlerinin Performans Karşılaştırılması

Bu çalışmada tat verilerinin üzerinde önerilen yöntemin performansını literatürde bulunan Sıralı İleri (Sİ) ve Geri Dönük Eleme (GDE) yöntemleriyle karşılaştırılmış ve Şekil 31 ve 32’de sırası ile burun kapalı ve açık durumları için gösterilmiştir. Önerilen yöntem burun açık ve kapalı durumlarında diğer iki yöntemle göre SD açısından daha iyi performans göstermiştir.



Şekil 32. Tat verisinde burun kapalı durumunda yöntemlerin SD karşılaştırılması




Şekil 33. Tat verisinde burun açık durumunda yöntemlerin SD karşılaştırılması


Şekil 32 ve 33'te sırası ile burun açık ve kapalı durumlarında, yatay eksen katılımcıları (D1...D5) gösterirken, dikey eksenler yeşil, mavi ve sarı renklerle sırası ile önerilen RAKS ve karşılaştırması yapılan Sİ ve GDE yöntemlerinin SD sonuçlarını göstermektedir. Her iki durum için önerdiğimiz yöntem SD açısından üstün performans göstermiştir.

3.2. Kokuya dayalı Veri Setinin Sınıflandırma Sonuçları

Kokuya dayalı EEG veri setinde 4 sınıflı bir sınıflandırma işlemi yapılmıştır. Bu çalışmada, veri kümesinin %50'si eğitim ve geri kalan kısmı test kümesi olarak iki gruba bölünmüş ve bir sonraki aşamada her iki gruptan dalgacık paket ayrımı (DPA) ile öznelilikler çıkarılmıştır. Sonra önerilen RAKS yöntemi ile eğitim kümesinde en iyi kanallar seçilmiş ve test kümesine uygulayarak *k*-EYK sınıflandırıcı ile sınıflandırılmıştır. Sınıflandırma sonuçları göz açık ve kapalı durumları için sırası ile Şekil 34 ve Şekil 35'te verilmiştir. Göz açık durumunda beş kişi için ortalama %99,28 SD elde edilirken, göz kapalı durumda %97,49 SD elde edilmiştir. Önerilen yöntemle 10 kişi için 216 kanal arasından burun açık ve kapalı durumlarında ortalama 23,55 kanal kullanılmaktadır. Böylece işlem karmaşıklığı %89,09 azaltılmıştır. Ayrıca 10 kişi için tüm kanallar ile elde edilen SD sonuçlarına göre ortalama %8,63 iyileştirme gözlemlenmiştir.



Şekil 34. Göz açık durumunda önerilen yöntem ve tüm kanallar ile SD sonuçları




Şekil 35. Göz kapalı durumunda önerilen yöntem ve tüm kanallar ile SD sonuçları

Literatürde bulunan ve bizim de kullandığımız koku veri seti için en yüksek sınıflandırma sonucu Ezzatdoost ve arkadaşları tarafından da kaydedilmiştir. Ezzatdoost ve arkadaşlarının çalışma sonucu gözler açık ve kapalı durumlarında sırası ile %96,71 ve %88,79 SD elde etmişlerdir (Ezzatdoost vd., 2020). Önerilen RAKS yöntemi ile Ezzatdoost'un sonuçları karşılaştırıldığında gözler açık ve kapalı durumlarında sınıflandırma doğruluğunu sırası ile %2,57 ve %8,7 oranında yükseltilmiştir.

3.3. Hayale Dayalı Veri Setinin Sınıflandırma Sonuçları


El açıp kapama hayaline dayalı çalışmada, veri kümesini eğitim ve test kümesi olarak iki gruba bölünmüştür ve bir sonraki aşamada her iki gruptan Hilbert dönüşümü ile öznitelikler çıkarılmıştır. Sonrasında, eğitim kümesine önerdiğimiz RAKS algoritması uygulanarak en iyi kanallar seçilmiştir. Bir sonraki adımda seçilen kanallar kullanılarak test kümesi üzerinde sınıflandırma işlemi DVM sınıflandırıcı ile yapılmıştır. Sınıflandırma sonuçları Şekil 35'te verilmiştir. Şekil 35'te, yatay eksen denekleri (D1, D2, ..., D29), dikey eksen ise 50 çalıştırmanın ortalama SD sonucunu ve her denek için kullanılan kanal sayısını

göstermektedir. Bu çalışmada, 29 denek üzerinde SD ortalaması test seti için %81,56 olarak hesaplanmıştır. Şekil 35'te görüldüğü üzere tüm kişiler için tüm kanal arasından ortalama 3,72 kanal seçilmiştir ve böylece işlem karmaşıklığı %87,58 oranında azaltılmıştır. Hayale dayalı veri kümesi üzerinde önerilen yöntemin performansını değerlendirmek için Sİ ve GDE yöntemleri ile SD performansları karşılaştırılmıştır ve Şekil 36'daki radar grafik şeklinde verilmiştir.



Şekil 36. Hayale dayalı Veri Setinin önerilen yöntem ile SD sonuçları

Bu çalışmada, 29 denek üzerinde üç farklı sınıflandırma yöntemi (Önerilen Yöntem, Sİ ve GDE) kullanılarak elde edilen sınıflandırma doğrulukları analiz edilmiştir. Şekil 37'de, her denek için üç farklı yöntemin sınıflandırma doğruluklarının karşılaştırmalı olarak gösterilmiştir.



Şekil 37. 29 denek için üç farklı yöntemin sınıflandırma sonuçları

Şekil 37’de görüldüğü üzere, önerilen yöntem, Sİ ve GDE yöntemlerine göre daha yüksek doğruluk oranları sergilemektedir. Ayrıca, Sİ ve GDE yöntemleri ile ortalama doğruluk oranları sırasıyla %80,54 ve %79,96 olarak hesaplanmıştır. Böylece, önerilen yöntem, doğruluk açısından Sİ ve GDE’ye göre sırasıyla %1,02 ve %1,6 daha yüksek bir performans sergilemekte ve sınıflandırma doğruluğunu artırmada etkili olduğunu ortaya koymaktadır. Ayrıca, kullanılan hayal verisi üzerinde en yüksek doğruluk oranı, Aydemir ve arkadaşları tarafından önerilen ve kişiye özel Sİ yöntemiyle %80,5 doğruluk oranı elde edilmiştir (Aydemir & Ergün, 2019). Bu sonuca göre, önerilen yöntemin sınıflandırma doğruluğunu yaklaşık %1,1 oranında iyileştirdiği gösterilmiştir.

Sonuç olarak, standart yaklaşımlarda seçilen bir kanal prosedürün sonuna kadar tutulur veya silinirken, önerilen yöntemde bu kanallar her iterasyonda güncellenir ve en iyi kanallar sürecin sonuna kadar tutularak daha iyi sonuçlar elde edilmesi sağlanır ki bu durum diğer yaklaşımlardan daha iyi olduğunu göstermektedir.

4. TARTIŞMA

EEG sinyalleri, beyin aktivitelerinin elektriksel ölçümlerini sağlayan önemli bir yöntemdir. Nörolojik hastalıkların teşhisinde EEG sinyalleriyle elde edilen verilerin analizi, özellikle son yıllarda, farklı duyuşal sistemlerle ilişkilendirilen beyin aktivitelerini anlamada önemli bir rol oynamaktadır. Tat alma duyusu, bu duyuşal sistemlerden biridir ve tat ile ilgili beyin aktivitelerinin ölçülmesi, özellikle nörolojik hastalıkların teşhisi ve takibi açısından önemli bilgiler sunabilir. Tat alma duyusu, beyin bölgelerinde meydana gelen elektriksel aktivitelerin karmaşıklığı ile ilişkilidir. EEG sinyalleri, bu aktivitelerin izlenmesi için kullanılabilir, ancak bu sinyaller çoğu zaman gürültü ve diğer faktörlerle karmaşık bir hale gelir. Bu nedenle, doğru sonuçlara ulaşmak için sinyallerin işlenmesi ve kanal seçme yöntemlerinin uygulanması gereklidir.


Kanal seçme yöntemleri, tat alma duyusuna bağı EEG sinyallerinin analizinde kritik bir adımdır. Beynin belirli bölgelerindeki (insular korteks) aktiviteler tat duyusuna daha duyarlı olabilir ve bu bölgelerdeki sinyaller, nörolojik hastalıkların erken teşhisi veya ilerleyişinin izlenmesi için kullanışlı olabilir. Kanal seçme işlemi, EEG sinyallerinde önemli olan kanalların belirlenmesini sağlar ve bu sayede gereksiz bilgi yığılmasından kaçınılarak daha hassas ve doğru analizler yapılabilir. Özellikle tat alma duyusunun nörolojik hastalıklarla ilişkili bozulmalarının tespiti, belirli kanallardan elde edilen EEG sinyalleriyle daha net bir şekilde ortaya konabilir. Bu yöntem, Alzheimer, Parkinson gibi hastalıkların erken evrelerinde tat alma duyusundaki değişikliklerin beyin aktiviteleriyle nasıl ilişkili olduğunu anlamada önemli bir araç olabilir. Sonuç olarak, önerilen kanal seçme yönteminde hem yüksek doğruluk hem de işlem karmaşıklığının az olması bakımından bu alanda kullanılabilirliğinin yüksek olduğunu göstermektedir.

Bu çalışmada, RAKS yöntemi kullanılarak burun kapalı ve açık durumlarına tada dayalı olarak kaydedilen EEG sinyalleri analiz edilmiştir. Sinyal analizi sürecinde, tüm EEG kanalları arasından ortalama olarak 6,28 kanal seçilmiş ve bu kanallar kullanılarak %82 sınıflandırma doğruluğu elde edilmiştir. Buna karşılık, tüm kanalların kullanıldığı durumlarda sınıflandırma doğruluğu %79,2 olarak ölçülmüştür. Bu sonuçlar, önerilen yöntemin sınıflandırma performansında %3,79 oranında bir iyileştirme sağladığını ortaya koymaktadır. Bunun yanı sıra, kullanılan kanal sayısında %63,03 oranında bir azalma sağlanmış, bu da veri işleme sürecinin karmaşıklığının önemli ölçüde düşmesine katkı

sağlamıştır. Böylelikle, yalnızca sınıflandırma doğruluğu artırılmakla kalmamış, aynı zamanda işlem karmaşıklığı ve kaynak tüketimi de optimize edilmiştir.


Yapılan bu çalışma, EEG sinyalleri aracılığıyla beyin aktivitelerinin daha verimli ve odaklı bir şekilde incelenmesi için önemli bir adım sunmaktadır. Literatürde, insan beyninin hangi bölgelerinin belirli fonksiyonlardan sorumlu olduğu halen geniş bir araştırma konusu olarak yer almaktadır. Önerilen kanal seçme yöntemi, belirli görevlerle ilişkili en etkin kanalları belirleyerek, bu alandaki çalışmalara önemli bir katkı sunabilir. Bu yaklaşım, beyin bölgelerinin fonksiyonel haritalanması sürecinde daha hassas ve güvenilir sonuçlar elde edilmesine olanak tanıyabilir.

Ayrıca, bu çalışmada etkin olarak seçilen kanalların tekrar sayıları hesaplanmış ve sonuçlar, Şekil 38’de bir ısı haritası ile görselleştirilmiştir. Isı haritası, belirli kanalların göreve dayalı etkinlik düzeylerini açıkça ortaya koymuş ve bu kanalların beyin aktivitesi üzerindeki önemini vurgulamıştır. Dolayısıyla, önerilen yöntemin EEG sinyalleri üzerinden gerçekleştirilecek diğer çalışmalarda da işlem karmaşıklığını azaltarak daha etkin sonuçlar sağlayabileceği düşünülmektedir.



Şekil 38. Önerilen yöntem ile seçilen kanalların ısı haritası

Şekil 38’de görüldüğü üzere önerilen yöntem ile seçilen kanallar arasında en fazla tekrar eden kanallar beyaz, sarı ve açık kahve rengi ile gösterilmiştir ve bu kanalların konumları insan beyninin üzerindeki konumları Şekil 39’da gösterilmiştir.



Şekil 39. Kanalların beyin üzerinde konumları

Bu çalışmada, Şekil 39’da gösterilen ve sarı renk ile işaretlenen elektrot konumları, insan beyinde tat algısı ile doğrudan ilişkili olan insular korteks bölgesine denk gelmektedir. İnsular korteks, tat duyusunun birincil kortikal merkezi olarak kabul edilmekte olup, temel tatların (tatlı, tuzlu, ekşi, acı, umami) algılanmasında ve işlenmesinde kritik bir rol oynamaktadır. Bu bölge, bireyin tat algısının farkındalığını sağlayarak, tatların ayrımının yapılmasında önemli bir nörofizyolojik süreç sunmaktadır (Frank vd., 2013) (Avery vd., 2020). İnsular korteks, tat algısının kortikal düzeyde nasıl işlendiğine dair önemli bilgiler sağlayarak, nörolojik çalışmalar için oldukça önemli bir hedef bölge olarak öne çıkmaktadır.

Tat duyusuna ilişkin nörofizyolojik mekanizmaların daha iyi anlaşılması için yapılan elektrofizyolojik çalışmalarda, beyin tat fonksiyonları ile ilgili bölgesel aktivitelerinin belirlenmesi hedeflenmiştir. Bu bağlamda, tat algısına yönelik sinyallerin en verimli şekilde alınabileceği elektrot konumlarının tespit edilmesi büyük önem taşımaktadır. Önerilen kanal seçme yöntemiyle gerçekleştirilen bu çalışmada, tat ile ilgili beyin aktivitelerinin en yoğun olduğu noktalar belirlenmiş ve sarı renk ile gösterilmiştir. Bu noktalar, insular korteksin tat algısındaki merkezi rolünü destekleyen bölgelerdir ve tat fonksiyonlarının analizi için ideal elektrot konumlarını işaret etmektedir.

Yapılan kanal seçme analizleri sonucunda, insular kortekse denk gelen elektrotların, tat ile ilişkili beyin sinyallerinin en etkin şekilde toplandığı bölgeler olduğu ortaya konmuştur.

Bu bulgular, tat duyusuna bağı beyin aktivitelerinin daha hassas bir şekilde değerlendirilmesine olanak tanımış ve tat algısı üzerine yapılan nörobilimsel çalışmaların doğruluğunu artıracak veriler sunmuştur. Ayrıca, insular korteksin bu tür çalışmalar için önemli bir odak noktası olabileceği vurgulanmıştır. Şekil 38'de görselleştirilen sarı renkli elektrot konumları, önerilen yöntemle seçilen etkin kanalları temsil etmekte olup, bu kanalların tat algısının beyin üzerindeki yansımalarını incelemeye yönelik çalışmalar için kritik bir referans noktası teşkil etmektedir.

Bu çalışmanın temel amacı, EEG sinyalleri aracılığıyla tat ve koku gibi duysal algıların beyindeki farklı bölgelere nasıl yansıdığını incelemek ve bu tepkilerin yüksek doğrulukla sınıflandırılmasına yönelik etkili bir yöntem geliştirmektir. Literatürde, tat ve koku duyularına yönelik EEG tabanlı çalışmaların sınırlı sayıda olması ve mevcut araştırmaların genellikle basit tat ve kokular üzerine yoğunlaşması, birbirine benzer ve ayrıştırılması zor tatlar ile beyin tepkilerinin nasıl farklılaştığını anlamaya yönelik önemli bir araştırma boşluğu ortaya koymaktadır. Bu eksikliği gidermek amacıyla, benzer tatların beyin tarafından nasıl ayrıştırıldığını anlamaya yönelik gelişmiş sinyal işleme ve kanal seçimi yöntemleri uygulanmıştır. Portakal, nane, kekik ve karanfil gibi farklı duysal uyarıcıların EEG sinyallerine olan etkilerini analiz ederek, beyin-bilgisayar arayüzü sistemleri ve nörolojik hastalıkların erken teşhisinde katkı sağlayabilecek bulgular elde edilmiştir. Çalışmada geliştirilen kanal seçimi yöntemleri, yalnızca etkin kanalların seçilmesi sayesinde sınıflandırma doğruluğunu artırırken aynı zamanda hesaplama maliyetlerini önemli ölçüde düşürmüştür. Bu araştırma, literatürdeki boşlukları doldurmayı hedefleyerek, tat ve koku algılarının EEG sinyalleri aracılığıyla daha etkin bir şekilde sınıflandırılması konusunda önemli bir bilimsel katkı sunmayı amaçlamaktadır. Elde edilen bulgular, sinir sistemine bağı nörolojik bozuklukların tanı ve tedavi süreçlerinde ileriye dönük olarak büyük faydalar sağlayabilir.

Önerilen yöntemin diğer yöntemlere göre avantajları ve dezavantajları şu şekilde özetlenebilir: Yöntem, en etkili kanalların seçilmesi sayesinde sınıflandırma doğruluğunu artırırken, gereksiz kanalların elimine edilmesiyle sinyallerin daha net bir şekilde işlenmesini sağlar ve hesaplama maliyetlerini önemli ölçüde azaltır. Bu, büyük veri setleriyle çalışırken zaman açısından verimlilik sağladığı gibi, özellikle karmaşık ve birbirine yakın tatların ayırt edilmesi gibi zorlayıcı problemler için güçlü bir performans sunar. Ayrıca, farklı veri setleri ve uygulamalar için uyarlanabilir olup, tat ve koku algılarının yanı sıra diğer bilişsel süreçlerin ve nörolojik bozuklukların incelenmesinde de kullanılabilir. Ancak

yöntemin uygulanabilmesi için gelişmiş ön işleme adımları ve ileri düzey sinyal işleme bilgisi gereklidir, bu da uygulamayı teknik olarak zorlaştırabilir. Kanal seçimi ve analiz süreçlerinin optimize edilmesi zaman alıcı olabileceği gibi, başarı oranı büyük ölçüde veri setinin kalitesine ve doğasına bağlıdır. Farklı veri setleri arasında tutarlılık sağlanamadığında, yöntem istenen performansı göstermeyebilir. Bu avantajlar ve dezavantajlar, yöntemin güçlü ve sınırlı yönlerini gözler önüne sererek, araştırma ve klinik uygulamalarda dikkat edilmesi gereken önemli noktaları ortaya koymaktadır.



5. SONUÇLAR

Önerilen RAKS yöntemi, Tat veri kümesinde %82,19 sınıflandırma doğruluğu (SD) sağlamış ve işlem karmaşıklığını %63,03 oranında azaltmıştır. Bu sonuçlar, burun açık ve kapalı durumlarının ortalamasına dayanmaktadır. Diğer yöntemlerle elde edilen en iyi sonuç ise %81,75 SD olarak rapor edilmiştir. RAKS yöntemi, Koku veri kümesinde göz açık ve kapalı durumlarının ortalaması alınarak %98,38 SD elde etmiş ve işlem karmaşıklığını %89,09 oranında azaltmıştır. Diğer yöntemlerle Koku veri kümesinde elde edilen en iyi SD sonucu %86,71 olarak elde edilmiştir. Motor hayali veri kümesi üzerinde RAKS yöntemiyle %81,56 SD elde edilirken, literatürde bulunan en iyi sonuç %80,5 SD olarak rapor edilmiştir. Ayrıca, Motor hayali veri kümesinde RAKS yöntemi işlem karmaşıklığını %75 oranında azaltmıştır. RAKS yöntemi hem sınıflandırma doğruluğu hem de işlem karmaşıklığının azaltılması açısından başarılı sonuçlar sunmuştur. Tat ve Motor Hayali veri kümelerinde diğer yöntemlere yakın ve başarılı sonuçlar elde edilirken, Koku veri kümesinde literatürdeki en iyi sonuçlardan daha üstün bir performans sergilemiştir. Ayrıca, RAKS yönteminin tüm veri kümelerinde işlem karmaşıklığını önemli ölçüde azalttığı, yöntemin verimli ve hızlı bir alternatif sunduğunu ortaya koymaktadır. Tat koku ve hayal için elde edilen sonuçların tablo 17’de verilmiştir.

Tablo 17. Tat koku ve hayal için elde edilen sonuçları

Veri kümesi	Önerilen raks Yöntemin Sonuç (%)	(GDE ve Sİ yöntemleri dahil) Literatürdeki Bulunan En İyi Sonuç (%)	Önerilen raks Yöntemin İşlem karmaşıklığını azaltılması (%)
Tat	82,19	81,75	63,03
Koku	98,38	86,71	89,09
Motor hayali	81,56	80,5	75

Bu çalışmanın temel amacı, EEG sinyalleri üzerinden tat ve koku algılarına ilişkin beyin aktivitelerinin sınıflandırılmasını iyileştiren yeni bir kanal seçimi yöntemi geliştirmek olmuştur. Çalışma boyunca elde edilen sonuçlar, önerilen yöntemin sınıflandırma doğruluğunu artırırken aynı zamanda veri işleme sürecindeki işlem karmaşıklığını önemli

ölçüde azalttığını göstermektedir. Özellikle, tat ve koku algılarına dayalı sinyallerin analizi sırasında gereksiz kanalların elimine edilmesi hem veri boyutunun küçültülmesine hem de model doğruluğunun artmasına olanak tanımıştır. Elde edilen bulgular, tat ve koku algılarının sinirsel temsilinin, nörolojik bozuklukların erken teşhisi ve tedavisi açısından önemli ipuçları sunduğunu göstermektedir. Çalışma, literatürdeki benzer araştırmalara kıyasla yüksek performans sağlamış ve özellikle önerilen kanal seçimi yöntemi ile daha verimli ve güvenilir sonuçlar elde edilmiştir. Önerilen yöntem hem hesaplama maliyetlerini azaltma hem de sınıflandırma doğruluğunu artırma potansiyeli sayesinde gelecekteki EEG tabanlı araştırmalarda ve klinik uygulamalarda geniş bir kullanım alanı bulabilir.



6. ÖNERİLER

EEG sinyallerinde kanal seçme, analizlerin doğruluğunu artırmak, veri işleme süresini kısaltmak ve sinyallerdeki gürültüyü minimize etmek için önemli bir adımdır. Kanal seçme yöntemlerinin optimizasyonu, EEG çalışmalarında verimliliği artırmanın yanı sıra, doğru sonuçlara ulaşmak için kritik rol oynar. Bu alanda, çeşitli öneriler ve stratejiler geliştirilebilir.

İlk olarak bileşen analizi (BA), kanal seçme sürecini iyileştirebilir. Örneğin, Ana Bileşen Analizi (PCA) ve Bağımsız Bileşen Analizi (ICA) gibi yöntemler, sinyalin en önemli bileşenlerini ayıklayarak gereksiz kanalları elemek için kullanılabilir. Bu sayede, analizde sadece yüksek bilgi içerikli kanallar kullanılır ve böylece veri boyutu küçültülürken sinyal kalitesi korunmuş olur. PCA ve ICA gibi teknikler, sinyallerin çeşitli kaynaklardan geldiği durumlarda faydalı olabilir ve sinyal-gürültü oranını artırabilir.

İkinci olarak, deney prosedürü üzerine yapılan iyileştirmeler kanal seçme sürecine olumlu katkılar sağlayabilir. Deney tasarımı, doğru kanal seçimi için kritik bir aşamadır. Bu süreçte, belirli görevler veya duyuşsal uyaranlar (örneğin, tat algısı gibi) için en uygun sinyal kayıt protokollerinin kullanılması, verimli kanal seçimi için büyük önem taşır. Özellikle, EEG deneylerinde katılımcıların dikkat düzeyi ve uyarıcılara verdiği yanıtlar, deney prosedürüne göre optimize edilmelidir. Ayrıca, denek sayısının artırılması da sinyallerdeki bireysel farklılıkları dengelemek için faydalı olabilir, böylece seçilen kanalların genellenebilirliği artar.

Üçüncü olarak, kanal seçimi süreci, yapay zekâ (AI) tabanlı optimizasyon teknikleriyle daha verimli hale getirilebilir. Özellikle Grey Wolf, PSO ve derin öğrenme yöntemleri, kanal seçimi sürecinde kullanılarak en verimli kanalların otomatik olarak belirlenmesini sağlayabilir. AI tabanlı optimizasyon, kanalların işlenmesinde hız ve doğruluk sağlar, ayrıca sinyal-gürültü oranını iyileştirme potansiyeli sunar. Bu yöntemler, insan müdahalesini en aza indirerek daha objektif ve tekrarlanabilir sonuçlar elde edilmesine olanak tanır.

Dördüncü olarak, kanal seçme işlemi, hibrit yöntemlerle desteklenerek daha etkin hale getirilebilir. Örneğin, farklı kanal seçme algoritmalarının veya analiz tekniklerinin bir arada kullanılması, tek bir yöntemden elde edilen sonuçlara göre daha kapsamlı ve güvenilir olabilir. Hibrit modeller hem frekans tabanlı hem de uzaysal bilgi kullanan yöntemlerin

birleřtirilmesi yoluyla, EEG sinyallerinden elde edilen bilgilerin daha iyi yorumlanmasını saęlayabilir.

Sonu olarak, EEG kanal seimi zerine yapılacak alıřmaların bileřen analizleri, deney prosedrlerinin optimize edilmesi, AI tabanlı optimizasyon tekniklerinin entegrasyonu ve hibrit yntemlerle geliřtirilmesi, sinyallerin daha verimli bir řekilde iřlenmesine ve analizlerde daha yksek doęruluk oranlarına ulařılmasına olanak tanıyabilir. Bu neriler, EEG sinyallerinde kanal seme iřleminin hem teorik hem de pratik uygulamalarda daha etkili bir řekilde kullanılmasını destekleyeceęi dřnlmektedir.



7. KAYNAKLAR

- Abdullah, Faye, I., & Islam, M. R. (2022). EEG channel selection techniques in motor imagery applications: a review and new perspectives. *Bioengineering*, 9(12), 726.
- Abu Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S., & Prasath, V. S. (2019). Effects of distance measure choice on k-nearest neighbor classifier performance: a review. *Big data*, 7(4), 221-248.
- Agarwal, P., & Kumar, S. (2024). EEG-based imagined words classification using Hilbert transform and deep networks. *Multimedia Tools and Applications*, 83(1), 2725-2748.
- Ahire, N., Awale, R. N., Patnaik, S., & Wagh, A. (2023). A comprehensive review of machine learning approaches for dyslexia diagnosis. *Multimedia Tools and Applications*, 82(9), 13557-13577.
- Ahmad, I., Yao, C., Li, L., Chen, Y., Liu, Z., Ullah, I., ... & Chen, S. (2024). An efficient feature selection and explainable classification method for EEG-based epileptic seizure detection. *Journal of Information Security and Applications*, 80, 103654.
- Ahmad, I., Zhu, M., Li, G., Javeed, D., Kumar, P., & Chen, S. (2024). A secure and interpretable AI for smart healthcare system: A case study on epilepsy diagnosis using EEG signals. *IEEE Journal of Biomedical and Health Informatics*.
- Ajra, Z., Xu, B., Dray, G., Montmain, J., & Perrey, S. (2023). Using shallow neural networks with functional connectivity from EEG signals for early diagnosis of Alzheimer's and frontotemporal dementia. *Frontiers in Neurology*, 14, 1270405.
- Ali, A., Afridi, R., Soomro, T. A., Khan, S. A., Khan, M. Y. A., & Chowdhry, B. S. (2022). A single-channel wireless EEG headset enabled neural activities analysis for mental healthcare applications. *Wireless Personal Communications*, 125(4), 3699-3713.
- Allahbakhshi, M., Sadri, A., & Shahdi, S. O. (2024). Diagnosis of Parkinson's Disease Using EEG Signals and Machine Learning Techniques: A Comprehensive Study. *arXiv preprint arXiv:2405.00741*.
- Alotaiby, T., El-Samie, F. E. A., Alshebeili, S. A., & Ahmad, I. (2015). A review of channel selection algorithms for EEG signal processing. *EURASIP Journal on Advances in Signal Processing*, 2015, 1-21.
- Al-Qaysi, Z. T., Ahmed, M. A., Hammash, N. M., Hussein, A. F., Albahri, A. S., Suzani, M. S., & Al-Bander, B. (2023). A systematic rank of smart training environment applications with motor imagery brain-computer interface. *Multimedia Tools and Applications*, 82(12), 17905-17927.
- Armstrong, R. A. (2021). The structure of the human brain as revealed in six histological sections. In *Diagnosis, Management and Modeling of Neurodevelopmental Disorders* (pp. 3-11). Academic Press.

- Attar, E. T. (2022). Review of electroencephalography signals approaches for mental stress assessment. *Neurosciences Journal*, 27(4), 209-215.
- Atzingen, G. V. V., Arteaga, H., Silva, A. R. D., Ortega, N. F., Costa, E. J. X., & Silva, A. C. D. S. (2022). The convolutional neural network as a tool to classify electroencephalography data resulting from the consumption of juice sweetened with caloric or non-caloric sweeteners. *Frontiers in Nutrition*, 9, 901333.
- Avery, J. A., Liu, A. G., Ingeholm, J. E., Riddell, C. D., Gotts, S. J., & Martin, A. (2020). Taste quality representation in the human brain. *Journal of Neuroscience*, 40(5), 1042-1052.
- Aydemir, O. (2017). Olfactory recognition based on EEG gamma-band activity. *Neural computation*, 29(6), 1667-1680.
- Aydemir, Ö., & Kayıkçıoğlu, T. (2009). EEG tabanlı beyin bilgisayar arayüzleri. *Akademik Bilişim*, 9, 11-13.
- Aydemir, O., & Ergün, E. (2019). A robust and subject-specific sequential forward search method for effective channel selection in brain computer interfaces. *Journal of neuroscience methods*, 313, 60-67.
- Baig, M. Z., Aslam, N., Shum, H. P., & Zhang, L. (2017). Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG. *Expert Systems with Applications*, 90, 184-195.
- Balakrishnama, S., & Ganapathiraju, A. (1998). Linear discriminant analysis-a brief tutorial. *Institute for Signal and information Processing*, 18(1998), 1-8.
- Bear, M., Connors, B., & Paradiso, M. A. (2020). *Neuroscience: exploring the brain, enhanced edition: exploring the brain*. Jones & Bartlett Learning.
- Behzad, R., & Behzad, A. (2021). The role of EEG in the diagnosis and management of patients with sleep disorders. *Journal of Behavioral and Brain Science*, 11(10), 257-266.
- Blankertz, B., Curio, G. ve Muller, K. R., (2002). Classifying single trial EEG: towards brain computer interfacing. *Adv. Neural Inf. Process. Syst. (NIPS 01)* 14 157–64.
- Borisoff, J. F., Mason, S. G., Bashashati, A., ve Birch, G. E., (2004). Brain–computer interface design for asynchronous control applications: improvements to the lf-asd asynchronous brain switch. *IEEE Trans. Biomed. Eng.* 51, 985–92.
- Boyacı, D., & İçigen, M. (2021). Profesyonel aşçıların tat ve lezzet kavramlarına ilişkin bilgi düzeylerinin belirlenmesi. *Ankara Hacı Bayram Veli Üniversitesi Turizm Fakültesi Dergisi*, 24(2), 310-329.
- Brari, Z., & Belghith, S. (2021). A novel Machine Learning approach for epilepsy diagnosis using EEG signals based on Correlation Dimension. *IFAC-PapersOnLine*, 54(17), 7-11.

- Britton, J. W., Frey, L. C., Hopp, J. L., Korb, P., Koubeissi, M. Z., Lievens, W. E., ... & St Louis, E. K. (2016). *Electroencephalography (EEG): An introductory text and atlas of normal and abnormal findings in adults, children, and infants*.
- Carter, R. (2019). *The brain book: An illustrated guide to its structure, functions, and disorders*. Dorling Kindersley Ltd.
- Chaichanasittikarn, O., Jiang, M., Seet, M., Saba, M., Hamano, J., & Dragomir, A. (2023, April). Wearable EEG-Based Classification of Odor-Induced Emotion. In 2023 11th International IEEE/EMBS Conference on Neural Engineering (NER) (pp. 1-4). IEEE.
- Chaddad, A., Wu, Y., Kateb, R., & Bouridane, A. (2023). Electroencephalography signal processing: A comprehensive review and analysis of methods and techniques. *Sensors*, 23(14), 6434.
- Chen, L., & Hao, Y. (2017). Feature Extraction and Classification of EHG between Pregnancy and Labour Group Using Hilbert-Huang Transform and Extreme Learning Machine. *Computational and Mathematical Methods in Medicine*, 2017(1), 7949507.
- ÇELTEK, A., & ALTUN, Ö. (2023). Effects of Human Factors in Aviation Sectors: Case of Overconfidence. *BİDGE Yayınları*.
- Cohen, M. X. (2014). Fluctuations in oscillation frequency control spike timing and coordinate neural networks. *Journal of Neuroscience*, 34(27), 8988-8998.
- Crouzet, S. M., Busch, N. A., & Ohla, K. (2015). Taste quality decoding parallels taste sensations. *Current Biology*, 25(7), 890-896.
- De Miras, J. R., Ibáñez-Molina, A. J., Soriano, M. F., & Iglesias-Parro, S. (2023). Schizophrenia classification using machine learning on resting state EEG signal. *Biomedical Signal Processing and Control*, 79, 104233.
- De Oliveira, A. P. S., De Santana, M. A., Andrade, M. K. S., Gomes, J. C., Rodrigues, M. C., & dos Santos, W. P. (2020). Early diagnosis of Parkinson's disease using EEG, machine learning and partial directed coherence. *Research on Biomedical Engineering*, 36, 311-331.
- Deivasigamani, S., Senthilpari, C., & Yong, W. H. (2021). Retracted article: machine learning method based detection and diagnosis for epilepsy in EEG signal. *Journal of Ambient Intelligence and Humanized Computing*, 12(3), 4215-4221.
- DeSesso, J. M. (2009). Functional anatomy of the brain. *Metabolic Encephalopathy*, 1-14.
- Dobrakowski, P., Blaszkiewicz, M., & Skalski, S. (2020). Changes in the Electrical Activity of the Brain in the Alpha and Theta Bands during Prayer and Meditation. *International Journal of Environmental Research and Public Health*, 17(24), 9567.
- Donnelly, L. (2011). The brain: functional divisions. *Anaesthesia & Intensive Care Medicine*, 12(5), 208-213.

- Dong, Y., Wang, S., Huang, Q., Berg, R. W., Li, G., & He, J. (2023). Neural decoding for intracortical brain–computer interfaces. *Cyborg and Bionic Systems*, 4, 0044.
- Edla, D. R., Mangalorekar, K., Dhavalikar, G., & Dodia, S. (2018). Classification of EEG data for human mental state analysis using Random Forest Classifier. *Procedia computer science*, 132, 1523-1532.
- Ezzatdoost, K., Hojjati, H., & Aghajan, H. (2020). Decoding olfactory stimuli in EEG data using nonlinear features: A pilot study. *Journal of Neuroscience Methods*, 341, 108780.
- Figuerola-García, J. C., López-Santana, E. R., & Rodríguez-Molano, J. I. (Eds.). (2018). *Applied Computer Sciences in Engineering: 5th Workshop on Engineering Applications, WEA 2018, Medellín, Colombia, October 17-19, 2018, Proceedings, Part I (Vol. 915)*. Springer.
- Fraiwan, L., Lweesy, K., Khasawneh, N., Wenz, H., & Dickhaus, H. (2012). Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier. *Computer methods and programs in biomedicine*, 108(1), 10-19.
- Frank, S., Kullmann, S., & Veit, R. (2013). Food related processes in the insular cortex. *Frontiers in human neuroscience*, 7, 499.
- Garrett, D., Peterson, D. A., Anderson, C. W., & Thaut, M. H. (2003). Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. *IEEE Transactions on neural systems and rehabilitation engineering*, 11(2), 141-144.
- Gao, H., Zhao, S., Li, H., Liu, L., Wang, H., Wang, Y., ... & Li, G. (2023). Basic taste sensation recognition from EEG based on multiscale convolutional neural network with residual learning. *IEEE Transactions on Instrumentation and Measurement*, 72, 1-10.
- Genon, S., Reid, A., Langner, R., Amunts, K., & Eickhoff, S. B. (2018). How to characterize the function of a brain region. *Trends in cognitive sciences*, 22(4), 350-364.
- Gupta, V., & Mittal, M. (2020). Efficient R-peak detection in electrocardiogram signal based on features extracted using Hilbert transform and Burg method. *Journal of the Institution of Engineers (India): Series B*, 101(1), 23-34.
- Göker, H., & Tosun, M. (2023). Fast Walsh–Hadamard transform and deep learning approach for diagnosing psychiatric diseases from electroencephalography (EEG) signals. *Neural Computing and Applications*, 35(32), 23617-23630.
- Hasan, M. R., Ibrahimy, M. I., Motakabber, S. M. A., & Shahid, S. (2015). Classification of multichannel EEG signal by linear discriminant analysis. In *Progress in Systems Engineering: Proceedings of the Twenty-Third International Conference on Systems Engineering* (pp. 279-282). Springer International Publishing.

- Hashida, J. C., de Sousa Silva, A. C., Souto, S., & Costa, E. J. X. (2005). EEG pattern discrimination between salty and sweet taste using adaptive Gabor transform. *Neurocomputing*, 68, 251-257.
- Hochberg, L. R., Bacher, D., Jarosiewicz, B., Masse, N. Y., Simeral, J. D., Vogel, J., ... & Donoghue, J. P. (2012). Reach and grasp by people with tetraplegia using a neurally controlled robotic arm. *Nature*, 485(7398), 372-375.
- Husain, M., & Schott, J. M. (Eds.). (2016). *Oxford textbook of cognitive neurology and dementia*. Oxford University Press.
- Inamoto, Y., Ueha, R., & Gonzalez-Fernandez, M. (2024). Use of CT for Dysphagia Evaluation: Advantages and Disadvantages in the Study of Swallowing. *Current Physical Medicine and Rehabilitation Reports*, 1-6.
- Jessell, T. M., Siegelbaum, S. A., & Hudspeth, A. J. (1991). Principles of neural science (pp. 173-193). J. H. Schwartz, & E. R. Kandel (Eds.). New York: Elsevier.
- Jafari, M., Sadeghi, D., Shoeibi, A., Alinejad-Rokny, H., Beheshti, A., García, D. L., ... & Gorriz, J. M. (2024). Empowering precision medicine: AI-driven schizophrenia diagnosis via EEG signals: A comprehensive review from 2002–2023. *Applied Intelligence*, 54(1), 35-79.
- Jurcak, V., Tsuzuki, D., & Dan, I. (2007). 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. *Neuroimage*, 34(4), 1600-1611.
- Kappacher, C., Schwarz, B., Rainer, M., & Huck, C. W. (2024). Unveiling the synergy of NIRS and enrichment technologies: A comprehensive review of in-sorbent-based detection and quantification strategies. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 123955.
- Karssemakers, L. H. E., Besseling, L. M. P., Schoonmade, L. J., Su, N., Nolte, J. W., Raijmakers, P. G., & Becking, A. G. (2024). Diagnostic accuracy of bone SPECT and SPECT/CT imaging in the diagnosis of unilateral condylar hyperplasia: A systematic review and meta-analysis. *Journal of Cranio-Maxillofacial Surgery*.
- Kroupi, E., Yazdani, A., Vesin, J.-M., & Ebrahimi, T. (2014). EEG correlates of pleasant and unpleasant odor perception. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 11(1s), 1-17.
- Knight, J. N. (2003). *Signal fraction analysis and artifact removal in EEG* (Doctoral dissertation, Colorado State University).
- Kurtuldu, E., Miloğlu, Ö., Derindağ, G., & Özdoğan, A. (2018). TAT DUYU BOZUKLUKLARINA GENEL BAKIŞ. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 28(2), 277-283.
- Kumar, K., Kumar, P., Patel, R. K., Sharma, M., Bajaj, V., & Acharya, U. R. (2024). Time frequency distribution and deep neural network for automated identification of insomnia using single channel EEG-signals. *IEEE Latin America Transactions*, 22(3), 186-194.

- Kumar, S., Sharma, A., & Tsunoda, T. (2017). An improved discriminative filter bank selection approach for motor imagery EEG signal classification using mutual information. *BMC bioinformatics*, 18, 125-137.
- Lee, H. C., & Lee, C. H. (2023). Generalized Optimal EEG Channels Selection for Motor Imagery Brain-Computer Interface. *IEEE Sensors Journal*.
- Li, K., Ao, B., Wu, X., Wen, Q., Ul Haq, E., & Yin, J. (2023). Parkinson's disease detection and classification using EEG based on deep CNN-LSTM model. *Biotechnology and Genetic Engineering Reviews*, 1-20.
- Liu, X., Wang, S., Lu, S., Yin, Z., Li, X., Yin, L., ... & Zheng, W. (2023). Adapting feature selection algorithms for the classification of Chinese texts. *Systems*, 11(9), 483.
- Lopes da Silva, F. H., & Niedermeyer, E. (2005). *Electroencephalography, basic principles, clinical applications and related fields*.
- Lovinger, D. M. (2008). Communication networks in the brain: neurons, receptors, neurotransmitters, and alcohol. *Alcohol Research & Health*, 31(3), 196.
- Luo, J., Ding, P., Gong, A., Tian, G., Xu, H., Zhao, L., & Fu, Y. (2022). Applications, industrial transformation and commercial value of brain-computer interface technology. *Sheng wu yi xue Gong Cheng xue za zhi= Journal of Biomedical Engineering= Shengwu Yixue Gongchengxue Zazhi*, 39(2), 405-415.
- Ma, Z. Z., Wu, J. J., Cao, Z., Hua, X. Y., Zheng, M. X., Xing, X. X., ... & Xu, J. G. (2024). Motor imagery-based brain-computer interface rehabilitation programs enhance upper extremity performance and cortical activation in stroke patients. *Journal of NeuroEngineering and Rehabilitation*, 21(1), 91.
- Maimaiti, B., Meng, H., Lv, Y., Qiu, J., Zhu, Z., Xie, Y., ... & Li, M. (2022). An overview of EEG-based machine learning methods in seizure prediction and opportunities for neurologists in this field. *Neuroscience*, 481, 197-218.
- Mantini, D., Perrucci, M. G., Del Gratta, C., Romani, G. L., & Corbetta, M. (2007). Electrophysiological signatures of resting state networks in the human brain. *Proceedings of the National Academy of Sciences*, 104(32), 13170-13175.
- Marino, M., & Mantini, D. (2024). Human brain imaging with high-density electroencephalography: Techniques and applications. *The Journal of Physiology*.
- Matthews, P. M., Honey, G. D., & Bullmore, E. T. (2006). Applications of fMRI in translational medicine and clinical practice. *Nature Reviews Neuroscience*, 7(9), 732-744.
- Matsuki, A., Kori, H., & Kobayashi, R. (2023). An extended Hilbert transform method for reconstructing the phase from an oscillatory signal. *Scientific Reports*, 13(1), 3535.

- Ma, Z. Z., Wu, J. J., Cao, Z., Hua, X. Y., Zheng, M. X., Xing, X. X., ... & Xu, J. G. (2024). Motor imagery-based brain-computer interface rehabilitation programs enhance upper extremity performance and cortical activation in stroke patients. *Journal of NeuroEngineering and Rehabilitation*, 21(1), 91.
- Mir, W. A., Anjum, M., & Shahab, S. (2023). Deep-EEG: an optimized and robust framework and method for EEG-based diagnosis of epileptic seizure. *Diagnostics*, 13(4), 773.
- Modir, A., Shamekhi, S., & Ghaderyan, P. (2023). A systematic review and methodological analysis of EEG-based biomarkers of Alzheimer's disease. *Measurement*, 113274.
- Naser, A., & Aydemir, O. (2023). Classification of pleasant and unpleasant odor imagery EEG signals. *Neural Computing and Applications*, 35(12), 9105-9114.
- Nour, M., Senturk, U., & Polat, K. (2023). Diagnosis and classification of Parkinson's disease using ensemble learning and 1D-PDCovNN. *Computers in biology and medicine*, 161, 107031.
- Nunez, P. L., & Srinivasan, R. (2006). *Electric fields of the brain: the neurophysics of EEG*. Oxford University Press, USA.
- Oikonomou, V. P., Georgiadis, K., Liaros, G., Nikolopoulos, S., & Kompatsiaris, I. (2017, June). A comparison study on EEG signal processing techniques using motor imagery EEG data. In *2017 IEEE 30th international symposium on computer-based medical systems (CBMS)* (pp. 781-786). IEEE.
- Ogawa, T., Annear, M. J., Ikebe, K., & Maeda, Y. (2017). Taste-related sensations in old age. *Journal of Oral Rehabilitation*, 44(8), 626-635.
- Oostenveld, R., & Praamstra, P. (2001). The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*, 112(4), 713-719.
- Ortiz-Catalan, M., Håkansson, B., & Brånemark, R. (2014). An osseointegrated human-machine gateway for long-term sensory feedback and motor control of artificial limbs. *Science translational medicine*, 6(257), 257re6-257re6.
- Otero, T. M., & Barker, L. A. (2013). The frontal lobes and executive functioning. In *Handbook of executive functioning* (pp. 29-44). New York, NY: Springer New York.
- Padfield, N., Zabalza, J., Zhao, H., Masero, V., & Ren, J. (2019). EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors*, 19(6), 1423.
- Park, C., Looney, D., & Mandic, D. P. (2011, August). Estimating human response to taste using EEG. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 6331-6334). IEEE.
- Pahuja, S. K., & Veer, K. (2022). Recent approaches on classification and feature extraction of EEG signal: A review. *Robotica*, 40(1), 77-101.

- Peng, C. J., Chen, Y. C., Chen, C. C., Chen, S. J., Cagneau, B., & Chassagne, L. (2020). An EEG-based attentiveness recognition system using Hilbert–Huang transform and support vector machine. *Journal of Medical and Biological Engineering*, 40(2), 230-238.
- Perez-Valero, E., Morillas, C., Lopez-Gordo, M. A., & Minguillon, J. (2023). Supporting the detection of early Alzheimer’s disease with a four-channel EEG analysis. *International Journal of Neural Systems*, 33(04), 2350021.
- Peter-Derex, L., Berthomier, C., Taillard, J., Berthomier, P., Bouet, R., Mattout, J., ... & Bastuji, H. (2021). Automatic analysis of single-channel sleep EEG in a large spectrum of sleep disorders. *Journal of Clinical Sleep Medicine*, 17(3), 393-402.
- Rajinikanth, V., Kadry, S., Taniar, D., Kamalanand, K., Elaziz, M. A., & Thanaraj, K. P. (2023). Detecting epilepsy in EEG signals using synchro-extracting-transform (SET) supported classification technique. *Journal of Ambient Intelligence and Humanized Computing*, 14(8), 10123-10141.
- Ramos-Aguilar, R., Olvera-López, J. A., Olmos-Pineda, I., & Sánchez-Urrieta, S. (2020). Feature extraction from EEG spectrograms for epileptic seizure detection. *Pattern Recognition Letters*, 133, 202-209.
- Ranjan, R., Sahana, B. C., & Bhandari, A. K. (2024). Deep learning models for diagnosis of schizophrenia using EEG signals: emerging trends, challenges, and prospects. *Archives of Computational Methods in Engineering*, 31(4), 2345-2384.
- Runnova, A., Selskii, A., Kiselev, A., Shamionov, R., Parsamyan, R., & Zhuravlev, M. (2021). Changes in EEG alpha activity during attention control in patients: association with sleep disorders. *Journal of Personalized Medicine*, 11(7), 601.
- Saa, J. F. D., & Gutierrez, M. S. (2010, June). EEG signal classification using power spectral features and linear discriminant analysis: a brain computer interface application. In *Eighth Latin American and Caribbean Conference for Engineering and Technology* (pp. 1-7). Arequipa: LACCEI.
- Saber, M. (2022). Removing Powerline Interference from EEG Signal using Optimized FIR Filters. *J. Artif. Intell. Metaheuristics*, 1(1), 8-19.
- Sarcan, E. T., & Özer, Y. (2023). Monoclonal antibodies and immuno-PET imaging: An overview. *Fabad Journal of Pharmaceutical Sciences*, 48(1), 165-182.
- SabbaghGol, H., Saadatfar, H., & Khazaiepoor, M. (2024). Evolution of the random subset feature selection algorithm for classification problem. *Knowledge-Based Systems*, 285, 111352.
- Sarnthein, J., & Neidert, M. C. (2024). A profile on the WISE cortical strip for intraoperative neurophysiological monitoring. *Expert Review of Medical Devices*, 21(5), 373-379.
- Saraiva, A. A., Castro, F. M. D. J., Nascimento, R. C., de Melo, R. T., Moura Sousa, J. V., Valente, A., & Fonseca Ferreira, N. M. (2020). Electroencephalography applied compression algorithms qualitative analysis. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 8(4), 367-373.

- Sedghizadeh, M. J., Hojjati, H., Ezzatdoost, K., Aghajan, H., Vahabi, Z., & Tarighatnia, H. (2020). Olfactory response as a marker for Alzheimer's disease: Evidence from perceptual and frontal lobe oscillation coherence deficit. *PloS one*, 15(12), e0243535.
- Shakshi, R. J., & Jaswal, R. (2016). Brain wave classification and feature extraction of EEG signal by using FFT on lab view. *Int. Res. J. Eng. Technol*, 3, 1208-1212.
- Sharma, M., Anand, D., Verma, S., & Acharya, U. R. (2023). Automated insomnia detection using wavelet scattering network technique with single-channel EEG signals. *Engineering Applications of Artificial Intelligence*, 126, 106903.
- Shin, J., von Lühmann, A., Blankertz, B., Kim, D. W., Jeong, J., Hwang, H. J., & Müller, K. R. (2016). Open access dataset for EEG+ NIRS single-trial classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(10), 1735-1745.
- Shor, O., Yaniv-Rosenfeld, A., Valevski, A., Weizman, A., Khrennikov, A., & Benninger, F. (2023). EEG-based spatio-temporal relation signatures for the diagnosis of depression and schizophrenia. *Scientific Reports*, 13(1), 776.
- Short, M. R., Hernandez-Pavon, J. C., Jones, A., & Pons, J. L. (2021). EEG hyperscanning in motor rehabilitation: a position paper. *Journal of NeuroEngineering and Rehabilitation*, 18(1), 98.
- Siddharth, S., Jung, T. P., & Sejnowski, T. J. (2019). Impact of affective multimedia content on the electroencephalogram and facial expressions. *Scientific Reports*, 9(1), 16295.
- Simmatis, L., Russo, E. E., Geraci, J., Harmsen, I. E., & Samuel, N. (2023). Technical and clinical considerations for electroencephalography-based biomarkers for major depressive disorder. *npj Mental Health Research*, 2(1), 18.
- Snipes, S., Krugliakova, E., Meier, E., & Huber, R. (2022). The theta paradox: 4-8 Hz EEG oscillations reflect both sleep pressure and cognitive control. *Journal of Neuroscience*, 42(45), 8569-8586.
- Songsamoe, S., Saengwong-ngam, R., Koomhin, P., & Matan, N. (2019). Understanding consumer physiological and emotional responses to food products using electroencephalography (EEG). *Trends in Food Science & Technology*, 93, 167-173.
- Souza-Couto, D., Bretas, R., & Aversí-Ferreira, T. A. (2023). Neuropsychology of the parietal lobe: Luria's and contemporary conceptions. *Frontiers in Neuroscience*, 17, 1226226.
- Syriopoulos, P. K., Kalampalikis, N. G., Kotsiantis, S. B., & Vrahatis, M. N. (2023). k-NN Classification: a review. *Annals of Mathematics and Artificial Intelligence*, 1-33.
- Sultana, O. F., Bandaru, M., Islam, M. A., & Reddy, P. H. (2024). Unraveling the complexity of human brain: structure, function in healthy and disease states. *Ageing Research Reviews*, 100, 102414.

- Tait, L., Tamagnini, F., Stothart, G., Barvas, E., Monaldini, C., Frusciante, R., ... & Goodfellow, M. (2020). EEG microstate complexity for aiding early diagnosis of Alzheimer's disease. *Scientific Reports*, 10(1), 17627.
- Tang, C., Gao, T., Li, Y., & Chen, B. (2022). EEG channel selection based on sequential backward floating search for motor imagery classification. *Frontiers in Neuroscience*, 16, 1045851.
- Ting, W., Guo-Zheng, Y., Bang-Hua, Y., & Hong, S. (2008). EEG feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement*, 41(6), 618-625.
- Tiwari, A., & Chaturvedi, A. (2021). A novel channel selection method for BCI classification using dynamic channel relevance. *IEEE Access*, 9, 126698-126716.
- Uchida, N., Buck, D. W., He, D., Reitsma, M. J., Masek, M., Phan, T. V., ... & Weissman, I. L. (2000). Direct isolation of human central nervous system stem cells. *Proceedings of the National Academy of Sciences*, 97(26), 14720-14725.
- Uktveris, T., & Jusas, V. (2015). Comparison of feature extraction methods for EEG BCI classification. In *Information and Software Technologies: 21st International Conference, ICIST 2015, Druskininkai, Lithuania, October 15-16, 2015, Proceedings 21* (pp. 81-92). Springer International Publishing.
- Usman, S. M., Khalid, S., Akhtar, R., Bortolotto, Z., Bashir, Z., & Qiu, H. (2019). Using scalp EEG and intracranial EEG signals for predicting epileptic seizures: Review of available methodologies. *Seizure*, 71, 258-269.
- Uysal, S. (2023). *Functional Neuroanatomy and Clinical Neuroscience: Foundations for Understanding Disorders of Cognition and Behavior*. Oxford University Press.
- Vansteensel, M. J., Pels, E. G., Bleichner, M. G., Branco, M. P., Denison, T., Freudenburg, Z. V., ... & Ramsey, N. F. (2016). Fully implanted brain-computer interface in a locked-in patient with ALS. *New England Journal of Medicine*, 375(21), 2060-2066.
- Velasco-Álvarez, F., Fernández-Rodríguez, Á., Vizcaíno-Martín, F. J., Díaz-Estrella, A., & Ron-Angevin, R. (2021). Brain-computer interface (BCI) control of a virtual assistant in a smartphone to manage messaging applications. *Sensors*, 21(11), 3716.
- Wadichar, A., Murarka, S., Shah, D., Bhurane, A., Sharma, M., Mir, H. S., & Acharya, U. R. (2023). A hierarchical approach for the diagnosis of sleep disorders using convolutional recurrent neural network. *IEEE Access*.
- Wang, C., Xu, T., Yu, W., Li, T., Han, H., Zhang, M., & Tao, M. (2022). Early diagnosis of Alzheimer's disease and mild cognitive impairment based on electroencephalography: from the perspective of event-related potentials and deep learning. *International Journal of Psychophysiology*, 182, 182-189.
- Wei, L., Ventura, S., Lowery, M., Ryan, M. A., Mathieson, S., Boylan, G. B., & Mooney, C. (2020, July). Random forest-based algorithm for sleep spindle detection in infant EEG. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 58-61). IEEE.

- Xia, X., Liu, X., Zheng, W., Jia, X., Wang, B., Shi, Y., & Men, H. (2023). Recognition of odor and pleasantness based on olfactory EEG combined with functional brain network model. *International Journal of Machine Learning and Cybernetics*, 14(8), 2761-2776.
- Xia, X., Yang, Y., Shi, Y., Zheng, W., & Men, H. (2024). Decoding human taste perception by reconstructing and mining temporal-spatial features of taste-related EEGs. *Applied Intelligence*, 54(5), 3902-3917.
- Yang, T., Zhang, P., Xing, L., Hu, J., Feng, R., Zhong, J., ... & Qian, Z. (2023). Insights into brain perceptions of the different taste qualities and hedonic valence of food via scalp electroencephalogram. *Food Research International*, 173, 113311.
- Yazdani, A., Kroupi, E., Vesin, J. M., & Ebrahimi, T. (2012, July). Electroencephalogram alterations during perception of pleasant and unpleasant odors. In *2012 Fourth International Workshop on Quality of Multimedia Experience* (pp. 272-277). IEEE.
- Yen, C., Lin, C. L., & Chiang, M. C. (2023). Exploring the frontiers of neuroimaging: a review of recent advances in understanding brain functioning and disorders. *Life*, 13(7), 1472.
- Zhang, Y., Liu, B., Ji, X., & Huang, D. (2017). Classification of EEG signals based on autoregressive model and wavelet packet decomposition. *Neural Processing Letters*, 45, 365-378.
- Zhang, Y. (2012). Support vector machine classification algorithm and its application. In *Information Computing and Applications: Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings, Part II 3* (pp. 179-186). Springer Berlin Heidelberg.
- Zheng, Z., Jing, X., Wang, Y., Song, X., & Li, H. (2023). A comparison of wavelet packet, wavelet leaders multifractal, and p-leader multifractal method in chatter detection. *Nanomanufacturing and Metrology*, 6(1), 10.
- Yuan, L., & Cao, J. (2018). Patients' EEG data analysis via spectrogram image with a convolution neural network. In *Intelligent Decision Technologies 2017: Proceedings of the 9th KES International Conference on Intelligent Decision Technologies (KES-IDT 2017)–Part I 9* (pp. 13-21). Springer International Publishing.

ÖZGEÇMİŞ

İlköğrenimini Abozer İlköğretim Okulu'nda bitirdikten sonra lise eğitimini 2003 yılında Khoy Rajai Lisesi'nde tamamladı. 2010-2011 öğretim yılında Tebriz Azad Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği bölümünde lisans eğitimine başladı. 2012 yılında bu bölümden mezun oldu. 2012 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı. 2016 yılında “Kablosuz Algılayıcı Ağlarda Kapasiteye Dayalı Akıllı ve Adaptif Ağ Yapılandırması” başlıklı yüksek lisans tezini sundu. 2017 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde doktora programına başladı. İyi derece İngilizce bilen Naser evli ve bir çocuk babasıdır. Tezden üretilen akademik çalışmaları ve yayınları aşağıdadır.

Projeler

118E241 - Beynin Farklı Koku ve Tat Etkileşimine Verdiği EEG işaretlerin İncelenmesi ve Sınıflandırılması (TUBİTAK 1001)

Makale(ler)

Naser, A., & Aydemir, O. (2023). Classification of pleasant and unpleasant odor imagery EEG signals. *Neural Computing and Applications*, 35(12), 9105-9114.

Naser, A., & Aydemir, O. (2024). Enhancing EEG signal classification with a novel random subset channel selection approach: Applications in taste, odor, and motor imagery analysis. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.3473810>

Hakemli Kongre / Sempozyumların Bildiri Kitaplarında Yer Alan Yayın(lar)

Aydemir, Ö., Naser, A., & Öztürk, M. (2020, October). Classification of EEG signals recorded while imagining odors with effective band pass filter parameters. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.