



KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

NÖROPAZARLAMA STRATEJİLERİNİN
GELİŞTİRİLMESİ AMACIYLA EEG SİNYAL İŞLEME
TEKNİKLERİNİN BELİRLENMESİ

YÜKSEK LİSANS
TEZİ

SUZAN SABAN

DANIŞMAN
DR. ÖĞR. ÜYESİ EDA DAĞDEVİR



2025

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

**NÖROPAZARLAMA STRATEJİLERİNİN GELİŞTİRİLMESİ
AMACIYLA EEG SİNYAL İŞLEME TEKNİKLERİNİN
BELİRLENMESİ**

(Yüksek Lisans Tezi)

**Hazırlayan
Suzan SABAN**

**Danışman
Dr. Öğr. Üyesi Eda DAĞDEVİR**

**Jüri Üyeleri
Prof. Dr. Fatma LATİFOĞLU
Doç. Dr. Nimet KORKMAZ
Dr. Öğr. Üyesi Eda DAĞDEVİR**

**Temmuz 2025
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Suzan SABAN





TEZ İNTİHAL RAPORU TESLİM FORMU

Doküman No	FR-287
İlk Yayın Tarihi	8/02/2022
Revizyon Tarihi	-
Revizyon No	0
Sayfa No	ii/1

T.C.
Kayseri Üniversitesi
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Anabilim Dalı : Elektrik-Elektronik Mühendisliği

Program Adı : Yüksek Lisans

Tez Başlığı : Nöropazarlama Stratejilerinin Geliştirilmesi Amacıyla EEG Sinyal İşleme Tekniklerinin Belirlenmesi

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 113 sayfalık kısmına ilişkin 08/07/2025 tarihinde **Turnitin** intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı: **% 5'tir.**

Uygulanan filtrelemeler:

- 1- Giriş dahil
- 2- Ana Bölümler dahil
- 3- Sonuç dahil
- 4- Alıntılar dahil
- 5- Kapak hariç
- 6- Önsöz ve Teşekkür hariç
- 7- İçindekiler hariç
- 8- Kaynakça hariç
- 9- Özet hariç
- 10- Yedi (7) kelimeden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 08/07/2025

Danışman

Dr. Öğr. Üyesi Eda DAĞDEVİR

Öğrenci

Suzan SABAN

Hazırlayan
BKK

Onaylayan
KASGEM

KILAVUZA UYGUNLUK

“Nöropazarlama Stratejilerinin Geliştirilmesi Amacıyla EEG Sinyal İşleme Tekniklerinin Belirlenmesi” başlıklı Yüksek Lisans tezi, Kayseri Üniversitesi Lisansüstü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Suzan SABAN

Tez Danışmanı

Dr. Öğr. Üyesi Eda DAĞDEVİR

Elektrik-Elektronik Mühendisliği ABD Başkanı

Prof. Dr. Engin Cemal MENGÜÇ

KABUL VE ONAY TUTANAĞI

Dr. Öğr. Üyesi Eda DAĞDEVİR danışmanlığında Suzan SABAN tarafından hazırlanan “Nöropazarlama Stratejilerinin Geliştirilmesi Amacıyla EEG Sinyal İşleme Tekniklerinin Belirlenmesi” başlıklı bu çalışma jürimiz tarafından Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik- Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

30 /07/2025

JÜRİ:

Danışman : Dr. Öğr. Üyesi Eda DAĞDEVİR

Üye : Prof. Dr. Fatma LATİFOĞLU

Üye : Doç. Dr. Nimet KORKMAZ

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun tarih ve sayılı kararı ile onaylanmıştır.

..... / /

Doç. Dr. Ahmet Terzi

Enstitü Müdür

ÖN SÖZ / TEŞEKKÜR

Bu tez çalışmasının ana fikrinin oluşmasında ve çalışmanın bu noktaya ulaşmasında büyük emeği olan, yüksek lisans eğitimim süresince bilgi ve tecrübeleri ile ufkumu açan, her koşulda desteğini hissettiren ve yolumu aydınlatan değerli danışmanım Sayın Dr. Öğr. Üyesi Eda DAĞDEVİR' e en içten teşekkürlerimi sunarım.

Bu süreçte yanımda olan, varlıklarıyla bana güç veren kıymetli aileme ve desteğini her zaman hissettiren değerli arkadaşlarıma teşekkür ederim. Yüksek lisans eğitimine başlamam konusunda beni cesaretlendiren, bu süreçte fedakarlığı ve desteğiyle her zaman yanımda olan sevgili eşim Ali Burak SABAN' a ve ilham kaynağım sevgili çocuklarım Yavuz Selim ile Bilge Hatun' a gönülden teşekkür ederim.

Suzan SABAN, Kayseri, 2025

NÖROPAZARLAMA STRATEJİLERİNİN GELİŞTİRİLMESİ AMACIYLA EEG SİNYAL İŞLEME TEKNİKLERİNİN BELİRLENMESİ

Suzan SABAN

**Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü
Yüksek Lisans, Temmuz 2025
Danışman: Dr. Öğr. Üyesi Eda DAĞDEVİR**

ÖZET

Bu tez çalışması kapsamında nöropazarlama alanında tüketici tercihlerinin EEG yöntemi ile belirlenmesi amacıyla sinyal işleme ve sinyal işleme parametrelerinin optimizasyonu yaklaşımı sunulmuştur. Bu amaçla ön işleme aşamasından geçirilen EEG sinyallerinden farklı özellikler elde edilmiş ve bu özelliklerin kombinasyonları ile 125 farklı özellik matrisi oluşturulmuştur. Oluşturulan özellik matrisleri, DVM, NB, K-EYK, RO ve YSA gibi geleneksel sınıflandırma algoritmaları ile sınıflandırılmış ve doğruluk, AUC, kesinlik, duyarlılık, F1 skoru gibi performans metrikleri elde edilmiştir. Ayrıca literatürde oldukça nadir rastlanan fakat uygulamada oldukça önemli olan sınıflandırma test ve eğitim süresi parametreleri de bu tez çalışması kapsamında sınıflandırma performansı değerlendirmesinde parametre metriği olarak hesaplanmıştır. 125 farklı özellik matrisinden DVM algoritması ile hesaplanan performans metrikleri ÇAGA yöntemiyle optimize edilerek, pareto optimal çözümlere karşılık gelen özellik matrisleri belirlenmiştir. ÇAGA ile elde edilen pareto optimal çözümler arasından tek optimum çözümün belirlenmesi için TOPSIS yöntemi kullanılmıştır. Buna göre, oluşturulan özellik matrisleri içerisinde doğruluk, AUC, kesinlik, duyarlılık, F1 skoru parametrelerinin en yüksek, test ve eğitim süresi parametrelerinin en düşük olmasını amaçlayan optimum tek çözüm için doğruluk 0,83, AUC 0,77, kesinlik 0,88, duyarlılık 0,81, F1 skoru 0,85 olarak, eğitim süresi 0,01063 s, test süresi 0,00055 s olarak belirlenmiştir. Bu optimum çözüme karşılık gelen özellik matrisi ise “spektral özellikler matrisi” olarak bulunmuştur. Sonuç olarak bu tez çalışması ile, sinyal işleme sürecinin performansının belirlenmesi için dikkate alınması gereken performans metriklerinin çok amaçlı değerlendirilmesi ve optimum çözümün belirlenmesi için literatüre özgün bir yaklaşım sunulmuştur.

Anahtar Kelimeler: Yapay zeka, optimizasyon, EEG, sinyal işleme, nöropazarlama

DETERMINATION OF EEG SIGNAL PROCESSING TECHNIQUES TO DEVELOP NEUROMARKETING STRATEGIES

Suzan SABAN

**Kayseri University Institute of Graduate Education
Master Thesis, July 2025
Thesis Advisor: Assist. Prof. Dr. Eda DAĞDEVİR**

ABSTRACT

In this thesis study, a signal processing and parameter optimization approach has been proposed to identify consumer preferences using EEG methodology within neuromarketing. For this purpose, various features were extracted from preprocessed EEG signals and 125 different feature matrices were constructed based on different combinations of these features. The feature matrices were classified using traditional classification algorithms such as SVM, NB, K-NN, RF, and ANN, and performance metrics including accuracy, AUC, precision, recall, and F1 score were obtained. Additionally, this study also evaluated classification training and testing time cost, which are rarely addressed in the literature but significant importance in practical applications. Among the 125 feature matrices, performance metrics computed using the SVM algorithm were optimized using the MOGA method to determine feature matrices corresponding to Pareto-optimal solutions. The TOPSIS method was employed in order to select a single optimal solution from among the Pareto-optimal solutions obtained via MOGA. Accordingly, the single optimal solution was determined based on maximizing accuracy, AUC, precision, recall, and F1 score, while minimizing test and training time cost. As a result, the performance metrics for the optimal solution were found to be as follows: accuracy: 0,83, AUC: 0,77, precision: 0,88, recall: 0,81, F1 score: 0,85, with training and test durations of 0,0106 and 0,0006 s respectively. The corresponding feature matrix for this optimal solution was identified as spectral features matrix. As a result, this thesis study introduces a novel multi-objective evaluation approach to the literature for assessing the performance of the signal processing pipeline and determining the optimal solution.

Keywords: Artificial intelligence, optimization, EEG, signal processing, neuromarketing

İÇİNDEKİLER

NÖROPAZARLAMA STRATEJİLERİNİN GELİŞTİRİLMESİ AMACIYLA EEG SİNYAL İŞLEME TEKNİKLERİNİN BELİRLENMESİ

BİLİMSEL ETİĞE UYGUNLUK.....	i
KILAVUZA UYGUNLUK.....	iii
KABUL VE ONAY TUTANAĞI	iii
ÖN SÖZ / TEŞEKKÜR	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	x
SİMGELER VE KISALTMALAR LİSTESİ.....	viii
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ.....	xvi
GİRİŞ	2

BİRİNCİ BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Tezin Konusu ve İçeriği	3
1.2. Tezin Amacı ve Kapsamı	3
1.3. Genel Bilgiler	4
1.3.1. Nöropazarlama ve Nöropazarlamanın Tarihçesi	4
1.3.2. Nöropazarlanın Mühendislik Boyutu	5
1.3.3. Nöropazarlamada Kullanılan Biyomedikal Veri Toplama Yöntemleri.....	5
1.3.3.1. Beyin İçi Nöral Aktiviteyi Kaydeden Yöntemler.....	6
Beynin Anatomik Yapısı	6
Beynin Fizyolojik Yapısı.....	8
a. Elektrofizyolojik Aktiviteye Dayalı Nörobilimsel Yöntemler.....	9
Elektroensefalografi (EEG).....	9
EEG Frekans Bantları	10
EEG' nin Olgunlaşma Süreci	12
EEG Sinyallerinin Kaydedilmesi.....	13
EEG Elektrotlarının Özellikleri ve Konumları.....	13

Magnetoensefalografi (MEG)	15
Kararlı Durum Topografisi (KDT).....	17
<i>b. Metabolik Aktiviteye Dayalı Nörobilimsel Yöntemler</i>	<i>18</i>
Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI).....	18
Pozitron Emisyon Tomografisi (PET).....	19
1.3.3.2. Beyin Dışı Nöral Aktiviteyi Kaydeden Yöntemler	20
Elektrokardiyografi (EKG).....	21
Göz İzleme Sistemi	22
Yüz Elektromiyografisi	23
Elektrodermal Aktivite (EDA) ve Galvanik Cilt Tepkisi (GCT)	24
1.3.3.3. Nöral Aktiviteyi Değiştiren (Manipüle eden) Yöntemler	26
Transkraniyal Manyetik Uyarım (TMU).....	27
Nörotransmitterler (NT)	28
1.4. Literatür Taraması	30
1.4.1. Nöropazarlama Alanındaki Genel Literatür Taraması	30
1.4.2. EEG yöntemi kullanılan Nöropazarlama Çalışmaları Alanında Literatür Taraması	31
1.4.3. Tez Çalışması Kapsamında Kullanılan Veri Setini Kullanan Literatür Çalışmaları.....	35

İKİNCİ BÖLÜM

MATERYAL VE YÖNTEM

2.1. Veri Seti.....	44
2.2. İşaret işleme.....	46
2.2.1. Verilerin ön işlenmesi.....	47
2.2.1.1.Çentik Filtre.....	47
2.2.1.2. Bant Geçiren Filtre	47
2.2.1.3. Savitzky–Golay Filtresi	47
2.2.2.Özellik Çıkarımı	49
2.2.2.1. Hjorth Parametreleri	49
a. Hjorth Aktivitesi	49
b. Hjorth Mobilitesi	49
c. Hjorth Kompleksitesi	50
2.2.2.2. Entropi Özellikleri.....	50
a. Tsallis Entropi	50

<i>b. Shannon Entropi</i>	51
2.2.2.3. İstatistiksel Özellikler	51
<i>a. Ortalama</i>	50
<i>b. Varyans</i>	50
<i>c. Standart Sapma</i>	50
<i>d. Çarpıklık</i>	53
<i>e. Basıklık</i>	53
<i>f. Medyan</i>	53
<i>h. Pik Faktörü</i>	54
<i>ı. Onuncu Zirveye Ulaşma Süresi</i>	54
2.2.2.4. Güç Spektral Yoğunluğu (GSY)	54
Welch Metodu	55
<i>a. Ortalama Güç</i>	55
<i>b. Ortalama Bant Frekansı</i>	56
2.2.3. Sınıflandırma	56
2.2.3.1. Destek Vektör Makinesi (DVM)	56
2.2.3.2. Naive Bayes (NB)	56
2.2.3.3. K-En Yakın Komşu Algoritması (K-EYK)	57
2.2.3.4. Rastgele Orman (RO)	57
2.2.3.5. Yapay Sinir Ağları (YSA)	57
2.2.4. Sınıflandırma Performansı Değerlendirme Ölçütleri	58
2.2.4.1. Doğruluk	59
2.2.4.2. Alıcı İşletim Karakteristiği (Receiver Operating Characteristic Curve, ROC Eğrisi) ve Alıcı İşletim Karakteristiği Altındaki Alan (Area Under the Receiver Operating Characteristic Curve, AUC)	60
2.2.4.3. Kesinlik	60
2.2.4.4. Duyarlılık	60
2.2.4.5. F1 Skoru	61
2.2.4.6. Zaman Maliyeti	61
2.3. İşaret İşleme Yönteminin Optimizasyonu	61
2.3.1 Genetik Algoritma	62

2.3.2. Çok Amaçlı Genetik Algoritmalar (ÇAGA)	64
2.3.3. İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS).....	65

ÜÇÜNCÜ BÖLÜM

BULGULAR

3.1. Sinyal işleme modeli sınıflandırma sonuçları	70
3.2. Özellik Matrislerinin Optimizasyonu	105

DÖRDÜNCÜ BÖLÜM

TARTIŞMA, SONUÇLAR VE ÖNERİLER

KAYNAKÇA	115
TEZ İNTİHAL RAPORU	125
ÖZGEÇMİŞ	1288
YAYINLAR	1288

SİMGELER VE KISALTMALAR LİSTESİ

Simgeler

Ca	: Kalsiyum
Cl	: Klor
dB	: Desibel
Hz	: Hertz
K	: Potasyum
kg	: Kilogram
mV	: Mili Volt
μ V	: Mikro Volt
Na	: Sodyum
s	: Saniye

Kısaltmalar

ABC	: Yapay Arı Kolonisi
A/ D	: Analogdan Dijitale Dönüştürücü
ADD	: Ayrık Dalgacık Dönüşümü

Ameva: Association Metric-Based Evaluation Of Variable Attributes

ATP	: Adenozin Trifosfat
AUC	: Alıcı İşletim Karakteristiği Altındaki Alan
BBA	: Bağımsız Bileşen Analizi
CMS	: Common Mode Sense
ÇAGA	: Çok Amaçlı Genetik Algoritma
DE	: Diferansiyel Entropi
DDİ	: Doğal Dil İşleme
DSA	: Derin Sinir Ağı
DRL	: Driven Right Leg
DVM	: Destek Vektör Makinesi
EDA	: Elektrodermal Aktivite
EEG	: Elektroensefalografi
EKG	: Elektrokardiyografi
ESA	: Evrişimli Sinir Ağı
fEMG	: Yüz Elektromiyografisi

fMRI	: Fonksiyonel Manyetik Rezonans Görüntüleme
GA	: Genetik Algoritma
GAA	: Gradyan Artırma Algoritması
Gİ	: Göz İzleme
GCT	: Galvanik Cilt Tepkisi
GKA	: Görgül Kip Ayrışımı
GMM	: Gizli Markov Model
GSY	: Güç Spektral Yoğunluğu
KA	: Karar Ağacı
KDT	: Kararlı Durum Topografisi
K- EYK	: K- En Yakın Komşuluk
LDA	: Latent Dirichlet Allocation
MEG	: Magnetoensefalografi
NB	: Navie Bayes
NT	: Nörotransmitter
ÖKF	: Özgül Kip Fonksiyonu
PET	: Pozitron Emisyon Tomografisi
RO	: Rastgele Orman
SAM	: Self-Assessment Manikin
S- Golay	: Savitzky Golay
TMU	: Transkraniyal Manyetik Uyarım
TOPSIS	: İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (Technique for Order Preference by Similarity to Ideal Solution)
UKSB	: Uzun Kısa Süreli Bellek
YSA	: Yapay Sinir Ağı
VADER	: Valence Aware Dictionary and Sentiment Reasoner

TABLOLAR LİSTESİ

Tablo 1.1. EEG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	15
Tablo 1.2. MEG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	17
Tablo 1.3. KDT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	18
Tablo 1.4. fMRI ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	19
Tablo 1.5. PET ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	20
Tablo 1.6. EKG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	21
Tablo 1.7. Gİ ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	22
Tablo 1.8. fEMG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	24
Tablo 1.9. EDA ve GCT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	25
Tablo 1.10. TMU ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	26
Tablo 1.11. NT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri.....	28
Tablo 1.12. Veri seti ile ilgili literatürdeki çalışmalar.....	40
Tablo 2.1. Katılımcılara gösterilen ürün görselleri.....	44
Tablo 2.2. Karmaşıklık matrisi.....	60
Tablo 3.1. Sinyal işleme modeli.....	70
Tablo 3.2. Özellik matrisi kombinasyonu.....	72
Tablo 3.3. DVM sınıflandırıcı sonuçları.....	73
Tablo 3.4. NB sınıflandırıcı sonuçları.....	76
Tablo 3.5. K-EYK sınıflandırıcı sonuçları.....	79
Tablo 3.6. RO sınıflandırıcı sonuçları.....	82

Tablo 3.7. YSA sınıflandırıcı sonuçları.....	85
Tablo 3.8. Her bir performans metriği için elde edilen en iyi değerler	105
Tablo 3.9. Pareto optimal çözümler ve karşılık gelen özellik matrisleri.....	106
Tablo 3.10. Pareto optimal çözümler arasından optimum çözüm ve karşılık gelen indis.....	110
Tablo 3.11. Literatür ve tez performans metriği sonuçları.....	111



ŞEKİLLER LİSTESİ

Şekil 1.1. Nörobilimsel yöntemlerin sınıflandırılması	6
Şekil 1.2. Beyin lobları	8
Şekil 1.3. Nöron hücresinin yapısı	9
Şekil 1.4. EEG frekans bantları.....	11
Şekil 1.5. Uluslararası 10-20 sistemi elektrot yerleşimi	15
Şekil 1.6. Yadava ve ekibi tarafından önerilen tercih tahmin modelinin akış şeması.....	34
Şekil 1.7. Tez çalışmasının tüm süreçlerinin akış şeması	41
Şekil 2.1. Katılımcıların ürün görselini izlerken EEG kaydının alındığı sistem.....	43
Şekil 2.2. EEG elektrotlarının kafa derisi üzerindeki yerleşimi ve ilgili aksesuarlar.....	46
Şekil 2.3. GA işlem adımları akış diagramı	64
Şekil 2.4. Tez çalışması kapsamında oluşturulan optimizasyon sürecine ait akış şeması.....	68
Şekil 3.1. DVM sınıflandırıcısı doğruluk grafiği.....	88
Şekil 3.2. DVM sınıflandırıcısı AUC grafiği.....	88
Şekil 3.3. DVM sınıflandırıcısı kesinlik grafiği.....	89
Şekil 3.4. DVM sınıflandırıcısı duyarlılık grafiği.....	89
Şekil 3.5. DVM sınıflandırıcısı F1 Skoru grafiği.....	90
Şekil 3.6. DVM sınıflandırıcısı eğitim süresi grafiği.....	90
Şekil 3.7. DVM sınıflandırıcısı test süresi grafiği.....	91
Şekil 3.8. NB sınıflandırıcısı doğruluk grafiği.....	91
Şekil 3.9. NB sınıflandırıcısı AUC grafiği.....	92
Şekil 3.10. NB sınıflandırıcısı kesinlik grafiği.....	92
Şekil 3.11. NB sınıflandırıcısı duyarlılık grafiği.....	93
Şekil 3.12. NB sınıflandırıcısı F1 Skoru grafiği.....	93
Şekil 3.13. NB sınıflandırıcısı eğitim süresi grafiği.....	94
Şekil 3.14. NB sınıflandırıcısı test süresi grafiği.....	94
Şekil 3.15. K-EYK sınıflandırıcısı doğruluk grafiği.....	95
Şekil 3.16. K-EYK sınıflandırıcısı AUC grafiği.....	95
Şekil 3.17. K-EYK sınıflandırıcısı kesinlik grafiği.....	96

Şekil 3.18. K-EYK sınıflandırıcısı duyarlılık grafiği.....	96
Şekil 3.19. K-EYK sınıflandırıcısı F1 Skoru grafiği.....	97
Şekil 3.20. K-EYK sınıflandırıcısı eğitim süresi grafiği.....	97
Şekil 3.21. K-EYK sınıflandırıcısı test süresi grafiği.....	98
Şekil 3.22. RO sınıflandırıcısı doğruluk grafiği.....	98
Şekil 3.23. RO sınıflandırıcısı AUC grafiği.....	99
Şekil 3.24. RO sınıflandırıcısı kesinlik grafiği.....	99
Şekil 3.25. RO sınıflandırıcısı duyarlılık grafiği.....	100
Şekil 3.26. RO sınıflandırıcısı F1 skoru grafiği.....	100
Şekil 3.27. RO sınıflandırıcısı eğitim süresi grafiği.....	101
Şekil 3.28. RO sınıflandırıcısı test süresi grafiği.....	101
Şekil 3.29. YSA sınıflandırıcısı doğruluk grafiği.....	102
Şekil 3.30. YSA sınıflandırıcısı AUC grafiği.....	102
Şekil 3.31. YSA sınıflandırıcısı kesinlik grafiği.....	103
Şekil 3.32. YSA sınıflandırıcısı duyarlılık grafiği.....	103
Şekil 3.33. YSA sınıflandırıcısı F1 Skoru grafiği.....	104
Şekil 3.34. YSA sınıflandırıcısı eğitim süresi grafiği.....	104
Şekil 3.35. YSA sınıflandırıcısı test süresi grafiği.....	105
Şekil 3.36. Her bir pareto optimal sonucun sınıflandırma performans metriği.....	106
Şekil 3.37. Her bir pareto optimal sonucun eğitim süresi.....	107
Şekil 3.38. Her bir pareto optimal sonucun test süresi.....	107
Şekil 3.39. Doğruluk- F1 skoru-test süresi parametreleri için elde edilen pareto cephesi.....	108
Şekil 3.40. Doğruluk- kesinlik-test süresi parametreleri için elde edilen pareto cephesi.....	108
Şekil 3.41. Doğruluk- eğitim -test süresi parametreleri için elde edilen pareto cephesi.....	109
Şekil 3.42. AUC- duyarlılık-test süresi parametreleri için elde edilen pareto cephesi.....	109
Şekil 3.43. Pareto optimal çözümlerin TOPSIS skorları.....	110

GİRİŞ

Tüketici davranışlarının doğru bir şekilde analiz edilmesi, pazarlama stratejilerinin geliştirilmesi açısından son derece önemlidir. Geleneksel anket ve gözlem yöntemlerinin sınırlılıkları, tüketicilerin karar alma süreçlerini anlamada daha objektif ve biyolojik temelli ölçüm tekniklerine yönelimini beraberinde getirmiştir. Bu bağlamda, son yıllarda hızla gelişen nöropazarlama, "nörobilim" ve "pazarlama" disiplinlerinin kesişiminde yer alan, tüketici davranışlarının duygusal ve bilişsel yönlerini anlamaya yönelik yenilikçi bir araştırma alanıdır. Nörobilim temelli yöntemlerle geleneksel pazarlama yaklaşımlarının ötesine geçerek, tüketicilerin bilinçaltı tepkilerini anlamayı ve bu doğrultuda daha etkili stratejiler geliştirmeyi hedefler [1]. Nöropazarlama çalışmalarında, bireylerin satın alma davranışlarını anlamada elektroensefalografi (EEG) gibi nörofizyolojik ölçüm tekniklerini kullanmak önemli bir alternatif sunmaktadır. EEG sinyalleri, bireylerin dış uyaranlara verdikleri zihinsel ve duygusal tepkilerin zamansal olarak incelenmesine olanak sağlamaktadır. EEG, yüksek zaman çözünürlüğü, düşük maliyet ve taşınabilirlik gibi avantajları sayesinde en çok tercih edilen elektrofizyolojik ölçüm yöntemlerinden birisidir [2].

Bu tez çalışması kapsamında, EEG sinyalleri kullanılarak tüketicilerin beğenme / beğenmeme durumlarının tahmin edilmesine yönelik özgün bir sinyal işleme ve optimizasyon modeli geliştirilmiştir. Çalışmada, Yadava ve arkadaşları tarafından literatüre kazandırılmış EEG veri seti kullanılmıştır. Katılımcıların ürün görsellerine verdikleri tepkiler analiz edilerek EEG sinyalleri, frontal, temporal, parietal, oksipital ve tüm loblar olmak üzere beş farklı beyin bölgesine ve delta, teta, alfa, beta, gama olmak üzere beş farklı frekans bandına ayrıştırılmıştır. Bu bölgelerden ve bantlardan elde edilen sinyallerden Hjorth parametreleri, entropi temelli özellikler, istatistiksel özellikler ve spektral özellikler çıkarılmış ve tüm bu özelliklerin kombinasyonları ile 125 farklı özellik matrisi oluşturulmuştur.

Oluşturulan her bir özellik matrisi, DVM (Destek Vektör Makineleri), NB (Naive Bayes), K-EYK (K-En Yakın Komşu), RO (Rastgele Orman) ve YSA (Yapay Sinir Ağları) olmak üzere beş farklı geleneksel sınıflandırma algoritması ile değerlendirilmiştir. Bu algoritmalar yardımıyla her bir özellik matrisi için doğruluk, AUC (Alıcı işletim karakteristiği altındaki alan), kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri hesaplanmış; ayrıca literatürde nadiren yer verilen ancak uygulamada kritik öneme sahip olan eğitim süresi ve test süresi parametreleri de dikkate alınarak sınıflandırma performansı çok yönlü olarak değerlendirilmiştir.

Çalışmanın özgün yönlerinden biri, sınıflandırma sürecinde kullanılan 125 özellik matrisinin Çok Amaçlı Genetik Algoritma (ÇAGA) yöntemi ile optimize edilmesidir. Böylece, yüksek doğruluğa sahip aynı zamanda eğitim ve test süresi açısından düşük zaman maliyetine sahip pareto optimal çözümler elde edilmiştir. Bu çözümler arasından tek bir optimum çözümün seçilebilmesi amacıyla TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) yöntemi kullanılmıştır. Sonuç olarak, sinyal işleme süreci ve optimizasyon algoritmaları birlikte kullanılarak nöropazarlama uygulamalarına yön verebilecek nitelikte etkili, uygulanabilir ve özgün bir yaklaşım geliştirilmiştir.

Bu tez çalışması ile, EEG sinyallerine dayalı tüketici tercih tahmini sistemlerinde kullanılan özelliklerin çok boyutlu performans değerlendirmesi yapılmış; yalnızca doğruluk değil, aynı zamanda pratik uygulamalar için hayati önem taşıyan zaman maliyetine dayalı metrikler de dikkate alınarak optimum çözüm elde edilmiştir. Böylece hem akademik hem de sektörel anlamda uygulanabilirliği yüksek, sinyal işleme ve karar destek sistemlerini bütünleşik olarak içeren yenilikçi bir model literatüre kazandırılmış

BİRİNCİ BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Tezin Konusu ve İçeriği

Bu tez çalışmasının konusu, nöropazarlama stratejilerinin geliştirilmesine katkı sağlamak amacıyla EEG sinyallerinin işlenmesinde yüksek performans sağlayan bir sinyal işleme ve optimizasyon metodolojisi geliştirmek üzerinedir. Bu tez çalışması kapsamında, tüketici beğeni durumunun EEG sinyalleri kullanılarak tahmin edilmesi hedeflenmiştir. Bu bağlamda farklı beyin lobları, EEG frekans bantları ve sinyal özellikleri kullanılarak, beş farklı sınıflandırma algoritması ile doğruluk, AUC, kesinlik, duyarlılık, F1 skoru, eğitim zaman maliyeti ve test zaman maliyeti parametre metrikleri hesaplanmıştır. İkinci aşamada, DVM sınıflandırma algoritması ile elde edilen sonuçlar arasından, ÇAGA yöntemi kullanılarak sınıflandırma başarımı yüksek ve işlem süresi düşük olan optimum özellik kombinasyonları belirlenmiştir. Son aşamada bu pareto optimal çözümler arasından optimum çözümü bulmak için TOPSIS yöntemi kullanılmıştır.

Bu tez çalışması, EEG sinyalleri ile tüketici tercihlerini sınıflandırmak üzere bir sinyal işleme ve optimizasyon prosedürü geliştirerek, pazarlama alanında karar verme süreçlerinin nörofizyolojik temellerine ilişkin yeni bir bakış açısı kazandırmayı hedeflemektedir. Çalışmada kullanılan filtreleme teknikleri, özellik çıkarımı yöntemleri ve sınıflandırıcılar detaylı biçimde açıklanmış; geliştirilen modelin performansı literatürdeki benzer yaklaşımlarla karşılaştırılarak değerlendirilmiştir.

1.2. Tezin Amacı ve Kapsamı

Bu tez çalışmasının amacı, EEG tabanlı sinyal işleme teknikleri aracılığıyla tüketicilerin ürünlere yönelik beğeni durumlarının daha doğru ve hızlı bir şekilde belirlenmesini sağlayacak bir model geliştirmektir. Bu tez çalışmasının kapsamı, EEG sinyallerinden elde edilen verilerin önışlenmesi, farklı sinyal özelliklerinin çıkarılması, bu özelliklerin

Bu tez çalışması, nöropazarlama alanına yenilikçi bir katkı sunmakta hem akademik hem de uygulamalı pazarlama stratejilerine veri temelli, nörofizyolojik bir bakış açısı kazandırmaktadır. Aynı zamanda sinyal işleme süresi ve sınıflandırma performansı açısından dengeli sonuçlar sunan bir prosedür önererek, pratik uygulamalar için zaman ve kaynak tasarrufu sağlamayı amaçlamaktadır.

1.3. Genel Bilgiler

Bu bölümde tez çalışmasının kapsamında yer alan genel bilgilere yer verilmiştir.

1.3.1. Nöropazarlama ve Nöropazarlamanın Tarihçesi

Nöropazarlama, tüketici sinirbilimi olarak da adlandırılan ve tüketici davranışlarının nörobilimsel temellerini inceleyen disiplinler arası bir araştırma alanıdır. Bu alan, beyin-bilgisayar arayüzleri ve diğer nörogörüntüleme teknikleri aracılığıyla tüketicilerin pazarlama uyaranlarına yönelik duygusal ve bilişsel tepkilerini analiz etmeyi amaçlamaktadır. Geleneksel pazar araştırma yöntemlerinin sınırlarını aşarak tüketicilerin bilinçli ve bilinçdışı tepkilerini daha derinlemesine incelemeyi hedefleyen nöropazarlama, bu sayede karar verme süreçlerinin nörofizyolojik temellerine ilişkin daha kapsamlı bir anlayış sunmaktadır [3].

Nörobilim, güncel tüketici araştırmalarına önemli katkılar sunarak, bireylerin karar verme süreçlerinde tercihlerini anlama ve yorumlama olanağı sağlamaktadır. Bu bağlamda, nöropazarlama, pazar araştırmalarında giderek artan bir uygulama alanı bulmakta olup, tüketicilerin ürün, marka veya reklam içeriğine verdikleri bilinçdışı tepkilere erişim imkanı sunmaktadır. Bu sayede, tüketici davranışları, satın alma karar süreçleri ve duygusal tepkiler ile önyargıların bu süreçler üzerindeki etkileri daha derinlemesine analiz edilebilmektedir. Nöropazarlama teknikleri ve araçları, çevresel değişkenlerin tüketici üzerindeki etkilerini incelemek için kullanılmakta olup, seçim sürecinde ortaya çıkan nörofizyolojik özellikler aracılığıyla tüketicinin iradesini ölçme, kaygılarını ve motivasyonlarını belirleme imkanı sunmaktadır [4].

Nöropazarlama beş temel ilke ile pazarlama alanına katkı sunmaktadır. Bunlar; bilişsel mekanizmaların belirlenmesi, örtülü tepkilerin ölçülmesi, psikolojik süreçlerin ayırt edilmesi, bireysel farklılıkların anlaşılması ve insan davranışına ilişkin tahminlerde bulunulmasıdır [5].

Nöropazarlama çalışmalarının, 1997 yılında Harvard Üniversitesinde Prof. Gerry Zaltman'ın manyetik rezonans görüntüleme (fMRI) yöntemi ile yapmış olduğu pazarlama araştırması ile başladığı bilinmektedir. 2002 yılında Prof. Ale Smidts ilk kez nöropazarlama terimini kullanarak akademik literatürde yer almasını sağlamıştır [6].

Tıp, elektronik, bilgisayar ve psikoloji alanlarından beslenen ve multidisipliner bir alan olan nöropazarlama, sadece pazarlama alanında değil birçok farklı branştaki araştırmalarda ve uygulamalarda kullanılmaktadır [7].

Nöropazarlama; marka deneyimi, reklamlar, ürün geliştirme, dijital uygulamalar, alışveriş davranışı ve karar verme, siyasal iletişim, sinema ve fragmanlar, oyun deneyimi, hukuk, bilişsel sinirbilim araştırmaları gibi birçok alanda kullanılmakta ve her geçen gün kullanım alanı artmaktadır [8].

1.3.2. Nöropazarlamanın Mühendislik Boyutu


Nöropazarlama, pazarlama uyaranlarına karşı insan beyninin verdiği tepkiyi doğrudan ölçmek için geleneksel anket yöntemlerinin yerine invaziv olmayan beyin sinyali kayıt tekniklerini kullanır. Beyinden nöral aktivite elde ederek, insanların bilişsel ve duygusal tepkileri anlaşılabilir ve sinyal işleme teknikleri ile makine öğrenimi algoritmaları kullanılarak beyin dalgalarının olası anlamları ölçülebilir, analizi yapılabilir ve yorumlanabilir [9],[10]. Nöropazarlama çalışmaları, mühendislik sinyal işleme yöntemlerini, gelişmiş istatistiksel ve spektral analiz yöntemlerini, makine öğrenimi algoritmalarını kullanarak beyinden gelen nörofizyolojik sinyallerin yorumlanmasına yüksek analitik doğruluk katarak, insanların tercihlerinin ve duygu durumlarının tespitinin daha doğru bir şekilde yapılmasına imkan sunar.

1.3.3. Nöropazarlamada Kullanılan Biyomedikal Veri Toplama Yöntemleri

Nöropazarlama araştırmalarında kullanılan biyomedikal veri toplama yöntemleri, Şekil 1.1' de gösterildiği gibi beyin içi nöral aktiviteyi kaydeden yöntemler, beyin dışı nöral aktiviteyi kaydeden yöntemler ve nöral aktiviteyi manipüle eden yöntemler olmak üzere üç ana gruba ayrılarak incelenebilir.

Literatürde yer alan çalışmalara göre nöropazarlama araştırmalarında en çok kullanılan biyomedikal veri toplama yöntemleri başta EEG olmak üzere nöral aktivite kaydının kullanıldığı yöntemlerdir. Beynin fizyolojik etkisinin ölçüldüğü bu yöntemleri anlamak için beyin anatomik ve fizyolojik yapısını anlamlandırmak oldukça önemlidir.

Şekil 1.1. Nörobilimsel yöntemlerin sınıflandırılması [11]



1.3.3.1. Beyin İçi Nöral Aktiviteyi Kaydeden Yöntemler

Beyin içi nöral aktiviteyi kaydeden yöntemleri elektrofizyolojik aktiviteye dayalı nörobilimsel yöntemler ve metabolik aktiviteye dayalı yöntemler olarak iki başlık altında incelenebilir. Elektrofizyolojik aktiviteye dayalı nörobilimsel yöntemleri incelerken literatürde sıklıkla kullanılan, EEG, MEG, KDT gibi biyomedikal veri toplama yöntemleri ele alınmıştır. Metabolik aktiviteye dayalı nörobilimsel yöntemler bölümünde ise fMRI ve PET biyomedikal veri toplama yöntemleri incelenmiştir.


Bu yöntemlerle elde edilen verilerin doğru yorumlanabilmesi için beynin yapısal ve işlevsel özelliklerinin iyi anlaşılması gerekir. Bu nedenle, beyin anatomisi ve fizyolojisi hakkında temel bilgi bir sonraki bölümde verilecektir.

Beynin Anatomik Yapısı

İnsan beyni sağ ve sol olmak üzere iki yarım küreden meydana gelir. Şekil 1.2' de gösterilen anatomik bölgeler kesin bir biçimde ayrılmamakla beraber belirli bilişsel ve motor işlevlere özelleşmiştir. Frontal lob, planlama, problem çözme, karar verme ve bilinçli düşünce süreçlerinin yürütülmesinde önemli bir yere sahiptir. Motor korteks, vücuttaki istemli kas hareketlerinin başlatılmasından sorumludur. Paryetal lob, dokunma,

basınç, sıcaklık, ağrı ve tat gibi duyuşal bilgilerin algılanması ve yorumlanmasını sağlar. Somatosensori korteks, paryetal lob içerisinde konumlanmış olup, vücudun farklı bölgelerinden gelen duyuşal verilerin organize edilerek algılanmasını ve yorumlanmasını gerçekleştirir. Oksipital lob, beyin arka bölümünde bulunur ve görsel bilgilerin işlenmesinden, görsel tanıma ve algı süreçlerinden sorumludur. Bu lob, ışık ve renk gibi temel görsel öğelerin yanı sıra karmaşık görsel sahnelerin anlamlandırılmasında da görev alır. Temporal lob ise işitsel uyarıların algılanması, dil işleme, hafıza oluşumu ve bazı duyuşal tepkilerin düzenlenmesi gibi çok yönlü işlevleri yerine getirir. Serebellum (beyincik), motor kontrolün incelikli düzenlenmesi, kasların temel gerilim seviyesinin korunması, hareketlerin doğruluğunun artırılması ve özellikle denge ile postürün sağlanmasından sorumludur. Beyin sapı, beyin ile omurilik arasındaki iletişimi sağlar. Ayrıca solunum ritmi, kalp atım hızı, kan basıncı düzenlenmesi, bilinç durumu ve uyku-uyanıklık döngüsünün kontrolü gibi yaşamsal fonksiyonların sürdürülmesinde kritik bir role sahiptir. Son olarak, burun soğanı, koku moleküllerinden alınan bilgilerin merkezi sinir sistemine iletilmesini ve burada işlenerek koku algısının oluşmasını sağlar. Koku duyusu, özellikle hafıza ve duyuşal tepkilerle yakından ilişkilidir ve limbik sistemle güçlü bağlantılar kurar [12].

Şekil 1.2. *Beyin lobları* [13]




Beynin Fizyolojik Yapısı

Beyin, merkezi sinir sisteminin en karmaşık ve en gelişmiş organıdır. İnsan beyninin ortalama ağırlığı yaklaşık 1,4 kg olup, vücut ağırlığının %2'sini oluşturur. Bu boyutuna rağmen, harcanan toplam enerjinin yaklaşık %20'sini beyin kullanmaktadır. Bu yüksek enerji tüketme ihtiyacı, beyin işlevsel kapasitesi ve bilişsel süreçlerdeki merkezi rolünden kaynaklanır. Beynin fizyolojik işlevleri, çevresel uyarıları algılayarak iletmekle görevli olan nöronlar aracılığıyla gerçekleştirilir. Nöronlar, elektriksel ve kimyasal sinyallerle iletişim kurarak bilgi iletimini sağlar [14]. Beynin fizyolojik yapısının daha iyi anlaşılabilmesi açısından nöronların yapısının ve işleyişinin nasıl olduğunu incelemek gereklidir.

Nöronlar, beyin işlevsel birimleri olup çevresel uyarıların algılanması, iletilmesi ve işlenmesinde temel rol oynarlar. Her bir nöron; dentrit, soma (hücre gövdesi) ve akson olmak üzere üç ana yapısal bileşenden oluşur. Dentritler aracılığıyla alınan uyarılar, sırasıyla soma ve akson boyunca iletilerek sinaps adı verilen bir nöronun aksonu ile diğerinin dentriti arasındaki bağlantı noktasında diğer nöronlara aktarılır [14]. Şekil 1.3. bir nöron hücresinin temel yapısını ve ana yapısal bileşenlerini göstermektedir.

Şekil 1.3. Nöron hücresinin yapısı [13]



Sinaptik iletim sırasında, kimyasal maddeler salınarak hücre zarında elektriksel potansiyel farkı oluşturur. Bu potansiyel farkın kaynağı, zarın iki tarafında bulunan iyon konsantrasyonlarındaki elektrokimyasal farklılıklardır. Hücre zarında bu değişimden

kaynaklı oluşan elektriksel potansiyel farka aksiyon potansiyeli adı verilir. Dinlenme halindeki bir nöronun zar potansiyeli yaklaşık -70 mV' dur. Hücre içi, daha fazla negatif yüklü molekül ve K^+ iyonu içerirken; hücre dışı ortamdaki Na^+ , Ca^{2+} ve Cl^- iyonları daha yoğundur. Bir uyarının eşik değeri olan yaklaşık -55 mV' yi aşması durumunda, zarın Na^+ geçirgenliği artar ve Na^+ iyonları hücre içine difüze olur. Bu süreçte zar potansiyeli yaklaşık +40 mV seviyesine ulaşır; bu olay depolarizasyon olarak tanımlanır. Ardından, K^+ kanalları açılır ve hücre içinden K^+ iyonlarının dışarıya çıkmasıyla birlikte potansiyel yeniden düşmeye başlar; bu aşama repolarizasyon olarak adlandırılır. Ancak, K^+ kanallarının geç kapanması nedeniyle fazla miktarda K^+ dışarı çıkar ve zar potansiyeli geçici olarak yaklaşık -85 mV' a kadar düşer; bu duruma hiperpolarizasyon denir. Son olarak, Na^+/K^+ pompası yani ATP'ye bağımlı aktif taşıma mekanizması devreye girerek, Na^+ iyonlarını hücre dışına ve K^+ iyonlarını hücre içine geri taşır. Bu süreç sayesinde hücre, başlangıç dinlenme potansiyeli olan -70 mV seviyesine geri döner. Bu elektrofizyolojik döngü, bir veya daha fazla nöronda gerçekleştiğinde, EEG gibi yöntemlerle izlenebilen beyin aktivitesine temel oluşturur [15].

a. Elektrofizyolojik Aktiviteye Dayalı Nörobilimsel Yöntemler

Elektrofizyolojik aktiviteye dayalı nörobilimsel yöntemler, beyin fonksiyonlarının doğrudan nöral elektriksel sinyaller aracılığıyla incelenmesini sağlar. Bu yöntemler, sinir hücreleri arasındaki elektriksel iletişimi yüksek hassasiyetle ölçerek, bilişsel süreçlerin anlık takibini mümkün kılar. Elektrofizyolojik aktiviteye dayalı nörobilimsel yöntemler, algı, dikkat ve karar verme gibi zihinsel faaliyetlerin anlaşılmasında önemli bilgiler sunar. Bu yönünden ötürü elektrofizyolojik aktiviteye dayalı nörobilimsel yöntemler, nöropazarlama araştırmalarında tüketici davranışlarının incelenmesinde yaygın biçimde kullanılmaktadırlar.

EEG, nöropazarlama teknikleri arasında sıklıkla tercih edilen bir nörobilimsel yöntemdir. Bu tez çalışması kapsamında EEG sinyalleri kullanıldığı için bir sonraki bölümde EEG detaylı bir şekilde incelenecektir.

Elektroensefalografi (EEG)

EEG, kafa derisine yerleştirilen elektrotlardan alınan sinyallerin kaydedilerek, beyin elektriksel aktivitesinin ölçülmesidir. Çok sayıda nörondan gelen elektriksel sinyallerden çeşitli bulgular elde edilir. Bu teknik ile beyin belirli bölümlerinden alınan elektriksel


sinyaller, matematiksel deęerler aracılıęıyla formüle edilerek arařtırmacılara dikkat, motivasyon, duygusal ilgi, biliřsel iř yk, meditasyon gibi durumlar hakkında bilgi verebilmektedir [16], [17]. Yzeyeye yakın konumda olması nedeniyle, EEG zerinde en yksek etkiyi serebral korteksin elektriksel aktivitesi oluřturur. EEG saęlıklı yetiřkinlere ve ocuklara tekrar tekrar uygulanabilecek, tamamen invaziv olmayan, hastalara, neredeyse hibir risk veya sınırlama iermeyen elektrofizyolojik aktiviteyi kaydeden bir yntemdir [18].

1875 yılında İngiliz hekim Richard Caton beyindeki elektriksel akımların varlıęını keřfederek tavřan ve maymunların aık beyinleri zerinde EEG gzlemleri yapmıřtır. Daha sonra Alman nrolog Hans Berger, 1924 yılında radyo ekipmanları yardımıyla insan kafatası zerinden llen elektriksel sinyalleri ykseltmiřtir ve beyinde oluřan zayıf elektrik akımlarının kafatası aılmadan kaydedilerek kaęıt zerinde grafiksel olarak gsterilebileceęini ortaya koymuřtur. Berger' in gzlemledięi nral aktiviteler; uyku, anestezi, oksijen eksiklięi gibi beyin fonksiyonel durumlarına ve epilepsi gibi bazı sinirsel hastalıklara gre deęiřiklik gstermekteydi. İlk kez "elektroensefalogram" kelimesini kullanan Berger, gnmzdeki elektroensefalografi uygulamalarının temellerini atmıřtır. Uyku halinden uyanıklıęa geiř gibi genel durum deęiřimlerinde nral aktivitenin tutarlı ve gzlemlenebilir řekilde deęiřtięini tespit etmiřtir [18].

EEG Frekans Bantları

EEG sinyallerinin genlikleri tepeden tepeye 0,5 ile 100 μV arasında deęiřir ve sinyal ritimleri řekil 1.4' de grldę gibi delta (0,5–4 Hz), teta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) ve gama (30 Hz zeri) olmak zere beř faklı frekans bandına ayrılmıřtır. EEG'de farklı ritimlerin katkısı, bireyin yařı ve davranıřsal durumuna, zellikle uyanıklık dzeyine baęlıdır ve nrolojik hastalıklar, metabolik bozukluklardan etkilenir [19].

Şekil 1.4. EEG frekans bantları



Delta ritmi, sıklıkla bebeklerde yetişkinlerde ise derin uyku sırasında kaydedilir. Derin uyku esnasında delta dalgaları genellikle büyük genliklere sahiptir ($75\text{--}200\ \mu\text{V}$) ve kafa derisinin tamamında güçlü uyum gösterir. Delta ritmi, 0,5 ile 4 Hz arasında düşük frekansa sahip olduğu için çene veya boyun kaslarının neden olduğu gürültülerle karıştırılma ihtimali vardır [19], [20].

Teta ritimleri, yetişkin insanlarda nadiren görülür. Genellikle 4 ile 8 Hz frekans aralığında yer alır ve dalgalar yüksek genlikli ve karakteristik testere dişi şeklindedir. Teta ritimlerinin genliği uyku sırasında ve çocuklarda artabilir. Teta ritminin genliğinin artması, uyku hali ile uyanık olma hali arasındaki farkı temsil ettiği için meditasyon ve zihinsel rahatlama sırasında da artar. Teta ritminin genliğinin artışı nörolojik bazı hastalıklar ile de ilişkilendirilebilir [19], [21].

Alfa ritimleri 8 ile 12 Hz aralığındadır, uyanıklık sırasında baskındır ve başın arka bölgelerinde en belirgin şekilde gözlemlenir. Gözler kapalıyken ve kişi rahat bir durumda olduğunda en iyi şekilde görülürler. Özellikle görsel dikkat ve zihinsel çaba ile bastırılır veya zayıflar. Alfa ritminin genliği, uyanık ve dinlenmiş durumdayken artar. Alfa ritmi

dikkat dağınıklığına sebep olan uyaranların ortaya çıkmasını engeller ve zihnin sakinleşmesini sağlar. Yaratıcılık, hayal gücü ve rahatlama ile ilişkilendirilir ve uykuya hazırlık döneminde alfa ritmi genliği arttığı için uyku kalitesini etkileyebilir [19], [22].

Beta ritimleri 12 ile 30 Hz aralığındadır, zihinsel aktivitenin konsantrasyonun arttığı durumlarla ilişkilidir, endişe, gerginlik veya stres gibi zihinsel uyarılma durumlarında artış gösterir. Uyanık halde ve gözler açık durumdayken beta ritimlerinin baskın olduğu gözlemlenir [18], [21].

Gama ritmi 30 ile 100 Hz frekans aralığındadır, sağlıklı yetişkin bireylerde bilişsel işlevlerin yüksek olması ile ilişkilendirilir. Gama ritmi dikkat, algılama, bilinç, karar verme ve istemli olarak yapılan hareketlerin başlangıcı ile ilişkilidir. Yoğun dikkat ve zihinsel çaba gerektiren durumlarda gama ritmi aktivitesi artış gösterir [22].

EEG, tüm memeli hayvanlarda gözlemlenir; bunlar arasında primat EEG' si özellikleri bakımından insan EEG'sine en yakın özellikleri taşır. Spektral özelliklerinin farklı olmasına karşın, kedi, köpek ve kemirgen EEG'leri de insan EEG'sine benzer. Elektriksel beyin aktivitesi daha alt omurgalılarda da görülür, fakat daha yüksek omurgalıların beyin aktivite kayıtlarında görülen ritmik özellikleri taşımaz [19].

EEG' nin Olgunlaşma Süreci

EEG bireyin yaşam süreci boyunca gelişim ve değişim gösteren bir nörofizyolojik aktivitedir. Olgunlaşma sürecini tamamlayarak kararlı bir yapıya ulaşması ortalama 30 yaş civarındır. İleri yaşlarda yeniden değişim göstermeye başlar. EEG' deki bu değişimlerin hızı, zihinsel sağlık ile yakından ilişkilidir. Bebeklikten ergenliğe uzanan dönemde EEG gelişimi, genellikle ritim frekanslarında artış olarak gözlemlenir. Yeni doğanlarda düşük frekanslı delta ritmi baskın iken, yaklaşık 12 aylıkken bu frekansın teta ritmine doğru kaydığı görülür. Çocukluk döneminde kafanın arka bölgelerinde görülen yavaş aktivite, ergenlik sürecinde giderek azalır. Alfa ritmi ise 10 yaş ortaya çıkmaya başlar.

EEG 21 ile 30 yaş arası dönem olan genç erişkinlik döneminde az da olsa hala kararlı olmayan özellikler gösterebilir. Bu dönemde, uyanıklık halinde 30 yaş sonrasında görülmeyen, 1,5- 3 Hz ve 4- 7 Hz aralığındaki ritimlerin EEG' ye katkısı bulunabilir.

Bu olgunlaşma süreci, nörofizyolojik düzeyde dentritik yapıların gelişimi ve miyelinleşme süreçleriyle doğrudan ilişkilidir. Glial hücreler tarafından üretilen miyelin kılıflar, nöron aksonlarını sararak elektriksel iletimi izole eder ve böylece sinirsel iletimin hızını artırırken enerji tüketimini azaltır. Miyelinli liflerde elektriksel sinyallerin iletimi, miyelinsiz liflere kıyasla daha hızlı ve daha verimlidir [19].

EEG Sinyallerinin Kaydedilmesi

EEG sinyallerinin yüksek kalitede olabilmesi için, EEG ölçüm sistemi; iletken ortamlı elektrotlar, filtreli amplifikatörler, analogdan dijitale (A/D) dönüştürücü ve kayıt cihazı gibi temel bileşenlerden oluşur. Kafa derisine yerleştirilen elektrotlar aracılığıyla kaydedilen μV düzeyindeki biyopotansiyel sinyaller, amplifikatörler tarafından uygun voltaj aralığına getirilerek kuvvetlendirilir. Bu işlemden sonra sinyaller, A/D dönüştürücü tarafından dijital formata çevrilir ve son olarak kayıt cihazı aracılığıyla veri depolama süreci tamamlanmış olur [23].


EEG Elektrotlarının Özellikleri ve Konumları

Yaygın olarak gümüş üzerine gümüş klorür kaplama elektrotlar kullanılır. Bu elektrotların tercih edilme sebebi, iyi elektriksel özellikleri sayesinde küçük potansiyel değişimlerini hassas şekilde kaydedebilir olmalarıdır. EEG elektrotları kayıt sırasındaki rollerine göre aktif, referans ve toprak olmak üzere üçe ayrılır. Aktif ve referans elektrotlar arasındaki potansiyel fark, her iki konumdaki elektriksel aktiviteyi yansıtır. Toprak elektrodu sistemin topraklama devresiyle bağlantısından kaynaklanan parazitleri gidermek içindir. Birçok EEG kayıt sistemi birkaç aktif elektrot, bir referans ve bir toprak elektrodu barındırır. Elektrot sayısının belirlenmesi yapılacak olan uygulamanın niteliğine göre değişmekle beraber, bazı klinik uygulamalarda sadece bir aktif elektrot yeterli olurken, birçok uygulamada beynin farklı bölgelerine yerleştirilen çoklu aktif elektrot ile kayıt yapılması gerekir. Elektrot sayısının artması uzamsal çözünürlük ile beraberinde maliyet ve analiz süresini de arttırır. Elektrot sayısının artması toplanan veri kalitesinin düşmesine sebep olabilir [23].

EEG elektrotlarının kafa derisi üzerindeki yerini belirlemek için 1958 yılında Uluslararası Elektroensefalografi ve Klinik Nörofizyoloji Federasyonu tarafından uluslararası 10-20 elektrot yerleşim sistemi adı verilen bir standart yerleşim protokolü geliştirilmiştir. Şekil 1.5' te gösterilen uluslararası 10-20 elektrot yerleşim sistemine göre kafa derisine

yerleştirilen elektrotlar nazyon, inion ve kulak önü noktası referans alınarak bu noktalar arasındaki mesafenin %10 ve %20'lik bölümlerine yerleştirilir. Kafa derisi üzerine yerleştirilen elektrotların adlandırılması harf ve sayılar kullanılarak yapılır. Burada harfler beyin bölgelerini; Fp: frontal kutup, F: frontal, C: central, P: paryetal, O: oksipital, T: temporal temsil ederken, tek sayılar sol yarım küreyi çift sayılar sağ yarım küreyi ifade eder. "z" harfi orta hattı gösterir ve sayı büyüdükçe orta hattan uzaklaşılır [23].

Şekil 1.5. Uluslararası 10-20 sistemi elektrot yerleşimi [23]



EEG uygulaması kolay, taşınabilir boyutlardaki cihazları sayesinde birçok ortamda uygulanabilir, düşük maliyetli ve invaziv olmayan bir yöntem olması gibi özellikler nedeniyle nöropazarlama alanındaki çalışmalarda sıklıkla tercih edilmektedir. EEG sinyalleri ile duygu tespiti, beğeni düzeyi, bilişsel süreçler, dikkat düzeyi gibi ölçümler yapılabilmektedir. Bu sayede nöropazarlama alanında EEG sinyallerinin kullanımı ürün reklamlarının geliştirilmesi, web sitesi dizaynı ya da geliştirilmesi, logo tasarımı, reklam veya afişlerdeki sloganların tespit edilmesi gibi pek çok uygulama alanı bulmaktadır. EEG'nin nöropazarlama alanında kullanılırken çeşitli kısıtlılıkları da vardır. Bunlara elektrik iletkenliğinin kişiden kişiye farklılık göstermesi nedeniyle kaydedilen EEG sinyalinin tam konumunun belirlenmesinin zorluğunu ve EEG sinyalinin ölçeklendirilemez oluşunu örnek verebiliriz. Tablo 1.1'de EEG ile ölçülebilen

parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.1. *EEG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki elektriksel aktiviteyi ölçer.
Ne Sağlar	• Farklı frekans bantlarında (delta, teta, alfa, beta, gama) beyin dalgalarının analizini sağlar. • Bilişsel, duygusal ve dikkat durumlarının fizyolojik temsillerini sunar.
Ne Zaman Kullanılır	• Reklam, ürün veya marka karşısında dikkat ve ilgiyi ölçmek için, • Tüketici tercihlerinin bilinçdışı süreçlerini değerlendirmede, • Zihinsel yük, karar verme, bellek aktivasyonu gibi bilişsel süreçleri analiz etmede kullanılır.
Avantajları	• Gerçek zamanlı beyin aktivitesi verisi sunar. • Non-invaziv ve nispeten düşük maliyetlidir. • Duygusal ve bilişsel süreçlerin ayrıntılı analizine olanak tanır. • Diğer biyometrik yöntemlerle entegre kullanılabilir.
Sınırlılıkları	• Gürültü ve hareket artefaktlarına duyarlıdır. • Yorumlama karmaşıktır ve uzmanlık gerektirir. • Derin beyin yapılarından sinyal alma kapasitesi sınırlıdır. • Elektrot yerleşimi ve veri kalitesi önemlidir.

Magnetoensefalografi (MEG)

Magnetoensefalografi (MEG), kafa derisi seviyesinde beyin aktivitesini kaydetmek için manyetik potansiyelleri kullanır ve deneğin başına yerleştirilen bir kask içindeki hassas dedektörlerle çalışır. Manyetik alan, EEG’de kullanılan elektrik alanının aksine, kan, beyin dokusu veya kemik gibi dokuların türünden etkilenmez ve beyin içindeki aktivitenin derinliğini yüksek uzamsal ve zamansal çözünürlükle gösterebilir. MEG, beyindeki nöral aktivitenin topluluk düzeyindeki hareketlerini izler. MEG kullanılarak yapılan araştırmaların maliyeti, deneylerin dünyanın manyetik alanından arındırılmış özel bir odada yapılmasını gerektirmesi nedeniyle artmaktadır [24].

MEG cihazı, üç boyutlu ve zamana bağlı yüksek çözünürlüğü sayesinde beyin görüntülemeye üstün bir performans sunmaktadır. MEG, beyin hücreleri arasında oluşan

son derece küçük elektrik akımlarının neden olduğu manyetik alanları ölçerek nöral aktiviteyi tespit edebilmektedir. Beyindeki nöronlar arasında meydana gelen elektrokimyasal sinyaller oldukça zayıf manyetik sinyallerdir, MEG sisteminde yer alan 122 yüksek hassasiyetli sensör aracılığıyla bu zayıf sinyaller kolaylıkla algılanabilmektedir. Sensörlerin duyarlılığı, son derece düşük seviyedeki sinyalleri, gürültülü bir ortamda dahi ayırt edebilecek düzeydedir [25].

Tablo 1.2’ de MEG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.2. *MEG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki nöral aktivitenin oluşturduğu manyetik alanları ölçer.
Ne Sağlar	• Zamanla değişen beyin faaliyetlerinin yüksek zamansal ve uzamsal çözünürlükle haritalanmasını sağlar. • Bilişsel ve duyuşal süreçlerin kaynağını doğrudan ve hassas biçimde saptar.
Ne Zaman Kullanılır	• Karar verme, algı, dikkat ve hafıza gibi bilişsel süreçlerin zamanlamasını analiz etmede, • Beynin farklı bölgelerinin senkronizasyonunu ve etkileşimini incelemeye, • Klinik uygulamalarda epilepsi odağının lokalizasyonu için kullanılır.
Avantajları	• Yüksek zamansal ve uzamsal çözünürlük sunar. • Non-invaziv ve doğrudan nöral aktivite ölçümü sağlar. • Derin beyin yapılarındaki etkinliği saptamada EEG’ye göre daha avantajlıdır. • Frekans bazlı analizlerle duyuşal tepkilerin haritalanmasını destekler.
Sınırlılıkları	• Ekipman maliyeti çok yüksektir ve özel korumalı odalar gerektirir. • Taşınabilirliği yoktur ve deneysel ortamda sınırlıdır. • Hareket artefaktlarına karşı oldukça hassastır. • Verilerin işlenmesi ve yorumlanması yüksek düzey uzmanlık gerektirir.

Kararlı Durum Topografisi (KDT)

Kararlı durum topografisi (KDT) 1990 yılında Profesör Richard Sillberstein tarafından geliştirilmiştir. Beyin aktivitesindeki hızlı değişimleri gözlemleyerek ölçmek için nöropazarlama araştırmalarında kullanılan bir araçtır [26].

KDT cihazı beyin içerisindeki elektriksel aktiviteyi ölçmesi açısından EEG cihazına benzer özelliktedir. KDT' nin temel prensibi, belirli bir frekansta tekrarlayan bir uyarıcı kullanarak beyinde tekrarlayan bir aktivite oluşturmaktır. Belirli bir frekansta yanıp sönen bir ışık görsel uyarıcı çalışmalarında kullanılabilir [27].

Tablo 1.3' te KDT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.3. *KDT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beynin belirli frekansta sunulan tekrarlı uyaranlara verdiği sürekli elektriksel yanıtı ölçer.
Ne Sağlar	• Dikkat, ilgi ve görsel algı gibi süreçlere bağlı sinirsel aktivitenin topografik dağılımını ortaya koyar.
	• EEG üzerinden elde edilen sinyallerin frekans çözümlemesini içerir.
Ne Zaman	• Görsel veya işitsel uyaranlara dikkat düzeyini değerlendirmede,
Kullanılır	• Tüketicinin görsel ilgisini çeken öğeleri belirlemede,
	• Ürün yerleşimi ve görsel odak analizlerinde kullanılır.
Avantajları	• Yüksek zamansal çözünürlük sağlar.
	• Dikkatin uzamsal dağılımını frekans bazlı analizle haritalandırabilir.
	• Uygulama sırasında sürekli uyaranla dikkat ölçümü yapılabilir.
	• Non-invaziv ve taşınabilir EEG sistemleriyle entegre çalışabilir.
Sınırlılıkları	• Sinyallerin yorumlanması için frekans analizi uzmanlığı gerekir.
	• Uygulama sürecinde sabit frekanslı uyaran sunumu gerekir.
	• Katılımcının göz hareketleri ve dikkat kaymaları ölçüm kalitesini etkileyebilir.
	• Yüksek kaliteli sinyal için dikkatli elektrot yerleşimi gerekir.

b. Metabolik Aktiviteye Dayalı Nörobilimsel Yöntemler

Metabolik aktiviteye dayalı nörobilimsel yöntemler, beyin bölgelerinin işlevsel durumunu, enerji tüketimi ve kan akışı gibi metabolik süreçler üzerinden değerlendirme imkanı sunar. Bu yöntemler, özellikle derin beyin yapılarının aktivitesini yüksek mekansal çözünürlükle inceleme olanağı tanır. Metabolik aktiviteye dayalı nörobilimsel yöntemlerden sıklıkla kullanılan iki yöntem olan Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ve Pozitron Emisyon Tomografisi (PET), bir sonraki bölümde ayrıntılı olarak incelenecektir.

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI)

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), manyetik alan ile radyo dalgalarını birleştirerek beyin yapılarını detaylı bir şekilde görmeyi sağlayan bir sinyal üretir. Beynin belirli bir bölgesi aktif hale geldiğinde, o bölgeye kan akışı artar ve kandaki oksijen seviyesi değişir, bu değişimi elektromanyetik alanlar ile tespit eden girişimsel olmayan bir yöntemdir. Belirli görevleri yerine getirirken veya pazarlama uyarıcılarına maruz kalırken beyin aktivitelerini ölçmeyi mümkün kıldığı için nöropazarlama çalışmaları için uygundur [24], [28], [29].

Tablo 1.4' te fMRI ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.4. *fMRI ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki kan oksijenlenme düzeyindeki değişiklikleri ölçer.
Ne Sağlar	• Nöral aktiviteye bağlı olarak artan kan akışını dolaylı yoldan gözlemler. • Beyin bölgelerinin görevlerle ilişkili aktivasyonunu haritalar.
Ne Zaman Kullanılır	• Duygusal ve bilişsel süreçlerin (karar verme, ödül beklentisi, hafıza) beyin temellerini araştırmada, • Marka algısı, tüketici tercihi ve reklam etkisinin beyindeki temsillerini analiz etmede, • Beyin bölgeleri arası etkileşim ve işlevsel bağlantıları incelemeye kullanılır.
Avantajları	• Yüksek uzamsal çözünürlük sağlar. • Derin beyin yapılarının aktivitesi ayrıntılı biçimde analiz edilebilir. • Görev temelli veya dinlenme durumunda işlevsel bağlantılar incelenebilir. • Nöral aktivite ile bilişsel süreçler arasında nedensel bağlar kurulabilir.
Sınırlılıkları	• Zamansal çözünürlüğü düşüktür. • Cihaz maliyeti yüksektir ve hareket hassasiyeti fazladır. • Katılımcıların hareketsiz kalması gerekir; doğal davranışlara uygunluk sınırlıdır. • Veri toplama ve analiz süreçleri karmaşıktır ve uzmanlık gerektirir.

Pozitron Emisyon Tomografisi (PET)

Pozitron emisyon tomografisi (PET), beyindeki nöronların aktivitesini ölçmek için radyoaktif madde kullanılarak uygulanan bir görüntüleme yöntemidir. Radyoaktif maddenin yaydığı pozitronlardan gelen radyasyonun kaydedilmesiyle, fMRI' ye benzer mekansal çözünürlüğe sahip fizyolojik görüntüler elde edilir. Aktif nöronlar daha fazla radyoaktif madde kullanır ve bu nedenle daha yoğun bir radyasyon yayarak daha belirgin bir görüntü oluştururlar [28], [29].

Tablo 1.5' te PET ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.5. *PET ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki metabolik aktiviteyi ölçer.
Ne Sağlar	• Radyonüklidlerle işaretlenmiş biyolojik moleküllerin dağılımını izler.
	• Nöral aktivitenin biyokimyasal ve nörokimyasal temellerini gösterir.
Ne Zaman	• Nörotransmitter düzeylerinin dolaylı ölçümü için,
Kullanılır	• Tüketici motivasyonu, ödül beklentisi ve bağımlılık davranışlarının araştırılmasında,
	• Klinik ve farmakolojik çalışmalarda ilaç etkilerinin beyin üzerindeki etkisini incelemede kullanılır.
Avantajları	• Nörokimyasal süreçleri doğrudan ölçme kapasitesi vardır.
	• Derin beyin yapılarının detaylı görüntülenmesini sağlar.
	• Metabolik aktivite üzerinden farklı psikolojik süreçler arasında ilişki kurulabilir.
	• Diğer nörogörüntüleme yöntemleriyle (fMRI, EEG) entegre kullanılabilir.
Sınırlılıkları	• İnvazivdir; radyoaktif madde enjeksiyonu gerektirir.
	• Yüksek maliyetli ve zaman alıcıdır.
	• Klinik ortam dışında kullanımı sınırlıdır.
	• Zayıf zamansal çözünürlüğe sahiptir.

1.3.3.2. Beyin Dışı Nöral Aktiviteyi Kaydeden Yöntemler

Beyin dışı nöral aktiviteyi kaydeden nörobilimsel yöntemler, merkezi sinir sisteminin dolaylı yansımalarını ve otonom sinir sistemi tepkilerini ölçmeye yönelik biyofizyolojik sinyalleri temel alır. Bu kapsamda Elektrokardiyografi (EKG), Göz Takip Sistemleri, Yüzeysel Elektromiyografi (fEMG) ve Elektrodermal Aktivite (EDA) / Deri İletkenliği (Galvanik Cilt Tepkisi – GCT) gibi biyomedikal veri toplama yöntemleri sıklıkla kullanılmaktadır. Bu yöntemler, bireyin duygusal durumları, dikkat düzeyi ve fizyolojik tepkileri hakkında dolaylı bilgileri elde etme imkanı vererek nörobilimsel araştırmalara önemli katkılar sağlamaktadır.

Elektrokardiyografi (EKG)

Elektrokardiyografi (EKG) kalp döngüsü sırasında meydana gelen elektrik potansiyelindeki değişiklikleri kaydederek kalbin elektriksel aktivitesini ölçmek için kullanılan invazif olmayan bir teşhis aracıdır. Elektriksel aktiviteden gelen sinyaller, milyonlarca bireysel hücre tarafından oluşturulan aksiyon potansiyelleri ve bunların aktivasyon sırasıyla belirlenir; bu süreç, kalp içi ve kalp dışı faktörlerden etkilenebilir. Sempatik sinir sistemi ve Parasempatik sinir sistemi gibi iki zıt sistem tarafından kontrol edilen kalp atış hızı; beynin bilişsel performansı, duygusal düzenleme ve stres tepkisi dahil çeşitli yönleriyle ilişkilidir. EKG'deki fizyolojik tepkiler beyin aktivitesinin birkaç saniye gerisinde kalsa da, pazarlama alanındaki nörobilimciler için, belirli bir pazarlama uyarıcısına maruz kalma durumunda test edilen bireylerin duygusal durumları hakkında gerçek zamanlı bilgi elde etmek adına değerli bir araştırma aracıdır [11], [27] .

Tablo 1.6' da EKG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.6. *EKG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Kalbin elektriksel aktivitesini ölçer.
Ne Sağlar	• Otonom sinir sistemi aktivitesinin göstergesi olarak kullanılır.. • Duygusal uyarılma, stres, heyecan ve rahatlama gibi durumların kardiyak yansımalarını sunar.
Ne Zaman Kullanılır	• Tüketicinin duygusal uyarılma düzeyini belirlemede, • Stresli veya ilgi uyandıran reklamlara verilen fizyolojik tepkileri izlemek için, • KDH üzerinden zihinsel yük ve karar verme süreçlerini analiz etmede,
Avantajları	• Ölçüm işlemi non-invazivdir ve kolay uygulanır. • Gerçek zamanlı veri sağlar. • Diğer biyometrik verilerle entegre edilebilir. • Pazarlama içeriğinin duygusal etkisini doğrudan ölçmede etkilidir.
Sınırlılıkları	• Duygusal durumlar dışındaki etkenlerden etkilenebilir. • Kalp hızı değişikliklerinin yorumu her zaman tek nedene bağlanamaz. • Elektrot yerleşimi ve kullanıcı hareketi ölçüm kalitesini etkiler. • Yorumlama için uzmanlık ve veri işleme gerektirir.

Göz İzleme Sistemi

Göz izleme (Gİ), beyin aktivitesini ölçmeden davranış ve bilişi incelemeye olanak tanır; bu yöntem ile deneğin nereye baktığını, ne kadar süreyle baktığını, bakış yolunu ve uyarıcılara bakarken göz bebeği büyüklüğündeki değişimler ölçülebilir. Bu sayede nöropazarlamacıların, belirli bir pazarlama uyarıcısına karşılık olarak insan davranışını açıklamak üzere bakış desenlerini ve konumlarını nöral aktivitelerden tanımlayıp kaydetmelerine olanak tanır [11], [24].

Tablo 1.7' de Gİ ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.7. *GI ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Gözün bakış yönünü, odaklanma süresini ve hareketlerini ölçer.
Ne Sağlar	• Odaklanma noktaları ve bakış sıçramaları gibi parametrelerle görsel dikkat analizini yapar. • Görsel içeriklerin hangi bölümlerinin dikkat çektiğini ortaya koyar.
Ne Zaman Kullanılır	• Reklam, afiş, web sitesi veya ambalaj gibi görsel materyallerin etkililiğini değerlendirmede, • Tüketici karar verme sürecinde dikkat odaklarını analiz etmede, • Kullanıcı deneyimi ve insan-bilgisayar etkileşimi çalışmalarında kullanılır.
Avantajları	• Doğrudan ve gerçek zamanlı dikkat ölçümü sunar. • Katılımcının doğal davranışlarını gözlemlemeye olanak tanır. • Görsel haritalar ve ısı haritaları ile kolay yorumlanabilir çıktılar sağlar. • Diğer nörobilimsel yöntemlerle entegre çalışabilir (EEG, fMRI vb).
Sınırlılıkları	• Dikkatin sadece görsel bileşenini ölçer; zihinsel dikkat hakkında doğrudan bilgi vermez. • Gözlük veya lens kullanımı sistem performansını etkileyebilir. • Katılımcı hareketliliği ölçüm doğruluğunu düşürebilir. • Kapsamlı analiz için yazılım ve uzmanlık gerektirir.

Yüz Elektromiyografisi

Yüz elektromiyografisi (fEMG), küçük yüzey elektrotları kullanılarak temel duyguların ifadesinde önemli rol oynayan yüz kaslarının aktivitelerini kaydeder ve duyguların bilinçli ya da bilinçsiz ifadelerini yansıtan istemli, istemsiz yüz kası hareketlerini test eder. Her duygu, belirli bir yüz hareketi konfigürasyonu ile karakterize edildiğinden, bu ifadelerin analizinde önemli rol oynar. fEMG, görsel gözleme kıyasla yüz ifadelerindeki değişiklikleri tespit etmede daha hassas ve kesin bir yöntemdir; deneklere duygusal yüz ifadelerini bastırmaları talimatı verilse bile, kas aktivitesiyle (mikro hareketlerle) oluşan herhangi bir elektriksel uyarıyı tespit edebilir. Bu yöntem, nöropazarlamada deneklerin duygularının bilinçli ve bilinçsiz ifadelerini anlamak amacıyla, istemli ve istemsiz yüz kası hareketlerini test etmek için kullanılır [11], [24].

Tablo 1.8’ de fEMG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.8. *fEMG ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Kasların elektriksel aktivitesini ölçer.
Ne Sağlar	• İstemli veya istemsiz kas gerilimi ile ilişkili fizyolojik tepkileri ortaya koyar. • Duygusal tepkilere bağlı yüz kası aktivitelerini belirleyebilir.
Ne Zaman Kullanılır	• Reklam veya ürün karşısında yüz ifadeleri yoluyla duygusal yanıtları analiz etmede, • Tüketicinin beğeni, memnuniyet ya da rahatsızlık gibi tepkilerini ölçmede, • Farklı uyaranlara verilen fizyolojik tepkileri karşılaştırmalı olarak değerlendirmede kullanılır.
Avantajları	• Yüz ifadeleri gibi mikro tepkileri yüksek hassasiyetle tespit edebilir. • Duygusal durumların dolaylı ama güvenilir fizyolojik yansımalarını sunar. • Gerçek zamanlı ve dinamik ölçümler yapılabilir. • Diğer biyometrik sistemlerle birlikte kullanılabilir (EEG, GCT vb).
Sınırlılıkları	• Elektrot yerleşimi uzmanlık ve dikkat gerektirir. • Kas dışı hareketler (konuşma, çiğneme) ölçümü etkileyebilir. • Yüz ifadeleri kültürel ve bireysel farklılıklardan etkilenebilir. • Doğrudan duygunun değil, kas aktivitesinin ölçüldüğü unutulmamalıdır. • Bireysel ve çevresel değişkenler sonucu etkileyebilir.

Elektrodermal Aktivite (EDA) ve Galvanik Cilt Tepkisi (GCT)

Elektrodermal aktivite (EDA), cilt yüzeyinde meydana gelen elektriksel iletkenlik değişimlerini ölçen bir yöntemdir. Bu değişimler, ter bezlerinin aktivitesiyle doğrudan ilişkilidir ve otonom sinir sistemi, özellikle sempatik sinir sistemi aracılığıyla kontrol edilir. Galvanik cilt tepkisi (GCT) ise EDA’ nın ölçüm yöntemlerinden biridir ve genellikle bu iki terim birbirinin yerine kullanılır. GCT, kişinin duygusal uyarılara verdiği fizyolojik yanıtları değerlendirmede etkili bir araçtır. Cilt iletkenliğindeki artış, heyecan, stres, ilgi veya korku gibi duygusal durumların bir göstergesi olarak kabul edilir.

Nöropazarlama bağlamında EDA/GCT ölçümleri, tüketicilerin bir ürün, reklam veya marka karşısında verdikleri bilinçdışı tepkileri analiz etmede yaygın biçimde kullanılmaktadır. Bu yöntem sayesinde, tüketicilerin dikkat düzeyi ve duygusal uyarılma seviyeleri objektif olarak değerlendirilebilir. Örneğin bir reklam kampanyası sırasında izleyicilerin hangi sahnelerde daha fazla fizyolojik tepki verdiği belirlenerek, içerik stratejileri bu doğrultuda optimize edilebilir. GCT' nin zaman çözünürlüğü yüksek olduğundan, özellikle kısa süreli uyarıcılara verilen tepkileri incelemede avantaj sağlamaktadır [30], [31].

Tablo 1.9' da EDA ve GCT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.9. *EDA ve GCT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Deri iletkenliğindeki değişiklikleri ölçer.
Ne Sağlar	• Otonom sinir sistemi aktivitesine bağlı fizyolojik uyarılma seviyesini ortaya koyar. • Stres, heyecan, dikkat gibi duygusal ve fizyolojik uyarılma durumlarını yansıtabilir.
Ne Zaman Kullanılır	• Reklam, ürün veya deneyim karşısında uyarılma tepkilerini ölçmede, • Tüketicinin heyecan, stres veya rahatlama gibi fizyolojik durumlarını değerlendirmede, • Farklı uyaranların uyarılma düzeyine etkisini karşılaştırmalı analizde kullanılır.
Avantajları	• Duygusal ve fizyolojik uyarılma durumunu doğrudan ve hassas şekilde ölçer. • Non-invaziv ve görece kolay uygulanabilir. • Gerçek zamanlı ve sürekli veri sağlar. • EEG, fEMG gibi diğer biyometrik ölçümlerle birlikte kullanılabilir.
Sınırlılıkları	• Terleme dışındaki sıcaklık, nem, cilt tipi gibi faktörler ölçümü etkileyebilir. • Uyarılmanın pozitif veya negatif duyguyla mı ilişkili olduğu tek başına belirlenemez. • Elektrotların doğru yerleşimi ve temas kalitesi önemlidir. • Bireysel ve çevresel değişkenler sonucu etkileyebilir.

1.3.3.3. Nöral Aktiviteyi Değiştiren (Manipüle eden) Yöntemler

Nörobilimsel araştırmalarda yalnızca nöral aktivitenin ölçülmesi değil, aynı zamanda belirli beyin bölgelerinin uyarılması veya bastırılması yoluyla bu aktivitenin doğrudan değiştirilmesi de mümkündür. Bu tür yöntemler, hem beyin işlevlerinin nedensel ilişkilerini ortaya koymak hem de çeşitli bilişsel ve duygusal süreçleri yönlendirmek amacıyla kullanılmaktadır. Nöropazarlama araştırmalarında nöral aktiviteyi değiştiren yöntemler arasında en sık başvuru alan tekniklerden biri Transkraniyal Manyetik Uyarım (TMU), bir diğeri ise nörotransmitterler aracılığıyla sinaptik iletişimin farmakolojik olarak düzenlenmesidir. Bir sonraki bölümde bu yöntemler detaylı olarak ele alınacaktır.

Transkraniyal Manyetik Uyarım (TMU)

TMU, osilasyonlu bir elektromanyetik alan kullanarak beyin aktivitesini doğrudan ölçmek yerine, belirli beyin bölgelerini lokal olarak uyarmaktadır. TMU’ nun etkileri, doğrudan bir ölçüm yerine, doğruluk veya tepki süresi gibi davranışsal tepkiler aracılığıyla dolaylı olarak değerlendirilmektedir. TMU, plastik muhafazalı elektriksel bir bobinin başa yakın bir konuma yerleştirilmesiyle uygulanmaktadır. Böylelikle beyin dokusundan geçen bir manyetik alan oluşturarak belirli bölgelerde nörofizyolojik değişiklikler meydana getirilmektedir. Yüksek frekanslı uyarımlar ile sinirsel aktivite geçici olarak artırılırken, düşük frekanslı uyarımlar ile de sinirsel aktivite geçici olarak baskılanmaktadır [24], [32].

Tablo 1.10’ da TMU ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.10. *TMU ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki nöral aktivitenin oluşturduğu manyetik alanları ölçer.
Ne Sağlar	• Zamanla değişen beyin faaliyetlerinin yüksek zamansal ve uzamsal çözünürlükle haritalanmasını sağlar. • Bilişsel ve duysal süreçlerin kaynağını doğrudan ve hassas biçimde saptar.
Ne Zaman Kullanılır	• Karar verme, algı, dikkat ve hafıza gibi bilişsel süreçlerin zamanlamasını analiz etmede, • Beynin farklı bölgelerinin senkronizasyonunu ve etkileşimini incelemeye, • Klinik uygulamalarda epilepsi odağının lokalizasyonu için kullanılır.
Avantajları	• Yüksek zamansal ve uzamsal çözünürlük sunar. • Non-invaziv ve doğrudan nöral aktivite ölçümü sağlar. • Derin beyin yapılarındaki etkinliği saptamada EEG’ ye göre daha avantajlıdır. • Frekans bazlı analizlerle duysal tepkilerin haritalanmasını destekler.
Sınırlılıkları	• Ekipman maliyeti çok yüksektir ve özel korumalı odalar gerektirir. • Taşınabilirliği yoktur ve deneysel ortamda sınırlıdır. • Hareket artefaktlarına karşı oldukça hassastır.

- Verilerin işlenmesi ve yorumlanması yüksek düzey uzmanlık gerektirir.

Nörotransmitterler (NT)

Nörotransmitterler (NT' ler), sinirsel sinyallerin bir nörondan hedef nörona iletimini sağlayan kimyasal bileşenlerdir. NT' lerin büyük bir bölümü, amino asitler ve peptitler gibi yaygın öncül maddelerden türetilmekte olup, bu dönüşüm genellikle sınırlı sayıda biyosentetik adım gerektirir. Nöropazarlama araştırmalarında oksitosin gibi farmakolojik ajanların katılımcılara doğrudan uygulanması etik kurullar ve denetim organları nezdinde çeşitli endişelere yol açabilmektedir. Örneğin, fenilalanin, serotonin, tirozin gibi belirli bir NT'nin aşırı yüklenmesi ya da tükenmesi, beslenme düzeni aracılığıyla kontrol edilebilmesi gibi alternatif yaklaşımlar mevcuttur. Bu tür müdahaleler, beyin içi ve dışındaki nöral aktiviteleri ölçmeye yönelik diğer nörobilimsel yöntemlerle birlikte uygulandığında, nöropazarlama araştırmalarında pazarlama uyaranlarına karşılık ortaya çıkan nöropsikolojik süreçlerin tüketici davranışlarıyla olan ilişkisini değerlendirmek mümkün hale gelmektedir [11].

Tablo 1.11' de NT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri detaylı olarak verilmektedir.

Tablo 1.11. *NT ile ölçülebilen parametreler, nöropazarlamada kullanım alanları, nöropazarlama araştırmalarındaki avantajları ve limitleri*

Ne Ölçer/	• Beyindeki kimyasal iletimi ve nöral iletişimin yapısını,
Ne Sağlar	• Duyguların, motivasyonun, ödül beklentisinin ve karar verme süreçlerinin nörokimyasal temelini, • Özellikle dopamin, serotonin, oksitosin ve norepinefrin gibi NT'lerin düzeylerini ve etkilerini ölçer.
Ne Zaman Kullanılır	• Tüketicinin ödül beklentisi, haz alma durumu ve motivasyon düzeyini değerlendirmek için, • Marka sadakati, güven, sosyal bağlılık gibi psikolojik süreçleri anlamada, • Duygusal karar verme ve alışveriş bağımlılığı gibi davranışları incelemede, • Farmakolojik müdahalelerle davranışsal tepkileri manipüle etmek amacıyla kullanılır.
Avantajları	• Tüketici davranışlarının biyolojik temellerine dair derinlemesine içgörüler sunar. • Duygusal tepkilerin nedenlerini nörokimyasal düzeyde açıklamaya olanak tanır. • Farklı NT sistemleri üzerinden spesifik duygusal süreçler hedeflenebilir. • Nöropazarlamada davranışsal yönlendirme potansiyeli taşır.
Sınırlılıkları	• Doğrudan ölçüm genellikle invaziv yöntemler veya farmakolojik müdahaleler gerektirir. • İnsan çalışmalarında etik kısıtlamalar ve yasal sınırlamalar vardır. • Beyindeki NT düzeyleri genellikle PET, kan örneği gibi dolaylı yollardan takip edilebilir. • Diğer fizyolojik veya davranışsal verilerle birlikte yorumlanması gerekir.

1.4. Literatür Taraması

Bu bölümde, özellikle son yıllarda literatürde yer alan nöropazarlama çalışmalarına yer verilmiştir ve tez çalışmasının literatürde yer alan çalışmalardan farkları ve özgün değeri belirtilmiştir.

1.4.1.Nöropazarlama Alanındaki Genel Literatür Taraması

Nöropazarlama sinirbilim, psikoloji, pazarlama, davranışsal ekonomi, istatistik ve veri bilimi, bilişsel bilimler, yapay zeka ve makine öğrenmesi ve etik gibi disiplinlerin bir araya gelmesiyle oluşur. Nöropazarlamanın temel amacı, tüketicilerin bilinçli ve bilinçdışı karar alma süreçlerini çeşitli nöropazarlama araçları kullanarak, daha derin bir şekilde çözümleyerek, pazarlama stratejilerini buna göre optimize etmektir. Bu bölümde çeşitli nöropazarlama araçları kullanılarak yapılan çalışmalardan bahsedilmektedir.

Nöropazarlama alanında en çok bilinen çalışmalardan biri 2003 yılında Houston' daki Baylor Tıp Fakültesi'nde yapılan Read Montague ve ekibinin Pepsi Paradoksu olarak adlandırılan çalışmasıdır. Montague ve ekibi dört gruba ayırdıkları 67 katılımcının Pepsi ve Coca Cola içerken beyin aktivitelerini fMRI kullanarak kaydetmiştir. Katılımcıların tattıkları içeceğin hangi markaya ait olduğunu bilmeden yaptıkları tercih ile markayı gördükten sonraki tercihleri karşılaştırılmıştır [33].

Bakalash ve ekibi; 2013 yılında 22-34 yaş arası 7 kadın 8 erkek 15 katılımcı ile yapmış olduğu çalışmada; fMRI ve anket kullanarak, reklamın tetiklediği duygusal uyarılma ve reklama dair hafıza arasındaki ilişkiyi incelemiştir. Katılımcılara daha önce yapılan bir anket çalışması ile belirlenmiş hatırlanabilir ve hatırlanamaz reklamlar izlettirilerek fMRI ile beyin aktivitelerini ölçmüştür [34].

Gangadharbatla ve ekibi; GCT ve EKG nöropazarlama araçlarını kullanarak yaptıkları araştırmada 60 katılımcının video oyunlarındaki markalara maruz kaldıklarında gösterdikleri tepkileri, artan deri iletkenliği ve azalan kalp atış hızı ile ölçmüştür. Katılımcılar bir araba yarışı video oyunu oynarken; oyun içerisine yerleştirilmiş reklam panosunda Citgo, Subway, Pepsi, Panasonic ve Evian markalarının logoları yer almıştır [35].

Maxian ve ekibi tarafından yapılan çalışmada; 2005 yılı En İyi 100 Global Marka Listesinden farklı 17 ürün kategorisi belirlenerek toplam 34 marka seçilmiştir. Yaşları 19 ile 23 arasında değişen 56 katılımcı yalnızca marka logolarına maruz bırakılmıştır. GCT, EKG ve fEMG teknikleri kullanılarak marka logolarına verilen tepkiler ölçülmüştür [36].

Silberstein ve ekibi; yaşları 18 ile 59 arasında değişen 50 erkek katılımcı ile yaptıkları çalışmada KDT kullanarak Kavramsal Kapanış olgusunu incelemişlerdir. Katılımcılar, on odalı sanal bir sanat galerisinde yapılan bir yolculuğu izlemişlerdir. Galeri odaları arasındaki kapının görünmesiyle birlikte sol yarıküredeki alt frontal kafa derisi bölgesinde beyin aktivitesinde anlamlı bir düşüş gözlemlenmiş ve bu durum Kavramsal Kapanış ile ilişkilendirilmiştir [37].

Baumgartner ve ekibi çalışmalarında, 32 katılımcıya düşük frekanslı TMU uygulayarak sağ veya sol dorsolateral prefrontal kortekslerini geçici olarak etkisiz hale getirmiştir. Ardından katılımcılar, Ultimatom Oyunu'nda adil ya da adaletsiz para tekliflerine tepki vermiştir. Bu çalışmanın sonucu; adil karar verme davranışının sağ dorsolateral prefrontal korteksin ve ventromedial prefrontal korteksin birlikte çalışmasıyla desteklendiğini göstermektedir [38].

Khushaba ve ekibi; 25 ile 65 yaş arasında 18 katılımcı ile yaptıkları çalışmalarında; Gİ ve EEG verileri kullanarak katılımcıların tercih ettikleri krakerleri derecelendirmiştir [39].

Dağdevir, 18- 70 yaş arasındaki 58 katılımcının kalp hacmi basıncı, elektro dermal aktivite ve vücut sıcaklığı gibi fizyolojik sinyal verilerini içeren NeuroBioSense" veri setini kullanarak yaptığı çalışmasında, 7 farklı duygu (Sevinç, Şaşkınlık, Öfke, Tiksime, Üzüntü, Korku, Nötr) durumu için farklı makine öğrenimi algoritmalarının sınıflandırma performanslarını karşılaştırmış ve nöropazarlamada tercih tespitine yol göstermeyi amaçlamıştır [40].

1.4.2. EEG yöntemi kullanılan Nöropazarlama Çalışmaları Alanında Literatür Taraması

Beyin aktivitelerinin incelenmesinde öne çıkan EEG, bireylerin duygusal tepkilerini ve bilişsel süreçlerini zaman çözünürlüğü yüksek bir şekilde ölçme imkanı sunarak, tüketici davranışlarını daha derinlemesine anlamayı kolaylaştırır. Düşük maliyetli, non-invaziv ve taşınabilir oluşu, EEG' nin nöropazarlama araştırmalarında sıkça tercih edilen bir yöntem haline gelmesini sağlamıştır. Bu bölümde, nöropazarlama alanında literatürdeki EEG sinyallerinin müşterilerin tepkilerini, davranışlarını ve duygularını tahmin etmedeki rolünü inceleyen güncel uygulama örnekleri ele alınacaktır.

Ullah ve ekibi tarafından 15 katılımcının yer aldığı Muse 2 Headband 4 kanallı EEG cihazı kullanılarak yapılan çalışmada, e-ticaret platformlarındaki ürünlere yönelik

tüketici tercihlerini “Beğenilen” ve “Beğenilmeyen” olarak sınıflandırmak amacıyla öngörüye dayalı bir modelleme yöntemi geliştirilmiştir. Katılımcılar, üç farklı modelde olan gömlek, ayakkabı, gözlük gibi 10 çeşit ürünü incelerken hem EEG sinyalleri hem de ürün tercihleri kayıt altına alınmıştır. Elde edilen veriler, ürün bazlı ve birey bazlı sınıflandırmalarda kullanılmak üzere; 5 farklı makine öğrenimi algoritması kullanılarak analiz edilmiştir. Birey bazlı sınıflandırma sonuçları, YSA için %50,40 ve K-EYK için %60,89 başarı oranlarıyla görece düşük kalmıştır. Öte yandan, ürün bazlı sınıflandırma performansı daha yüksek bulunmuş; YSA ile %81,23 ve DVM ile %80,38 doğruluk oranına ulaşılmıştır [41].

Sourov ve ekibi; yaşları 19 ile 28 arasında değişen 24’ ü erkek 25’ i kadın 49 katılımcının EEG verilerini kullanarak yapmış olduğu çalışmada, tüketicilerin görsel reklamlara verdikleri tepkileri incelemiş ve tüketici tercihlerini sınıflandırmıştır. Bu çalışmada EEG verilerinin kayıt aşamasında 14 kanallı Emotiv Epoc+ cihazı kullanılmıştır ve kanal seçimi yapılmaksızın 14 kanaldan gelen EEG verisi işlenerek sınıflandırma yapılmıştır. Katılımcılara internetten toplanan, erkeklere yönelik ürünler (örneğin, erkek ayakkabıları), kadınlara yönelik ürünler (örneğin, kadın ayakkabıları) ve cinsiyetten bağımsız olduğu düşünülen ürünler (örneğin yiyecekler) olmak üzere üç kategoride toplam 30 adet reklam görseli gösterilmiştir. Ekip özellik çıkarma aşamasında istatistiksel özellikler, özellik seçme aşamasında istatistiksel grafikler kullanmıştır. Katılımcıların beğenme ve beğenmeme tercih sınıflandırmasında DVM, K-EYK ve YSA sınıflandırma algoritmalarını kullanılmıştır. Kadın katılımcılar ve K-EYK sınıflandırıcısı için elde edilen maksimum doğruluk %75,7 olarak elde edilmiştir [42].

Zeng ve ekibinin dokuz erkek altı kadın 15 katılımcı ile gerçekleştirdiği çalışmasında 32 kanallı BrainAmp Amplifier EEG cihazı kullanılmıştır. Katılımcılara 25 farklı spor ayakkabısı görseli sunulurken EEG sinyalleri kayıt altına alınarak beğeni beğenmeme tercih tahmini yapılmıştır. EEG verileri uluslararası 10–20 sistemine göre katılımcıların başına yerleştirilen 22 gümüş klorür elektrottan kaydedilmiştir. Sinyal ön işleme aşamasında bant geçiren filtre ve bağımsız bileşen analizi (BBA) uygulanarak istenmeyen gürültü ve artefaktlar giderilmiştir. Ekip çalışmasında özellik çıkarma aşamasında GSY, beyin asimetrisi, Diferansiyel Entropi (DE) ve Hjorth parametreleri özellik çıkarma yöntemlerini uygulamıştır. K-EYK sınıflandırma algoritması ile %94,22 doğruluk oranı elde edilmiştir [43].

Alakuş ve ekibi tarafından yapılan çalışmada; 28 farklı katılımcıdan 14 kanallı Emotiv Epoc + kullanılarak toplanan EEG verileri ile duygu durumu analizi yapılmıştır. Katılımcılar duygu durumlarını sıkıcı, sakin, korkunç ve eğlenceli olacak şekilde yansıtan 4 farklı bilgisayar oyununu 5 dakika boyunca oynamıştır ve her bir oyun için duyguların değerlendirilmesinde kullanılan görsel bir öz-değerlendirme anketi olan Self-Assessment Manikin (SAM) formunu doldurmuştur [44].

Ceylan, 55 katılımcı ile yaptığı çalışmasında farklı iki otomobil markasının (Mercedes ve Dacia) reklam filmleri izletilmiştir. Ayrıca bu reklam filmleri içerisinde otomobilin ön görünüm, ön konsol, yan görünüm, arka görünüm, arka far, logo ve ızgara bölümlerinden oluşan 7 farklı görsel gösterilerek EEG kayıtlarını almıştır. Reklam videosu izletildikten sonra, katılımcıların 10 saniyelik resim gösterimi sırasında beğeni puanlamasını ekranda açılan form ile Hiç Beğenmedim (-2), Beğenmedim (-1), Kararsızım (0), Beğendim (1), ve Çok Beğendim (2) olarak yapmaları istenmiştir. Ceylan çalışmasında, EEG sinyallerini Görgül kip ayrışımı (GKA) tabanlı yöntemlerle ve Derin Öğrenme teknikleriyle analiz etmiştir. Özellik çıkarma aşamasında elde ettiği Öz Kip Fonksiyonlarından (ÖKF) 15 istatistiksel özellik çıkararak beğeni durumu sınıflandırması yapmıştır. GKA tabanlı yöntemler ile en yüksek doğruluk GGKA yöntemi ile %94 olarak, Derin Öğrenme yönteminde ise en yüksek doğruluk ResNet50 mimarisi ile %93 olarak kaydetmiştir [27].

Golnar-Nik ve ekibi, yaş ortalaması 23 olan 16 katılımcı ile gerçekleştirdiği çalışmada; birbirinden farklı özelliklere sahip olan Apple, Samsung, Nokia ve Meizu marka cep telefonlarının reklamlarını izleterek katılımcıların EEG kayıtlarını almıştır. EEG verileri ile beğenme ve beğenmeme kararları arasındaki farkın daha çok F4 ve Ft8 elektrotlarının bulunduğu sağ frontal bölgede olduğu gözlemlenmiştir. Ayrıca bir ürünün beğenilip beğenilmeyeceği ya da satın alınıp alınmayacağına dair karar verme olasılığını tahmin etmek için en ayırt edici EEG kanallarının frontal ve centro-parietal bölgelerdeki (Fp1, Cp3, Cpz) elektrotlar olduğu belirtilmiştir. Ekip 32 kanallı EEG cihazı kullandığı çalışmada, ham EEG sinyallerini filtrelemek için bant geçiren filtre ve BBA filtresi uygulamıştır. Özellik çıkarma aşamasında GSY Welch yöntemi ile spektral özellikler çıkarılmıştır. Sınıflandırıcı olarak DVM ve LDA algoritmaları kullanılmıştır. Beğenip beğenmeme tercihleri arasında %63,95 oranında doğruluk ile ayırım yapılmıştır [45].

Soria Morillo ve ekibi, 10 katılımcıya 14 reklam videosu izlettiği çalışmasında 14 kanallı Emotiv Epoc + cihazı kullanmış ve beyinin farklı bölgelerinin aktivitesinin nasıl tepki verdiğini ayırık sınıflandırma teknikleri kullanarak anlamlandırmaya çalışmıştır. Çalışmada ham EEG sinyallerine bant geçiren filtre uygulanmış, göz kırpma artefaktları ve yüz hareketleriyle ortaya çıkan kas aktivasyonu için etkili olan BBA filtresi uygulanmıştır. Özellikle çıkarma aşamasında istatistiksel özellikler ve GSY welch yöntemi ile spektral özellikler çıkarılmıştır. Sınıflandırma algoritmaları olarak YSA, Ameva (Association Metric-based Evaluation of Variable Attributes) ve C4.5 Karar Ağacı tercih edilmiş ve en yüksek doğruluk oranını YSA ile %80 olarak elde edilmiştir [46].

Chew ve ekibi, 5 katılımcı ile gerçekleştirdiği çalışmasında; 3 boyutlu hareketli 60 sanal bilezik benzeri şekil kullanarak tüketici estetik tercihlerini incelemiştir. Bu çalışmada EEG sinyallerinin filtreleme aşamasında Advance Brain Monitoring firmasının geliştirdiği yazılım geliştirme kiti kullanılarak göz kırpması, kas hareketi, sıçrama gibi artefaktlar temizlenmiştir. Özellik çıkarma aşamasında, Kısa Zamanlı Fourier Dönüşümü ile elde edilen zaman-frekans verileri kullanılarak delta, teta, alfa, beta ve gama bantlarında güç değerleri hesaplanmış; olaya bağlı senkronizasyon/ desenkronizasyon yaklaşımı ile normalize edilmiştir. Üç boyutlu bilezik şekilleri izlenirken elde edilen EEG sinyalleri zaman-frekans analiziyle alfa, beta, teta, gama ve delta ritimlerine ayrılmış, ardından bu sinyaller DVM ve K-EYK sınıflandırıcıları kullanılarak beğeni ve beğenmeme olmak üzere iki sınıfa ayrılmıştır. Frontal bölgede bulunan Fz, F3 ve F4 EEG kanallarından elde edilen alfa, teta ve delta ritimleri kullanılarak sınıflandırma yapılmış ve K-EYK yöntemiyle %80'e varan doğruluk elde edilmiştir [47].


Baldo ve ekibi, yaş ortalaması 29 olan 40 kadın katılımcı ile öz değerlendirme ve EEG verilerini karşılaştırdığı çalışmasında; 30 kadın ayakkabısı modeli katılımcılara gösterilirken EEG sinyallerini kaydetmek için 64-kanallı BioSemi EEG sistemi kullanılmıştır. Deney aşamasında, gerçek mağaza ortamındaki etkileşimli ortamı taklit etmek ve katılımcıların ayakkabı modellerine dair net bir fikir geliştirmesini sağlamak için, her ayakkabının yanında fiyat bilgisi de yer almıştır. Katılımcılar, istedikleri kadar zaman harcayarak her ayakkabıyı 1'den 5'e kadar 1 = hiç beğenmedim, 5 = çok beğendim ve satın almak isterim olacak şekilde puanlamıştır. Çalışanın sonucu, öz değerlendirme anket verilerinin ayakkabı başarısını %60 doğrulukla tahmin edebildiğini gösterirken,

EEG verilerinin %80 doğruluk oranıyla çok daha güçlü bir tahmin aracı olduğunu ortaya koymuştur [48].

1.4.3. Tez Çalışması Kapsamında Kullanılan Veri Setini Kullanan Literatür Çalışmaları

Yadava ve ekibi, e-ticaret ürünlerine yönelik tüketici tercihlerini “beğenme” ve “beğenmeme” şeklinde anlamaya yönelik tahmine dayalı bir modelleme yapmak için 25 erkek ve 15 kadından oluşan 40 katılımcının EEG sinyallerini analiz etmiştir. Ekip çalışmasında dahili olarak 2048 Hz örnekleme frekansına sahip, uluslararası 10-20 sistemine uygun, kablosuz Emotiv Epoc+ cihazını kullanmış ve EEG sinyallerini kanal başına 128 Hz’e düşürerek kaydetmiştir. Kaydedilen EEG verileri bluetooth bağlantısı aracılığıyla bilgisayara aktarılmıştır. Çalışmada deney sırasında katılımcı bilgisayar ekranında alışveriş ürünlerinden birine bakarken eşzamanlı olarak EEG sinyalleri kaydedilmiştir. Katılımcı ürünü inceledikten sonra beğendi veya beğenmedi olarak tercihini belirtmiştir. Önerilen yaklaşımın akış şeması Şekil 1.6’da verilmiştir.

Şekil 1.6. Yadava ve ekibi tarafından önerilen tercih tahmin modelinin akış şeması



Kayıt aşamasından sonra sinyal ön işlemede 5 boyutlu pencere aralığı kullanılarak ikinci dereceden bir polinomla Savitzky–Golay (S-Golay) filtresi uygulanmıştır.

Özellik çıkarımı için ayrık dalgacık dönüşümü (ADD) kullanılmıştır. EEG sinyalleri Db4 tekniği ile dört seviyede çözülmüştür. Hesaplama 14 kanal için yapılmıştır ve her bir kanal için (gama, beta, alfa, teta ve delta) karşılık gelen 14 boyutlu bir özellik vektörü

elde edilmiştir. Ekip sınıflandırıcı olarak Gizli Markov Model (GMM) kullanmıştır ve en yüksek tahmin oranını %70,33 olarak kaydetmiştir [49].

Yadava ve ekibi tarafından oluşturulan veri setinin 25 erkek katılımcının EEG verilerinden oluşan kısmı erişime açıktır. Bu sebepten ötürü bu veri seti ile ilgili literatürdeki çalışmalar çoğunlukla 25 erkek katılımcının EEG verisi ile yapılmıştır.

Kumar ve ekibi; Yadava ve ekibi tarafından oluşturulan veri setini kullanarak yaptıkları çalışmalarında, tüketici ürünlerinin değerlendirme tahminini gerçekleştirmek amacıyla farklı veri kaynaklarını birleştiren çok yönlü yeni bir analiz çerçevesi önermiştir. Bu kapsamda, EEG sinyalleri ile küresel ölçekte elde edilen ürün ve marka değerlendirmelerini bütünleştirmiş ve bir tahmin modeli geliştirmiştir. Küresel değerlendirmeleri, Doğal Dil İşleme (DDİ) teknikleri kullanarak e-ticaret platformlarından toplanan müşteri yorumlarının analiz edilmesiyle elde etmiştir. Çalışmanın genel performansını artırmak ve küresel ile yerel değerlendirmeleri optimize etmek amacıyla Yapay Arı Kolonisi (ABC) tabanlı optimizasyon algoritması uygulanmıştır. Çalışmada, EEG sinyalleri, ürünün markası ve müşteri yorumlarından elde edilen duygu puanları gibi üç farklı veri kaynağı kullanılarak çoklu analiz tabanlı bir tahmin mekanizması oluşturulmuştur. Sinyal ön işleme aşamasında, EEG sinyalleri üzerinde S-Golay filtresi uygulanmış ve ikinci dereceden polinom ile 5 büyüklüğünde bir pencere kullanılmıştır. Özellik çıkarımı sürecinde, EEG sinyallerindeki değişimlerin tespiti açısından yüksek duyarlılığa sahip olması nedeniyle, ADD yöntemini kullanmışlardır. Özellik çıkarımı sürecinde her bir bant dalgası için ortalama, standart sapma ve enerji olmak üzere üç istatistiksel özellik elde ederek tahmin sürecinde kullanılmak üzere analiz edilmiştir. Ekip EEG sinyalleri ve e-ticaret platformlarından alınan müşteri yorumlarından yararlanılarak ürün değerlendirme tahmini gerçekleştirmiştir. Yorumların ön işleme aşamasında, gereksiz bileşenlerin ayıklanması amacıyla durak kelimeler, noktalama işaretleri ve tekrarlayan kelimeler çıkarılmıştır. Yorumların duygu analizi sürecinde kelimeleri duygu dereceleriyle eşleştiren sözlük tabanlı bir analiz teknik olan VADER (Valence Aware Dictionary and Sentiment Reasoner) yöntemi kullanılmıştır. VADER, Tüketici tercihlerini EEG sinyallerinden tahmin etmek amacıyla her bir frekans bandı için beş farklı Rastgele Orman (RO) modeli eğitilmiştir. Çalışmanın sonuçları, teta bandı dalgalarının EEG sinyalleri kullanılarak tüketici tercihlerini tahmin etmek açısından önemli özellikler taşıdığını göstermektedir.

Ekip sınıflandırma aşamasında, RO algoritması kullanmıştır ve en yüksek tahmin oranını %71 olarak kaydetmiştir [50].

Amin ve ekibi çalışmalarında, Yadava ve ekibi tarafından oluşturulan veri setinin 25 katılımcının EEG sinyallerinden oluşan kısmını kullanılarak tüketici davranışlarını analiz amacıyla veri madenciliği ve makine öğrenimi algoritmalarıyla bir model önermiştir. EEG sinyallerinden zaman-frekans dağılımı özelliklerini çıkararak bu özelliklere çeşitli sınıflandırma algoritmaları uygulamıştır. Yapılan analizlerle, tüketicilerin belirli pazarlama politikalarına yönelik olumlu ya da olumsuz tepkilerinin ardındaki nedenler ortaya konulmuştur. Ayrıca, nöropsikolojik ölçümlerin tüketicilerin pazarlama uyarılarına karşı duyarlılıklarını ne derece doğru bir şekilde yansıtıp yansıtmadığı da değerlendirilmiştir. Bu çalışmada sinyal önileme metodu olarak hareketli ortalama kullanılmıştır. Sinyal önileme aşamasından sonra hızlı ve tekrarsız dönüşümlerin sağladığı üstünlük nedeniyle ADD yöntemi kullanılarak özellik çıkarımı yapılmıştır. Sınıflandırma aşamasında özellikler, eğitim ve test setlerine ayrılmış, eğitim seti kullanılarak bir model oluşturulmuş ve test seti için sınıf etiketleri tahmin edilmiştir. Son olarak, gerçek ve tahmin edilen sınıf etiketleri karşılaştırılarak modelin performansı değerlendirilmiştir. Özellik çıkarımının ardından, tüketicilerin ürün reklamı tercihlerini sınıflandırmak amacıyla Karar Ağacı algoritması (KA) kullanılmıştır. En yüksek doğruluk oranı serebral korteksde %95 olarak KA algoritması ile elde edilmiştir [51].

Aldayel ve ekibi çalışmalarında, tüketici davranışları içindeki gizli zihinsel süreçleri yakalamaya odaklanmıştır. Özellikle, karar vericinin belirli bir davranışın nedenini bilinçli olarak açıklayamadığı veya farkında olmadığı durumları ele almıştır. Deney sürecinde, subjektif tercihler için özdeğerlendirme anketi, objektif tercihler için ise valans göstergeleri kullanılmıştır. Düşük ve yüksek valanslar, hedef beğenme/ beğenmeme tercih değerlerinin göstergeleri olarak belirlenmiştir. EEG sinyallerinin işlenmesi sürecinde, 4– 45 Hz aralığında bir bant geçiren filtre kullanılmış ve ardından gürültüleri temizlemek amacıyla bağımsız bileşen analizi (BBA) ve S–Golay filtresi uygulanmıştır. Bu çalışmada tercihleri tanımlamak için sadece F3, F4, AF3 ve AF4 elektrotları kullanılmıştır. GSY welch yöntemi kullanılarak EEG frekansları elde edilmiş ve bunlar, valansları ölçmek için tercih göstergeleri olarak kullanılmıştır. Performans karşılaştırmaları için üç sınıflandırıcı kullanılmıştır: RO, DVM ve K-EYK. Valans göstergesi olmadan yapılan sınıflandırmada, RO algoritması %83 doğrulukla en yüksek

performansı sergilemiş ve bunu %72 doğrulukla K-EYK takip etmiştir. Ancak, valans göstergesi ile yapılan sınıflandırmalarda en iyi sonuçlar, tüm üç sınıflandırıcı için de elde edilmiştir. Valans göstergesi ile yapılan sınıflandırmada, RO algoritması %94 doğrulukla en yüksek performansı sağlamış ve bunu %87 doğrulukla DVM izlemiştir. Genel olarak, RO algoritması, K-EYK ve DVM algoritmalarına kıyasla daha yüksek doğruluk oranları elde etmiştir [52].

Ykhlef ve ekibi çalışmalarında, Yadava veri setinin 25 katılımcıdan oluşan kısmını kullanarak bireylerin tercih tespitini artırmaya yönelik farklı özellik çıkarım ve sınıflandırma yöntemlerini incelemiştir. Çalışmada, EEG sinyallerinin ön işlenmesi için 4- 45 Hz bant geçiren filtre, BBA ve S-Golay filtreleri uygulanmış, ardından AF3, F3, AF4 ve F4 elektrotları kullanılarak frekans bantları çıkarılmıştır. EEG sinyallerinden ADD ve GSY yöntemleriyle çıkarılan özellikleri kullanılarak, beğeni ve beğenmeme durumlarının belirlenmesine yönelik EEG tabanlı tercih indeksleri hesaplanmıştır ve tercih indekslerinin sınıflandırma sonuçlarında doğruluk yüzdesini arttırdığı tespit edilmiştir. EEG verilerinden elde edilen özellikler doğrultusunda oluşturulan tercih indeksleri, deneklerin öznel öz-değerlendirme etiketleri ve valans tabanlı nesnel etiketlerle değerlendirilmiş, bu iki etiketleme türü arasındaki uyum Cohen'in kappa katsayısı ile analiz edilmiştir. Ekip tercih sınıflandırması için derin sinir ağı (DSA) önermiş ve performansı DVM, K-EYK ve RO gibi geleneksel sınıflandırıcılarla karşılaştırmıştır. Çalışmanın sonuçları incelendiğinde; önerilen DSA modelinin K-EYK ve DVM' ye kıyasla daha yüksek doğruluk, hassasiyet ve geri çağırma değerleri sunduğunu, RO modelinin ise benzer performans sergilediği görülmektedir [3].

Alimardini ve ekibi çalışmalarında Yadava veri seti ile Utrecht kentinde nöropazarlama şirketi olarak faaliyet gösteren Unravel1 tarafından oluşturulan bir veri setini kullanarak makine öğrenimi ve derin öğrenme yaklaşımlarının performansını karşılaştırmıştır. Sinyal ön işleme aşamasında bant geçiren filtre kullanılmıştır. Ekip özellik çıkarımı için EEG sinyallerindeki belirgin frekans bantlarını çıkarıp her bir banda ait spektral enerji hesaplaması yapmıştır. Tüm kanallardan elde edilen spektral enerjiler birleştirilmiş ve nihai özellik vektörü oluşturulmuştur. Sınıflandırma sonuçları açısından karşılaştırma yapıldığında makine öğrenimi ile %50,71 derin öğrenme ile %51,48 doğruluk oranı ile her iki sınıflandırma yaklaşımının da Yadava veri seti üzerinde anlamlı bir doğruluk gösteremediği görülmüştür [53].

Panda ve ekibi çalışmalarında nöropazarlamaya dayalı bir nöro-tavsiye sistemini önermiştir. Katılımcılar ürünleri izlerken, kafa derisi aktivasyonu topografik harita kullanılarak kaydedilmiştir ve yüksek düzeyde uyarılmış EEG kanalları aynı sepette gruplandırılmıştır. Her biri üç çeşide sahip on dört farklı ürün türü için üç sepet oluşturulmuştur. Sepetler oluşturulurken beğeni-beğenmeme faktörleri de dikkate alınmıştır. Öneri sisteminin etkinliğini test etmek için destek, güven ve kaldırma olmak üzere üç popüler ölçüm kullanılmıştır. Ham EEG sinyallerinin ön işleminde yüksek frekans gürültülerini temizlemek için 1-40 Hz arasında bant geçiren filtresi uygulanmıştır. Sonrasında, EEG sinyallerindeki her türlü artefaktı temizlemek için BBA kullanılmıştır. Özellik çıkarımı aşamasında farklı frekans aralıklarında zaman çözünürlüğünü bulmada verimli oluşundan ötürü, kafa derisindeki aktivasyonun yerel değişikliklerini topografik harita üzerinde belirlemek amacıyla Morlet dalgacık dönüşümü kullanılmıştır. Her sepet için hem beğeni hem beğenmeme durumunda ortak kanallar ve beyin lobları incelenmiştir. Sınıflandırma aşamasında, ürünler hakkında beğenme/ beğenmeme tercihini tahmin etmek için Uzun Kısa Süreli Bellek (UKSB) tabanlı derin öğrenme modeli kullanılmıştır. UKSB derin öğrenme modeli, ürünlere yönelik beğenme/beğenmeme tercihini tahmin ederken %92,36 sınıflandırma doğruluğu elde etmiştir [54].

Chakladar ve ekibi çalışmalarında 25' i erkek 15' i kadın 40 katılımcıdan oluşan Yadava veri setini kullanarak, derin transfer öğrenme, uzamsal dikkat modelleri ve derin sinir ağlarını birleştiren EEG tabanlı nöropazarlama modelini önermiştir. Tüketici tercihinin sınıflandırılmasına yönelik olarak önerilen nöropazarlama modeli, derin transfer öğrenmesi, uzamsal dikkat mekanizması ve iki boyutlu evrişimli sinir ağı (2D ESA) tabanlı bir derin öğrenme modelini içermektedir. Sinyal ön işleme aşamasında 1 ile 40 Hz arasında bir bant geçiren filtre uygulanmıştır. Sonrasında, BBA kullanılarak EEG'deki göz ve kalp artefaktları kaldırılmıştır. Özellik çıkarma aşamasında; görev sırasında altta yatan beyin desenlerini bulmak için yaygın olarak kullanılan bağlantısallık özellikler ve giriş özellik tanımlayıcılarından dikkat haritalarını hesaplamak için Konvolüsyonel Blok Dikkat Modülü mekanizması uygulanarak dikkat ağırlıklı bağlantısallık özellikler çıkarılmıştır. Ardından, Konvolüsyonel Blok Dikkat Modülü aracılığıyla uzamsal dikkat uygulanarak; dikkat ağırlıklı bağlantısallık özellikleri 2D ESA modeline aktarılmış ve tüketici tercihi bu yapı üzerinden değerlendirilerek sınıflandırılmıştır. Önerilen model, %95,60 sınıflandırma doğruluğu elde etmiştir [55].

Upadhyay ve ekibi çalışmasında tüketici tercihlerinin tahmin edilmesi amacıyla bir derin sinir ağı olan NMNet'i önermektedir. NMNet yöntemi ile ham EEG sinyallerini doğrudan işleyerek daha sadeleştirilmiş ve verimli bir çözüm önerisi sunulmaya çalışılmıştır. Ekip bu yöntem ile EEG sinyallerinden hem zamansal hem de uzamsal alanlarda özellikler çıkarmak için transformer tabanlı bir model kullanmıştır. Geliştirilen dönüştürücü tabanlı model, Zamansal dönüştürücü ve Uzamsal dönüştürücü olmak üzere iki ana bileşenden oluşmaktadır. Ham EEG sinyallerini işlemek için, her kanalın sinyallerini parçalara ayırarak Zamansal dönüştürücüden geçirip EEG sinyallerinin zaman alanı özellikleri çıkartılmıştır. Uzamsal dönüştürücü ile kanallar arasında uzamsal dikkat hesaplanarak, modelin farklı kanal sinyalleri arasındaki bağlantıları etkili bir şekilde yakalaması sağlanmıştır. Son olarak, tamamen bağlı katmanlar uygulanarak küresel bilgi birleştirilmiş ve tüketicilerin tercihleri tahmin edilmiştir. Çalışmanın sonucunda %92 sınıflandırma doğruluğu elde edilmiştir [56].

Ouzir ve ekibi 25 katılımcının EEG sinyallerini kullanarak sağ/sol beyin bölgelerinin e-ticaret ürünlerine yönelik tüketici tercihlerindeki önemini değerlendirmektedir. Sinyal ön işleme aşamasında, istenmeyen gürültüleri gidermek için S-Golay filtresi kullanılmıştır. Kaydedilen sinyallerden anlamlı özellikleri çıkarmak için ADD uygulanmıştır. Çalışmanın sınıflandırma aşamasında K-EYK, RO, YSA, Gradyan Artırma Algoritması (GAA) algoritmaları kullanılmıştır. En yüksek doğruluk oranları sağ paryetal bölgede YSA ile %69,28, GAA ile %69,00, K-EYK ile %67,08, RO ile %66,51 olarak gözlemlenmiştir [57].

Bu tez çalışmasında kullanılan veri setini kullanan literatürdeki çalışmalar ve kullandıkları ön işleme metotları, özellik çıkarma yöntemleri, sınıflandırıcı algoritmaları ve en yüksek doğruluk oranları Tablo 1.12' de verilmiştir.

Tablo 1.12. *Veri seti ile ilgili literatürdeki çalışmalar*

Yazar, Yıl	Katılımcılar	Ön İşleme	Özellik Çıkarma	Özellik Seçme	Sınıflandırıcı	Doğruluk (en yüksek)
Yadava ve Ekibi, 2017	25 erkek, 15 kadın, 40 Katılımcı	S-Golay	ADD	-	GMM	%70,33
Kumar ve Ekibi, 2018	25 erkek, 15 kadın, 40 Katılımcı	S-Golay	ADD, İstatistiksel Özellikler	-	RO	%71
Amin ve Ekibi, 2020	25 Erkek Katılımcı	Hareketli Ortalama	ADD	-	K-EYK, DA, NB, KA, DVM, RO	%95 (KA)
Aldayel ve Ekibi, 2021	25 Erkek Katılımcı	Bant geçiren, S-Golay, BBA, Ortalama	GSY, İstatistiksel Özellikler	-	DVM, RO, K-EYK	%83 (RF)
Ykhlef, 2021	25 Erkek Katılımcı	Bant geçiren, S-Golay, BBA	ADD, GSY	-	DSA, DVM, K-EYK, RF	%93 (RF, DNN)
Alimardini, 2021	25 Erkek Katılımcı	Bant geçiren	Spektral Enerji	-	ESA	%52
Panda, 2024	40 Katılımcı	Bant geçiren, BBA	Morlet Dalgacık Dönüşümü	-	LSTM	%92,36
Chakladar, 2024	40 Katılımcı	Bant geçiren	Bağılantısal Özellikler, KBDM	-	2D ESA	%95,60
Uadhyay, 2024	25 Erkek Katılımcı	-	-	-	NMNet	%92
Ouzir, 2024	25 Erkek Katılımcı	S-Golay	ADD	-	K-EYK, RO, YSA, GAA	%69,28 (YSA)

Bu tez çalışması kapsamında, açık erişimli bir veri seti kullanılarak tüketicilerin karar alma süreçleri EEG sinyal işleme yöntemleri ile analiz edilmiştir. Bu amaçla, bir EEG sinyal işleme prosedürü oluşturulmuş ve sinyal işleme prosedürünün her aşamasında kullanılan yöntemler literatüre atıf yapılarak açıklanmıştır. Literatür çalışmalarına ek olarak nöropazarlama stratejilerini bir adım daha öne taşımak amacıyla oluşturulan sinyal işleme prosedürünün hem yüksek performans hem de düşük sinyal işleme süresi ve

işleme modeli- optimizasyon modeli) sonuçları verilmiştir. 4. Bölümde ise elde edilen tüm sonuçlar tez çalışmasının literatüre katkısı ile birlikte değerlendirilmiş ve sunulmuştur. Ayrıca, ilerleyen çalışmalar için yapılabilecek gelişmelere değinilerek bu tez çalışmasının gelişmeye açık yönleri vurgulanmıştır.



İKİNCİ BÖLÜM

MATERYAL VE YÖNTEM

2.1. Veri Seti

Bu tez çalışmasında Yadava ve arkadaşları tarafından oluşturulmuş ve akademik araştırmalarda kullanılmak üzere kamuya açık olarak erişime sunulmuş bir veri seti kullanılmıştır. Veri setinde 18 ile 38 yaş arasındaki 25 erkek katılımcıdan elde edilen EEG kayıtları bulunmaktadır. EEG verileri kaydedilirken katılımcılar Şekil 2.1’ deki gibi çeşitli ürün görsellerini izlerken ve EEG sinyalleri 14 kanallı Emotiv Epoc+ cihazı kullanılarak kaydedilmiştir.

Şekil 2.1. Katılımcıların ürün görselini izlerken EEG kaydının alındığı sistem




Ürün görselleri Tablo 2.1’ de gösterildiği gibi gözlük, çanta, gömlek, kalem, ayakkabı gibi 14 farklı kategoriden oluşmuştur ve her kategoride üç farklı görsel bulunmaktadır.

Tablo 2.1. Katılımcılara gösterilen ürün görselleri

Ürünler	Çeşit 1	Çeşit 2	Çeşit 3	Ürünler	Çeşit 1	Çeşit 2	Çeşit 3
Gömlekler				Eldivenler			
Ayakkabılar				Güneş Gözlükleri			
Kravatlar				Kazaklar			
Okul Çantaları				Çoraplar			
Atkılar				Duvar Saatleri			
Kemerler				Kalemler			
Bileklikler				Kol Saatleri			

Her bir görsel, bilgisayar ekranında 4 saniye boyunca gösterilmiştir. Her bir katılımcıya toplamda birbirinden farklı 42 ürün görüntüsü gösterilerek her bir katılımcı için 42 EEG kaydı elde edilmiştir. Daha sonra katılımcılardan gösterilen her ürünle ilgili beğeni veya beğenmeme tercihlerini belirtmeleri istenmiştir. Her katılımcı, bir ürün görselini izlerken "beğenme" veya "beğenmeme" şeklinde geri bildirimde bulunmuş ve EEG verileri eş zamanlı olarak kaydedilmiştir. Kullanıcının tercih ettiği seçim, her resim sunumundan sonra belgelenmiştir. Sonuç olarak, toplam 1050 EEG sinyal kaydı üretilmiş ve bu kayıtlardan 1045'i kamuya açık olarak paylaşılmıştır. EEG sinyalleri 128 Hz örnekleme frekansında kaydedilmiştir. Katılımcıların EEG kayıtları alınırken kafa derisi üzerine EEG elektroları uluslararası 10-20 sistemine göre konumlandırılmıştır. EEG elektrotlarının kafa derisi üzerindeki yerleşimi ve ilgili aksesuarları Şekil 2.2' de gösterildiği gibidir. Burada kulaklar üzerinde bulunan Common Mode Sense (CMS) ve Driven Right Leg (DRL) elektrotları referans elektrotlardır.

Şekil 2.2. EEG elektrotlarının kafa derisi üzerindeki yerleşimi ve ilgili aksesuarlar



Veri seti, "AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 ve AF4" konumlarında bulunan 14 elektrottan elde edilen özellikleri içermektedir.

2.2. İşaret işleme

EEG sinyalleri kaydedilirken, kas aktivitesi, göz kırpması veya şebeke gürültüsü gibi sebeplerden ötürü çeşitli artefaktlar ortaya çıkmaktadır. EEG sinyallerini gürültüden arındırarak anlamlı bilgiler elde etmek için işaret ön işleme adımı çok önemlidir. İşaret ön işleme sayesinde beyinden gelen nöral aktivite doğru bir şekilde analiz edilir. Bu tez

çalışmasında uygulanan işaret ön işleme yöntemleri Bölüm 2.2.1.' de detaylı olarak anlatılmıştır.

2.2.1. Verilerin ön işlenmesi

Bu tez çalışması kapsamında kullanılan veri setinin elde edilmesinin ardından, veriler aşağıda detayları verilen filtreleme yöntemleri ile ön işleme aşamasından geçirilmiştir. Ardından, tez çalışması kapsamında kullanılacak gerekli kanal seçimi, frekans seçimi vb. ayrıştırılmalarla ön işleme aşaması tamamlanmış ve veriler özellik çıkarımı aşamasına hazır hale getirilmiştir.

2.2.1.1. Çentik Filtre

Bu tez çalışmasında; EEG sinyallerinin, gürültüden arındırılarak anlamlı verilerin elde edilmesi amacıyla öncelikle verilerin 50 Hz şebeke gürültüsünden arındırılması için çentik filtre uyguladık. Bu filtreler, farklı ülkelerde kullanılan güç hattı frekanslarına (50 Hz veya 60 Hz) bağlı olarak sistemdeki parazitleri azaltmak amacıyla tasarlanmaktadır. Çentik filtreler genlik yanıtında belirgin bir çentiğe sahip olan filtrelerdir. Böyle bir yanıt, birim çember üzerine karmaşık eşlenik bir sıfır çifti yerleştirilmesi ile elde edilebilir. Bu tür bir sistemin transfer fonksiyonu, Eşitlik 2.1 ile ifade edilir. [58], [59]

$$H(z) = \frac{1 - 2 \cos(\omega_0)z^{-1} + z^{-2}}{1 - 2R \cos(\omega_0)z^{-1} + R^2z^{-2}} \quad (2.1)$$

Çentik filtrelerin en önemli özellikleri merkez frekans, bant genişliği ve derinlik olarak sayılabilir. Merkez Frekans, filtrenin en yüksek zayıflamayı sağladığı frekansı ifade eder. Bant Genişliği, çentik filtresinin etkili olduğu frekans aralığıdır. Derinlik, belirli bir frekanstaki zayıflama derecesidir ve genellikle desibel (dB) cinsinden ifade edilir [60], [61].

2.2.1.2 Bant Geçiren Filtre

Bant geçiren filtreler, belirli bir frekans aralığındaki sinyallerin geçmesine izin verirken, bu aralığın dışındaki düşük ve yüksek frekanslı bileşenleri bastıran sinyal işleme araçlarıdır. Hem analog hem de dijital sistemlerde yaygın olarak kullanılmakta olan bant geçiren filtreler, biyomedikal sinyal işleme alanında sıkça kullanılan filtre çeşididir. EEG

gibi elektrofizyolojik sinyallerin analizinde, hareket artefaktları gibi istenmeyen düşük frekanslı ve elektriksel gürültü gibi yüksek frekanslı bileşenleri ortadan temizlemek amacıyla bant geçiren filtreler sıklıkla tercih edilmektedir. Bant geçiren filtre, alt kesim frekansı ve üst kesim frekansı olarak tanımlanan iki frekans noktası arasında kalan frekans bileşenlerini geçirirken, bu bandın dışında kalan frekansları bastırır. Örneğin, EEG verilerinde genellikle 1–50 Hz arasında yer alan sinyaller bilgi açısından anlamlı kabul edildiğinden, bu aralıkta çalışan bir bant geçiren filtre ile veri ön işleme gerçekleştirilir [62].

Bant geçiren filtre, nöropazarlama uygulamalarında EEG sinyallerinin ön işlenmesi aşamasında, istenmeyen frekans bileşenlerinin giderilmesi ve sinyal-gürültü oranının iyileştirilmesi amacıyla uygulanan temel bir sinyal işleme adımıdır.

2.2.1.3. Savitzky–Golay Filtresi

Savitzky- Golay filtresinin çalışması şu şekildedir; örnekleme yoluyla elde edilen $2m+1$ adet eşit aralıklı nokta $(-m, \dots, 0, \dots, +m)$, sıfır ortalamalı ölçüm gürültüsü ile bozulmuş p dereceli bir polinomun örnekleri olarak kabul edilir. S- Golay yöntemi, en küçük kareler polinomunun veya türevlerinin $i = 0$ noktasındaki değerini tahmin eder. Ardışık noktalar için tekrar tekrar yeni bir polinom uyarlamaya gerek yoktur; bu işlem sabit katsayılarla sahip bir evrişim uygulanarak otomatik olarak gerçekleştirilebilir. Bu sayede, örnekler üzerinde sürekli bir en küçük kareler polinom uyumu işlemi otomatik olarak gerçekleştirilmiş olur [63].

S- Golay filtresi, veri düzleştirme sürecinde doğrusal en küçük kareler yaklaşımını benimseyerek, yüksek bir sinyal-gürültü oranı elde edilmesine olanak tanırken, sinyalin özgün biçimini büyük ölçüde korur. Standart filtreleme yöntemlerine kıyasla sunduğu çeşitli avantajlar nedeniyle, S- Golay filtresi, gürültüden arındırılmış fakat yapısal bütünlüğü korunmuş sinyallerin elde edilmesinde tercih edilen etkili bir yöntemdir. Uygun pencere boyutu ve polinom derecesi seçildiğinde, S- Golay filtresinin performansı klasik filtrelerle kıyasla çok daha üstündür. Bu filtre özellikle biyomedikal sinyal işleme alanında gürültü giderme amacıyla yaygın olarak kullanılmaktadır [64].

2.2.2. Özellik Çıkarımı

Bu tez çalışması kapsamında; özellik çıkarımı aşamasında öncelikle Hjorth parametreleri kullanılmıştır. Daha sonra entropi tabanlı özellikler Tsallis Entropi, Shannon Entropi yöntemleri kullanılarak elde edilmiştir. Ardından, istatistiksel özellikler olan Ortalama, Varyans, Standart Sapma, Çarpıklık, Basıklık, Medyan, Pik Faktörü, Onuncu Zirveye Ulaşma Süresi hesaplanmıştır. Spektral tabanlı Ortalama Güç, Ortalama Bant Frekansı özelliklerinin hesaplanması aşamasında Welch yöntemi kullanılarak güç spektral yoğunluğu (GSY) tahmini yapılmıştır. Özellik çıkarım yöntemlerine ilişkin detaylı açıklamalar, Bölüm 2.2.2.1 ile 2.2.2.4 arasında yer alan alt başlıklarda, ayrıntılı biçimde açıklanmıştır.

2.2.2.1. Hjorth Parametreleri

Hjorth parametreleri, bir biyosinyalin zaman domenindeki özelliklerini yansıtan ve güç spektral yoğunluğunun istatistiksel momentlerine karşılık gelen ölçütlerdir; bu parametreler, sinyalin aktivite, hareketlilik ve karmaşıklık düzeylerini nicel olarak değerlendirmek amacıyla kullanılır [13], [65].

a. Hjorth Aktivitesi

Aktivite, bir zaman fonksiyonunun varyansını ve dolayısıyla sinyalin gücünü temsil eder. Aktivite, zaman domenindeki sinyal genliklerinin kare standart sapmasının bir ölçüsünü sağlar. Aynı zamanda frekans domeninde güç spektrumunun yüzey alanını da temsil edebilir[65]. Matematiksel ifadesi Eşitlik 2.2 ile gösterildiği gibidir.

$$Hjorth\ Aktivitesi = Var(x(t)) \quad (2.2)$$

b. Hjorth Mobilitesi

Mobilite parametresi, sinyalin türevinin varyansının karekökünün, sinyalin kendisinin varyansına oranı olarak tanımlanır. Bu oran, sinyalin ortalama frekansı veya güç spektrumunun standart sapmasıyla ilişkilidir [65]. Matematiksel ifadesi Eşitlik 2.3 ile gösterildiği gibidir.

$$Hjorth\ Mobilitesi = \sqrt{\frac{Var(\frac{dx(t)}{dt})}{Var(x(t))}} \quad (2.3)$$

c. Hjorth Kompleksitesi

Kompleksite, sinyalin bant genişliğini tahmin etmeye yarar ve sinyalin şekil bakımından saf bir sinüs dalgasına ne kadar benzediğini gösterir [65]. Matematiksel ifadesi Eşitlik 2.4 ile gösterildiği gibidir.

$$Hjorth\ Kompleksitesi = \frac{Mobilite(\frac{dx(t)}{dt})}{Mobilite(x(t))} \quad (2.4)$$

2.2.2.2. Entropi Özellikleri

Entropi, termodinamikte bir gaz veya sıvı sistemin durumu ile moleküllerin dağılım olasılığını tanımlamak için kullanılır. Kristal yapı gibi düzenli bir sistemde her molekül belirli bir konumda yer alır; dolayısıyla, moleküllerin hareket ve dağılım olasılığı sınırlıdır. Fakat sıvı hal gibi düzensiz bir sistemde moleküller daha serbest hareket eder ve olası konum sayısı artar. Bir kristalin erimesi esnasında sistemin düzensizliği arttığı için entropi de artar [66].

Entropi, rastgele bir sürecin belirsizlik düzeyini ölçmek için kullanılır ve bir sinyalin ne kadar öngörülemez olduğunu ifade eder. Arızasız çalışan döner elemanlı makineler genellikle daha rastgele sinyaller üretirken, arızalı makineler daha düzenli ve öngörülebilir sinyaller verir. EEG sinyallerinde ise entropinin, duyguların tespitinde etkili bir özellik olduğu düşünülmektedir [65].

Bu tez çalışmasında Tsallis Entropi, Shannon Entropi yöntemleri kullanılmıştır. Bir sonraki bölümde Tsallis Entropi ve Shannon Entropi hakkında detaylı bilgi verilmiştir.

a. Tsallis Entropi

Tsallis entropisi, klasik Boltzmann-Gibbs entropisinin genelleştirilmiş bir biçimidir ve özellikle karmaşık, uzun menzilli korelasyonların mevcut olduğu sistemlerin istatistiksel mekaniğinde kullanılır. 1988 yılında Constantino Tsallis tarafından önerilen bu entropi ölçüsü, sistemlerin genişleyebilir olmayan özelliklerini modellemek üzere geliştirilmiştir. Geleneksel Boltzmann-Gibbs entropisi, alt sistemlerin istatistiksel olarak bağımsız olduğu veya korelasyonların yerel olduğu durumlarda geçerlidir. Ancak biyolojik sistemler, özellikle beyin dinamikleri gibi karmaşık sistemlerde, korelasyonlar çok ölçekli ve uzun menzilli olabilmektedir. Bu bağlamda, Tsallis entropisi daha uygun bir model sunar [67]. Matematiksel ifadesi Eşitlik 2.5'deki gibidir.

$$S_q = k \frac{1 - \sum_i p_i^q}{q - 1}, q \in R \quad (2.5)$$

Burada; S_q , Tsallis entropisini, p_i , sistemin i ' inci durumu için olasılığı, q entropi indeksi olup, sistemin genişleyebilirliğini ve korelasyon özelliklerini kontrol eder, k ise genellikle Boltzmann sabiti olarak alınır.

$q=1$ limitinde Tsallis entropisi, klasik Shannon entropisine dönüşür ve Eşitlik 2.6 ile ifade edilir.

$$\lim_{q \rightarrow 1} S_q = -k \sum_i p_i \ln p_i \quad (2.6)$$

EEG sinyallerinin analizinde Tsallis entropisi, beyin elektriksel aktivitesinin karmaşıklığını ve düzensizliğini ölçmek için kullanılmaktadır. EEG sinyalleri hem zamansal hem de frekans alanlarında yüksek derecede karmaşık ve nonlineer özellikler taşır. Bu nedenle, klasik lineer analiz yöntemleri yetersiz kalabilir. Tsallis entropisi, beyin sinyallerindeki uzun menzilli korelasyonları ve kaotik dinamikleri yakalayarak, epilepsi teşhisi, uyku evrelerinin sınıflandırılması, bilişsel durumların değerlendirilmesi ve duygusal durumların tespiti gibi uygulamalarda etkin bir araç olarak kullanılmaktadır [68]. Sonuç olarak, Tsallis entropisi, EEG sinyallerinin çok boyutlu ve karmaşık yapısını

anlamada güçlü bir matematiksel araç olup, nörobilim ve klinik tanı alanlarında geniş uygulama potansiyeline sahiptir.

b. Shannon Entropi

EEG analizinde Shannon entropisi, sinyalde daha önce gözlemlenen genlik değerlerinin olasılık dağılımına dayanarak, gelecekteki genlik değerlerinin öngörülebilirliğini ölçen bir yöntemdir. Uyanık bireylerde EEG genliklerinin olasılık yoğunluk fonksiyonları, zaman içinde genellikle sabit bir yapı sergiler. Ancak anestezi ilaç konsantrasyonu arttıkça, EEG genliğinde belirgin bir artış gözlenir. Bu durum, genlik değerlerinin olasılık yoğunluk fonksiyonunun genişlemesine, yassılaşmasına ve çarpık bir dağılımdan daha düzgün bir dağılıma doğru değişmesine yol açar. Yapılan araştırmalar, artan anestezi ilaç konsantrasyonlarıyla birlikte EEG sinyalinin Shannon entropisinde de artış meydana geldiğini ortaya koymuştur. Bu doğrultuda, Shannon entropisi; anestezi ilaç etkisinin izlenmesinde basit, güvenilir ve sayısal bir EEG ölçütü olarak önerilmiştir [66].

Shannon Entropisi, rastgele bir değişkenin veya rastgele bir sinyalin öngörülemezliğini ölçen bir metriktir. Entropi değeri arttıkça, belirsizlik ve rastgelelik düzeyi de artar [65]. Matematiksel olarak Eşitlik 2.7 ile ifade edilir.

$$H(X) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (2.7)$$

2.2.2.3. İstatistiksel Özellikler

EEG sinyalleri gibi biyomedikal sinyallerin analizinde, temel istatistiksel özellikler sinyalin dağılımı, yayılımı, simetrisi ve uç değer davranışları hakkında bilgi sağlayarak özellik çıkarımında önemli rol oynar. Bu özellikler, sınıflandırma, kümeleme ve örüntü tanıma gibi makine öğrenimi yöntemleriyle birlikte kullanılarak zihinsel durumların ayrıştırılmasına katkıda bulunur [69].

Bu tez çalışmasında istatistiksel özellikler olarak Ortalama, Varyans, Standart Sapma, Çarpıklık, Basıklık, Medyan, Pik Faktörü, Onuncu Zirveye Ulaşma Süresi kullanılmıştır. Bir sonraki bölümde bu sekiz istatistiksel özellik hakkında bilgi verilmiştir.

a. Ortalama

Ortalama, bir veri kümesindeki tüm değerlerin toplamının veri sayısına bölünmesiyle elde edilen merkezi eğilim ölçüsüdür. Zaman serilerinde ve sinyal işleme uygulamalarında sinyalin genel seviyesini temsil eder. Matematiksel olarak Eşitlik 2.8 ile ifade edilir [70].

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2.8)$$

b. Varyans

Varyans, bir veri kümesindeki değerlerin, aritmetik ortalamaya göre ne ölçüde dağıldığını niceliksel olarak ifade eden temel bir istatistiksel ölçüttür. Veri setindeki saçılma derecesini dikkate alan başlıca olasılık dağılımı ölçülerinden biridir ve özellikle değişkenliğin analizinde önemli bir rol oynar [65]. Matematiksel olarak Eşitlik 2.9 ile ifade edilir.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (2.9)$$

c. Standart Sapma

Standart sapma, varyansın karekökü olarak tanımlanır ve bir veri kümesindeki gözlemlerin ortalama etrafındaki tipik uzaklığını belirtir. Gürültü analizi ve zaman serisi özellik çıkarımı gibi birçok alanda önemli bir parametredir [71]. Matematiksel olarak Eşitlik 2.10 ile ifade edilir.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.10)$$

d. Çarpıklık

Çarpıklık, bir dağılımın simetrikliğini değerlendiren bir ölçüttür. Eğer bir dağılımın sol ve sağ tarafları birbirinin aynası değilse, bu dağılım çarpık olarak kabul edilir [65]. Matematiksel olarak Eşitlik 2.11 ile ifade edilir.

$$\text{Çarpıklık} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^{3/2}} \quad (2.11)$$

e. Basıklık

Basıklık, bir EEG sinyalinin tepe yoğunluğunu ölçmek için kullanılan bir istatistiksel özelliktir. Sinyal normal dağılıma sahipse, basıklık değeri 3 olur. Eğer sinyal normal dağılmıyorsa, basıklık değeri daha sivri tepe için 3'ten büyük, daha basık tepe için 3'ten küçük değerler alır [65].

Basıklık matematiksel olarak Eşitlik 2.12' deki gibi ifade edilir.

$$\text{Basıklık} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^2} - 3 \quad (2.12)$$

f. Medyan

Medyan, sıralanmış veri kümesinin ortasındaki değerdir ve özellikle uç değerlerin etkisini azaltmak amacıyla kullanılır. Simetrik olmayan dağılımlarda merkezi eğilim ölçüsü olarak ortalamaya göre daha sağlamdır [72]. Veri sayısı tek ise medyan sıralanmış verilerin tam ortasındaki değerdir ve matematiksel olarak Eşitlik 2.13 ile ifade edilir.

$$\text{Medyan} = x_{\frac{N+1}{2}} \quad (2.13)$$

Veri sayısı çift ise medyan ortadaki iki değer aritmetik ortalaması alınarak bulunur. Matematiksel olarak Eşitlik 2.14 ile ifade edilir.

$$\text{Medyan} = \frac{x_{\frac{N}{2}} + x_{\frac{N}{2}+1}}{2} \quad (2.14)$$

h. Pik Faktörü

Pik faktörü, bir sinyalin maksimum genliğinin RMS (Root Mean Square) değerine oranıdır. Sinyalin ani değişimlere veya yüksek enerjili bileşenlere sahip olup olmadığını belirlemede kullanılır (Randall& Monitoring, 2011). Matematiksel olarak Eşitlik 2.15 ile ifade edilir.

$$Pik Faktörü = \frac{|x|_{maks}}{RMS} \quad (2.15)$$

ı. Onuncu Zirveye Ulaşma Süresi

Onuncu Zirveye Ulaşma Süresi (Rise Time), sinyalin genliğinin tepe değerinin %10'una ulaştıktan sonra, %90'ına ulaşması için geçen süreyi ifade eder. Zaman domeninde sistem cevabının geçici karakteristiklerini değerlendirmede kullanılır [74]. Matematiksel olarak Eşitlik 2.16 ile ifade edilir.

$$t_r = t_{90\%} - t_{10\%} \quad (2.16)$$

2.2.2.4. Güç Spektral Yoğunluğu (GSY)

Güç spektral yoğunluğu (GSY), bir işaretin frekans ekseninde gösterdiği güç dağılımının ölçüsüdür. Diğer bir ifadeyle, GSY, bir sinyalin frekans uzayında ne kadar enerji taşıdığını göstererek sinyalin spektral içeriğine dair bilgi sağlar. GSY bu özelliği sayesinde, biyomedikal sinyal işleme alanında EEG sinyallerinin analizinde oldukça önemlidir. GSY elde edilirken genel olarak üç kategoriye ayrılmış tahmin yaklaşımları vardır. Bunlar; periyodogram temelli Welch yöntemi gibi parametrik olmayan yöntemler, parametrik yöntemler ve yarı-parametrik yöntemlerdir [62].

GSY hesaplamaları, delta, teta, alfa, beta ve gama beyin dalgalarının güç düzeylerini analiz etmeye olanak tanıdığı için, EEG temelli nöropazarlama çalışmalarında bilişsel yük, dikkat, uyarılma gibi zihinsel durumların incelenmesinde sıklıkla tercih edilir [75].

Bu tez çalışmasında parametrik olmayan yöntemlerden biri olan Welch metodu kullanılmıştır. Bir sonra ki bölümde Welch metodu açıklanmıştır.

Welch Metodu

Welch yöntemi, GSY tahmini için kullanılan geliştirilmiş periyodogram temelli parametrik olmayan bir yöntemdir ve klasik periyodogram yöntemine göre daha kararlı sonuçlar verir. Welch yöntemi ile sinyal örtüşen parçalara ayrılarak, her bir parçaya pencereleme fonksiyonu uygulanır. Ardından her bir segmentin Fourier dönüşümüne dayalı olarak GSY'nin hesaplanması yapılır. Eşitlik 2.17' de Welch metodunun matematiksel gösterimi verilmiştir [76].

$$P^{\wedge}_{welch}(f) = \frac{1}{L} \sum_{i=0}^{L-1} S^{\wedge i}_{xx}(f) \quad (2.17)$$

Welch yöntemi, hem hesaplama açısından verimli olması hem de spektral çözünürlük ile varyans arasında dengeli bir sonuç sağlaması nedeniyle EEG analizlerinde sıklıkla tercih edilmektedir. Özellikle zamanla değişen nöral aktivitenin analizinde, Welch yöntemi kullanılarak elde edilen spektral ölçümler anlamlı çıkarımlar yapılmasını sağlar [77].

Bu tez çalışmasında Welch yöntemi kullanılarak GSY tahmini yapılmış ve Ortalama Güç, Ortalama Bant Frekansı spektral özellikleri çıkarılmıştır. Bir sonra ki bölümde Ortalama Güç ve Ortalama Bant Frekansı hakkında bilgi verilmiştir.

a. Ortalama Güç

Ortalama güç, bir sinyalin belirli bir frekans bandında taşıdığı toplam enerjinin o bandın genişliğine oranlanmasıyla elde edilir. GSY üzerinden hesaplanır ve belirli bir frekans aralığı için matematiksel olarak Eşitlik 2.18' de gösterildiği gibi ifade edilir. Bu ölçüm, sinyalin enerji içeriğini frekans bandı bazında değerlendirme imkanı sunduğu için, EEG bantlarında bilişsel ya da duygusal süreçlerle ilişkilendirilmiş güç değişimlerinin incelenmesini sağlar [62].

$$P_{avg} = \frac{1}{f_2 - f_1} \int_{f_1}^{f_2} P(f) df \quad (2.18)$$

b. Ortalama Bant Frekansı

Ortalama Bant Frekansı, sinyalin güç yoğunluğunun spektrum boyunca nasıl dağıldığını gösteren ve bir çeşit "ağırlıklı ortalama" gibi davranan bir özelliktir. Bu değer, toplam güç dikkate alınarak GSY' nin frekansa göre ağırlıklandırılmasıyla elde edilir ve matematiksel olarak Eşitlik 2.19' daki gibi ifade edilir.

$$f_{mean} = \frac{\int_{f_1}^{f_2} f \cdot P(f) df}{\int_{f_1}^{f_2} P(f) df} \quad (2.19)$$

Ortalama Bant Frekansı, özellikle EEG spektrumunun enerji yoğunluğunun hangi frekanslarda toplandığını belirlemek için önemlidir ve dikkat, uyanıklık veya zihinsel yük gibi durumları izlemek amacıyla kullanılabilir [18], [75].

2.2.3. Sınıflandırma

Elde edilen özellik matrisleri farklı matematiksel ve istatistiksel temeller üzerine inşa edilmiş sınıflandırıcılar ile sınıflandırılarak verilerin hangi sınıf etiketine sahip oldukları belirlenir. Bu amaçla, bu tez çalışmasında kullanılan sınıflandırma metotları aşağıda verilmiştir.

2.2.3.1. Destek Vektör Makinesi (DVM)

DVM, sınıflandırma problemlerinde verileri ayıran en geniş aralığa sahip hiper düzlemi bulmaya çalışır. Veri seti doğrusal olarak ayrılamıyorsa, kernel tekniklerini kullanılarak veri daha yüksek boyutlu bir uzaya taşınıp doğrusal olarak ayrıştırılabilir. DVM' nin en önemli avantajı, özellikle küçük ve orta ölçekli veri setlerinde yüksek doğruluk sağlamasıdır. Dezavantajı ise büyük veri setlerinde eğitim süresinin artması ve parametre ayarlama gerekliliğidir. EEG'de, özellikle motor imgeleme ve epileptik atak tespiti gibi görevlerde yüksek performans sunar [78].

2.2.3.2. Naive Bayes (NB)

Naive Bayes sınıflandırıcı algoritması, Bayes teoremine dayanan basit ve etkili olasılıksal bir sınıflandırma yöntemidir. Bu yöntem, önceden sınıflandırılmış veri örneklerini kullanarak, yeni bir verinin mevcut sınıflardan herhangi birine ait olma olasılığını hesaplamaya dayanır. NB sınıflandırıcısında, niteliklerin birbirinden bağımsız olduğu varsayılır; yani bir özelliğin değeri, diğer özelliklerin değerleri hakkında bilgi taşımaz.

Ayrıca, tüm örneklerin sınıflandırma sürecinde eşit derecede önemli olduğu kabul edilir [79].

2.2.3.3. K-En Yakın Komşu Algoritması (K-EYK)

KEYK algoritması, sınıflandırılması gereken örneğin etrafındaki en yakın k komşunun sınıf etiketlerine bakarak karar verir. Bu algoritmanın temel avantajı, hiçbir varsayım yapmadan çalışması ve model eğitimi gerektirmemesidir; bu nedenle "tembel öğrenme" olarak da adlandırılır. Ancak büyük veri setlerinde mesafe hesaplarının artması nedeniyle performans sonuçları çok iyi olmayabilir. EEG verilerinde değişken ve heterojen yapıya sahip olduğu için bazen tercih edilir, örneğin bilişsel durum sınıflandırmalarında kullanılmıştır [80].

2.2.3.4. Rastgele Orman (RO)

Rastgele Orman, çok sayıda karar ağacından oluşan bir topluluk öğrenme yöntemidir. Her bir karar ağacı, eğitim verisinin rastgele alt örnekleri ve rastgele seçilen özellik alt kümeleri kullanılarak oluşturulur. Bu sayede, ağaçlar arasında çeşitlilik sağlanır ve genel modelin aşırı öğrenme yapması önlenir. Sınıflandırma için, tüm ağaçların oy çokluğuna göre karar verilir. RO' nun başlıca avantajları; yüksek doğruluk, parametre ayarının görece kolay olması ve değişken önemi ölçümleri sunabilmesidir. Dezavantajı ise çok büyük veri setlerinde eğitim süresinin artabilmesidir [81].

EEG sinyal analizinde RO, özellikle epileptik atak tespiti, uyku evrelerinin sınıflandırılması ve duygu durum analizlerinde etkin şekilde kullanılmıştır. EEG verisinin gürültülü ve karmaşık doğası nedeniyle, RO' nun sağlam yapısı başarıyı artırmaktadır.

2.2.3.5. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beyninin öğrenme, yeni bilgiler türetme ve keşfetme gibi yeteneklerini taklit ederek, herhangi bir dış yardım almadan otomatik olarak bu süreçleri gerçekleştirebilen bilgisayar sistemleridir. Geleneksel programlama yöntemleri ile bu tür yeteneklerin modellenmesi oldukça zordur. Bu nedenle, yapay sinir ağları, programlanması zor veya mümkün olmayan problemlerin çözümünde kullanılan, bilgisayar tabanlı ve adaptif bir bilim dalı olarak tanımlanabilir.

Yapay sinir ağları, biyolojik sinir hücrelerinden esinlenerek geliştirilmiş makine öğrenmesi modelleridir. İlk yapay sinir ağı modelleri, algılayıcı adı verilen ve beyin sinir

hücrelerine benzer bir yapıya sahip modellerdir. Daha sonraki gelişmelerde ortaya çıkan modeller de temelde bu yapıyı referans alır.

Denetimli öğrenme yaklaşımı kapsamında, öncelikle eğitim için kullanılacak veri kümesi belirlenir ve yapay sinir ağına uygulanır. Ağ öğrenme sürecine başladığında, öğrenme oranı, hata oranı gibi parametreler çeşitli kontrol mekanizmalarıyla izlenir ve belirlenen kriterlere ulaşıldığında işlem tamamlanır. Bu kontrol mekanizmaları; iterasyon sayısı, öğrenme oranı ve hata eşik değeri gibi parametrelerden oluşur. İterasyon sayısı, ileri beslemeli algoritmanın mevcut veri kümesi üzerinde kaç kez çalıştırılacağını belirler.

Eğitim tamamlandıktan sonra, yapay sinir ağı eğitim sırasında karşılaşmadığı yeni örnekler için de doğru tepkiyi verebilir. Eğitilmiş bir ağ, giriş verisinin tamamı yerine sadece bir kısmı kendisine verilse bile, hafızasındaki en yakın örneği bularak tam bir giriş verilmiş gibi işlem yapar ve buna uygun bir çıktı üretir. Eksik, bozuk ya da daha önce hiç karşılaşılmamış veri girildiğinde bile ağ, kabul edilebilir en uygun çıktıyı üretebilir. Bu yetenek, yapay sinir ağlarının genelleştirme özelliği olarak adlandırılır [82].

YSA, karmaşık örüntüleri tanıma ve öğrenme yeteneği sayesinde, EEG verileri üzerinde oldukça başarılı sonuçlar veren denetimli bir öğrenme yöntemidir. EEG sinyallerinin çok boyutlu ve gürültülü yapısı, YSA' nın yüksek boyutlu verileri işleyebilme kapasitesi ile kolaylıkla ve ideal şekilde analiz edilebilir.

2.2.4. Sınıflandırma Performansı Değerlendirme Ölçütleri

Bu tez çalışması kapsamında önerilen yöntemin başarısını değerlendirmek amacıyla çeşitli performans metrikleri kullanılmıştır. Bu performans metriklerinden Doğruluk, Alıcı İşletim Karakteristiği Altındaki Alan (AUC), Kesinlik, Duyarlılık, F1 skoru modelin sınıflandırma başarımını çok yönlü olarak analiz etmek için tercih edilmiştir. Bu performans metrikleri ile modelin hem pozitif hem de negatif sınıfları ayırt etme yeteneğini değerlendirmekte ve genel dengeleme performansını ortaya koymaktadır. Performans metrikleri hesaplanırken aşırı öğrenme durumunu engellemek için 10 kat çapraz doğrulama tekniği uygulanmıştır. Bu yöntem, her iterasyonda bir alt kümenin test verisi olarak ayrılması ve kalan dokuz alt kümenin modelin eğitimi için kullanılması esasına dayanır.

Buna ek olarak, zaman maliyeti (hesaplama süresi) de önemli bir değerlendirme kriteri olarak dikkate alınmıştır. Zaman maliyeti, algoritmanın işlem verimliliğini ve gerçek zamanlı uygulamalara uygunluğunu ölçmek açısından kritik bir parametredir. Bu bağlamda, önerilen yöntemin sadece doğruluk açısından değil, aynı zamanda hesaplama süresi bakımından da optimize edildiği gözlemlenmiştir. Zaman maliyeti, önerilen yaklaşımın gerçek zamanlı uygulamalarda kullanılabilirliğini doğrudan etkileyen bir faktör olarak ele alınmıştır. Bu tez çalışması kapsamında eğitim ve test sürelerinin hesaplanması için tüm sinyal işleme ve sınıflandırma prosedürü, Intel Core i5-10500 3.10 GHz işlemciye, 8 GB RAM'e sahip, 64 bit Windows 11 Pro (sürüm 24H2) işletim sistemli aynı bilgisayarda gerçekleştirilmiştir.

Sınıflandırma performansını ölçmek amacıyla kullanılan metrikler, sınıflandırıcının karmaşıklık matrisi aracılığı ile hesaplanır. İkili sınıflandırma için (Örn. Beğendi-Beğenmedi) Karmaşıklık matrisi Tablo 2.2' de verilmiştir. Burada: TP: Gerçek pozitif (True Positive), TN: Gerçek negatif (True Negative), FP Yanlış pozitif (False Positive) FN: Yanlış negatif (False Negative) olmak üzere:

Tablo 2.2. Karmaşıklık matrisi

		Tahmin	
		Beğendi	Beğenmedi
Gerçek	Beğendi	TP	FP
	Beğenmedi	FN	TN

2.2.4.1. Doğruluk

Doğruluk, sınıflandırma problemlerinde modelin doğru tahmin ettiği örneklerin tüm örnekler içerisindeki oranını ifade eder. Genellikle dengeli veri setlerinde performans ölçütü olarak tercih edilir [83]. Doğruluk matematiksel olarak Eşitlik 2.20 ile ifade edilir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.20)$$

2.2.4.2. Alıcı İşletim Karakteristiği (Receiver Operating Characteristic Curve, ROC Eğrisi) ve Alıcı İşletim Karakteristiği Altındaki Alan (Area Under the Receiver Operating Characteristic Curve, AUC)

ROC eğrisi, duyarlılığın (TPR) 1- özgülüğe (FPR) karşı çizildiği grafiksel bir araçtır. AUC değeri ise bu eğrinin altında kalan alanı temsil eder ve modelin genel ayırt ediciliğini ölçer. AUC değeri 1'e yaklaştıkça modelin performansı artar [83]. ROC eğrisi değeri y eksenini için Eşitlik 2.24

$$\text{Doğru Pozitif Oranı (TPR)} = \frac{TP}{TP + FN} \quad (2.24)$$

x eksenini için ise Eşitlik 2.25 ile hesaplanabilir.

$$\text{Yanlış Pozitif Oranı (FPR)} = \frac{FP}{FP + TN} \quad (2.25)$$

AUC skoru Eşitlik 2.26' da gösterildiği gibi TPR değerinin integrali alınarak hesaplanabilir.

$$AUC = \int_0^1 TPR(x) dx \quad (2.26)$$

2.2.4.3. Kesinlik

Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Özellikle yanlış pozitiflerin önemli olduğu durumlarda değerlendirme için kullanılır [84]. Kesinlik, matematiksel olarak Eşitlik 2.21 ile ifade edilir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2.21)$$

2.2.4.4. Duyarlılık

Duyarlılık, modelin pozitif sınıfı doğru olarak ne oranda tanıdığını gösterir. Genellikle yanlış negatiflerin kritik olduğu sağlık, güvenlik gibi alanlarda tercih edilir [84]. Duyarlılık matematiksel olarak Eşitlik 2.22 ile ifade edilir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (2.22)$$

2.2.4.5. F1 Skoru

F1 skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır. Bu metrik, sınıflar arasında dengesizlik olduğu durumlarda daha dengeli bir performans değerlendirmesi sunar [83]. F1 Skoru matematiksel olarak Eşitlik 2.23 ile ifade edilir.

$$F1 \text{ Skoru} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (2.23)$$

2.2.4.6. Zaman Maliyeti

Zaman maliyeti, bir modelin eğitim ve tahmin işlemlerini gerçekleştirmesi için geçen süredir. Genellikle saniye, milisaniye ya da işlem döngüsü cinsinden ölçülür. Gerçek zamanlı sistemlerde ve büyük veri uygulamalarında önemli bir değerlendirme kriteridir (Domingos, 2012). Zaman maliyeti doğrudan bir formül ile hesaplanmaz; eğitim süresi için Eşitlik 2.27 kullanılarak hesaplama yapılabilir.

$$T_{\text{eğitim}} = \text{Toplam süre (model . fit (X,y))} \quad (2.27)$$

Tahmin süresi ise Eşitlik 2.28 kullanılarak hesaplanabilir.

$$T_{\text{tahmin}} = \text{Toplam süre (model . predict (X))} \quad (2.28)$$

2.3. İşaret İşleme Yönteminin Optimizasyonu

İşaret işleme sürecinde kullanılan filtreleme, özellik çıkarımı ve dönüşüm adımlarının uygun parametrelerle yapılandırılması, analiz sonuçlarının doğruluğu açısından kritik bir öneme sahiptir. EEG gibi karmaşık ve gürültülü işaretlerde, geleneksel yöntemlerle belirlenen sabit parametreler her zaman en iyi sonucu verememektedir. Geleneksel yaklaşımlar sabit parametrelerle sınırlı kalırken, bu çalışmada ele alınan optimizasyon teknikleri, adaptif ve veri odaklı bir yaklaşım sunarak sinyal işleme performansını artırmayı hedeflemektedir. Bu kapsamda, genetik algoritmalar, işaret işleme yöntemlerinin optimizasyonunda sıkça başvurulan sezgisel bir yöntemdir. Bir sonraki bölümde genetik algoritmalar hakkında bilgi verilmektedir.

2.3.1 Genetik Algoritma

Genetik Algoritma (GA) ilk defa Holland tarafından 1975' te kullanılmıştır ve canlı sistemlerdeki genetik şifre mantığı kullanılarak sezgisel olarak en iyi çözümü veya en iyi çözüme yakın olabilecek bir sonuç bulmayı hedefler. Bu mantık doğal seçim yani güçlü bireyin hayatta kalma olasılığının yüksek olmasıdır. Bu yöntemle evrim sonucu hayatta kalan birey en iyi sonuç olarak alınır. GA, canlı sistemlerdeki genetik şifre mantığı kullanılarak sezgisel olarak en iyi çözüm veya en iyi çözüme yakın olabilecek bir sonuç bulmayı hedefler. Bu mantık, doğal seçime yani güçlü bireyin hayatta kalma olasılığının yüksek olmasına dayanır. Bu yöntemle evrim sonucu hayatta kalan birey en iyi sonuç olarak alınır. GA sezgisel bir yöntemdir [86].

GA' lar, doğal seçim ve kalıtım ilkelerine dayanan arama tabanlı hesaplama yöntemleridir. GA' lar, Evrimsel Hesaplama olarak adlandırılan daha geniş bir hesaplama paradigmasının alt dalını oluşturmaktadır. Bu algoritmalar, belirli bir problem kapsamında geniş ve çeşitli çözüm kümeleri oluşturarak optimal veya optimal çözüme yakın sonuçlara ulaşmayı amaçlar.

Elde edilen çözümler, biyolojik genetik süreçlere benzer şekilde, rekombinasyon (çaprazlama) ve mutasyon işlemlerine tabi tutularak yeni bireylerin oluşmasını sağlar. Bu süreç, nesiller boyunca tekrar edilerek daha iyi çözümlerin evrimleşmesine katkıda bulunur. Her birey, belirlenen amaç fonksiyonunun değeri temelinde özgün bir uygunluk değeri ile değerlendirilir. Daha yüksek uygunluk değerine sahip bireyler, sonraki nesillerde daha avantajlı bireylerin üretilmesine olanak tanıyacak şekilde seçilir. Böylece, her nesilde daha başarılı çözümler elde edilerek süreç, önceden belirlenen durma kriterine ulaşıncaya kadar devam eder.

Genetik algoritmalar, büyük ölçüde olasılıksal kriterlere dayanmaktadır. Bununla birlikte, rastgele çözümler üreten ve optimal sonuçları belirlemede yetersiz kalan yerel rastgele arama yöntemlerine kıyasla daha etkin çalışırlar. Bunun nedeni, geçmiş çözüm verilerinin süreç içerisinde değerlendirilmesi ve algoritmanın dinamik bir biçimde kendini geliştirebilmesidir. Genetik algoritmaların temel işlemleri Seçim (Selection), Çaprazlama (Crossover), Mutasyon (Mutation) olarak sıralanır. Bu işlemler şu şekilde açıklanır:

- Seçim (Selection): Bireyler arasından daha yüksek uygunluk değerine sahip olanların bir sonraki nesilde yer alma olasılığını artıran bir süreç olarak tanımlanabilir.


- Çaprazlama (Crossover): Seçilen bireylerin yeni bireyler üretmesini sağlamak için bu bireylerin genetik bilgilerinin değiş tokuş edilmesini sağlayan mekanizma olarak tanımlanabilir.
- Mutasyon (Mutation): Çeşitliliği korumak ve yerel maksimumlara takılmayı önlemek amacıyla bireylerin genetik yapılarında küçük değişiklikler yapılmasını içeren işlem olarak tanımlanabilir [87], [88].

GA'nın işleyişi Şekil 2.4' de verilen akış diagramı ile gösterilmektedir. Bu akış diagramı Genetik Kodlama adımı ile başlar. Bunu takip eden adımlar Amacın Tanımlanması, Başlangıç Popülasyonunun Yaratılması, Uygunluğun Hesaplanması, Yeniden Üreme (Seleksiyon), Çaprazlama, Dönüşüm şeklinde devam eder. Dönüşüm adımından sonra bitiş kriterine ulaşılmış olma durumu sorgulanır ve eğer bitiş kriterine ulaşılmış ise En İyi Sonuç gösterilir. Şayet bitiş kriterine ulaşılamamış ise uygunluğun hesaplanması adımına dönülerek işlem adımları tekrarlanır.

Genetik algoritmanın birçok avantajı vardır, bu avantajları aşağıdaki gibi sıralayabiliriz.

- Gerçek dünya problemlerinin çoğunda bulunmayan taklitçi bilgilere ihtiyaç duymaz.
- İlkel yöntemlere kıyasla daha kapsamlı ve optimum çözümler sunar.
- İyi yapılandırılmış ve uyumlu yeteneklere sahiptir.
- Sürekli ve ayrık fonksiyonları iyileştirme kapasitesine sahip olup, çok amaçlı problemlere uygulanabilir.
- Tek bir çözüm yerine en iyi çözümleri sunmayı hedefler.
- Zamanla gelişen ve tatmin edici sonuçlar üreten çözümler sunar.
- Geniş arama uzayına ve çok sayıda parametreye sahip problemlerde en iyi performansı gösterir.

Şekil 2.3. GA işlem adımları akış diagramı [89]



Eğer bir optimizasyon probleminde birden fazla amaç fonksiyonu dikkate alınıyorsa, bu tür problemler çok amaçlı optimizasyon problemleri olarak adlandırılır. Bu problemlerin çözümünde ise Çok Amaçlı Genetik Algoritmalar (ÇAGA) yaygın olarak kullanılmaktadır. Literatürde bu alana yönelik çeşitli ÇAGA yöntemleri geliştirilmiş olup, yeni yaklaşımların önerilmesine yönelik çalışmalar günümüzde de devam etmektedir [90]. Bu tez çalışması kapsamında çok amaçlı genetik algoritma kullanılmıştır.

2.3.2. Çok Amaçlı Genetik Algoritmalar (ÇAGA)

Çok Amaçlı Genetik Algoritmalar (ÇAGA), evrimsel hesaplama yöntemlerinin bir uzantısı olarak geliştirilmiştir. Aynı anda birden fazla ve çoğunlukla birbirleriyle çelişen amaç fonksiyonunu optimize etmeye yönelik algoritmalarlardır. Geleneksel genetik algoritmalar yalnızca tek bir uygunluk (fitness) fonksiyonuna odaklanırken, ÇAGA

yaklaşımı, karar vericilere Pareto optimal çözümler kümesi sunar ve çoklu amaçlar arasında denge kurulmasını hedefler.

ÇAGA' nın temel çalışma prensibi, çözüm adaylarının seçim, çaprazlama, mutasyon evrimsel süreçleri aracılığıyla geliştirilmesi üzerine kuruludur. Ancak, klasik genetik algoritmalarından farklı olarak, uygunluk değerlendirmesi sırasında çok amaçlı değerlendirme yapılır. Murata ve Ishibuchi (1995) tarafından geliştirilen ÇAGA çerçevesinde, amaç fonksiyonları belirli bir ağırlıklandırma ile birleştirilir ve her bireyin uygunluk değeri bu ağırlıklı toplam üzerinden hesaplanır. Bu ağırlıklar her seçim işleminde rastgele belirlenerek, algoritmanın çözüm uzayının farklı bölgelerini keşfetmesine olanak tanır. Bu sayede, çözüm popülasyonu içerisinde çeşitlilik korunur ve yalnızca belirli bir yönelim yerine çok boyutlu optimizasyon gerçekleştirilir.

ÇAGA' nın bir diğer ayırt edici özelliği elit koruma stratejisidir. Bu strateji ile her nesilde elde edilen baskın olmayan çözümlerden oluşan geçici bir Pareto optimal çözüm kümesi oluşturulur. Bu kümeden seçilen bireyler, elit çözümler olarak bir sonraki nesle doğrudan aktarılır. Bu yöntem, algoritmanın zamanla iyileşen ve çeşitlilik içeren bir çözüm kümesi üretmesini garanti altına alır.

ÇAGA, çok amaçlı optimizasyon gerektiren problemler için etkili, esnek ve güçlü bir çözümleme aracı sunmakta; Pareto optimalite ilkeleri doğrultusunda karar vericilere geniş bir çözüm havuzu sağlayarak çok kriterli karar destek sistemlerinde yaygın biçimde kullanılmaktadır [91], [92].

Bu çalışmada farklı beyin lobu, EEG frekansı ve özellik matrisi kombinasyonları için sınıflandırma performans metriklerinin optimizasyonu amacıyla ÇAGA kullanılmıştır. ÇAGA ile pareto optimal çözümler kümesi elde edilmiş ve bu değerler TOPSIS metodu ile tek bir optimal sonuca indirgenmiştir.

2.3.3. İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS)

İlk olarak Yoon ve Hwang tarafından ortaya koyulan TOPSIS, çok kriterli karar verme yöntemlerinden biridir. TOPSIS yöntemi, geometrik bakış açısıyla, seçilecek alternatifin pozitif ideal çözüme en kısa mesafede ve negatif ideal çözüme en uzak mesafede olması gerektiği ilkesine dayanır. Bu yöntemde, Öklid mesafesi kullanılarak bir alternatifin optimal çözüme olan yakınlığı tespit edilir. Her bir özelliğe ait elde edilebilecek en iyi değerlerin toplamı pozitif ideal çözümdür. Negatif ideal çözüm ise her bir özellik için

elde edilen en kötü değerlerden oluşur. TOPSIS yöntemi, bir alternatifin hem pozitif ideal çözüme hem de negatif ideal çözüme olan mesafesini dikkate alır. Bağlı uzaklıkların karşılaştırılmasına dayanarak, alternatifler arasında öncelik sıralaması belirlenebilir. Bu yöntem, karar verme süreçlerinde yaygın olarak kullanılmaktadır. TOPSIS yöntemi, basit yapısı, kolay anlaşılabilir olması, hesaplama açısından verimliliği ve alternatiflerin bağlı performansını ölçme kabiliyeti nedeniyle sıkça tercih edilmektedir [93]. TOPSIS yönteminin işlem adımları aşağıdaki gibidir.

TOPSIS yöntemi, bir karar matrisi oluşturularak başlar. Karar matrisi oluşturulurken satırlara alternatifler sütunlara ise kritereler yerleştirilir.

$$A_{ij} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \quad (2.29)$$

İkinci işlem adımı karar matrisinin normalize edilmesidir.

$$n_{ij} = \frac{a_{ij}}{\sqrt{\sum_{i=1}^m a_{ij}^2}} \quad (i = 1, \dots, m \text{ ve } j = 1, \dots, p) \quad (2.30)$$

Eşitlik 2.30' da yer alan a_{ij} , matrisi oluşturmakta olan her bir elemanı göstermektedir. n_{ij} ise karar matrisindeki değerlerin her birinin karelerinin alınarak oluşturulduğu sütun toplamının kareköküne bölünmesi ile bulunmaktadır. Bu işlem ile Eşitlik 2.31' de verilen normalize edilmiş N matrisi bulunur.

$$N = \begin{bmatrix} n_{11} & n_{12} & \dots & n_{1p} \\ n_{21} & n_{22} & \dots & n_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ n_{m1} & n_{m2} & \dots & n_{mp} \end{bmatrix} \quad (2.31)$$

Üçüncü adımda normalize edilmiş olan matrisin her bir sütununa ait olan değerlerinin, sütunlar için belirlenen ağırlık değerleri ile çarpılması sonucu Eşitlik 2.32' de verilen V ağırlıklandırılmış normalize matrisi elde edilmektedir.

$$N = \begin{bmatrix} w_1 n_{11} & w_2 n_{12} & \dots & w_n n_{1p} \\ w_1 n_{21} & w_2 n_{22} & \dots & w_n n_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ w_1 n_{m1} & w_2 n_{m2} & \dots & w_n n_{mp} \end{bmatrix} = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1p} \\ v_{21} & v_{22} & \dots & v_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ v_{m1} & v_{m2} & \dots & v_{mp} \end{bmatrix} \quad (2.32)$$

Dördüncü aşamada pozitif ve negatif ideal çözüm belirlenir. Pozitif ideal çözüm değerleri Eşitlik 2.33 ile bulunur,

$$A^* = \{ \max_j v_{ij} \mid j = 1, \dots, p; i = 1, \dots, m \} \quad (2.33)$$

negatif ideal çözüm değerleri Eşitlik 2.34 ile ifade edilir.

$$A^- = \{ \min_j v_{ij} \text{ olmak üzere} \} \quad (2.34)$$

Beşinci aşamada alternatiflerin pozitif ideal çözüme ve negatif ideal çözüme uzaklıklarının belirlenmesinde Eşitlik 2.35 ve Eşitlik 2.36' da verilen Öklid uzaklık formülü kullanılır.

$$S_i^* = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^*)^2} \quad (2.35)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad (2.36)$$


Altıncı adımda her alternatifin ideal çözüme yakınlık düzeyi Eşitlik 2.37 ile ölçülür.

$$C_i^* = \frac{S_i^-}{S_i^- + S_i^*} \quad (2.37)$$

Bu tez çalışması kapsamında, Şekil 2.4'te akış şeması verilen optimizasyon süreci uygulanmıştır. DVM sınıflandırıcı ile 125 özellik matrisi kullanılarak elde edilen sınıflandırma performans metriklerinden ÇAGA ile Doğruluk, Kesinlik, Duyarlılık, F1 skoru, AUC değerlerini en yüksek, zamanlama maliyeti değerlerini en düşük seçecek pareto optimal çözümler elde edilmiştir. Bu pareto optimal çözümler arasından her

performans metriği için belirlenen ağırlık katsayılarına göre, tek çözüm ise TOPSIS metodu ile belirlenmiştir.

Şekil 2.4. Tez çalışması kapsamında oluşturulan optimizasyon sürecine ait akış şeması



ÜÇÜNCÜ BÖLÜM

BULGULAR

Bu tez çalışması iki ana aşamada tamamlanmıştır. İlk aşamada belirlenen sinyal işleme prosedürüne göre özellik matrisleri oluşturulmuş ve farklı sınıflandırıcılar ile sınıflandırılarak; sınıflandırma performansları ve zamanlama maliyeti parametreleri hesap edilmiştir. İkinci aşamada ise bu özellik matrisi kombinasyonlarından sınıflandırma performans parametreleri yüksek, zamanlama maliyetlerini düşük seçecek optimum özellik matrisi belirlenmiştir. Buna göre elde edilen bulgular da iki ana başlık altında aşağıda verilmiştir.

3.1. Sinyal işleme modeli sınıflandırma sonuçları

Kurulan model için oluşturulan her bir modelin beyin lobu, EEG frekans bandı ve hesaplanan özellikler Tablo 3.1’ de verilmiştir. Buna göre EEG sinyallerinden frontal, temporal, paryetal, oksipital ve tüm loblar olmak üzere 5 farklı beyin lobu; delta, teta, alfa, beta, gama olmak üzere 5 farklı EEG frekans bandı ve hjorth özellikleri, entropi özellikleri, istatistiksel özellikler, spektral özellikler ve tüm bu özellikler olmak üzere 5 farklı özellik matrisi belirlenmiştir.

Tablo 3.1. *Sinyal işleme modeli*

Beyin Lobu	Frekans bandı	Özellik
Hepsi	Delta	Hepsi
Frontal Lob	Teta	Hjorth
Temporal Lob	Alfa	Özellikleri
Paryetal Lob	Beta	Entropi
Oksipital Lob	Gama	Özellikler

Toplam 125 özellik matrisi kombinasyonu için DVM, RO, K-EYK, NB, ve YSA sınıflandırıcı algoritmaları ile yapılan sınıflandırma sonunda elde edilen doğruluk, AUC,

kesinlik, duyarlılık, F1 skoru, eğitim süresi maliyeti, test süresi maliyeti değerleri hesaplanmıştır. Bu hesaplamalar yapılırken K-EYK sınıflandırıcı algoritması için en yakın 5 komşu seçilmiştir. Ayrıca YSA sınıflandırıcı algoritması için giriş gizli ve çıkış katman olmak üzere 3 katman kullanılmıştır, katmandaki nöron sayısı 10 olarak belirlenmiştir. Gösterim kolaylığı ve anlaşılabilirliği sağlamak için her bir özellik matrisi kombinasyonu Tablo 3.2’ de gösterildiği gibi numaralandırılmış ve bu tez çalışmasının geri kalanında bu numaralar ile temsil edilmiştir. Elde edilen sonuçlar her bir sınıflandırıcı için sırayla Tablo 3.3, Tablo 3.4, Tablo 3.5, Tablo 3.6, Tablo 3.7’ de gösterilmiştir. Tüm indisler için DVM, RF, ANN, KNN, NB sınıflandırma algoritmaları ile elde edilen doğruluk, AUC, kesinlik, duyarlılık, F1 skoru, eğitim süresi maliyeti, test süresi maliyeti performans parametrelerinin sonuçları sırasıyla Şekil 3.1– Şekil 3.35’ te gösterilmiştir.

Buna göre DVM sınıflandırıcı için en yüksek doğruluk 0,8804, en yüksek AUC 0,8842, en yüksek kesinlik 0,9120, en yüksek duyarlılık 0,8641, en yüksek F1 skoru 0,8874, en düşük eğitim süresi 0,0104 ve en düşük test süresi 0,0005 s olarak elde edilmiştir.

NB sınıflandırıcı için en yüksek doğruluk 0,8851, en yüksek AUC 0,8930, en yüksek kesinlik 0,9149, en yüksek duyarlılık 0,8696, en yüksek F1 skoru 0,8917, en düşük eğitim süresi 0,0032 ve en düşük test süresi 0,0013 s olarak elde edilmiştir.

K-EYK sınıflandırıcı için en yüksek doğruluk 0,8517, en yüksek AUC 0,8687, en yüksek kesinlik 0,8809, en yüksek duyarlılık 0,8451, en yüksek F1 skoru 0,8539, en düşük eğitim süresi 0,0033 ve en düşük test süresi 0,0010 s olarak elde edilmiştir.

RO sınıflandırıcı için en yüksek doğruluk 0,8852, en yüksek AUC 0,9053, en yüksek kesinlik 0,9096, en yüksek duyarlılık 0,8720, en yüksek F1 skoru 0,8904, en düşük eğitim süresi 0,3783 ve en düşük test süresi 0,0428 s olarak elde edilmiştir.

YSA sınıflandırıcı için en yüksek doğruluk 0,8947, en yüksek AUC 0,8910, en yüksek kesinlik 1,0000 olarak birden fazla özellik kombinasyonunda, en yüksek duyarlılık 0,7609, en yüksek F1 skoru 0,8642, en düşük eğitim süresi 0,1571 ve en düşük test süresi 0,0042 s olarak elde edilmiştir.

Tüm sınıflandırıcılardan elde edilen sonuçlar karşılaştırıldığında en yüksek doğruluk 0,8947 olarak YSA sınıflandırıcısı ile, en yüksek AUC 0,9053 olarak RO sınıflandırıcısı ile, en yüksek kesinlik 1,0000 olarak YSA sınıflandırıcısı ile birden fazla özellik kombinasyonunda, en yüksek duyarlılık 0,8720 olarak RO sınıflandırıcısı ile, en yüksek

F1 skoru 0,8917 olarak NB sınıflandırıcısı ile, en düşük eğitim süresi 0,0032 s olarak NB sınıflandırıcısı ve en düşük test süresi 0,0005 s olarak DVM sınıflandırıcısı ile elde edilmiştir. En yüksek performans parametrelerinin ve en düşük zaman maliyeti parametrelerinin elde edildiği sınıflandırıcılar ve bu sınıflandırıcılarda kullanılan özellik matrisi kombinasyonları Tablo 3.8’ de verilmiştir. Bu sonuçlar, tüketici beğeni durumunu belirleme için yapılan bir sınıflandırma çalışmasında en iyi performansın belirlenmesinde tek bir kriterin olmadığını ve en iyi performanslarında farklı sınıflandırıcı ve özellik kombinasyonlarında elde edildiğini göstermektedir. Bu karmaşık durum, karmaşık kombinasyonlar içinden optimum performans parametrelerini belirlemek üzere bir yaklaşım sunmayı gerekli hale getirmiştir. Bu nedenle bu tez çalışmasında, sınıflandırıcı DVM olarak sabit tutulmak üzere optimum özellik matrislerinin kombinasyonu performans parametrelerinin optimizasyonu ile belirlenmiştir. Sonraki bölümde özellik matrisleri kombinasyonlarının optimizasyonu ile elde edilen bulgulara yer verilmiştir.

Tablo 3.2. Özellik matrisi kombinasyonları ve indisleri

No.	Lob	Frekans bandı	Özellik matrisi	No.	Lob	Frekans bandı	Özellik matrisi	No.	Lob	Frekans bandı	Özellik matrisi	No.	Lob	Frekans bandı	Özellik matrisi	No.	Lob	Frekans bandı	Özellik matrisi
1	Hepsi	delta	Hepsi	26	frontal	delta	Hepsi	51	temporal	delta	Hepsi	76	paryetal	delta	Hepsi	101	oksipital	delta	Hepsi
2	Hepsi	delta	Hjorth	27	frontal	delta	Hjorth	52	temporal	delta	Hjorth	77	paryetal	delta	Hjorth	102	oksipital	delta	Hjorth
3	Hepsi	delta	Entropi	28	frontal	delta	Entropi	53	temporal	delta	Entropi	78	paryetal	delta	Entropi	103	oksipital	delta	Entropi
4	Hepsi	delta	İstatistiksel	29	frontal	delta	İstatistiksel	54	temporal	delta	İstatistiksel	79	paryetal	delta	İstatistiksel	104	oksipital	delta	İstatistiksel
5	Hepsi	delta	Spektral	30	frontal	delta	Spektral	55	temporal	delta	Spektral	80	paryetal	delta	Spektral	105	oksipital	delta	Spektral
6	Hepsi	teta	Hepsi	31	frontal	teta	Hepsi	56	temporal	teta	Hepsi	81	paryetal	teta	Hepsi	106	oksipital	teta	Hepsi
7	Hepsi	teta	Hjorth	32	frontal	teta	Hjorth	57	temporal	teta	Hjorth	82	paryetal	teta	Hjorth	107	oksipital	teta	Hjorth
8	Hepsi	teta	Entropi	33	frontal	teta	Entropi	58	temporal	teta	Entropi	83	paryetal	teta	Entropi	108	oksipital	teta	Entropi
9	Hepsi	teta	İstatistiksel	34	frontal	teta	İstatistiksel	59	temporal	teta	İstatistiksel	84	paryetal	teta	İstatistiksel	109	oksipital	teta	İstatistiksel
10	Hepsi	teta	Spektral	35	frontal	teta	Spektral	60	temporal	teta	Spektral	85	paryetal	teta	Spektral	110	oksipital	teta	Spektral
11	Hepsi	alfa	Hepsi	36	frontal	alfa	Hepsi	61	temporal	alfa	Hepsi	86	paryetal	alfa	Hepsi	111	oksipital	alfa	Hepsi
12	Hepsi	alfa	Hjorth	37	frontal	alfa	Hjorth	62	temporal	alfa	Hjorth	87	paryetal	alfa	Hjorth	112	oksipital	alfa	Hjorth
13	Hepsi	alfa	Entropi	38	frontal	alfa	Entropi	63	temporal	alfa	Entropi	88	paryetal	alfa	Entropi	113	oksipital	alfa	Entropi
14	Hepsi	alfa	İstatistiksel	39	frontal	alfa	İstatistiksel	64	temporal	alfa	İstatistiksel	89	paryetal	alfa	İstatistiksel	114	oksipital	alfa	İstatistiksel
15	Hepsi	alfa	Spektral	40	frontal	alfa	Spektral	65	temporal	alfa	Spektral	90	paryetal	alfa	Spektral	115	oksipital	alfa	Spektral
16	Hepsi	beta	Hepsi	41	frontal	beta	Hepsi	66	temporal	beta	Hepsi	91	paryetal	beta	Hepsi	116	oksipital	beta	Hepsi
17	Hepsi	beta	Hjorth	42	frontal	beta	Hjorth	67	temporal	beta	Hjorth	92	paryetal	beta	Hjorth	117	oksipital	beta	Hjorth
18	Hepsi	beta	Entropi	43	frontal	beta	Entropi	68	temporal	beta	Entropi	93	paryetal	beta	Entropi	118	oksipital	beta	Entropi
19	Hepsi	beta	İstatistiksel	44	frontal	beta	İstatistiksel	69	temporal	beta	İstatistiksel	94	paryetal	beta	İstatistiksel	119	oksipital	beta	İstatistiksel
20	Hepsi	beta	Spektral	45	frontal	beta	Spektral	70	temporal	beta	Spektral	95	paryetal	beta	Spektral	120	oksipital	beta	Spektral
21	Hepsi	gama	Hepsi	46	frontal	gama	Hepsi	71	temporal	gama	Hepsi	96	paryetal	gama	Hepsi	121	oksipital	gama	Hepsi
22	Hepsi	gama	Hjorth	47	frontal	gama	Hjorth	72	temporal	gama	Hjorth	97	paryetal	gama	Hjorth	122	oksipital	gama	Hjorth
23	Hepsi	gama	Entropi	48	frontal	gama	Entropi	73	temporal	gama	Entropi	98	paryetal	gama	Entropi	123	oksipital	gama	Entropi
24	Hepsi	gama	İstatistiksel	49	frontal	gama	İstatistiksel	74	temporal	gama	İstatistiksel	99	paryetal	gama	İstatistiksel	124	oksipital	gama	İstatistiksel
25	Hepsi	gama	Spektral	50	frontal	gama	Spektral	75	temporal	gama	Spektral	100	paryetal	gama	Spektral	125	oksipital	gama	Spektral

Tablo 3.3. *DVM sınıflandırıcı sonuçları*

Özellik seti	Doğruluk	AUC	Kesinlik	Duyarlılık	F1	Eğitim Süresi (s)	Test Süresi (s)
1	0,56	0,49	0,28	0,50	0,36	0,05755	0,00408
2	0,56	0,53	0,56	0,51	0,53	0,01926	0,00264
3	0,57	0,56	0,55	0,53	0,54	0,03287	0,00242
4	0,57	0,52	0,60	0,52	0,56	0,02676	0,00308
5	0,55	0,54	0,40	0,49	0,44	0,01695	0,00259
6	0,56	0,82	0,28	0,50	0,36	0,04014	0,00382
7	0,87	0,85	0,90	0,85	0,88	0,01538	0,00075
8	0,79	0,82	0,79	0,78	0,79	0,01991	0,00235
9	0,72	0,79	0,72	0,72	0,72	0,02394	0,00260
10	0,82	0,82	0,87	0,80	0,83	0,01563	0,00061
11	0,56	0,77	0,28	0,50	0,36	0,03837	0,00395
12	0,80	0,78	0,86	0,78	0,82	0,01674	0,00067
13	0,78	0,82	0,77	0,77	0,77	0,01974	0,00215
14	0,71	0,80	0,72	0,72	0,72	0,02537	0,00262
15	0,83	0,81	0,87	0,81	0,84	0,01698	0,00059
16	0,56	0,81	0,28	0,50	0,36	0,05437	0,00395
17	0,85	0,82	0,87	0,83	0,85	0,01644	0,00070
18	0,80	0,82	0,80	0,79	0,80	0,03205	0,00209
19	0,67	0,79	0,68	0,68	0,68	0,02478	0,00268
20	0,84	0,85	0,87	0,82	0,85	0,01694	0,00064
21	0,56	0,78	0,28	0,50	0,36	0,03822	0,00390
22	0,80	0,81	0,84	0,78	0,81	0,01918	0,00190
23	0,77	0,81	0,77	0,76	0,77	0,02176	0,00236
24	0,66	0,77	0,66	0,66	0,66	0,02719	0,00290
25	0,84	0,84	0,86	0,82	0,84	0,02523	0,00068
26	0,78	0,84	0,77	0,78	0,78	0,04268	0,00274
27	0,82	0,81	0,85	0,81	0,83	0,02065	0,00081
28	0,81	0,80	0,84	0,80	0,82	0,02373	0,00194
29	0,74	0,80	0,74	0,73	0,74	0,02142	0,00222
30	0,81	0,82	0,85	0,79	0,82	0,01663	0,00058
31	0,70	0,78	0,70	0,70	0,70	0,02558	0,00280
32	0,82	0,79	0,86	0,80	0,83	0,01714	0,00064
33	0,83	0,82	0,85	0,81	0,83	0,01986	0,00203
34	0,80	0,83	0,80	0,79	0,80	0,02081	0,00218
35	0,79	0,75	0,85	0,76	0,81	0,01278	0,00055
36	0,76	0,78	0,76	0,76	0,76	0,02660	0,00268
37	0,81	0,75	0,86	0,78	0,82	0,01331	0,00069
38	0,75	0,76	0,77	0,73	0,75	0,01975	0,00207
39	0,78	0,80	0,78	0,76	0,77	0,02110	0,00228
40	0,83	0,83	0,86	0,82	0,84	0,01492	0,00055
41	0,79	0,84	0,79	0,79	0,79	0,02530	0,00276
42	0,82	0,78	0,86	0,80	0,83	0,01615	0,00058
43	0,84	0,86	0,86	0,82	0,84	0,01969	0,00211

44	0,75	0,80	0,74	0,74	0,74	0,02078	0,00219
45	0,87	0,87	0,90	0,86	0,88	0,01270	0,00059
46	0,71	0,79	0,71	0,71	0,71	0,02746	0,00281
47	0,88	0,88	0,91	0,86	0,89	0,01685	0,00065
48	0,83	0,86	0,85	0,81	0,83	0,02956	0,00093
49	0,76	0,82	0,76	0,76	0,76	0,02376	0,00278
50	0,86	0,85	0,89	0,85	0,87	0,02469	0,00079
51	0,86	0,85	0,87	0,85	0,86	0,02836	0,00226
52	0,79	0,77	0,86	0,77	0,81	0,01469	0,00066
53	0,84	0,83	0,88	0,82	0,85	0,01662	0,00083
54	0,84	0,82	0,88	0,82	0,85	0,01885	0,00079
55	0,83	0,82	0,87	0,81	0,84	0,01139	0,00062
56	0,80	0,82	0,81	0,79	0,80	0,02241	0,00215
57	0,84	0,79	0,89	0,82	0,85	0,01620	0,00060
58	0,83	0,82	0,88	0,81	0,84	0,01516	0,00063
59	0,84	0,81	0,87	0,83	0,85	0,01934	0,00088
60	0,84	0,81	0,89	0,82	0,85	0,01165	0,00059
61	0,79	0,71	0,84	0,77	0,80	0,02044	0,00237
62	0,85	0,80	0,89	0,83	0,86	0,01410	0,00060
63	0,82	0,78	0,87	0,80	0,83	0,01294	0,00060
64	0,78	0,76	0,80	0,75	0,78	0,01908	0,00070
65	0,86	0,83	0,90	0,84	0,87	0,01186	0,00058
66	0,81	0,84	0,84	0,80	0,82	0,02074	0,00193
67	0,85	0,81	0,89	0,83	0,86	0,01391	0,00057
68	0,80	0,76	0,84	0,78	0,81	0,01322	0,00061
69	0,86	0,83	0,87	0,85	0,86	0,02041	0,00070
70	0,86	0,87	0,90	0,84	0,87	0,01224	0,00053
71	0,81	0,83	0,84	0,80	0,82	0,02175	0,00186
72	0,83	0,83	0,88	0,81	0,84	0,01839	0,00057
73	0,78	0,71	0,85	0,76	0,80	0,01264	0,00062
74	0,83	0,80	0,84	0,81	0,83	0,01883	0,00071
75	0,82	0,81	0,88	0,80	0,84	0,01323	0,00062
76	0,80	0,81	0,81	0,79	0,80	0,02170	0,00228
77	0,83	0,81	0,88	0,81	0,84	0,01338	0,00061
78	0,81	0,78	0,87	0,78	0,83	0,01479	0,00065
79	0,76	0,78	0,80	0,73	0,76	0,01821	0,00125
80	0,81	0,81	0,87	0,78	0,83	0,01215	0,00061
81	0,84	0,86	0,86	0,83	0,84	0,02258	0,00206
82	0,84	0,82	0,88	0,82	0,85	0,01274	0,00059
83	0,81	0,81	0,86	0,79	0,82	0,01646	0,00070
84	0,78	0,80	0,81	0,75	0,78	0,01908	0,00095
85	0,83	0,80	0,88	0,81	0,85	0,01084	0,00062
86	0,82	0,84	0,85	0,81	0,83	0,02093	0,00196
87	0,87	0,83	0,90	0,85	0,87	0,01274	0,00056
88	0,82	0,79	0,88	0,80	0,83	0,01323	0,00062
89	0,82	0,86	0,84	0,80	0,82	0,02001	0,00068

90	0,84	0,83	0,89	0,82	0,85	0,01040	0,00068
91	0,81	0,80	0,83	0,80	0,81	0,01956	0,00198
92	0,84	0,82	0,89	0,82	0,85	0,01454	0,00071
93	0,84	0,83	0,88	0,82	0,85	0,01603	0,00068
94	0,79	0,82	0,82	0,78	0,80	0,01831	0,00096
95	0,86	0,83	0,90	0,84	0,87	0,01188	0,00057
96	0,75	0,77	0,76	0,73	0,74	0,01963	0,00200
97	0,88	0,86	0,91	0,86	0,88	0,01565	0,00064
98	0,79	0,76	0,86	0,76	0,81	0,01349	0,00074
99	0,79	0,79	0,80	0,78	0,79	0,01880	0,00091
100	0,88	0,88	0,91	0,86	0,88	0,01399	0,00067
101	0,82	0,80	0,85	0,80	0,82	0,03445	0,00220
102	0,80	0,72	0,86	0,77	0,81	0,01365	0,00063
103	0,79	0,78	0,86	0,77	0,81	0,01498	0,00065
104	0,79	0,80	0,83	0,77	0,80	0,01772	0,00065
105	0,83	0,78	0,88	0,81	0,84	0,01100	0,00065
106	0,84	0,83	0,85	0,83	0,84	0,02132	0,00204
107	0,84	0,83	0,89	0,82	0,85	0,01144	0,00056
108	0,82	0,80	0,88	0,80	0,84	0,01427	0,00062
109	0,81	0,81	0,82	0,80	0,81	0,01970	0,00073
110	0,84	0,85	0,89	0,82	0,85	0,01133	0,00060
111	0,85	0,80	0,87	0,84	0,86	0,02002	0,00222
112	0,83	0,81	0,88	0,81	0,84	0,01250	0,00056
113	0,79	0,86	0,86	0,77	0,81	0,01463	0,00062
114	0,82	0,83	0,86	0,80	0,83	0,01764	0,00065
115	0,83	0,77	0,88	0,81	0,85	0,01063	0,00055
116	0,77	0,81	0,78	0,75	0,77	0,02106	0,00218
117	0,80	0,81	0,86	0,78	0,82	0,01211	0,00066
118	0,86	0,85	0,90	0,84	0,87	0,01373	0,00062
119	0,79	0,85	0,83	0,77	0,80	0,01747	0,00066
120	0,83	0,80	0,88	0,81	0,85	0,01169	0,00057
121	0,82	0,80	0,85	0,80	0,82	0,02917	0,00191
122	0,85	0,82	0,89	0,83	0,86	0,01251	0,00055
123	0,86	0,86	0,90	0,84	0,87	0,01367	0,00060
124	0,76	0,73	0,80	0,73	0,76	0,01839	0,00065
125	0,87	0,86	0,91	0,85	0,88	0,01086	0,00062

Tablo 3.4. NB sınıflandırıcı sonuçları

Özellik seti	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 skoru	Eğitim Süresi (s)	Test Süresi (s)
1	0,44	0,49	0,47	0,49	0,48	0,02541	0,04901
2	0,55	0,42	0,40	0,49	0,44	0,00558	0,00795
3	0,43	0,50	0,43	0,48	0,45	0,00632	0,01044
4	0,54	0,55	0,41	0,48	0,44	0,01074	0,02247
5	0,56	0,49	0,61	0,51	0,56	0,00450	0,00565
6	0,82	0,77	0,84	0,80	0,82	0,01865	0,04336
7	0,89	0,89	0,91	0,87	0,89	0,00580	0,00775
8	0,80	0,81	0,82	0,78	0,80	0,00613	0,01023
9	0,78	0,82	0,81	0,75	0,78	0,01033	0,02177
10	0,84	0,79	0,88	0,82	0,85	0,00454	0,00551
11	0,80	0,81	0,84	0,78	0,81	0,01794	0,04272
12	0,82	0,78	0,84	0,80	0,82	0,00547	0,00771
13	0,75	0,73	0,78	0,73	0,75	0,00607	0,01031
14	0,78	0,78	0,81	0,76	0,79	0,01069	0,02184
15	0,81	0,77	0,86	0,79	0,82	0,00451	0,00539
16	0,84	0,85	0,86	0,83	0,84	0,01809	0,04252
17	0,84	0,82	0,89	0,82	0,85	0,00548	0,00781
18	0,82	0,82	0,85	0,80	0,82	0,00665	0,01035
19	0,75	0,76	0,78	0,72	0,75	0,01110	0,02256
20	0,85	0,83	0,88	0,84	0,86	0,00492	0,00615
21	0,82	0,79	0,84	0,80	0,82	0,02105	0,04483
22	0,86	0,85	0,90	0,84	0,87	0,00624	0,00813
23	0,78	0,79	0,82	0,76	0,79	0,00658	0,01082
24	0,82	0,86	0,85	0,80	0,82	0,01064	0,02221
25	0,85	0,82	0,89	0,83	0,86	0,00525	0,00541
26	0,81	0,79	0,85	0,79	0,82	0,01141	0,02528
27	0,84	0,81	0,88	0,82	0,85	0,00436	0,00521
28	0,80	0,79	0,85	0,78	0,81	0,00475	0,00621
29	0,80	0,83	0,85	0,78	0,81	0,00710	0,01310
30	0,86	0,86	0,88	0,84	0,86	0,00465	0,00336
31	0,83	0,80	0,87	0,81	0,84	0,01135	0,02516
32	0,83	0,81	0,87	0,81	0,84	0,00431	0,00479
33	0,79	0,82	0,82	0,78	0,80	0,00473	0,00626
34	0,80	0,81	0,85	0,78	0,81	0,00702	0,01310
35	0,84	0,86	0,88	0,82	0,85	0,00432	0,00357
36	0,83	0,81	0,86	0,82	0,84	0,01156	0,02618
37	0,80	0,76	0,87	0,77	0,82	0,00431	0,00493
38	0,83	0,80	0,86	0,81	0,83	0,00472	0,00628
39	0,80	0,82	0,83	0,79	0,81	0,00717	0,01296
40	0,85	0,84	0,88	0,83	0,85	0,00439	0,00343
41	0,86	0,87	0,89	0,84	0,86	0,01176	0,02537
42	0,83	0,82	0,88	0,81	0,85	0,00440	0,00496
43	0,79	0,81	0,83	0,77	0,80	0,00517	0,00637

44	0,80	0,76	0,86	0,78	0,82	0,00705	0,01277
45	0,81	0,80	0,85	0,79	0,82	0,00428	0,00337
46	0,82	0,81	0,86	0,80	0,83	0,01150	0,02482
47	0,84	0,82	0,89	0,82	0,85	0,00422	0,00473
48	0,83	0,81	0,86	0,81	0,84	0,00464	0,00601
49	0,78	0,80	0,82	0,76	0,79	0,00693	0,01274
50	0,85	0,83	0,88	0,84	0,86	0,00394	0,00356
51	0,83	0,82	0,87	0,81	0,84	0,00501	0,00683
52	0,84	0,80	0,89	0,82	0,85	0,00329	0,00162
53	0,84	0,84	0,88	0,82	0,85	0,00409	0,00202
54	0,78	0,82	0,82	0,76	0,79	0,00399	0,00367
55	0,84	0,81	0,88	0,82	0,85	0,00394	0,00129
56	0,82	0,77	0,85	0,80	0,83	0,00520	0,00706
57	0,84	0,79	0,88	0,82	0,85	0,00350	0,00164
58	0,82	0,77	0,86	0,80	0,83	0,00372	0,00203
59	0,77	0,72	0,82	0,74	0,78	0,00464	0,00412
60	0,81	0,75	0,87	0,78	0,83	0,00318	0,00133
61	0,78	0,77	0,80	0,76	0,78	0,00550	0,00675
62	0,82	0,78	0,88	0,80	0,84	0,00379	0,00165
63	0,80	0,75	0,84	0,78	0,81	0,00364	0,00202
64	0,76	0,75	0,81	0,73	0,77	0,00527	0,00367
65	0,81	0,80	0,86	0,79	0,82	0,00317	0,00129
66	0,81	0,78	0,85	0,79	0,82	0,00500	0,00663
67	0,85	0,83	0,88	0,84	0,86	0,00335	0,00171
68	0,77	0,79	0,84	0,74	0,79	0,00351	0,00199
69	0,79	0,76	0,85	0,76	0,80	0,00403	0,00370
70	0,82	0,77	0,87	0,80	0,83	0,00371	0,00143
71	0,82	0,79	0,87	0,79	0,83	0,00491	0,00672
72	0,84	0,80	0,89	0,82	0,85	0,00327	0,00163
73	0,80	0,72	0,86	0,77	0,81	0,00374	0,00209
74	0,81	0,82	0,85	0,79	0,82	0,00403	0,00366
75	0,81	0,78	0,86	0,79	0,82	0,00412	0,00136
76	0,83	0,80	0,87	0,82	0,84	0,00514	0,00757
77	0,86	0,85	0,90	0,84	0,87	0,00352	0,00168
78	0,81	0,79	0,86	0,79	0,82	0,00368	0,00199
79	0,77	0,79	0,82	0,74	0,78	0,00456	0,00389
80	0,83	0,82	0,86	0,82	0,84	0,00318	0,00132
81	0,81	0,81	0,85	0,79	0,82	0,00549	0,00685
82	0,84	0,84	0,87	0,82	0,85	0,00386	0,00167
83	0,76	0,79	0,82	0,73	0,77	0,00369	0,00206
84	0,81	0,83	0,84	0,80	0,82	0,00447	0,00386
85	0,86	0,84	0,89	0,85	0,87	0,00506	0,00164
86	0,84	0,82	0,88	0,82	0,85	0,00527	0,00721
87	0,79	0,73	0,86	0,77	0,81	0,00364	0,00170
88	0,81	0,82	0,88	0,79	0,83	0,00422	0,00203
89	0,76	0,76	0,82	0,73	0,77	0,00429	0,00389

90	0,83	0,81	0,88	0,81	0,84	0,00319	0,00132
91	0,85	0,82	0,87	0,83	0,85	0,00531	0,00684
92	0,81	0,82	0,87	0,79	0,83	0,00328	0,00169
93	0,81	0,79	0,86	0,78	0,82	0,00351	0,00201
94	0,79	0,78	0,83	0,77	0,80	0,00432	0,00395
95	0,81	0,79	0,86	0,79	0,82	0,00316	0,00132
96	0,88	0,87	0,90	0,87	0,88	0,00558	0,00677
97	0,80	0,78	0,87	0,78	0,82	0,00375	0,00167
98	0,81	0,80	0,85	0,79	0,82	0,00342	0,00198
99	0,76	0,74	0,80	0,74	0,77	0,00493	0,00373
100	0,86	0,85	0,89	0,85	0,87	0,00326	0,00132
101	0,84	0,81	0,86	0,82	0,84	0,00495	0,00673
102	0,82	0,79	0,87	0,79	0,83	0,00334	0,00166
103	0,82	0,83	0,87	0,80	0,83	0,00355	0,00211
104	0,78	0,81	0,83	0,76	0,79	0,00399	0,00371
105	0,88	0,86	0,91	0,86	0,88	0,00409	0,00136
106	0,85	0,85	0,87	0,83	0,85	0,00489	0,00735
107	0,83	0,81	0,88	0,81	0,84	0,00329	0,00165
108	0,78	0,77	0,85	0,75	0,79	0,00541	0,00201
109	0,80	0,81	0,83	0,78	0,80	0,00403	0,00401
110	0,82	0,80	0,87	0,80	0,83	0,00324	0,00129
111	0,82	0,80	0,86	0,80	0,83	0,00521	0,00688
112	0,85	0,84	0,89	0,83	0,86	0,00330	0,00170
113	0,77	0,75	0,80	0,75	0,77	0,00357	0,00199
114	0,82	0,84	0,88	0,80	0,83	0,00430	0,00395
115	0,87	0,86	0,90	0,85	0,87	0,00315	0,00137
116	0,85	0,84	0,89	0,83	0,86	0,00561	0,00686
117	0,86	0,88	0,90	0,84	0,87	0,00433	0,00174
118	0,81	0,78	0,87	0,79	0,83	0,00360	0,00205
119	0,78	0,84	0,82	0,76	0,79	0,00458	0,00378
120	0,83	0,81	0,87	0,81	0,84	0,00333	0,00132
121	0,78	0,72	0,82	0,76	0,79	0,00523	0,00683
122	0,85	0,85	0,89	0,83	0,86	0,00349	0,00165
123	0,83	0,85	0,86	0,81	0,83	0,00357	0,00237
124	0,76	0,77	0,81	0,73	0,77	0,00399	0,00373
125	0,85	0,81	0,89	0,83	0,86	0,00537	0,00144

Tablo 3.5. K-EYK sınıflandırıcı sonuçları

Özellik seti	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 skoru	EğitimSüresi (s)	TestSüresi (s)
1	0,48	0,46	0,45	0,46	0,46	0,01604	0,01023
2	0,52	0,53	0,51	0,51	0,51	0,00826	0,00399
3	0,45	0,42	0,43	0,44	0,43	0,00387	0,00338
4	0,53	0,53	0,52	0,52	0,52	0,00435	0,00414
5	0,50	0,47	0,49	0,49	0,49	0,00379	0,00171
6	0,68	0,74	0,70	0,66	0,68	0,00487	0,00580
7	0,70	0,69	0,70	0,69	0,69	0,00437	0,00203
8	0,67	0,70	0,67	0,64	0,66	0,00410	0,00206
9	0,70	0,73	0,70	0,68	0,69	0,00416	0,00304
10	0,80	0,86	0,81	0,79	0,80	0,00445	0,00201
11	0,59	0,61	0,58	0,58	0,58	0,00419	0,00555
12	0,70	0,73	0,71	0,69	0,70	0,00417	0,00192
13	0,71	0,73	0,73	0,69	0,71	0,00365	0,00210
14	0,76	0,80	0,75	0,75	0,75	0,00391	0,00283
15	0,76	0,79	0,76	0,74	0,75	0,00457	0,00176
16	0,62	0,69	0,62	0,59	0,60	0,00387	0,00557
17	0,78	0,83	0,78	0,78	0,78	0,00402	0,00216
18	0,63	0,63	0,62	0,61	0,62	0,00427	0,00212
19	0,78	0,85	0,78	0,77	0,78	0,00377	0,00267
20	0,84	0,86	0,86	0,82	0,84	0,00361	0,00169
21	0,62	0,62	0,62	0,61	0,61	0,00369	0,00497
22	0,78	0,81	0,79	0,77	0,78	0,00363	0,00180
23	0,58	0,57	0,57	0,56	0,57	0,00367	0,00186
24	0,72	0,75	0,72	0,71	0,72	0,00362	0,00266
25	0,82	0,82	0,83	0,81	0,82	0,00479	0,00158
26	0,78	0,81	0,80	0,76	0,78	0,00368	0,00291
27	0,69	0,70	0,68	0,68	0,68	0,00524	0,00190
28	0,81	0,80	0,84	0,79	0,81	0,00387	0,00297
29	0,71	0,75	0,71	0,70	0,71	0,00353	0,00205
30	0,75	0,75	0,77	0,73	0,75	0,00437	0,00145
31	0,68	0,72	0,70	0,66	0,68	0,00361	0,00253
32	0,70	0,73	0,69	0,69	0,69	0,00396	0,00136
33	0,68	0,66	0,70	0,66	0,68	0,00334	0,00137
34	0,71	0,76	0,71	0,70	0,71	0,00339	0,00174
35	0,78	0,74	0,80	0,76	0,78	0,00359	0,00140
36	0,68	0,73	0,68	0,66	0,67	0,00366	0,00335
37	0,75	0,74	0,75	0,73	0,74	0,00336	0,00137
38	0,64	0,66	0,63	0,63	0,63	0,00412	0,00154
39	0,74	0,75	0,75	0,72	0,74	0,00358	0,00188
40	0,77	0,76	0,78	0,75	0,76	0,00375	0,00147
41	0,71	0,73	0,73	0,69	0,71	0,00343	0,00275
42	0,73	0,77	0,73	0,72	0,73	0,00456	0,00150
43	0,64	0,68	0,64	0,62	0,63	0,00345	0,00159

44	0,73	0,78	0,73	0,71	0,72	0,00346	0,00181
45	0,83	0,82	0,86	0,82	0,84	0,00537	0,00146
46	0,63	0,69	0,62	0,62	0,62	0,00340	0,00256
47	0,81	0,82	0,82	0,79	0,81	0,00334	0,00209
48	0,64	0,68	0,64	0,61	0,63	0,00334	0,00141
49	0,81	0,82	0,84	0,79	0,81	0,00410	0,00191
50	0,80	0,84	0,81	0,78	0,80	0,00382	0,00152
51	0,75	0,81	0,76	0,73	0,74	0,00370	0,00144
52	0,82	0,84	0,84	0,81	0,82	0,00627	0,00156
53	0,85	0,85	0,86	0,84	0,85	0,00444	0,00122
54	0,78	0,79	0,80	0,76	0,78	0,00453	0,00131
55	0,79	0,85	0,80	0,78	0,79	0,00484	0,00111
56	0,79	0,77	0,83	0,77	0,80	0,00345	0,00142
57	0,82	0,83	0,82	0,81	0,82	0,00485	0,00181
58	0,79	0,79	0,82	0,78	0,80	0,00451	0,00114
59	0,80	0,82	0,82	0,79	0,81	0,00484	0,00137
60	0,84	0,84	0,86	0,83	0,84	0,00445	0,00109
61	0,79	0,78	0,81	0,77	0,79	0,00397	0,00146
62	0,85	0,87	0,85	0,85	0,85	0,00447	0,00104
63	0,76	0,76	0,78	0,74	0,76	0,00452	0,00109
64	0,80	0,86	0,81	0,79	0,80	0,00391	0,00146
65	0,78	0,76	0,81	0,75	0,78	0,00467	0,00100
66	0,75	0,79	0,76	0,74	0,75	0,00402	0,00147
67	0,79	0,82	0,81	0,78	0,79	0,00455	0,00104
68	0,80	0,86	0,80	0,80	0,80	0,00574	0,00111
69	0,77	0,80	0,78	0,76	0,77	0,00355	0,00131
70	0,79	0,82	0,80	0,78	0,79	0,00541	0,00106
71	0,78	0,80	0,80	0,76	0,78	0,00340	0,00145
72	0,79	0,82	0,81	0,77	0,79	0,00479	0,00107
73	0,69	0,72	0,69	0,68	0,68	0,00608	0,00110
74	0,77	0,78	0,78	0,75	0,76	0,00375	0,00132
75	0,81	0,80	0,84	0,80	0,82	0,00679	0,00117
76	0,82	0,82	0,84	0,80	0,82	0,00370	0,00247
77	0,62	0,64	0,61	0,61	0,61	0,00548	0,00115
78	0,76	0,81	0,80	0,74	0,77	0,00646	0,00131
79	0,69	0,72	0,69	0,68	0,69	0,00361	0,00140
80	0,77	0,80	0,77	0,75	0,76	0,00487	0,00107
81	0,74	0,80	0,75	0,73	0,74	0,00407	0,00161
82	0,67	0,72	0,66	0,65	0,66	0,00476	0,00109
83	0,72	0,71	0,74	0,70	0,72	0,00667	0,00136
84	0,76	0,76	0,77	0,75	0,76	0,00366	0,00139
85	0,85	0,82	0,88	0,83	0,85	0,00489	0,00106
86	0,74	0,73	0,74	0,72	0,73	0,00438	0,00159
87	0,71	0,72	0,71	0,69	0,70	0,00462	0,00101
88	0,76	0,80	0,76	0,75	0,76	0,00620	0,00113
89	0,75	0,76	0,76	0,74	0,75	0,00368	0,00141

90	0,79	0,77	0,80	0,78	0,79	0,00492	0,00105
91	0,74	0,78	0,75	0,72	0,73	0,00409	0,00150
92	0,66	0,69	0,66	0,65	0,65	0,00449	0,00100
93	0,67	0,73	0,67	0,65	0,66	0,00558	0,00110
94	0,72	0,72	0,72	0,70	0,71	0,00379	0,00150
95	0,78	0,84	0,79	0,77	0,78	0,00597	0,00106
96	0,70	0,73	0,70	0,68	0,69	0,00347	0,00151
97	0,83	0,82	0,85	0,81	0,83	0,00446	0,00104
98	0,72	0,70	0,74	0,69	0,72	0,00550	0,00117
99	0,78	0,81	0,81	0,77	0,79	0,00353	0,00133
100	0,82	0,84	0,83	0,81	0,82	0,00535	0,00105
101	0,73	0,74	0,78	0,70	0,74	0,00341	0,00148
102	0,59	0,60	0,58	0,58	0,58	0,00578	0,00102
103	0,77	0,80	0,78	0,75	0,76	0,00469	0,00115
104	0,73	0,75	0,74	0,71	0,73	0,00402	0,00136
105	0,78	0,77	0,80	0,77	0,79	0,00514	0,00182
106	0,77	0,83	0,76	0,76	0,76	0,00346	0,00148
107	0,74	0,76	0,74	0,73	0,74	0,00581	0,00104
108	0,78	0,84	0,79	0,78	0,78	0,00440	0,00113
109	0,84	0,83	0,86	0,83	0,84	0,00431	0,00136
110	0,79	0,82	0,81	0,78	0,79	0,00484	0,00106
111	0,77	0,79	0,77	0,75	0,76	0,00350	0,00147
112	0,73	0,78	0,73	0,73	0,73	0,00479	0,00131
113	0,71	0,73	0,72	0,69	0,70	0,00485	0,00115
114	0,75	0,73	0,78	0,72	0,75	0,00468	0,00141
115	0,79	0,81	0,80	0,78	0,79	0,00450	0,00106
116	0,68	0,73	0,69	0,67	0,68	0,00384	0,00146
117	0,78	0,81	0,78	0,77	0,78	0,00443	0,00101
118	0,66	0,70	0,66	0,64	0,65	0,00474	0,00109
119	0,82	0,83	0,85	0,80	0,82	0,00389	0,00130
120	0,78	0,76	0,81	0,77	0,79	0,00447	0,00104
121	0,69	0,76	0,68	0,68	0,68	0,00368	0,00192
122	0,80	0,84	0,81	0,79	0,80	0,00458	0,00106
123	0,71	0,76	0,71	0,70	0,71	0,00620	0,00113
124	0,78	0,81	0,79	0,78	0,78	0,00361	0,00135
125	0,83	0,84	0,84	0,81	0,83	0,00739	0,00105

Tablo 3.6. RO sınıflandırıcı sonuçları

Özellik seti	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 Skoru	Eğitim Süresi (s)	Test Süresi (s)
1	0,53	0,53	0,49	0,49	0,49	0,76811	0,04894
2	0,53	0,48	0,49	0,50	0,49	0,50725	0,05111
3	0,56	0,61	0,54	0,53	0,53	0,50822	0,04683
4	0,54	0,58	0,50	0,50	0,50	0,56247	0,04673
5	0,58	0,56	0,57	0,55	0,56	0,48084	0,04852
6	0,82	0,78	0,87	0,79	0,83	0,64181	0,04602
7	0,85	0,85	0,89	0,83	0,86	0,45317	0,04441
8	0,88	0,86	0,90	0,86	0,88	0,48266	0,04477
9	0,80	0,79	0,85	0,78	0,81	0,52644	0,04557
10	0,84	0,79	0,89	0,82	0,85	0,43432	0,04439
11	0,83	0,79	0,88	0,81	0,84	0,63623	0,04337
12	0,85	0,85	0,88	0,83	0,85	0,45463	0,04433
13	0,78	0,76	0,81	0,76	0,79	0,47571	0,04434
14	0,84	0,86	0,86	0,82	0,84	0,57357	0,04507
15	0,86	0,82	0,89	0,84	0,86	0,43770	0,04401
16	0,87	0,86	0,91	0,85	0,88	0,69876	0,04282
17	0,84	0,87	0,88	0,82	0,85	0,47044	0,04441
18	0,85	0,83	0,89	0,83	0,86	0,50123	0,04499
19	0,86	0,86	0,89	0,85	0,87	0,55298	0,04680
20	0,87	0,87	0,90	0,85	0,87	0,47004	0,04517
21	0,85	0,80	0,89	0,83	0,86	0,67506	0,04323
22	0,80	0,80	0,85	0,78	0,82	0,45161	0,04370
23	0,82	0,82	0,87	0,80	0,84	0,47271	0,04476
24	0,82	0,82	0,85	0,80	0,82	0,52650	0,04386
25	0,76	0,78	0,82	0,73	0,78	0,43333	0,04455
26	0,82	0,82	0,88	0,80	0,83	0,53382	0,04417
27	0,81	0,81	0,85	0,79	0,82	0,42898	0,04554
28	0,84	0,86	0,86	0,82	0,84	0,44762	0,04610
29	0,82	0,83	0,87	0,80	0,83	0,50210	0,04517
30	0,85	0,83	0,89	0,83	0,86	0,40396	0,04512
31	0,84	0,81	0,88	0,82	0,85	0,54258	0,04352
32	0,80	0,80	0,84	0,78	0,81	0,42574	0,04495
33	0,82	0,79	0,86	0,80	0,83	0,44642	0,04536
34	0,84	0,85	0,86	0,83	0,84	0,49186	0,04571
35	0,85	0,86	0,88	0,84	0,86	0,41004	0,04526
36	0,82	0,76	0,88	0,80	0,83	0,52841	0,04383
37	0,82	0,81	0,86	0,80	0,83	0,42434	0,04496
38	0,87	0,85	0,91	0,85	0,88	0,45720	0,04480
39	0,80	0,79	0,85	0,78	0,81	0,49105	0,04521
40	0,85	0,82	0,89	0,83	0,86	0,40166	0,04533
41	0,84	0,80	0,86	0,82	0,84	0,54230	0,04357
42	0,82	0,80	0,85	0,80	0,83	0,42904	0,04455
43	0,84	0,83	0,88	0,82	0,85	0,45557	0,04517

44	0,81	0,82	0,84	0,80	0,82	0,49760	0,04543
45	0,86	0,86	0,90	0,84	0,87	0,41406	0,04549
46	0,85	0,86	0,88	0,83	0,85	0,52901	0,04287
47	0,83	0,80	0,88	0,81	0,84	0,42280	0,04448
48	0,86	0,86	0,90	0,84	0,87	0,45361	0,04420
49	0,82	0,85	0,86	0,80	0,83	0,48034	0,04412
50	0,83	0,85	0,87	0,81	0,84	0,39324	0,04436
51	0,86	0,86	0,89	0,85	0,87	0,44000	0,04476
52	0,82	0,82	0,85	0,80	0,83	0,39341	0,04592
53	0,81	0,81	0,86	0,79	0,82	0,40859	0,04612
54	0,82	0,86	0,86	0,80	0,83	0,43299	0,04615
55	0,86	0,91	0,88	0,85	0,86	0,38665	0,04593
56	0,85	0,83	0,89	0,83	0,86	0,44124	0,04427
57	0,84	0,81	0,85	0,82	0,84	0,39792	0,04590
58	0,78	0,76	0,82	0,76	0,79	0,43489	0,04575
59	0,79	0,77	0,84	0,77	0,80	0,42203	0,04562
60	0,82	0,80	0,87	0,80	0,83	0,38455	0,04615
61	0,86	0,81	0,90	0,84	0,87	0,43783	0,04510
62	0,80	0,74	0,86	0,78	0,82	0,39563	0,04537
63	0,82	0,81	0,88	0,80	0,84	0,40233	0,04675
64	0,82	0,86	0,83	0,81	0,82	0,42458	0,04564
65	0,80	0,77	0,85	0,78	0,81	0,40746	0,04664
66	0,81	0,80	0,86	0,79	0,82	0,43147	0,04451
67	0,82	0,82	0,87	0,80	0,83	0,39113	0,04561
68	0,79	0,81	0,83	0,77	0,80	0,40293	0,04485
69	0,81	0,80	0,85	0,79	0,82	0,41411	0,04571
70	0,85	0,85	0,87	0,83	0,85	0,38956	0,04580
71	0,84	0,81	0,89	0,82	0,85	0,44125	0,04475
72	0,81	0,80	0,85	0,79	0,82	0,39291	0,04617
73	0,79	0,78	0,84	0,76	0,80	0,40686	0,04625
74	0,84	0,80	0,88	0,82	0,85	0,42485	0,04571
75	0,80	0,79	0,82	0,78	0,80	0,39490	0,04679
76	0,83	0,83	0,86	0,81	0,84	0,43154	0,04467
77	0,86	0,87	0,88	0,84	0,86	0,39461	0,04645
78	0,80	0,79	0,83	0,78	0,80	0,40752	0,04582
79	0,76	0,80	0,78	0,74	0,76	0,42288	0,04612
80	0,88	0,84	0,89	0,86	0,88	0,38962	0,04604
81	0,85	0,79	0,89	0,83	0,86	0,43922	0,04476
82	0,82	0,81	0,85	0,81	0,83	0,39207	0,04510
83	0,80	0,73	0,84	0,78	0,81	0,41056	0,04673
84	0,85	0,87	0,87	0,84	0,85	0,44662	0,04559
85	0,85	0,82	0,87	0,84	0,85	0,38445	0,04644
86	0,85	0,80	0,88	0,83	0,85	0,44289	0,04478
87	0,84	0,83	0,88	0,82	0,85	0,39215	0,04555
88	0,82	0,82	0,85	0,81	0,83	0,40085	0,04601
89	0,76	0,81	0,77	0,74	0,76	0,42475	0,04600

90	0,84	0,85	0,87	0,82	0,84	0,38932	0,04543
91	0,85	0,81	0,89	0,83	0,86	0,46168	0,04558
92	0,84	0,86	0,88	0,82	0,85	0,45836	0,05701
93	0,81	0,83	0,84	0,79	0,81	0,42829	0,04767
94	0,81	0,87	0,81	0,80	0,81	0,44253	0,04620
95	0,81	0,84	0,85	0,79	0,82	0,38240	0,04562
96	0,83	0,79	0,88	0,81	0,84	0,43156	0,04410
97	0,81	0,81	0,84	0,79	0,82	0,39255	0,04524
98	0,81	0,76	0,86	0,78	0,82	0,39976	0,04533
99	0,84	0,87	0,85	0,83	0,84	0,41993	0,04501
100	0,81	0,79	0,85	0,79	0,82	0,38090	0,04572
101	0,89	0,88	0,91	0,87	0,89	0,43867	0,04425
102	0,84	0,82	0,88	0,82	0,85	0,39845	0,04501
103	0,83	0,81	0,85	0,81	0,83	0,40721	0,04629
104	0,79	0,82	0,80	0,77	0,79	0,42508	0,04557
105	0,80	0,80	0,82	0,78	0,80	0,38483	0,04591
106	0,82	0,82	0,87	0,79	0,83	0,42635	0,04400
107	0,82	0,84	0,85	0,81	0,83	0,38959	0,04469
108	0,77	0,80	0,78	0,75	0,76	0,40337	0,04614
109	0,79	0,80	0,82	0,78	0,80	0,42158	0,04559
110	0,80	0,79	0,83	0,79	0,81	0,37835	0,04539
111	0,84	0,82	0,88	0,82	0,85	0,42902	0,04346
112	0,84	0,84	0,87	0,82	0,84	0,38899	0,04443
113	0,86	0,85	0,89	0,85	0,87	0,40434	0,04541
114	0,82	0,86	0,85	0,80	0,82	0,41232	0,04501
115	0,86	0,83	0,89	0,84	0,86	0,37841	0,04544
116	0,83	0,85	0,87	0,81	0,84	0,42193	0,04338
117	0,85	0,89	0,86	0,83	0,85	0,39611	0,04481
118	0,85	0,87	0,88	0,83	0,85	0,39291	0,04532
119	0,80	0,81	0,82	0,78	0,80	0,41668	0,04518
120	0,79	0,80	0,83	0,78	0,80	0,37902	0,04574
121	0,82	0,82	0,88	0,80	0,83	0,42718	0,04359
122	0,81	0,83	0,84	0,79	0,81	0,38961	0,04408
123	0,82	0,82	0,87	0,80	0,83	0,39432	0,04531
124	0,83	0,83	0,86	0,81	0,83	0,42056	0,04502
125	0,80	0,79	0,86	0,78	0,82	0,38252	0,04538


Tablo 3.7. YSA sınıflandırıcı sonuçları

Özellik seti	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 Skoru	Eğitim Süresi (s)	Test Süresi (s)
1	0,54	0,50	0,44	0,15	0,23	0,19131	0,00766
2	0,55	0,48	0,40	0,02	0,04	0,17230	0,00511
3	0,56	0,50	0,50	0,01	0,02	0,17456	0,00538
4	0,48	0,51	0,39	0,31	0,35	0,16734	0,00517
5	0,56	0,49	0,00	0,00	0,00	0,16138	0,00477
6	0,88	0,87	1,00	0,73	0,84	0,19745	0,00791
7	0,79	0,74	1,00	0,54	0,70	0,17442	0,00612
8	0,80	0,82	1,00	0,56	0,72	0,17085	0,00570
9	0,76	0,75	0,94	0,48	0,64	0,19221	0,00518
10	0,83	0,82	1,00	0,62	0,77	0,16615	0,00585
11	0,79	0,79	1,00	0,54	0,70	0,18432	0,00597
12	0,82	0,80	1,00	0,60	0,75	0,16606	0,00651
13	0,82	0,81	0,98	0,60	0,74	0,18376	0,00613
14	0,81	0,81	0,97	0,60	0,74	0,19080	0,00562
15	0,82	0,79	1,00	0,60	0,75	0,17340	0,00466
16	0,85	0,81	1,00	0,66	0,80	0,22045	0,00674
17	0,85	0,83	1,00	0,66	0,79	0,17420	0,00640
18	0,81	0,78	1,00	0,58	0,73	0,19238	0,00611
19	0,83	0,83	0,94	0,67	0,78	0,20670	0,00605
20	0,87	0,84	1,00	0,70	0,82	0,19289	0,00589
21	0,83	0,80	1,00	0,62	0,77	0,17543	0,00757
22	0,82	0,80	1,00	0,60	0,75	0,18710	0,00603
23	0,83	0,82	1,00	0,61	0,76	0,19721	0,00573
24	0,86	0,88	0,92	0,74	0,82	0,16499	0,00530
25	0,84	0,82	1,00	0,65	0,78	0,19470	0,00599
26	0,87	0,86	0,98	0,71	0,82	0,19301	0,00593
27	0,80	0,80	1,00	0,55	0,71	0,17890	0,00506
28	0,84	0,86	0,97	0,66	0,78	0,16708	0,00472
29	0,81	0,75	1,00	0,57	0,73	0,18056	0,00436
30	0,83	0,80	1,00	0,61	0,76	0,17804	0,00655
31	0,80	0,79	1,00	0,55	0,71	0,18730	0,00534
32	0,83	0,81	1,00	0,62	0,77	0,16986	0,00506
33	0,79	0,78	0,98	0,54	0,69	0,18685	0,00546
34	0,83	0,81	0,97	0,65	0,77	0,18662	0,00709
35	0,80	0,72	1,00	0,54	0,70	0,17358	0,00561
36	0,82	0,80	1,00	0,60	0,75	0,18310	0,00621
37	0,85	0,80	1,00	0,67	0,80	0,17304	0,00708
38	0,82	0,81	0,97	0,62	0,75	0,16546	0,00425
39	0,81	0,79	0,96	0,59	0,73	0,19672	0,00562
40	0,87	0,84	1,00	0,70	0,82	0,17012	0,00491
41	0,83	0,81	1,00	0,61	0,76	0,19386	0,00525
42	0,85	0,87	1,00	0,65	0,79	0,20315	0,00805
43	0,80	0,80	0,98	0,57	0,72	0,17929	0,00681


44	0,81	0,82	0,90	0,65	0,75	0,19891	0,00486
45	0,83	0,76	1,00	0,61	0,76	0,19495	0,00545
46	0,79	0,81	1,00	0,53	0,70	0,22950	0,00526
47	0,82	0,80	1,00	0,60	0,75	0,19794	0,00609
48	0,82	0,79	1,00	0,60	0,75	0,18271	0,00637
49	0,81	0,81	0,91	0,65	0,75	0,20258	0,00536
50	0,83	0,84	1,00	0,62	0,77	0,17190	0,00478
51	0,82	0,79	1,00	0,59	0,74	0,19169	0,00464
52	0,81	0,78	1,00	0,57	0,72	0,18942	0,00519
53	0,78	0,74	0,94	0,54	0,68	0,16210	0,00560
54	0,89	0,89	1,00	0,74	0,85	0,17296	0,00510
55	0,87	0,86	1,00	0,71	0,83	0,18072	0,00515
56	0,84	0,82	1,00	0,65	0,78	0,17777	0,00515
57	0,86	0,82	1,00	0,67	0,81	0,15949	0,00464
58	0,87	0,83	1,00	0,71	0,83	0,17106	0,00467
59	0,81	0,81	0,95	0,61	0,75	0,17019	0,00573
60	0,84	0,78	1,00	0,63	0,77	0,17127	0,00516
61	0,83	0,81	1,00	0,62	0,77	0,16761	0,00464
62	0,81	0,76	1,00	0,57	0,73	0,16750	0,00518
63	0,82	0,84	0,95	0,62	0,75	0,16480	0,00457
64	0,81	0,81	0,95	0,61	0,74	0,16790	0,00550
65	0,85	0,83	1,00	0,66	0,80	0,16362	0,00488
66	0,86	0,83	1,00	0,67	0,81	0,16636	0,00569
67	0,80	0,78	1,00	0,56	0,72	0,17454	0,00506
68	0,83	0,81	0,98	0,62	0,76	0,17530	0,00460
69	0,80	0,85	0,96	0,58	0,72	0,17750	0,00636
70	0,83	0,82	1,00	0,62	0,77	0,17891	0,00462
71	0,79	0,78	1,00	0,53	0,69	0,19178	0,00637
72	0,84	0,76	1,00	0,63	0,77	0,16487	0,00600
73	0,83	0,79	1,00	0,61	0,76	0,16883	0,00571
74	0,79	0,81	0,89	0,60	0,72	0,16722	0,00528
75	0,80	0,80	1,00	0,55	0,71	0,20627	0,00704
76	0,87	0,86	0,99	0,71	0,83	0,19753	0,00560
77	0,84	0,81	1,00	0,64	0,78	0,18363	0,00496
78	0,80	0,82	0,96	0,57	0,72	0,18097	0,00529
79	0,82	0,84	0,97	0,61	0,75	0,18837	0,00529
80	0,85	0,87	1,00	0,65	0,79	0,19550	0,00640
81	0,84	0,79	1,00	0,64	0,78	0,17197	0,00573
82	0,84	0,81	1,00	0,63	0,77	0,20372	0,00482
83	0,81	0,82	0,93	0,62	0,75	0,17159	0,00466
84	0,81	0,83	0,95	0,61	0,75	0,17381	0,00775
85	0,83	0,79	1,00	0,61	0,76	0,16442	0,00542
86	0,81	0,80	1,00	0,57	0,72	0,16122	0,00483
87	0,84	0,81	1,00	0,63	0,77	0,17216	0,00531
88	0,80	0,79	0,96	0,58	0,72	0,16651	0,00523
89	0,76	0,78	0,86	0,54	0,66	0,18596	0,00501

90	0,85	0,83	1,00	0,67	0,80	0,15712	0,00583
91	0,83	0,80	1,00	0,61	0,76	0,16886	0,00524
92	0,80	0,77	1,00	0,54	0,70	0,17645	0,00534
93	0,79	0,78	0,95	0,57	0,71	0,17524	0,00646
94	0,78	0,79	0,93	0,54	0,68	0,16643	0,00485
95	0,85	0,82	1,00	0,66	0,80	0,15789	0,00491
96	0,83	0,83	1,00	0,62	0,77	0,16549	0,00544
97	0,82	0,85	1,00	0,60	0,75	0,17807	0,00485
98	0,83	0,77	1,00	0,61	0,76	0,16277	0,00469
99	0,79	0,83	0,89	0,60	0,71	0,17754	0,00470
100	0,82	0,79	1,00	0,60	0,75	0,17064	0,00550
101	0,83	0,84	1,00	0,61	0,76	0,16068	0,00473
102	0,83	0,82	1,00	0,61	0,76	0,18972	0,00555
103	0,80	0,77	0,98	0,55	0,71	0,15932	0,00529
104	0,78	0,81	0,93	0,56	0,70	0,17615	0,00502
105	0,84	0,86	1,00	0,63	0,78	0,16033	0,00485
106	0,81	0,77	1,00	0,57	0,73	0,17723	0,00596
107	0,85	0,82	1,00	0,65	0,79	0,16276	0,00474
108	0,78	0,76	0,85	0,60	0,70	0,15913	0,00456
109	0,75	0,80	0,87	0,51	0,64	0,16280	0,00486
110	0,85	0,85	1,00	0,67	0,80	0,17237	0,00496
111	0,79	0,75	1,00	0,53	0,69	0,16266	0,00476
112	0,86	0,85	1,00	0,68	0,81	0,16973	0,00648
113	0,83	0,80	0,97	0,65	0,77	0,16807	0,00632
114	0,78	0,78	0,87	0,58	0,69	0,17197	0,00614
115	0,89	0,87	1,00	0,76	0,86	0,17629	0,00497
116	0,85	0,82	1,00	0,66	0,80	0,17137	0,00566
117	0,85	0,81	1,00	0,66	0,79	0,17131	0,00544
118	0,78	0,75	1,00	0,51	0,67	0,16341	0,00488
119	0,71	0,72	0,80	0,47	0,59	0,16930	0,00659
120	0,81	0,78	1,00	0,58	0,73	0,17897	0,00535
121	0,83	0,83	1,00	0,62	0,77	0,17206	0,00554
122	0,84	0,84	1,00	0,64	0,78	0,17495	0,00565
123	0,81	0,85	1,00	0,58	0,73	0,22523	0,00423
124	0,77	0,77	0,84	0,58	0,69	0,17904	0,00570
125	0,84	0,85	1,00	0,63	0,77	0,18051	0,00610


Şekil 3.1. DVM sınıflandırıcısı doğruluk grafiği




Şekil 3.2. DVM sınıflandırıcısı AUC grafiği




Şekil 3.3. DVM sınıflandırıcısı kesinlik grafiği




Şekil 3.4. DVM sınıflandırıcısı duyarlılık grafiği




Şekil 3.5. DVM sınıflandırıcısı F1 Skoru grafiği




Şekil 3.6. DVM sınıflandırıcısı eğitim süresi grafiği




Şekil 3.7. DVM sınıflandırıcısı test süresi grafiği




Şekil 3.8. NB sınıflandırıcısı doğruluk grafiği




Şekil 3.9. NB sınıflandırıcısı AUC grafiği




Şekil 3.10. NB sınıflandırıcısı kesinlik grafiği




Şekil 3.11. NB sınıflandırıcısı duyarlılık grafiği




Şekil 3.12. NB sınıflandırıcısı F1 Skoru grafiği




Şekil 3.13. NB sınıflandırıcısı eğitim süresi grafiği




Şekil 3.14. NB sınıflandırıcısı test süresi grafiği




Şekil 3.15. K-EYK sınıflandırıcısı doğruluk grafiği




Şekil 3.16. K-EYK sınıflandırıcısı AUC grafiği




Şekil 3.17. K-EYK sınıflandırıcısı kesinlik grafiği




Şekil 3.18. K-EYK sınıflandırıcısı duyarlılık grafiği




Şekil 3.19. K-EYK sınıflandırıcısı F1 Skoru grafiği




Şekil 3.20. K-EYK sınıflandırıcısı eğitim süresi grafiği




Şekil 3.21. K-EYK sınıflandırıcısı test süresi grafiği




Şekil 3.22. RO sınıflandırıcısı doğruluk grafiği




Şekil 3.23. RO sınıflandırıcısı AUC grafiği




Şekil 3.24. RO sınıflandırıcısı kesinlik grafiği




Şekil 3.25. RO sınıflandırıcısı duyarlılık grafiği




Şekil 3.26. RO sınıflandırıcısı F1 Skoru grafiği




Şekil 3.27. RO sınıflandırıcısı eğitim süresi grafiği




Şekil 3.28. RO sınıflandırıcısı test süresi grafiği




Şekil 3.29. YSA sınıflandırıcısı doğruluk grafiği




Şekil 3.30. YSA sınıflandırıcısı AUC grafiği




Şekil 3.31. YSA sınıflandırıcısı kesinlik grafiği




Şekil 3.32. YSA sınıflandırıcısı duyarlılık grafiği




Şekil 3.33. YSA sınıflandırıcısı F1 Skoru grafiği



Şekil 3.34. YSA sınıflandırıcısı eğitim süresi grafiği



Şekil 3.35. YSA sınıflandırıcısı test süresi grafiği



Tablo 3.8. Her bir performans metriği için elde edilen en iyi değerler

	Elde edilen değer	Sınıflandırıcı	Özellik matrisi kombinasyonu indisi
Doğruluk	0,8947	YSA	115,108
AUC	0,9053	RO	55
Kesinlik	1,0000	YSA	6, 7, 8, 10, 11, 12, 15, 16, 17, 18, 20, 21, 22, 23, 25
Duyarlılık	0,8720	RO	101
F1 skoru	0,8917	NB	7
Eğitim süresi (s)	0,0032	NB	110
Test süresi (s)	0,0005	SVM	70

3.2. Özellik Matrislerinin Optimizasyonu


Elde edilen 125 farklı özellik matrisi için DVM sınıflandırıcısı ile elde edilen doğruluk, AUC, kesinlik, duyarlılık, F1 skoru değerleri maksimum, eğitim zaman maliyeti, test zaman maliyeti değerlerini minimum olacak şekilde ÇAGA (Çok Amaçlı Genetik Algoritma) yöntemi ile birden fazla Pareto optimal çözümler elde edilmiştir. ÇAGA ile elde edilen pareto optimal çözümler ve karşılık gelen özellik matrisleri Tablo 3.8’ de verilmiştir. Her bir pareto optimal sonucun sınıflandırma performans metriği, eğitim

süresi ve test süresi değerleri ise sırasıyla Şekil 3.36, Şekil 3.37, Şekil 3.38’ de verilmiştir. Elde edilen pareto optimal çözümler için oluşan pareto cephesi görselleri farklı amaç fonksiyonları için 3 boyutlu olarak Şekil 3.39, Şekil 3.40, Şekil 3.41, Şekil 3.42’ de verilmiştir. Ardından TOPSIS metodu ile tek optimal çözüm belirlenmiştir.


Tablo 3.9. Pareto optimal çözümler ve karşılık gelen özellik matrisleri

İndis	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 skoru	Eğitim süresi (s)	Test süresi (s)
115	-0,83	-0,77	-0,88	-0,81	-0,85	0,01063	0,00055
70	-0,86	-0,87	-0,90	-0,84	-0,87	0,01224	0,00053
115	-0,83	-0,77	-0,88	-0,81	-0,85	0,01063	0,00055
105	-0,83	-0,78	-0,88	-0,81	-0,84	0,01100	0,00065
85	-0,83	-0,80	-0,88	-0,81	-0,85	0,01084	0,00062


Şekil 3.36. Her bir pareto optimal sonucun sınıflandırma performans metriği




Şekil 3.37. Her bir pareto optimal sonucun eğitim süresi




Şekil 3.38. Her bir pareto optimal sonucun test süresi




Şekil 3.39. Doğruluk- F1 skoru-test süresi parametreleri için elde edilen pareto cephesi




Şekil 3.40. Doğruluk- kesinlik-test süresi parametreleri için elde edilen pareto cephesi



Şekil 3.41. Doğruluk- eğitim -test süresi parametreleri için elde edilen pareto cephesi




Şekil 3.42. AUC- duyarlılık-test süresi parametreleri için elde edilen pareto cephesi



Son aşamada, belirlenen pareto optimal çözümler arasından tek optimum çözüm TOPSIS metodu ile belirlenmiştir. Bu amaçla TOPSIS amaç fonksiyonu ağırlıkları parametre taraması yoluyla doğruluk, AUC, kesinlik, duyarlılık, F1 skoru, değerleri maksimum, eğitim zaman maliyeti, test zaman maliyeti parametreleri için sırasıyla 0,30, 0,15, 0,15,

0,15, 0,15, 0,05, 0,05 olacak şekilde optimum çözüm belirlenmiştir. Pareto optimal çözümlerin TOPSIS skorları Şekil 3.43’ te yer almaktadır. Bölüm 2.3.3’te yer alan TOPSIS metodunda kullanılan denklemler sayesinde pareto optimal çözümler arasından optimum çözüm ve karşılık gelen indis Tablo 3.9’ da verilmiştir. Buna göre 115. indis ile temsil edilen özellik matrisi beyin lobu için; oksipital lob frekans bandı için alfa bandı özellik matrisi için “spektral özellikler matrisi” dir.

Şekil 3.43. Pareto optimal çözümlerin TOPSIS skorları



Tablo 3.10. Pareto optimal çözümler arasından optimum çözüm ve karşılık gelen indis

Parametre	Değer
Doğruluk	0.8325
AUC	0.7697
Kesinlik	0.8841
Duyarlılık	0.8118
F1 Skoru	0.8464
Eğitim süresi (s)	0.01063
Test süresi (s)	0.00055
İndis	115
Beyin lobu	Oksipital Lob
Frekans bandı	Alfa Bandı
Özellik matrisi	Spektral Özellikler Matrisi

Tablo 3.10’da gösterilen sonuçlar ile literatürde yer alan sonuçlar karşılaştırıldığında 0,83 doğruluk, 0,77 AUC, 0,88 kesinlik, 0,81 duyarlılık ve 0,85 F1 skoru elde edilmiş ayrıca yöntemin 0,01063 s eğitim süresi, 0,00055 s test süresi ile zamanlama maliyeti açısından oldukça hızlı çalıştığı sonucuna varılmıştır. Bu da önerilen yaklaşımın gerçek zamanlı sistemlere entegrasyonu açısından avantaj sunduğunu göstermektedir. Tez çalışmasında elde edilen sonuçlar ile literatürde yer alan aynı veri setini ve sınıflandırıcıyı kullanan çalışmalarla elde edilen performans metrikleri karşılaştırma sonuçları Tablo 3.11’de yer almaktadır. Buna göre, Amin ve ekibi 0,52 doğruluk, 0,51 AUC, 0,37 duyarlılık değerleri ile aynı sınıflandırma performansı değerlendirme ölçütleri açısından bu tez çalışmasının çok gerisinde kalmıştır. Aldayel ve ekibi 0,71 doğruluk, 0,72 kesinlik, 0,71 duyarlılık değerlerine ulaşmıştır ancak aynı sınıflandırma performansı değerlendirme ölçütleri karşılaştırıldığında bu tez çalışmasının gerisinde kalmıştır. Ykhlef ve ekibi; Aldayel ve ekibinin elde ettiği sonuçlarla benzer sonuçlar elde etmiştir ve 0,71 doğruluk, 0,72 kesinlik, 0,71 duyarlılık değerleri ile aynı sınıflandırma performansı değerlendirme ölçütleri açısından tez çalışmamızın gerisinde kalmıştır.

Sonuç olarak, bu tez çalışmasında önerilen yöntem; doğruluk, AUC, kesinlik, duyarlılık, F1 skoru olmak üzere beş adet sınıflandırma performansı değerlendirme ölçütü kullanarak literatürdeki benzer çalışmalardan daha üstün bir performans sergilemiş, hem de işlem süresi açısından düşük zamanlama maliyeti ile gerçek zamanlı uygulamalara entegre edilebilecek bir potansiyel ortaya koymuştur. Bu bağlamda, özellikle oksipital lob ve alfa bandına ait spektral özelliklerin kullanılması, EEG sinyallerinden anlamlı bilgiler çıkarılmasında etkili olmuş ve nöropazarlama alanındaki uygulamalarda kullanılabilecek güvenilir bir yöntem ortaya konmuştur.

Tablo 3.11. Tez çalışması sonuçları ile literatürün karşılaştırılması

Referanslar	Amin ve Ekibi, 2020 [52]	Aldayel ve Ekibi, 2021 [53]	Ykhlef, 2021 [3]	Bu tez çalışması
Doğruluk	0,52	0,71	0,71	0.83
AUC	0,51	-	-	0.77
Kesinlik	-	0,72	0,72	0.88
Duyarlılık	0,37	0,71	0,71	0.81
F1 Skoru	-	-	-	0.85
Eğitim süresi (s)	-	-	-	0.01063
Test süresi (s)	-	-	-	0.00055

DÖRDÜNCÜ BÖLÜM

TARTIŞMA, SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında, nöropazarlama stratejilerinin geliştirilmesine katkı sağlamak amacıyla EEG sinyalleri kullanılarak tüketicilerin beğenme/ beğenmeme durumlarının tahminlenmesinde optimum bir yaklaşım sunan bir sinyal işleme ve optimizasyon modeli önerilmiştir. Yadava ve ekibi tarafından oluşturulan ve literatürde yaygın olarak kullanılan EEG veri seti kullanılarak, EEG sinyalleri analiz edilmiştir. Katılımcıların ürün görsellerine verdikleri tepkileri analiz etmek için, EEG sinyalleri delta, teta, alfa, beta, gama frekans bantlarında ve Frontal, temporal, paryetal, oksipital lob beyin bölgelerine göre ayrıştırılmış; ardından bu verilerden hjorth özellikleri, entropi özellikler, istatistiksel özellikler, spektral özellikler çıkarılmıştır. Çıkarılan özelliklerden elde edilen özellik kombinasyonları ile DVM, NB, K-EYK, RO, YSA olmak üzere beş farklı geleneksel sınıflandırma algoritması kullanılarak tüketici tercih durumu (beğeni / beğenmeme) tahminlenmiştir. Her sınıflandırıcı için doğruluk, AUC, kesinlik, duyarlılık, F1 skoru gibi performans metrikleri değerlendirilmiş ve ayrıca literatürde nadiren ele alınan zaman maliyeti parametresi de eğitim süresi ve test süresi olmak üzere değerlendirme kriteri olarak belirlenmiştir.

EEG tabanlı tüketici tercih tahmini sistemlerinin nihai sonucu eş zamanlı sinyal işleme ve bilgi çıkarımı olduğundan optimum çözümlerin sunulduğu yaklaşımların literatürde yer alması oldukça değerlidir. Bu tez çalışmasının özgün yönlerinden biri, bu sınıflandırma sürecinde kullanılan özellik matrislerinin ÇAGA ile optimize edilmesidir. Bu sayede doğruluk oranı yüksek, eğitim ve test süresi düşük olan pareto optimal çözümler elde edilmiştir. ÇAGA ile elde edilen bu çözümler, son aşamada TOPSIS yöntemi ile analiz edilerek pareto optimal çözüm kümesi içerisinde tek optimum çözüm belirlenmiştir. Böylece, sinyal işleme ve optimizasyon yöntemlerinin birlikte kullanıldığı, nöropazarlama çalışmalarına yön verecek nitelikte bir yaklaşım literatüre kazandırılmıştır.

Bu tez çalışmasının optimizasyon aşamasında karşılaştırılabilirliği sağlamak amacıyla tüm özellik matrisleri için aynı sınıflandırıcı kullanılmıştır. Fakat bu durumun, bazı özellik matrisleri için dezavantaj yaratabileceği düşünülerek, her özellik matrisi için grid araması yaklaşımı ile optimal DVM parametrelerinin seçilip sonra karşılaştırma yapılması bu tez çalışmasının gelişmeye açık yönlerinden birisidir. Ayrıca bu tez çalışmasında kullanılan veri seti sınırlı sayıda katılımcıya ait EEG verisi içermektedir. Gelecek çalışmalarda, daha geniş ve kapsamlı veri setleri kullanılarak benzer analizlerin yapılması elde edilen sonuçların güvenilirliğini artıracaktır. Farklı daha büyük veri setleri ile benzer analizlerin yapılması geliştirilen modelin farklı koşullarda gösterdiği performansın daha sağlıklı bir şekilde değerlendirilmesine olanak sağlayacaktır. Tez çalışmasında, EEG verileri çevrimdışı olarak analiz edilmiştir. Gerçek zamanlı EEG veri analizi yapan bir yazılım sistemi geliştirildiği takdirde, kullanıcıların anlık tepkilerine göre içerik değişikliği yapabilen reklam veya e-ticaret sistemleri tasarlanması tez çalışmasının gelişmeye açık yönlerinden birisidir. Ayrıca, EEG verileri ile Gİ, fEMG veya GCT gibi biyofizyolojik sinyallerin entegre kullanımı, tüketici tepkilerinin daha kapsamlı şekilde analiz edilmesini mümkün kılabilir. Bu tür çoklu modalite yaklaşımı, duygu tanıma doğruluğunu artıracak niteliktedir.

KAYNAKÇA

- [1] N. Lee, A. J. Broderick, and L. Chamberlain, “What is ‘neuromarketing’? A discussion and agenda for future research,” *Int. J. Psychophysiol.*, vol. 63, no. 2, pp. 199–204, 2007.
- [2] C. Morin, “Neuromarketing: the new science of consumer behavior,” *Society*, vol. 48, no. 2, pp. 131–135, 2011.
- [3] M. Aldayel, M. Ykhlef, and A. Al-Nafjan, “Recognition of Consumer Preference by Analysis and Classification EEG Signals,” *Front Hum Neurosci*, vol. 14, Jan. 2021, doi: 10.3389/fnhum.2020.604639.
- [4] F. M. Córdova, F. Cifuentes, C. Castro, and C. Hinostroza, “Analysis of the purchasing decision-making process in e-commerce using SED Method from Neuromarketing,” in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 704–711. doi: 10.1016/j.procs.2022.11.232.
- [5] H. Plassmann, V. Venkatraman, S. Huettel, and C. Yoon, “Consumer neuroscience: applications, challenges, and possible solutions,” *Journal of Marketing Research*, vol. 52, no. 4, pp. 427–435, Aug. 2015.
- [6] V. Özlem Akgün, G. S. Ergün, İ. Meslek, Y. Okulu, A. Üniversitesi, and M. Meslek, “Yeni Bir Pazarlama Yaklaşımı Olarak Nöropazarlama Üzerine Kuramsal Bir Araştırma,” 2016.
- [7] A. Tüfekçi, M. Tolon, and G. A. Figen, “Kültürel Öğeler İçeren Reklamların Beğenisi Demografik Özelliklere Göre Farklılaşır Mı (Does, Likes of Advertisements Containing Cultural Elements, Different According to Demographic Characteristic),” *Journal of Business Research - Turk*, vol. 13, no. 3, pp. 2819–2831, Sep. 2021, doi: 10.20491/isarder.2021.1292.
- [8] K. O. Erdemir and Ö. Yavuz, “Nöropazarlama’ya Giriş ,” 2016, *BrandMap*.
- [9] F. S. Rawnage *et al.*, “Technological advancements and opportunities in neuromarketing: A systematic review,” *Brain Informatics*, vol. 7, no. 1, pp. 1–25, Dec. 2020, doi: 10.1186/s40708-020-00109-x.

- [10] R. N. Khushaba, C. Wise, S. Kodagoda, J. Louviere, B. E. Kahn, and C. Townsend, "Consumer neuroscience: Assessing the brain response to marketing stimuli using electroencephalogram (EEG) and eye tracking," *Expert Syst Appl*, vol. 40, no. 9, pp. 3803–3812, Jul. 2013, doi: 10.1016/j.eswa.2012.12.095.
- [11] W. M. Lim, "Demystifying neuromarketing," *J Bus Res*, vol. 91, pp. 205–220, Oct. 2018, doi: 10.1016/j.jbusres.2018.05.036.
- [12] F. A. C. Azevedo *et al.*, "Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain," *Journal of Comparative Neurology*, vol. 513, no. 5, pp. 532–541, 2009.
- [13] E. Dağdevir, D. Prof, and M. Tokmakçı, "Erciyes Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı Motor İmge Tabanlı Beyin Bilgisayar Arayüzü Sistemlerinde Ön İşleme Yönteminin Sınıflandırma Performansına Etkisinin Araştırılması."
- [14] E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. Siegelbaum, A. J. Hudspeth, and S. Mack, *Principles of neural science*, vol. 4. McGraw-hill New York, 2000.
- [15] D. Purves, G. J. Augustine, D. Fitzpatrick, W. Hall, A.-S. LaMantia, and L. White, *Neurosciences*. De Boeck Supérieur, 2019.
- [16] F. Üniversitesi Sosyal Bilimler Dergisi, N. Literature Review Atilla YÜCEL, and P. Coşkun, "Araştırma Makalesi Nöropazarlama Literatür İncelemesi." [Online]. Available: <http://www.medicana.com.tr/formlar/2012/eylul/eegnedir.aspx>
- [17] B. Graimann, B. Z. Allison, and G. Pfurtscheller, *Brain-computer interfaces: Revolutionizing human-computer interaction*. Springer science & business media, 2010.
- [18] M. Teplan, "Fundamentals of EEG measurement," *Measurement Science Review*, vol. 2, no. 2, pp. 1–11, 2002.
- [19] K. Blinowska and P. Durka, "Electroencephalography (EEG)," *Wiley Encyclopedia of Biomedical Engineering*, vol. 10, 2006, doi: 10.1002/9780471740360.

- [20] N. Birbaumer, T. Hinterberger, A. Kubler, and N. Neumann, “The thought-translation device (TTD): neurobehavioral mechanisms and clinical outcome,” *IEEE transactions on Neural Systems and rehabilitation engineering*, vol. 11, no. 2, pp. 120–123, 2003.
- [21] M. J. Kaufman, *Brain Imaging in Substance Abuse: Research, Clinical, and Forensic Applications*. Springer Science & Business Media, 2000.
- [22] J. Fell, N. Axmacher, and S. Haupt, “From alpha to gamma: Electrophysiological correlates of meditation-related states of consciousness,” *Med. Hypotheses*, vol. 75, no. 2, pp. 218–224, Aug. 2010, doi: 10.1016/j.mehy.2010.02.025.
- [23] L. Hu and Z. Zhang, Eds., *EEG Signal Processing and Feature Extraction*. Singapore: Springer Nature, 2019.
- [24] M. D. Bercea, “Anatomy of methodologies for measuring consumer behavior in neuromarketing research,” in *Proc. Lupcon Center for Business Research (LCBR) Eur. Marketing Conf.*, Ebermannstadt, Germany, Aug. 2012.
- [25] C. Behremen, “Yiyecek ve içecek işletmelerinin nöropazarlama faaliyetlerinde duyuşal algıların etkisi: Psikonörobiyokimya perspektifi,” M.S. thesis, Balıkesir Univ., Inst. of Social Sciences, Balıkesir, Turkey, 2015.
- [26] R. B. Silberstein, M. A. Schier, A. Pipingas, J. Ciorciari, S. R. Wood, and D. G. Simpson, “Steady-State Visually Evoked Potential Topography Associated with a Visual Vigilance Task,” 1990.
- [27] B. Ceylan, “Nöropazarlama uygulamaları için EEG sinyallerinin analizi ile beğeni durum tespiti / Recognition of preferences with analysis of EEG signals for neuromarketing applications,” İstanbul, 2024.
- [28] L. Zurawicki, *Neuromarketing: Exploring the brain of the consumer*. Springer Science & Business Media, 2010.
- [29] S. Kumari and A. K. Dutta, “Brain waves, neuroimaging (fMRI, EEG, MEG, PET, NIR),” in *Computational techniques in neuroscience*, CRC Press, 2023, pp. 67–82.

- [30] R. Ohme, M. Matukin, and B. Pacula-Lesniak, "Biometric Measures for Interactive Advertising Research," *Journal of Interactive Advertising*, vol. 11, no. 2, pp. 60–72, Mar. 2011, doi: 10.1080/15252019.2011.10722185.
- [31] H. D. Critchley, "Electrodermal responses: what happens in the brain," *The Neuroscientist*, vol. 8, no. 2, pp. 132–142, 2002.
- [32] T. K. Perrachione and J. R. Perrachione, "Brains and brands: developing mutually informative research in neuroscience and marketing," *Journal of Consumer Behaviour*, vol. 7, no. 4–5, pp. 303–318, Jul. 2008, doi: 10.1002/cb.253.
- [33] S. M. McClure, J. Li, D. Tomlin, K. S. Cypert, L. M. Montague, and P. Read Montague, "Neural Correlates of Behavioral Preference for Culturally Familiar Drinks," 2004.
- [34] T. Bakalash and H. Riemer, "Exploring ad-elicited emotional arousal and memory for the ad using fMRI," *J Advert*, vol. 42, no. 4, pp. 275–291, Oct. 2013, doi: 10.1080/00913367.2013.768065.
- [35] H. Gangadharbatla, S. Bradley, and W. Wise, "Psychophysiological responses to background brand placements in video games," *J Advert*, vol. 42, no. 2–3, pp. 251–263, Apr. 2013, doi: 10.1080/00913367.2013.775800.
- [36] W. Maxian, S. D. Bradley, W. Wise, and E. N. Toulouse, "Brand Love is in the Heart: Physiological Responding to Advertised Brands," *Psychol Mark*, vol. 30, no. 6, pp. 469–478, Jun. 2013, doi: 10.1002/mar.20620.
- [37] R. Silberstein, S. Seixas, and G. Nield, "Conceptual Closure Elicited by Event Boundary Transitions Affects Commercial Communication Effectiveness," *Front Neurosci*, vol. 14, Apr. 2020, doi: 10.3389/fnins.2020.00292.
- [38] T. Baumgartner, D. Knoch, P. Hotz, C. Eisenegger, and E. Fehr, "Dorsolateral and ventromedial prefrontal cortex orchestrate normative choice," *Nat Neurosci*, vol. 14, no. 11, pp. 1468–1474, Nov. 2011, doi: 10.1038/nn.2933.
- [39] R. N. Khushaba, C. Wise, S. Kodagoda, J. Louviere, B. E. Kahn, and C. Townsend, "Consumer neuroscience: Assessing the brain response to marketing stimuli using

- electroencephalogram (EEG) and eye tracking,” *Expert Syst Appl*, vol. 40, no. 9, pp. 3803–3812, Jul. 2013, doi: 10.1016/j.eswa.2012.12.095.
- [40] E. Dağdevir, K. Üniversitesi, T. Bilimler Meslek Yüksekokulu, E. ve Otomasyon Bölümü, and B. Cihaz Teknolojisi Programı, Kayseri, “Reklam İzlenimi Sırasında Fizyolojik Parametrelerin Analizine Dayalı Tüketici Tercihlerinin Sınıflandırılması,” 2024.
- [41] A. Ullah, G. Baloch, A. Ahmed, A. B. Buriro, A. Junaid, B. Ahmed, ve S. Akhtar, “Neuromarketing solutions based on EEG signal analysis using machine learning,” *Int. J. Adv. Comput. Sci. Appl.*, cilt. 13, no. 1, 2022.
- [42] I. H. Surov *et al.*, “EEG-Based Preference Classification for Neuromarketing Application,” *Comput Intell Neurosci*, vol. 2023, no. 1, Jan. 2023, doi: 10.1155/2023/4994751.
- [43] L. Zeng, M. Lin, K. Xiao, J. Wang, and H. Zhou, “Like/Dislike Prediction for Sport Shoes With Electroencephalography: An Application of Neuromarketing,” *Front Hum Neurosci*, vol. 15, Jan. 2022, doi: 10.3389/fnhum.2021.793952.
- [44] T. B. Alakus, M. Gonen, and I. Turkoglu, “Database for an emotion recognition system based on EEG signals and various computer games–GAMEEMO,” *Biomed Signal Process Control*, vol. 60, p. 101951, 2020.
- [45] P. Golnar-Nik, S. Farashi, and M. S. Safari, “The application of EEG power for the prediction and interpretation of consumer decision-making: A neuromarketing study,” *Physiol Behav*, vol. 207, pp. 90–98, Aug. 2019, doi: 10.1016/j.physbeh.2019.04.025.
- [46] L. M. Soria Morillo, J. A. Alvarez-Garcia, L. Gonzalez-Abril, and J. A. Ortega Ramírez, “Discrete classification technique applied to TV advertisements liking recognition system based on low-cost EEG headsets,” *Biomed Eng Online*, vol. 15, Jul. 2016, doi: 10.1186/s12938-016-0181-2.
- [47] L. H. Chew, J. Teo, and J. Mountstephens, “Aesthetic preference recognition of 3D shapes using EEG,” *Cogn Neurodyn*, vol. 10, no. 2, pp. 165–173, Apr. 2016, doi: 10.1007/s11571-015-9363-z.

- [48] D. Baldo, H. Parikh, Y. Piu, and K. M. Müller, “Brain Waves Predict Success of New Fashion Products: A Practical Application for the Footwear Retailing Industry,” *Journal of Creating Value*, vol. 1, no. 1, pp. 61–71, May 2015, doi: 10.1177/2394964315569625.
- [49] M. Yadava, P. Kumar, R. Saini, P. P. Roy, and D. Prosad Dogra, “Analysis of EEG signals and its application to neuromarketing,” *Multimed Tools Appl*, vol. 76, no. 18, pp. 19087–19111, Sep. 2017, doi: 10.1007/s11042-017-4580-6.
- [50] S. Kumar, M. Yadava, and P. P. Roy, “Fusion of EEG response and sentiment analysis of products review to predict customer satisfaction,” *Information Fusion*, vol. 52, pp. 41–52, Dec. 2019, doi: 10.1016/j.inffus.2018.11.001.
- [51] C. R. Amin, M. F. Hasin, T. S. Leon, A. B. Aurko, T. Tamanna, M. A. Rahman, ve M. Z. Parvez, “Consumer behavior analysis using EEG signals for neuromarketing application,” *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 2061–2066, Dec. 2020.
- [52] M. Aldayel, M. Ykhlef, and A. Al-Nafjan, “Consumers’ Preference Recognition Based on Brain–Computer Interfaces: Advances, Trends, and Applications,” *Arab J Sci Eng*, vol. 46, no. 9, pp. 8983–8997, Sep. 2021, doi: 10.1007/s13369-021-05695-4.
- [53] M. Alimardani and M. Kaba, “Deep Learning for Neuromarket-ing; Classification of User Preference using EEG Signals,” 2021, doi: 10.1145/3460881.
- [54] D. Panda, D. Das Chakladar, S. Rana, and S. Parayitam, “An EEG-based neuro-recommendation system for improving consumer purchase experience,” *Journal of Consumer Behaviour*, vol. 23, no. 1, pp. 61–75, Jan. 2024, doi: 10.1002/cb.2142.
- [55] D. Panda, D. Das Chakladar, S. Rana, and M. N. Shamsudin, “Spatial Attention-Enhanced EEG Analysis for Profiling Consumer Choices,” *IEEE Access*, vol. 12, pp. 13477–13487, 2024, doi: 10.1109/ACCESS.2024.3355977.
- [56] A. Upadhyay, A. Dubey, P. Goenka, and S. M. Kuriakose, “NMNet: Spatial-Temporal Transformer for EEG Signal Analysis in Neuromarketing,” in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Jan. 2024, pp. 474–478. doi: 10.1145/3632410.3632472.

- [57] M. Ouzir, H. Chakir Lamrani, R. L. Bradley, and I. El Moudden, "Neuromarketing and decision-making: Classification of consumer preferences based on changes analysis in the EEG signal of brain regions," *Biomed Signal Process Control*, vol. 87, Jan. 2024, doi: 10.1016/j.bspc.2023.105469.
- [58] A. Çakır and S. Koçkanat, "Notch Filter Design with the Help of Modified Artificial Bee Colony (MABC) Algorithm to Eliminate Network Noise on the ECG Signal EKG İşareti Üzerindeki Şebeke Gürültüsünün Yok Edilmesi İçin Modifiye Yapay Arı Kolonisi (MABC) Algoritması Yardımıyla Çentik Filtre Tasarımı," 2024.
- [59] J. G. Proakis and D. G. Manolakis, *Digital Signal Processing: Principles, Algorithms, and Applications*, 1996.
- [60] S. Haykin and B. Van Veen, *Signals and systems*. John Wiley & Sons, 2007.
- [61] S. K. Mitra, *Digital signal processing: a computer-based approach*. McGraw-Hill Higher Education, 2001.
- [62] L. Sörnmo and P. Laguna, *Bioelectrical signal processing in cardiac and neurological applications*. Academic press, 2005.
- [63] A. Savitzky and M. J. E, "Smoothing and Differentiation of Data by Simplified Least Squares Procedures," 1951. [Online]. Available: <https://pubs.acs.org/sharingguidelines>
- [64] S. Hargittai, "Savitzky-Golay Least-Squares Polynomial Filters in ECG Signal Processing," 2005.
- [65] N. Sakib, M. K. Islam, and T. Faruk, "Machine Learning Model for Computer-Aided Depression Screening among Young Adults Using Wireless EEG Headset," *Comput Intell Neurosci*, vol. 2023, no. 1, Jan. 2023, doi: 10.1155/2023/1701429.
- [66] B. Bein, "Entropy," *Best Practice & Research Clinical Anaesthesiology*, vol. 20, no. 1, pp. 101–109, 2006.
- [67] C. Tsallis, "The nonadditive entropy S_q and its applications in physics and elsewhere: Some remarks," 2011, *MDPI AG*. doi: 10.3390/e13101765.

- [68] M. Costa, A. L. Goldberger, and C.-K. Peng, “Multiscale entropy analysis of biological signals,” *Physical Review E—Statistical, Nonlinear, and Soft Matter Physics*, vol. 71, no. 2, p. 021906, 2005.
- [69] A. Subasi, *Practical guide for biomedical signals analysis using machine learning techniques: A MATLAB based approach*. Academic Press, 2019.
- [70] S. Sanei and J. A. Chambers, *EEG signal processing*. John Wiley & Sons, 2013.
- [71] D. N. Joanes and C. A. Gill, “Comparing measures of sample skewness and kurtosis,” *Journal of the Royal Statistical Society: Series D (The Statistician)*, vol. 47, no. 1, pp. 183–189, 1998.
- [72] R. R. Wilcox, *Fundamentals of modern statistical methods: Substantially improving power and accuracy*, vol. 249. Springer, 2001.
- [73] R. B. Randall and V. C. Monitoring, “Industrial, aerospace and automotive applications,” *Vibration-Based Condition Monitoring*. West Sussex, pp. 13–20, 2011.
- [74] K. Ogata, *Modern control engineering*. Prentice Hall India, 2009.
- [75] E. Niedermeyer and F. H. L. da Silva, *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins, 2005.
- [76] P. D. Welch, “The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms $I_k(f_n) = I_A h(\%) [a_k]$,” 1967.
- [77] P. Stoica and R. L. Moses, *Spectral analysis of signals*, vol. 452. Citeseer, 2005.
- [78] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, “A review of classification algorithms for EEG-based brain-computer interfaces,” Jun. 01, 2007. doi: 10.1088/1741-2560/4/2/R01.
- [79] T. M. Mitchell and T. M. Mitchell, *Machine learning*, vol. 1, no. 9. McGraw-hill New York, 1997.

- [80] Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21–27, Jan. 1967, doi: 10.1109/TIT.1967.1053964.
- [81] M. Pal, "Random forest classifier for remote sensing classification," *Int J Remote Sens*, vol. 26, no. 1, pp. 217–222, Jan. 2005, doi:10.1080/01431160412331269698.
- [82] E. Öztemel, "Yapay sinir ağları," *PapatyaYayincilik, Istanbul*, 2003.
- [83] D. M. Powers, "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [84] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf Process Manag*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.
- [85] P. Domingos, "A few useful things to know about machine learning," *Commun ACM*, vol. 55, no. 10, pp. 78–87, 2012.
- [86] K. F. Man, K. S. Tang, S. Kwong, K. F. Man, K. S. Tang, and S. Kwong, "Genetic algorithms in production planning and scheduling problems," *Genetic Algorithms: Concepts and Designs*, pp. 259–280, 1999.
- [87] A. Lambora, K. Gupta, and K. Chopra, "Genetic algorithm-A literature review," in *2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)*, IEEE, 2019, pp. 380–384.
- [88] D. M. Powers, "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [89] Y. Zhou, "Study on genetic algorithm improvement and application," Ph.D. dissertation, Worcester Polytechnic Institute, 2006.
- [90] E. Ufuk ERGÜL, A. Üniversitesi, T. Fakültesi, and E.-E. Mühendisliği Bölümü, "Çok Amaçlı Genetik Algoritma Yöntemlerinin Başarımının Belirlenmesi İçin İki Yeni Ölçüt Önerisi," 2015.

- [91] T. Murata and H. Ishibuchi, “MOGA: multi-objective genetic algorithms,” in *IEEE international conference on evolutionary computation*, IEEE Piscataway, 1995, pp. 289–294.
- [92] H. Ishibuchi and Y. Shibata, “Single-Objective and Multi-Objective Evolutionary Flowshop Scheduling,” in *Applications of Multi-Objective Evolutionary Algorithms*, World Scientific, 2004, pp. 529–554.
- [93] S. Syamsudin and R. Rahim, “Study approach technique for order of preference by similarity to ideal solution (TOPSIS),” *Int. J. Recent Trends Eng. Res*, vol. 3, no. 3, pp. 268–285, 2017.



TEZ İNTİHAL RAPORU

Suzan SABAN Yüksek Lisans Tezi

ORJİNALLIK RAPORU

% 5	% 3	% 3	% 2
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

ÖĞRENCİ KAYNAKLAR

1	acikbilim.yok.gov.tr İnternet Kaynağı	<% 1
2	polen.itu.edu.tr İnternet Kaynağı	<% 1
3	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	<% 1
4	web.deu.edu.tr İnternet Kaynağı	<% 1
5	docplayer.biz.tr İnternet Kaynağı	<% 1
6	Submitted to Karadeniz Teknik University Öğrenci Ödevi	<% 1
7	Mustafa Seker, Mahmut Tokmakci, Musa Hakan Asyali, Hatice Segmen. "Examining EEG signals with parametric and non-parametric analyses methods in migraine patients during pregnancy", 2010 15th National Biomedical Engineering Meeting, 2010 Yayın	<% 1
8	www.researchgate.net İnternet Kaynağı	<% 1
9	www.ozguryayinlari.com İnternet Kaynağı	<% 1
10	www.turmob.org.tr İnternet Kaynağı	<% 1

22	www.aysetolga.com İnternet Kaynağı	<% 1
23	Submitted to Yonsei University Öğrenci Ödevi	<% 1
24	acikerisim.sakarya.edu.tr İnternet Kaynağı	<% 1
25	Submitted to Bülent Ecevit Üniversitesi Öğrenci Ödevi	<% 1
26	9lib.net İnternet Kaynağı	<% 1
27	Burak Ceylan, Serkan Tuzun, Aydin Akan. "An EEG Based Liking Status Detection Method for Neuromarketing Applications", 2020 28th Signal Processing and Communications Applications Conference (SIU), 2020 Yayın	<% 1
28	Submitted to Firat Üniversitesi Öğrenci Ödevi	<% 1
29	Submitted to ALKEV Öğrenci Ödevi	<% 1
30	Submitted to Beykent Üniversitesi Öğrenci Ödevi	<% 1
31	Submitted to Istanbul Medipol Üniversitesi Öğrenci Ödevi	<% 1
32	Submitted to Police Academy Öğrenci Ödevi	<% 1
33	dergipark.org.tr İnternet Kaynağı	<% 1
34	fc5df1b7-ace4-4336-87e5-47fe13907584.filesusr.com İnternet Kaynağı	<% 1
35	acikerisim.pau.edu.tr:8080 İnternet Kaynağı	

- 63 Arvind Dagur, Karan Singh, Pawan Singh Mehra, Dharendra Kumar Shukla. "Intelligent Computing and Communication Techniques - Volume 3", CRC Press, 2025
Yayın <% 1
-
- 64 Jneed, Hikmet. "İşletmelerde Finansal Bilgi Manipülasyonunun Beneish Modeli ile Tespiti ve Topsis Yöntemi ile Performans Ölçümleri : Borsa İstanbul'da Gıda İşletmelerinde bir Uygulama.", Marmara Üniversitesi (Turkey)
Yayın <% 1
-
- 65 KARAKOYUN, Murat and HACIBEYOĞLU, Mehmet. "BİYOMEDİKAL VERİ KÜMELERİ İLE MAKİNE ÖĞRENMESİ SINIFLANDIRMA ALGORİTMALARININ İSTATİSTİKSEL OLARAK KARŞILAŞTIRILMASI", Dokuz Eylül Üniversitesi Mühendislik Fakültesi, 2014.
Yayın <% 1
-
- 66 Karahasanoğlu, Melih. "Sağlık Sektöründe Müşteri Kayıp Analizi ve Veri Madenciliği ile bir Uygulama", Bursa Uludag University (Turkey), 2023
Yayın <% 1
-
- 67 Yücel, Yakup Bahadır. "Çok kriterli karar verme teknikleri ile tekstil sektöründe en uygun tedarikçi seçimi ve bir yazılım uygulaması", Bartın University (Turkey), 2024
Yayın <% 1
-

Ayrılan çıktı

Kapat

Eşleştirmeleri çıkar

Kapat

Bibliyografyayı Okut

Kapat

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	Suzan SABAN
------------	-------------

EĞİTİM BİLGİLERİ

Derece	Kurum	Mezuniyet Yılı
Lise	Fatih Lisesi, Elazığ	2001
Ön Lisans	Biyomedikal Cihazlar Teknolojisi, Fırat Üniversitesi, Elazığ	2003
Lisans	Elektrik-Elektronik Mühendisliği, Erciyes Üniversitesi, Kayseri	2015

EĞİTİM BİLGİLERİ

Dil	Derece
İngilizce	Temel Seviye

İŞ DENEYİMLERİ

Derece	Kurum	Görev Süresi
2/1	Erciyes Üniversitesi, Klinik Mühendisliği Araştırma ve Uygulama Merkezi, Biyomedikal Teknikeri (Kalibrasyon Uzmanı)	15 yıl

YAYINLAR

S. Saban and E. Dağdevir, “Biomedical signal processing methods for neuromarketing: A comparative study”, 5th International Conference on Applied Engineering and Natural Sciences, Konya, Turkey, 2023.



Uygulama ve Proje Odaklı, İş Dünyası ile Bütünleşen Üniversite

