T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

Nöropazarlama Uygulamaları için EEG Sinyallerinin Analizi ile Beğeni Durum Tespiti

Burak CEYLAN

DANIŞMAN
Prof. Dr. Fırat KAÇAR

II. DANIŞMAN
Prof. Dr. Aydın AKAN

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği, Doktora Programı

Haziran, 2024

TEZ KABUL VE ONAYI

Burak CEYLAN tarafından, **Prof. Dr.** Fırat KAÇAR danışmanlığında hazırlanan **"Nöropazarlama Uygulamaları İçin EEG Sinyallerinin Analizi ile Beğeni Durum Tespiti"** başlıklı bu çalışma, jürimiz tarafından **03/06/2024** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	Sonuç
DANIŞMAN	Prof. Dr. Fırat KAÇAR İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Yasin ÖZCELEP İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Onur OSMAN İstanbul Topkapı Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Cengiz Polat UZUNOĞLU İstanbul Üniversitesi-Cerrahpaşa Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Yalçın ÇEKİÇ Bahçeşehir Üniversitesi Mekatronik Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Burak CEYLAN

(İmza)

Annem, Babam, Kardeşlerim, Eşim ve Oğluma ithaf ediyorum…

BÜTÇE DESTEKLERİ

Nöropazarlama Uygulamaları İçin EEG Sinyallerinin Analizi ile Beğeni Durum Tespiti

Bu tez çalışması, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 123E667 numaralı projesi ile desteklenmiştir.

TEŞEKKÜR

Doktora eğitimimin İstanbul Üniversitesinde başlamasının en önemli sebebi olmuştu çok kıymetli tez danışmanım Prof. Dr. Aydın AKAN, çünkü O neredeyse orayı tercih edecektim. Sonra İzmir Katip Çelebi Üniversitesine geçse de, tezimde kullandığım verilerin elde edilmesinde bile hocamın hep peşindeydim. Tezimin başlangıcından sonuna kadar yaşadığım zorluklarda hep arkamda olduğu, bana yön verdiği için çok teşekkür ederim.

Akademik hayatımda tanıdığım ender kişilerden olan, her derdimi ve fikrimi paylaşabildiğim, yol gösterici bilgi ve fikirleriyle samimiyetini benden esirgemeyen değerli tez danışmanım Prof. Dr. Fırat KAÇAR hocama şükranlarımı sunuyorum.

Abi kardeş gibi yakın gördüğüm, mesailerimizi beraber, tezlerimizi yan yana yazdığımız, içindeki eşsiz cevheri kendisinin farkında olmadığını düşündüğüm, farklı fikirlerde olduğumuz konularda bile konuşabildiğimiz, benim için çok değerli olan Mühendis Serkan TÜZÜN'e teşekkür ederim.

Tez sürecinde beni her defasında yüreklendiren mesai arkadaşlarım Dr. Sedat KILINÇ, Arş. Gör. Sedat İN, Dr. Merve DOĞRUYOL BAŞAR, Dr. Yeşim HEKİM TANÇ'a, veri seti alımında bana yardımcı olan arkadaşım Dr. Ziyşan Buse YARALI ÇEVİK'e, İzmir Kâtip Çelebi Üniversitesi akademik çalışanlarına ve beni sürekli bilgilendiren Dr. Serkan ÇİZMECİOĞULLARI'na teşekkür ederim.

Etik kurul onay alımında değerli vakitlerini ayırdığı için Doç. Dr. Hatice Sabiha TÜRE hocama teşekkürlerimi sunuyorum.

Sadece tez sürecim de değil her zaman arkamda olduklarını bildiğim bir çınar gibi gölgelerinde kendimi güvende hissettiğim, beni bu dünyaya hazırlayan, her düştüğümde beni kaldıran canım anneme, babama ve beni destekleyen kardeşlerime teker teker teşekkür ederim.

Bu süreçte bana sabreden, beni motive eden, bu dünyadaki varlığıyla beni şanslı hissettiren hayat arkadaşım, yol arkadaşım Sevgili Eşim Zekiye Ceylan'a ve belki de hayattaki yaşama sevincimi yeniden kazandıran Aslan oğlum Yunus Selim'e teşekkür ederim.

Burada sayamadığım ama yanımda olan herkese teşekkür ederim.

Haziran 2024 **Burak CEYLAN**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xi**
SİMGE VE KISALTMA LİSTESİ ..... **xiii**
ÖZET ..... **xv**
ABSTRACT ..... **xvii**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **4**
2.1. NÖROPAZARLAMA 4
2.2. NÖROPAZARLAMADA KULLANILAN NÖROBİLİMSEL YÖNTEMLER 4
2.2.1. Beyin İçindeki Sinirsel Aktiviteyi Kaydeden Metabolik Aktivite Temelli Yöntemler 5
2.2.2. Beyindeki Sinirsel Aktiviteyi Kaydeden Elektromanyetik Aktiviteye Dayalı Nörobilimsel Yöntemler 6
2.2.3. Beyin Dışındaki Sinirsel Aktiviteyi Gözlemlemeye Yönelik Diğer Nörobilimsel Yöntemler ve Araçlar 10
2.3. ZAMAN-FREKANS YÖNTEMLERİ 13
2.3.1. Yaygın Kullanılan Zaman-Frekans Yöntemleri 13
2.3.2. Kısa Zamanlı Fourier Dönüşümünü (STFT) 14
2.3.3. Görgül Kip Ayrışımı (GKA) 16
2.3.4. Grup Görgül Kip Ayrışımı (GGKA) 20
2.3.5. Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA) 24
3. YÖNTEM **26**
3.1. VERİ SETİ 26

3.1.1. Deney Tasarımı 28
3.1.2. Veri Önişleme 31
3.2. EEG SİNYALLERİ VE MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK BEGENİ DURUM KESTİRİMİ 31
3.2.1. Öznitelik Çıkarımı 31
3.2.2. Öznitelik Seçimi 35
3.2.3. Sınıflandırma Yöntemleri 36
3.3. EEG SİNYALLERİ VE DERİN ÖĞRENME KULLANILARAK BEGENİ DURUM KESTİRİMİ 46
3.3.1. Yapay Sinir Ağları (YSA) 46
3.3.2. Derin Öğrenme 46
3.3.3. Transfer Öğrenme 48
4. BULGULAR 55
4.1. EEG SİNYALLERİ VE MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK ELDE EDİLEN BULGULAR 55
4.1.1. Görgül Kip Ayrışımı ile İlgili Sınıflandırma Sonuçları 57
4.1.2. Grup Görgül Kip Ayrışımı İle İlgili Sınıflandırma Sonuçları 60
4.1.3. Çok Değişkenli Görgül Kip Ayrışımı ile İlgili Sınıflandırma Sonuçları 65
4.2. EEG SİNYALLERİ VE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK ELDE EDİLEN BULGULAR 68
5. TARTIŞMA 75
6. SONUÇ VE ÖNERİLER 79
7. KAYNAK 80
İNTİHAL RAPORU İLK SAYFASI 85
ETİK KURUL İZİN YAZISI 86
ÖZGEÇMİŞ 89

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Bir Sinyale GKA yönteminin uygulanması 17

Şekil 2.2: GKA Akış Şeması 18

Şekil 2.3: Bir sinyalin alt ve üst zarflarının oluşturulması 19

Şekil 2.4: GGKA yönteminin akış şeması. 22

Şekil 2.5: Üç değişkenli verilerin projeksiyonları için yön vektörleri: (a) açısal örnekleme ve (b) tekdüze örnekleme [35] 25

Şekil 3.1: Elektrotların şırınga ile hazır hale getirilmesi 26

Şekil 3.2: Henüz veri alımına hazır olmayan Elektrotların Empedans değerleri. 27

Şekil 3.3: Veri alımına hazır olan Elektrotların Empedans değerleri. 27

Şekil 3.4: Mercedes Marka Arabanın Ön konsol Sorusu. 29

Şekil 3.5: Dacia Marka Arabanın ön konsol sorusu. 29

Şekil 3.6: Dacia Marka Arabanın Arka Far Sorusu. 30

Şekil 3.7: Mercedes Marka Arabanın Arka Far Sorusu. 30

Şekil 3.8: K-Katlı çapraz doğrulama akış diyagramı. 37

Şekil 3.9: Destek Vektör makineleri Sert ve Yumuşak Marj. 39

Şekil 4.1: GKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin ROC eğrisi. 60

Şekil 4.2: Dacia araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için sınıflandırma sonuçlarının grafiği. 63

Şekil 4.3: Mercedes Marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için sınıflandırma sonuçlarının grafiği. 64

Şekil 4.4: GGKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren MediumGaussianSVM sınıflandırma yönteminin ROC eğrisi. 65

Şekil 4.5: ÇDGKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin ROC eğrisi. 68

Şekil 4.6: Dacia marka, Beğenmedi sınıfına (önden görünüm) ait örnek spektrogram imgesi 69

Şekil 4.7: Mercedes Marka, Beğenmedi sınıfına (konsol) ait örnek spektrogram imgesi..... 69

Şekil 4.8: Dacia Marka Beğendi sınıfına (ızgara) ait örnek spektrogram imgesi..... 70

Şekil 4.9: Mercedes Marka, Beğendi sınıfına (önden görünüm) ait örnek spektrogram imgesi. 70

TABLO LİSTESİ

Sayfa No

Tablo 4.1: Dacia marka arabanın 71/125/250/500 örnek ile EEG verisinin pencereleme yapılmadan sınıflandırma sonuçları.....56

Tablo 4.2: Mercedes marka arabanın 71/125/250/500 örnek ile EEG verisinin pencereleme yapılmadan doğruluk sınıflandırma sonuçları. 56

Tablo 4.3: GKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu 57

Tablo 4.4: GKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu 58

Tablo 4.5: GKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 58

Tablo 4.6: GKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 59

Tablo 4.7: GKA yöntemi ile Dacia ve Mercedes marka arabaların 1000 ve 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 59

Tablo 4.8: GKA yöntemi ile Mercedes marka arabanın MediumGaussianSVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri sonucu. 60

Tablo 4.9: GGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu 61

Tablo 4.10: GGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 61

Tablo 4.11: GGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 62

Tablo 4.12: GGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 62

Tablo 4.13: GGKA yöntemi ile Dacia ve Mercedes marka arabaların 1000 ve 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 62

Tablo 4.14: Dacia marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için doğruluk sınıflandırma sonuçları.....63

Tablo 4.15: Mercedes Marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için doğruluk sınıflandırma sonuçları. 64

Tablo 4.16: GGKA yöntemi ile Mercedes marka arabanın en yüksek başarımı veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri. 65

Tablo 4.17: ÇDGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 66

Tablo 4.18: ÇDGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 66

Tablo 4.19: ÇDGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 67

Tablo 4.20: ÇDGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu. 67

Tablo 4.21: ÇDGKA yöntemi ile Mercedes marka arabanın en yüksek başarımı veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri. 68

Tablo 4.22: Dacia marka arabanın Derin Öğrenme yöntemleri ile sınıflandırma sonucu 71

Tablo 4.23: Mercedes marka arabanın Derin Öğrenme yöntemleri ile sınıflandırma sonucu . 72

Tablo 4.24: Dacia ve Mercedes marka arabaların markadan bağımsız Derin Öğrenme yöntemleri ile sınıflandırma sonucu 73

Tablo 4.25: Dacia marka arabanın en yüksek doğruluk veren yöntemlerin karşılaştırılması .. 74

Tablo 4.26: Mercedes marka arabanın en yüksek doğruluk veren yöntemlerin karşılaştırılması 74

Tablo 5.1: Literatürdeki bazı çalışmaların tablo halinde gösterimi. 78

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

σ : Standart Sapma
f : Frekans
$\overline{x}$: Ortalama

Kısaltmalar **Açıklama**

AMA : Amerikan Pazarlama Birliği
ANS : Otonom Sinir Sistemi
BCI : Beyin Bilgisayar Arayüzleri
CNN : Evrişimsel Sinir Ağı
CV : Değişkenlik katsayısı
CWT : Sürekli Dalgacık Dönüşümü
ÇDGKA : Çok Değişkenli Görgül Kip Ayrışımı
DEHB : Dikkat Eksikliği Hiperaktivite Bozukluğu
EEG : Elektroensefalogram
EEMD : Ensemble Empirical Mode Decomposition
EMD : Empirical Mode Decomposition
EKG : Elektrokardiyografi
fMRI : Fonksiyonel Manyetik Rezonans Görüntüleme
GAN : Üretken Rakip Ağlar
GGKA : Grup Görgül Kip Ayrışımı
GKA : Görgül Kip Ayrışımı
GSR : Galvanik Cilt Tepkisi
HHT : Hilbert-Huang Dönüşümü
HRV : Kalp Atış Hızı Değişkenliği
IMF : Intrinsic Mode Functions
KNN : K-en Yakın Komşu
LDA : Lineer Diskriminant Analizi

MEG : Manyetik Beyin Görüntüleme
MEMD : Multivariate Empirical Mode Decomposition
MRI : Manyetik Rezonans Görüntüleme
PET : Pozitron Emisyon Tomografisi
PSD : Güç Spektral Yoğunluğu
RBF : Radyal Temel Fonksiyon
RMS : Root Mean Square
RUS : Random Under-Sampling
SNR : Sinyal-Gürültü Oranı
SNS : Sempatik Sinir Sistemi
SSEP : Kararlı Durum Işitsel Uyarılmış Potansiyeli
SST : Kararlı Durum Topografisi
SSVEP : Kararlı Durum Görsel Uyarılmış Potansiyeli
STFT : Short Time Fourier Transform
SQUID : Süper Iletken Kuantum Girişim Cihazları
SVM : Support Vector Machines
TF : Time-frequency
ZF : Zaman-Frekans

ÖZET

[DOKTORA TEZİ]

[NÖROPAZARLAMA UYGULAMALARI İÇİN EEG SİNYALLERİNİN ANALİZİ İLE BEĞENİ DURUM TESPİTİ]

[Burak CEYLAN]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği, Doktora Programı

[Danışman : Prof. Dr. Fırat KAÇAR
II. Danışman : Prof. Dr. Aydın AKAN]

[Nöropazarlama, nörobilim ve pazarlamanın bir karışımıdır. Beynin pazarlama uyaranlarına nasıl tepki verdiğini analiz ederek tüketici davranışına ilişkin daha derin bilgiler sağlaması açısından önemlidir. Bu yaklaşım, bilinçaltı tercihleri ve duyguları ortaya çıkararak anket gibi geleneksel yöntemlerin ötesine geçiyor. Nöropazarlama, daha etkili pazarlama stratejileri oluşturmaya, ürün tasarımını geliştirmeye, müşteri deneyimlerini geliştirmeye ve rekabet avantajı sunmaya yardımcı olabilir. Tüketici kararlarını gerçekten neyin etkilediğinin daha doğru anlaşılması açısından oldukça değerlidir.

Bu tez çalışmasında nöropazarlama uygulamalarında kullanılmak üzere elektroensefalogram (EEG) sinyallerine dayanan bir beğeni kestirim sistemi geliştirilmesi amaçlanmıştır. Katılımcılara 2 farklı ürüne ait reklam videosu izletilmiştir, video izlendiği sırada kaydedilen EEG verileri işlenerek, tüketicinin bir ürünü beğenip beğenmediği tespit edilecektir. Nöropazarlama, pazarlama ve reklam sektöründe oldukça güncel ve önemli bir araştırma konusu haline gelmiştir. Çalışmamızda video ve görüntüler izletilen katılımcılardan, 32 kanallı EEG sinyalleri, EEG kepi yardımıyla, kafa derisi üzerine yerleştirilen elektrotlar ile beğeni

durumu tespit edilmiştir. Reklam videolarının izlenmesi sonrasında katılımcılara anket uygulanarak, ürünlere ait farklı görüntülerin (Örneğin; arabanın önden görünümü, ön konsolu, yandan görünümü, arkadan görünümü, arka far, logo ve ön ızgara gibi) beğeni derecesine oy vermeleri istenmiştir.

1) Kaydedilen EEG sinyallerinden, farklı video bölgelerine karşı gelen sinyaller bölütlenmiştir.

a) GKA (Görgül Kip Ayrışımı), GGKA (Grup Görgül Kip Ayrışımı), ÇDGKA (Çok Değişkenli Görgül Kip Ayrışımı) gibi sinyal analiz yöntemleri ile kip fonksiyonlarına (ÖKF) ayrıştırılmıştır.

b) Bu ÖKF'lerden çeşitli öznitelikler elde edilmiştir[1], [2], [3], [4], [5].

c) Elde edilen öznitelikler Makine Öğrenmesi yöntemleriyle sınıflandırılmıştır.

2) Kaydedilen bu EEG sinyalleri zaman-frekans (ZF) analiz yöntemleri (dalgacık dönüşümü, kısa süreli Fourier dönüşümü) ile analiz edilerek ZF enerji dağılımları renkli resim olarak elde edilmiştir. Bu resimler evrişimsel sinir ağı (CNN) gibi derin öğrenme ağlarının eğitilmesi ve sınıflandırılması yapılarak beğeni kestirim sonuçları geliştirilmiştir. ⌋

Haziran 2024 , ⌊108.⌋ sayfa.

Anahtar kelimeler: ⌊ Nöropazarlama, Elektroensefalogram, Görgül Kip Ayrışımı, Makine Öğrenmesi, Derin Öğrenme ⌋

ABSTRACT

Ph.D. THESIS

RECOGNITION OF PREFERENCES WITH ANALYSIS OF EEG SIGNALS FOR NEUROMARKETING APPLICATIONS

Burak CEYLAN

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Biomedical Engineering

Biomedical Engineering, Doctorate Program

Supervisor : Prof. Dr. Fırat KAÇAR

Co-Supervisor: Prof. Dr. Aydın AKAN

Neuromarketing is a blend of neuroscience and marketing. It is important because it provides deeper insights into consumer behavior by analyzing how the brain responds to marketing stimuli. This approach goes beyond traditional methods such as surveys by uncovering subconscious preferences and emotions. Neuromarketing can help create more effective marketing strategies, improve product design, improve customer experiences and deliver a competitive advantage. It is very valuable for gaining a more accurate understanding of what really influences consumer decisions.

In this thesis study, it is aimed to develop a liking estimation system based on electroencephalogram (EEG) signals to be used in neuromarketing applications. The subjects were shown advertising videos for 2 different products. The EEG data recorded while watching the video will be processed to determine whether the consumer liked a product or not. Neuromarketing has become a very current and important research topic in the marketing and advertising industry. In our study, the liking status of the subjects who were shown videos and

images was determined by using 32-channel EEG signals and electrodes placed on the scalp with the help of an EEG cap. After watching the advertising videos, a survey was administered to the subjects and they were asked to vote on the degree of liking of different images of the products (for example, the front view of the car, the front console, the side view, the rear view, the taillight, the logo and the front grille).

1) From the recorded EEG signals, signals corresponding to different video regions were segmented.

a) It is decomposed into intrinsic mode functions (IMF) by signal analysis methods such as EMD (Empirical Mode Decomposition), EEMD (Ensemble Empirical Mode Decomposition), MEMD (Multivariate Empirical Mode Decomposition).

b) Various attributes were obtained from these IMFs. [1-5].

c) The obtained features were classified with Machine Learning methods.

2) These recorded EEG signals were analyzed with time-frequency (TF) analysis methods (wavelet transform, short-term Fourier transform) and TF energy distributions were obtained as color images. These images were trained and classified by deep learning networks such as convolutional neural network (CNN) and liking estimation results were developed.

]

June 2024, [108.] pages.

Keywords: [Neuromarketing, Electroencephalogram, Empirical Mode Decomposition, Machine Learning, Deep Learning]

1. GİRİŞ

Küreselleşen, değişen ve gelişen teknolojinin etkisiyle, yeni trendlerin takibi, insanların birbiriyle iletişimi ve etkileşiminin arttığı, bilgiye erişimin çok hızlı olduğu günümüzde, şirketlerin rekabet edebilmesi, varlıklarını devam ettirebilmesi ve kar edebilmesi için şirketlerin tüketici algısını çok iyi organize etmesi gerekmektedir.

Algı yönetiminin tanımı ve kavramı ABD Ordusu tarafından geliştirilmiş olsa da birçok alanda kullanılmaktadır. Pazarlamada tüketici algı yönetiminin, yeni tüketicilere ulaşmayı, markanın bilinirliğini ve güvenilirliğini artırmayı, belirli bir markanın benzer markalı ürünlerden üstün olduğunu tüketiciye kabul ettirmeyi ve bilinçaltını etkilemeyi, satın alma kararlarını yönetmeyi ve tüketicinin ürünü satın almasını sağlamayı gerektirdiğini söyleyebiliriz.

Bu noktada sorulması gereken mantıklı soru şu; "Bir ürünü satın alma kararını gerçekten kendimiz mi veriyoruz?" ya da bir ürünü almaya karar verdiğimizde alacağımız markaya nasıl ve neye dayanarak karar veriyoruz?

Bu soruların cevabını irdelerken, markaların reklamları, logoları, renkleri, tasarımı bilinçaltımızda bizi yönlendirdiğini hiç düşündük mü?

İnsanların ürün üretmeye başladıkları andan itibaren bilerek ya da bilmeyerek pazarlama yapmaya başladıklarını söylemek yanlış olmaz. Bu süreçte pazarlama kavramı, yaklaşımı ve yöntemleri, devrin teknolojik gelişmeleriyle sürekli değişim göstermiştir. Tarihsel sürece baktığımızda, Matbaanın icadıyla yazılı reklam yönteminin geliştiğini, Sanayi Devrimi ile makineleşme ve seri üretimin arttığı, radyo ve televizyon icadıyla görsel ve radyo reklamcılığı başlamıştır ve ardından telefon, bilgisayar internetin icadı gibi devrin çığır açan teknolojileri ile sosyal medya reklamları gelişim göstermiştir.

Amerikan Pazarlama Birliği (AMA), 1935 yılından bu yana çeşitli tarihlerde pazarlama tanımları yapmaktadır [6]. AMA tarafından 1935 yılında yapılan ilk pazarlama tanımında şöyle denilmektedir: “Pazarlama, mal ve hizmetlerin üreticiden tüketiciye akışını sağlayan işletme faaliyetidir."

1985 yılında tanım şu şekilde gelişti: ``Pazarlama, kişisel ve organizasyonel hedefleri karşılayacak değişimi yaratmak amacıyla malların, hizmetlerin ve fikirlerin geliştirilmesi, fiyatlandırılması, dağıtımı ve tutundurulmasını planlama ve yürütme sürecidir."[6]

AMA'nın 2017'deki son tanımı şu şekildedir: ``Pazarlama; müşteriler, alıcılar, iş ortakları ve genel olarak toplum için değer taşıyan tekliflerin yaratılması, iletilmesi, sunulması ve paylaşılması için yapılan faaliyet, kurumlar ve süreçler bütünüdür."[7]

Pazarlama kavramı ve anlayışı, teknolojinin gelişmesi ve pazarın küreselleşmesiyle birlikte ürün ve üretim yaklaşımından modern pazarlama yaklaşımına doğru evirilmiştir. Böylece müşterilerin istek ve talepleri doğrultusunda üretim ve satış yapan, müşteri odaklı bir satış yöntemi benimsenmiştir.

Geçmişte bilgiye erişimi sınırlı olan tüketiciler, internetin gelişip yaygınlaşmasıyla birlikte tüm dünyayla iletişim kurarak birbirleriyle bilgi paylaşmaya başlamışlardır. Modern pazarlama sürecinde, bir ürünü satın almadan önce ürün özelliklerini, fiyatlarını ve tüketici yorumlarını karşılaştırma fırsatı bulan tüketicileri memnun etmek zor hale gelmiştir. Bu durum, pazarlama profesyonellerini pazarlama tarihinde her zamankinden daha fazla zorlamaya başladı. Hem diğer üreticilerle rekabet edebilmek hem de tüketiciyi etkilemek için daha fazla çaba sarf etmelerine neden oldu.

Pazarlama çalışmaları, pazarlamanın temelini oluşturan tüketicilerin ihtiyaçlarını, beklentilerini, beğenilerini ve hoşlanmadıklarını anlamak ve satın alma davranışı kararlarını etkileyen faktörleri belirlemek amacıyla çoğunlukla tüketicilerden anket doldurmaları istenerek gerçekleştirilmektedir. Bu yöntem geliştirilmiş ve yaygın olarak kullanılmış olsa da bazı durumlarda tüketiciler etik ve kişisel kaygılardan dolayı gerçek düşüncelerini paylaşmamaktadır. Bazen araştırmanın yapıldığı ortama, toplum baskısına, o anki ruh haline göre katılımcıların tercihleri değişebiliyor ya da satın alma aşamasında ürünü gerçekten beğenip beğenmediklerine dair gerçek ruh halini tam olarak yansıtmayabiliyor.

Böylece şirketler, tüketicinin satın alma kararının merkezinde yer alan, insan vücudunun kara kutusu olan beyne odaklanmaya başladı. 21. yüzyılda pazarlama araştırmalarında nörogörüntüleme yöntemlerinin kullanılması, alana yeni bir araştırma yöntemi olan nöropazarlamayı kazandırmıştır.

Sinirbilimin bir uygulaması olan nöropazarlama, tüketicilerin pazarlanan ürün veya hizmetlere yönelik bilişsel ve duygusal tepkilerini inceleyen psikoloji, ekonomi ve pazarlama gibi disiplinleri birleştiren ekonomi alanında devrim niteliğinde bir fikirdir. Nöropazarlama geniş, disiplinlerarası bir araştırma alanıdır; sadece pazarlama uyaranlarının satışlar üzerindeki etkisine odaklanmakla kalmıyor, aynı zamanda uyaranların sunumundaki görsel farklılıkların tüketici tercihleri üzerindeki etkisini de açıklıyor. Bu uyaranlar belirli bir ürünün adının, markasının veya logosunun görseli veya videosu olabilir.

Bu tez çalışmasında, gelişmiş sinyal ayrıştırma yöntemleri, makine öğrenimi algoritmaları ve Derin Öğrenme yöntemleri kullanarak tüketicilerin bir ürünün durumunu beğenmesini tahmin etmek için çok kanallı EEG sinyallerinden yararlanıyoruz. EEG sinyallerini kullanarak beğeni durumu tespiti, beyindeki karmaşık nöronal aktivitenin neden olduğu sinyallerin durağan olmayan davranışından dolayı karmaşık bir çalışmadır. EEG sinyallerinde gizli olan bu bilgileri çıkarmak için gelişmiş sinyal işleme yöntemleri kullanılmalıdır.

2. KAVRAMSAL ÇERÇEVE

2.1. NÖROPAZARLAMA

Nöropazarlama, tüketici davranışlarını anlamak ve etkilemek için sinir bilimini pazarlamayla birleştiren ilgi çekici ve gelişen bir alandır. Reklamlar, ürünler ve fiyatlandırma stratejileri gibi pazarlama uyaranlarına verilen beyin tepkilerini ölçmek ve analiz etmek için gelişmiş sinirbilimsel tekniklerin kullanılmasını içerir [8].

Nöropazarlamanın amacı, satın alma davranışını yönlendiren bilinçaltı faktörleri ortaya çıkarmak ve bireylerin pazarlama mesajlarını nasıl algılayıp tepki verdiklerine dair iç görü sağlamaktır. Şirketler bu karmaşıklıkları anlayarak pazarlama stratejilerini optimize edebilir ve kampanyalarının etkinliğini artırabilir [9]. Nöropazarlama, pazardaki tüketici tercihlerinin ve motivasyonlarının inceliklerini ortaya çıkarmak için bilinçaltından yararlanarak geleneksel pazar araştırma yöntemlerinin ötesine geçer. Karar almayı şekillendirmek ve etkili stratejiler oluşturmak için değerli bilgiler sağlamak üzere psikoloji, sinir bilimi ve pazarlamadan yararlanır [10].

2.2. NÖROPAZARLAMADA KULLANILAN NÖROBİLİMSEL YÖNTEMLER

Nörobilimsel yöntemler, tüketici davranışlarına ilişkin nesnel ve kesin bilgiler sağlayarak nöropazarlama alanının ilerlemesinde önemli bir rol oynamaktadır. Bu yöntemler, araştırmacıların beyin aktivitesini ve fizyolojik tepkileri doğrudan ölçmesine olanak tanıyarak bireylerin bilgiyi nasıl işlediğini, karar verdiğini ve tercihleri nasıl oluşturduğunu daha iyi anlamasına olanak tanır. Bu düzeydeki doğruluk ve ayrıntı çok önemlidir çünkü pazarlamacıların, geleneksel tekniklerin genellikle yakalayamadığı tüketicilerin bilinçaltı tepkilerine ilişkin değerli bilgiler edinmesine yardımcı olur [8].

Araştırmacılar, fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), Elektroensefalografi (EEG) ve Pozitron Emisyon Tomografisi (PET) gibi nörogörüntüleme tekniklerini kullanarak, pazarlama uyaranlarına yanıt olarak beyin aktivasyon modellerini değerlendirerek duygusal katılım, dikkat ve hafızaya ilişkin iç görüler sağlayabilirler [11], [12], [13], [14]. Ek olarak göz izleme teknolojisi, tüketicinin dikkatini ve tercihlerini anlamaya yardımcı olan görsel dikkat ve

bakış kalıpları hakkında kesin veriler sunar [15], [16]. Galvanik Cilt Tepkisi (GSR), Kalp Atış Hızı Değişkenliği (HRV) ve Yüz İfadesi Analizi gibi biyometrik ölçümler, pazarlama uyaranlarının uyandırdığı duygusal uyarılma ve fizyolojik tepkiler hakkında bilgi sağlar [17], [18]. Genel olarak, nöropazarlamada nörobilimsel yöntemlerin benimsenmesi, pazarlamacıların tüketici davranışı hakkında daha derin bir anlayış kazanmalarına ve tüketici davranışı analizi, reklamcılık ve markalamanın yanı sıra ürün geliştirme ve paketleme için daha etkili stratejiler geliştirmelerine olanak tanıyarak alanda devrim yarattı.

Sinirbilimcilerin davranış sırasında meydana gelen sinirsel süreçleri gerçek zamanlı olarak gözlemlemelerine olanak tanıyan bu yöntemler, üç geniş kategoriye ayrılabilir: Beyin içindeki sinirsel aktiviteyi kaydeden metabolik aktivite temelli, Beyin içindeki sinirsel aktiviteyi kaydeden elektromanyetik aktivite temelli ve Beyin dışındaki sinirsel aktiviteyi kaydeden sinirbilimsel yöntemler ve araçlar.

2.2.1. Beyin İçindeki Sinirsel Aktiviteyi Kaydeden Metabolik Aktivite Temelli Yöntemler

2.2.1.1. Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI)

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), sinirbilim araştırmalarında ve tıbbi teşhislerde yaygın olarak kullanılan, invaziv olmayan bir görüntüleme tekniğidir. Bilim adamlarının ve klinisyenlerin kandaki oksijen seviyelerindeki değişiklikleri ölçerek beyin aktivitesini incelemesine olanak tanır ve beynin işlevsel organizasyonuna dair iç görüler sağlar. Belirli görevlere veya bilişsel süreçlere dahil olan beyin bölgelerini görselleştiren fMRI, insan beyni ve onun karmaşık işleyişine ilişkin anlayışımızda devrim yarattı. Bu teknolojinin psikoloji, klinik araştırma ve bilişsel sinir bilimi de dahil olmak üzere çeşitli alanlar için önemli etkileri vardır [11].

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), beyindeki kan akışı ve oksijenasyon seviyelerindeki değişiklikleri ölçmek ve görselleştirmek için manyetik rezonans görüntüleme (MRI) teknolojisini kullanan özel bir görüntüleme tekniğidir. Nöral aktivitenin, kan oksijen düzeyine bağlı (BOLD) kontrastı olarak bilinen, kan oksijenlenmesinde değişiklikler yaratması ilkesine dayanır. fMRI, bu değişiklikleri tespit ederek farklı bilişsel süreçlere ve görevlere dahil olan beyin bölgelerini tanımlayabilir ve beyin fonksiyonu ve bağlantısına ilişkin değerli bilgiler sağlayabilir [12], [19].

Fonksiyonel Manyetik Rezonans Görüntülemenin (fMRI) gelişimi, bilim adamlarının MRI tarayıcılarını kullanarak kan oksijenlenmesindeki değişiklikleri tespit etmenin mümkün olduğunu keşfettiği 1990'ların başlarına kadar uzanabilir. Seiji Ogawa ve meslektaşlarının 1990 yılındaki çığır açan çalışması, sinirsel aktivite, kan akışı ve sonuçta ortaya çıkan manyetik rezonans sinyali arasındaki bağlantıyı göstererek fMRI'nin yolunu açtı [20]. Bu keşif, nörogörüntülemede önemli gelişmelere yol açarak araştırmacıların beyin fonksiyonlarını ve bilişi daha iyi uzaysal ve zamansal çözünürlükle araştırmasına olanak tanıdı. O zamandan bu yana fMRI sinir biliminde vazgeçilmez bir araç haline geldi ve insan beyni ve bozukluklarına ilişkin anlayışımızın ilerlemesine yardımcı oldu [21].

2.2.1.2. Pozitron emisyon tomografisi (PET)

Pozitron emisyon tomografisi (PET), nörobilimde sıklıkla kullanılan bir görüntüleme tekniğidir. PET, beyindeki nöronların aktivitesini ölçmek için kullanılan bir yöntemdir [22]. PET, radyofarmasötik bir madde enjekte edilerek uygulanır. Bu madde, beyin hücreleri tarafından metabolize edilir ve nöronlar tarafından kullanılır. Aktif nöronlar daha fazla radyofarmasötik madde kullanır ve bu nedenle daha yoğun bir radyasyon yayarak daha belirgin bir görüntü oluştururlar. PET taramaları, beynin farklı bölgelerindeki nöron aktivitesinin ölçümüne izin verir. Bu, belirli bir görevi yaparken veya belirli bir uyaran karşısında beyinde hangi bölgelerin aktif olduğunu göstermek için kullanılır. PET taramaları, beyin fonksiyonlarına dair birçok bilgi sağlayabilir. Nörolojik bozukluklarda, beyin tümörlerinde veya nöropsikiyatrik hastalıklarda nöron aktivitesindeki değişiklikleri tespit etmek için kullanılmaktadır. Ayrıca, belirli ilaçların beyindeki etkilerini ölçmek için de kullanılabilir [23], [24].

2.2.2. Beyindeki Sinirsel Aktiviteyi Kaydeden Elektromanyetik Aktiviteye Dayalı Nörobilimsel Yöntemler

2.2.2.1. Manyetik Beyin Görüntüleme (MEG)

Manyetik Beyin Görüntüleme (MEG), beyindeki nöronal aktivitenin oluşturduğu manyetik alanları ölçmek için kullanılan, invazif olmayan bir nörogörüntüleme tekniğidir [22]. Fonksiyonel manyetik rezonans görüntüleme (fMRI) ve pozitron emisyon tomografisi (PET) gibi diğer beyin görüntüleme yöntemlerinden farklı olarak MEG, milisaniyelik zamansal çözünürlük sağlayarak araştırmacıların beyin aktivitesinin hızlı dinamiklerini yakalamasına olanak tanır. MEG, sinir ağlarındaki elektrik akımlarının ürettiği küçük manyetik alanları tespit ederek insan beyninin işleyişine dair değerli bilgiler sunuyor.

Manyetik Beyin Görüntüleme (MEG), beyindeki nöronların elektriksel aktivitelerinden kaynaklanan manyetik alanların ölçülmesi ve analizini ifade eder [25]. MEG, sinirsel elektrik akımları sonucu ortaya çıkan minik manyetik alanların, SQUID (süper iletken kuantum girişim cihazları) adı verilen süper iletken sensörler kullanılarak tespit edilmesi prensibine dayanmaktadır. MEG, bu manyetik alanları yakalayarak araştırmacıların beyin aktivitesini mükemmel zamansal çözünürlükle lokalize etmelerine ve incelemelerine olanak tanır ve bu da onu beyin fonksiyonunun çeşitli yönlerini araştırmak için değerli bir araç haline getirir.

İlk MEG cihazının geliştirildiği 1960'lı yıllara kadar uzanan zengin bir geçmişi vardır [26]. Yıllar geçtikçe MEG teknolojisi, sensör tasarımı, veri toplama ve analiz tekniklerindeki gelişmelerle birlikte gelişti. Dikkate değer kilometre taşları arasında kask şeklindeki sensörlerin kullanıma sunulması, geliştirilmiş gürültü azaltma stratejileri ve MEG'in fMRI ve EEG gibi diğer beyin görüntüleme yöntemleriyle entegrasyonu yer alıyor. MEG'in geliştirilmesi ve iyileştirilmesi, beyin fonksiyonuna ilişkin anlayışımıza büyük katkıda bulunmuş ve biliş ve nörolojik bozuklukların araştırılmasında yeni yollar açmıştır [27].

2.2.2.2. Elektroensefalografi (EEG)

Beynin elektriksel aktivitesini ölçmek için kullanılan nörofizyolojik bir yöntemdir. Beyindeki nöronlar tarafından üretilen elektriksel potansiyelleri kaydeden ve beyin işlevi ve işlev bozukluğu hakkında değerli bilgiler sağlayan invazif olmayan bir tekniktir. EEG, araştırmacıların beyin aktivitesini gerçek zamanlı olarak incelemelerine olanak tanıyarak bilişsel süreçlere, sinirsel gelişime ve nörolojik bozukluklara yönelik bir pencere sağlar. Beyin nöronları tarafından üretilen elektrik sinyallerini tespit etmek ve ölçmek için kafa derisine elektrotların yerleştirilmesini içerir. Nöral salınımlar veya beyin dalgaları olarak bilinen bu sinyaller, milyonlarca nöronun kolektif aktivitesinin sonucudur. EEG beyin fonksiyonu hakkında değerli bilgiler sağlar ve dikkat, hafıza ve uyku gibi bilişin çeşitli yönlerini incelemek için kullanılabilir. Kaydedilen EEG sinyalleri, beyin durumlarını ve süreçlerini anlamak için daha fazla analiz edilebilecek ilgili bilgileri çıkarmak için güçlendirilir ve işlenir. EEG, klinik ortamlarda epilepsi ve uyku bozuklukları gibi nörolojik bozuklukları teşhis etmek ve izlemek için yaygın olarak kullanılmaktadır. Aynı zamanda araştırmalarda da yaygın olarak kullanılıyor ve bilim adamlarının davranışın sinirsel bağıntılarını araştırmasına ve beyin dinamiklerini incelemesine olanak tanıyor. Çok yönlülüğü ve invazif olmayan yapısıyla EEG, sinir bilimi alanında vazgeçilmez bir araç haline geldi.

Elektroensefalografi (EEG), 19. yüzyılın sonlarına kadar uzanan zengin bir tarihsel geçmişe sahiptir. 1875 yılında İngiliz Doktor Richard Caton, beynin elektriksel aktivitesini araştıran ilk deneylerden birini gerçekleştirdi. Hayvanların açıkta kalan beyin korteksindeki voltaj değişikliklerini kaydetti. Alman psikiyatrist Hans Berger'in EEG'de önemli ilerlemeler kaydetmesi ancak 20. yüzyılın başlarında gerçekleşti. 1924 yılında Berger, kafa derisine yerleştirilen elektrotları kullanarak insan beyin dalgalarını başarıyla kaydetti. "Elektroensefalogram" terimini icat etti ve konuyla ilgili ufuk açıcı çalışmasını yayınladı [28]. Berger'in keşifleri, beynin elektriksel aktivitesinin daha fazla araştırılması ve anlaşılmasının yolunu açtı. Yıllar geçtikçe, elektrot tasarımı, sinyal amplifikasyonu ve veri analizi tekniklerindeki gelişmelerle birlikte EEG teknolojisi gelişti. Bugün EEG, sinir bilimi, bilişsel psikoloji ve klinik araştırma dahil olmak üzere çeşitli akademik alanlarda önemli bir rol oynamaya devam ediyor [29].

EEG, nöronlar tarafından üretilen elektrik sinyallerini ölçen kafa derisine küçük elektrotlar yerleştirerek beynin elektriksel aktivitesini kaydeder. Elektrotlar, elektroensefalografi (EEG) yoluyla elektriksel beyin aktivitesinin yakalanmasında çok önemli bir rol oynar. Bu sensörler tipik olarak gümüş veya altın gibi iletken malzemelerden yapılır ve optimum elektrik iletkenliğini sağlar. Elektrot yerleştirme, Uluslararası 10-20 Sistemi olarak bilinen ve farklı kafa derisi bölgeleri arasında hassas konumlandırmayı içeren yerleşik bir standart sistemi takip eder. Bu sistem, EEG kayıtları için tutarlı ve tekrarlanabilir elektrot yerleşimleri sağlayarak araştırmacıların ve klinisyenlerin verileri doğru bir şekilde karşılaştırmasına olanak tanır. Bu sistemde, "10-20" terimi elektrotların kafatası üzerindeki dağılımını belirtir. Elektrotların yerleştirilmesi, EEG çalışmasının özel hedeflerine bağlıdır; farklı elektrot konfigürasyonları, farklı beyin alanlarının incelenmesine olanak tanır. EEG'de kullanılan yaygın elektrot türleri arasında, invaziv olmayan kayıtlar için yüzey elektrotları (örn., Ag/AgCl) ve invazif kayıtlar için intrakranyal elektrotlar bulunur.

Her elektrotun bir ismi var ve bu isimler elektriksel aktiviteyi ölçmek istenen beyin bölgesini temsil eder. İsimler genellikle harf ve rakamlardan oluşur. Harf, beyin bölgesinin türünü belirtirken, rakam elektrotun belirli bir yüzde oranını gösterir.

Harf Kodları: Harfler beyin bölgelerini belirtir. Örneğin:

- "F" -> Frontal (Alın)

- "T" -> Temporal (Yan)
- "C" -> Central (Merkezi)
- "P" -> Parietal (Tepe)
- "O" -> Occipital (Arka)

Elektroensefalografi (EEG), çeşitli frekanslardaki voltaj dalgalanmalarını kaydederek beyindeki elektriksel aktiviteyi ölçer. EEG'deki bu frekans bantları, kapsadıkları frekans aralığına göre kategorize edilir. EEG'deki farklı frekans bantlarını anlamak, araştırmacıların farklı beyin durumlarını ve bilişsel işlevleri etkili bir şekilde incelemesine ve yorumlamasına olanak tanır. Bu sinyaller daha sonra EEG dalga formu olarak adlandırılan beynin elektriksel aktivitesinin görsel bir görüntüsünü üretmek, istenmeyen gürültü ve artefaktları ortadan kaldırmak için kuvvetlendirilir, filtrelenir ve ardından analiz için sayısallaştırılır. Dalga formu, elektriksel aktivitenin farklı frekans aralıklarına karşılık gelen bir dizi salınım veya dalga ile karakterize edilir. EEG'de en yaygın olarak tanınan frekans bantları delta (0,5-4 Hz), teta (4-8 Hz), alfa (8-13 Hz), beta (14-30 Hz) ve gama (30-100 Hz) dalgalarıdır. Her frekans bandı belirli bilişsel ve fizyolojik süreçlerle ilişkilidir. Delta dalgaları tipik olarak derin uyku sırasında gözlemlenir ve bilinçsiz işlemlerle ilişkilendirilir. Teta dalgaları hayal kurma ve meditasyon durumlarıyla bağlantılıdır. Alfa dalgaları gevşeme ve tembellik sırasında baskınken, beta dalgaları aktif düşünme ve konsantrasyonla ilişkilidir. Son olarak gama dalgaları, hafıza oluşumu ve sinir senkronizasyonu gibi üst düzey bilişsel süreçlerle ilişkilidir.

EEG sinyali, zaman-alanı analizi, frekans-alanı analizi ve zaman-frekans analizi gibi farklı şekillerde analiz edilebilir. Zaman alanı analizi, EEG dalgalarının ve süresini analiz etmeyi içerirken, frekans alanı analizi, farklı frekans bantlarındaki EEG sinyallerinin gücünü ve koheransını analiz etmeyi içerir. Zaman-frekans analizi, EEG sinyalinin daha ayrıntılı bir görünümünü sağlamak için hem zaman-alanı hem de frekans-alanı analizini birleştirir.

EEG'nin nörofeedback ve beyin-bilgisayar arayüzleri (BCI'ler) alanında değerli bir araç olduğu kanıtlanmıştır. Neurofeedback, bireylere beyin aktiviteleri hakkında bilgi sağlamak için gerçek zamanlı EEG verilerini kullanıyor ve onlara bunu nasıl kendi kendilerini düzenleyeceklerini öğretiyor. Bu teknik, dikkat eksikliği hiperaktivite bozukluğu (DEHB), anksiyete ve epilepsi gibi çeşitli alanlarda umut verici sonuçlarla uygulanmıştır [30]. Ek olarak EEG, beyin ile harici

cihazlar arasında doğrudan iletişimi sağlayan BCI'ların temel bir bileşenidir. Belirli beyin kalıplarını tespit ederek bireyler bilgisayar programlarını, protez cihazlarını ve hatta robotik uzuvları kontrol edebilir. Bu teknoloji, motor engelli bireylerin bağımsızlığını yeniden kazanmalarına ve yaşam kalitelerini iyileştirmelerine yardımcı olma konusunda büyük bir potansiyele sahiptir. Ancak, nörofeedback ve BCI'ların doğruluğunu ve verimliliğini artırmak için sinyal işleme, özellik çıkarma ve kullanıcı eğitimi açısından hâlâ aşılması gereken zorluklar bulunmaktadır. EEG teknolojisi ve analiz tekniklerinde devam eden gelişmeler, bu alanda gelecekteki heyecan verici uygulamaların önünü açıyor.

2.2.2.3. Kararlı Durum Topografisi (SST)

Kararlı durum topografyası (Steady-State Topography, SST), beyin aktivitesinin tekrar eden bir uyarıcıya verdiği tepkiyi ölçen bir nörobilimsel yöntemdir. Bu yöntem, beyindeki elektrofizyolojik aktiviteyi kaydetmek için elektroensefalografi (EEG) kullanır. SST'nin temel prensibi, belirli bir frekansta tekrarlayan bir uyarıcı kullanarak beyinde tekrarlayan bir aktivite oluşturmaktır. Örneğin, görsel uyaran çalışmalarında, belli bir frekansta yanıp sönen bir ışık kullanılabilir. Bu uyarıcı, beyinde tekrarlayan bir yanıt oluşturacak şekilde tasarlanır. EEG sinyalleri bu uyarıcıya verilen yanıtı kaydeder ve beyindeki aktivitenin bir haritasını oluşturur. Bu teknik, belirli duyusal girdilerin işlenmesinde rol oynayan beyin bölgeleri hakkında mekansal bilgi sağlar. SST, kararlı durum görsel uyarılmış potansiyelleri (SSVEP'ler) veya kararlı durum işitsel uyarılmış potansiyelleri (SSEP'ler) kaydederek araştırmacıların beynin işlevsel organizasyonunu araştırmasına ve duyusal işleme mekanizmalarını anlamalarına olanak tanır. SST, dikkat, algı ve bellek gibi süreçlerin incelenmesinde, farklı beyin hastalıkları ve bozuklukları hakkında bilgi sağlamak için, bilişsel sinir bilimi, klinik araştırmalar ve beyin-bilgisayar arayüzü çalışmaları dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır. SST, beyin aktivitesini araştırmak için invaziv olmayan ve uygun maliyetli bir araç sunarak onu hem klinik hem de araştırma ortamlarında değerli bir araç haline getiriyor.

2.2.3. Beyin Dışındaki Sinirsel Aktiviteyi Gözlemlemeye Yönelik Diğer Nörobilimsel Yöntemler ve Araçlar

2.2.3.1. Göz Takibi

Göz Takibi, dikkat, hafıza, algı, dil, problem çözme ve karar verme gibi çeşitli bilişsel süreçleri incelemek için gelişimsel bilişsel sinirbilimde popüler bir araştırma aracı haline gelen yaygın olarak kullanılan bir nörobilimsel yöntemdir [16]. Göz Takibi, kişi bir uyaranı görüntülerken gözlerin hareketini ve sabitlenmesini ölçer. Araştırmacılar, bir kişinin bakışlarını ve sabitlenmelerini takip ederek dikkatin nasıl dağıtıldığını, hangi bilgilerin işlendiğini ve bilişsel

süreçlerin nasıl ortaya çıktığını inceleyebilir. Bu teknoloji, müdahaleci olmayan yapısı ve objektif veri sağlama yeteneği nedeniyle akademik araştırmalarda büyük önem kazanmıştır. Göz takibi, okuma ve dil çalışmaları, bilişsel psikoloji ve insan-bilgisayar etkileşimi dahil olmak üzere akademik çevredeki çeşitli alanları geliştirme potansiyeline sahiptir [15].

Göz izleme metodolojisi, kişinin bilişsel ve duygusal zihinsel durumunu anlamak ve gerçek dünya bağlamlarındaki tepkileri açıklamak için karar verme paradigmalarıyla da birleştirmektedir. Çalışmalar, göz hareketlerinin insan düşünce süreçlerini yansıttığını ve göz izlemeyi karar vermeyi anlamak için değerli bir araç haline getirdiğini göstermiştir [31].

Göz izleme teknolojisi, tıbbi yorumlama ve teşhiste yer alan algısal ve bilişsel süreçleri incelemek için de kullanılmıştır. Göz izleme çalışmaları, yorumlama sürecinin dinamikleri ve başarı ve hataların olası tahmin edicileri hakkında iç görü sağlamıştır. Başka bir çalışmada, normal ve anormal bilişsel işlemeye ilişkin fikir edinmede göz izlemenin önemini vurgulamaktadır [32].

Psikoloji alanında göz takibi; algı, dikkat ve hafıza gibi bilişsel süreçleri incelemek için kullanılmaktadır. Okuma ve dil çalışmalarında göz izleme, okuma kalıplarının analiz edilmesine, okuma güçlüklerinin belirlenmesine ve öğretim yöntemlerinin optimize edilmesine yardımcı olabilir. Ek olarak, insan-bilgisayar etkileşimi araştırmalarında göz takibi çok önemlidir; kullanıcı ara yüzlerinin, web sitesi tasarımlarının ve sanal gerçeklik sistemlerinin geliştirilmesine ve değerlendirilmesine olanak tanır. Göz izleme çalışmalarından elde edilen veriler eğitim, psikoloji, pazarlama ve diğer disiplinlerdeki kanıta dayalı uygulamalara katkı sağlayabilir.

2.2.3.2. Elektrokardiyografi

Elektrokardiyografi (EKG) kalbin elektriksel aktivitesini kaydetmek için kullanılan invazif olmayan bir teşhis aracıdır. EKG, kalp döngüsü sırasında meydana gelen elektrik potansiyelindeki değişiklikleri kaydederek kalbin elektriksel aktivitesini ölçer. Bu, kalp tarafından üretilen elektriksel impulsları algılayan göğüs, kol ve bacak derisine bir dizi elektrot yerleştirilerek gerçekleştirilir.

EKG geleneksel olarak kardiyolojide kalp fonksiyonunu izlemek için bir araç olarak kullanılırken, son yıllarda nörobilimde kalp ve beyin arasındaki ilişkiyi incelemek için bir yöntem olarak da kullanılmaktadır. Otonom sinir sistemi (ANS), diğer fizyolojik süreçlerin yanı sıra kardiyovasküler sistemin düzenlenmesinden sorumludur. ANS'nin, kalp atış hızı ve kan basıncını düzenlemek için zıt çalışan sempatik sinir sistemi (SNS) ve parasempatik sinir sistemi (PNS) olmak üzere iki kısmı vardır.

SNS, kalp atış hızını ve kan basıncını artırırken, PNS bunları azaltır. Bu iki dal arasındaki denge kalp ve damar sağlığının korunması için çok önemlidir ve bu dengenin bozulması çeşitli nörolojik ve psikiyatrik bozukluklarla ilişkilidir. EKG, SNS ve PNS arasındaki etkileşimi yansıtan kalp atış hızı değişkenliğini (HRV) ölçmek için kullanılmaktadır. HRV, ardışık kalp atışları arasındaki zamandaki değişimi ifade eder ve daha yüksek bir HRV genellikle daha iyi kardiyovasküler sağlığın bir belirteci olarak kabul edilir.

Çeşitli çalışmalar, HRV'nin bilişsel performans, duygusal düzenleme ve stres tepkisi dahil olmak üzere beyin işlevinin çeşitli yönleriyle de ilişkili olduğunu göstermiştir. Nörolojik bozuklukları teşhis etme ve izleme: Alzheimer hastalığı, Parkinson hastalığı ve epilepsi dahil olmak üzere bir dizi nörolojik bozuklukta HRV'de değişiklikler gözlemlenmiştir. Bu nedenle EKG, bu koşulları teşhis etmek ve izlemek için invaziv olmayan bir araç olarak kullanılabilir.

EKG'nin nörobilimde bir yöntem olarak kullanılması, duygusal işleme ve bilişsel işleyişin altında yatan nöral mekanizmaları anlamada umut verici sonuçlar göstermiştir. Örneğin araştırmalar, HRV'deki değişikliklerin duygusal işleme ile ilişkili olduğunu ve duygusal uyarılmanın bir indeksi olarak kullanılabileceğini göstermiştir.

Kalbin elektriksel aktivitesini değerlendirmek için kullanılan bir tanı aracı olan elektrokardiyografinin zengin bir tarihsel geçmişi vardır. Bu alanın temeli, Hollandalı fizyolog Willem Einthoven'ın 1901'de ilk pratik elektrokardiyografı geliştirmesiyle 19. yüzyılın sonlarına kadar uzanıyor. Einthoven'in icadı, bir dizi galvanometre kullanılarak kalbin ürettiği elektriksel uyarıların kaydedilmesine ve yorumlanmasına olanak tanıyordu. Çalışmaları ona 1924'te prestijli Nobel Fizyoloji veya Tıp Ödülü'nü kazandırdı. Sonraki yıllarda, Lewis ve Grant gibi doktorlar tarafından standart elektrotların kullanıma sunulması ve standartlaştırılmış EKG dalga biçimi yorumunun geliştirilmesi de dahil olmak üzere elektrokardiyografide daha fazla ilerleme kaydedildi. Yıllar geçtikçe teknolojik gelişmeler ve sinyal işleme tekniklerindeki

gelişmeler, elektrokardiyografide devrim yaratmış ve günümüzde klinik uygulamada yaygın kullanımını kolaylaştırmıştır.

2.3. ZAMAN-FREKANS YÖNTEMLERİ

Zaman-frekans yöntemleri, sinyalleri analiz etmek ve zaman içinde geliştikçe frekans içeriklerini araştırmak için kullanılan tekniklerdir. Bu yöntemler, frekans bileşenlerinin zamanla değiştiği, durağan olmayan sinyallerin anlaşılması için gereklidir. Zaman-frekans analizi, araştırmacıların, geleneksel Fourier analizi tarafından yeterince yakalanamayan sinyallerdeki zamansal değişimleri ortaya çıkarmasına olanak tanır.

Zaman-frekans yöntemleri, sinyalleri hem zaman hem de frekans alanlarında aynı anda incelemek için kullanılan bir dizi analiz tekniğini ifade eder. Bir sinyalin frekans içeriği hakkında bilgi sağlayan ancak zamansal özellikleri hakkında bilgi vermeyen geleneksel Fourier analizinin aksine, zaman-frekans yöntemleri, bir sinyalin frekans bileşenlerinin zaman içinde nasıl değiştiğinin daha ayrıntılı bir şekilde anlaşılmasına olanak tanır. Bu yöntemler, sinyalin yerelleştirilmiş bir temsilini sağlayarak, zamanın farklı noktalarında frekans içeriğindeki değişiklikleri ortaya çıkarır.

Zaman-frekans yöntemleri bir sinyali zaman-frekans bileşenlerine ayrıştırarak, sinyallerin dinamik davranışına ilişkin değerli bilgiler sunarak onları sinyal işleme, iletişim sistemleri, biyomedikal sinyal analizi ve görüntü işleme gibi çeşitli alanlarda durağan olmayan ve zamanla değişen sinyallerin incelenmesi için paha biçilemez hale getirir.

2.3.1. Yaygın Kullanılan Zaman-Frekans Yöntemleri

Zaman-Frekans Yöntemleri, bir sinyalin zamanla değişen frekans içeriğini ortaya çıkarmak için sinyal işleme ve analizde yaygın olarak kullanılan tekniklerdir. En iyi bilinen yöntemlerden biri, bir sinyalin Fourier dönüşümünü kısa örtüşen zaman pencereleri üzerinden hesaplayan Kısa Zamanlı Fourier Dönüşümüdür (STFT). Bu, farklı zaman anlarındaki frekans bileşenleri hakkında bilgi sağlar. Bir diğer popüler yöntem ise sinyalleri hem zaman hem de frekans alanlarında farklı çözünürlüklerde analiz etmek için farklı ölçeklerde dalgacıklar kullanan Sürekli Dalgacık Dönüşümüdür (CWT). CWT, yerelleştirilmiş geçici özellikleri etkili bir şekilde yakalayabilir. Görgül Kip Ayrışımı (GKA), yerel karakteristik zaman ölçeklerini birleştirerek bir sinyali içsel mod işlevlerine ayrıştıran, veriye dayalı uyarlanabilir bir yöntemdir. Özellikle doğrusal olmayan ve durağan olmayan sinyallerin analizi için uygundur.

Hilbert-Huang Dönüşümü (HHT), bir sinyalden anlık frekansları ve fazları çıkarmak için GKA'nı Hilbert spektral analiziyle birleştiren başka bir veri odaklı yaklaşımdır.

2.3.2. Kısa Zamanlı Fourier Dönüşümünü (STFT)

Fourier Dönüşümü, zamanın bir fonksiyonunu frekansın bir fonksiyonuna dönüştüren ve bir sinyalde bulunan frekans bileşenlerini analiz etmemize olanak tanıyan matematiksel bir tekniktir. Bir sinyali farklı frekanslardaki sinüzoidal fonksiyonlara ayrıştırarak altta yatan dalga formuna ilişkin değerli bilgiler sağlar. Fourier Dönüşümü, her biri kendine özgü matematiksel formüllere sahip olan hem sürekli hem de ayrık formlarda temsil edilebilir. Sürekli durumda, dönüşüm zaman içindeki bir integral olarak ifade edilirken, ayrık durumda bir dizi karmaşık hesaplama kullanılarak hesaplanır. Fourier Dönüşümünün tanımını ve özelliklerini anlayarak sinyallerin frekans içeriğini daha derinlemesine anlayabilir, iletişim sistemleri, görüntü işleme ve ses sinyali analizi gibi alanlarda çeşitli uygulamalara olanak sağlanabilir.

Kısa Zamanlı Fourier Dönüşümü (STFT) ise, bir sinyalin frekans içeriğinin zamanla değişebileceği, durağan olmayan sinyalleri analiz etmek için kullanılan bir sinyal işleme tekniğidir. Sinyali üst üste binen kısa bölümlere bölerek ve her bir bölüm üzerinde Fourier dönüşümleri gerçekleştirerek bir sinyalin zaman-frekans gösterimini sağlar. STFT, bir sinyalin frekans bileşenlerinin zaman içinde nasıl değiştiğini incelememize olanak tanır ve sinyalin zamanla değişen özellikleri hakkında değerli bilgiler ortaya çıkarır. Bir pencereleme tekniği uygulayarak ve örtüşen bölümleri birleştirerek STFT, zaman ve frekans çözünürlükleri arasında bir denge sağlar. Bu, onu ses işleme, konuşma tanıma, müzik analizi, biyomedikal sinyal analizi ve daha fazlası gibi çeşitli uygulamalar için uygun hale getirir. STFT birçok araştırma alanında yaygın olarak kullanılmaktadır ve durağan olmayan sinyallerin anlaşılması ve işlenmesinde değerli bir araç olduğu kanıtlanmıştır.

STFT, daha uzun bir zaman sinyalinin eşit uzunluktaki daha kısa bölümlere bölünmesi ve daha sonra her bir kısa bölüm üzerinde Fourier Dönüşümünün ayrı ayrı hesaplanmasıyla elde edilir. Bu, Fourier Dönüşümünü zaman içinde lokalize ederek, durağan olmayan sinyallerin veya spektral içeriği zamanla değişen sinyallerin analizini mümkün kılar.

Verilen bir $x(t)$ sinyali, STFT ile şu şekilde tanımlanır:

$$X(\tau, f) = \int_{-\infty}^{\infty} x(t) w(t-\tau) e^{-j2\pi f t} dt \qquad (2.1)$$

- $X(\tau, f)x(t)$ Sinyalinin STFT'dir.
- $w(t-\tau), \tau$ Zamanına odaklanan bir pencereleme fonksiyonudur.
- f frekanstır.
- τ pencerenin merkezlendiği zamandır.

Pencereleme fonksiyonu $w(t)$, zaman-frekans çözünürlüğü değişimini belirlediği için çok önemlidir. Yaygın pencere fonksiyonu arasında dikdörtgen, Hamming, Hanning ve Gauss pencereleme fonksiyonları bulunur. Pencere uzunluğu analizi etkiler:

- Daha uzun pencereler daha iyi frekans çözünürlüğü sağlar ancak daha zayıf zaman çözünürlüğü sağlar.
- Daha kısa pencereler daha iyi zaman çözünürlüğü sağlar ancak daha zayıf frekans çözünürlüğü sağlar.

Hamming penceresi, zaman alanında bir sinyale uygulanarak bu sinyalin belirli bir bölümünü vurgulayan ve diğer bölümleri bastıran bir pencere fonksiyonudur. Pencereleme, sinyalin zaman alanında belirli bir kısmının analiz edilmesini sağlar ve genellikle sinyalin başlangıcı ve sonundaki keskin geçişlerin etkisini azaltmak için kullanılır. Hamming penceresi, belirli bir formüle göre tanımlanmış bir ağırlık fonksiyonudur. Hamming penceresinin tüm örnekleri sıfırdan farklıdır, bu da kenar etkilerini (edge effects) azaltır. Pencereleme, sinyalin spektrumunu genişletir ve spektral sızıntıyı (spectral leakage) azaltır. Hamming penceresi, bir cosinus fonksiyonuna dayalıdır, bu da pencerenin yumuşak bir geçişe sahip olmasını sağlar.

İfade edilmesi şu şekildedir:

$$w(n) = 0.54 - 0.46\cos\left(\frac{2\pi n}{N-1}\right) \qquad (2.2)$$

n: $Pencerenin$ örnek $sayısı$ $(0'dan\ N-1'e\ kadar)$

N: $Pencerenin\ toplam$ örnek $sayısı$ $(uzunluğu)$

2.3.2.1. Spektrogram

Spektrogram, zamanla değişen bir sinyaldeki frekans spektrumunun görsel bir temsilidir. Bir sinyalin frekans içeriği hakkında ayrıntılı bilgi sağlar ve ses sinyali işleme, konuşma analizi ve biyomedikal sinyal analizi gibi çeşitli alanlarda yaygın olarak kullanılır.

STFT genlik karesi alınarak, bir zaman-frekans enerji dağılım kestirimi olan spektrogram $S(n, \omega)$ oluşturulur;

$$\text{Spektrogram, } S(n, \omega) = |\, STFT(n, \omega)|^{\,2} \tag{2.3}$$

Desibel (dB) cinsinden spektrogram, spektrogramın genlik değerlerinin logaritmasını alarak elde edilir.

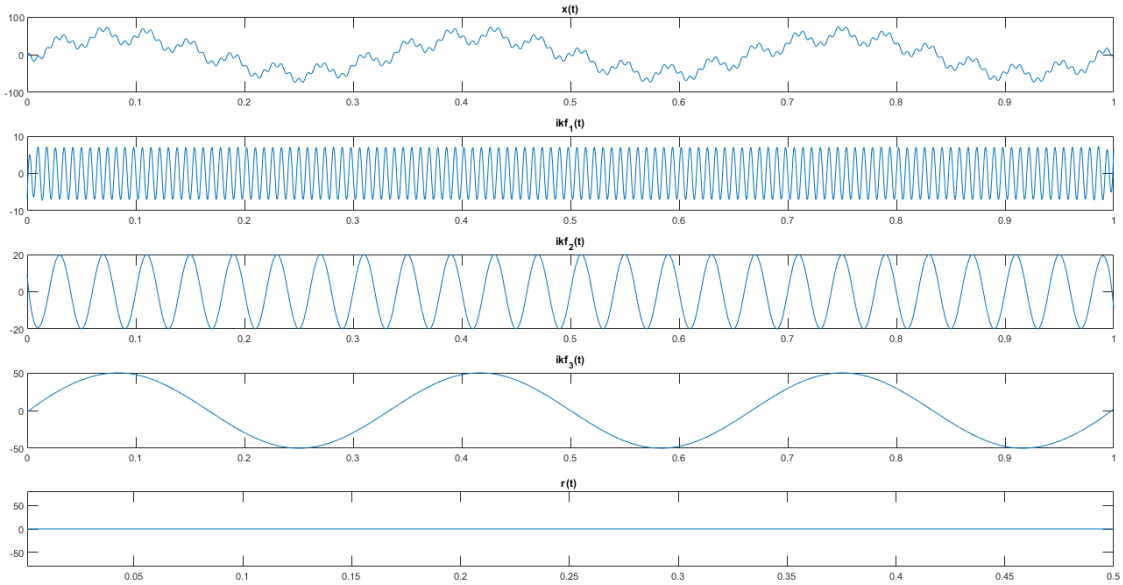
$$S_{dB}(n, \omega) = 10\ log_{10}(S(n, \omega)) \tag{2.4}$$

2.3.3. Görgül Kip Ayrışımı (GKA)

Görgül Kip Ayrışımı (GKA) durağan olmayan ve doğrusal olmayan verileri analiz etmek için kullanılan bir sinyal işleme tekniğidir. 1990'ların sonlarında Dr. Norden E. Huang tarafından geliştirildi ve çeşitli araştırma alanlarında büyük ilgi gördü [5]. Bu yöntem özellikle geleneksel matematiksel yaklaşımlar kullanılarak kolayca analiz edilemeyen karmaşık sinyallerle uğraşırken kullanışlıdır. GKA, şekil. 2.1 de gösterildiği gibi bir sinyali sınırlı sayıda Özgül Kip Fonksiyonuna (ÖKF'ler) ve artık bileşene ayrıştırır. Her ÖKF, orijinal sinyalin tek bir frekans bileşenini temsil ederken, kalan bileşen, kalan eğilimleri veya gürültüyü yakalar. GKA, sinyali bu bileşenlere ayırarak, altta yatan dinamiklerin daha kapsamlı anlaşılmasına olanak tanır ve durağan olmayan sinyallerin veri odaklı bir şekilde analiz edilmesini ve işlenmesini sağlar.

Görgül Kip Ayrışımı, Huang ve arkadaşları tarafından geliştirilen bir veri analiz yöntemidir. Doğrusal olmayan ve durağan olmayan sinyalleri, farklı frekans bileşenlerinin enerji dağılımını temsil eden Özgül Kip Fonksiyonlarına (ÖKF'ler) ayrıştırmak için kullanılan bir zaman-frekans analiz aracıdır. GKA, herhangi bir ön bilgi veya önceden tanımlanmış temel fonksiyon varsaymaksızın karmaşık sinyalleri uyarlanabilir bir şekilde ayrıştırma yeteneği nedeniyle sinyal analizi, zaman serisi analizi ve görüntü işleme gibi çeşitli alanlarda önemli bir ilgi ve popülerlik kazanmıştır. Diğer ayrıştırma yöntemlerinden farklı olarak GKA, Fourier veya dalgacık dönüşümlerine dayanmaz ancak ÖKF'leri doğrudan verilerden çıkarmak için bir eleme işlemi kullanır. Bu benzersiz özellik, GKA'nı, geleneksel yöntemlerle etkili bir şekilde ayrıştırılamayan zamanla değişen veya durağan olmayan sinyallerin analizi için uygun hale

getirir. Araştırmacılar, GKA'nın arka planını ve ilkelerini anlayarak bu yöntemi sinyal işleme, görüntü analizi ve ötesindeki çeşitli uygulamalar için etkili bir şekilde kullanabilirler.

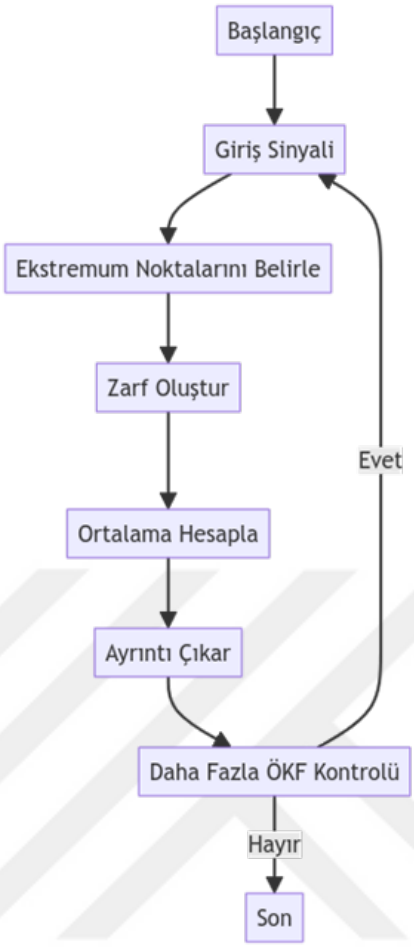


Şekil 2.1: Bir Sinyale GKA yönteminin uygulanması

Özgül Kip Fonksiyonu (ÖKF) kriterleri Görgül Kip Ayrışımı (GKA) yönteminin temelini oluşturur. ÖKF, GKA süreci sırasında bir sinyalden çıkarılan bir fonksiyondur ve iki temel koşulu karşılaması gerekir:

- Ekstremada Simetri: Fonksiyondaki ekstrema sayısı (yani yerel maksimum ve minimum) ve sıfır geçiş sayısı ya eşit olmalı ya da en fazla bir farklı olmalıdır.

- Sıfır Ortalama Zarf: Yerel maksimumlar ve yerel minimumlar tarafından tanımlanan zarfın ortalama değeri herhangi bir noktada sıfır olmalıdır. Başka bir deyişle, sırasıyla yerel maksimum ve minimumların enterpolasyonuyla oluşturulan üst ve alt zarfların ortalamasının mümkün olduğu kadar sıfıra yakın olması gerekir. Bu kriter, ÖKF'nin verilerdeki bir eğilimi veya eğilimi değil, gerçek bir salınım modunu temsil etmesini sağlar.

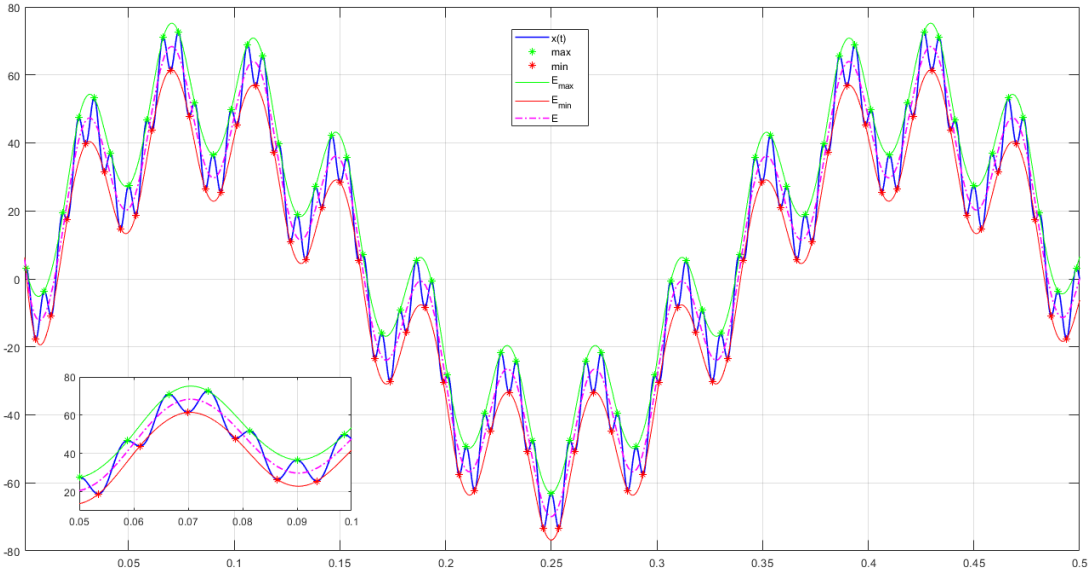


Şekil 2.2: GKA Akış Şeması

GKA akış şeması şekil 2.2 de verilmiştir, algoritma adımları ise şu şekildedir;

1. Ekstremumların Tanımlanması: Belirli bir zaman serisi için $X(t)$, tüm yerel maksimum ve minimumları tanımlayın.

2. Zarf Oluşturma: Bir üst zarf oluşturmak için tüm yerel maksimumlar $E_max(t)$asında enterpolasyon yapın ve benzer şekilde yerel minimumu $E_min(t)$llanarak bir alt zarf oluşturun. Zarf oluşturulmuş bir sinyalin örneği şekil 2.3 de verilmiştir.



Şekil 2.3: Bir sinyalin alt ve üst zarflarının oluşturulması

3. Ortalama Zarf Hesaplaması: Üst ve alt zarfların ortalamasını hesaplayın.

$$m(t) = \left(E_m ax(t) + E_m in(t)\right)/2 \tag{2.5}$$

4. Ayrıntı Çıkarma: Ortalama zarfı orijinal verilerden çıkarın. $d(t) = X(t) - m(t)$

$d(t)$ ÖKF'nin ilk adayı.

5. Eleme Süreci: ÖKF adayının daha önce belirtilen iki koşulu karşıladığından emin olmak için, ÖKF adayı üzerinde 2-4 arasındaki adımları tekrarlayın. Bu yinelemeli süreç, ÖKF kriterleri karşılanana kadar devam eder. Ortaya çıkan işlev ilk ÖKF'dir

6. Artık Hesaplaması: Bir kalıntı elde etmek için çıkarılan ÖKF'yi orijinal verilerden çıkarın.

7. Kalıntı Üzerinde Yineleme: Kalıntıyı yeni veri olarak değerlendirin ve sonraki ÖKF'yi ayıklamak için 1-6 arasındaki adımları yineleyin.

8. Sonlandırma: İşlem, artık daha fazla ÖKF'nin çıkarılamayacağı monotonik bir fonksiyon haline geldiğinde sona erer.

Verilen bir $X(t)$ sinyali;

GKA ile n adet özgül kip fonksiyonuna Ö$KF_i(t)$ayrıştırıyor;

$$X(t) = \sum_{i=1}^{n} \text{Ö}KF_i(t) + R(t) \quad (2.6)$$

2.3.3.1. Görgül Kip Ayrışım Yönteminin Sınırlamaları

Görgül Kip Ayrışım yöntemi yaygın kullanımına ve çeşitli alanlara uygulanabilirliğine rağmen GKA'nın dikkate alınması gereken dezavantajları vardır. Bu sınırlamalar mod karıştırma sorunu, gürültüye duyarlılık, çok değişkenli verilerin işlenmesindeki zorluk ve hesaplama karmaşıklığı dahil olmak üzere GKA ile ilgili zorlukları sıralayabiliriz.

1. **Mod Karıştırma:** Mod karıştırma, tek bir ÖKF'nin oldukça farklı ölçeklerdeki sinyallerden oluşabileceği veya benzer ölçekteki bir sinyalin farklı ÖKF'lere bölünebildiği GKA'da önemli bir sorundur. Bu sorun, sinyal aralıklı veya ani olaylar içerdiğinde ortaya çıkar ve ÖKF'nin tek bir salınım modunu anlamlı bir şekilde temsil etmemesine yol açar.

2. **Gürültüye Duyarlılık:** ÖKF gürültüye duyarlıdır. Verilerdeki gürültü, sahte ÖKF'lerin oluşmasına yol açabilir, bu da gürültünün neden olduğu ÖKF'ler ile gerçek sinyal özelliklerini temsil edenler arasında ayrım yapmayı zorlaştırır.

3. **Çok Değişkenli Verilerin İşlenmesindeki Zorluk**: GKA, tek değişkenli veriler için tasarlanmıştır. Çok Değişkenli verileri ayrıştırmak için Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA) yöntemi tasarlanmıştır.

4. **Hesaplama Karmaşıklığı:** GKA, özellikle uzun veri kümeleri için hesaplama açısından yoğun olabilir. Eleme süreci, tüm ÖKF'leri çıkarmak için birden fazla yineleme gerektirir; bu, büyük veri kümeleri veya gerçek zamanlı uygulamalar için zaman alıcı olabilir.

2.3.4. Grup Görgül Kip Ayrışımı (GGKA)

Grup Görgül Kip Ayrışımı (GGKA), öncelikle bir sinyali Özgül Kip Fonksiyonu olarak bilinen sonlu bir salınım bileşenleri kümesine ayrıştırmak için kullanılan gelişmiş bir zaman serisi analiz yöntemidir. Standart GKA algoritması, zaman-frekans analiz yöntemi olarak sinyal

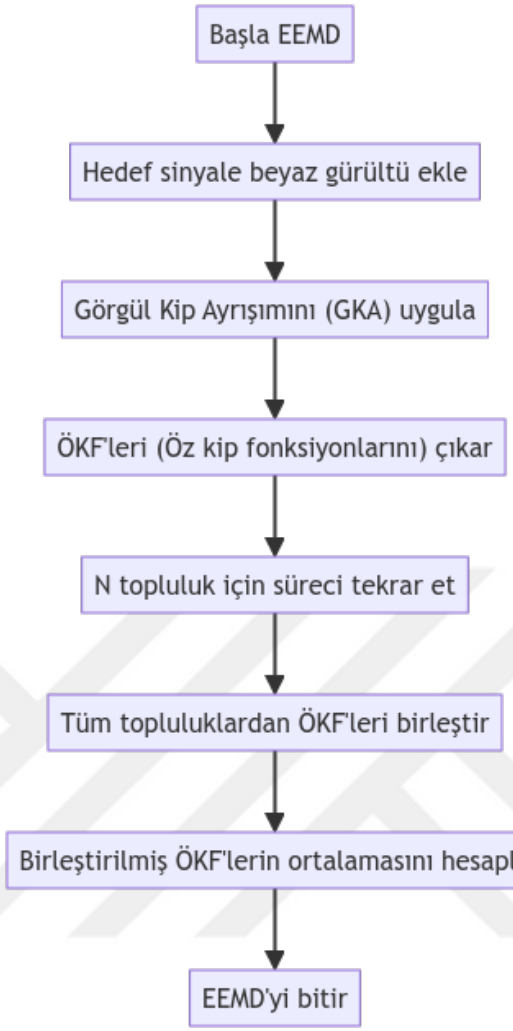
işleme uygulamalarında başarılı sonuçlar vermesine rağmen "mod karıştırma problemi" yaşamaktadır. Mod karıştırma sorunu, analiz edilen sinyalin frekans içeriğinin doğru bir şekilde temsil edilmemesine ve böylece GKA'nın etkinliğinin azalmasına yol açar. Yöntem, GKA'nın doğasında bulunan mod karıştırma probleminin üstesinden gelmek için tasarlanmış Görgül Kip Ayrışımı yönteminin geliştirilmiş halidir.

GGKA'na Beyaz Gürültü Eklenmesinin amaçları;

- **Tekdüzen (Uniform) Bir Referans Ölçeği Sağlamak:** Sinyale beyaz gürültünün eklenmesi, zaman-frekans alanında tekdüze bir referans ölçeği sağlanmasına yardımcı olur. Bu, sinyalden Özgül Kip Fonksiyonlarını (ÖKF'ler) çıkarmak için kullanılan GKA'nın eleme işlemine yardımcı olur.

- **Mod Karıştırma Problemini Azaltır**: GKA'da mod karıştırma, tek bir ÖKF'nin oldukça farklı ölçeklerde sinyaller içermesi veya benzer ölçekte bir sinyalin farklı ÖKF'lerde bulunması durumunda meydana gelir. GGKA'na beyaz gürültünün eklenmesi, sinyalin farklı ölçeklerinin gücünün farklı ÖKF bileşenleri üzerinde daha eşit bir şekilde dağıtılmasına yardımcı olur ve böylece mod karışımını azaltır.

- **Ortalama etkisi:** GGKA, orijinal sinyale tekrar tekrar farklı beyaz gürültü örnekleri ekleyerek ve sonuçta ortaya çıkan her sinyali ÖKF'lere ayrıştırarak, bir ÖKF setleri topluluğu oluşturur. Bu ÖKF'lerin tüm topluluk üyeleri genelinde ortalaması, gürültünün sıfır ortalamalı ve ilişkisiz olduğu varsayılarak, eklenen beyaz gürültüyü etkili bir şekilde iptal eder. Sonuç, orijinal sinyalin altında yatan gerçek kipleri daha doğru bir şekilde temsil eden bir dizi ÖKF meydana getirir.



Şekil 2.4: GGKA yönteminin akış şeması.

GGKA yönteminin akış şeması şekil 2.4 de verilmiştir, algoritma adımları ise şu şekildedir;

1. **Beyaz Gürültü Ekleme:** Her bir grup için, orijinal veri serisine farklı beyaz gürültü serileri eklenir. $x(t)$ orijinal veriyi ve $w_i(t)$ i. grup için eklenen beyaz gürültüyü ifade ederse, yeni oluşturulan veri serisi şu şekilde hesaplanır:

$$y_i(t) = x(t) + w_i(t) \tag{2.7}$$

2. **Her Bir Gürültülü Seriye GKA Uygulama:** GKA, her bir gürültü eklenmiş $y_i(t)$ serisine ayrı ayrı uygulanır ve bu seriler ÖKF olarak bilinen bileşenlere ayrıştırılır. n farklı GKA ve $r_i(t)$ artık bileşeni olmak üzere, her bir gürültülü seri için aşağıdaki gibi ifade edilir:

$$y_i(t) = \sum_{j=1}^{n} \text{Ö}KF_{ij}(t) + r_i(t) \quad (2.8)$$

3. **Çoklu Grup İşlemi:** Adım 1 ve 2, *N* farklı grup için tekrarlanır. Her bir grup, orijinal veriye farklı bir beyaz gürültü serisi eklenerek oluşturulur.

4. **Karşılık Gelen IMF'lerin Ortalamasını Hesaplama:** Her bir ÖKF için, tüm N grup üzerinden ortalamalar hesaplanır.

$$\text{Ö}KF_j(t) = (1/N) * \sum_{j=1}^{n} \text{Ö}KF_{ij}(t) \quad (2.9)$$

5. Orijinal sinyal *x*(*t*), eklenen beyaz gürültü dışında, elde edilen tüm ortalama ÖKF'lerin toplamıyla yaklaşık olarak yeniden oluşturulabilir.

$$x(t) \approx \sum_{j=1}^{n} \text{Ö}KF_j(t) \quad (2.10)$$

GGKA 'da Beyaz Gürültünün Özellikleri:

Ortalama: İdeal olarak beyaz gürültünün ortalaması sıfır olmalıdır.

Varyans (Genlik): Beyaz gürültünün genliği GGKA 'da çok önemli bir parametredir. Çok az gürültü mod karıştırma problemini tam olarak çözemeyeceğinden, çok fazla gürültü ise sinyali bastırabileceğinden dikkatli seçilmelidir. Bu parametreyi ayarlamak için evrensel bir kural yoktur çünkü bu, büyük ölçüde analiz edilen belirli verilerin özelliklerine bağlıdır. Ancak bilinçli bir karar vermenize yardımcı olabilecek bazı genel kurallar ve hususlar vardır:

- **Sinyalin Standart Sapmasının Yüzdesi:** Yaygın bir yaklaşım, gürültü genliğini orijinal sinyalin standart sapmasının bir yüzdesi olarak ayarlamaktır. Bu yüzde değişebilir, ancak genellikle %10 ila %20 aralığındadır. Bu yaklaşım, gürültü seviyesinin sinyalin kendi değişkenliğine göre olmasını sağlar.
- **Sinyal-Gürültü Oranı (SNR):** Orijinal verilerinizin SNR'nı göz önünde bulundurulur. Veriler zaten önemli miktarda gürültü içeriyorsa, GGKA işleminin sinyal ve gürültü bileşenlerini etkili bir şekilde ayırabildiğinden emin olmak için eklenen gürültü genliğini buna göre ayarlamanız gerekebilir.
- **Grup Boyutu:** GGKA sürecindeki grup sayısı da rol oynar. Daha fazla sayıda grup, gürültünün etkisini daha etkili bir şekilde ortalayabilir ve potansiyel olarak sonuçları olumsuz etkilemeden daha yüksek bir gürültü genliğine izin verebilir.

Rastgelelik: Grup ortalama sürecinin etkililiğini sağlamak için sinyale eklenen her beyaz gürültü örneği rastgele bir gerçekleşme olmalıdır.

2.3.5. Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA)

Çok Değişkenli Görgül Kip Ayrışımı (ÇDGKA) algoritması, çok değişkenli verileri işlemek için klasik Görgül Kip Ayrıştırma'yı (GKA) genişleten gelişmiş bir sinyal işleme yöntemidir. Doğası gereği tek değişkenli olan GKA'dan farklı olarak ÇDGKA, kanallar arasındaki ilişkileri korurken çok kanallı verileri her kanal için Öz Kip Fonksiyon (ÖKF'ler) olarak bilinen öz kip fonksiyonlarına ayrıştırarak çok kanallı verilerin analizine olanak tanır.[4], [33], [34]

ÇDGKA algoritması, uyarlanabilir ve ampirik doğasından dolayı, geleneksel sinyal işleme teknikleri gibi basit bir matematiksel formülü takip etmez. Bununla birlikte, özellikle hem GKA hem de ÇDGKA için merkezi olan zarf tahmini ve eleme sürecine odaklanarak, algoritma adımlarını bir dereceye kadar matematiksel olarak tanımlayabiliriz. ÇDGKA'deki temel fark, zarfları ve projeksiyonlar arasındaki ortalama eğilimleri tahmin etmek için çok değişkenli sinyallerin n boyutlu uzayda birden fazla yöne yansıtılmasıdır.

ÇDGKA Algoritma adımları şu şekildedir;

1. **Sinyal Projeksiyonu:** Verilen *N*-kanallı birçok değişkenli sinyal $X(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T$, *N*-boyutlu uzayda farklı yönler üzerine projekte edilir. Şekil 2.5 (a), küresel açılara dayanan tekdüze olmayan bir örnekleme şemasını gösterirken, Şekil 2.5(b), düşük tutarsızlıklı Hammersley dizileri tarafından oluşturulan projeksiyon vektör yönleri için tekdüze örneklemeyi göstermektedir [33], [35], [36]. Bu projeksiyon işlemi, sinyali farklı yönlerdeki bileşenlerine ayırır. Her bir yön için projeksiyon $\boldsymbol{p_i}(t)$şöyle hesaplanır:

$$p_i(t) = D_i \cdot X(t) \tag{2.11}$$

D_i N-boyutlu uzayda i-inci yönü ve $p_i(t)$ bu yöne projekte edilen sinyali temsil eder.

2. **Zarfların Hesaplanması:** Her bir projeksiyon $p_i(t)$ için, yerel maksimum ve minimumlar kullanılarak üst ve alt zarflar hesaplanır ve bu zarfların ortalaması alınır, Bu zarflar arasındaki ortalama zarf $m_i(t)$ile ifade edilir:

$$m_i(t) = \left(e_{(\text{üst},i)}(t) + e_{(\text{alt},i)}(t)\right)/2 \tag{2.12}$$

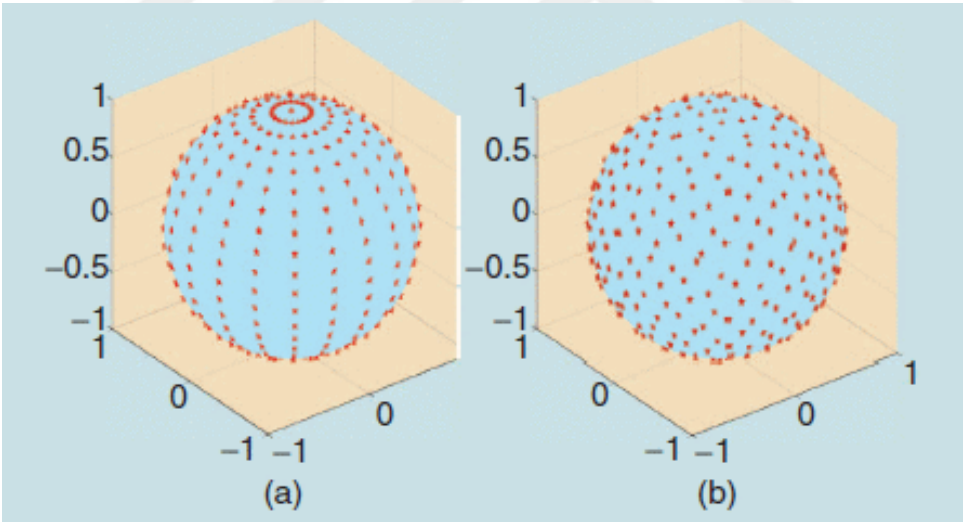
Bu ifade, i-inci projeksiyon için ortalama zarfı temsil eder.

3. **Detay Sinyalinin Çıkarılması:** Her bir yön için detay sinyali, projekte edilmiş sinyalden ortalama zarfın çıkarılmasıyla elde edilir:

$$d_i(t) = p_i(t) - m_i(t) \tag{2.13}$$

4. **Çok Boyutlu Detay ve IMF Çıkarımı:** Tüm yönler için elde edilen detay sinyalleri birleştirilerek çok boyutlu bir detay sinyali oluşturulur. Bu sinyal, belirli kriterlere uygunsa (örneğin, sıfır ortalama ve simetrik ekstremum sayısı) bir ÖKF olarak kabul edilir.

5. **Yineleme:** Çıkarılan ÖKF, orijinal sinyalden çıkarılarak artık sinyal elde edilir ve bu süreç artık sinyal üzerinde tekrarlanır. Süreç, artık sinyal monotonik bir fonksiyon haline geldiğinde veya belirli bir enerji eşiğinin altına düştüğünde daha fazla ÖKF çıkarılamayacak bir duruma gelene kadar devam eder.



Şekil 2.5: Üç değişkenli verilerin projeksiyonları için yön vektörleri: (a) açısal örnekleme ve (b) tekdüze örnekleme [35].

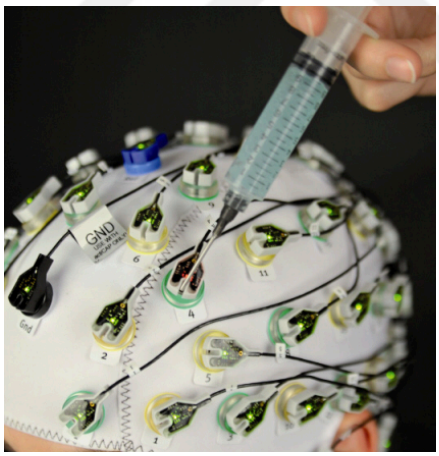
3. YÖNTEM

3.1. VERİ SETİ

Bu tez kapsamında İzmir Katip Çelebi Üniversitesi Biyomedikal Mühendisliği Bölümü Elektrofizyolojik Sinyaller Laboratuvarında deneysel çalışmalar yapılmıştır. 55 gönüllü, iki farklı markanın ("Marka 1-Dacia" ve "Marka 2-Mercedes") yaklaşık 75 saniye süren reklam filmleri izletilmiştir; Dacia reklamını 27 kişi, Mercedes reklamını ise 28 kişi izledi. Dacia reklamını izleyenlerin yaş ortalaması 24,62±4,18 ve Mercedes reklamını izleyenlerin yaş ortalaması 23,39±4,57 dir.

EEG sinyallerinin toplanabilmesi için İzmir Kâtip Çelebi Üniversitesi Klinik Araştırmalar Etik Kurulu'ndan 21.01.2021 tarihinde ve 12 numaralı belgeyle etik onay alınmıştır.

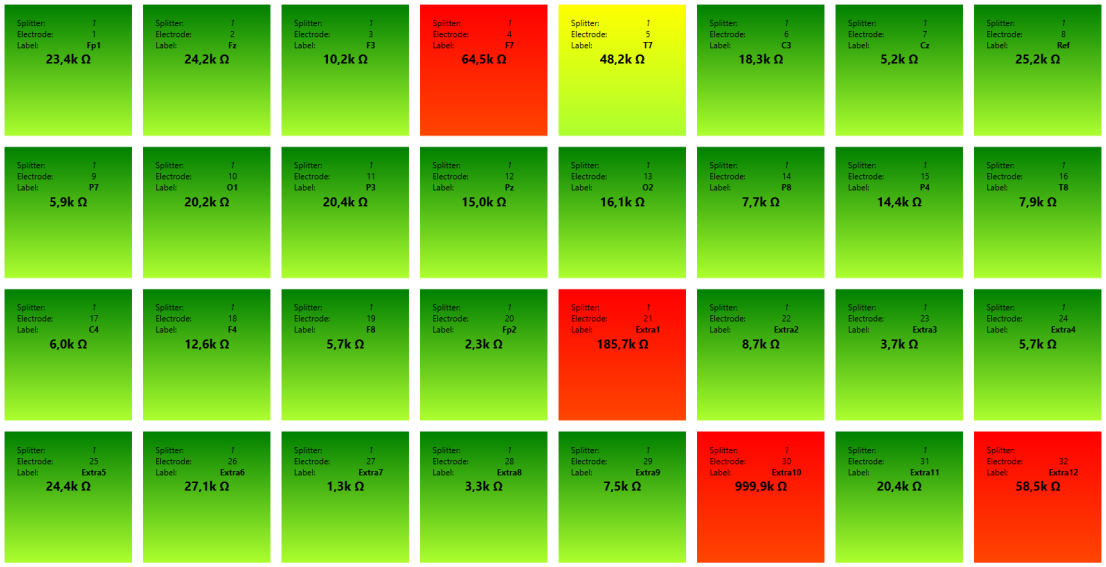
Çalışmada, EEG verilerinin toplanmasında, birbirine entegre çalışan, Brain Product marka ActiCHamp model 32 kanallı EEG cihazı, 10-20 elektrot bağlantı sistemi ile tasarlanmış EEG başlığı ve IMotion yazılımı kullanılmıştır. Örnekleme frekansı 500 Hz olarak alınmıştır.



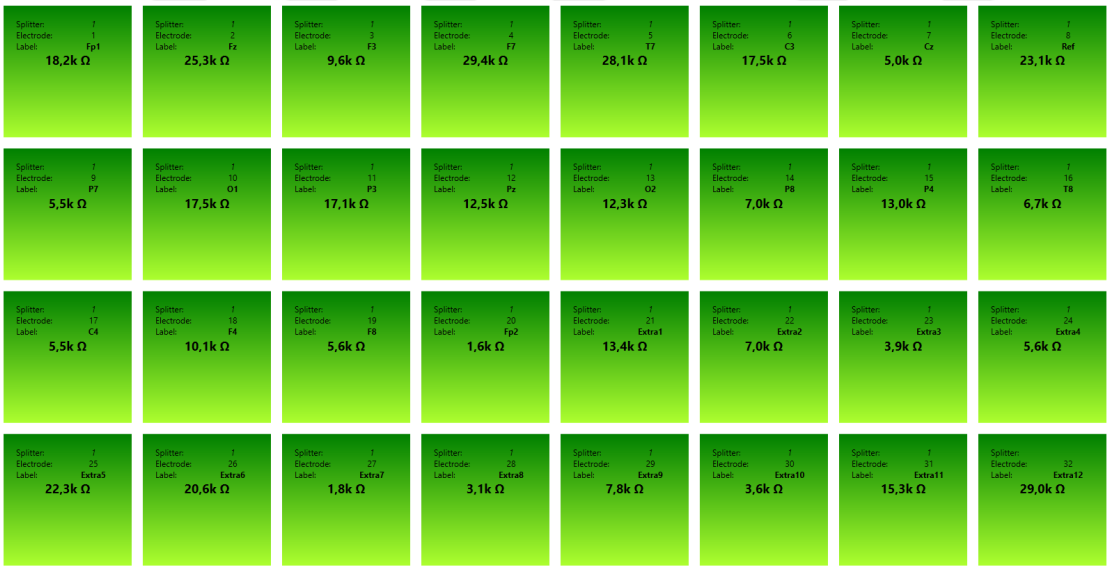
Şekil 3.1: Elektrotların şırınga ile hazır hale getirilmesi

EEG başlığına elektrotlar tek tek yerleştirip iletkenliği sağlanması için Şekil 3.1 de görüldüğü gibi iletken jel şırınga yardımı ile empedans değeri düşünceye kadar doldurulur. Düzgün veri alınabilmesi için oldukça önemlidir. Elektrotların üzerinde bulunan led ve ekranda bulunan empedans değeri ve ışık rengine göre elektrotların uygun şekilde veri alımına hazır hale gelip gelmediği kontrol edilir. Elektrotlar ilk takıldığında Elektrotların üzerinde bulunan led ilk takıldığında kırmızı renktedir, empedans değerine göre sarı ve yeşil rengi almaktadır. Şekil 3.2 de görüldüğü gibi, empedans değeri 60 kOhm dan büyük ise kırmızı, 25-60 kOhm arası sarı, 25

kOhm dan düşük ise yeşil rengi almaktadır. Şekil 3.3 de görüldüğü gibi, tüm elektrotlar empedans değeri uygun yani yeşil olunca EEG veri alımına başlanmaktadır.



Şekil 3.2: Henüz veri alımına hazır olmayan Elektrotların Empedans değerleri.



Şekil 3.3: Veri alımına hazır olan Elektrotların Empedans değerleri.

Bu çalışmada EEG tabanlı duygu tanıma çalışmalarında sıklıkla kullanılan 16 EEG kanalı. (Fp1, AF3, F3, F7, FC1, FC5, T7, C3, Fp2, AF4, F4, F8, FC2, Fc6, T8 ve C4) beğeni durum tespiti analizi için kullanılmıştır.

Bu tür deneysel çalışmalarda dikkat edilmesi gereken önemli bir husus da uyaran gösterimi ile EEG veri kaydı sırasında gecikme yaşanmasına dikkat edilmesidir. Uyaran gösterimi ile EEG çekimi eş zamanlı çalışmazsa, EEG verilerinde asıl işlenmesi gereken zaman aralıkları kayabilir ve düzgün sonuç alınmayabilir. Bu yüzden, çalışmadan düzgün sonuç alınabilmesi ve daha sonra emeklerin zayi olmaması için son derece önemli ve temel bir konudur. Bizde çalışmamızın deney tasarımında hem reklam videosu hem de anket değerlendirme soruları sunumu aynı ekranda IMotions yazılımı ile katılımcılara gösterilmiştir. IMotion yazılımı ile EEG cihazı eş zamanlı çalışmakta ve uyaranı görme zamanı ile EEG kaydı arasında herhangi bir gecikme oluşmamıştır.

3.1.1. Deney Tasarımı

Deney tasarımı, kişisel bilgilerin yer aldığı üç ekran ve ardından bir araba markasının reklam videosu ve araba ile ilgili anket sorularından oluşmaktadır. Deney tasarımı gönüllü katılımcılara deney öncesinde anlatılmış ve onayları alınmıştır. Deneye katılan gönüllü bireylerin ekrana kişisel bilgilerini girdikten sonra araba reklam videosunu izlemeleri sağlanmıştır. Katılımcılara önce bir otomobil markasının reklam videosu ve ardından videodan seçilen 7 farklı görsel gösterilmiştir. Bu 7 görsel otomobilin ön görünüm, ön konsol, yan görünüm, arka görünüm, arka far, logo ve ızgara bölümlerinden oluşmaktadır. Şekil 3.4, Şekil 3.5, Şekil 3.6 ve Şekil 3.7 de her iki markaya ait görsel örnekler verilmiştir. Her resmin gösterim süresi 10 saniyedir. Video ile her resim arasında beş saniyelik siyah bir ekran gösterilmiştir. Reklam videosu izlenildikten sonra, katılımcılardan 10 saniyelik resim gösterimi süresince beğeni tercihlerini ekranda açılan formda yapmaları istenmiştir; Hiç Beğenmedim (-2), Beğenmedim (-1), Kararsızım (0), Beğendim (1), ve Çok Beğendim (2). Reklam videosu izlenirken eşzamanlı olarak kaydedilen EEG sinyallerinden, bu gösterilen yedi bölüme karşılık gelen EEG kayıtları bölütlenerek sinyal işleme yöntemleri ile analiz edilmiştir.



SORU 2 Yeni Mercedes-Benz CLS'nin ön konsolunu beğendiniz mi?

Hiç Beğenmedim	Beğenmedim	Kararsızım	Beğendim	Çok Beğendim
○	○	○	○	○

Şekil 3.4: Mercedes Marka Arabanın Ön konsol Sorusu.



SORU 2 Yeni Dacia Duster'ın ön konsolunu beğendiniz mi?

Hic Begenmedim	Begenmedim	Kararsizim	Begendim	Cok Begendim
○	○	○	○	○

Şekil 3.5: Dacia Marka Arabanın ön konsol sorusu.



SORU 5 Yeni Dacia Duster'ın arka farını beğendiniz mi?

Hic Begenmedim Begenmedim Kararsizim Begendim Cok Begendim

Şekil 3.6: Dacia Marka Arabanın Arka Far Sorusu.



SORU 5 Yeni Mercedes-Benz CLS'nin arka farını beğendiniz mi?

Hiç Beğenmedim Beğenmedim Kararsızım Beğendim Çok Beğendim

Şekil 3.7: Mercedes Marka Arabanın Arka Far Sorusu.

3.1.2. Veri Önişleme

EEG sinyallerini kaydederken, kas aktivitesi, göz kırpma veya elektrik şebeke gürültüsü (50 Hz) gibi çeşitli gürültüler ortaya çıkmaktadır. Deneyler sırasında kayıt edilen EEG sinyallerinden istenmeyen gürültü ve EEG dışı çeşitli artefaktları ortadan kaldırmak için bant geçiren Butterworth tip ll bant geçiren filtre uygulayarak 0,5 - 45 Hz dışındaki gürültüler bastırılmıştır.

Çalışmada marka 1 ve marka 2 olmak üzere 75 saniye süren iki video izlettirilir. Katılımcıların 27 si marka 1 28 ise marka 2 reklam videosunu izlemiştir. Yaklaşık 75 saniye süren reklam videolarından seçilen 7 farklı görselin 1 er saniyelik (500 örnek) EEG segmenti alınır. Her kişi için toplamda 16x7x500=56000 (16 kanal, 7 farklı görsel, 500 örnek) segment üretilir.

Oluşan EEG segmentlerini özellik çıkarmak amacıyla ileri sinyal işleme yöntemleri kullanarak sinyalimizi analiz etmek için GKA, GGKA ve ÇDGKA olmak üzere 3 farklı ayrıştırma yöntemi kullanarak kiplerine ayrıştırıldı. GKA yöntemi ile 5 kip, GGKA yöntemiyle 8 kip, ÇDGKA yöntemi ile 6 kipe ayrıştırılmıştır.

3.1.2.1. Pencereleme

Elde edilen kipleri Video içeriklerine göre 7 parçayı ayırdığımız 1 er saniyelik 500 örnek ile ayırdığımız kısımları, her pencereyi 71 uzunlukta tutarak yüzde 25 örtüşecek şekilde ötelenerek toplam 9 pencere oluşturulur. Her pencereden 15 istatistik yöntem ile 9x15=135 öznitelik elde edilir. Böylelikle elimizde her kişi için 16x7x135 EEG segmenti (kanal*parça*öznitelik) olmuş oldu. Her bir katılımcı ve 1 kip için Kanalları yan yana, görselleri alt alta koyarak 7x2160 uzunluğunda matrisimiz oldu. Her bir kişinin EEG segmentlerini alt alta koyarak marka 1 için 189x2160, marka 2 için 196x2160 uzunluğunda verimiz oluştu.

3.2. EEG SİNYALLERİ VE MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK BEGENİ DURUM KESTİRİMİ

3.2.1. Öznitelik Çıkarımı

Pencereleme yaptığımız her kısma 15 istatistik ölçüt ile öznitelik çıkarımı yapıldı. İstatistik ölçüt olarak en küçük, en büyük, aralık, ortalama, ortanca, değişkenlik katsayısı, üçüncü moment, varyans, basıklık, etkin değer, enerji, ortalama sapma, frekans bölgesinde yüksek dereceli moment öznitelikleri hesaplanmıştır:

3.2.1.1. Değişkenlik Katsayısı

Değişkenlik katsayısı (CV), bir veri setinin standart sapmasının ortalamaya oranı olarak tanımlanır. Değişkenlik katsayısı, veri setinin ne kadar dağıldığını veya yayıldığını gösteren bir ölçüttür ve farklı ortalamalara sahip veri setlerinin dağılımlarını karşılaştırmak için kullanılır.

İfade edilmesi şu şekildedir:

$$c_v = \frac{\sigma}{\bar{x}} = \frac{\sqrt{\frac{1}{N}\sum_{i=1}^{N}(x(i)-\bar{x})^2}}{\bar{x}} \quad (3.1)$$

$\bar{x} = ortalama \;\; \sigma = standart\ sapma$

3.2.1.2. Üçüncü Moment

Üçüncü moment, istatistik ve olasılık teorisinde önemli bir kavramdır ve bir veri setinin veya olasılık dağılımının simetrisini ölçmek için kullanılır. Özellikle, bir veri setinin ne kadar ve hangi yönde çarpık olduğunu belirlemek için kullanılır.

Matematiksel olarak, bir veri setinin üçüncü momenti (veya çarpıklık momenti), veri noktalarının ortalamadan ne kadar farklı olduğunun küp değerlerinin ortalaması olarak tanımlanır. Çarpıklık, bir dağılımın normal dağılımdan ne kadar sapma gösterdiğini ve verilerin ortalamaya göre nasıl dağıldığını anlamak için kullanılır.

İfade edilmesi şu şekildedir:

$$M_3 = \frac{1}{N}\sum_{i=1}^{N}(x(i) - \bar{x})^3 \quad (3.2)$$

$\bar{x} = ortalamax(i) = herbir\ gözlemi\ temsil\ eder.$

$N = \ veri\ setindeki\ toplam\ gözlem\ sayısıdır.$

3.2.1.3. Değişinti (Varyans)

"Değişinti", genellikle "varyans" olarak bilinen bir istatistiksel terimdir ve bir veri setindeki değerlerin, ortalamadan ne kadar farklılık gösterdiğinin bir ölçüsüdür. Başka bir deyişle, varyans bir veri setindeki değerlerin dağılımının ne kadar geniş olduğunu gösterir. Matematiksel olarak varyans, veri noktalarının ortalamadan farklarının karelerinin ortalaması olarak hesaplanır.

İfade edilmesi şu şekildedir:

$$([\![Varyans)\sigma]\!]^2 = 1/N \sum_{i=1}^{N}(x(i) - \bar{x})^2 \quad (3.3)$$

$\bar{x} = ortalamax(i) = herbirgözlemitemsileder.$

$N = \ veri\ setindeki\ toplam\ gözlem\ sayısıdır.$

3.2.1.4. Basıklık (Kurtosis)

Basıklık (Kurtosis), bir veri setinin veya olasılık dağılımının tepe noktasının ve kuyruklarının şeklini tanımlayan bir istatistiksel ölçüttür. Basıklık, bir dağılımın normal (Gauss) dağılımına göre ne kadar sivri veya basık olduğunu gösterir ve veri setindeki aşırı değerlerin (outliers) varlığını anlamak için kullanılır. Yüksek basıklık, veri setinin uç değerlere (aşırı değerlere) sahip olduğunu ve bu değerlerin sık olduğunu gösterir. Düşük basıklık, veri setinin daha düzgün bir dağılıma ve daha az uç değere sahip olduğunu gösterir. Basıklığın matematiksel formülü bir veri setindeki değerlerin dördüncü momentlerinin ortalamasının, standart sapmanın dördüncü kuvvetine bölünmesiyle bulunur.

İfade edilmesi şu şekildedir:

$$k = M_4/\sigma^4 = ((1/N)\sum(i = 1)^N(x(i) - \bar{x})^4)/((1/N)\sum(i = 1)^N(x(i) - \bar{x})^2)^2 \quad (3.4)$$

3.2.1.5. Etkin Değer (Root Mean Square-RMS)

Etkin değer (Root Mean Square - RMS) fizik, mühendislik ve sinyal işleme gibi çeşitli alanlarda yaygın olarak kullanılan istatistiksel bir ölçüdür. Etkin değer, bir değişkenin (genellikle zamanla değişen bir sinyalin) karesel ortalama kökü olarak tanımlanır. Bu, sinyalin gücünü veya büyüklüğünü etkin bir şekilde ifade eden bir ölçüttür. Etkin değer, bir dizi değerin karelerinin aritmetik ortalamasının karekökü olarak hesaplanır.

İfade edilmesi şu şekildedir:

$$x_{RMS} = \sqrt{1/N \sum_{i=1}^{N} x(i)^2} \quad (3.5)$$

3.2.1.6. Enerji

Sinyal işlemede "enerji", bir sinyalin belirli bir süre boyunca veya sinyalin tüm süresi boyunca ölçülen toplam büyüklüğünü ifade eder. Bir sinyalin gücünü veya gücünü karakterize etmek için kullanılan temel bir kavramdır. Dijital sinyal işlemede bu kavram, sinyallerin analiz edilmesine, filtrelenmesine ve dönüştürülmesine yardımcı olur.

İfade edilmesi şu şekildedir:

$$E = 1/N \sum_{i=1}^{N} x(i)^2 \quad (3.6)$$

3.2.1.7. Ortalama Sapma

Ortalama mutlak sapma olarak da bilinen ortalama sapma, bir kümedeki her veri noktası ile bu kümenin ortalaması arasındaki ortalama mesafeyi temsil eden istatistiksel bir ölçüdür. Verilerdeki yayılmayı veya değişkenliği ölçmenin, sayıların ne kadar "yayıldığını" göstermenin bir yoludur. Düşük ortalama sapma, veri noktalarının çoğunun ortalamaya yakın olduğunu gösterir; bu da veri kümesinde daha az yayılma veya değişkenlik anlamına gelir. Ortalama sapmanın yüksek olması, veri noktalarının ortalamadan daha fazla dağıldığı anlamına gelir ve bu da daha yüksek değişkenliğe işaret eder.

İfade edilmesi şu şekildedir:

$$OS = \frac{1}{N}\sum_{i=1}^{N}|x(i) - \bar{x}| \quad (3.7)$$

3.2.1.8. Frekans Alanındaki Yüksek Dereceli Momentler

Frekans alanındaki yüksek dereceli momentler, sinyal işleme ve istatistiksel analizde, özellikle bir sinyalin spektral özelliklerini karakterize etmede yararlı olan gelişmiş araçlardır. Bu momentler, bir sinyalin frekans spektrumunun şekli ve dağılımı hakkında bilgi sağlar.

İfade edilmesi şu şekildedir:

$$\langle {\omega_k}^i \rangle = \quad 1/N \sum_{k=1}^{N} (2\pi/N\, k)^i S_X(\omega_k) \quad (3.8)$$

$i = 1,2,3$

$S_X(\omega_k)$ =Bu, ω_k frekansındaki güç spektral yoğunluğudur (PSD).

Birinci Dereceden Moment

Genellikle spektrumun "spektral merkezi" veya "ağırlık merkezi" olarak adlandırılan frekans alanındaki birinci dereceden moment, bir sinyalin spektrumunun denge noktasını veya ortalama frekansını yansıtan bir ölçüdür. Sinyal işlemede temel bir kavramdır ve özellikle bir sinyalin spektral içeriğini baskın frekansları açısından karakterize etmek için kullanışlıdır. Spektral ağırlık merkezi, sinyal işlemenin çeşitli alanlarında önemli bir araçtır ve bir sinyalin frekans

içeriğini özetlemenin basit ama etkili bir yolunu sunar. Bir sinyalin gücünün çoğunluğunun frekans spektrumunda nerede yoğunlaştığını anlayarak, sinyalin doğası ve özellikleri hakkında fikir sahibi olunabilir.

İkinci Dereceden Moment

Bir sinyalin spektral varyansı veya bant genişliği ile ilişkilendirilen frekans alanındaki ikinci dereceden moment, bir sinyalin gücünün frekans spektrumu boyunca yayılmasının veya dağılımının bir ölçüsünü sağlar. Sinyal işlemede, sinyalin frekans içeriği hakkında fikir veren önemli bir kavramdır. İkinci dereceden moment, sinyalin enerjisinin ortalama (merkez) frekansı etrafında nasıl dağıldığını ölçer ve sinyalin bant genişliğini tahmin etmek için kullanılır. Farklı sinyal türleri veya aynı sinyalin farklı durumları, ikinci dereceden moment kullanılarak tanımlanabilen farklı spektral yayılımlara sahip olabilir.

Üçüncü Dereceden Moment

Bir sinyalin spektrumunun çarpıklığıyla ilişkili olan frekans alanındaki üçüncü dereceden moment, ortalama frekansı etrafındaki güç dağılımının asimetrisine ilişkin bilgiler sunar. Sinyal işlemede önemli bir kavramdır ve özellikle frekans spektrumunun şeklini karakterize etmek için kullanışlıdır. Üçüncü dereceden moment, bir sinyalin spektral merkezi etrafındaki güç dağılımının asimetrisinin bir ölçüsünü sağlar. Güç dağılımının daha yüksek frekanslara doğru çarpık olup olmadığını gösterirken negatif bir değer, daha düşük frekanslara doğru bir çarpıklığı gösterir. Üçüncü dereceden moment, sinyallerin belirli özelliklerini veya davranışlarını tanımlamak için, özellikle modüle edilmiş sinyallerin farklı türleri arasında ayrım yapmak veya bozulmaları tanımlamak için kullanılabilir.

3.2.2. Öznitelik Seçimi

Öznitelik seçimi, model yapımında kullanılmak üzere ilgili özniteliklerin bir alt kümesini seçmek için makine öğreniminde kullanılan bir süreçtir. Modelleri basitleştirir, bu da onların yorumlanmasını kolaylaştırır, aşırı uyumu azaltır ve eğitim sürelerinin kısalmasına, başarımın artmasına ve daha iyi genellemeye yol açabilir.

Bu çalışma kapsamında Relief yöntemi ile öznitelik seçimi yapıldı ve sınıflandırma yöntemleri ile başarım sonuçları elde edildi. Relief algoritması ve onun varyantları (ReliefF gibi), belirli bir sınıflandırma sorunu için verilerin en ilgili özelliklerini tanımlamak ve sıralamak için makine öğreniminde kullanılan özellik seçme teknikleridir. Bu yöntemler hem ilgili hem de

ilgisiz özelliklere sahip verilerle ilgilenmedeki etkinlikleri açısından özellikle dikkat çekicidir ve özellikler arasındaki etkileşimleri de ele alabilirler [37].

Yöntem, veri kümesinden rastgele bir örnek seçerek başlar. Algoritma aynı sınıftan en yakın komşuyu ve farklı sınıfların her birinden en yakın komşuyu. Öklid mesafesi gibi mesafe ölçümleri bunun için yaygın olarak kullanılır. Algoritma her özellik için puanını günceller. Bir özelliğin puanı, seçilen örneği farklı sınıflardaki komşulardan ayırt ederse artar ve seçilen örnek ile aynı sınıftaki komşular arasında ayrım yapamadığında azalır. Bu süreç, her seferinde rastgele yeni bir örnek seçilerek ve özellik puanları güncellenerek birden çok kez tekrarlanır. Birkaç yinelemeden sonra özellikler, puanlarına göre sıralanır. Daha yüksek puanlar, farklı sınıfların örnekleri arasında ayrım yapmada daha iyi oldukları için sınıflandırmayla daha ilgili olan özellikleri gösterir.

Relief yöntemi özellikle ilgili ve ilgisiz özelliklerin bir karışımına sahip olduğunuz durumlarda kullanışlıdır. Veri kümesinin boyutluluğunu azaltarak ve potansiyel olarak bir makine öğrenimi modelinin performansını artırarak, sınıflandırma görevi için gerçekten önemli olan özelliklerin belirlenmesine yardımcı olur.

3.2.3. Sınıflandırma Yöntemleri

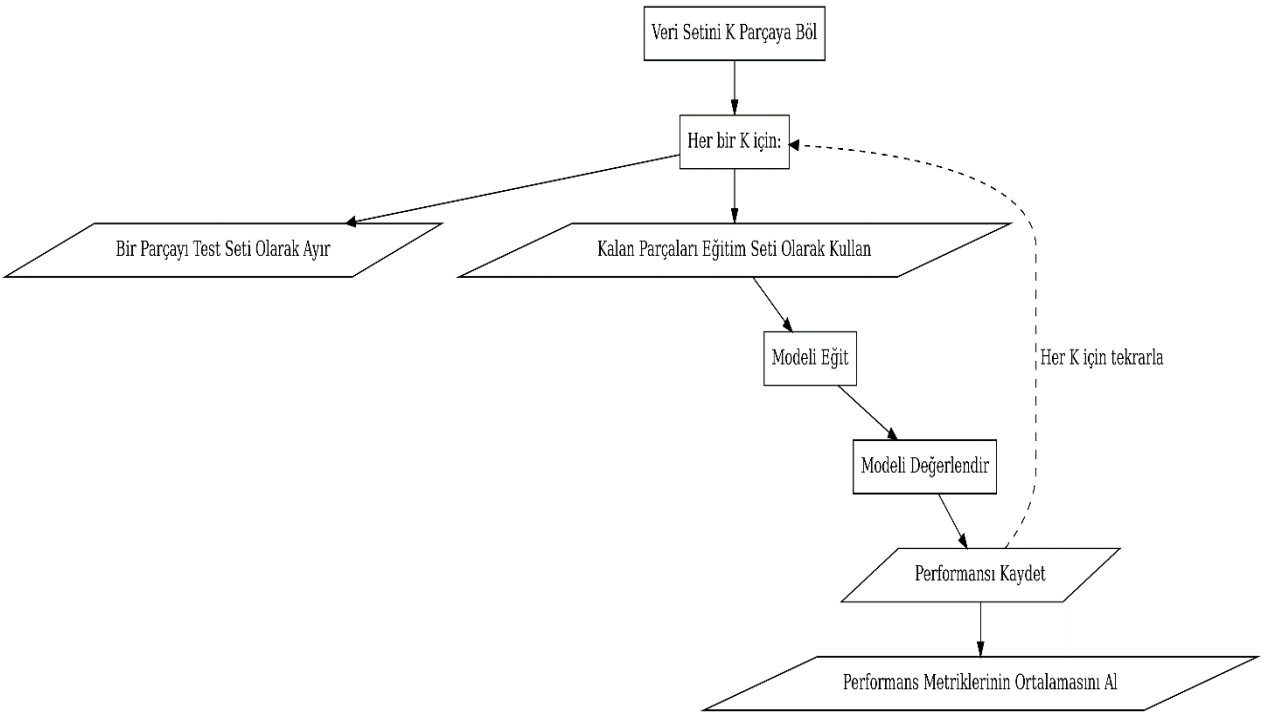
Sınıflandırma yöntemleri, veri bilimi ve makine öğrenmesi alanlarında sıklıkla kullanılan temel tekniklerdir. Bu yöntemler, veri setlerindeki örnekleri belirli kategorilere veya sınıflara ayırmak için kullanılır. Sınıflandırma, denetimli öğrenme türünde yer alır, yani model eğitim sürecinde hem girdi verilerini hem de bu verilerin hangi sınıfa ait olduğunu gösteren etiketleri kullanır. Model eğitildikten sonra, etiketlenmemiş yeni verileri sınıflandırabilir hale gelir.

3.2.3.1. K-katlı Çapraz Doğrulama

K-katlı çapraz doğrulama, bir makine öğrenimi modelinin performansını değerlendirmek ve modelin bağımsız veri setleri üzerindeki güvenirliğini ve etkinliğini sağlamak için kullanılan istatistiksel bir tekniktir. Veri sınırlı olduğunda özellikle yararlı olan bu yöntem, verilerin eğitim ve test amaçları için maksimum düzeyde kullanılmasına yardımcı olur.

Bu yöntemde, tüm veri seti, 'k' eşit büyüklükteki kat veya parçaya rastgele bölünür. Bu parçalardan biri test için ayrılırken, kalan 'k-1' parça eğitim verisi olarak kullanılır. Bu işlem her bir parça tam olarak bir kez test seti olacak şekilde 'k' kez tekrarlanır. Sonunda, modelin

performansı, her bir tekrarlama için elde edilen sonuçların ortalaması alınarak hesaplanır. Şekil 3.8 de K-katlı Çapraz Doğrulama akış şeması görülmektedir.



Şekil 3.8: K-Katlı çapraz doğrulama akış diyagramı.

3.2.3.2. Destek Vektör Makineleri (Support Vector Machines – SVM)

Destek Vektör Makineleri (SVM), verileri hiperdüzlemlerle ayıran etkili bir veri sınıflandırma yöntemidir. Genellikle makine öğrenimi alanında kullanılır ve özellikle örüntü tanıma ve sınıflandırma problemlerinde tercih edilir. İlk olarak Boser, Guyon ve Vapnik tarafından [38] tanıtılan SVM, çeşitli uygulamalarda geniş kabul görmüştür. Diğer istatistiksel sınıflandırma yöntemleri olan sinir ağları ve karar ağaçları ile karşılaştırıldığında, SVM eğitildikten sonra yeni veri kümelerinin sınıflandırılmasını son derece hızlı bir şekilde gerçekleştirebilir. SVM'lerin etkinliği ve verimliliği nedeniyle metin sınıflandırma, görüntü sınıflandırma, spam tespiti, el yazısı tanımlama, gen ifadesi analizi, yüz tespiti, biyolojik ve diğer bilimler alanında yaygın olarak kullanılmaktadır.

Destek Vektör Makineleri (SVM), karar sınırlarını belirleyen karar düzlemleri (hiperdüzlem) kavramına dayanır. Karar düzlemi, farklı sınıf üyeliklerine sahip nesneleri ayıran bir düzlemdir. İdeal bir karar düzlemi, herhangi bir sınıfın en yakın eğitim veri noktalarına en büyük mesafeye sahip olan düzlemdir. Bu mesafe, marj olarak adlandırılır. Karar düzleminin destekçileri, karar

düzlemine en yakın olan ve karar düzleminin konumunu belirlemede rol oynayan eğitim veri noktalarıdır. En iyi karar düzlemi, maksimum marja sahip olan, yani iki sınıfın destekçileri arasındaki maksimum mesafeye sahip olan düzlemdir. Başka bir deyişle, marj ne kadar büyük olursa, sınıflandırıcının genelleme yeteneği o kadar iyi olur.

Bir x girdi vektörü için hiper-düzlem şu şekilde tanımlanır:

$$f(x) = w^T x + b = 0 \quad (3.9)$$

Burada w ağırlık vektörüdür ve b yanlılık (bias) terimidir. Karar fonksiyonu, w ve b kullanılarak sign($f(x)$) olarak hesaplanır. Marj, hiperdüzleme en yakın olan destek vektörlerin düzleme dik olan mesafesi olarak tanımlanır. Bu mesafe maksimize edildiğinde, modelin genelleme hatası minimize edilmiş olur.

Hiper düzlemin optimalliği, her kategorideki en yakın veri noktaları arasındaki en büyük marj ile belirlenir. Karar düzleminin destekleyicisi olan veri noktalarına destek vektörleri denir. SVM modelinde, özellikle doğrusal olmayan, gürültülü bir veri seti durumunda ve mükemmel olarak ayrılabilir olmayan veri setleri için, yumuşak marjın yaklaşımı kullanılır. Bu yaklaşım, veri setindeki gürültüyü ve diğer anomalileri tolere etmek amacıyla tasarlanmıştır. Yumuşak marjın, modelin bazı veri noktalarını yanlış sınıflandırmaya izin verir, böylece genel modelin aşırı uyuma (overfitting) karşı daha dirençli olmasını sağlar. Sert marj, yumuşak marj ve destek vektörleri Şekil 3.9 da görülmektedir.

Slack değişkenleri ξi, her bir veri noktası için tanımlanır ve bu değişkenler, belirli veri noktalarının marjın yanlış tarafında olmasına izin verir. Eğer bir veri noktası doğru şekilde sınıflandırılmışsa ve marjın sınırları içindeyse, ilgili slack değişkeni sıfır olur. Eğer veri noktası yanlış sınıflandırılmışsa veya marjın sınırlarının dışındaysa, slack değişkeni sıfırdan büyük bir değer alır ve bu değer, noktanın marjın sınırından ne kadar uzakta olduğunu gösterir.

En iyi karar sınırı, eğitim verilerinde maksimum marja ve minimum hataya sahip olan sınırdır.

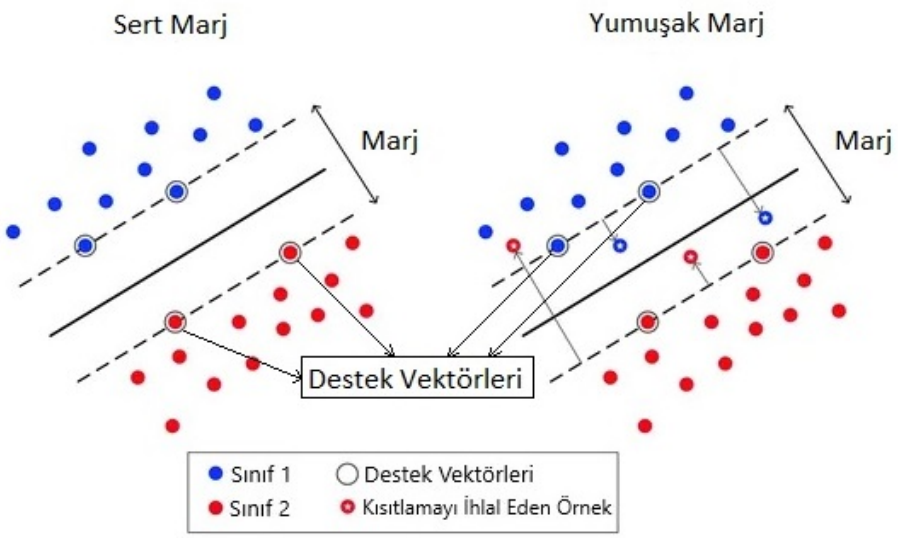
Yumuşak marjın SVM'in optimizasyon problemi genellikle aşağıdaki gibi formüle edilir:

$$\min(1/2|w|^2 + C\sum(i=1)^N \xi_i) \quad (3.10)$$

C: ceza parametresidir

w: modelin ağırlık vektörüdür.

$\boldsymbol{\xi i}$: $i'nci\ veri\ noktasının\ slack\ değişkenidir$



Şekil 3.9: Destek Vektör makineleri Sert ve Yumuşak Marj.

Çekirdek Yöntemleri

Doğrusal olmayan sınıflandırma problemleri için SVM, çekirdek fonksiyonlar kullanarak özellik uzayını dönüştürür. Çekirdek fonksiyonları, orijinal veri uzayını daha yüksek boyutlu bir uzaya dönüştürerek lineer olmayan ilişkileri lineer hale getirir. En yaygın kullanılan çekirdek fonksiyonları olan lineer, polinom, Radyal Temel Fonksiyon (RBF) ve sigmoid çekirdekleridir.

Lineer Çekirdek: Lineer çekirdek, en basit çekirdek fonksiyonudur ve herhangi bir özellik dönüşümü uygulamadan doğrudan veri noktalarının lineer kombinasyonlarını kullanır. Bu çekirdek, veriler zaten lineer olarak ayrılabilir olduğunda tercih edilir.

İfade edilmesi şu şekildedir:

$$K(x, z) = x^T z \tag{3.11}$$

Polinom Çekirdek: Polinom çekirdek, girdi vektörlerinin daha yüksek dereceden polinom uzayına dönüştürülmesine dayanır. Bu dönüşüm, doğrusal olmayan veri yapılarını etkili bir şekilde ele alabilmek için daha yüksek boyutlu bir özellik uzayında lineer bir sınıflandırıcı kullanılmasına izin verir.

İfade edilmesi şu şekildedir:

$$K(x, z) = (\gamma x^T z + r)^d \quad (3.12)$$

x ve z girdi vektörleridir, γ ölçekleme faktörüdür ve genellikle veri ölçeklendirilmesi için kullanılır. r serbest terimdir ve polinomun sabit bölümünü ayarlar. d polinomun derecesidir ve modelin karmaşıklığını belirler, d derecesi 2 olduğunda ikinci dereceden polinom çekirdek olmuş olur "quadratic kernel", 3 olduğunda ise 3. Dereceden polinom çekirdek, "cubic kernel" diye ifade edilir.

Radyal Temel Fonksiyon (RBF) Çekirdek: RBF çekirdek, iki örnek arasındaki uzaklığa bağlı olarak benzerliği ölçer ve genellikle Gauss çekirdeği olarak da bilinir. RBF çekirdeği, özellikle veri noktaları arasındaki uzaklık büyük olduğunda, yüksek derecede yerel benzerlikler yakalamada etkilidir.

İfade edilmesi şu şekildedir:

$$K(x, z) = exp(-\gamma|x - z|^2) \quad (3.13)$$

x ve z girdi vektörleri

γ ise ölçekleme parametresi ve bu parametre çekirdeğin genişliğini belirler.

"**Medium Gaussian Kernel**" terimi, γ değerinin ne çok yüksek ne de çok düşük olduğu, yani "orta" bir değer alması durumunu ifade eder. Bu orta seviye ayar, çekirdeğin ne çok dar ne de çok geniş olmasını sağlayarak, modelin hem yerel hem de genel özellikleri dengeli bir şekilde yakalamasına olanak tanır. Bu tür bir ayar, veri setindeki genel yapıyı öğrenirken aşırı uyuma (overfitting) veya yetersiz uyuma (underfitting) riskini minimize eder. Medium Gaussian Kernel kullanırken, γ parametresinin optimal değerini belirlemek için çapraz doğrulama yöntemi önerilir. Çapraz doğrulama, modelin farklı γ değerleriyle test edilmesini ve en iyi performans gösteren değerin seçilmesini sağlar. Bu süreç, modelin farklı veri kümeleri üzerindeki genelleme kabiliyetini artırır ve en iyi sonuçları elde etmeye yardımcı olur.

"**Coarse Gaussian SVM**" terimi, SVM (Support Vector Machine) kullanarak bir sınıflandırma veya regresyon modeli oluştururken, Gaussian (RBF- Radial Basis Function) çekirdeği kullanılırken özellikle geniş bir çekirdek genişliğine sahip bir ayarın seçilmesini ifade eder. Burada "coarse" (kaba) kelimesi, modelin daha geniş özellikleri dikkate alarak daha geniş çapta

bir genelleme yapmasını belirtir. Bu tür bir model, özellikle veri üzerindeki küçük değişiklikler ve gürültülü veriler tarafından kolayca etkilenmemesi isteniyorsa tercih edilir. Coarse Gaussian Kernel'de γ parametresi düşük tutularak çekirdeğin etki alanı genişletilir. Bu durumda, çekirdek fonksiyonu, örnekler arasındaki uzaklıkları daha büyük bir toleransla ele alır ve model daha geniş özellik yapılarına odaklanır. Bu geniş çekirdek genişliği, modelin veri üzerindeki küçük değişikliklere karşı daha dayanıklı olmasını sağlar, ancak aynı zamanda modelin bazı önemli yerel özellikleri göz ardı etmesine de neden olabilir.

Sigmoid Çekirdek: Sigmoid çekirdek, genellikle sinir ağlarında kullanılan aktivasyon fonksiyonlarına benzer bir yapı sunar ve verileri sigmoid fonksiyonu üzerinden dönüştürür.

İfade edilmesi şu şekildedir:

$$K(x, z) = tanh(\gamma x^T z + r) \quad (3.14)$$

γ: ölçeklendirme faktörü

r: serbest terim

Sigmoid çekirdek, özellikle veriler üzerinde doğrusal olmayan dönüşümler gerçekleştirmek için kullanılır, ancak dikkatli kullanılması gerekir çünkü her zaman geçerli bir çekirdek matrisi üretmeyebilir.

3.2.3.3. Doğrusal (Lineer) Diskriminant Analizi (LDA)

Lineer Diskriminant Analizi (LDA), bir istatistiksel sınıflandırma tekniğidir ve veri setlerindeki örnekleri farklı gruplara veya sınıflara ayırmak için kullanılır. Bu teknik, boyut indirgeme amacıyla da kullanılabilir. Ana düşünce, verileri en iyi ayıran eksenleri veya "diskriminantları" bulmaktır. İki sınıflı bir durumda, LDA (Lineer Diskriminant Analizi), sınıflar arasındaki değişkenliği maksimuma çıkarmaya çalışırken, sınıf içi değişkenliği minimuma indiren bir doğrusal kombinasyon bulmaya çalışır.

LDA'nın matematiksel formülasyonu şu şekildedir:

Sınıf İçi Dağılım Matrisi SW (Within-Class Scatter Matrix):

$$S_W = \sum_{i=1}^{C} \sum_{x \in D_i} (x - \mu_i)(x - \mu_i)^T \quad (3.15)$$

$Burada\ C\ sınıf\ sayısını, Di'nci\ sınıfa\ ait\ gözlemleri,$

μ *ise* $i'nci$ *sınıfın ortalamasını ifade eder.*

Sınıflar Arası Dağılım Matrisi (Between-class scatter matrix):

$$S_B = \sum_{i=1}^{C} N_i(\mu_i - \mu)(\mu_i - \mu)^T \quad (3.16)$$

Burada μ *genelortalama ve* $Ni'nci$ *sınıftaki gözlem sayısıdır.*

Diskriminant Vektörleri: Diskriminant vektörleri, $\left(\boldsymbol{S_W^{-1}S_B}\right)$ matrisinin özvektörleri olarak hesaplanır ve bu vektörler, veri setini en iyi ayıran yönleri belirler.

$$\text{Diskriminant Vektörler} = \text{Özvektörler}(S_W^{-1}S_B)$$

3.2.3.4. K-en Yakın Komşu (KNN) algoritması

K-en Yakın Komşu (KNN), gözetimli öğrenme algoritmaları içinde yer alan ve sınıflandırma ile regresyon problemleri için kullanılan temel bir yöntemdir. KNN algoritması, bir nesnenin sınıfını veya değerini, ona en yakın olan diğer önceden tanımlanmış nesnelerin sınıfları temel alarak tahmin eder. KNN algoritması, bir öğrenme modelinin öğrenme aşamasını gerektirmez; bunun yerine, veri noktalarının tamamını hafızada tutar ve sınıflandırma yapılacak nokta sorgulandığında işlem gerçekleştirir. Bu nedenle "tembel öğrenme" (lazy learning) metotları arasında sınıflandırılır.

KNN algoritmasında, parametre olarak belirlenen K değeri, bir test veri noktasının sınıfını tahmin ederken göz önünde bulundurulacak en yakın komşu sayısını ifade eder. Veri noktaları arasındaki uzaklığı ölçmek için genellikle Öklid, Manhattan veya Minkowski uzaklığı gibi metrikler kullanılır. Test noktası, en yakın K komşularının çoğunlukla ait olduğu sınıfa atanır.

Öklid Uzaklığı

En yaygın kullanılan uzaklık metriği Öklid uzaklığıdır. İki nokta P=($p1$, $p2$,...,pn) Q=($q1$,$q2$,...,qn) arasındaki Öklid uzaklığı şu formülle hesaplanır:

$$d(P,Q) = \sqrt{\sum_{i=1}^{n}(p_i - q_i)^2} \quad (3.17)$$

Manhattan Uzaklığı

Manhattan uzaklığı, iki nokta arasındaki mesafeyi "şehir bloğu" olarak hesaplar ve aşağıdaki formülle tanımlanır:

$$d(P,Q) = \sum_{i=1}^{n}|p_i - q_i| \quad (3.18)$$

Minkowski Uzaklığı

Minkowski uzaklığı, Öklid ve Manhattan uzaklıklarının genelleştirilmiş bir formudur ve parametre p ile ifade edilir:

$$d(P,Q) = (\sum_{i=1}^{n}|p_i - q_i|^p)^{1/p} \quad (3.19)$$

Burada p bir parametredir; p=2 olduğunda Öklid, p=1 olduğunda Manhattan uzaklığına dönüşür.

Cubic KNN, Fine KNN, Cosine KNN

"Cubic KNN", genellikle KNN algoritmasında kullanılan uzaklık ölçütünü ifade eder. Bu varyasyonda, Minkowski uzaklığı p=3 alınarak kullanılır ki bu da "kübik" teriminin kökenidir.

"Fine KNN", algoritmanın parametrelerinin (örneğin K değeri) çok dikkatli bir şekilde seçildiği ve genellikle daha küçük K değerleri kullanıldığı bir KNN türünü ifade eder. Bu terim, algoritmanın daha hassas ve detaylı bir sınıflandırma yapabilmesi için kullanılır. Fine KNN genellikle, modelin aşırı uydurmasını (overfitting) önlemek amacıyla küçük veri kümelerinde tercih edilir. Fine KNN, modelin daha kararlı ve genellemeye daha uygun olmasını sağlamak için küçük komşuluk değerleri ile daha dikkatli bir biçimde uygulanır.

"Cosine KNN", uzaklık ölçümü olarak kosinüs benzerliğini kullanan bir KNN varyasyonudur. Bu yöntem, özellikle metin madenciliği ve doğal dil işleme gibi alanlarda yaygın olarak kullanılır. Kosinüs benzerliği, iki vektörün arasındaki açının kosinüsünü alarak, vektörlerin yönlerinin benzerliğini ölçer, büyüklüklerini dikkate almaz.

İfade edilmesi şu şekildedir:

$$"benzerlik"\ (P,Q) = (P \cdot Q)/(|P||Q|) \quad (3.20)$$

Burada $P{\cdot}Q$ iki vektörün nokta çarpımını, $\|P\|$ve $\|Q\|$ ise sırasıyla P ve Q vektörlerinin normlarını (Euclidean uzunluklarını) ifade eder. Normlar, vektörlerin büyüklüklerini temsil eder. Cosine KNN, benzerlik skoru yüksek olan komşuları baz alarak sınıflandırma yapar.

3.2.3.5. Bagged Ensemble (Bagging ya da Bootstrap Aggregating) Sınıflandırma Yöntemi

Bagged Ensemble (Bagging ya da Bootstrap Aggregating) sınıflandırma yöntemi, birçok zayıf tahmin modelinin tahminlerini bir araya getirerek bir topluluk (ensemble) model oluşturma temeline dayanır. Bu yöntem, Leo Breiman tarafından 1996 yılında geliştirilmiştir ve temel

amacı, tekil tahmin modellerindeki varyansı azaltarak daha kararlı ve doğru tahminler yapabilmektir.

Veri setinden, yineleme ile rastgele örnekler çekerek birden fazla alt veri seti oluşturulur. Bu alt veri setleri orijinal veri setinin yaklaşık olarak aynı boyutta ancak farklı örneklemeler içerir. Her bir alt veri seti, aynı sınıflandırma algoritması (karar ağaçları) kullanılarak ayrı ayrı eğitilir. Bu süreç, her bir alt set için bağımsız olarak tekrarlanır ve her biri için bir model oluşturulur. Oluşturulan tüm modellerin tahminleri, çoğunluk oyu (sınıflandırma için) veya ortalama alma (regresyon için) yöntemleri kullanılarak birleştirilir. Bu birleştirme, toplam tahminin daha doğru ve kararlı olmasını sağlar. Bagging, karar ağaçları gibi yüksek varyansa sahip modellerle özellikle iyi çalışır ve rastgele ormanlar (random forests) gibi daha karmaşık topluluk yöntemlerinin temelini oluşturur. Karar ağaçları bagging ile birleştirildiğinde, her bir ağaç farklı veri alt kümelerinden elde edilen bilgilerle oluşturulur ve sonuçlar birleştirilerek genel bir sonuca ulaşılır. Bu süreç, modelin hem doğruluğunu artırır hem de aşırı uyum sorununu azaltır.

3.2.3.6. Rusboost Ensemble Sınıflandırma Yöntemi

RUSBoost, sınıflandırma problemleri için geliştirilmiş özel bir topluluk (ensemble) öğrenme algoritmasıdır ve özellikle dengesiz veri setleri üzerinde çalışırken etkilidir. RUSBoost, "Random Under-Sampling Boost" ifadesinin kısaltmasıdır ve hem random under-sampling (RUS) hem de AdaBoost algoritmasının birleşimini içerir. Bu yöntem, dengesiz sınıf dağılımlarında azınlık sınıfına ait örneklerin doğru bir şekilde sınıflandırılmasını iyileştirmeyi amaçlar.

Random Under-Sampling (RUS): Dengesiz veri setlerinde, çoğunluk sınıfına ait örneklerin sayısı azınlık sınıfına göre çok fazladır. RUS adımında, çoğunluk sınıfından rastgele örnekler azaltılarak (under-sampling) her bir iterasyonda dengeli bir veri seti oluşturulur. Bu, azınlık sınıfının örneklerinin göz ardı edilmesini önler ve modelin azınlık sınıfa daha iyi odaklanmasını sağlar.

Boosting: Boosting, zayıf sınıflandırıcıların bir dizi iterasyon boyunca uygulanarak, her biri önceki iterasyonlardaki hatalar üzerine kurularak güçlendirilmesi sürecidir. RUSBoost'ta, her iterasyonda elde edilen dengeli veri seti üzerinden bir zayıf sınıflandırıcı eğitilir. Öğrenme süreci boyunca, yanlış sınıflandırılan örneklerin ağırlıkları artırılır, böylece sonraki zayıf sınıflandırıcılar bu örnekleri doğru sınıflandırmaya daha fazla odaklanır.

Algoritmanın temel adımları şu şekilde ifade edilir,

- Başlangıçta, tüm veri noktalarına eşit ağırlık verilir.
- Her iterasyonda:
    - Random under-sampling ile dengeli bir veri seti oluşturulur.
    - Bu veri seti üzerinde bir zayıf sınıflandırıcı (genellikle bir karar ağacı) eğitilir.
    - Sınıflandırıcının performansına bağlı olarak, hatalı sınıflandırılan örneklerin ağırlıkları artırılır.
    - Bu süreç, belirlenen iterasyon sayısı kadar veya erken durdurma kriterleri sağlanana kadar devam eder.
- Sonuçta, tüm zayıf sınıflandırıcılar ağırlıklı bir şekilde birleştirilerek nihai bir model oluşturulur.

3.2.3.7. Subspace Dimension Ensemble Sınıflandırma Yöntemi

Subspace Dimension Ensemble, özellikle yüksek boyutlu veri setlerinde sınıflandırma problemleri için geliştirilmiş bir topluluk (ensemble) öğrenme yöntemidir. Bu yöntem, veri setinin boyutunu azaltmak ve sınıflandırma performansını artırmak için alt uzaylar (subspaces) oluşturarak çalışır. Bu yöntem, yüksek boyutluluk sorunlarını hafifletmeye ve modelin genelleme yeteneğini artırmaya yardımcı olur.

1. **Alt Uzayların Oluşturulması:** Bu adımda, orijinal özellik uzayından daha düşük boyutlu alt uzaylar oluşturulur. Her alt uzay, ana veri setinden rastgele seçilen özelliklerden oluşur. Bu işlem, her bir modelin farklı özellik kombinasyonları üzerinde eğitilmesini sağlar, böylece modelin çeşitliliği artar ve aşırı uyum (overfitting) riski azalır.

2. **Model Eğitimi:** Her bir alt uzay için ayrı bir model (genellikle zayıf sınıflandırıcılar gibi karar ağaçları) eğitilir. Bu modeller, kendi alt uzaylarındaki veriler üzerinde eğitilir ve her biri farklı özelliklerin bilgisini kullanarak öğrenir.

3. **Model Sonuçlarının Birleştirilmesi:** Tüm alt uzay modellerinin tahminleri, çoğunluk oylaması veya ortalama alma gibi yöntemlerle birleştirilir. Bu birleştirme işlemi, sınıflandırmanın sonucunu belirler ve genellikle ensemble yöntemlerinin nihai adımıdır.

3.3. EEG SİNYALLERİ VE DERİN ÖĞRENME KULLANILARAK BEGENİ DURUM KESTİRİMİ

Katılımcılardan aldığımız EEG verilerini Kısa Zamanlı Fourier Dönüşümü (STFT) ile imge haline getirildi. İmge haline getirilen EEG verileri Derin Öğrenme- Transfer Öğrenme ile beğeni durum kestirimi yapıldı.

3.3.1. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insan beynindeki nöron ağlarından esinlenerek geliştirilmiş hesaplama modelleridir ve özellikle desen tanıma, sınıflandırma ve tahmin gibi görevlerde kullanılır. YSA'lar, girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere üç ana katmandan oluşur. Girdi katmanı ham veriyi alır, gizli katmanlar bu veriyi işler ve dönüştürür, çıktı katmanı ise nihai sonucu üretir. Nöronlar arasındaki her bağlantının ilişkili bir ağırlığı vardır ve her nöronun, eğitim sırasında hataları en aza indirecek şekilde ayarlanan bir önyargısı vardır. Aktivasyon fonksiyonları, bir nöronun çıktı değerini belirler ve yaygın olarak sigmoid, tanh, ReLU ve softmax gibi fonksiyonlar kullanılır. Sinir ağları öğrenme sürecinde, ileri yayılım ile girdi verisi ağ boyunca ilerleyerek bir çıktı oluşturur ve kayıp fonksiyonu aracılığıyla bu çıktının hedef değerlerden ne kadar farklı olduğu hesaplanır. Geri yayılım yöntemiyle, ağırlık ve önyargılar güncellenerek kayıp azaltılmaya çalışılır. Bu süreçte gradyanlar hesaplanır ve gradyan azaltma algoritmaları (SGD, Adam gibi) kullanılır. Farklı YSA türleri arasında basit görevler için ileri beslemeli sinir ağları, görüntü işleme için evrişimli sinir ağları (CNN'ler), sıralı veriler için tekrarlayan sinir ağları (RNN'ler) ve gerçekçi veriler üretmek için üretken rakip ağlar (GAN'lar) bulunur. Görüntü tanıma, doğal dil işleme, ses tanıma, otonom araçlar ve sağlık gibi birçok alanda uygulanırlar. Ancak, aşırı uyum, yüksek hesaplama maliyetleri ve yorumlanabilirlik gibi zorluklar da barındırırlar. Yapay Sinir Ağları, veri analizinde ve yorumlamada güçlü araçlar sunarak geniş bir yelpazede devrim niteliğinde çözümler sağlar.

3.3.2. Derin Öğrenme

Çok katmanlı sinir ağlarının kullanımıyla karakterize edilen (dolayısıyla "derin" terimi) bu yaklaşım, ham verilerden yüksek seviyeli özelliklerin otomatik olarak çıkarılmasına olanak

tanır. Derin öğrenme modelleri, özellikle evrişimli sinir ağları (CNN'ler) ve tekrarlayan sinir ağları (RNN'ler), görüntü ve konuşma tanıma, doğal dil işleme ve otonom sürüş gibi görevlerde dikkate değer bir başarı göstermiştir.

Makine öğrenimi ve yapay zekanın bir alt kümesi olan derin öğrenme, çok büyük miktarda veriden öğrenebilen ve karar verebilen algoritmaların geliştirilmesini sağlayarak birçok alanda devrim yarattı. Manuel özellik çıkarımı gerektiren geleneksel makine öğrenimi modellerinin aksine, derin öğrenme, ham verilerden yüksek seviyeli özellikleri otomatik olarak çıkarmak için birçok katmana sahip sinir ağlarını (bu nedenle "derin" terimi) kullanır. Derin öğrenme modelleri, özellikle evrişimli sinir ağları (CNN'ler) ve tekrarlayan sinir ağları (RNN'ler), görüntü ve konuşma tanıma, doğal dil işleme ve otonom sistemler gibi alanlarda önemli atılımların gerçekleştirilmesinde etkili olmuştur. Derin öğrenme modellerinin başarısı büyük ölçüde büyük veri kümelerinden iyi genelleme yapma yeteneklerine ve veriler içindeki karmaşık kalıpları ve ilişkileri yakalamadaki yeterliliklerine bağlanıyor. Ayrıca, hesaplama gücündeki ilerlemeler ve büyük veri kümelerinin kullanılabilirliği, derin öğrenme tekniklerinin hızlı ilerlemesini ve benimsenmesini hızlandırmış, bu da onları hem akademik araştırmalarda hem de pratik uygulamalarda vazgeçilmez araçlar haline getirmiştir. Derin öğrenme gelişmeye devam ettikçe, daha da karmaşık ve akıllı sistemlerin kilidini açmayı ve çeşitli sektörlerde inovasyonu teşvik etmeyi vaat etmektedir.

Derin öğrenmenin merkezinde, her biri basit bir hesaplama gerçekleştiren, birbirine bağlı düğümlerden veya nöronlardan oluşan katmanlardan oluşan sinir ağları bulunur. Bu katmanlar genel olarak üç türe ayrılabilir: giriş katmanları, gizli katmanlar ve çıkış katmanları. Giriş katmanı ham verileri alır ve sonraki katmanlara iletir. Çok sayıda olabilen ve derin öğrenmenin "derin" yönünü oluşturan gizli katmanlar, karmaşık dönüşümler ve özellik çıkarımları gerçekleştirir. Bu katmanlar, ağın derinliğinin karmaşık kalıpların ve hiyerarşik özelliklerin öğrenilmesini sağladığı yerdir. Son olarak çıktı katmanı, işlenmiş bilgiye dayalı olarak nihai tahmin veya sınıflandırmayı üretir. Bu katmanlardaki her nöron, girdilerinin ağırlıklı toplamına doğrusal olmayan bir aktivasyon fonksiyonu uygulayarak ağın verilerdeki doğrusal olmayan ilişkileri yakalamasına olanak tanır.

Derin bir sinir ağının eğitimi, geri yayılım adı verilen bir süreç yoluyla nöronlar arasındaki bağlantıların ağırlıklarının ayarlanmasını içerir; bu, ağırlıkları yinelemeli olarak güncelleyerek tahmin edilen ve gerçek çıktılar arasındaki hatayı en aza indirir. Bu eğitim, önemli hesaplama

kaynakları ve büyük veri kümeleri gerektirir, ancak ortaya çıkan modeller, karmaşık görevlerde dikkate değer doğruluk ve performans elde etme kapasitesine sahiptir.

3.3.3. Transfer Öğrenme

Transfer öğrenme, belirli bir görev için geliştirilen bir modelin ikinci bir görevdeki model için başlangıç noktası olarak yeniden kullanıldığı bir makine öğrenme tekniğidir. Bu yaklaşım, bir problem alanından elde edilen bilgiyi kullanır ve bunu farklı ancak ilişkili bir problem alanına uygular, böylece modelin yeni görevdeki verimliliğini ve performansını artırır. Transfer öğrenimi özellikle modellerin sıfırdan eğitilmesi için önemli miktarda veri ve hesaplama kaynağı gerektirdiği derin öğrenmede özellikle değerlidir.

Transfer öğrenmenin arkasındaki temel fikir, bir veri kümesindeki bir model tarafından öğrenilen belirli özelliklerin farklı veri kümeleri ve görevler için yararlı olabilmesidir. Örneğin, ImageNet gibi geniş bir görüntü veri kümesi üzerinde eğitilmiş derin bir sinir ağı, kenarlar, dokular ve şekiller gibi genel özellikleri tanımayı öğrenebilir. Öğrenilen bu özellikler, hedef veri kümesinin çok daha küçük olabileceği tıbbi görüntü analizi gibi görüntüyle ilgili başka bir göreve aktarılabilir.

Transfer öğrenme genellikle aşağıdaki adımları içerir:

1. **Önceden Eğitilmiş Model Seçimi**: Büyük ve çeşitli bir veri kümesi üzerinde önceden eğitilmiş bir model seçin. Yaygın seçenekler arasında ImageNet veri kümesi üzerinde eğitilmiş VGG, ResNet ve Inception gibi modeller yer alır.

2. **Model Uyarlaması**: Önceden eğitilmiş modeli yeni göreve uyacak şekilde değiştirin. Bu genellikle yeni görevdeki sınıf sayısına uyacak şekilde modelin son katmanlarının değiştirilmesini veya yeni göreve özel yeni katmanların eklenmesini içerir.

3. **Özellik Çıkarma veya İnce Ayar**:

    - **Özellik Çıkarma**: Önceden eğitilmiş katmanları dondurun, böylece eğitim sırasında ağırlıkları değişmez. Yalnızca belirli bir görev için eklenen yeni katmanlar eğitilir. Bu yaklaşım, aşırı uyum riskini azalttığı için yeni veri kümesi küçük olduğunda kullanışlıdır.

- **İnce ayar**: Önceden eğitilmiş katmanların bir kısmını veya tamamını çözün ve bunları yeni katmanlarla birlikte eğitin. Bu yaklaşım, özellikle yeni veri kümesi yeterince büyük olduğunda, modelin öğrenilen özellikleri yeni göreve daha etkili bir şekilde uyarlamasına olanak tanır.

4. **Eğitim ve Optimizasyon**: Değiştirilen modeli yeni veri kümesi üzerinde eğitin. Önceden eğitilmiş modelin başlangıç ağırlıkları genellikle rastgele başlatmaya göre daha iyi bir başlangıç noktası sağlayarak daha hızlı yakınsamaya ve daha iyi performansa yol açar.

Transfer öğrenimi çeşitli avantajlar sunar:

- **Azaltılmış Eğitim Süresi**: Önceden eğitilmiş bir modelden yararlanmak, model zaten iyi optimize edilmiş bir durumdan başladığından, yeni bir modeli eğitmek için gereken süreyi önemli ölçüde azaltabilir.

- **Geliştirilmiş Performans**: Önceden eğitilmiş modeller, özellikle yeni veri kümesi küçük olduğunda veya görev orijinal görevle ilgili olduğunda genellikle yeni görevde daha iyi performans elde eder.

- **Kaynak Verimliliği**: Transfer öğrenimi, derin öğrenme tekniklerinin sınırlı veri ve hesaplama kaynaklarına sahip görevlere uygulanmasını mümkün kılar.

Transfer öğrenme (transfer learning) sırasında, modelin performansını ve eğitim sürecini optimize etmek için belirli hiperparametreler önemli rol oynar. Bunlar arasında başlangıç öğrenme hızı (initial learning rate) ve mini batch boyutu (mini batch size) öne çıkar. Bu hiperparametrelerin doğru şekilde ayarlanması, modelin yeni göreve adaptasyonunu ve genel performansını doğrudan etkileyebilir.

3.3.3.1. Başlangıç Öğrenme Hızı (Initial Learning Rate)

Başlangıç öğrenme hızı, modelin ağırlıklarının güncellenme hızını belirler. Transfer öğrenme sırasında, önceden eğitilmiş bir modelin ağırlıkları, yeni görev için adapte edilirken başlangıç öğrenme hızı dikkatle seçilmelidir:

1. **Düşük Öğrenme Hızı**: Genellikle transfer öğrenmede düşük bir başlangıç öğrenme hızı tercih edilir. Bu, önceden öğrenilen özelliklerin aşırı derecede değiştirilmesini önler ve yeni görev için ince ayar yapılmasına olanak tanır. Özellikle modelin son katmanlarının

dışındaki katmanlar dondurulmadığında (fine-tuning yapıldığında), düşük öğrenme hızı, transfer edilen bilgilerin korunmasını sağlar.

2. **Yüksek Öğrenme Hızı**: Yeni eklenen katmanlar veya son katmanlar için başlangıçta daha yüksek bir öğrenme hızı kullanılabilir. Bu, bu katmanların yeni göreve daha hızlı adapte olmasına yardımcı olabilir. Ancak, tüm katmanlar için yüksek bir öğrenme hızı kullanmak, modelin hızlı bir şekilde aşırı öğrenmesine (overfitting) veya stabil olmamasına neden olabilir.

3.3.3.2. Mini Yığın Boyutu (Mini Batch Size)

Mini yığın boyutu, eğitim verisinin küçük gruplar halinde modele sunulmasını ifade eder. Bu boyut, modelin eğitim sürecini ve bellek kullanımını etkiler:

1. **Küçük Mini Yığın Boyutu**: Küçük bir yığın boyutu, modelin daha sık güncellenmesini sağlar ve genellikle daha iyi genelleme performansı elde edilmesine yardımcı olabilir. Ancak, küçük yığın boyutları, eğitim süresinin uzamasına ve her güncelleme sırasında daha fazla gürültü olmasına neden olabilir.

2. **Büyük Mini Yığın Boyutu**: Büyük yığın boyutları, eğitim sürecini hızlandırabilir ve daha stabil gradyan güncellemeleri sağlar. Ancak, büyük yığın boyutları daha fazla bellek gerektirir ve genelleme performansını olumsuz etkileyebilir. Ayrıca, modelin lokal minimumlara sıkışma olasılığı da artabilir.

3.3.3.3. Transfer Öğrenmede Kullanılan Derin Ağ Mimarileri

Çalışmamızda Spectrogram ile imge haline getirilen EEG verileri Derin Katmanlı Ağlar ile eğitilmiş ve sınıflandırılmıştır. Squeezenet, googlenet, resnet18, mobilenetv2, resnet50, resnet101, inceptionv3 ve inceptionresnetv2 derin katmanlı ağlar kullanılarak sınıflandırma sonuçları elde edilmiştir.

1. Squeezenet

Derin öğrenme tabanlı görüntü sınıflandırma görevlerinde parametre sayısını ve model boyutunu önemli ölçüde azaltarak yüksek doğruluk elde etmeyi amaçlayan bir konvolüsyonel sinir ağı (CNN) mimarisidir. Bu model, Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally ve Kurt Keutzer tarafından 2016 yılında yayımlanan "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size"

başlıklı çalışmada tanıtılmıştır [39]. SqueezeNet'in orijinal versiyonu toplamda 18 katmandan oluşur.

SqueezeNet'in temel yapı taşı Fire modülüdür. Bir Fire modülü iki ana bileşenden oluşur:

1. Squeeze Katmanı: Bu katman, 1x1 konvolüsyon filtreleri kullanarak girdi kanallarının sayısını azaltır. Böylece, modelin parametre sayısında önemli bir düşüş sağlanır.

2. Expand Katmanı: Bu katman hem 1x1 hem de 3x3 konvolüsyon filtreleri kullanarak kanalları genişletir. Bu sayede, model daha karmaşık ve detaylı özellikler öğrenebilir.

2. GoogleNet

Inception V1 olarak da bilinen GoogleNet, Szegedy ve diğerleri tarafından tanıtılan evrişimli sinir ağı (CNN) mimarisinde önemli bir ilerlemeyi temsil etmektedir. Bu mimari, "Going Deeper with Convolutions" başlıklı makalede sunulmuştur ve temel amacı, hesaplama verimliliğini artırırken daha derin ve geniş ağların avantajlarını birleştirmektir [40].

GoogleNet'in mimarisi, ağın paralel olarak birden fazla filtre boyutuyla evrişimler gerçekleştirmesine olanak sağlamak üzere tasarlanmış **Inception modülleri** etrafında oluşturulmuştur. Bu yaklaşım, ağın çeşitli ölçeklerde çeşitli mekansal özellikleri yakalamasını sağlar. Inception modülleri, farklı boyutlardaki konvolüsyon ve havuzlama işlemlerini bir arada kullanarak, ağın daha geniş bir alanda özellik çıkarımını gerçekleştirmesine olanak tanır. GoogleNet, ya da Inception V1, 22 katmanlı bir derin öğrenme modelidir.

3. ResNet

Residual Networks (ResNet), derin öğrenme alanında önemli bir yenilik olan ve 2015 yılında Kaiming He ve diğerleri tarafından "Deep Residual Learning for Image Recognition" başlıklı makalede tanıtılmış bir mimaridir [41]. ResNet, özellikle derin ağların eğitiminde karşılaşılan gradyan azalması (vanishing gradient) problemini hafifletmek için artık bağlantılar (residual) kullanır. Bu yaklaşım, çok daha derin ağların başarılı bir şekilde eğitilmesine olanak tanır.

ResNet'in temel yeniliği, ağ derinliğinin arttırılmasının eğitim doğruluğunda doygunluğa veya bozulmaya yol açtığı çok derin ağlarda gözlemlenen bozulma sorununu gideren artık öğrenmenin tanıtılmasıdır. ResNet'in ayrıntılarına dalmadan önce bozulma sorununu anlamak önemlidir. Sinir ağları derinleştikçe, karmaşık temsilleri öğrenme kapasitelerinin artması

nedeniyle teorik olarak daha iyi performans göstermeleri gerekir. Ancak pratikte daha derin ağlar genellikle eğitim konusunda zorluk çeker ve sığ ağlara kıyasla daha yüksek eğitim hatası sergiler. Bunun nedeni aşırı uyum değildir; çünkü eğitim hatasının kendisi artar ve bu da daha derin ağların optimize edilmesinin daha zor olduğunu gösterir. Her residual blok, iki veya üç konvolüsyon katmanını bypass eden bir bağlantı içerir. Bu bağlantı, giriş sinyalini doğrudan çıkışa ekleyerek derin ağlarda bilgi akışını kolaylaştırır.

ResNet-18, 18 katmanlı, her residual blokta iki konvolüsyon katmanı, ResNet-50 ve ResNet 101 mimariler sırasıyla 50 katmanlı ve 101 katmanlı, her residual blokta üç konvolüsyon katmanı bulunmaktadır.

4. MobilenetV2

MobileNetV2, mobil ve gömülü görüntü uygulamaları için tasarlanmış yüksek verimli bir derin sinir ağı mimarisidir. Sandler ve arkadaşları tarafından "MobileNetV2: Inverted Residuals and Linear Bottlenecks." isimli makalesinde tanıtıldı [42]. MobileNetV2, ters çevrilmiş artık bloklar (Inverted Residuals) ve doğrusal darboğazlar (Linear Bottlenecks) gibi ağın hem doğruluğunu hem de hesaplama verimliliğini artıran yeni mimari unsurlar sunar.

Inverted Residuals: Kanal sayısını genişleten geleneksel artık blokların aksine, ters çevrilmiş artık bloklar önce genişler ve ardından özellikleri daha düşük boyutlu bir alana yansıtır. Bir girdi katmanına aynı boyutta bir çıktı üretmek için kullanılan ve katmanlar arasında doğrudan bağlantılar içeren yapılardır.

Linear Bottlenecks: Doğrusal olmayan dönüşümlerin neden olduğu bilgi kaybını önleyerek, ağ katmanları boyunca gerekli bilgileri korur. Modelin daraltılmış (sıkıştırılmış) temsilinin doğrusal (linear) bir aktivasyon fonksiyonu kullanarak işlendiği bir yapıdır.

MobileNetV2'nin ters çevrilmiş artık blokların ve doğrusal darboğazların yenilikçi kullanımıyla karakterize edilen mimarisi, verimli derin sinir ağlarının tasarımında ileriye doğru atılan büyük bir adımı temsil ediyor. Yüksek performansı ve hesaplama verimliliğini dengeleme yeteneği, onu özellikle mobil ve gömülü cihazlara dağıtım için çok uygun hale getiriyor.

5. İnceptionV3

InceptionV3, Szegedy ve diğerleri tarafından "Rethinking the Inception Architecture for Computer Vision." başlıklı makalelerinde tanıtılan bir evrişimli sinir ağı (CNN) mimarisidir [43]. Bu mimari, derin sinir ağlarının hem temsil gücünü hem de hesaplama verimliliğini artırmak için tasarlanan önceki Inception sürümlerinin (V1 ve V2) geliştirilmiş halidir. InceptionV3, faktorize ve asimetrik evrişimler, yardımcı sınıflandırıcılar ve etkili ızgara boyutunun küçültülmesi dahil olmak üzere, görüntü sınıflandırma görevlerinde üstün performansına katkıda bulunan çeşitli yenilikçi teknikleri içerir.

- Hesaplama maliyetini azaltmak ve verimliliği artırmak için Inception V3, büyük evrişimli filtreleri daha küçük, faktorize ve asimetrik evrişimler ile değiştirir. Örneğin, 5x5'lik bir evrişimin yerini iki adet 3x3'lük evrişim alır ve 3x3'lük bir evrişim, 1x3'lük bir evrişim ve ardından 3x1'lik bir evrişim olarak çarpanlara ayrılır. Bu çarpanlara ayırma, parametre sayısının ve hesaplama işlemlerinin azaltılmasına yardımcı olur.

- Yardımcı sınıflandırıcılar, yok olan gradyan problemini azaltmak ve eğitim sırasında ek düzenleme sağlamak için ağa eklenen ara sınıflandırıcılardır. Bu sınıflandırıcılar, ağın çeşitli derinliklerdeki anlamlı özellikleri öğrenmesini teşvik ederek derin denetim mekanizmaları görevi görür.

- Önemli bilgileri korurken özellik haritalarının uzamsal boyutlarını alt örnekleyen dikkatle tasarlanmış indirgeme modülleri aracılığıyla etkili ızgara boyutu küçültülmesi sağlanır. Bu strateji, hesaplama yükünün yönetilmesine ve ağda derinlik ile genişlik arasındaki dengenin korunmasına yardımcı olur.

6. İnception ResnetV2

Inception-ResNet-v2, Inception modüllerinin ve Artık bağlantıların güçlü yönlerini birleştiren gelişmiş bir derin evrişimli sinir ağı (CNN) mimarisidir. Szegedy ve diğerleri tarafından "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning," başlıklı makalelerinde, derin ağların hem eğitim verimliliğini hem de temsil gücünü geliştirmeyi amaçlıyor [44]. Bu mimari, yok olan gradyan sorununu azaltarak Inception ağlarının eğitimini geliştirmek için artık bağlantıların faydalarından yararlanır, böylece daha derin ve daha güçlü ağların inşasına olanak tanır.

- Inception-ResNet-v2, farklı filtre boyutlarına sahip paralel evrişimli yollar aracılığıyla çeşitli ölçeklerdeki çeşitli mekansal özellikleri yakalayan Inception modüllerinin çok ölçekli özellik çıkarma yeteneğini içerir.

- Inception-ResNet bloklarını oluşturmak için Inception modüllerine artık bağlantılar eklenir. Bu bağlantılar, geri yayılım sırasında gradyan akışının korunmasına yardımcı olur, kaybolan gradyan sorununu çözer ve daha derin ağların eğitimini kolaylaştırır.

- Daha önceki Inception mimarilerine benzer şekilde Inception-ResNet-v2, önemli mekansal bilgileri korurken özellik haritalarını verimli bir şekilde alt örneklemek için özel indirgeme modülleri kullanır.

4. BULGULAR

4.1. EEG SİNYALLERİ VE MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK ELDE EDİLEN BULGULAR

Bu tez kapsamında veri seti kısmında anlatıldığı gibi toplam 55 katılımcıya 2 farklı araba reklamı izletildi ve yaklaşık 75 saniye süren videolar izletilirken kişilerden EEG verisi alındı. Katılımcıların 27'si Dacia, 28 ise Mercedes reklam videosunu izlemiştir. Yaklaşık 75 saniye süren reklam videolarının EEG verisinden 7 farklı görselin 1 er saniyelik (500 örnek) EEG segmenti alındı ve ileri sinyal işleme metotları uygulandı. Daha sonra pencereleme yapıldı ve istatistik metrikleri ile öznitelik çıkarımı yapıldı.

Alınan 7 segmentden öznitelik çıkarımı yapılmadan 2 yaklaşım ile öznitelik çıkarımı yapıldı. İlk yaklaşım pencereleme yapılmadan alınan 7 EEG segmentinden öznitelik çıkarımı ve ikinci yaklaşım ise pencereleme yapıldıktan sonra öznitelik çıkarımı oldu.

Pencereleme yapılmadan bir saniyelik (500 örnek) sinyalin tamamından, daha sonra 250 örnek, 125 örnek ve 71 örnek üzerinden istatistik metrikler ile öznitelik çıkarımı yapıldı ve alınan öznitelikler peş peşe eklenerek öznitelik vektörü oluşturuldu, sonrasında sınıflandırıldı. Alınan sonuçlar incelendiğinde bu 4 örneklemenin başarım sonuçlarından anlamlı bir sonuç çıkarılamadı. Yani bazı sonuçlarda 500 örneklem sınıflandırma sonucu daha yüksek sonuç verirken bazı sonuçlarda ise diğer örneklem sonuçları daha yüksek sonuç verdi. Bu sonuçlar bizi ikinci yaklaşıma yönlendirdi. Pencereleme yapıldığında toplam öznitelik sayısı ve sınıflandırma başarımının arttığı gözlemlenmiştir.

16 kanaldan alınmış, 2 markadan, seçilen 7 bölgeden, 1 saniyelik alınmış veriler, tablo 4.1 de ilk 71, 125 250 ve 500 örnek ile segmentlenerek sınıflandırma yapılmıştır. Böylelikle sınıflandırma için hazırladığımız öznitelik vektörümüz Dacia marka araba için 189x241 olmuş oldu. Tablo 4.1'de 196 Öznitelik seçimi ile sınıflandırma işlemi bulunmaktadır. Tablo 4.1' en sağındaki sütunda ise pencereleme yapılarak alınan sınıflandırma başarımı bulunmaktadır.

Tablo 4.1: Dacia marka arabanın 71/125/250/500 örnek ile EEG verisinin pencereleme yapılmadan sınıflandırma sonuçları.

Dacia data	71	125	250	500	71 sel196	125 sel196	250 sel196	500 sel196	pen sel196
LinearSVM	0,54	0,49	0,50	0,45	0,56	0,52	0,59	0,47	0,59
QuadradicSVM	0,54	0,46	0,51	0,51	0,56	0,49	0,57	0,52	0,60
CubicSVM	0,58	0,41	0,52	0,51	0,56	0,54	0,57	0,53	0,60
MediumGaussianSVM	0,48	0,43	0,50	0,48	0,55	0,49	0,50	0,49	0,62
CoarseGaussianSVM	0,51	0,52	0,52	0,51	0,52	0,51	0,52	0,50	0,52
FineKNN	0,57	0,44	0,51	0,46	0,58	0,52	0,54	0,49	0,61
CosineKNN	0,56	0,49	0,52	0,55	0,61	0,57	0,49	0,60	0,60
CubicKNN	0,56	0,55	0,51	0,54	0,52	0,51	0,54	0,59	0,56
BaggedEnsemble	0,52	0,49	0,52	0,45	0,51	0,55	0,54	0,50	0,60
SubspaceDimensionEnsemble	0,44	0,48	0,49	0,50	0,54	0,52	0,56	0,42	0,62

Tablo 4.2: Mercedes marka arabanın 71/125/250/500 örnek ile EEG verisinin pencereleme yapılmadan doğruluk sınıflandırma sonuçları.

Mercedes data	71	125	250	500	71 sel196	125 sel196	250 sel196	500 sel196	pen sel196
LinearSVM	0,75	0,71	0,71	0,73	0,74	0,73	0,72	0,73	0,78
QuadradicSVM	0,69	0,67	0,69	0,65	0,70	0,69	0,67	0,68	0,77
CubicSVM	0,68	0,63	0,65	0,65	0,70	0,64	0,58	0,66	0,74
MediumGaussianSVM	0,74	0,74	0,74	0,74	0,74	0,74	0,74	0,74	0,78
CoarseGaussianSVM	0,74	0,74	0,74	0,74	0,74	0,74	0,74	0,74	0,77
FineKNN	0,66	0,58	0,64	0,59	0,65	0,63	0,62	0,59	0,75
CosineKNN	0,72	0,73	0,72	0,69	0,73	0,72	0,72	0,72	0,72
CubicKNN	0,73	0,74	0,72	0,73	0,74	0,72	0,74	0,74	0,74
BaggedEnsemble	0,70	0,69	0,70	0,70	0,73	0,72	0,66	0,69	0,74
RUSBoostEnsemble	0,52	0,51	0,40	0,52	0,49	0,56	0,47	0,47	0,61

16 kanaldan alınmış, 2 markadan, seçilen 7 bölgeden, 1 saniyelik alınmış veriler, tablo 4.2 de ilk 71, 125 250 ve 500 örnek ile segmentlenerek sınıflandırma yapılmıştır. Böylelikle sınıflandırma için hazırladığımız öznitelik vektörümüz Mercedes için 196x241 olmuş oldu. Tablo 4.2'de 196 Öznitelik seçimi ile sınıflandırma işlemi bulunmaktadır. Tablo 4.2' en sağındaki sütunda ise pencereleme yapılarak alınan sınıflandırma başarımı bulunmaktadır.

Alınan sonuçlardan sonra 500 örnek kullanılarak, pencereleme yapılarak ve öznitelik seçimi yapılarak sinyal işleme yöntemleri uygulanmıştır.

4.1.1. Görgül Kip Ayrışımı ile İlgili Sınıflandırma Sonuçları

Dacia ve Mercedes olmak üzere 2 farklı araba markasının reklamı izletilerek, 7 farklı bölgeyi aldığımız sonuçlara Görgül Kip Ayrışımı uygulayarak ve pencereleme yaparak öznitelik vektörünü oluşturduk.

Öznitelik vektörü şu şekilde oluştu;

Dacia 27 kişi, Mercedes 28 kişi, 16 kanal, 7 kesit ve 500 örnek alınan verimizde, kişiler alt alta koyuldu kanallar yan yana koyuldu, böylelikle marka 1 için 189X8001, marka 2 için 196x8001 matrisimiz oluşmuş oldu, GKA ile 5 kip elde edildi ve daha sonrasında pencereleme yapılarak 9 pencereye 15 istatistik metrik uygulandı, her kip için matrisimiz Dacia için 189x2161, Mercedes için 196x2161 haline geldi, son olarak kiplerimizi yan yana koyarak matrisimiz 189x10801 ve 196x10801 haline geldi, öznitelik seçimi ile en iyi 1000 ve 500 öznitelik seçildi ve sınıflandırma yöntemlerini uygulandı. Tablo 4.3, Tablo 4.4, Tablo 4.5 ve Tablo 4.6 da başlık olarak 1den2 ifadesi ilk kip ile ikinci kipin yanyana koyularak, 1den3 ifadesi ilk üç kipin yanyana koyularak vb. gibi öznitelik vektörünün oluştuğunu ifade etmektedir.

Tablo 4.3 ile Tablo 4.4 de Dacia marka araba reklamı için Görgül Kip Ayrışımı yöntemi ile en iyi 1000 ve 500 öznitelik seçilerek doğruluk başarımı tablo halinde verilmiştir. Tablo 4.3 de Görgül Kip Ayrışımı yöntemi ile elde edilen sınıflandırma başarımları incelendiğinde, Dacia marka araba reklamı için en yüksek doğruluk başarımını Medium Gaussian SVM sınıflandırma yöntemi ile 1000 öznitelik seçilerek ve 5 kip yanyana koyularak alınmıştır.

Tablo 4.5 ile Tablo 4.6 da Mercedes marka araba reklamı için en iyi 1000 ve 500 öznitelik seçilerek doğruluk başarımı tablo halinde verilmiştir. Mercedes marka araba reklamı için en yüksek doğruluk başarımını Medium Gaussian SVM sınıflandırma yöntemi ile 1000 öznitelik seçilerek ve 5 kip yanyana koyularak alınmıştır.

Tablo 4.3: GKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu

Dacia-1000 -GKA	1den2	1den3	1den4	1den5
LinearDiscriminant	0,60	0,61	0,67	0,60
LinearSVM	0,49	0,34	0,60	0,66

QuadradicSVM	0,51	0,43	0,70	0,68
CubicSVM	0,47	0,46	0,63	0,68
MediumGaussianSVM	0,70	0,71	0,74	0,75
CoarseGaussianSVM	0,71	0,71	0,73	0,74
FineKNN	0,64	0,59	0,60	0,56
CosineKNN	0,57	0,59	0,61	0,65
CubicKNN	0,54	0,60	0,57	0,57
BaggedEnsemble	0,56	0,55	0,57	0,61
SubspaceDimensionEnsemble	0,65	0,59	0,68	0,66

Tablo 4.4: GKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu

Dacia-500 -GKA	1den2	1den3	1den4	1den5
LinearDiscriminant	0,63	0,60	0,59	0,62
LinearSVM	0,65	0,47	0,62	0,70
QuadradicSVM	0,70	0,45	0,64	0,67
CubicSVM	0,72	0,43	0,66	0,69
MediumGaussianSVM	0,71	0,70	0,68	0,74
CoarseGaussianSVM	0,70	0,70	0,68	0,74
FineKNN	0,69	0,61	0,62	0,60
CosineKNN	0,65	0,65	0,62	0,70
CubicKNN	0,53	0,56	0,57	0,60
BaggedEnsemble	0,58	0,58	0,59	0,57
SubspaceDimensionEnsemble	0,63	0,61	0,58	0,64

Tablo 4.5: GKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-1000-GKA	1den2	1den3	1den4	1den5
LinearDiscriminant	0,67	0,65	0,71	0,73
LinearSVM	0,74	0,76	0,74	0,76
QuadradicSVM	0,74	0,77	0,74	0,74
CubicSVM	0,76	0,74	0,76	0,76
MediumGaussianSVM	0,71	0,79	0,85	0,86
CoarseGaussianSVM	0,68	0,80	0,84	0,82
FineKNN	0,70	0,71	0,75	0,74
CosineKNN	0,73	0,73	0,73	0,74
CubicKNN	0,74	0,73	0,74	0,74
BaggedEnsemble	0,70	0,71	0,70	0,73
SubspaceDimensionEnsemble	0,67	0,65	0,71	0,72

Tablo 4.6: GKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-500-GKA	1den2	1den3	1den4	1den5
LinearDiscriminant	0,69	0,72	0,72	0,76
LinearSVM	0,76	0,76	0,74	0,74
QuadradicSVM	0,75	0,76	0,74	0,74
CubicSVM	0,76	0,76	0,75	0,74
MediumGaussianSVM	0,82	0,83	0,84	0,85
CoarseGaussianSVM	0,82	0,83	0,84	0,81
FineKNN	0,73	0,74	0,74	0,73
CosineKNN	0,73	0,73	0,73	0,72
CubicKNN	0,73	0,74	0,74	0,74
BaggedEnsemble	0,71	0,73	0,73	0,72
SubspaceDimensionEnsemble	0,68	0,68	0,69	0,72

GKA yöntemi ile Dacia ve Mercedes marka arabaların kipleri 5 kipi yan yana koyularak öznitelik vektörü oluşturulmuş, en iyi 1000 ve 500 öznitelik seçilerek Doğruluk sınıflandırma sonuçları Tablo 4.7 de tablo halinde verilmiş ve karşılaştırılmıştır. En yüksek başarımı her iki marka içinde 1000 öznitelik seçilerek MediumGaussianSVM yöntemi vermiştir.

Tablo 4.7: GKA yöntemi ile Dacia ve Mercedes marka arabaların 1000 ve 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

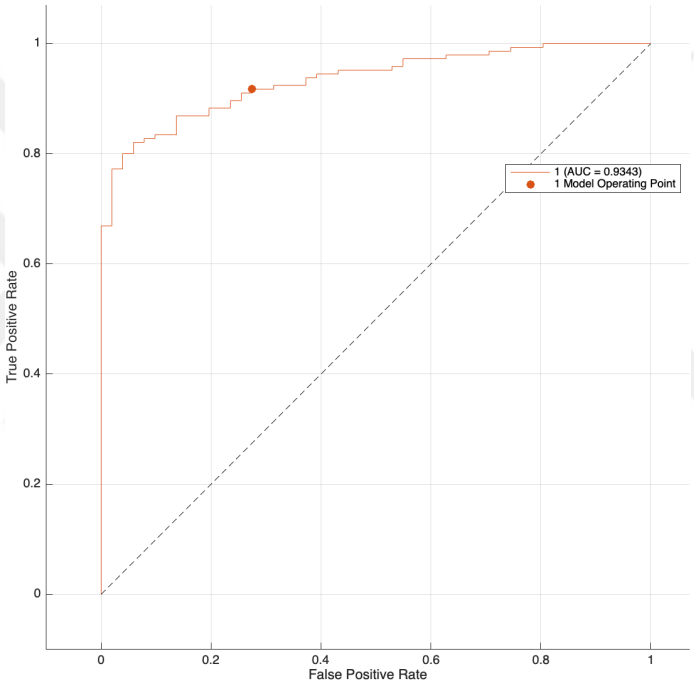
GKA	Mercedes		Dacia	
1 den 5 ÖKF	1000	500	1000	500
LinearDiscriminant	0,73	0,76	0,60	0,62
LinearSVM	0,76	0,74	0,66	0,70
QuadradicSVM	0,74	0,74	0,68	0,67
CubicSVM	0,76	0,74	0,68	0,69
MediumGaussianSVM	0,86	0,85	0,75	0,74
CoarseGaussianSVM	0,82	0,81	0,74	0,74
FineKNN	0,74	0,73	0,56	0,60
CosineKNN	0,74	0,72	0,65	0,70
CubicKNN	0,74	0,74	0,57	0,60
BaggedEnsemble	0,73	0,72	0,61	0,57
SubspaceDimensionEnsemble	0,72	0,72	0,66	0,64

Tablo 4.8 de GKA yöntemi kullanılarak en yüksek doğruluk başarımını veren Medium Gaussian SVM yönteminin karıştırma matrisi ve diğer ölçüm metrikleri tablo haline

getirilmiştir. Şekil 4.1 de GKA yöntemi kullanılarak en yüksek doğruluk başarımını veren Medium Gaussian SVM yönteminin ROC eğrisi çizilmiştir.

Tablo 4.8: GKA yöntemi ile Mercedes marka arabanın MediumGaussianSVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri sonucu.

GKA-Mercedes-1000 MediumGaussianSVM		F1-Score	0,87
		Precision	0,87
TP-85	FN-13	Sensitivity-	0.87
FP-13	TN-78	Specificity-	0,86
Accuracy- 0,86			



Şekil 4.1: GKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin ROC eğrisi.

4.1.2. Grup Görgül Kip Ayrışımı İle İlgili Sınıflandırma Sonuçları

Dacia ve Mercedes olmak üzere 2 farklı araba markasının reklamı izletilerek, 7 farklı bölgeyi aldığımız sonuçlara Grup Görgül Kip Ayrışımı uygulayarak ve pencereleme yaparak öznitelik vektörünü oluşturduk.

Öznitelik vektörü şu şekilde oluştu;

GGKA ile 8 kip elde edildi ve daha sonrasında pencereleme yapılarak 9 pencereye 15 istatistik metrik uygulandı, her kip için matrisimiz marka 1 için 189x2161, marka 2 için 196x2161 haline

geldi, son olarak kiplerimizi yan yana koyarak matrisimiz 189x17281 ve 196x17281 haline geldi, öznitelik seçimi ile en iyi 1000 ve 500 öznitelik seçildi ve sınıflandırma yöntemlerini uygulandı.

Tablo 4.9 ve Tablo 4.10 de Dacia marka araba reklamı için Grup Görgül Kip Ayrışımı yöntemi ile en iyi 1000 ve 500 öznitelik seçilerek elde edilen sınıflandırma başarımları tablo halinde verilmiştir. Tablo 4.9 da Dacia marka araba reklamı için en yüksek doğruluk başarımını Linear SVM sınıflandırma yöntemi ile 1000 öznitelik seçilerek ve 8 kip yanyana koyularak alınmıştır.

Tablo 4.11 ve Tablo 4.12 de Mercedes marka araba reklamı için Grup Görgül Kip Ayrışımı yöntemi ile en iyi 1000 ve 500 öznitelik seçilerek elde edilen sınıflandırma başarımları tablo halinde verilmiştir. Tablo 4.11 de Mercedes marka araba reklamı için en yüksek doğruluk başarımını Medium Gaussian SVM sınıflandırma yöntemi ile 1000 öznitelik seçilerek ve 8 kip yanyana koyularak alınmıştır.

Tablo 4.9: GGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu

Dacia-1000 selected-GGKA	1den2	1den3	1den4	1den5	1den6	1den7	1den8
LinearSVM	0,65	0,72	0,75	0,81	0,79	0,81	**0,86**
QuadradicSVM	0,66	0,72	0,76	0,8	0,79	0,8	0,75
CubicSVM	0,68	0,7	0,75	0,81	0,81	0,83	0,85
MediumGaussianSVM	0,7	0,69	0,71	0,77	0,81	0,83	0,81
CoarseGaussianSVM	0,49	0,52	0,51	0,52	0,52	0,52	0,80
FineKNN	0,63	0,6	0,67	0,7	0,69	0,67	0,71
CosineKNN	0,66	0,7	0,77	0,81	0,79	0,84	0,83
CubicKNN	0,62	0,6	0,7	0,74	0,69	0,78	0,75
BaggedEnsemble	0,56	0,59	0,59	0,67	0,64	0,63	0,59
SubspaceDimensionEnsemble	0,68	0,68	0,72	0,81	0,79	0,84	0,83

Tablo 4.10: GGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Dacia-500 selected-GGKA	1den2	1den3	1den4	1den5	1den6	1den7	1den8
LinearSVM	0,66	0,78	0,78	0,80	0,79	0,76	0,80
QuadradicSVM	0,67	0,77	0,77	0,78	0,76	0,78	0,79
CubicSVM	0,66	0,74	0,76	0,79	0,78	0,79	0,79
MediumGaussianSVM	0,70	0,71	0,77	0,77	0,79	0,79	0,78
CoarseGaussianSVM	0,52	0,52	0,53	0,52	0,52	0,52	0,53
FineKNN	0,63	0,64	0,67	0,68	0,68	0,65	0,62
CosineKNN	0,68	0,73	0,76	0,83	0,80	0,81	**0,81**

CubicKNN	0,61	0,62	0,70	0,70	0,74	0,69	0,68
BaggedEnsemble	0,54	0,59	0,61	0,67	0,65	0,65	0,60
SubspaceDimensionEnsemble	0,57	0,72	0,69	0,70	0,68	0,73	0,70

Tablo 4.11: GGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-1000 selected-GGKA	1den2	1den3	1den4	1den5	1den6	1den7	1den8
LinearSVM	0,72	0,74	0,72	0,74	0,75	0,76	0,76
QuadradicSVM	0,70	0,75	0,73	0,75	0,76	0,77	0,77
CubicSVM	0,71	0,75	0,74	0,74	0,75	0,76	0,78
MediumGaussianSVM	0,78	0,85	0,88	0,94	0,94	0,91	**0,94**
CoarseGaussianSVM	0,75	0,77	0,77	0,79	0,80	0,83	0,85
FineKNN	0,75	0,75	0,75	0,76	0,76	0,77	0,76
CosineKNN	0,73	0,74	0,74	0,72	0,75	0,72	0,71
CubicKNN	0,74	0,74	0,74	0,74	0,74	0,74	0,74
BaggedEnsemble	0,73	0,74	0,72	0,76	0,72	0,73	0,74
SubspaceDimensionEnsemble	0,69	0,71	0,71	0,74	0,74	0,72	0,77

Tablo 4.12: GGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-500 selected-GGKA	1den2	1den3	1den4	1den5	1den6	1den7	1den8
LinearSVM	0,74	0,74	0,74	0,77	0,76	0,76	0,80
QuadradicSVM	0,72	0,73	0,75	0,79	0,79	0,80	0,80
CubicSVM	0,74	0,74	0,77	0,79	0,77	0,78	0,78
MediumGaussianSVM	0,84	0,87	0,91	0,9	0,92	0,92	**0,93**
CoarseGaussianSVM	0,78	0,76	0,77	0,79	0,78	0,78	0,84
FineKNN	0,75	0,74	0,76	0,76	0,76	0,76	0,76
CosineKNN	0,75	0,72	0,75	0,73	0,75	0,74	0,74
CubicKNN	0,74	0,74	0,74	0,74	0,74	0,74	0,74
BaggedEnsemble	0,72	0,73	0,74	0,74	0,73	0,75	0,74
SubspaceDimensionEnsemble	0,66	0,67	0,7	0,74	0,74	0,77	0,77

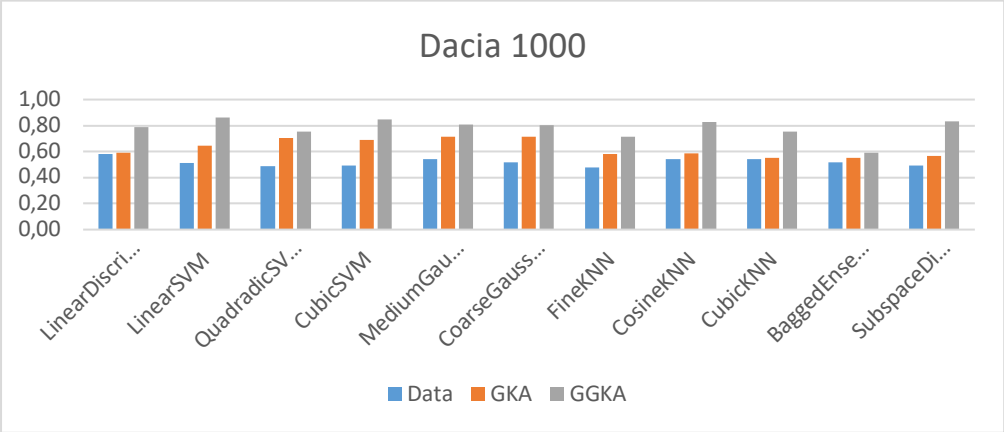
Tablo 4.13: GGKA yöntemi ile Dacia ve Mercedes marka arabaların 1000 ve 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

GGKA	Mercedes		Dacia	
1 den 8 ökf ler	1000	500	1000	500
LinearDiscriminant	0,75	0,78	0,79	0,74
LinearSVM	0,80	0,77	0,86	0,80
QuadradicSVM	0,80	0,79	0,75	0,79

CubicSVM	0,78	0,76	0,85	0,79
MediumGaussianSVM	**0,94**	0,93	0,81	0,78
CoarseGaussianSVM	0,85	0,84	0,80	0,78
FineKNN	0,76	0,75	0,71	0,66
CosineKNN	0,74	0,74	0,83	0,81
CubicKNN	0,74	0,74	0,75	0,70
BaggedEnsemble	0,74	0,76	0,59	0,63
SubspaceDimensionEnsemble	0,77	0,81	0,83	0,75

Tablo 4.14: Dacia marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için doğruluk sınıflandırma sonuçları.

GKA VE GGKA Bütün Kipler Yanyana	DACİA		
	1000	1000	1000
	Data	GKA	GGKA
LinearDiscriminant	0,58	0,60	0,79
LinearSVM	0,51	0,66	0,80
QuadradicSVM	0,49	0,68	0,80
CubicSVM	0,49	0,68	0,81
MediumGaussianSVM	0,54	0,75	0,80
CoarseGaussianSVM	0,52	0,74	0,52
FineKNN	0,48	0,56	0,69
CosineKNN	0,54	0,65	0,83
CubicKNN	0,54	0,57	0,75
BaggedEnsemble	0,52	0,61	0,59
SubspaceDimensionEnsemble	0,49	0,66	0,76

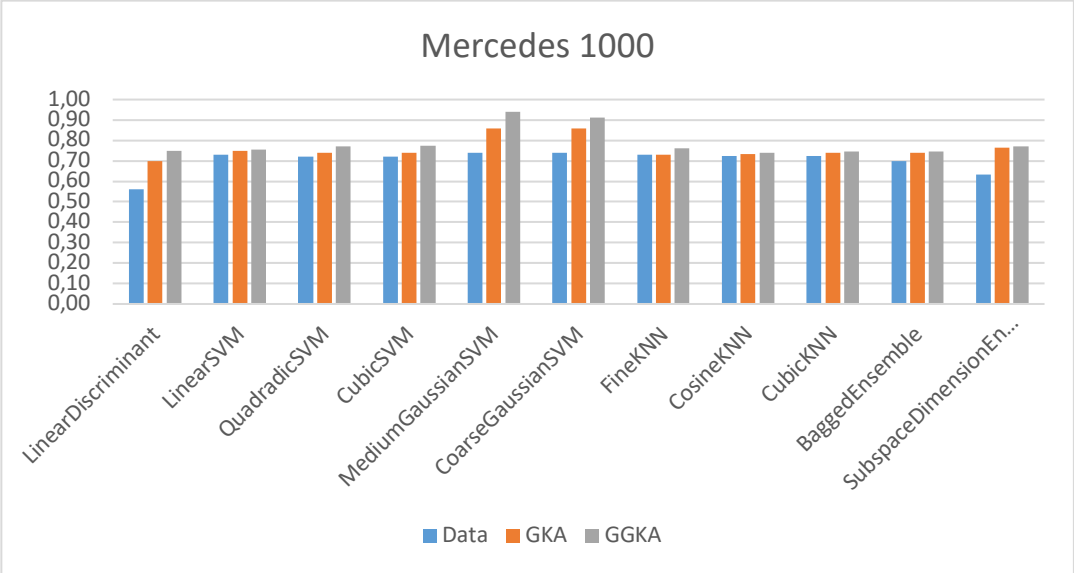


Şekil 4.2: Dacia araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için sınıflandırma sonuçlarının grafiği.

Dacia marka araba ve Mercedes marka arabanın sınıflandırma sonuçları Tablo 4.10 ve Tablo 4.11 de karşılaştırıldığında, Görgül Kip Ayrışımı yönteminde bulunan mod mixing problemini Grup Görgül Kip Ayrışımı yöntemiyle aşıldığı görülmektedir. Şekil 4.2 ve Şekil 4.3 de grafik gösterimi ile de karşılaştırılmıştır.

Tablo 4.15: Mercedes Marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için doğruluk sınıflandırma sonuçları.

GKA VE GGKA Bütün Kipler Yanyana	MERCEDES		
	1000	1000	1000
	Data	GKA	GGKA
LinearDiscriminant	0,56	0,73	0,75
LinearSVM	0,73	0,76	0,76
QuadradicSVM	0,72	0,74	0,77
CubicSVM	0,72	0,76	0,78
MediumGaussianSVM	0,74	0,86	**0,94**
CoarseGaussianSVM	0,74	0,82	0,85
FineKNN	0,73	0,74	0,76
CosineKNN	0,72	0,74	0,74
CubicKNN	0,72	0,74	0,74
BaggedEnsemble	0,70	0,73	0,74
SubspaceDimensionEnsemble	0,63	0,72	0,77

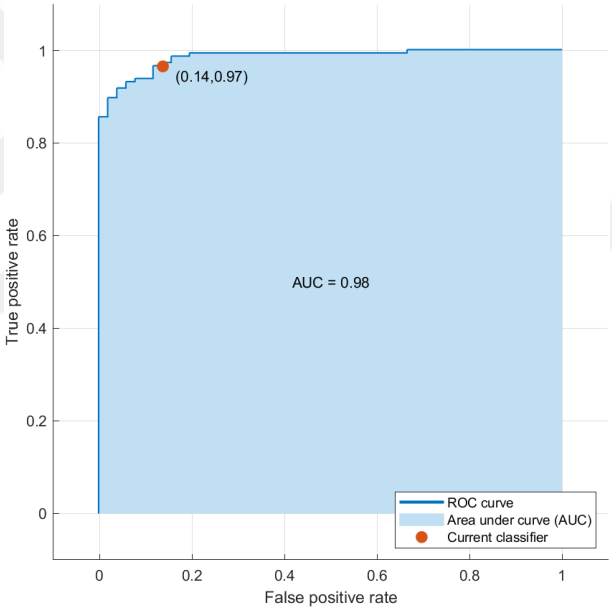


Şekil 4.3: Mercedes Marka araba reklamından alınan EEG verilerinin Data, GKA ve GGKA yöntemleri uygulanarak 1000 öznitelik için sınıflandırma sonuçlarının grafiği.

GGKA ile en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi ve diğer ölçüm metrikleri Tablo 4.16 da verilmiş ve Şekil 4.4 ROC eğrisi çizilmiştir.

Tablo 4.16: GGKA yöntemi ile Mercedes marka arabanın en yüksek başarımı veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri.

GGKA-Mercedes-1000 MediumGaussianSVM		F1-Score	0,88
		Precision	0,89
TP-46	FN-7	Sensitivity	0.90
FP-5	TN-138	Specificity	0,95
Accuracy- 0,94			



Şekil 4.4: GGKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren MediumGaussianSVM sınıflandırma yönteminin ROC eğrisi.

4.1.3. Çok Değişkenli Görgül Kip Ayrışımı ile İlgili Sınıflandırma Sonuçları

Dacia ve Mercedes olmak üzere 2 farklı araba markasının reklamı izletilerek, 7 farklı bölgeyi aldığımız sonuçlara Çok Değişkenli Görgül Kip Ayrışımı uygulayarak ve pencereleme yaparak öznitelik vektörünü oluşturduk. Öznitelik vektörü şu şekilde oluştu;

ÇDGKA ile 6 kip elde edildi ve daha sonrasında pencereleme yapılarak 9 pencereye 15 istatistik metrik uygulandı, her kip için matrisimiz marka 1 için 189x2161, marka 2 için 196x2161 haline geldi, son olarak kiplerimizi yan yana koyarak matrisimiz 189x12966 ve 196x12966 haline

geldi, öznitelik seçimi ile en iyi 1000 ve 500 öznitelik seçildi ve sınıflandırma yöntemleri uygulandı.

Tablo 4.17 ve Tablo 4.18 de Dacia marka araba reklamı için Çok Değişkenli Görgül Kip Ayrışımı yöntemi ile en iyi 1000 ve 500 öznitelik seçilerek elde edilen sınıflandırma başarımları tablo halinde verilmiştir. Tablo 4.18 de Dacia marka araba reklamı için en yüksek doğruluk başarımını Medium Gaussian SVM ve Coarse Gaussian SVM sınıflandırma yöntemi ile 500 öznitelik seçilerek ve 8 kip yanyana koyularak alınmıştır.

Tablo 4.19 ve Tablo 4.20 de Mercedes marka araba reklamı için Grup Görgül Kip Ayrışımı yöntemi ile en iyi 1000 ve 500 öznitelik seçilerek elde edilen sınıflandırma başarımları tablo halinde verilmiştir. Tablo 4.19 de Mercedes marka araba reklamı için en yüksek doğruluk başarımını Medium Gaussian SVM sınıflandırma yöntemi ile 1000 öznitelik seçilerek ve 8 kip yanyana koyularak alınmıştır.

Tablo 4.17: ÇDGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Dacia-1000 selected-ÇDGKA	1den2	1den3	1den4	1den5	1den6
LinearDiscriminant	0,60	0,68	0,68	0,71	0,74
LinearSVM	0,69	0,73	0,69	0,75	0,72
QuadradicSVM	0,65	0,70	0,71	0,76	0,77
CubicSVM	0,62	0,68	0,58	0,68	0,71
MediumGaussianSVM	0,62	0,68	0,70	0,75	0,79
CoarseGaussianSVM	0,62	0,68	0,71	0,76	0,79
FineKNN	0,49	0,52	0,51	0,49	0,47
CosineKNN	0,60	0,62	0,64	0,62	0,61
CubicKNN	0,64	0,66	0,65	0,67	0,63
BaggedEnsemble	0,57	0,65	0,55	0,62	0,63
SubspaceDimensionEnsemble	0,62	0,67	0,69	0,75	0,77

Tablo 4.18: ÇDGKA yöntemi ile Dacia marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Dacia-500 selected-ÇDGKA	1den2	1den3	1den4	1den5	1den6
LinearDiscriminant	0,62	0,54	0,60	0,66	0,71
LinearSVM	0,70	0,70	0,75	0,75	0,76
QuadradicSVM	0,74	0,66	0,72	0,79	0,78
CubicSVM	0,73	0,69	0,72	0,80	0,79
MediumGaussianSVM	0,69	0,68	0,72	0,76	0,81
CoarseGaussianSVM	0,70	0,68	0,72	0,77	0,81

FineKNN	0,51	0,54	0,54	0,51	0,48
CosineKNN	0,66	0,63	0,70	0,65	0,67
CubicKNN	0,71	0,69	0,69	0,67	0,62
BaggedEnsemble	0,62	0,66	0,65	0,66	0,63
SubspaceDimensionEnsemble	0,61	0,57	0,61	0,71	0,74

Tablo 4.19: ÇDGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 1000 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-1000 selected-ÇDGKA	1den2	1den3	1den4	1den5	1den6
LinearDiscriminant	0,69	0,70	0,78	0,74	0,77
LinearSVM	0,74	0,74	0,73	0,74	0,75
QuadradicSVM	0,74	0,74	0,75	0,74	0,77
CubicSVM	0,74	0,74	0,76	0,75	0,74
MediumGaussianSVM	0,79	0,86	0,88	0,90	**0,91**
CoarseGaussianSVM	0,79	0,86	0,88	0,90	0,91
FineKNN	0,74	0,74	0,74	0,74	0,75
CosineKNN	0,73	0,73	0,73	0,74	0,72
CubicKNN	0,73	0,74	0,74	0,74	0,75
BaggedEnsemble	0,70	0,73	0,74	0,72	0,74
SubspaceDimensionEnsemble	0,65	0,69	0,74	0,71	0,74

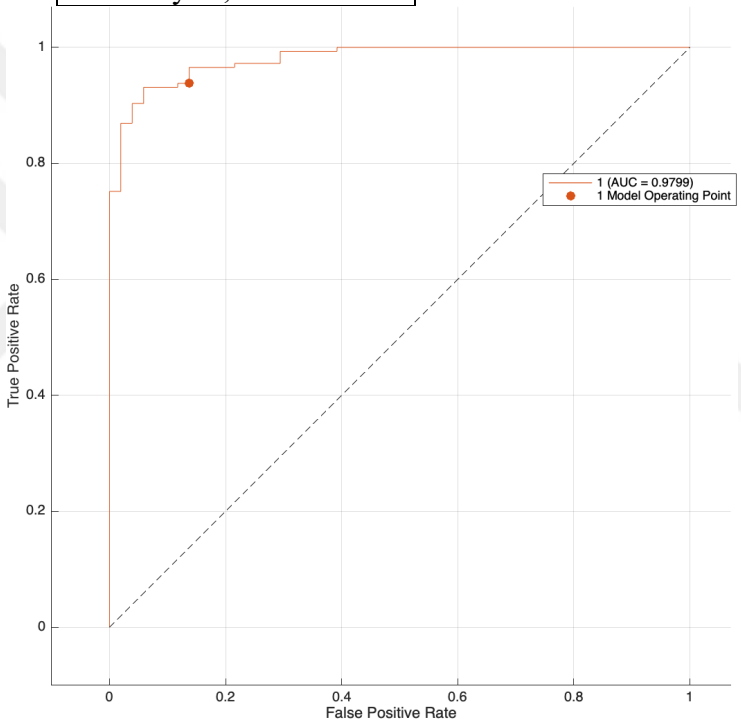
Tablo 4.20: ÇDGKA yöntemi ile Mercedes marka arabanın ÖKF'ler yanyana koyularak, 500 öznitelik seçilerek Doğruluk sınıflandırma sonucu.

Mercedes-500 selected-ÇDGKA	1den2	1den3	1den4	1den5	1den6
LinearDiscriminant	0,68	0,64	0,72	0,72	0,73
LinearSVM	0,74	0,74	0,74	0,74	0,74
QuadradicSVM	0,74	0,74	0,74	0,75	0,76
CubicSVM	0,74	0,74	0,74	0,75	0,76
MediumGaussianSVM	0,83	0,85	0,85	0,88	**0,90**
CoarseGaussianSVM	0,83	0,85	0,85	0,89	0,88
FineKNN	0,74	0,74	0,74	0,74	0,74
CosineKNN	0,73	0,73	0,72	0,71	0,73
CubicKNN	0,73	0,74	0,74	0,74	0,74
BaggedEnsemble	0,71	0,70	0,74	0,72	0,74
SubspaceDimensionEnsemble	0,67	0,66	0,73	0,72	0,70

ÇDGKA ile en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi ve diğer ölçüm metrikleri Tablo 4.21 de verilmiş ve Şekil 4.5'de ROC eğrisi çizilmiştir.

Tablo 4.21: ÇDGKA yöntemi ile Mercedes marka arabanın en yüksek başarımı veren Medium Gaussian SVM sınıflandırma yönteminin karıştırma matrisi (confusion matrisi) ve diğer ölçüm metrikleri.

ÇDGKA-Mercedes-1000 MediumGaussianSVM		F1-Score	0,83
		Precision	0,84
TP-46	FN-7	Sensitivity	0.82
FP-5	TN-138	Specificity	0,94
Accuracy- 0,91			

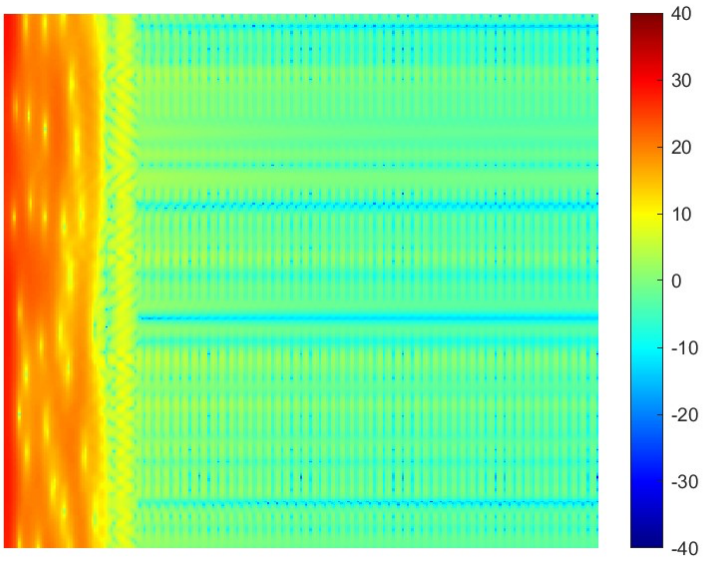


Şekil 4.5: ÇDGKA yöntemi ile Mercedes marka arabanın en yüksek doğruluk başarımını veren Medium Gaussian SVM sınıflandırma yönteminin ROC eğrisi.

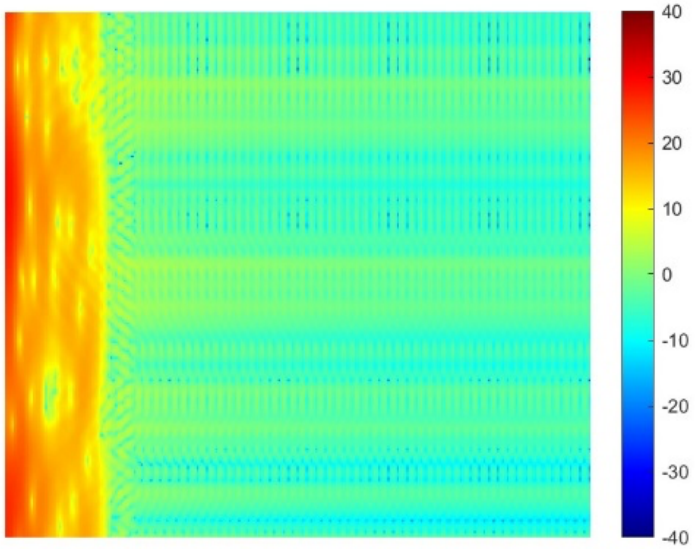
4.2. EEG SİNYALLERİ VE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK ELDE EDİLEN BULGULAR

Dacia ve Mercedes olmak üzere 2 farklı araba markasının reklamı izletilerek, 7 farklı bölgeyi bölütleyerek aldığımız verilere STFT uygulayarak, spektrogram ile imge haline getirildi. Örnek imgeler Şekil 4.4, Şekil 4.5, Şekil 4.6 ve Şekil 4.7 de verilmiştir. Spektrogramlardan oluşan veri setine, anket sorularından arabanın 7 farklı bölgesi için kişilerin beğeni durumlarını sorduğumuz soruların tamamına 0 ya da 1 yanıtını veren kişilerin verileri dahil edilmemiştir.

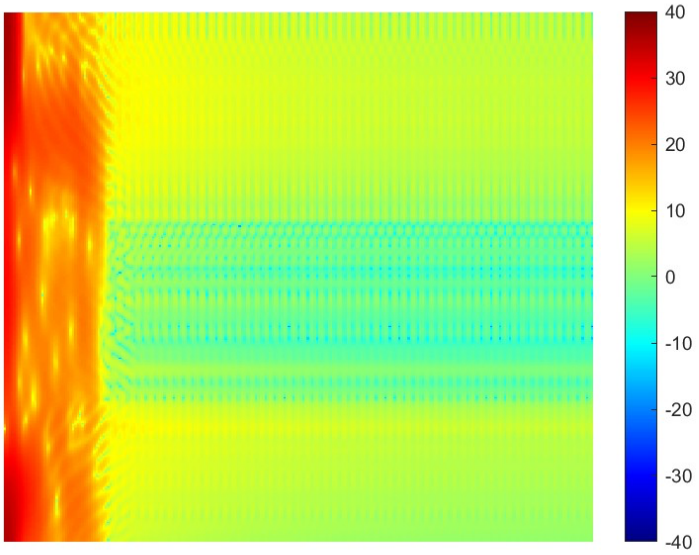
Böylelikle veri setinde; Dacia marka arabanın reklamını izleyenlerden 2240 imge, Mercedes marka arabanın reklamını izleyenlerden de 1680 imge yer almıştır.



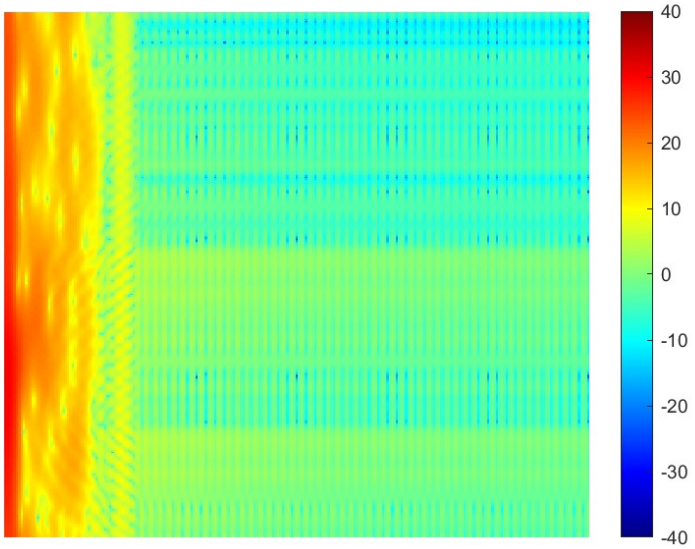
Şekil 4.6: Dacia marka, Beğenmedi sınıfına (önden görünüm) ait örnek spektrogram imgesi



Şekil 4.7: Mercedes Marka, Beğenmedi sınıfına (konsol) ait örnek spektrogram imgesi.



Şekil 4.8: Dacia Marka Beğendi sınıfına (ızgara) ait örnek spektrogram imgesi.



Şekil 4.9: Mercedes Marka, Beğendi sınıfına (önden görünüm) ait örnek spektrogram imgesi.

İmge haline getirilen veriler Transfer Öğrenme yöntemiyle, farklı ağ mimarileri kullanılarak eğitildi ve sınıflandırıldı. Yüzde 80 eğitim, yüzde 20 test olmak üzere rastgele ayrılan imgeler, 8 farklı derin öğrenme ağı; Squeezenet, googlenet, resnet18, mobilenetv2, resnet50, resnet101, inceptionv3 ve inceptionresnetv2 kullanılarak, 3 farklı Başlangıç Öğrenme Oranı (initial learning rate); 0.01, 0.001, 0,0001 belirlenerek, 5 farklı Mini Yığın Boyutu (mini batch size) 8,

16, 32, 64, 128 seçilerek eğitildi. Sınıflandırma sonucunda 8(ağ) X 3(öğrenme oranı) X 5(mini yığın boyutu) = 120 farklı derin öğrenme ağ ve parametre ile doğruluk oranları oluşmuş oldu, Tablo 4.16 da Dacia marka arabanın ve Tablo 4.17 de Mercedes marka arabanın en yüksek doğruluk başarımını veren 25 ağ ve parametreler tablo haline getirildi. Dacia marka arabanın Derin Öğrenme yöntemleri ile sınıflandırılmasında en yüksek doğruluk başarımını resnet101 mimarisi, Mercedes marka arabanın Derin Öğrenme yöntemleri ile sınıflandırılmasında en yüksek doğruluk başarımını resnet50 mimarisi vermiştir.

Tablo 4.22: Dacia marka arabanın Derin Öğrenme yöntemleri ile sınıflandırma sonucu

Dacia				
Ağ Mimarisi	Başlangıç Öğrenme Oranı	Mini Yığın Boyutu	Doğruluk	Süre
resnet101	0,01	128	86,16	00:54:27
inceptionv3	0,001	8	83,04	00:26:15
mobilenetv2	0,01	16	83,04	00:08:13
resnet50	0,001	8	82,59	00:14:16
resnet18	0,001	16	82,59	00:04:42
resnet101	0,001	16	82,59	00:17:40
resnet18	0,001	64	82,14	00:04:08
mobilenetv2	0,001	16	81,70	00:08:13
resnet50	0,001	64	81,25	00:09:44
mobilenetv2	0,01	64	80,80	00:07:08
resnet101	0,01	64	80,80	00:15:35
resnet101	0,0001	8	80,36	00:26:36
resnet101	0,01	32	80,36	00:16:12
resnet50	0,001	32	79,91	00:10:01
resnet18	0,0001	8	79,46	00:06:04
resnet50	0,0001	8	79,46	00:14:26
inceptionv3	0,0001	8	79,46	00:26:37
inceptionv3	0,001	32	79,46	00:16:42
resnet18	0,0001	16	79,02	00:04:45
resnet50	0,0001	16	79,02	00:10:54
resnet18	0,001	32	79,02	00:04:22
resnet101	0,001	32	79,02	00:16:13
inceptionv3	0,01	64	79,02	00:15:59
mobilenetv2	0,001	8	78,57	00:13:17
inceptionresnetv2	0,01	64	78,57	01:32:05

Tablo 4.23: Mercedes marka arabanın Derin Öğrenme yöntemleri ile sınıflandırma sonucu

Mercedes				
Ağ Mimarisi	Başlangıç Öğrenme Oranı	Mini Yığın Boyutu	Doğruluk	Süre
resnet50	0,01	64	92,86	00:07:12
resnet50	0,0001	16	92,26	00:07:56
resnet18	0,001	16	90,48	00:03:37
resnet18	0,001	32	89,88	00:03:03
mobilenetv2	0,001	8	89,88	00:09:34
resnet101	0,001	32	89,88	00:11:56
resnet50	0,001	8	89,29	00:10:24
inceptionv3	0,001	32	89,29	00:12:27
resnet101	0,01	128	89,29	00:39:32
resnet18	0,001	8	88,69	00:04:02
resnet50	0,01	32	88,69	00:07:26
inceptionv3	0,01	32	88,69	00:12:24
resnet50	0,001	64	88,69	00:07:12
resnet101	0,0001	8	88,10	00:19:33
resnet101	0,001	8	88,10	00:19:16
inceptionv3	0,001	8	88,10	00:19:18
resnet50	0,001	16	88,10	00:08:00
resnet50	0,001	32	88,10	00:07:25
resnet101	0,001	16	87,50	00:12:52
mobilenetv2	0,01	128	86,90	00:06:10
inceptionv3	0,01	128	86,31	00:26:11
resnet18	0,001	64	85,71	00:02:57
resnet101	0,01	8	85,71	00:19:20
mobilenetv2	0,001	16	85,71	00:06:04
mobilenetv2	0,001	32	85,71	00:05:06

Dacia ve Mercedes imgeleri, markadan bağımsız şekilde beğendi/beğenmedi şeklinde 1824 beğenmedi imgesi, 2096 beğendi imgesi haline getirildi. Beğendi/beğenmedi imgesi haline getirilen imgeler, 8 farklı ağ, 3 farklı başlangıç öğrenme oranı ve 5 farklı mini yığın boyutu ile eğitildi ve sınıflandırması yapılarak en yüksek doğruluk başarımını veren 25 mimari Tablo 4.18'de tablo haline getirildi. En yüksek başarımı inceptionv3 mimarisi vermiştir.

Tablo 4.24: Dacia ve Mercedes marka arabaların markadan bağımsız Derin Öğrenme yöntemleri ile sınıflandırma sonucu

Dacia+Mercedes				
Ağ Mimarisi	Başlangıç Öğrenme Oranı	Mini Yığın Boyutu	Doğruluk	Süre
inceptionv3	0,001	16	86,99	00:30:59
resnet50	0,01	32	86,22	00:19:11
resnet18	0,001	8	84,95	00:10:57
resnet50	0,001	8	84,95	00:25:45
resnet50	0,01	16	84,95	00:18:31
resnet101	0,001	8	84,69	00:47:01
resnet101	0,001	32	84,69	00:30:35
inceptionv3	0,01	32	84,69	00:33:39
resnet101	0,001	16	84,18	00:30:21
resnet101	0,0001	8	83,67	01:05:54
inceptionv3	0,01	16	83,67	00:29:47
resnet18	0,001	32	83,67	00:07:41
inceptionresnetv2	0,01	8	83,42	02:16:25
resnet18	0,001	16	83,42	00:08:08
inceptionv3	0,001	8	83,16	00:46:46
resnet50	0,001	32	83,16	00:18:29
resnet50	0,001	16	82,91	00:18:41
inceptionresnetv2	0,001	8	82,65	02:15:43
resnet50	0,01	128	82,65	00:30:06
resnet18	0,001	64	82,40	00:07:51
inceptionresnetv2	0,001	32	82,14	01:21:31
resnet101	0,01	32	82,14	00:31:29
mobilenetv2	0,01	64	82,14	00:14:54
inceptionresnetv2	0,01	16	81,89	01:25:41
inceptionv3	0,001	32	81,89	00:33:08

Bu tez çalışmasında Görgül Kip Ayrışımı (GKA) tabanlı yöntemlerle ve Derin Öğrenme teknikleriyle kullanılmıştır. Dacia marka araba için en yüksek başarımı veren sınıflandırma sonuçları tablo 4.25 de verilmiştir. GGKA yöntemi ile Derin Öğrenme yöntemlerinden resnet50 mimarisi 0.86 ile en yüksek başarımı vermiştir

Tablo 4.25: Dacia marka arabanın en yüksek doğruluk veren yöntemlerin karşılaştırılması

Dacia		
Yöntem	Sınıflandırma Yöntemi	Doğruluk
Data	LinearDiscriminant	0.58
GKA	Medium Gaussian SVM	0.75
GGKA	Medium Gaussian SVM	0.86
ÇDGKA	Medium Gaussian SVM	0.81
Derin Öğrenme-resnet101	--	0.86

Mercedes marka araba için en yüksek başarımı veren sınıflandırma sonuçları tablo 4.26 da verilmiştir. GGKA yöntemiyle 0.94 ile en yüksek başarım elde edilmiştir.

Tablo 4.26: Mercedes marka arabanın en yüksek doğruluk veren yöntemlerin karşılaştırılması

Mercedes		
Yöntem	Sınıflandırma Yöntemi	Doğruluk
Data	Medium Gaussian SVM	0.74
GKA	Medium Gaussian SVM	0.86
GGKA	Medium Gaussian SVM	0.94
ÇDGKA	Medium Gaussian SVM	0.91
Derin Öğrenme-resnet50	--	0.93

5. TARTIŞMA

Bu tez çalışmasında EEG sinyallerini kullanarak nöropazarlama uygulamaları için bir beğeni durumu tespiti geliştirilmektedir. Otomobil reklamlarını izleyen katılımcıların EEG verilerini analiz ederek, tüketicilerin ürünlere olan beğenilerini saptanması hedeflenmiştir. Bu tez çalışması, katılımcıların iki farklı otomobil reklamını izlediği bir durumu ele alır. Reklamları izledikten sonra, katılımcılardan farklı otomobil görüntülerine (ön görünüş, ön konsol, yan görünüş, arka görünüş, arka ışık, logo ve ön ızgara) puan vermeleri istenir. Bu video bölgelerine karşılık gelen EEG sinyalleri, EEG kayıtlarından bölütlenir ve Görgül Kip Ayrışımı (GKA) tabanlı yöntemlerle ve Derin Öğrenme teknikleriyle analiz edilir. Elde edilen Öz Kip Fonksiyonlarından (ÖKF) 15 istatistiksel öznitelikler çıkarılır ve beğeni durumu sınıflandırması gerçekleştirilir. GKA tabanlı yöntemlerle en yüksek doğruluk başarımını GGKA yöntemi ile Mercedes marka arabanın yüzde 94 elde edilmiştir. Derin Öğrenme yöntemiyle en yüksek doğruluk başarımını yüzde 93 ile resnet50 mimarisi ile elde edilmiştir.

Bu tez çalışmasının bulguları, çeşitli sınıflandırıcılar kullanılarak elde edilen sınıflandırma sonuçlarını içerir. Bu sonuçlar, EEG tabanlı yöntemin, nöropazarlama çalışmalarında tüketicilerin ürün tercihlerini etkili bir şekilde belirlemek için kullanılabileceğini göstermektedir. Bu araştırma, nöropazarlama alanında EEG verilerinin kullanım potansiyelini ve EEG sinyallerinin tüketici tercihlerinin anlaşılmasında nasıl değerli bir araç olabileceğini, GKA tabanlı ileri sinyal işleme yöntemlerinin kullanılabilirliğini vurgulamaktadır.

EEG verileri kullanılarak beğeni durumunu irdeleyen çalışmalar anlatılmıştır. Başarım sonuçları karşılaştırıldığında, yöntemlerin etkinliğinin önemli olması kadar, kullanılan veri seti, deney senaryosu, seçilen öznitelikler, katılımcı sayısı oldukça önemli olduğu gözlemlenmiştir. Literatürdeki bazı çalışmalar aşağıda özetlenmiş ve Tablo 5.1 de tablo halinde verilmiştir.

Yapılan bir çalışmada EEG kayıtlarını kullanarak bir kullanıcının izlediği video klibi beğenip beğenmediğini değerlendirmeyi amaçlamaktadır. Queen Mary Üniversitesi'nden (QMUL) sağlanan DEAP veri seti kullanılmıştır. Araştırmacılar, EEG sinyallerini segmentlere ayırmış ve her segmentten özellikler çıkarmışlardır. Kullanılan sınıflandırıcılar arasında k-en yakın komşu, destek vektör makinesi, çok katmanlı sinir ağı ve otomatik kodlayıcı sinir ağı bulunmaktadır. Deney sonuçları, otomatik kodlayıcı sinir ağının %80 gibi daha yüksek bir

doğruluk oranı sağladığını göstermiştir. Bu sonuçlar, EEG sinyallerinin video içeriğine duygusal tepkilerin değerlendirilmesinde kullanılabilirliğini göstermektedir [45].

Başka bir çalışma, korku ve rahatlama hisleri uyandıran filmleri izlerken tek kanallı EEG kayıtlarını analiz ederek farklı duygusal durumları sınıflandırmayı hedeflemiştir. Araştırmacılar, 19 üniversite öğrencisine üç farklı duygusal durumu uyandıran bir video klibi izletmiş ve onlardan duygusal sonuçlarını 0 ile 10 arasında bir sayıyla puanlamalarını istemişlerdir. EEG verileri, sürekli dalgacık dönüşümü (SDD) tabanlı bir gürültü giderme algoritması kullanılarak önceden işlenmiştir. Daha sonra, kısa zamanlı Fourier dönüşümü (STFT) kullanılarak zaman-frekans alanında güç dağılımı analiz edilmiştir. Sonuçlar, korku ve rahatlama duygularının EEG dinamiklerine dayalı olarak %94.208 oranında sınıflandırılabileceğini göstermiştir. Bu sonuçlar, EEG sinyallerinin duygusal durumları sınıflandırmada etkili olduğunu ortaya koymaktadır [29].

Garg ve arkadaşlarının yayınladığı çalışma, EEG sinyallerini kullanarak duygusal durumları sınıflandırmayı amaçlamaktadır. AMIGOS veri seti kullanılmış ve Fourier ve dalgacık dönüşümü yoluyla iki özellik (normalize edilmiş güç ve normalize edilmiş dalgacık enerjisi) çıkarılmıştır. Araştırmada, derin sinir ağı ile tek ve birleştirilmiş özellikler için üç farklı aktivasyon fonksiyonu (exponential linear unit, rectified linear unit [ReLU] ve leaky ReLU) kullanılmıştır. Birleştirilmiş özellikler ve sızıntılı ReLU kullanılarak elde edilen sonuçlar, valence, arousal, dominance ve liking için sırasıyla %85,47, %81,87, %84.04 ve %86,63 doğruluk sağlamıştır. Bu sonuçlar, EEG sinyallerinin duygusal durumların doğru bir şekilde sınıflandırılmasında etkili olabileceğini göstermektedir [46].

Başka bir çalışmada, EEG sinyalleri kullanılarak duygu sınıflandırma performansının artırılmasına odaklanıyor. Bu çalışmada DEAP veri seti kullanılmış, ham EEG sinyallerinden derin anlamsal bilgileri ve doğrusal frekanslı cepstral katsayıları (LFCC) çıkarmak için önceden eğitilmiş Derin Artık Ağları (ResNets) kullanır. Çıkarılan bu özellikler daha sonra sınıflandırma doğruluğunu artırmak için birleştirilir. Araştırmacılar, k-en yakın komşu (KNN) sınıflandırıcısının kullanılmasının en iyi performansı sağladığını bulmuş ve bu etkinliğin nedenleri hakkında ayrıntılı bir tartışma sunmuştur. Önerilen yaklaşımın en iyi doğruluğu %93,75'e ulaşmış ve ortalama doğruluk %89,72'dir. Makale, EEG tabanlı duygu tanımada derin öğrenme ve geleneksel frekans özelliklerini birleştirmenin avantajlarını vurgulamaktadır [14].

Pereira ve Silva yaptığı çalışmada, video içeriğinin izleyiciler üzerindeki duygusal etkisini değerlendiren bir yöntem sunuldu. EEG verileri, gönüllülerin LIRIS-ACCEDE veri setinden seçilen videoları izlerken toplandı. Yapısal Nedensel Model (SCM) kullanılarak, video içeriğinin yaş, cinsiyet, EEG sinyali, beğenme/beğenmeme ve duygusal durumlar gibi değişkenler üzerindeki nedensel etkisi incelendi. Araştırma, video içeriğinin izleyicilerin duygusal tepkileri üzerinde önemli bir etkiye sahip olduğu sonucuna varmaktadır [47].

Luo ve arkadaşları yaptığı çalışmada, EEG işleme teknikleri ve spiking neural networks (SNNs) kullanılarak duygu durumlarının sınıflandırılması için yenilikçi bir yöntem sunuldu. üç algoritma (ayrık dalga dönüşümü (DWT), varyans ve hızlı Fourier dönüşümü (FFT)) EEG sinyallerini çıkarmak için kullanılıyor ve bu sinyaller SNN tarafından duygu sınıflandırması için işleniyor. DEAP ve SEED veri setleri kullanılarak, duygu durumlarının (arousal, valence, dominance ve liking) sınıflandırılması gerçekleştirildi. Deney sonuçları, varyans veri işleme tekniği ve SNN kullanılarak DEAP veri seti için arousal, valence, dominance ve liking durumlarının sırasıyla %74, %78, %80 ve %86.27 doğrulukla sınıflandırılabileceğini gösteriyor. SEED veri seti için ise genel doğruluk oranı %96.67 olarak belirlenmiştir. Araştırma, EEG verilerinin duygu tanıma alanındaki potansiyelini ve SNN'nin avantajlarını ortaya koymaktadır [13].

“EEG Based Neuromarketing Recommender System for Video Commercials" başlıklı makale, film fragmanlarının etkinliğini değerlendirmek için EEG sinyallerini kullanan bir nöropazarlama öneri sistemi geliştirmeyi amaçlamaktadır. Sistem, reklamları duygu, dikkat ve keyif açısından değerlendirir ve yüksek doğruluk oranlarına sahip algoritmalar kullanarak tüketici tepkilerini analiz eder. Araştırma, 18 katılımcıyla gerçekleştirilmiştir, önerilen çerçevenin video reklamlarının etkisini tahmin etmede başarılı olduğunu göstermiştir. Sistem, reklamları duygu, dikkat ve eğlence olmak üzere üç açıdan değerlendiriyor. Duygu analizi %91,97 doğruluk oranıyla Rastgele Orman algoritması kullanılarak gerçekleştirilmektedir. Dikkat analizi, %91,70 doğruluk oranına sahip c-Support Vector Classifier (c-svc) algoritmasını kullanır. Eğlence analizi, Merkezi Limit teoremi ve Ampirik kural gibi istatistiksel yaklaşımlar kullanılarak değerlendirilmektedir [48].

Tablo 5.1: Literatürdeki bazı çalışmaların tablo halinde gösterimi.

Araştırmacılar	Yayın Yılı	Çalışmanın Odak Noktası	Veri Seti	Ana Bulgular	Doğruluk Oranı (%)
Luo ve ark. [13]	2020	EEG ve SNN ile duygu durumları sınıflandırma	DEAP, SEED	SNN'nin duygu sınıflandırmasında etkinliği	74 - 86.27
Pereira ve Silva [40]	2022	Video içeriğinin duygusal etkisini hesaplama	LIRIS-ACCEDE	SCM kullanılarak video içeriğinin duygusal etkileri analizi	-
Liu ve ark. [14]	2018	EEG sinyallerini kullanarak otomatik duygu tanıma performansını artırmak	DEAP	Çoklu özellik füzyon yöntemlerinin geliştirilmesi	93.75 – 89.72
You ve Liu [38]	2020	EEG ile video beğeni durumu analizi	DEAP	Otomatik kodlayıcı sinir ağı yüksek doğrulukla beğeni analizi	80
Jalilifard ve ark. [29]	2020	Korku ve rahatlama duygularını sınıflandırma	-	EEG sinyallerinin duygusal durum sınıflandırmasındaki başarısı	94.208
Garg ve ark [39]	2021	EEG sinyalleriyle duygusal durum sınıflandırma	AMIGOS	DNN ile çeşitli duygusal durumların sınıflandırılması	85.47 - 86.63
Bandara ve ark. [41]	2021	Reklamları duygu, dikkat ve eğlence analizlerini sınıflandırılması.	-	Reklamları duygu, dikkat ve eğlence analizlerini sınıflandırma başarısı	91.97-91.70
Bu tez calışması	2024	EEG sinyalleriyle beğeni durumu kestirimi	-	GKA tabanlı yöntemler ve Derin Öğrenme yöntemleri ile beğeni durumu kestirimi	94-93

6. SONUÇ VE ÖNERİLER

Bu çalışma, EEG sinyallerinin Görgül Kip Ayrışım (GKA) tabanlı yöntemlerle ve Derin Öğrenme teknikleri ile analiz edilerek, tüketicilerin beğeni durumlarının yüksek doğrulukla sınıflandırılabileceğini göstermiştir. Bu bulgular, EEG sinyallerinde, GKA tabanlı yöntemlerin ve Derin Öğrenme tekniklerinin nöropazarlama uygulamalarında etkili bir araç olabileceğini göstermektedir.

Araştırma, EEG sinyallerinin analizinin, tüketicilerin ürün tercihlerini anlamak ve pazarlama stratejilerini buna göre şekillendirmek için değerli bir araç olduğunu ortaya koymaktadır. Bu, özellikle reklam ve ürün tasarımı gibi alanlarda reklamcılık alanına, pazarlama sektörüne ve karar vericilere önemli iç görüler sunabilir.

EEG sinyallerinin daha kapsamlı analizi ve farklı tüketici grupları üzerinde yapılan çalışmalarla, bu alanda daha geniş bir anlayışın geliştirilebileceğini önermektedir. Ayrıca, farklı ürün kategorileri ve reklam türleri üzerinde yapılan çalışmaların, EEG tabanlı nöropazarlama araştırmalarını daha da zenginleştireceğini belirtmektedir.

Nöropazarlama çalışmalarında EEG sinyallerinin daha derinlemesine analizi, tüketici tercihleri ve duygusal tepkiler arasındaki ilişkileri daha net bir şekilde ortaya çıkarabilir. Ayrıca tüketici tepkilerini anlamak ve buna göre ürünlerin veya reklamların optimize edilmesi için kullanılabilir.

7. KAYNAK

[1] T. M. Rutkowski, D. P. Mandic, A. Cichocki, ve A. W. Przybyszewski, "EMD approach to multichannel EEG data the amplitude and phase components clustering analysis", *Journal of Circuits, Systems and Computers*, c. 19, sy 1, ss. 215-229, Şub. 2010, doi: 10.1142/S0218126610006037.

[2] B. Sharma, S. Kaur, # [2] Scholar, ve M. Tech, "Distinction Between EMD & EEMD Algorithm for Pitch Detection in Speech Processing", *International Journal of Engineering Trends and Technology*, c. 7, sy 3, 2014, Erişim: 28 Mayıs 2024. [Çevrimiçi]. Erişim adresi: http://www.ijettjournal.org

[3] X. Zhao, T. H. Patel, ve M. J. Zuo, "Multivariate EMD and full spectrum based condition monitoring for rotating machinery", *Mech Syst Signal Process*, c. 27, sy 1, ss. 712-728, Şub. 2012, doi: 10.1016/J.YMSSP.2011.08.001.

[4] H. Hao, H. L. Wang, ve N. U. Rehman, "A joint framework for multivariate signal denoising using multivariate empirical mode decomposition", *Signal Processing*, c. 135, ss. 263-273, Haz. 2017, doi: 10.1016/J.SIGPRO.2017.01.022.

[5] Z. Wu ve N. E. Huang, "Ensemble empirical mode decomposition: A noise-assisted data analysis method", *Adv Adapt Data Anal*, c. 1, sy 1, ss. 1-41, Oca. 2009, doi: 10.1142/S1793536909000047.

[6] G. T. Gundlach, "The American Marketing Association's 2004 Definition of Marketing: Perspectives on Its Implications for Scholarship and the Role and Responsibility of Marketing in Society", *Journal of Public Policy & Marketing*, c. 26, sy 2, ss. 243-250, 2007, doi: 10.1509/jppm.26.2.243.

[7] "American Marketing Association, 'Definitions of Marketing,' [Çevrimiçi]. Available: https://www.ama.org/the-definition-of-marketing/. [Erişim: 01-Haziran-2024]."

[8] N. Lee, A. J. Broderick, ve L. Chamberlain, "What is 'neuromarketing'? A discussion and agenda for future research", *International Journal of Psychophysiology*, c. 63, sy 2, ss. 199-204, Şub. 2007, doi: 10.1016/J.IJPSYCHO.2006.03.007.

[9] P. Aytekin ve A. Kahraman, "Pazarlamada yeni bir araştırma yaklaşımı: nöropazarlama (a new research approach ın marketıng: neuromarketıng)", *Journal of Management, Marketing&Logistics - JMML*, c. 1, ss. 48-62, May. 2014.

[10] R. Gill ve J. Singh, "A study of neuromarketing techniques for proposing cost effective information driven framework for decision making", *Mater Today Proc*, c. 49, ss. 2969-2981, Oca. 2022, doi: 10.1016/J.MATPR.2020.08.730.

[11] K. Fehse, F. Simmank, E. Gutyrchik, ve A. Sztrókay-Gaul, "Organic or popular brands—food perception engages distinct functional pathways. An fMRI study", *Cogent Psychol*, c. 4, sy 1, s. 1284392, Ara. 2017, doi: 10.1080/23311908.2017.1284392.

[12] Y. Wang, V. Chattaraman, H. Kim, ve G. Deshpande, "Predicting Purchase Decisions Based on Spatio-Temporal Functional MRI Features Using Machine Learning", *IEEE*

Trans Auton Ment Dev, c. 7, sy 3, ss. 248-255, Eyl. 2015, doi: 10.1109/TAMD.2015.2434733.

[13] Y. Luo *vd.*, "EEG-Based Emotion Classification Using Spiking Neural Networks", *IEEE Access*, c. 8, ss. 46007-46016, 2020, doi: 10.1109/ACCESS.2020.2978163.

[14] N. Liu, Y. Fang, L. Li, L. Hou, F. Yang, ve Y. Guo, "Multiple feature fusion for automatic emotion recognition using EEG signals", *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, c. 2018-April, ss. 896-900, Eyl. 2018, doi: 10.1109/ICASSP.2018.8462518.

[15] R. N. Khushaba, C. Wise, S. Kodagoda, J. Louviere, B. E. Kahn, ve C. Townsend, "Consumer neuroscience: Assessing the brain response to marketing stimuli using electroencephalogram (EEG) and eye tracking", *Expert Syst Appl*, c. 40, sy 9, ss. 3803-3812, Tem. 2013, doi: 10.1016/J.ESWA.2012.12.095.

[16] R. S. Hessels ve I. T. C. Hooge, "Eye tracking in developmental cognitive neuroscience – The good, the bad and the ugly", *Dev Cogn Neurosci*, c. 40, s. 100710, Ara. 2019, doi: 10.1016/J.DCN.2019.100710.

[17] L. Danner, S. Haindl, M. Joechl, ve K. Duerrschmid, "Facial expressions and autonomous nervous system responses elicited by tasting different juices", *Food Research International*, c. 64, ss. 81-90, Eki. 2014, doi: 10.1016/J.FOODRES.2014.06.003.

[18] R. Ohme, D. Reykowska, D. Wiener, ve A. Choromanska, "Analysis of Neurophysiological Reactions to Advertising Stimuli by Means of EEG and Galvanic Skin Response Measures", *J Neurosci Psychol Econ*, c. 2, sy 1, ss. 21-31, 2009, doi: 10.1037/A0015462.

[19] J. P. Marques dos Santos, M. Martins, H. A. Ferreira, J. Ramalho, ve D. Seixas, "Neural imprints of national brands versus own-label brands", *Journal of Product and Brand Management*, c. 25, sy 2, ss. 184-195, Nis. 2016, doi: 10.1108/JPBM-12-2014-0756/FULL/PDF.

[20] S. Ogawa, T. -M Lee, A. S. Nayak, ve P. Glynn, "Oxygenation-sensitive contrast in magnetic resonance image of rodent brain at high magnetic fields", *Magn Reson Med*, c. 14, sy 1, ss. 68-78, Nis. 1990, doi: 10.1002/MRM.1910140108.

[21] L. A. Casado-Aranda, L. N. Van der Laan, ve J. Sánchez-Fernández, "Neural correlates of gender congruence in audiovisual commercials for gender-targeted products: An fMRI study", *Hum Brain Mapp*, c. 39, sy 11, ss. 4360-4372, Kas. 2018, doi: 10.1002/HBM.24276.

[22] S. Kumari ve A. K. Dutta, "Brain waves, neuroimaging (fMRI, EEG, MEG, PET, NIR)", *Computational Techniques in Neuroscience*, ss. 67-82, Kas. 2023, doi: 10.1201/9781003398066-4.

[23] K. Köhler-Forsberg *vd.*, "Predicting Treatment Outcome in Major Depressive Disorder Using Serotonin 4 Receptor PET Brain Imaging, Functional MRI, Cognitive-, EEG-Based, and Peripheral Biomarkers: A NeuroPharm Open Label Clinical Trial Protocol",

Front Psychiatry, c. 11, s. 513221, Tem. 2020, doi: 10.3389/FPSYT.2020.00641/BIBTEX.

[24] S. Hellwig ve K. Domschke, "Update on PET imaging biomarkers in the diagnosis of neuropsychiatric disorders", *Curr Opin Neurol*, c. 32, sy 4, ss. 539-547, Ağu. 2019, doi: 10.1097/WCO.0000000000000705.

[25] A. L. Fred *vd.*, "A Brief Introduction to Magnetoencephalography (MEG) and Its Clinical Applications", *Brain Sci*, c. 12, sy 6, Haz. 2022, doi: 10.3390/BRAINSCI12060788.

[26] D. Cohen, "Magnetoencephalography: Evidence of Magnetic Fields Produced by Alpha-Rhythm Currents", *Science (1979)*, c. 161, sy 3843, ss. 784-786, 1968, doi: 10.1126/science.161.3843.784.

[27] R. Paetau, "Magnetoencephalography in pediatric neuroimaging", *Dev Sci*, c. 5, sy 3, ss. 361-370, Ağu. 2002, doi: 10.1111/1467-7687.00375.

[28] J. L. Stone ve J. R. Hughes, "Early history of electroencephalography and establishment of the american clinical neurophysiology society", *Journal of Clinical Neurophysiology*, c. 30, sy 1, ss. 28-44, Şub. 2013, doi: 10.1097/WNP.0B013E31827EDB2D.

[29] A. Jalilifard, A. Rastegarnia, E. B. Pizzolato, ve M. K. Islam, "Classification of emotions induced by horror and relaxing movies using single-channel EEG recordings", *International Journal of Electrical and Computer Engineering (IJECE)*, c. 10, sy 4, ss. 3826-3838, Ağu. 2020, doi: 10.11591/IJECE.V10I4.PP3826-3838.

[30] G. Guney, E. Kisacik, C. Kalaycioglu, ve G. Saygili, "Exploring the attention process differentiation of attention deficit hyperactivity disorder (ADHD) symptomatic adults using artificial intelligence onelectroencephalography (EEG) signals", *Turkish Journal of Electrical Engineering and Computer Sciences*, c. 29, sy 5, ss. 2312-2325, Oca. 2021, doi: 10.3906/elk-2011-3.

[31] A. Vehlen, I. Spenthof, D. Tönsing, M. Heinrichs, ve G. Domes, "Evaluation of an eye tracking setup for studying visual attention in face-to-face conversations", *Scientific Reports 2021 11:1*, c. 11, sy 1, ss. 1-16, Oca. 2021, doi: 10.1038/s41598-021-81987-x.

[32] Z. Luo, "Using eye-tracking technology to identify learning styles: Behaviour patterns and identification accuracy", *Educ Inf Technol (Dordr)*, c. 26, sy 4, ss. 4457-4485, Tem. 2021, doi: 10.1007/S10639-021-10468-5/METRICS.

[33] N. Rehman ve D. P. Mandic, "Multivariate empirical mode decomposition", *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, c. 466, sy 2117, ss. 1291-1302, May. 2010, doi: 10.1098/RSPA.2009.0502.

[34] D. P. Mandic, N. Ur Rehman, Z. Wu, ve N. E. Huang, "Empirical mode decomposition-based time-frequency analysis of multivariate signals: The power of adaptive data analysis", *IEEE Signal Process Mag*, c. 30, sy 6, ss. 74-86, 2013, doi: 10.1109/MSP.2013.2267931.

[35] D. P. Mandic, N. Ur Rehman, Z. Wu, ve N. E. Huang, "Empirical mode decomposition-based time-frequency analysis of multivariate signals: The power of adaptive data analysis", *IEEE Signal Process Mag*, c. 30, sy 6, ss. 74-86, 2013, doi: 10.1109/MSP.2013.2267931.

[36] N. Ur Rehman ve D. P. Mandic, "Empirical mode decomposition for trivariate signals", *IEEE Transactions on Signal Processing*, c. 58, sy 3 PART 1, ss. 1059-1068, Mar. 2010, doi: 10.1109/TSP.2009.2033730.

[37] M. Robnik-Šikonja ve I. Kononenko, "Theoretical and Empirical Analysis of ReliefF and RReliefF", *Mach Learn*, c. 53, sy 1-2, ss. 23-69, Eki. 2003, doi: 10.1023/A:1025667309714/METRICS.

[38] B. E. Boser, I. M. Guyon, ve V. N. Vapnik, "Training algorithm for optimal margin classifiers", *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, ss. 144-152, 1992, doi: 10.1145/130385.130401.

[39] F. Iandola, M. W. Moskewicz, K. Ashraf, S. Han, W. Dally, ve K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <1MB model size", *arXiv.org*, 2016.

[40] C. Szegedy *vd.*, "Going deeper with convolutions", *Computer Vision and Pattern Recognition*, c. 07-12-June-2015, ss. 1-9, Eki. 2014, doi: 10.1109/CVPR.2015.7298594.

[41] K. He, X. Zhang, S. Ren, ve J. Sun, "Deep Residual Learning for Image Recognition", *Computer Vision and Pattern Recognition*, c. 2016-December, ss. 770-778, Ara. 2015, doi: 10.1109/CVPR.2016.90.

[42] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, ve L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks", *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, ss. 4510-4520, Ara. 2018, doi: 10.1109/CVPR.2018.00474.

[43] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, ve Z. Wojna, "Rethinking the Inception Architecture for Computer Vision", *Computer Vision and Pattern Recognition*, c. 2016-December, ss. 2818-2826, Ara. 2015, doi: 10.1109/CVPR.2016.308.

[44] C. Szegedy, S. Ioffe, V. Vanhoucke, ve A. A. Alemi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning", *AAAI Conference on Artificial Intelligence*, ss. 4278-4284, 2016, doi: 10.1609/AAAI.V31I1.11231.

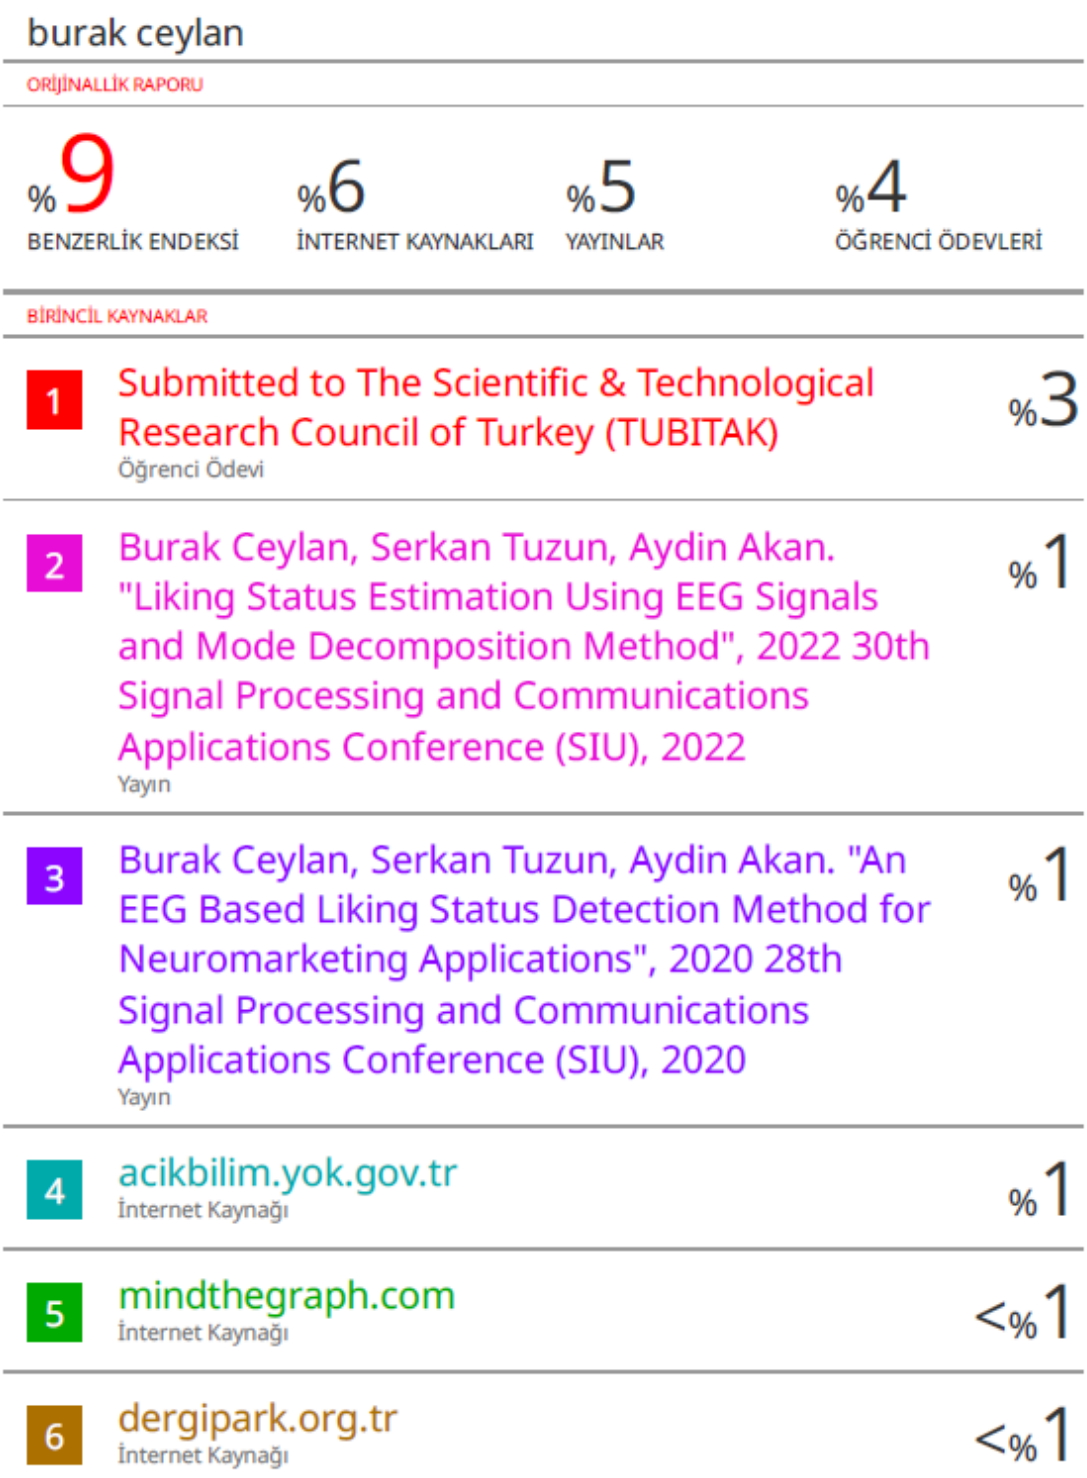
[45] S. D. You ve C. W. Liu, "Classification of User Preference for Music Videos Based on EEG Recordings", *LifeTech 2020 - 2020 IEEE 2nd Global Conference on Life Sciences and Technologies*, ss. 1-2, Mar. 2020, doi: 10.1109/LIFETECH48969.2020.1570614518.

[46] X. Yin *vd.*, "Deep Neural Network for Electroencephalogram based Emotion Recognition", *IOP Conf Ser Mater Sci Eng*, c. 1187, sy 1, s. 012012, Eyl. 2021, doi: 10.1088/1757-899X/1187/1/012012.

[47] E. T. Pereira ve G. D. N. Silva, "Towards Causal Effect Estimation of Emotional Labeling of Watched Videos", *Revista de Informática Teórica e Aplicada*, c. 29, sy 2, ss. 48-62, May. 2022, doi: 10.22456/2175-2745.111817.

[48] S. K. Bandara, U. C. Wijesinghe, B. P. Jayalath, S. K. Bandara, P. S. Haddela, ve L. M. Wickramasinghe, "EEG Based Neuromarketing Recommender System for Video Commercials", *2021 IEEE 16th International Conference on Industrial and Information Systems, ICIIS 2021 - Proceedings*, ss. 11-16, 2021, doi: 10.1109/ICIIS53135.2021.9660742.

İNTİHAL RAPORU İLK SAYFASI



burak ceylan

ORİJİNALLİK RAPORU

%9	%6	%5	%4
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%3
2	Burak Ceylan, Serkan Tuzun, Aydin Akan. "Liking Status Estimation Using EEG Signals and Mode Decomposition Method", 2022 30th Signal Processing and Communications Applications Conference (SIU), 2022 Yayın	%1
3	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
4	acikbilim.yok.gov.tr İnternet Kaynağı	%1
5	mindthegraph.com İnternet Kaynağı	<%1
6	dergipark.org.tr İnternet Kaynağı	<%1