

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



EEG SİNYALLERİNDEN DUYGU TANIMA İÇİN AKILLI

YÖNTEMLERİN GELİŞTİRİLMESİ

Merve AKAY YILDIRIM

Yüksel Lisans Tezi

ADLİ BİLİŞİM MÜHENDİSLİĞİ ANABİLİM DALI

OCAK 2022

T.C.
Fırat Üniversitesi
Fen Bilimleri Enstitüsü

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

EEG SİNYALLERİNDEN DUYGU TANIMA İÇİN AKILLI YÖNTEMLERİN GELİŞTİRİLMESİ

Tez Yazarı
Merve AKAY YILDIRIM

Danışman
Doç. Dr. Türker TUNCER

OCAK 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksel Lisans Tezi

Başlığı: EEG Sinyallerinden Duygu Tanıma İçin Akıllı Yöntemlerin Geliştirilmesi
Yazarı: Merve AKAY YILDIRIM
İlk Teslim 21.12.2021
Savunma 24.01.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Türker TUNCER Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Dr. Öğr. Üyesi Orhan YAMAN Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Mehmet BAYĞIN Ardahan Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20.... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “EEG Sinyallerinden Duygu Tanıma İçin Akıllı Yöntemlerin Geliştirilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

24.01.2022

Merve AKAY YILDIRIM



ÖNSÖZ

Bu tez çalışması Fırat Üniversitesi Fen Bilimleri Enstitüsü Adli Bilişim Mühendisliği Anabilim Dalı Tezli Yüksek Lisans Programı için hazırlanmıştır. Bu tez çalışması EEG sinyallerinden duygu tanıma uygulamaları üzerine çalışılmıştır.

Tez çalışmam boyunca benden hiçbir yardımını ve desteğini esirgemeyen danışmanım Sayın Doç. Dr. Türker TUNCER'e minnet ve şükranlarımı sunarım.

Yüksek lisans programının her aşamasında yanımda, arkamda olan sevgili eşim Yusuf YILDIRIM'a teşekkürü bir borç bilirim.

Yaptığım ve yapacağım işlerde arkamda olan ve desteklerini benden esirgemeyen sevgili aileme minnet ve şükranlarımı sunarım.

Merve AKAY YILDIRIM

ELAZIĞ, 2022

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ	ix
SİMGELER	x
KISALTMALAR	xi
1. GİRİŞ	1
1.1. Literatür Özeti	2
2. EEG TABANLI DUYGU TANIMA	16
2.1. Duygu Modelleri	16
2.2. Elektroensefalografi.....	16
2.3. EEG Tabanlı Duygu Tanıma Süreci	17
2.3.1. Katılımcı Seçimi.....	17
2.3.2. Uyarılar.....	18
2.3.3. EEG Sinyallerinin Elde Edilmesi	19
2.3.4. EEG Veri Setleri.....	22
2.3.5. Ön İşleme	25
2.3.6. Özellik Çıkarma	26
2.3.7. Duygu Sınıflandırma	27
3. DUYGU TANIMADA KULLANILAN YÖNTEMLER.....	28
3.1. Destek Vektör Makinesi	29
3.2. Yerel İkili Örüntüler	29
3.3. Bir Boyutlu Yerel İkili Örüntüler	30
3.4. K-En Yakın Komşu	31
3.5. Ayrık Dalgacık Dönüşümü	32
3.6. Sınıflandırıcı Performansı ve Doğruluk Ölçümleri.....	32
3.6.1. Doğruluk Hesaplaması	32
3.6.2. Çapraz Doğrulama.....	34
4. MATERYAL VE METOT	35
4.1. Bir Boyutlu Yerel İkili Örüntü ile Ayrık Dalgacık Dönüşümü Kullanarak Duygu Tanıma	35
4.2. Asal Örüntü Yöntemi Kullanarak Duygu Tanıma	37
5. BULGULAR VE TARTIŞMA	44
5.1. Bir Boyutlu Yerel İkili Örüntü ile Ayrık Dalgacık Dönüşümü Yöntemi.....	44
5.2. Asal Örüntü Yöntemi.....	45
6. SONUÇLAR.....	55
KAYNAKLAR.....	56
ÖZGEÇMİŞ	

ÖZET

EEG Sinyallerinden Duygu Tanıma İçin Akıllı Yöntemlerin Geliştirilmesi

Merve AKAY YILDIRIM

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Adli Bilişim Mühendisliği Anabilim Dalı
Ocak 2022, Sayfa: xi + 61

Günümüzde duyguların tanınması birçok alanda önemli bir unsur haline gelmiştir. EEG sinyallerinin çeşitli beyin ve nörolojik durumları teşhis ettiği düşünülmektedir. Duygusal durumun tespiti ve analizi için karakteristik sinyaller ürettiğinden bu çalışmada EEG sinyalleri kullanılmıştır. Bu tez çalışmasında önerilen modelin birincisinde efektif ve basit yöntem geliştirerek yüksek doğruluğa sahip otomatik duygu tanıma, diğerinde ise tek boyutlu sinyaller için yeni bir öğrenme modeli ile daha yüksek sınıflandırma geliştirerek yüksek doğruluğa sahip otomatik duygu tanıma amaçlanmıştır.

Önerilen yöntemlerin birincisinde yerel ikili desen, çok düzeyli ayrık dalgacık dönüşümü, komşuluk bileşen analizi ve k-en yakın komşu sınıflandırıcı kullanılarak yeni bir otomatik EEG duygu tanıma modeli sunulmuştur. Bu model GAMEEMO veri setinde mükemmel sınıflandırma oranına %100.0 ulaşmıştır. Bu sonuçlar, modelin duygu sınıflandırması için EEG sinyalleri üzerindeki yüksek sınıflandırma yeteneğini açıkça göstermiştir.

Önerilen diğer yöntemde, asal örüntü ve ayarlanabilir q-faktörlü dalgacık dönüşümü (AQDD) özellik üretme modeli sunulmuştur. Bu model, özellik çıkarma, özellik seçimi ve sınıflandırma olmak üzere makine öğrenimi modelinin tüm aşamalarını kapsamaktadır. Önerilen model 87 özellik vektörü ürettiğinden dolayı, bu model PrimePatNet87 olarak adlandırılmıştır. Önerilen modeli geliştirmek için herkese açık GAMEEMO, DREAMER ve DEAP veri seti kullanılmıştır. PrimePatNet87 modeli, birey bazlı çapraz doğrulama (LOSO) ile tüm veri kümelerinde %99'un üzerinde sınıflandırma doğruluğuna ulaşmıştır. Bu sonuçlar, önerilen asal örüntü modelinin gerçek dünya uygulamaları için hazır olduğunu göstermiştir.

Anahtar Kelimeler: EEG Sinyal Tanıma, Duygu Tanıma, Yerel Özellik Çıkarma, Özellik Seçme, Sınıflandırma

ABSTRACT

Developing Intelligent Methods for Emotion Recognition from EEG Signals

Merve AKAY YILDIRIM

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Digital Forensics Engineering
January 2022, Pages: xi + 61

Nowadays, emotion recognition has become an important element in many areas. EEG signals are thought to diagnose a variety of brain and neurological conditions. EEG signals were used in this study because they generate characteristic signals for the detection and analysis of the emotional state. In the proposed model of this thesis, it was aimed to develop an effective and simple method to develop high-accuracy automatic emotion recognition, together with developing a higher classification with a new learning model for one-dimensional signals, and to achieve high-accuracy automatic emotion recognition.

In the first proposed methods, a new automatic EEG emotion recognition model is presented using local binary pattern, multilevel discrete wavelet transform, neighborhood component analysis and k-nearest neighbor classifier. This model has reached an excellent classification rate of 100.0% in the GAMEEMO dataset. These results clearly demonstrated the model's high classification ability on EEG signals for emotion classification.

In the other proposed method, the prime pattern and tunable q-factor wavelet transform (TQDD) feature generation model are presented. This model covers all phases of the machine learning model, including feature extraction, feature selection, and classification. Since the proposed model generates 87 feature vectors, this model is named PrimePatNet87. The publicly available GAMEEMO, DREAMER and DEAP datasets were used to develop the proposed model. The PrimePatNet87 model achieved over 99% classification accuracy across all datasets with leave one subject out (LOSO) validation. These results show that the proposed prime pattern model is ready for real-world applications.

Keywords: EEG Signal Recognition, Emotion Recognition, Local Feature Extraction, Feature Selection, Classification

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1.	Değerlik-uyarılma duygu modeli 16
Şekil 2.2.	Frekans bantlarına EEG sinyalleri 17
Şekil 2.3.	EEG tabanlı duygu tanıma süreci 17
Şekil 2.4.	Duygu durumları için öz değerlendirme formu [94]..... 19
Şekil 2.5.	EEG sinyallerini elde etmede kullanılan ekipmanlar 20
Şekil 2.6.	Elektrotların 10-20 sistemine göre yerleştirilmesi 21
Şekil 2.7.	Elektrotların 10-10 sistemine göre yerleştirilmesi 21
Şekil 2.8.	EEG frekans bantları ile zihinsel durumun ilişkilendirilmesi 26
Şekil 3.1.	Makine öğrenme yöntemleri 28
Şekil 3.2.	Destek vektör makinesi çalışma mantığı 29
Şekil 3.3.	Yerel ikili örüntü yöntemi..... 30
Şekil 3.4.	Bir boyutlu yerel ikili örüntü yöntemi 30
Şekil 3.5.	Veri kümesinin segmentlere ayrılması..... 34
Şekil 4.1.	Önerilen yöntemin blok diyagramı 36
Şekil 4.2.	KNN sınıflandırıcısının optimum parametreleri 37
Şekil 4.3.	Önerilen modelin diyagramı 39
Şekil 4.4.	Önerilen asal örüntünün grafiksel gösterimi 40
Şekil 5.1.	DREAMER veri setini kullanan uyarılma, baskınlık ve değerlik durumları için çoğunluk oylaması sonuçları47
Şekil 5.2.	Yinelemeli çoğunluk oylaması kullanılarak elde edilen kanal sayısına karşı doğruluk grafiği 50
Şekil 5.3.	GAMEMO veri seti için ilk EEG kanalı kullanılarak elde edilen özellik sayısına karşı yanlış sınıflandırma oranları (%) grafiği..... 51
Şekil 5.4.	GAMEMO veri seti için birinci kanalın beş sınıflandırıcı ile önerilen model kullanılarak elde edilen doğruluklar 52
Şekil 5.5.	250, 500, 750 ve 1000 özellikleri kullanılarak DREAMER uyarılma durumu için elde edilen doğruluklar 53

TABLolar LİSTESİ

	Sayfa
Tablo 2.1. DEAP veri seti özellikleri	22
Tablo 2.2. SEED veri seti özellikleri	23
Tablo 2.3. DREAMER veri seti özellikleri	23
Tablo 2.4. MAHNOB-HCI veri seti özellikleri.....	24
Tablo 2.5. GAMEEMO veri seti özellikleri.....	24
Tablo 3.1. Karışıklık matrisi	33
Tablo 4.1. Kullanılan DVM sınıflandırıcısının parametreleri	43
Tablo 5.1. Önerilen yöntemin her bir kanala ait metrik değeri	44
Tablo 5.2. Önerilen yöntemin diğer çalışmalarla karşılaştırılması.....	45
Tablo 5.3. Önerilen modelde GAMEEMO veri seti kullanılarak elde edilen sonuçlar (%)	46
Tablo 5.4. Önerilen model kullanılarak DREAMER veri setinin her bir kanala ait uyarılma ve değerlik (%) performansı	46
Tablo 5.5. Önerilen model kullanılarak DREAMER veri setinin her bir kanala ait baskınlık (%) performansı	47
Tablo 5.6. Önerilen modelin DEAP veri seti kullanılarak her bir kanala ait uyarılma ve değerlik (%) performansı	48
Tablo 5.7. Önerilen modelin DEAP veri seti kullanılarak her bir kanala ait baskınlık (%) performansı ..	49
Tablo 5.8. Önerilen modelde DEAP veri seti kullanılarak elde edilen çoğunluk oylama sonuçları	49

SİMGELER

$ADD(.)$: Bir boyutlu ayırık dalgacık dönüşümü
as	: Asal sayı kümesi
A^k	: k. alçak geçirgen frekans katsayısı
Y^k	: k. yüksek geçirgen frekans katsayısı
b^i	: i. örtüşen blok
$C(.,.)$: Kullanılan sınıflandırıcı
dim	: Gözlem sayısı
dn	: Doğru negatif
dp	: Doğru pozitif
e	: Eşik değeri
f	: Fazlalık
$fc()$: Chi2 özellik seçim fonksiyonu
f^t	: t. özellik vektörü
$F1$: F1-Skor
g	: EEG sinyali
h^k	: 256 uzunluktaki k. histogram
idx	: Artan nitelikli indeksler
$l(i)$: i. kayıp değeri
L	: Level sayısı
Ln	: Sinyal uzunluğu
$mod(.)$: Mod işlevi
mf	: Birleştirilen 15360 uzunluğundaki özellikler
m^k	: Hesaplanan k. harita sinyali
OA	: Doğruluk
ov	: Son özellik vektörünün birleştiği yer
Pr	: Hassasiyet
Rec	: Hatırlama
S	: Sinyal
$std(.)$: Standart sapma fonksiyonu
t	: Doğruluklarına göre sıralanmış tahmini değer
tv	: Oylanan tahmin vektör
y	: Gerçek çıktı
yn	: Yanlış negatif
yp	: Yanlış pozitif

KISALTMALAR

ADD	: Ayırık Dalgacık Dönüşümü
AQDD	: Ayarlanabilir Q-Faktörlü Dalgacık Dönüşümü
AQDDT	: Ayarlanabilir Q-Faktörlü Dalgacık Dönüşüm Tabanı
BBYİÖ	: Bir Boyutlu Yerel İkili Örüntüler
DA	: Doğrusal Ayırıcı
DVM	: Destek Vektör Makinesi
EEG	: Elektroensefalografi
KA	: Karar Ağacı
KBA	: Komşuluk Bileşen Analizi
KNN	: K-en Yakın Komşu
LOSO	: Birey Bazlı Çapraz Doğrulama
mRMR	: Minimum Artıklık Maksimum Alaka Düzeyi
SBO	: Sınıflandırma Başarı Oranı
TA	: Torbalı Ağaç
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Son zamanlarda duyguların tanınması amacıyla beyin bilgisayar ara yüzleri alanı popüler olmaya başlamış, bu alanda birçok psikolog, sinirbilimci, mühendis duygu tanıma üzerine çalışma yapmıştır. Duygu tanıma ile uyku bozuklukları, epilepsi nöbetlerinin takibi ve tespiti, gerçek duygularını göstermekte zorlanan parkinson, otizm gibi hastalıkların teşhisi yapılmıştır.

Duygu, dış uyaranlara tepki olarak tanımlanabilen ve insan bilincini temsil eden [1], bireyin düşüncelerinden oluşur. Duygular, insanlar birbirleriyle iletişim kurarken, düşünürken, herhangi bir şeye karar verirken uyaranlara verdikleri tepki olarak bilindiğinden, günlük yaşamlarındaki davranışlarını belirlemede temel bir rol oynar[2]. Duygu, kişiden kişiye farklılık gösteren öznel bir durumdur. Her insanın bir olaya veya uyarılana verdiği tepki ve sonrasında oluşan duygu durumu birbirinden bağımsız olabilir.

Duygunun tanımlanabilmesi için yüz ifadesi, ses, kan basıncı, beyin dalgaları gibi fizyolojik özelliklerden faydalanılmaktadır. Duyguların daha iyi tanınması, insanlar arasında etkili iletişime yol açacaktır. Bu yüzden duygu tanıma sistemleri günümüzde birçok alanlarda kullanılmaktadır. Bu sistemler teknolojinin gelişmesi ile birlikte akıllı ev, akıllı şehir[3], sağlık [4, 5], mobil sistemler[6, 7], eğitim[8] gibi farklı alanlarda kullanılmasını sağlamıştır.

EEG, beyin bilgisayar ara yüzü alanında önemli rol oynayan, beyin aktivite sensörleri sayesinde elde edilen kayıtlardır diyebiliriz. EEG, beyindeki aktivitelerin belirli araçlar yardımıyla sinyallerin kaydedildiği inceleme yöntemi olan noninvazif [9] yöntemdir. EEG, saç derisini çevreleyecek şekilde iletken elektrotlar aracılığı ile kaydedilmektedir. Alınan kaydın incelenmesi sonucu beynin yapısal özellikleri, fonksiyonellik tespit edildiğinden kıymetli veriler barındırır. EEG, beyin ile ilgili birçok hastalığın tanınması, takibi, değerlendirilmesinde büyük öneme sahiptir.

İnsanların gerçek duygularını tanımlamak ve anlamak zor bir problemdir. Bu problemin çözümü için birçok yöntem önerilmiş ve birçok veri kullanılmıştır. Sıklıkla kullanılan veriler yüz ve konuşma verileridir. Ancak bireyler yüz ifadelerini ve seslerini kontrol edebilmektedir. Bu problemin üstesinden gelebilmek için EEG tabanlı duygu tanıma yöntemleri önerilmiştir. EEG tabanlı duygu tanımanın en zor kısmı ise EEG sinyallerinin yorumlanmasıdır. EEG sinyalleri genellikle nörologlar tarafından yorumlanabilen özel ve medikal sinyallerdir. Bunun yanı sıra EEG' den duygu tanıma zor ve uzmanlık isteyen bir süreçtir. Bu problemlerin üstesinden gelebilmek için makine öğrenmesi teknikleri kullanılarak EEG duygu tanımlama yöntemleri önerilmiştir. Bu konuyla ilgili birçok yayın ve veri seti bulunmaktadır ancak makine öğrenmesi yöntemleri bu konuda yüksek başarımla elde edememektedir. Bu nedenle derin öğrenme yöntemleri EEG duygu veri setlerine uygulanarak yüksek başarımla elde edilmesi amaçlanmıştır ancak derin öğrenme yöntemlerinin de hesaplama maliyetleri yüksektir.

EEG sinyallerini duygu tanıma kullanmak daha güvenilirdir. Geçmiş ve günümüzde yapılan çalışmalar incelendiğinde EEG sinyalleri kontrol edilemediği için daha doğru sonuç vermesi amacıyla bu sinyaller üzerinden duygu tanıma seçilmiştir. Son zamanlarda duygu tanıma işleminin sağlıklı olabilmesi için başvurulan yöntem beyin sinyallerine dayalı duygu tahmini araştırmaları hız kazanmıştır. Ses ve yüz verileri kullanılarak duygu tanımayla ilgili yapılan çalışmalar vardır ancak ses, yüzlerin kontrol edilebilir olması sebebiyle doğru ve güvenilir sonuçların elde edilemeyeceği aşikârdır. Bu sebepten dolayı duygusal ve bilişsel durumu anlayıp, anlamlı sinyale dönüştüren yöntemin duygu tanıma amaçlı kullanılması doğruluk düzeyini artıracaktır.

Bu çalışmada önerilen ilk model ile efektif ve basit yöntemler geliştirerek yüksek doğruluğa sahip EEG sinyallerinden duygu tanıma amaçlanmıştır. Diğer modelde ise yeni bir öğrenme modeli önererek tek boyutlu sinyaller için yüksek doğruluğa sahip otomatik duygu tanıma amaçlanmıştır.

Yapılacak olan çalışmada var olan veri setleri üzerinden makine öğrenmesi yöntemi ile hem basit bir yöntem önerilecek hem de yüksek başarımlar elde edilecektir. Bu çalışmada önerilen ilk yöntemde GAMEEMO, ikinci yöntemde ise GAMEEMO, DREAMER ve DEAP veri seti kullanılacaktır. Tez organizasyonu genel hatlarıyla şu şekildedir: 2. bölümde duygu ve elektroensefalografi kavramları tanıtılarak, EEG tabanlı duygu tanıma süreci, 3. bölümde duygu tanıma kullanılan makine öğrenme ve derin öğrenme yöntemleri, 4. Bölümde bu çalışmada önerilen iki modelin yöntemleri, 5. bölümde önerilen yöntemlerden elde edilen sonuçlar, 6. bölümde ise sonuç kısmına yer verilmiştir.

1.1. Literatür Özeti

Literatüre bakıldığında EEG sinyallerinden duygu tanıma üzerine birçok çalışma yer almaktadır. Son beş yılda olan çalışmalardan bazıları aşağıda incelenmiştir.

Iacoviello vd. [10] dalgacık dönüşüm, temel bileşen analizi ve destek vektör makinesi kullanarak tetiklenen duygulardan elde edilen EEG sinyalleri sınıflandırmak için yöntem önermiştir. Bu çalışmada 8 kanal içeren, koku ile uyarılan 25 ve 40 yaş arası 10 erkekten alınan EEG sinyalleri ile tek bir duygu durumu için veri seti oluşturulmuştur. Elde edilen EEG sinyallerine dalgacık dönüşüm ile ön işleme, temel bileşen analizi ile özellik seçimi, seçilen özelliklerin sınıflandırılması için de destek vektör makinesi kullanılmıştır. Sinyaller, özellik seçimi olan uygun bir sınıflandırıcının eğitimi olan çevrimdışı, sınıflandırıcının yeni verilere uygulanması olan çevrimiçi olmak üzere iki aşamalı algoritma ile sınıflandırılmış, sınıflandırma performansı 10 kat çapraz yöntemi ile hesaplanmıştır. Önerilen yöntemde yaşanan konsantrasyon sebebiyle tatmin edici sonuçlar elde edilememiş, sınıflandırma sonucu diğer sınıflandırma yöntemleri ile karşılaştırılmamıştır. Ayrıca önerilen algoritmanın birden fazla duygu durumu ve daha büyük veri seti için performansı bilinmemektedir.

Khezri vd. [11] füzyon tabanlı dinamik ağırlıklı sınıflandırıcı ile çok modlu duygu tanıma yöntemi önermiştir. Bu çalışmada 25 video ile uyarılan 25 kişiden alınan EEG sinyalleri ile öfke, üzüntü, korku, iğrenme, mutluluk ve şaşkınlık duygu durumları için veri seti oluşturulmuştur. Elde edilen sinyallere chebyshev tip 2 filtre uygulanarak ön işleme yapılmış, sıralı ileri özellik seçim yöntemi ile özellikler çıkarılmıştır. Önerilen yöntem destek vektör makinesi ve k-en yakın komşu ile birlikte sınıflandırma yapılmış, önerilen yöntemin doğruluk değeri sırasıyla %84,7 ve %80 elde edilmiştir. Kullanıcıdan bağımsız bu sistemin performans tespiti için daha büyük veri seti ile sonuçlandırılması gerekmektedir.

Lahane ve Sangaiah [12] yapay sinir ağı sınıflandırıcısı kullanarak EEG sinyallerinden duygu tanıma için bir yöntem önermiştir. Bu çalışmada California Riverside Üniversitesi'nin arşivinden alınan tek boyutlu veri akışları ile CLAW veri seti kullanılmıştır. Alınan EEG sinyallere bağımsız bileşenler analizi ile ön işleme yapılmış, çekirdek yoğunluk tahmini kullanılarak özellik çıkarılmış ve sınıflandırma için yapay sinir ağı kullanılmıştır. Önerilen yöntem optimum bellek kullanımı ve veri akışının verimli işlenmesi katkılarını sağlasa da ön işleme, özellik çıkarma veya sınıflandırma için farklı teknikler kullanılarak daha iyi performans elde edilebilir.

Placidi vd.[13] hoş olmayan kokuların hatırlanması sonucu oluşan tiksinti duygusunun sınıflandırılması için ikili, eşik tabanlı bir sınıflandırma algoritması önermiştir. Bu çalışmada 8 kanal içeren, 18 erkek ve 10 kadından oluşan 28 kişiden alınan EEG sinyalleri ile veri seti oluşturulmuştur. Sistem kalibre edilmiş ardından elde edilen sinyallere kısa süreli fourier dönüşümü ile ön işleme yapılmış ve özellikleri çıkarılmıştır. İkinci testte de aynı işlemler yapılmış, depolanan etiketli denemelerle karşılaştırılarak eşik sınıflandırma algoritması ile sınıflandırma işlemi yapılmıştır. Önerilen yöntemin doğruluk değeri ilk test için %88,7, ikinci test için %89,9 elde edilmiştir. Önerilen yöntemin performansı diğer sınıflandırma yöntemleriyle değerlendirilmemiş ve karşılaştırmaları yapılmamıştır.

Zheng ve Lu [14] EEG tabanlı duygu tanıma için kritik frekans bantları ve kanalları araştırarak, pozitif, nötr ve negatif olan üç duygu durumu için 15 duygusal film klipleri ile uyarılan, 15 kişiden alınan EEG sinyalleri ile veri seti oluşturmuştur. Alınan EEG sinyallerine bant geçiren filtre ile ön işleme yapılmış ardından sinyaller segmentlere bölünmüştür. Delta, theta, alpha, beta ve gamma olmak üzere beş frekans bandının kısa süreli fourier dönüşümü hesaplanmış, diferansiyel entropi özellikleri çıkarılmıştır. Çıkarılan güç spektral yoğunluğu, diferansiyel asimetri, rasyonel asimetri, diferansiyel entropi ve diferansiyel kaudalite özellikleri, k-en yakın komşu, lojistik regresyon, destek vektör makinesi ve derin inanç ağları ile sınıflandırılmış, diferansiyel entropi özelliği derin inanç ağlarının doğruluğu %86.08 olmak üzere diğerlerine göre en iyi performans elde edilmiştir. Önerilen yöntemin eğitimi için hesaplama süresi azaltılmalı ve bu yöntemin analizi

ve performansının tespiti için daha fazla kişi ve duygu durumu içeren büyük ölçekli veri setine uygulanmalıdır.

Zhang vd. [15] kanal sayısının ve çıkarılan özellik karmaşıklığına çözüm olarak EEG tabanlı duygu tanımda ampirik mod ayrıştırma ve örnek entropi kullanan yöntem önermiştir. Bu çalışma için 40 video ile uyarılan 32 kişiden oluşan DEAP[16] veri seti kullanılmıştır. Alınan EEG sinyallerin özelliklerini çıkarma için ampirik mod ayrıştırma ve örnek entropi kullanılmıştır. Ampirik mod ayrıştırma ile elde edilen içsel mod fonksiyonlarının örnek entropileri hesaplanarak özellik vektörleri oluşturulmuş, sınıflandırma için destek vektör makinesi kullanılarak duygu tanıma gerçekleştirilmiştir. Sınıflandırma performansı 10 kat çapraz doğrulama ile hesaplanmış, ortalama doğruluk değeri %94,98 elde edilmiştir. Önerilen sistemde sinyallere ön işleme yapılmamış ayrıca daha fazla özellik çıkarılarak sınıflandırma performansı artırılabilirdi.

Atkinson ve Campos [17] karşılıklı bilgiye dayalı özellik seçme yöntemi ile destek vektör makinesi sınıflandırıcısını birleştirerek yeni bir özellik tabanlı duygu tanıma modeli önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan sinyallere ön işleme için çözünürlük azaltma, elektrookülografi çıkarma ve bant filtresi gerçekleştirilmiş, çıkarılan özelliklerin seçimi için minimum yedeklilik-maksimum alaka düzeyi yöntemi kullanılmıştır. Ardından duygular, değer ve uyarılma olmak üzere radyal temelli işlev çekirdekli destek vektör makinesi kullanılarak sınıflandırılmıştır. Sınıflandırma için değer ve uyarılma doğruluk değeri sırasıyla %62,33, %60,7 elde edilmiştir. Elde edilen sınıflandırma sonucunun düşük olduğu, iyileştirme gerektiği tespit edilmiştir.

Kumar vd.[18] bispektrumun türetilmiş özellikleri ile EEG'den duygu tanıma için yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan sinyallere kaynak ayırma tekniği kullanılarak ön işleme yapılmıştır. Beyin ritimleri teta, alfa ve beta butterworth filtresi kullanılarak gerçekleştirilmiştir. Özellik çıkarmada iki kanallı EEG sinyalleri kullanılmış ve bispektrum hesaplanmıştır. Sınıflandırma için yapay sinir ağları ile birlikte doğrusal ve radyal temelli işlev çekirdeklerine sahip doğrusal çekirdek en küçük kare destek vektör makinesi sınıflandırıcısı kullanılmış, performans 10 kat çapraz doğrulama ile hesaplanmıştır. Değer ve uyarılma sınıflandırması için doğruluk değeri sırasıyla %61,17 ve %64,84 elde edilmiştir. Farklı sınıflandırıcılar ve farklı kanallardan gelen özellikleri birleştirerek daha iyi doğruluk elde edilebilir.

Bhatti vd.[19] farklı müzik türlerinin insan duygularına etkisinin araştırılması için EEG sinyallerinden duygu tanıma ile ilgili çalışma yapmıştır. Bu çalışmada alınan 30 adet müzik dinletilen 15 erkek ve 15 kadın olmak üzere 30 kişiden oluşan veri seti oluşturulmuştur. Alınan sinyale ön işleme için bant geçiş filtresi kullanılmış daha sonra on üç özellik çıkarılmıştır. Zaman alanı ve dalgacık alan özellikleri hesaplanmış, hamming penceresi ve kısa süreli fourier dönüşüm kullanılarak frekans alanı özellikleri çıkarılmıştır. Üç özelliğin birleşmesiyle çıkan özellikler çok katmanlı algılayıcı, destek vektör makinesi ve k-en yakın komşu kullanılarak sınıflandırılmıştır. 10

kat çapraz doğrulama ile performansı hesaplanmış, dört duygu için doğruluk değeri sırasıyla %78,11, %75,62, %72,80 olmak üzere en iyi doğruluk değeri Çok Katmanlı Algılayıcı sınıflandırıcıdan elde edilmiştir. Farklı özellikler çıkararak duygu tanıma için daha iyi sonuç elde edilebilir. Ayrıca duygu durumu arttıkça performansın düşeceği tahmin edilmektedir.

Mehmood ve Lee [4] EEG sinyallerinden duygu tanıma için yeni bir özellik çıkarma yöntemi önermiştir. Bu çalışmada 9 erkek ve 12 kadın olmak üzere IAPS (uluslararası duygusal resim sistemi) [20] veri seti kullanılmıştır. Alınan sinyallere ön bağımsız bileşen analizi ile ön işleme yapılmıştır. Özellik çıkarma için geç pozitif bileşen tabanlı yöntem kullanılmış ardından olaya ilişkin potansiyel analizi yapılmıştır. Çıkarılan özellikler k-en yakın komşu, destek vektör makinesi kullanılarak sınıflandırılmış, sınıflandırma doğruluğu sırasıyla %56,2, %57,9 elde edilmiştir. İyileştirme ile daha fazla özelliğin çıkarılması sağlanarak performans artırılabilir. Önerilen yöntemin performans analizi için farklı veri setinde değerlendirilmelidir.

Bong vd.[21] inme hastalarında, makine öğrenme tekniği kullanarak EEG sinyalleri üzerinden duygu tanıma için çalışma yapmıştır. Bu çalışmada 19 sol, 19 sağ beyin hasar hastası ve 19 normal olmak üzere üç grup için altı duygu uyarılarak veri seti oluşturulmuştur. Bu kişilere uluslararası duygusal resim sistemi [22]ve uluslararası duygusal sayısallaştırılmış sesler [23] veri tabanlarından alınan resim ve videolar izletilmiştir. Sinyal işleme için butterworth bant geçiren filtre kullanılmış ardından dalgacık paket dönüşümü kullanılarak bant yerelleştirilmesi yapılmıştır. Daha sonra yerelleştirilmiş bantlardan özellik çıkarma için Hurst üssü kullanılmıştır. K-en yakın komşu ve olasılıksal sinir ağı kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma doğruluğu için sol beyin hasar grubu için %82,32 elde edilmiş ve en iyi frekans bandının beta olduğu görülmüştür. Önerilen yöntemde daha fazla duygu durumu ile performans değerlendirilmelidir.

Alhagry vd. [24] derin öğrenme ile EEG sinyallerinden duygu tanıma için yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Ham EEG sinyalleri alınmış, her video 12 segmente ayrılmıştır. Uzun kısa süreli bellek yöntemi -tekrarlayan sinir ağı ile özellikler çıkarılmış, çıkarılan özellikler yoğun katman kullanılarak sınıflandırılmıştır. Düşük/yüksek uyarılma, değerlik ve beğenme sınıflandırma doğruluğu sırasıyla %85,65, %85,45 ve %87,99 elde edilmiştir. Önerilen yöntemin farklı sınıflandırıcı yöntemleri ile performansı artırılabilir.

Zheng vd. [25] EEG sinyallerinden duygu tanımda kullanılan yöntemlerin performanslarının değerlendirilmesi için veri seti geliştirilmiştir. Bu çalışmada pozitif, nötr ve negatif olmak üzere üç duygu durumundan oluşan, 15 film klipi ile uyarılan 15 kişiden alınan EEG sinyalleri ile veri seti oluşturulmuştur. Bu çalışma ayrıca DEAP veri seti ile karşılaştırılmıştır. Alınan EEG sinyallere bant geçiren filtre ile ön işleme yapılmış, diferansiyel entropi, güç spektral yoğunluğu, diferansiyel asimetri, rasyonel asimetri, diferansiyel kaudalite, asimetri olmak üzere

altı farklı özellik çıkarılmıştır. Boyut azaltma için kullanılan doğrusal dinamik sistem, temel bileşen analizi ve minimum fazlalık maksimal ilişki algoritmasının performansları karşılaştırılmıştır. Çıkarılan özellikler k-en yakın komşu, destek vektör makinesi ve lojistik regresyon ve grafik düzenlenmiş aşırı öğrenme makinesi ile sınıflandırılmış ve performansları karşılaştırılmıştır. Diferansiyel entropi özelliklerine sahip grafik düzenlenmiş aşırı öğrenme makinesinde doğruluk değeri deap ve yeni veri seti olan seed'de sırasıyla %69,67, %91.07 elde edilmiştir.

Mert ve Akan [26] EEG'den duygu tanıma için zaman-frekans dağılımına dayalı yöntem önemiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Veri tabanından elde edilen sinyallerden sonra kanal seçimi yapılmış, wigner-ville dağılımı ve senkronizasyon dönüşümü kullanılarak özellik vektörleri çıkarılmıştır. Negatif olmayan matris çarpanlara ayırma ve bağımsız bileşen analizi ile iki boyutlu özellikler indirgenmiştir. Ardından özellik seçimi yapılarak özellik vektörleri katılımcıyı dışarıda bırakma çapraz doğrulamaya göre k-en yakın komşu, destek vektör makinesi ve yapay sinir ağı sınıflandırıcılarına uygulanmış, uyarılma ve değerlik duygu durumu sınıflandırılması yapılmıştır. T-test ile hesaplanan yapay sinir ağı sınıflandırıcısının uyarılma ve değerlik doğruluk değeri sırasıyla %82,11, %82.03 olmak üzere, diğer iki sınıflandırıcıya göre daha iyi sonuç elde edilmiştir. Önerilen yöntem farklı kanal seçimi ile daha iyi performans elde edilebilir.

Al Zoubi vd.[27] EEG sinyallerinden duygu tanıma için yeni bir yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan sinyallere ön işleme yapılmış, özellik çıkarma ve tahmin için sıvı hal makinesi (SHM) kullanılmıştır. Sınıflandırma için yapay sinir ağları, radyal temel işlev çekirdekli destek vektör makinesi, k-en yakın komşu, arar ağacı, doğrusal diskriminant analizi sınıflandırıcıları kullanılmış, performansları 10 kat çapraz doğrulama ile hesaplanmıştır. Değerlik, uyarılma ve beğenmenin tahmini için SHM'deki ayırma özelliği kullanılmış, doğruluk değeri sırasıyla %84,63, %88,54 ve %87.03 elde edilmiştir. Önerilen yöntemde 32 kanal kullanılmış fakat daha az kanal ile çalışma yapılarak daha iyi sonuç elde edilebilir.

Kaur vd. [28] EEG sinyallerinden olumlu, olumsuz duyguların analizi için yöntem önermiştir. Bu çalışmada 14 kanal içeren, farklı videolar ile uyarılan 10 kişiden alınan EEG sinyalleriyle veri seti oluşturulmuştur. Alınan ham EEG sinyallerin özelliklerini çıkarma için fraktal boyut yöntemi kullanılmıştır. Radyal temel fonksiyon, doğrusal, polinom çekirdekleri içeren destek vektör makinesi kullanılarak sakinlik, öfke ve mutluluk duygularının sınıflandırması yapılmış, doğruluk değeri radyal temel fonksiyon çekirdeği içeren destek vektör makinesi ile %60 olmak üzere en iyi sonuç elde edilmiştir. Önerilen yöntemin performans ve analizi için büyük ölçekli veri seti ve duygu durumları kullanılarak çalışılması gerekmektedir. Farklı yöntemlerle farklı özellikler çıkararak ve farklı yöntemlerle sınıflandırma performansı artırılabilir.

Chakladar ve Chakraborty [29] EEG sinyallerinden duygu tanıma için gerçekleştirilen çalışmada boyut küçültme için yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmış fakat 13 kanalı ele alınmıştır. EEG verilerine ön işleme yapılmış, kanal seçimi her kanalın özellik sınıfı korelasyon entropi ile gerçekleştirilmiş, iki kanal arası korelasyona dayalı yeni bir uygunluk fonksiyonu uygulanmıştır. En yüksek uygunluk değerine sahip kanal çıktı alt kümesine eklenmiş, alt kümesi oluşturulduktan sonra azaltılmış kanal kümesinden yüksek dereceli istatistik özellikleri çıkarılmıştır. Doğrusal ayırım analizi kullanılarak olumlu, olumsuz, kızgın ve uyum duygularının sınıflandırması yapılmıştır. Karışıklık matrisi ile performansı hesaplanan sınıflandırma için doğruluk değeri %82 elde edilmiştir. Önerilen yöntemin farklı kanal seçimi ve sınıflandırma yöntemleriyle sınıflandırma performansı artırılabilir.

Su vd. [30] ergenlerde çevresel duygu durumları için bağımsız bileşen analiz tabanlı uzamsal özellik çıkarma yöntemi önermiştir. Bu çalışmada 32 kanal içeren, 150 video izleyerek uyarılan 10 kişiden alınan EEG sinyalleri ile veri seti oluşturulmuştur. Alınan sinyallere ön işleme için hamming tabanlı kayan pencere kullanılmıştır. Bağımsız bileşen analizi kullanılarak uzamsal özellikleri çıkarılmıştır. Duyguların sınıflandırılması için destek vektör makinesi kullanılmış, 5 kat çapraz doğrulama ile hesaplanan uyarılma ve değerlik doğruluk değeri sırasıyla %73,35 ve %68,54 elde edilmiştir. Önerilen yöntemde kanal seçimi ve bağımsız bileşen analizi parametreleri ile ayrıca farklı sınıflandırma yöntemleriyle performansı artırılabilir.

Shawky vd. [31] üç boyutlu evrişim ağları ile EEG sinyallerinden uzamsal ve zamansal özelliklerin çıkarılması için yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Veri artırma ile gürültü eklenerek örnek sayısı artırılmış, ardından sinyallerin üç boyutlu giriş gösterimi ve üç boyutlu evrişimli sinir ağlarının eğitimi ve testi gerçekleştirilmiştir. Tek etiketli ve çok etiketli sınıflandırmalar karşılaştırılmış, çok etiketli sınıflandırmanın %93,43 olduğu görülmüştür. Sınıflandırma değerlik ve uyarılma doğruluk değeri sırasıyla %87,44 ve %88,49 elde edilmiştir. Önerilen yöntemde farklı sınıflandırma yöntemleri kullanılarak performansı artırılabilir.

Taran ve Bajaj [32] EEG sinyallerinden duygu tanıma sistemlerinde özellik çıkarma için korelasyon ve anlık frekans tabanlı yöntem önermiştir. Bu çalışmada 24 kanal içeren, 4 duygu durumundan oluşan, ses video ile uyarılan, 20 kişiden alınan EEG sinyalleri ile veri seti oluşturulmuştur. Ham EEG sinyallerine ampirik mod ayrışımı uygulanarak gürültülü içsel mod fonksiyonları çıkarılmış, çıkarılan sinyaller varyasyonel mod ayrıştırması kullanılarak modlara ayrıştırılmıştır. Varyasyonel modların frekans filtrelemesi yapılmış, tüm bu işlemlerden sonra duygu tanıma için doğrusal olmayan çok sınıflı en küçük kareler destek vektör makinesi sınıflandırıcısı ile sınıflandırma yapılmıştır. Sınıflandırma performansları için polinom, radyal temel fonksiyon, meksika şapka ve morlet olmak üzere çekirdek fonksiyonları ile değerlendirilmiş, doğruluk değeri sırasıyla %88,66, %88,78, %86, %90,63 elde edilmiştir. Önerilen yöntemde farklı

sınıflandırma algoritması kullanılarak performans artırılabilir ayrıca, büyük ölçekli veri seti ve daha fazla duygu durumunda uygulanması gerekmektedir.

Pandey ve Seeja [33] varyasyonel mod ayrıştırma ve derin sinir ağı kullanarak EEG sinyallerinden öznenen bağımsız duygu tanıma için bir yöntem önermiştir. Bu çalışmada 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan EEG sinyallere ön işleme yapılmış, EEG verilerinin veri tabanı oluşturulmuş karşılaştırma için DEAP veri tabanı kullanılmıştır. Ampirik mod ayrışımı ve varyasyon mod ayrıştırma kullanılarak özellik çıkarma işlemi gerçekleştirilmiş, en iyi özelliğin varyasyon mod ayrıştırmadan elde edildiği görülmüştür. Sınıflandırma için destek vektör makinası ve derin sinir ağı kullanılmış, uyarılma ve değerlik değeri sırasıyla %61,25, %62,50 olmak üzere derin sinir ağında daha iyi sonuç elde edilmiştir. Önerilen yöntem analiz ve performans için farklı veri setinde uygulanmalı ve farklı yöntemlerle daha iyi özellik çıkararak performansı artırılabilir.

Liang vd. [34] EEG sinyallerinden duygu tanıma için denetimsiz öğrenmeye dayalı yeni bir yöntem önermiştir. Bu çalışmada 32 kanal ve 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan ham EEG sinyallerinin gürültüsünün giderilmesi için ön işleme yapılmış, özellik çıkarma için frekans, zaman ve dalgacık içeren segment ve segment tabanlı özellik vektörlerinin ortalaması alınarak oluşturulan deneme tabanlı yöntem kullanılmıştır. Hipergraf laplacian bölümlenme ile duygu tanıma gerçekleştirilmiştir. Uyarılma, değerlik, hakimiyet ve beğenme değeri sırasıyla %61,02, %52,58, %63,67, %65,62 elde edilmiştir. Yapılan çalışmada denetimsiz öğrenme kullanıldığı için karmaşıklık daha fazladır. Önceki çalışmalarla karşılaştırıldığında iyileştirme yapılarak karmaşıklık giderilebilir ve performansı artırılabilir.

Zangeneh Soroush vd. [35] duygu durumunun tanınması için EEG'nin faz uzayı ve düzlemlerini kullanarak çalışma önermiştir. Bu çalışma için 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan EEG, her kanal için yeniden oluşturulup Açık Uzayı adı verilen durum uzayına dönüştürülmüştür. Geometrik doğrusal olmayan özellikler hesaplanmış, bu özellikler istatistiksel olarak incelenerek duygu tanıma için sınıflandırma adımına geçilmiştir. Sınıflandırma için çok katmanlı algılayıcı ve bayes sınıflandırıcı kullanılmış ardından sınıflandırma doğruluğunun iyileştirilmesi için dempster-shafer teorisi ile birleştirilmiştir. 10 kat çapraz doğrulama ile yüksek uyarılma - yüksek değer, düşük uyarılma - yüksek değer, yüksek uyarılma - düşük değerlik ve düşük uyarılma - düşük değerlik olmak üzere 4 gruba ayrılmıştır. Sınıflandırma doğruluğu %91,37 elde edilmiştir. Önerilen yöntemde veri setinin büyüklüğü artırılabilir aynı zamanda hesaplama süresi karmaşık olduğundan daha hızlı algoritmalarla verimli hale getirilebilir.

Qayyum vd. [36] video izlerken alınan EEG sinyallerine göre kişiselleştirilmiş video özetleme yöntemi önermiştir. Bu çalışmada EEG verilerini elde etmek için 14 kanal içeren, 50 video ile uyarılan 30 erkek 20 kadından alınan EEG sinyalleri ile veri seti oluşturulmuştur. Alınan EEG sinyalleri ön işlemde geçirilip gürültü giderme işlemi yapılmış, zaman, frekans ve dalgacık

özelliklerini hibrit şekilde kullanarak on dokuz özellik çıkarılmıştır. Altı insan duygusunun sınıflandırılması için adaboost, naive bayes ve destek vektör makinesi olmak üzere üç sınıflandırıcı kullanılarak sınıflandırma yapılmıştır. Sınıflandırma doğruluk değeri sırasıyla %88,72, %77,85 ve %92,83 olmak üzere en iyi sonucu destek vektör makinesinden elde edilmiştir. Önerilen yöntemde anlamsal boşlukları azaltarak daha iyi sonuçlar elde edilebilir.

Masruroh vd. [37] temel bileşen analizi ve genelleştirilmiş öğrenme vektör niceleme kullanarak özellik çıkarımını entegre eden algoritma ile EEG sinyallerinden duygu tanıma için çalışma yapmıştır. Bu çalışmada 32 kişiden alınan DEAP veri seti kullanılmış fakat 32 kanaldan 1 kanal kullanılmıştır. Alınan sinyallere, pencereleme ve sinyalin frekansa bağlı olarak bölünmesiyle ön işleme yapılmıştır. Ardından temel bileşeni bulmak için matris oluşturularak veri seçilmiştir. Duygu durumları düşük ve yüksek değerlik olarak sınıflandırılmıştır. Önerilen bu algoritma, destek vektör makinesi ve rastgele orman sınıflandırıcı ile karşılaştırılmış, sınıflandırma doğruluk değeri diğer sınıflandırıcılara göre %62,98 olmak üzere daha iyi sonuç elde edilmiştir.

Lan vd. [38] öznenen bağımsız sınıflandırıcının düşük doğruluğa yol açma problemine çözüm olarak transfer öğrenimi veya alan uyarılama tekniklerini önermiştir. Bu çalışmada 32 kanallı, 32 konudan oluşan DEAP ve 15 kişiden oluşan SEED[14] veri seti kullanılmıştır. DEAP veri setinde değerlik, uyarılma, hakimiyet, beğenme, aşinalık olmak üzere beş duygu; SEED veri setinde olumlu, olumsuz ve nötr olmak üzere üç duygu içermektedir. Alınan EEG sinyali, segmentlere ayrılmış daha sonra özellik çıkarma için diferansiyel entropi kullanılmıştır. Etki alanı uyarılama teknikleri üzerine DEAP ve SEED üzerinde karşılaştırmalı çalışma yapılmış, SEED'in DEAP'ten daha etkili çalıştığı görülmüştür. Ardından çapraz veri kümesi ortamında etki alanı uyarılmasının etkinliği analiz edilmiş, transfer bileşeni analizi ve maksimum bağımsızlık alanı adaptasyonu daha iyi performans göstermiş bu sayede doğruluk değeri sırasıyla %7,25-%13,40 artmıştır. Fakat doğruluk değeri, veri seti eğitimin ve testlerin altında kalmıştır.

Qing vd. [39] makine öğrenimi ve EEG sinyalleri kullanarak yorumlanabilir duygu tanıma modeli önermiştir. Bu çalışmada DEAP ve SEED veri seti kullanılmıştır. Her bir veri setinden alınan EEG sinyallere ön işleme yapılmış ardından özellik çıkarılmıştır. Yumuşak oylama yöntemi ile sınıflandırıcı oluşturulmuş, karar ağacı, k-en yakın komşu ve rastgele orman sınıflandırıcıları seçilmiştir. Etiketleme işlemi için sınıflandırma stratejisi geliştirilmiştir. Sınıflandırma sonuçları elde edildikten sonra korelasyon ve entropi eğrisi alınmış ardından sınıflandırma doğruluğunun iyileştirilmesi için ağırlık katsayıları oluşturulmuştur. Ağırlık katsayısından sonra DEAP ve SEED doğruluk değeri sırasıyla %63,09 ve %75 elde edilmiştir. Önerilen yöntemin önceki ve sonraki sınıflandırma sonucuna göre önemli ölçüde bir fark görülmemiştir.

Alakus vd. [1] yapılan ses video ile uyarılan çalışmalardan farklı olarak bilgisayar oyunlarına dayalı duygu tanıma sistemi için veri seti geliştirmiştir. Oluşturulan veri seti 14 kanallı EEG cihazından alınan, komik, sakin, sıkıcı ve korku duygularından oluşan, 4 farklı bilgisayar oyunu ile

uyarılan 28 kişiden oluşmaktadır. EEG kanallarını frekans zaman analizi için ayırıcık dalgacık dönüşümü uygulanmış, istatistiksel zaman frekans ve kaotik özellikleri çıkarılmıştır. Pozitif-negatif duygu tahmini ve uyarılma-değerlik boyut sınıflandırma için destek vektör makinesi, çok katmanlı algılayıcı sinir ağı ve k-en yakın komşu sınıflandırıcılar kullanılmıştır. Çok katmanlı algılayıcı sinir ağı doğruluk değeri %72,2 elde edilmiş ve diğer sınıflandırıcılara göre daha iyi performans göstermiştir. Geliştirilen veri seti ile MAHNOB HCI ve DEAP veri seti karşılaştırılınca DEAP'de EEG kanalı 32, MAHNOB HCI'da 27, burada 14 olduğu; örnek sayısı DEAP'de 8064, MAHNOB HCI'da 540, burada 38.252 kullanıldığı; EEG verisi DEAP'de 40.960 MAHNOB HCI'da 17.280, burada ise 1568 kullanıldığı ancak EEG verilerinin DEAP'de 32 iken burada 28 kişiden elde edildiği görülmüştür.

Hou vd. [40] on üç kokunun algılanması sırasında duyguların sınıflandırılması ile ilgili yöntem önermiştir. Bu çalışmada veri seti 32 kanallı EEG cihazından alınan, on üç koku ile uyarılan 11 kişiden elde edilmiştir. Elde edilen sinyallere butterworth filtresi ile ön işleme yapılmış ardından önerilen ortalama frekans bant bölme yöntemini kullanarak sinyallerin güç spektral yoğunluğu özellikleri çıkarılmıştır. Destek vektör makinesi, naive bayes, oylama-aşırı öğrenme makinesi, geri yayılım sinir ağları ve k-en yakın komşu sınıflandırıcıları kullanılarak sınıflandırılmış, performans değerlendirmesi için, sınıflandırma doğruluğu, cohen'in kappa, hassas, fl ölçüsü ve geri çağırma kullanılmıştır. Önerilen yöntemin destek vektör makinesi ile sınıflandırma performansı %88,5 olmak üzere daha iyi sonuç elde edilmiştir. Önerilen yöntemin hesaplaması diğer yöntemlere göre basit ve avantajlı olsa da bu yöntem yüksek özellik boyutuna yol açabileceğinden sınıflandırmanın gerçek zamanlı performansının düşebilmesi dezavantajdır.

Zhou vd. [41] çok seviyeli özellikler kılavuzlu kapsül ağı ile çok kanallı EEG tabanlı duygu tanıma için yeni bir yöntem önermiştir. Bu çalışma için DEAP ve DREAMER veri seti kullanılmıştır. Alınan ham EEG sinyallere ön işlem yapılmıştır. Önerilen yöntemde convrelu, kılavuzlu primarycaps ve emotioncaps olmak üzere üç modül ve parametre miktarının azaltılması ve hesaplama hızı için darboğaz katmanı kullanılmıştır. Sınıflandırma performanslarının değerlendirilmesi için DEAP ve DREAMER veri setlerinde değerlik, uyarılma ve baskınlık değerleri 10 kat çapraz doğrulama yöntemi ile değerlendirilmiş, DEAP'de sırasıyla %97,97, %98,31, %98,32; DREAMER'de ise %94,59, %95,26, %95,13 elde edilmiştir. DEAP veri setinde, burada yapılan diğer çalışmalara göre ek olarak baskınlık doğruluk değeri kullanılmıştır. Bu yöntemde katmanlar arası parametreler ağıın karmaşıklığını, çıkarılan çok seviyeli özellikler modelin karmaşıklığını artırmıştır.

Chen vd. [42] LIBSVM sınıflandırıcısına dayalı EEG sinyallerinden duygu tanıma yöntemi önermiştir. Bu çalışmada veri seti 16 kanallı EEG kullanılarak, duygusal etiket içeren 40 video ile uyarılmış 20 kişiden elde edilmiştir. Alınan EEG sinyallere bağımsız bileşen analizi ile ön işleme yapılmıştır. Ön işlem yapılan sinyallerden özellik çıkarma için lempel-ziv karmaşıklığı ve dalgacık

detay katsayısı hesaplanmış, eş entegrasyon ilişki derecesi elde edilmiştir. Sonra sinyallere ampirik mod ayrıştırma gerçekleştirilmiş, içsel mod işlevinin ortalama yaklaşım entropisi hesaplanmıştır. Çıkarılan özellikler çekirdek işlevi gauss kernel işlevi olan lıbsvm yöntemi ile sınıflandırılmış ardından takagi-sugeno bulanık model tabanlı çok kanallı sınıflandırma verileri ile birleştirilerek duygu tanıma sonuçlandırılmıştır. Önerilen yöntem evrişimli sinir ağı, k-en yakın komşu, sıralı kayan ileri seçim, ampirik dalgacık ayrıştırma sınıflandırıcıları ile karşılaştırılmış değerlik ve uyarılma sırasıyla %82,63, %74,88 elde edilmiştir. Önerilen yöntemin analizi ve performans tespiti için veri seti ve duygu durumunun artırılması gerekmektedir.

Hassouneh vd. [3] derin sinir ağı ve makine öğrenme yöntemleri ile yüz ifadelerini ve EEG sinyallerini kullanarak duygu tanıma için yöntem önermiştir. Bu çalışmada 14 kanallı EEG kullanarak altı duygudan oluşan, video ile uyarılmış 19 kişiden alınan EEG sinyalleriyle veri seti oluşturulmuştur. Önerilen model üç uzun kısa süreli bellek, gömme ve yoğun katmandan oluşmaktadır ve burada özellikler çıkarılmıştır. Özellikler beş kat çapraz doğrulama ile evrişimli sinir ağı ve uzun kısa süreli bellek sınıflandırıcılarına verilmiş, duyguların doğruluk, duyarlılık, özgüllük, f puanı, hassasiyet performansları hesaplanmıştır. Yüzdeki işaretlerin sınıflandırma doğruluğu evrişimli sinir ağı ile %99,81, EEG sinyallerinin sınıflandırma doğruluğu uzun kısa süreli bellek ile %87,25 elde edilmiştir. Önerilen modelde daha fazla veri toplanarak doğruluk değeri iyileştirilebilir.

Garg ve Verma [43] dalgacık tabanlı derin öğrenme ile çok kanallı EEG sinyalinin frekans ve uzamsal özelliklerini de içeren duygu tanıma önermiştir. Bu çalışmada üç boyutlu değerlik, uyarılma ve baskınlık içeren 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti ve evrişimli sinir ağının googlenet mimarisi kullanılmıştır. Çok modlu verilerde dalgacık dönüşümü kullanılarak zaman frekans özellikler çıkarılmıştır. Destek vektör makinesi, k-en yakın komşu ve çok katmanlı algılayıcı ile sınıflandırma gerçekleştirilmiş iki boyutlu uzaylarda iki sınıf için değerlik ve uyarılma doğruluk değeri sırasıyla %92,19, %61,23 elde edilmiştir. Ancak önerilen modelde iki sınıf için iyi performans gösterse de sınıf sayısı arttıkça performans düşmektedir.

Wei vd. [44] derin öğrenme kullanarak EEG tabanlı pozitif, negatif ve nötr olmak üzere üç duygu tanıma sistemi önermiştir. Bu çalışma için 15 kişiden oluşan SEED veri seti kullanılmıştır. Alınan sinyallere filtreleme ile ön işleme yapılmış, çift ağaçlı karmaşık dalgacık dönüşümü kullanarak alt bantlara ayrılmıştır. Zaman, frekans ve doğrusal olmayan analizlerden dört özellik çıkarılmıştır. Basit yinelenen birimler dönüşen ortalama mutlak değer, güç spektral yoğunluk, fraktal boyut, diferansiyel entropi özellikler üzerinde eğitilmiştir. Sınıflandırma performansının yüksek olması üç topluluk stratejisi kullanılmıştır. Doğruluk, karışıklık matrisi, hassasiyet, geri çağırma, f puanı, zaman performansları hesaplanmış, basit tekrarlayan birimler modeli diferansiyel entropi özelliği ile %80.02 doğruluk ile en iyi performans elde edilmiştir. Önerilen modelin

dezavantajı konuya özel olduğu için tüm konularda kullanılmaması ve derin öğrenme kullanıldığı için eğitime fazla zaman harcanmasıdır.

Wang vd. [45] evrişimli sinir ağı ve EEG tabanlı duygu tanıma için kısa süreli fourier dönüşümü ile yeni bir elektrot-frekans dağılım haritalarını önermiştir. Bu çalışma için SEED ve DEAP veri seti kullanılmıştır. Alınan sinyallere ön işleme yapılmıştır. Elektrot-frekans dağılım haritaları ile özellik çıkarılmış ve duygu sınıflandırılması için derin evrişimli sinir ağına dayalı blok tasarlamıştır. SEED veri setinde sınıflandırma doğruluğu %90,59 elde edilmiştir. Çapraz veri kümesi sınıflandırmasını gerçekleştirmek için evrişimli sinir ağı, derin model aktarımı öğrenme yöntemi ile DEAP veri setine uygulanmıştır. Kısa süreli fourier dönüşümü algoritması ile oluşturulan özellik vektörlerinin boyutlarını azaltmak için temel bileşen analizi kullanılmıştır. EEG elektrotlarının ve frekans bantlarının otomatik elde etmesi için grad-cam kullanılmıştır. Önerilen yöntemde daha gelişmiş yöntemler kullanılarak yüksek performans elde edilebilir.

Moon vd. [46] evrişimli sinir ağı ile bağlantı özellikleri birlikte kullanılarak EEG sinyallerinden duygu tanıma için yeni bir sınıflandırma sistemi önermiştir. Bu çalışma için 32 kanal içeren, 32 kişiden oluşan DEAP veri seti kullanılmıştır. Ham EEG sinyallerinden pearson korelasyon katsayısı, faz kilitleme değeri ve transfer entropisi olmak üzere üç farklı beyin bağlantı ölçüleri hesaplanarak bağlantı matrisi belirli sıraya göre oluşturulmuştur. Ardından duygusal videoların sınıflandırılması için evrişimli sinir ağı kullanılmıştır. Önerilen yöntemin sınıflandırma doğrulukları güç spektral yoğunlukları ile evrişimli sinir ağı, k-en yakın komşu, rastgele orman, sinir ağı ile karşılaştırılmış en iyi sınıflandırma sonucu %87,36 elde edilmiştir. Benzer duygu durumlarının yanlış sınıflandırıldığı gözlemlenmiştir. Ayrıca çekirdek boyutunun artırılarak sınıflandırma doğruluğunda eğitilecek parametre sayısının yükünden dolayı fazla artış gözlemlenmemiştir.

Yin vd. [47] EEG sinyallerinden duygu tanıma için bireyden bağımsız bir yeni yerel olarak sağlam özellik seçim yöntemi önermiştir. Bu çalışmada yöntemin doğrulanması için 40 video ile uyarılan 32 kişiden oluşan DEAP ve 20 film klipi ile uyarılmış 27 kişiden oluşan MAHNOB-HCI veri seti kullanılmıştır. EEG sinyallere bandpass filtre, bağımsız bileşen analizi ile ön işleme yapılmış, EEG segmentlere ayrılarak özellik çıkarılmıştır. Çıkarılan zaman frekans özellikleri yerel olarak sağlam özellik seçimi yöntemi ile sağlam özellik elde edilmiştir. Her özellik için bireyler arası tutarlılığı hesaplanmış ardından sağlam özellik seçilip, seçilen özellikleri birleştirmek için topluluk oluşturulup, sınıflandırma gerçekleştirilmiştir. En küçük kare destek vektör makinesi ve saf bayes ile sınıflandırılmış uyarılma ve değerlik doğruluğu sırasıyla %65-%67, %68-%70 elde edilmiştir. Önerilen yöntem bireye özgü sınıflandırma konusunda geride kalmıştır.

Maheshwari vd. [48] ritme özgü çok kanallı evrişimli sinir ağı ile çok kanallı EEG sinyallerinden duygu sınıflandırması için yöntem önermiştir. Bu çalışmada EEG sinyal için 32 kişiden oluşan DEAP, 23 kişiden oluşan DREAMER ve altı uyarana maruz bırakılan 23 kişiden

oluşan DASPS veri seti kullanılmıştır. Alınan çok kanallı EEG sinyalleri örtüşen pencere ile segmentlere ayrılarak ön işleme gerçekleştirilmiştir. Ritim çıkarılması ardından ritim seçimi için filtre kullanılmıştır. Çıkarılan ritimler derin evrişimli sinir ağı sınıflandırıcısı ile düşük değerlik, yüksek değerlik; düşük uyarılma, yüksek uyarılma; düşük baskınlık, yüksek baskınlık olarak sınıflandırılmıştır. DEAP ve DREAMER için düşük değerlik ve yüksek değerlik, düşük uyarılma ve yüksek uyarılma doğruluk değeri 10 kat çapraz doğrulama ile sırasıyla %98,91, %98,76; %98,70, %98,82 elde edilmiştir. Önerilen yöntemde, konudan bağımsız çapraz doğrulama kullanarak daha düşük doğruluk elde ettiği ve doğruluk analizi için daha büyük veri setlerinde uygulanması gerektiği görülmüştür.

Salankar vd. [49] ampirik mod ayrıştırma ve ikinci dereceden fark grafiği kullanarak EEG sinyallerinden duygu tanıma için sınıflandırma yöntemi önermiştir. Bu çalışmada 32 kanal içeren, 40 video ile uyarılmış 32 kişiden oluşan DEAP veri seti kullanılmıştır. Ampirik mod ayrıştırma ile EEG sinyallerinin özellikleri çıkarılmıştır. İçsel mod işlevlerinin ikinci dereceden fark grafiğinden eliptik bölge alanı, merkezi eğilim ölçüsü ve ortalama özellikleri çıkarılmıştır. Sınıflandırma için çok katmanlı algılayıcı ve destek vektör makinesi kullanılmış, çok katmanlı algılayıcı ile sınıflandırmada en iyi doğruluk üzere uyarılma, uyarılma-değerlik, öfke ve sevinç doğruluk değeri sırasıyla %100, %100, %93,8 elde edilmiştir. Önerilen yöntemin performans tespiti için daha büyük veri seti ve duygu durumlarında test edilmesi gerekmektedir.

Topic ve Russo [50] derin öğrenme ile EEG sinyalinden topografik ve holografik özellik haritalarının oluşturulması için yeni bir duygu tanıma modeli önermiştir. Bu çalışmada 32 kanal içeren 40 video ile uyarılmış 32 kişiden oluşan DEAP; 62 kanal içeren, 10 video ile uyarılmış 15 kişiden oluşan SEED; 14 kanal içeren 18 video ile uyarılmış 23 kişiden oluşan DREAMER ve 14 kanal içeren 16 video ile uyarılmış 40 kişiden oluşan AMIGOS veri seti kullanılmıştır. Alınan EEG sinyallerinden topografik ve holografik olmak üzere iki yöntemle özellik haritaları oluşturulmuştur. Evrişim, doğrultulmuş doğrusal birim, maksimum havuz, evrişim, doğrultulmuş doğrusal birim ve tamamen bağlı derin öğrenme ile özellik çıkarılmış daha sonra destek vektör makinesi ile sınıflandırma yapılmıştır. 10 kat çapraz doğrulama kullanılarak performansı hesaplanmış en iyi doğruluk değeri AMIGOS veri setinde holografik özelliği ile %90,54, en kötü ise SEED veri setinde topografik özelliği ile %70,37 elde edilmiştir. Önerilen modelin dezavantajı duyguları gerçek zamanlı olarak tanınamamasıdır.

Huang vd. [51] EEG sinyalinden duygu tanıma için yeni bir iki yarım küre tutarsızlık evrişimli sinir ağı önermiştir. Bu çalışmada DEAP veri setinden gelen verileri kullanarak uyarıldığındaki EEG değişimi elde edilmiştir. Uluslararası 10-20 Sistemine göre üç özellik matrisi oluşturularak özellik çıkarılmıştır. Üç evrişimli sinir ağı katmanı kullanılarak uzamsal ve zamansal özellikler çıkarılmıştır. Özellikler çıkarıldıktan sonra iki yarım küre tutarsızlık evrişimli sinir ağı ile model çıkarma ve sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntem 10 kat çapraz

doğrulama kullanılarak performansı hesaplanmış, özneye bağlı deneyde uyarılma ve değerlik doğruluk değeri sırasıyla %94,72 ve %94,38 fakat öznenen bağımsız deneyde daha düşük performans ile %63,94 ve %68,14 elde edilmiştir. Önerilen yöntemin performans tespiti için daha büyük veri seti ile uygulanması gerekmektedir.

Yin vd. [52] EEG'nin diferansiyel entropisine dayalı derin öğrenme tabanlı yeni bir duygu tanıma yöntemi önermiştir. Bu çalışma için 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Alınan EEG verileri kalibre edildikten sonra segmentlere ayrılmış ardından diferansiyel entropi ile özellik çıkarılmış, özellik küpü oluşturulmuştur. Özellik küpü, duygu tanıma için ECLGCNN adı verilen grafik evrişimli sinir ağı, uzun-kısa süreli bellek sinir ağı ve yoğun katman ile birleştirilmiş ve duygu sınıflandırılmıştır. Önerilen yöntemin performansı 3 kez 5-kat çapraz ile hesaplanmış, destek vektörü sınıflandırması, karar ağacı ve rastgele orman sınıflandırıcıları ile karşılaştırılmıştır. Önerilen yöntemin ikili sınıflandırma doğruluğu diğer yöntemlere göre daha yüksek olduğu tespit edilmiştir. Bu yöntemde hesaplamaların karmaşık olduğu; ikili sınıflandırma kullanıldığı fakat çok sınıflandırma için performansı bilinmediği tespit edilmiştir.

Naser ve Saha [53] müzik beğenisinin EEG tabanlı duygu tanımaya etkisini araştırmak için bir çalışma yapmıştır. Bu çalışma için 40 video ile uyarılan 32 kişiden oluşan DEAP veri seti kullanılmıştır. Güç spektral yoğunluğu, çift ağaçlı karmaşık dalgacık paket dönüşümü, ikili fonksiyonel bağlantı, elektrot çiftleri arasındaki yanallık indeksi, beyin ağlarının topolojik özellikleri ile özellikler çıkarılmıştır. Özellik seçimi için bilgi teorisine dayalı bir özellik seçim yöntemi kullanılmıştır. Veriler üzerinde çapraz doğrulama ile üç farklı müzik beğenisi uyarılma, değerlik ve baskınlık değerlerinden yüksek / düşük sınıflandırma yapılmıştır. Önerilen yöntemin sınıflandırılması için farklı yöntemler seçilerek performansı artırılabilir.

Cheng vd. [54] derin orman kullanarak çok kanallı EEG sinyallerinden duygu tanıma için yöntem önermiştir. Bu çalışmada DEAP ve DREAMER veri seti kullanılmıştır. Alınan ham EEG verileri örtüşmeyen pencere kullanılarak segmentlere ayrılmış, ayrılan segmentler için iki boyutlu zaman çerçevesi oluşturulmuştur. Ayrılan sinyalin her segmenti tüm segmentin etiketi ile aynı etiketlenmiştir. EEG verilerinden uzamsal bilgilerin çıkarılması için tarama modülü ve tarama çıktısının ikili sınıflandırılması için kademeli orman kullanılmıştır. Önerilen yöntem DEAP ve DREAMER veri seti için 10 kat çapraz doğrulama kullanılarak performansı hesaplanmış, yedi makine öğrenme yöntemleriyle karşılaştırılmıştır. DEAP için değerlik ve uyarılma doğruluğu sırasıyla %97,69 ve %97,53; DREAMER için, ortalama değerlik, uyarılma ve baskınlık sırasıyla %89,03, %90,41 ve %89,89 elde edilmiştir. Küçük veri setinde yüksek performans elde eden bu yöntem büyük veri setinde değerlendirilmeli, özneye bağlı bu sınıflandırma yöntemi öznenen bağımsız sınıflandırma için kullanılmamıştır.

Tuncer vd. [55] firat fraktal adı verilen yeni bir desen ile özellik çıkararak EEG tabanlı duygu tanıma için yöntem önermiştir. Bu çalışmada GAMEEMO veri seti kullanılmıştır. Alınan EEG sinyali ayarlanabilir q dalgacık dönüşümü uygulayarak alt bantlara ayrılmış, her EEG sinyali ve alt bantlara uygulanan ffd yöntemi ile çıkan özellikler birleştirilmiştir. Ki-kare seçici ile özellik seçimi yapılmış, özellikler doğrusal ayırıcı, k-en yakın komşu, destek vektör makinesi sınıflandırıcıları ile sınıflandırılmış, doğruluk değeri sırasıyla %87,23, %98,32, %98,94 elde edilmiştir. Önerilen yöntemin analizi ve performans tespiti için büyük ölçekli veri setlerinde uygulanmalıdır. Önerilen yöntemde alınan EEG sinyallerinde gürültü giderme işlemi yapılmamıştır.

Subasi vd. [56] ayarlanabilir q dalgacık dönüşümü ve rotasyon orman topluluğu sınıflandırıcısını kullanarak EEG tabanlı duygu tanıma için yöntem önermiştir. Bu çalışmada SEED veri kümesi kullanılmıştır. Alınan EEG sinyaller segmentlere ayrılmış, gürültü gidermek için çok ölçekli bir temel bileşen analizi kullanılmıştır. Ardından sinyaller ayarlanabilir q dalgacık dönüşümü ile özellikler çıkarılmıştır. Gereksiz özelliklerin giderilmesi için boyut küçültme uygulanmıştır. Sınıflandırma için rotasyon orman topluluğu, sekiz sınıflandırıcı ile birlikte kullanılmış kappa, roc alanı ve f ölçümü ile performansları değerlendirilmiştir. Rotasyon orman topluluğu ve destek vektör makinesi ile birlikte kullanıldığında doğruluk değeri %93,1 elde edilmiştir. Önerilen yöntemin performans ve analiz tespiti için daha büyük veri seti ve duygu durumlarında kullanılması gerekmektedir.

2. EEG TABANLI DUYGU TANIMA

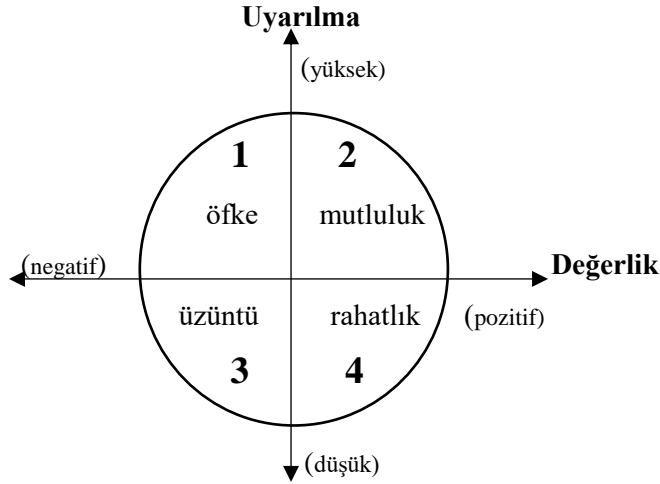
Bu bölümde EEG tabanlı duygu tanıma için duygu modelleri, elektroensefalografi sinyalleri ve bu sinyallerden duygu analizi yapabilmek için duygu tanıma süreci ele alınmıştır.

2.1. Duygu Modelleri

Duygu modelleri, ayrık ve kategorik olmak üzere ikiye ayrılmaktadır [57]. Ayrık model mutluluk, korku, öfke, üzüntü, şaşkınlık, tiksinti olmak üzere altı temel duygusal durumdan meydana gelen pozitif ve negatif duygudan oluşmaktadır [58]. Kategorik, ayrık modeldeki gibi duygular isimleri ile ifade edilmeyip, uyarılma ve değerlik düzlemindeki konumlarıyla ifade edilmektedir [59].

Bilişsel olarak boyutsal modelde duygular, uyarılma ve değerlik düzleminde iki boyutlu veya uyarılma, değerlik ve baskınlık düzleminde üç boyutlu modelde gösterilir. İki boyutlu duygusal model Şekil 2.1'deki gibidir. Değerlik eksenini pozitif ve negatif duyguların derecesini, uyarılma ise duyguların yüksek veya düşük olduğunu ifade etmektedir.

Şekil 2.1'e göre, 1. alan yüksek uyarılma negatif değerlik olmak üzere öfke duygularını, 2. alan yüksek uyarılma pozitif değerlik olmak üzere mutluluk duygularını, 3. alan düşük uyarılma negatif değerlik olmak üzere üzüntü duygularını ve 4. alan ise düşük uyarılma pozitif değerlik olmak üzere rahatlık duygularını içermektedir.




Şekil 2.1. Değerlik-uyarılma duygu modeli

2.2. Elektroensefalografi

EEG, insan beynindeki aktivitesini izleme ve kaydetme sürecidir. Bu süreç saç derisinde belirli noktaları çevreleyecek şekilde ekipmanlar aracılığı ile kaydedilmektedir. Literatüre


bakıldığında EEG, duygu tanıma ile ilgili çalışmalarda sıklıkla uygulanmaktadır. İnsanların duygusal durumlarını belirlemede yardımcı olan EEG sinyalleri frekans bantlarına göre alfa, beta, delta, teta ve gama olmak üzere Şekil 2.2 gibi beş gruba ayrılmaktadır. Alfa 8-13 Hz, beta 13-30 Hz, delta 0.5-4 Hz, teta 4-8 Hz ve gama 30 Hz'den büyük frekansa sahiptir. Her frekans bantların EEG sinyalleri insan beyninin duygusal durumunu tanımlamak için kullanılabilir [60].



Şekil 2.2. Frekans bantlarına EEG sinyalleri

2.3. EEG Tabanlı Duygu Tanıma Süreci

EEG tabanlı duygu tanıma katılımcı seçimi, uyaran seçimi, EEG sinyallerinin elde edilmesi, elde edilen sinyallere ön işleme yapılması, sinyallerden özellik çıkarma ve çıkarılan özelliklere göre duyguların sınıflandırılması olmak üzere Şekil 2.3'te gösterildiği gibi altı süreçten oluşmaktadır. Yapılan çalışmalara bakıldığında Zheng vd.[61], Dadebayev vd.[62], Javaid vd.[63], duygu tanıma sürecini 6 aşamada göstermiştir.



Şekil 2.3. EEG tabanlı duygu tanıma süreci

2.3.1. Katılımcı Seçimi

EEG tabanlı duygu tanıma çalışmalarında ilk aşama deneye katılacak deneklerin seçilmesidir. Katılımcılar kendi rızası ile ilgili çalışmalara göre seçilir. Örneğin duygularını

göstermekte zorlanan otizm, parkinson gibi hastalar, hastalıklarının tanınması ve gerekli aksiyonların alınması için seçilirler.

Cinsiyet ve yaş faktörü duygu tanıma çalışmalarında katılımcı seçerken büyük öneme sahiptir. Çünkü kadınlar duygularını erkeklerden daha yüksek duygu durumu ile ifade etmektedir. Örneğin mutluluk, üzüntü, kaygı, korku gibi duygu durumları kadınlarda daha yüksek düzeyde ifade edilmektedir [64]. Dahası orta ve ileri yaşlardaki kadınlarda duygu tanınmanın daha doğru sonuç verdiği [65] gözlemlenmiştir.

2.3.2. Uyarılar

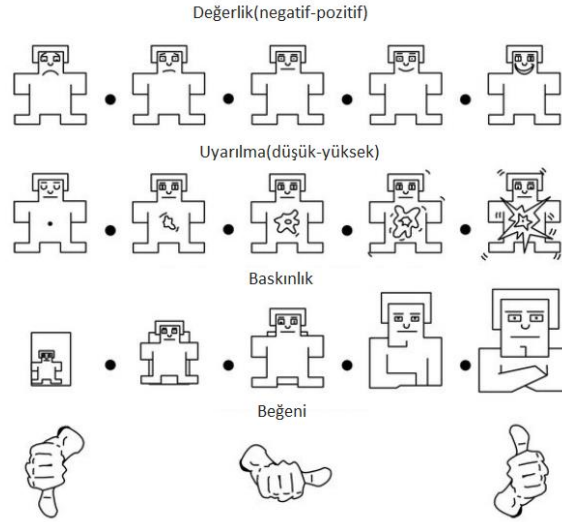
Duygu tanımada görsel, işitsel ve görsel-işitsel olmak üzere üç tür uyaran bulunmaktadır. Görsel uyarılar resim veya görüntülerden oluşmaktadır. En iyi görsel uyaran veri kümesi halka açık olan Uluslararası Duygusal Resim Sistemi [22]'dir. Uluslararası Duygusal Resim Sistemi, uyarılma, değerlik ve baskınlık seviyeleri ile etiketlenen çok fazla görüntüden oluşmaktadır[66]. Bu uyaran ile deneye katılmış kişilerde görselliği etkileyerek duyguların çıkarılması sağlanır. İşitsel uyarılar ses veya müzikten oluşmaktadır. En popüler işitsel uyaran veri kümesi halka açık olan Uluslararası Duygusal Dijitalleştirilmiş Sesler [23]'dir. Uluslararası Duygusal Resim Sistemi ve Uluslararası Duygusal Dijitalleştirilmiş Sesler olan bu veri kümeleri Florida Üniversitesi Ulusal Akıl Sağlığı Duygu ve Dikkat Merkezi tarafından geliştirilmiştir. Görsel-işitsel uyarılar ses ve görüntüyü içeren müzik klipleri, video, film, bilgisayar oyunundan oluşmaktadır. Sadece görsel veya işitsel uyarılar duygu tanımada etkili olmadığı için görsel-işitsel uyarılar ile duyguları daha kolay tanıyabiliriz. Bu yüzden görsel-işitsel uyarılarla duygu tanıma ile ilgili birçok çalışma mevcuttur.

Uyarıların Değerlendirilmesi

Uyarılar ile elde edilen EEG sinyallerinin doğruluğunu test etmek için öz değerlendirme formu kullanılmaktadır. 1-9 arasında değer alan, değerlik, uyarılma, beğeni ve baskınlık olmak üzere dört duygu durumundan meydana gelen örnek öz değerlendirme formu Şekil 2.4'te gösterilmiştir.

Değerlik

Memnuniyet durumunu ölçen bu değer 5'ten küçük ise mutsuz, büyükse mutlu olarak değerlendirilmektedir.



Şekil 2.4. Duygu durumları için öz değerlendirme formu [94]

Uyarılma

Fizyolojik durumunu belirleyen bu değer, düşük veya yüksek olarak sınıflandırılmaktadır. Bu değer 5'ten küçük olduğunda sakin, 5 ve büyük olduğunda heyecan olarak değerlendirilmektedir.

Beğeni


Bu parametre beğenilip beğenilmediğini ifade etmektedir. Beğenilmemişse sol taraftaki, kararsızsa ortadaki, beğenilmişse sağ taraftaki durum seçilmektedir.

Baskınlık

Bu parametre duygunun baskınlığını ifade etmektedir. Bu değer 5'ten küçükse duyguya hâkim olmadığı, 5 ve büyükse duyguya hâkim olduğunu göstermektedir.

2.3.3. EEG Sinyallerinin Elde Edilmesi

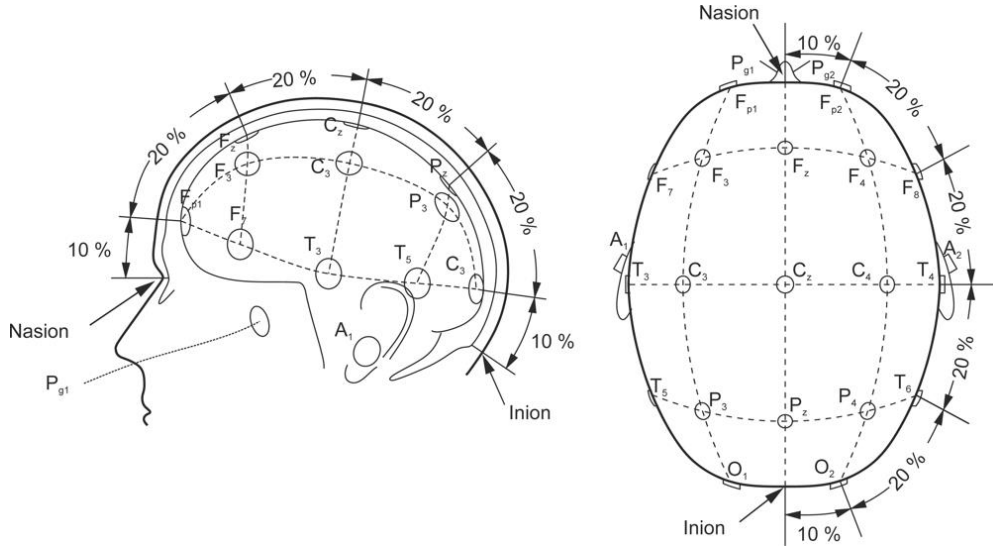
EEG sinyallerinin elde edilmesinde yaygın olarak kullanılan ekipmanlar Emotiv EPOC, Biosemi Active Two, OpenBCI, Neurosky gibidir ve Şekil 2.5'te gösterilmiştir. EEG sinyaller iki yöntemle toplanabilmektedir. Bunlar elektrotun beyin kortekse girerek alınmasıyla elde edilen ve yüksek sinyal içeren invaziv yöntem ve elektrotun kafa derisine yerleştirilerek elde edilen beyin bilgisayar ara yüzünü kullanan non-invaziv yöntemdir. İnvaziv yöntemin non-invaziv yöntemine göre kullanımı daha zordur. Bu yüzden duygu tanıma çalışmalarında non-invaziv yöntemler kullanılmaktadır.



Şekil 2.5. EEG sinyallerini elde etmede kullanılan ekipmanlar (a) Emotiv EPOC ekipmanı [67] (b) Biosemi Active Two ekipmanı [68] (c) OpenBCI ekipmanı [69] (d) Neurosky ekipmanı [70]

İnsan beyninin en üst tabakası olan serebral korteks frontal, oksipital, temporal, pariyetal olmak üzere dört kısma ayrılmaktadır. frontal adı verilen ön lob, bilişsel duygu ve düşünceden sorumludur. Oksipatal lob görsel duyuların işlenmesinden, Temporal lob işitsel ve koku duyuların işlenmesinden sorumludur. Pariyetal, duylardan gelen bilgileri algılamaya ve dokunma hissine tepki veren bu lob aynı zamanda dengeden de sorumludur[71].

Uyaran seçiminden sonraki aşama EEG sinyallerinin elde edilmesidir. Bu sinyaller EEG toplama ekipmanı ve elektrotlar yardımı ile elde edilir. Elektrotların sayısı 6 ile 62 arasında değişmektedir. Genel olarak elektrotlar 10-20 sistemine göre yerleştirilmektedir. Her elektrot belirli bir etiketlemeyle adlandırılmaktadır. Şekil 2.6'daki gibi harf ve sayıdan oluşan bu etiketler elektrotun yerleştirildiği alana bağlıdır. Fp frontal kutup, F frontal, O oksipital, C merkez, T zaman, P pariyetal olmak üzere elektrotların 10-20 sistemine göre yerleştirilmesi Şekil 2.6 gibidir. Sağ tarafta bulunan elektrotlar çift, sol tarafta bulunan elektrotlar tek sayı olarak verilmiştir.




Şekil 2.6. Elektrotların 10-20 sistemine göre yerleştirilmesi

Elektrotların 10-10 sistemine göre yerleştirilmiş hali Şekil 2.7'deki gibidir. Bitişik elektrotların birbirleriyle olan mesafeleri %10 veya %20 olacak şekilde ayarlanması 10-10 ve 10-20 sistemini belirtmektedir[72].

10-20 sisteminde olduğu gibi burada da her elektrot bir veya iki harf ve sayıdan oluşan etiketlemeyle adlandırılmaktadır. EEG deneylerinin çoğunda olduğu gibi yaygın olarak kullanılan elektrotlar F3, F4, FP1, FP2, AF3, AF4, F7, F8, FC5, FC6, O1, O2, T7, T8, P7, P8'dir.

Nawaz vd.[63], Liu vd.[73] Chen vd.[42] EEG sinyallerini elde etmek için Emotiv EPOC ekipmanı ve AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 ve AF4 olmak üzere 14 elektrot kullanmıştır. Alakus vd. [1] diğerlerinden farklı olarak 2048 Hz olan Emotiv EPOC ekipmanı AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4, P3 ve P4 olmak üzere 16 elektrot kullanmıştır. Liv vd. [74] farklı bir ekipman olmak zere Neuroscan Quik-Cap ve uluslararası 10-20 sistemini kullanmıştır.



Şekil 2.7. Elektrotların 10-10 sistemine göre yerleştirilmesi

2.3.4. EEG Veri Setleri

DEAP[16], SEED[14], DREAMER[75], MAHNOB-HCI[76], GAMEEMO[1] gibi halka açık EEG veri setleri vardır. Bu veri setlerinin karşılaştırılması için kıyaslama yapılmaktadır. Veri büyüklüğü gelişmiş sinir ağı modelleriyle uğraşırken aynı zamanda performansını da engelleyebilmektedir. Bu yüzden kendi veri setlerini oluşturarak analiz yapan birçok çalışma mevcuttur. Duygu tanıma çalışmalarında yaygın olarak kullanılan veri setleri ve özellikleri aşağıdaki gibidir.

DEAP Veri Seti

Keolstra vd. [16] 32 kanal içeren EEG cihazı ile 19 ile 37 yaş aralığında 16 kadın ve 16 erkek olmak üzere 32 kişiden alınan sinyallerle veri seti oluşturmuştur. 40 video ile uyarılan bu kişiler her videoyu uyarılma, değerlik, beğenme, aşinalık ve baskınlık durumlarında değerlendirmiştir. DEAP veri setinin özellikleri Tablo 2.1’de verilmiştir.

Tablo 2.1. DEAP veri seti özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz ve kanalı	Biosemi ActiveTwo 32 kanal
Örnekleme oranı	512 Hz-128 Hz
Toplam örnek sayısı	8064
Uyarılma	Müzik videoları
Video sayısı	40
Deney sayısı	1
Duygusal durum	Uyarılma Değerlik Beğenme Aşinalık Baskınlık
Kişi sayısı	32
Yaş aralığı	19 ile 37
Kayıt süresi	1 dakika

SEED Veri Seti

Zheng vd. [14] 62 kanal içeren EEG cihazı ile yaş ortalaması 23.27 olan 15 kişiden alınan sinyallerle veri seti oluşturmuştur. 3 denemede ile gerçekleştirilen bu deneyde 10 çin filmi ile uyarılan bu kişiler videoları, pozitif, negatif ve nötr duygu durumlarında değerlendirmiştir. SEED veri setinin özellikleri Tablo 2.2’de verilmiştir.

Tablo 2.2. SEED veri seti özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz ve kanalı	ESI NeuroScan 62 kanal
Örnekleme oranı	1000 Hz- 200 Hz
Uyarılma	Çin filmlerinden alıntılar
Video sayısı	10
Deney sayısı	3
Duygusal durum	Pozitif Nötr Negatif
Kişi sayısı	15
Yaş ortalaması	23.27
Kayıt süresi	4 dakika

DREAMER Veri Seti

Katsigiannis vd. [75] 14 kanal içeren Emotiv Epoc+ cihazı ile yaş ortalaması 26.6 olan 23 kişiden alınan sinyallerle veri seti oluşturmuştur. Ses video ile uyarılan kişiler bu deneyde videoları uyarılma, değerlik ve baskınlık duygu durumlarında değerlendirmiştir. DREAMER veri setinin özellikleri Tablo 2.3'te verilmiştir.

Tablo 2.3. DREAMER veri seti özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz ve kanalı	EMOTİV EPOC+ 14 kanal
Örnekleme oranı	128 Hz
Uyarılma	Ses-video
Video sayısı	18
Deney sayısı	1
Duygusal durum	Uyarılma Değerlik Baskınlık
Kişi sayısı	23
Yaş ortalaması	26.6
Kayıt süresi	1 dakika

MAHNOB-HCI Veri Seti

Soleymani vd. [76] 32 kanal içeren cihaz ile 27 kişiden alınan sinyallerle veri seti oluşturmuştur. 18 film klipi ile uyarılan bu kişiler filmleri, duygusal anahtar kelime, uyarılma, değerlik, baskınlık ve öngörülebilirlik duygu durumlarında değerlendirmiştir. MAHNOB-HCI veri setinin özellikleri Tablo 2.4'te verilmiştir.

Tablo 2.4. MAHNOB-HCI veri seti özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz ve kanalı	32 kanal
Örnekleme oranı	256 Hz
Toplam örnek sayısı	540
Uyarılma	Film klipi
Video sayısı	18
Deney sayısı	20
Duygusal durum	Duygusal anahtar kelime Uyarılma Değerlik Baskınlık Öngörülebilirlik
Kişi sayısı	27

GAMEEMO Veri Seti

Alakus vd. [1] 14 kanal içeren Emotiv EPOC+ cihazı ile 16 farklı kafa derisi bölgesine elektrotlar yerleştirilerek 20 ile 27 yaşları arasında 28 kişiden alınan sinyallerle veri seti oluşturmuştur. Diğer veri setlerinden farklı olarak uyarılma türü olarak oyun seçilmiştir. Her bir oyun 5 dakika olmak üzere 4 oyun için toplam 20 dakika oyun oynayan bu kişiler, oyunları korku, sıkıcı, komik ve sakin olmak üzere dört duygu durumu için değerlendirilmiştir. GAMEEMO veri setinin özellikleri Tablo 2.5'te verilmiştir.

Tablo 2.5. GAMEEMO veri seti özellikleri

Özellik	Değer
Sinyal türü	EEG
Cihaz ve kanalı	EMOTİV EPOC+ 14 kanal
EEG elektrotları	16 farklı kafa derisi bölgesi
Sinyallerin bant genişliği	0.16Hz-43Hz.
Örnekleme oranı	2048 Hz

Tablo 2.5. (Devamı)

Özellik	Değer
Toplam örnek sayısı	38252
Uyarılma	Oyun türü
Duygusal durum	Komik Sıkıcı Korku Sakin
Kişi sayısı	28
Yaş aralığı	20 ile 27
Kayıt süresi	5*4=20 dakika

2.3.5. Ön İşleme

EEG tabanlı duygu tanımada en önemli aşama sinyallere ön işleme yapılmasıdır. Buradaki amaç duygusal verilerle ilgili olmayan bilgileri örneğin göz kırpması ve kas hareketinden oluşan gürültüyü ortadan kaldırmaktır. Gürültüye sahip EEG sinyalleri elde edildikten sonra daha doğru ve kaliteli sonuç için özellik çıkarılmadan önce gürültüleri ortadan kaldırmak, ön işlem yapmak gerekir.

Sinyallere ön işleme yapılarak elektrookülografi, elektromiyografi ve elektrokardiyografi parazitleri ya da yüksek frekanstan dolayı ortaya çıkan elektromanyetik ve frekans parazitleri ortadan kaldırılır. EEG sinyallere alt örnekleme, gürültünün kaldırılması, filtreleme gibi yöntemlerle ön işleme yapılmaktadır.

Artefakt alt uzay yeniden inşası, EEG sinyallerindeki artefaktları kaldıran bileşen tabanlı bir yöntemdir. Ortak ortalama referans yöntemi ise, elektrotlar ile ortalama değer tahmin edilerek, tahmin edilen değeri tüm elektrot örneklerinden çıkarır. Yapılan çalışmalar incelendiğinde Mehmood ve Lee [4], Lahane ve Sangaiah [12], Mert ve Akan [26], Liu vd. [73] Chen vd. [42], Yin vd. [47] bağımsız bileşen analizi ile sinyallere ön işleme yapmıştır. Liu vd. [73], Katsigiannis vd. [75] sonlu dürtü yanıtı ile sinyallere ön işleme yapmıştır.

Zeng ve Lu [14], Atkinson ve Compos [17], Bhatti vd. [19] bant geçiş filtreleme; Kumar vd. [18], Bong vd.[21], Hou vd. [40] butterworth; Khezri vd. [11] chebyshev filtreler kullanarak sinyallere ön işleme yapmıştır.

2.3.6. Özellik Çıkarma

Özellik çıkarma, duygusal durumları ayırt edebilmek için belirli hesaplama ve yöntemlerle özelliklerinin çıkarıldığı aşamadır. Bu aşama sinyallere ön işleme yapıldıktan sonra gerçekleşmektedir. Duygu tanıma kolaylık sağlayan bu aşama kilit noktadır. Çünkü çıkarılan bu

özellikler sınıflandırmanın doğruluğu ve güvenilirliğini etkilemektedir. Literatüre bakıldığında genel olarak zaman, frekans ve zaman-frekans alanına dayalı özellik çıkarma yöntemleri kullanılmıştır.

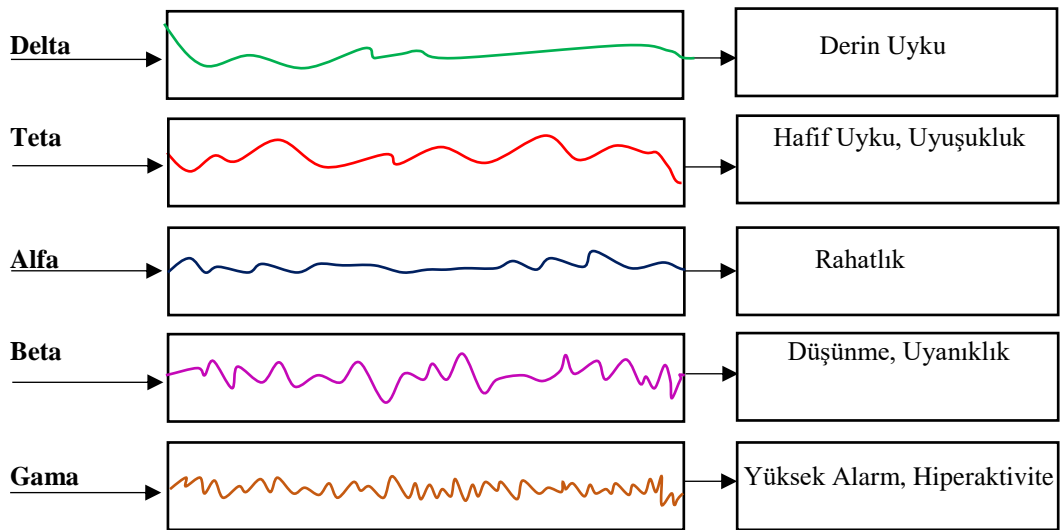
Zaman Alanı Özellikleri

EEG sinyallerinden belirli yöntem ve hesaplamalar ile zamansal veriler elde edilmektedir. Olayla ilgili potansiyeller ile zaman alanı özellikler çıkarılabilmektedir. Standart sapma, güç, normalize, çarpıklık gibi istatistiksel ölçümler ile zaman alanı özellikleri çıkarılmıştır[77]. Pradhan ve Dutt [78] karmaşıklık ölçüsü kullanarak fraktal boyut ile zaman alanı özelliklerini çıkarmıştır.

Frekans Alanı Özellikleri

EEG verilerinin zaman alanından frekans alanına dönüştürülerek hesaplanmasıyla elde edilmektedir. EEG frekans bantları ile zihinsel durumun arasında ilişki vardır. İlişki durumu Şekil 2.8'de gösterilmiştir. 0 ile 4 Hz arasındaki delta dalgalarına bakıldığında dalgaların yavaş ve derin uyku ile ilişkilendirildiği görülmektedir. 4 ile 8 Hz arasındaki teta dalgalarına bakıldığında uykulu, uyuşukluk durumlarında görülmektedir. 8 ile 13 Hz arasındaki alfa insanların rahat ve bilinçli olduğu durumlarda görülmektedir. 13-30 Hz arasındaki beta insanların düşünceli, beynin yoğun olduğu durumlarda görülmektedir. 30 Hz ve daha büyük frekansa sahip gama beynin hiperaktivite durumlarında görülmektedir.

Zaman alanından frekans alanına dönüştürmek için hızlı ve ayrık fourier dönüşümü yöntemleri kullanılmaktadır. Frekans alanı özellerini çıkarmak için bant gücü, güç spektrumu ve güç yoğunluğu spektrumu hesaplanmaktadır.



Şekil 2.8. EEG frekans bantları ile zihinsel durumun ilişkilendirilmesi

Literatüre bakıldığında EEG sinyalleri kullanarak özelliklerin çıkarılması için güç spektral yoğunluğu, kısa süreli fourier dönüşümü, ampirik mod ayrıştırma, diferansiyel entropi, örnek entropi, istatistiksel özellikler, dalgacık dönüşümü, dalgacık entropisi, derin özellik kümeleme, yüksek dereceli geçiş, ayırık dalgacık dönüşümü, temel bileşenler analizi, wigner ville dağılımı, değişken mod ayrıştırma gibi yöntemler kullanılmaktadır.

Sinyalin sabit olmadığı durumlarda zaman-frekans yöntemleri dinamik değişiklikler ile bilgiler elde edilebilir [77]. EEG sinyallerinin zaman veya frekans alanı özelliklerinden yeterli bilgi elde edilemediğinde zaman frekans alanı özellikleri kullanılarak çalışma yapılmıştır. Genel olarak ayırık dalgacık dönüşümü ve kısa süreli fourier dönüşümü kullanılmaktadır.

Duygusal durumları doğru ve kaliteli ayırt edebilen özellikler çıkarılıp seçildikten sonra duygu tanıma için sınıflandırma algoritmalarıyla eğitilmektedir.

2.3.7. Duygu Sınıflandırma

Duygu sınıflandırılması, özellik çıkarılması ve seçiminden sonra duyguların tanınması için sınıflandırıldığı son aşamasıdır. Burada EEG özellikleri, duygusal durumun eğitilmesi için makine öğrenimi sınıflandırıcılarına beslenmektedir.

Sınıflandırma için derin öğrenme yöntemleri ve makine öğrenme yöntemleri kullanılmaktadır. Derin öğrenmede yapay sinir ağı, evrişimsel sinir ağı, derin sinir ağı, uzun ve kısa süreli bellek gibi yöntemler uygulanmaktadır. Sınıflandırma için genelde derin öğrenme yöntemleri kullanılır. Makine öğrenmede ön bilgi ve etkili özelliklerin bulunması kolay olmadığından ve bu da sınıflandırma doğruluğunu etkilediğinden genel olarak derin öğrenme algoritmaları kullanılmaktadır.

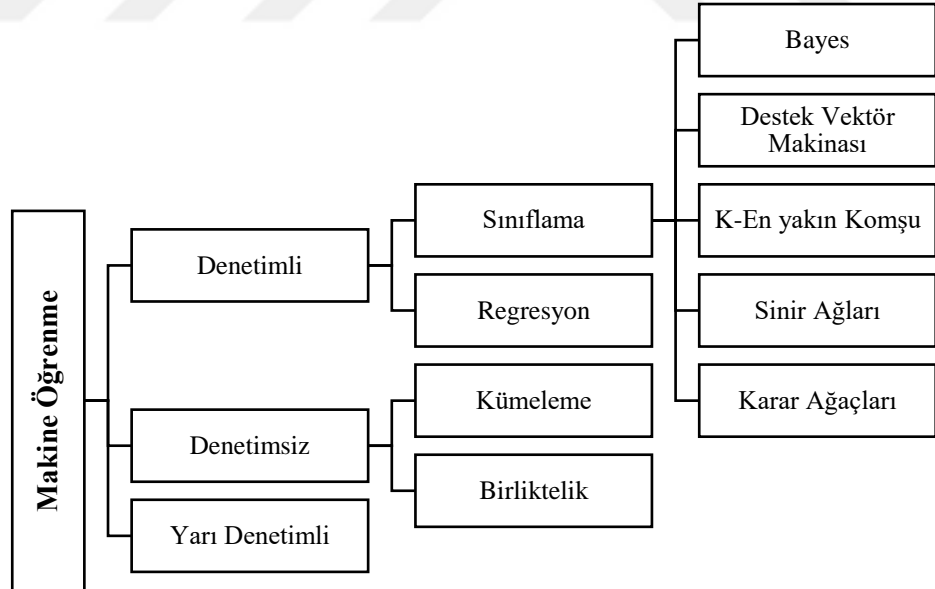
3. DUYGU TANIMADA KULLANILAN YÖNTEMLER

Makine öğrenme denetimli, denetimsiz ve yarı denetimli olmak üzere Şekil 3.1’de gösterildiği gibi üçe ayrılan algoritmalarıdır. Denetimsiz öğrenme, girdi değerine karşılık çıktısının bilinmediği algoritmalarıdır. Veriler üzerinde anlam çıkarmaya çalışan bu algoritmalar kümeleme ve birliktelik olarak ikiye ayrılmaktadır.

Yarı denetimli öğrenme, girdi ve çıktı değerlerinden, çıktının bazılarının etiketlenmesi yöntemidir diyebiliriz. Denetimsiz öğrenmede girdi ile ilgili yapının keşfi, denetimli öğrenmede de etiketlenmemiş verilerin tahmini kullanılmaktadır.

Denetimli öğrenme etiketli veriler kullanılarak giriş verileri ve hedefte çıktı içeren modeldir. EEG verilerini iki etiketleme yöntemi ile etiketlemektedir. Duygu durumlarını boyutsal model olan uyarılma değeri ile tanımlama, diğeri ise veri elde etme aşamasında deneklerin uyarılara göre duygusal durumun tanımlanmasıdır. Denetimli öğrenme Şekil 3.1’deki gibi sınıflama ve regresyon olmak üzere ikiye ayrılmaktadır. Denetimli öğrenmede sınıflandırma için kullanılan algoritmalar bayes, destek vektör makinaları, k-en yakın komşu, sinir ağları ve karar ağaçlarıdır.

Literatüre bakıldığında en çok kullanılan yöntemin destek vektör makinası olduğu, onu da sinir ağları takip ettiği görülmüştür.

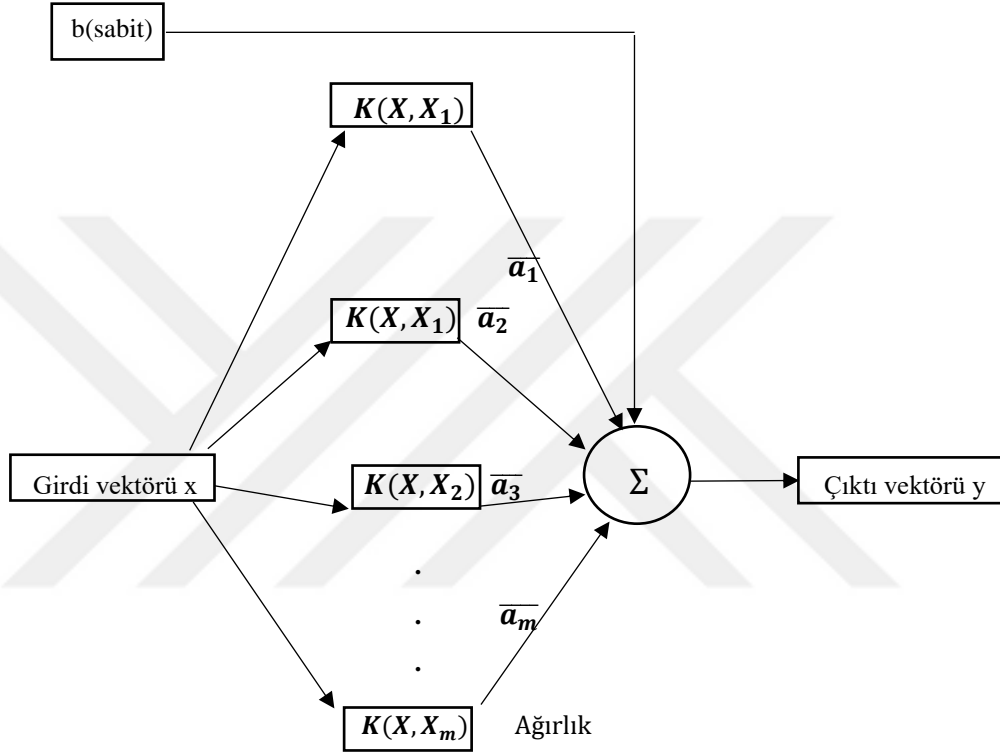


Şekil 3.1. Makine öğrenme yöntemleri

3.1. Destek Vektör Makinesi

Destek Vektör Makineleri (DVM), Vapnik tarafından geliştirilen, denetimli öğrenmenin yöntemi olan, örüntülerdeki veri setlerinin bilinmediği durumda kullanılan bir sınıflama algoritmasıdır. DVM'nin çalışma mantığı Şekil 3.2 ve formülü Denklem 3.1'de verilmiştir.

Destek vektör makinesi en çok kullanılan sınıflandırma algoritması olduğu görülmüştür. Yüksek boyutta sınıflandırma işlemleri için farklı çekirdek işlevlerini kullanabilmektedir.




Şekil 3.2. Destek vektör makinesi çalışma mantığı

$$y = f(x) \sum_{k=1}^m \bar{a}_k \cdot K(X, X_k) + b \quad (3.1)$$

3.2. Yerel İkili Örüntüler

Yerel ikili örüntü bir görseli bölgelere ayırarak özellik çıkarmaya yarayan yaklaşımdır. Bu yaklaşım, gri görüntüdeki Şekil 3.3'teki gibi her pixelin 3x3 komşuluklarını karşılaştırarak Eşitlik Denklem 3.1'deki gibi ikili taban adı verilen kod üretir. Komşu pixel ve merkez pixel karşılaştırılıp Denklem 3.3'teki gibi komşu pixel merkez pixelden küçük ise ikilik tabanda 0, büyük ve eşit ise 1 olarak kodlama yapılır. Oluşan ikili taban Denklem 3.2'deki gibi onluk sisteme çevrilir ve böylece BP kodu elde edilmiş olur.



Şekil 3.3. Yerel ikili örüntü yöntemi

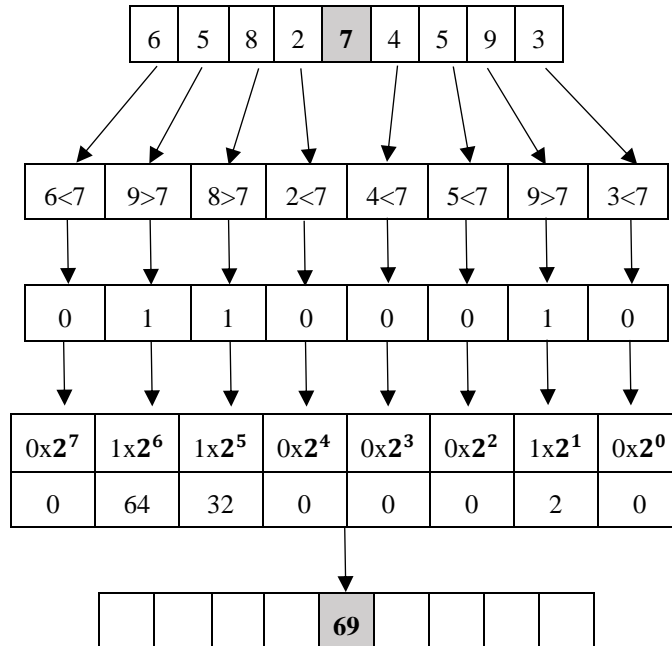
$$\text{İkili Taban: } 11010101 \quad (3.2)$$

$$\text{Onluk Taban: } 213 \quad (3.3)$$

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.4)$$

3.3. Bir Boyutlu Yerel İkili Örüntüler

Bir boyutlu yerel ikili örüntülerde (BBYİÖ) Şekil 3.4 'te gösterildiği gibi işaretlenen merkez veri, Denklem 3.5 ve Denklem 3.6'daki gibi diğer komşu örnekler ile karşılaştırma yapıp, komşu örnekten küçükse Denklem 3.7'de gösterildiği 0, büyük veya eşitse 1 yazılarak ikili tabanda dizi elde edilir. Daha sonra bu dizi onluk tabana dönüştürülür.



Şekil 3.4. Bir boyutlu yerel ikili örüntü yöntemi

$$x = S_i - S_c \quad (3.5)$$

$$Y(x) = \sum_{i=0}^S f(x) \cdot 2^{i-1} \quad (3.6)$$

$$f = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0, \end{cases} \quad (3.7)$$

Literatüre bakıldığında sinyallerden özellik çıkarma için bir boyutlu yerel ikili örüntüler (BBYİÖ)[79, 80] sıklıkla kullanılmıştır.

3.4. K-En Yakın Komşu

K en yakın komşu (KNN) algoritması genel olarak en sık kullanılan algoritmalarından biridir. KNN basit, güçlü bir yöntem olduğu için yüz tanıma, karakter tanıma, duygu tanıma alanlarında sıklıkla kullanılmaktadır. Etiketlenmemiş test verisi verildiği zaman KNN, veri setinde en yakın olan k 'yı bulur ve ardından en uygun etiketi atar [81].

KNN, en yakın eğitim örneklerine göre nesne sınıflandırma işlemi yapmaktadır. Bir nesne, komşularının çoğunluk oyuyla sınıflandırılır.

KNN algoritmasında dikkat edilmesi gereken iki durum vardır. Bunlardan ilki, performansı etkileyen doğru k seçimidir. k değerleri büyük olduğunda, küçük fakat önemli modelleri göz ardı edebilir. Diğer durum ise test örnekleri ve komşular arasındaki mesafenin hesaplanmasıdır [82]. Mesafe fonksiyonlarında en popüler mesafe ölçüsü öklid, manhattan ve minkowski'dir.

X_1, X_2, \dots, X_n ve Y_1, Y_2, \dots, Y_n olmak üzere n özellik uzayının boyutu olduğu özellik vektörünü temsil etmektedir. Öklid mesafesinin matematiksel gösterimi Denklem 3.8'de verilmiştir.

$$mes_{\text{öklid}}(X, Y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \quad (3.8)$$

İki veri noktasının farkını mutlak değer içerisinde hesaplayan manhattan mesafesinin matematiksel gösterimi Denklem 3.9'da verilmiştir.

$$mes_{\text{manhattan}}(X, Y) = \sum_{i=1}^n |X_i - Y_i| \quad (3.9)$$

Sabit bir p için $p \in (0, \infty)$ olmak üzere minkowski mesafesinin matematiksel gösterimi Denklem 4.10'da verilmiştir.

$$mes_{\text{minkowski}}(X, Y) = (\sum_{i=1}^n |X_i - Y_i|^p)^{1/p} \quad (3.10)$$

K-en yakın komşuların hesaplaması ile ilgili algoritma şu şekildedir:

1. K = önceden en yakın komşu sayısı belirlenir. Ayrıca K farklı değerler alabilir.
2. Sorgu örneği ile tüm örnekler arasındaki mesafe istenilen algoritmayla hesaplanır.
3. Tüm eğitim örnekleri için mesafeler sıralanarak K . minimum mesafesine göre en yakın komşu belirlenir.
4. Bu algoritma denetimli öğrenme olduğu için K 'nın altına düşen değerler için eğitim verilerinin tüm kategorileri alınır.
5. En yakın komşuların çoğu tahmin için kullanılır.

3.5. Ayrık Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünde veri boyutu oldukça büyük ve fazla hesaplama yükü olduğundan ayrık dalgacık dönüşümünden yararlanır. Öteleme ve ölçek parametreleri ayrık dalgacık dönüşümü (ADD) elde etmek için kullanılır. Alçak ve yüksek geçirgen olmak üzere iki filtreleme vardır. Yüksek frekanslı değişimin analizi için yüksek geçirgen filtre, alçak frekanslı değişimin analizi için ise alçak geçirgen filtre kullanılmaktadır. Bu analizlerde yaklaşıklık adı verilen yüksek ölçek katsayısı ve ayrıntı adı verilen düşük ölçek katsayıları elde edilir.

Tez çalışmasında özellik çıkarmak sadece alçak seviyeli özellik çıkaran bir boyutlu yerel ikili örüntülere (BBYİÖ) ek olarak ayrık dalgacık dönüşümü (ADD) [83, 84] kullanılmıştır.

3.6. Sınıflandırıcı Performansı ve Doğruluk Ölçümleri

Elde edilen veriler sınıflandırıldıktan sonra sınıflandırıcının doğruluk oranını ve performansını ölçmek çok önemlidir. Algoritma daha iyi hale getirilerek ve hatalar önlenerek daha yüksek bir başarımla elde edilir.

3.6.1. Doğruluk Hesaplaması

Doğruluk, algoritmanın performansını ölçmek için kullanılan veya gözden kaçan verilerin yüzdesini bulmak için kullanılan ölçümdür.

İkili sınıflandırma için kullanılan doğruluk ölçümleri doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif olmak üzere dört metrik ile ifade edilmektedir [85].

DP veya doğru pozitif, doğru sınıflandırılmış pozitif verilerin sayısını,

DN veya doğru negatif, doğru sınıflandırılmış negatif verilerin sayısını,

YP veya yanlış pozitif, yanlış sınıflandırılmış pozitif verilerin sayısını,

YN veya yanlış negatif, yanlış sınıflandırılmış negatif verilerin sayısını,

DP, DN, YP ve YN değerlerinin toplamı ise toplam örnek sayısını vermektedir.

Tablo 3.1'deki gibi 2x2 matris kullanılarak görselleştirilen karışıklık matrisi de kullanılabilir. Bu matrise göre sınıflandırıcının performansı için doğruluk (OA), hassasiyet (Pr), hatırlama (Rec) ve F1-skor ($F1$) hesaplanabilmektedir.

Tablo 3.1. Karışıklık matrisi

		Tahmin	
		Evet	Hayır
Gerçek	Evet	DP	YN
	Hayır	YP	DN

Doğruluk, Denklem 3.11'de gösterildiği OA doğruluk olmak üzere gibi doğru tahmin sayısının toplam tahmin sayısına oranı ile hesaplanmaktadır.

$$Doğruluk (OA) = \frac{\text{doğru tahmin sayısı}}{\text{toplam tahmin sayısı}} = \frac{dp+dn}{dp+dn+yp+yn} \quad (3.11)$$

Hassasiyet, tanımlanan pozitif verilerin hangi oranının gerçekte doğru olduğunu gösterir. Denklem 3.12'de hassasiyet metriği doğru pozitifin doğru pozitif ve yanlış pozitifin toplamına oranı ile hesaplanmaktadır.

$$Hassasiyet=Pr = \frac{dp}{dp+yp} \quad (3.12)$$

Hatırlama, sadece doğru olan pozitif vakaları yani pozitif verinin doğru tahmin edildiği yüzdeyi gösterir. Denklem 3.13'te hatırlama metriği doğru pozitifin, doğru pozitif ve yanlış negatifin toplamına oranı ile hesaplanmaktadır.


$$Hatırlama=Rec = \frac{dp}{dp+yn} \quad (3.13)$$

Denklem 3.14'te f1 skor değeri hassasiyet ve hatırlama değerlerinin harmonik ortalamasını gösterir. Hassasiyet ve hatırlamanın çarpımının hassasiyet ve hatırlamanın toplamına oranının iki katı şeklinde hesaplanmaktadır.

$$F1 = 2 * \frac{Pr*Rec}{Pr+Rec} \quad (3.14)$$

3.6.2. Çapraz Doğrulama

Çapraz doğrulama, başlangıçtaki eğitim veri setini segmentlere ayırmak ve bu verileri de birden fazla alt kümeye k kez bölmektir [86]. Şekil 3.5'te gösterimi verilmiştir.



Şekil 3.5. Veri kümesinin segmentlere ayrılması

Çapraz doğrulamada optimum değer en fazla 10 olarak belirlenmiş, veriye göre 2, 3 veya 5 [30, 52] olarak da kullanılmıştır. Bu çalışmada önerilen bir yöntemde 10 katlı çapraz doğrulama kullanılmıştır. Sistemin genel başarısının hesaplanması t veri sayısı ve n toplam veri sayısı olmak üzere sınıflandırma başarı oranı (SBO) ve Ortalama SBO Denklem 3.15'te verilmiştir.

$$SBO = \frac{t}{n} , \text{ Ortalama } SBO = \frac{\sum_{i=1}^t SBO_i}{t} \quad (3.15)$$

4. MATERYAL VE METOT

Bu tezde yüksek doğruluğa sahip iki adet otomatik EEG tabanlı duygu tanıma yöntemi önerilmiştir. Birincisinde bir boyutlu yerel ikili örüntü ile ayrık dalgacık dönüşümü yöntemi kullanırken ikincisinde asal örüntü yöntemi kullanılarak duygu tanıma gerçekleştirilmiştir. Bölüm 4.1 ve Bölüm 4.2’de ayrıntılı verilmiştir.

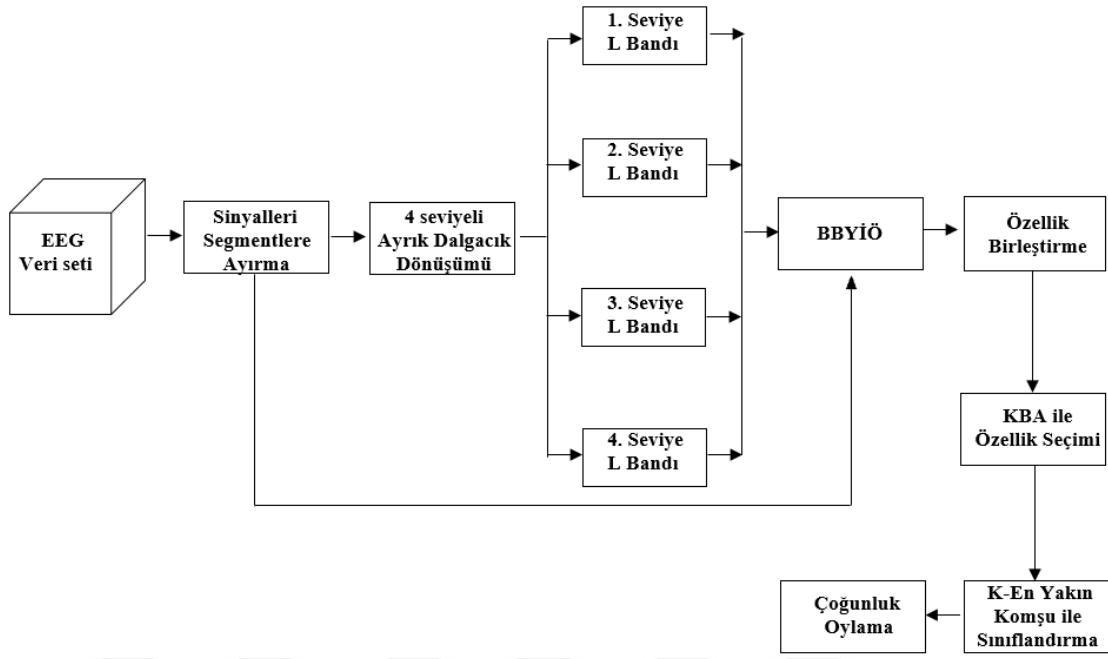
4.1. Bir Boyutlu Yerel İkili Örüntü ile Ayrık Dalgacık Dönüşümü Kullanarak Duygu Tanıma

Önerilen yöntemde 14 kanal içeren EEG cihazı ile bilgisayar oyunu oynayarak uyarılmış 28 kişiden alınan GAMEEMO [1] veri seti kullanılmıştır. EEG duygu veri setleri Bölüm 2.3.4’te detaylı verilmiştir.

Yapılan çalışmalar incelendiğinde bir boyutlu yerel ikili örüntüler (BBYİÖ) kullanılarak özellik çıkarılmış fakat BBYİÖ sadece alçak seviyeli özellikleri çıkardığı için bu duruma çözüm olarak ayrık dalgacık dönüşümü (ADD) önerilmiştir. Önerilen yöntemde öncelikle EEG sinyalleri için GAMEEMO veri seti kullanılmış ardından veri setinden elde edilen sinyaller segmentlere ayrılmıştır. Ayrılan her bir sinyale 4 seviyeli ayrık dalgacık dönüşümü uygulayarak 4 adet alçak geçiren filtre katsayıları elde edilmiştir. Burada ana dalgacık filtre symlet 4 kullanılmıştır.

Özellik çıkarmada, sinyalin boyutuna bağlı kalmaksızın frekans ve zamansal alanda özellik çıkardığı ve bu özelliklerin de sınıflandırma doğruluğu yüksek olduğu için BBYİÖ kullanılmıştır. Bu aşamada her bir sinyalden 256 özellik ve histogramı çıkarılmış, 1280 uzunluğunda özellik vektörü elde edilmiştir. Çıkarılan özelliklerin seçilmesi için komşuluk bileşen analizi (KBA) kullanılmıştır. Burada KBA en belirgin 256 özelliği seçmiştir. Seçilen özelliklerin sınıflandırılması için k-en yakın komşu sınıflandırıcısı, sınıflandırma doğruluğu için 10 kat çapraz doğrulama yöntemi kullanılmıştır. Son olarak çoğunluk oylama yöntemi ile her bir sinyalin tahmin edilen değeri hesaplanmıştır.

Önerilen yöntemin blok diyagramı Şekil 4.1’de verilmiştir.



Şekil 4.1. Önerilen yöntemin blok diyagramı

Önerilen yöntemde, çok seviyeli ayırık dalgacık dönüşüm için Denklem 4.1 ve Denklem 4.2'ye göre g EEG sinyalini, A^k k. alçak geçiren frekans katsayısını, Y^k k. yüksek geçiren frekans katsayısını ve $ADD(.)$ bir boyutlu ayırık dalgacık dönüşümünü temsil etmektedir.

$$[A^1, Y^1] = ADD(g) \quad (4.1)$$

$$[A^k, Y^k] = ADD(A^{k-1}), k \in \{2,3,4\} \quad (4.2)$$

1'den 4'e kadar değer alabilen t değeri ve f^t t. özellik vektörü olmak üzere BBYO ve ADD çok seviyeli özellik çıkarma yöntemi Denklem 4.3 ve Denklem 4.4'te verilmiştir.

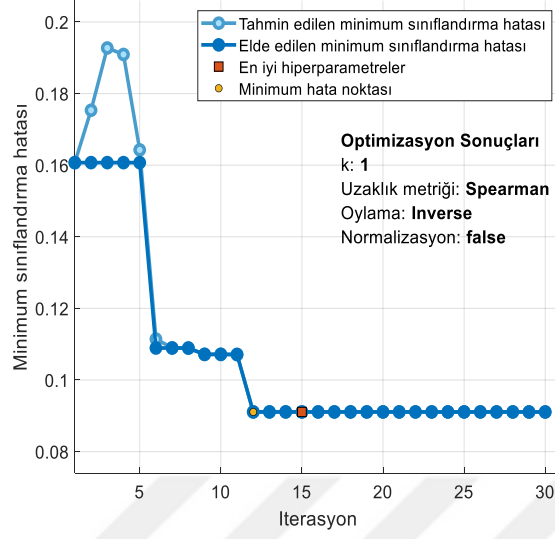
$$f^1 = BBYO(g) \quad (4.3)$$

$$f^{t+1} = BBYO(A^t), t \in \{1,2,3,4\} \quad (4.4)$$

BBYO ve ADD tabanlı özellik çıkarma işleminden sonra elde edilen özelliklerin birleştirilmesi Denklem 4.5'teki verilmiştir. Bu işlem sonucunda 1280 özellik elde edilmiştir. Ardından k-en yakın komşu sınıflandırıcısı ile elde edilen 560×1280 boyutundaki özellik vektörü 10-kat çapraz doğrulama yöntemi ile sınıflandırılmış ve tahmin edilen etiket vektörü 560 elemanlı olarak oluşturulmuştur. Burada Matlab Classification Learner aracı kullanılarak optimum k-en yakın komşu parametrelerin seçimi yapılmıştır. Bu optimum parametreler Şekil 4.2'de gösterilmiştir.

Çoğunluk oylama ile her bir sinyalin tahmin edilen değeri hesaplanmıştır.

$$ft((k - 1) * 256 + j) = f^k(j), j \in \{1,2, \dots, 256\}, k \in \{1,2, \dots, 5\} \quad (4.5)$$



Şekil 4.2. KNN sınıflandırıcısının optimum parametreleri

Önerilen duygu tanıma yönteminde 14 kanallı GAMEEMO veri seti kullanıldığı için her bir kanala ait değerler hesaplanmıştır. Hesaplanan metriklerin matematiksel gösterimi doğruluk OA olmak üzere Denklem 4.6'da hassasiyet Pr olmak üzere Denklem 4.7'de hatırlama Rec olmak üzere Denklem 4.8 ve F1 skor $f1$ olmak üzere Denklem 4.9'da gösterilmiştir. Ayrıca doğru pozitif dp , yanlış pozitif yp , doğru negatif dn ve yanlış negatif yn olmak üzere bu değerler performans metriklerinin hesaplanması için kullanılmıştır.

$$OA = \frac{dp+dn}{dp+dn+yp+yn} \quad (4.6)$$

$$Pr = \frac{dp}{dp+yp} \quad (4.7)$$

$$Rec = \frac{dp}{dp+yn} \quad (4.8)$$

$$F1 = 2 \frac{Pr*Rec}{Pr+Rec} \quad (4.9)$$

4.2. Asal Örüntü Yöntemi Kullanarak Duygu Tanıma

EEG tabanlı duygu tanımda en yüksek sınıflandırma doğruluğunu elde etmek için yeni bir model olan asal örüntü yöntemi önerilmiştir. Önerilen asal örüntü modelinde özellik oluşturma, özellik seçimi ve sınıflandırma olmak üzere üç adımdan oluşmaktadır. Bu modelin yeniliği, en

önemli özellik vektörünü seçmek için özellik çıkarma, özellik seçme ve sınıflandırmanın birlikte kullanıldığı özellik üretimidir. Bu aşamada 87 özellik vektörü ürettiği için bu model PrimPatNet87 olarak adlandırılmıştır.

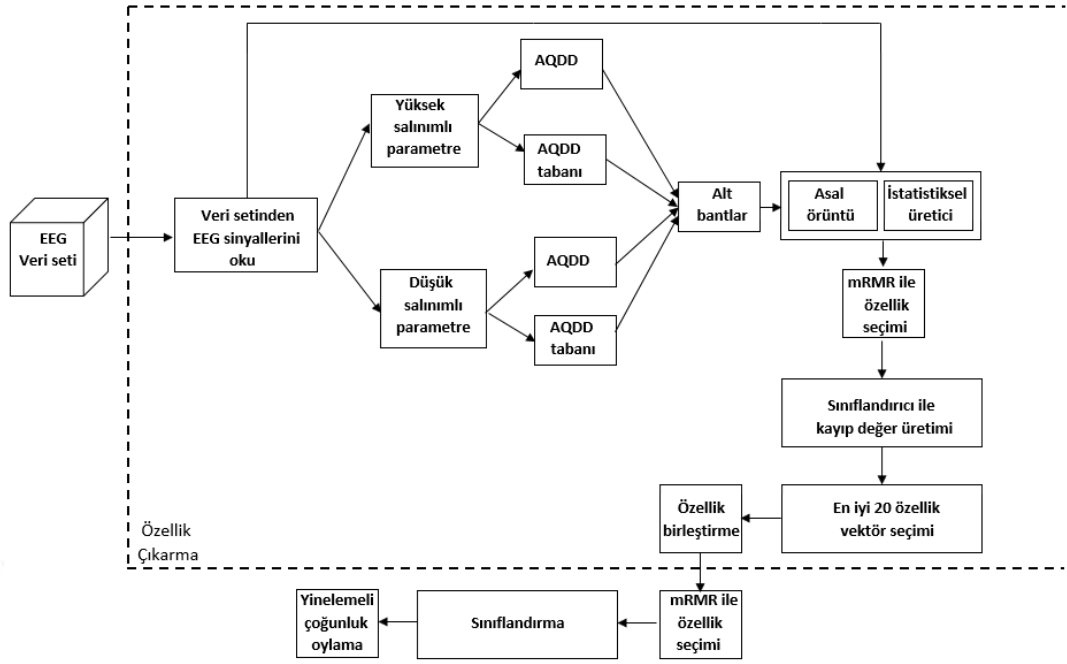
DeneySEL çalışmalarını gerçekleştirmek için çoklu kanal içeren GAMEEMO[1], DEAP[16] ve DREAMER[75] veri seti kullanılmıştır. GAMEEMO veri seti 7 kanal, DEAP veri seti 32 kanal, DREAMER veri seti ise 14 kanal içermektedir. EEG duygu veri setleri Bölüm 2.3.4'te detaylı verilmiştir. Önerilen asal örüntü ağını uygulamak için MATLAB (2020b) kullanılmıştır. Önerilen bu model, 32 GB ana belleğe sahip, 3.60 GHz bir Intel i9 9900 işlemciye ve 1 TB sabit diske sahip kişisel bilgisayarda uygulanmıştır. Sınıflandırma sonuçlarını hesaplamak için DVM [95] sınıflandırıcılar kullanılmış ve GAMEEMO, DEAP ve DREAMER veri setleri için hesaplanan sonuçlar sonraki sayfalarda verilmiştir.

İlk olarak EEG veri setinde alınan sinyaller okunur. Ardından özellik oluşturma aşamasına geçilir. Özellik çıkarma bu çalışmanın kilit noktasıdır çünkü en iyi özellikleri oluşturmak ve seçmek için bir öğrenme modeli sunulmuştur. Kullanılan birincil özellik oluşturma işlevi, histogram tabanlı bir yöntem olan asal desendir. Bu çalışmada özellik oluşturma için düşük ve yüksek salınımlı ayarlanabilir q-faktörlü dalgacık dönüşümü (AQDD)[87] ve ayarlanabilir q faktörü dalgacık dönüşüm taban (AQDDT)[87] ayrıştırıcılar kullanılmış, 86 alt bantlar oluşturulmuştur. Daha sonra önerilen asal model ve istatistiksel özellik çıkarıcı kullanılarak oluşan alt bantlardan $768+30=798$ özellik oluşturulmuştur. Her bir özellik vektörünün yanlış sınıflandırma oranları, bir DVM sınıflandırıcısı kullanılarak hesaplanmıştır.

Elde edilen özellikler arasında özellik seçimi için Minimum Artıklık Maksimum Alaka Düzeyi (mRMR) seçici kullanılmış, her bir özellik vektöründen en bilgilendirici 399 özelliği seçmiştir. En iyi 20 özellik vektörü yanlış sınıflandırma oranlarına göre seçilmiş ve birleştirilmiştir. Son olarak 7980 uzunluğunda özellik vektörü elde edilmiş. mRMR [88,89] seçici kullanılarak ilk 1000 özellik seçilmiştir. DVM sınıflandırıcı kullanılarak tek kanallı sonuçlar elde edilmiş ve sınıflandırma sonuçlarını elde etmek için mod işlevine dayalı çoğunluk oylaması kullanılmıştır.

Önerilen modelin diyagramı Şekil 4.3'te gösterilmiştir. Önerilen modelde kullanılan adımları ve teknikleri aşağıda verilmiştir.

1. Alt bantlar oluşturmak için yüksek ve düşük salınımlı parametreleri seçin. Bu çalışmada, f fazlalık ve L level sayısı olmak üzere 4,3,31 q faktörü düşük salınımlı, 1,3,10 q-faktörü yüksek salınımlı parametreler seçilmiştir.
2. AQDD ve AQDDT kullanarak alt bantlar oluşturun. Burada Denklem 4.10-4.13'teki gibi $aqdd$ ve $aqdd_f$ ayrıştırıcıları kullanarak dört tür alt bant oluşturulmuştur. $11+32+11+32=86$ olmak üzere alt bant üretilmiştir.



Şekil 4.3. Önerilen modelin diyagramı

$$R_1 = aqdd(EEG, 1,3,10) \quad (4.10)$$

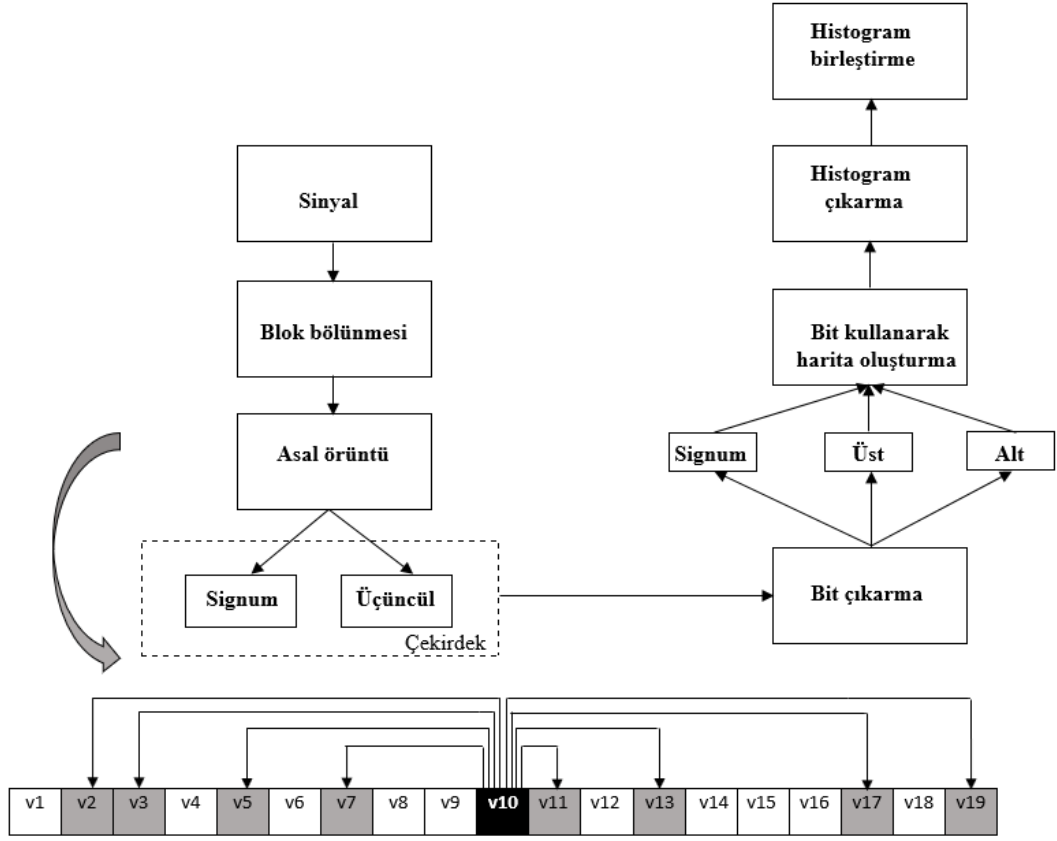
$$R_2 = aqdd(EEG, 4,3,31) \quad (4.11)$$

$$R_3 = aqdd_f(EEG, 1,3,10) \quad (4.12)$$

$$R_4 = aqdd_f(EEG, 4,3,31) \quad (4.13)$$

3. Asal örüntü ve istatistiksel momentler kullanarak 798 özellik çıkarın.

Bu çalışmada çarpıklık, ortalama, basıklık, medyan, medyan, standart sapma, ortalama karekök, enerji, maksimum, aralık, minimum, bilgi entropisi, logaritmik entropi, kesin entropi ve higuchi olmak üzere 15 istatistiksel moment hem sinyale hem de sinyalin mutlak değerine uygulanmıştır. İstatistiksel özellikler bu momentler kullanılarak oluşturulmuştur. Asal örüntü, dokusal özellikleri çıkarmak için kullanılır. Bu modelde asal sayıların özellik üretme yeteneği araştırılmış, ayrıca sunulan asal örüntünün özellik oluşturma yeteneğini uygulamak için asal örüntüde iki özellik oluşturma işlevi kullanılmıştır. Önerilen asal örüntünün grafiksel açıklaması Şekil 4.4'teki gibidir.



Şekil 4.4. Önerilen asal örüntünün grafiksel gösterimi

Sunulan asal model kullanılarak, her bir sinyalden 768 dokusal özellik üretilir ve sunulan asal modelin adımları aşağıda belirtilmiştir. Ayrıca, $prime-pat(.)$ işlevi, sunulan asal örüntü oluşturma işlevini ifade etmektedir. Önerilen AQDD ve asal örüntü tabanlı özellik çıkarma işlemi Denklem 4.14-4.15'te verilmiştir. Denklemlerde kullanılan asal örüntü ve istatistiksel özellik üretici ($itou(.)$), EEG sinyali ve AQDD teknikleri kullanılarak oluşturulan alt bantlar (R) kullanılarak 87 özellik vektörü üretilmiştir.

$$X^1 = conc(prime - pat(S), stfe(S)) \quad (4.14)$$

$$X^{j+1} = conc(prime - pat(R^j), itou(R^j)), j \in \{1, 2, \dots, 86\} \quad (4.15)$$

3.1. Tek boyutlu bir sinyale örtüşen blok bölme uygulayın. Burada özellik oluşturmak için 2,3,5,7,11,13,17 ve 19 olmak üzere ilk 8 asal sayı kullanılmıştır. Bu yüzden 19 boyutlu örtüşen bloklar kullanılmıştır. Denklem 4.16'da b^i , i . örtüşen blok olmak üzere S sinyal ve Ln sinyal uzunluğunu temsil etmektedir.

$$b^i(j) = S(i + j - 1), i \in \{1,2, \dots, Ln - 18\}, j \in \{1,2, \dots, 19\} \quad (4.16)$$

3.2. Bloğun merkez değeri olan 10. Değerini, asal değer, üçlü ve signum fonksiyonlarını kullanarak üç bitlik grup oluşturun. Denklem 4.17-5.19'da bit^k , 8 uzunluğa sahip k. bit grubudur. $\alpha(.,.)$, $\gamma(.,.)$ ve $\delta(.,.)$ signum, üst üçlü, alt üçlü olarak adlandırılan fonksiyonlar bit fonksiyonlardır. as asal sayı kümesini tanımlamaktadır.

$$bit^1(j) = \alpha(b^i(j), b^i(10)), j \in \{1,2, \dots, 8\} \quad (4.17)$$

$$bit^2(j) = \gamma(b^i(as(j)), b^i(10)) \quad (4.18)$$

$$bit^3(j) = \delta(b^i(as(j)), b^i(10)) \quad (4.19)$$

Kullanılan çekirdeklerin matematiksel açılımı Denklem 4.20-4.23'te verilmiştir. Burada e eşik değeri, $std(.)$ standart sapma fonksiyonunu temsil etmektedir.

$$\alpha(b^i(pr(j)), b^i(10)) = \begin{cases} 0, & b^i(as(j)) - b^i(10) < 0 \\ 1, & b^i(as(j)) - b^i(10) \geq 0 \end{cases} \quad (4.20)$$

$$\gamma(b^i(pr(j)), b^i(10)) = \begin{cases} 0, & b^i(as(j)) - b^i(10) \leq e \\ 1, & b^i(as(j)) - b^i(10) > e \end{cases} \quad (4.21)$$

$$\delta(b^i(pr(j)), b^i(10)) = \begin{cases} 0, & b^i(as(j)) - b^i(10) \geq -e \\ 1, & b^i(as(j)) - b^i(10) < -e \end{cases} \quad (4.22)$$

$$d = \frac{std(S)}{2} \quad (4.23)$$

3.3. Denklem 4.24'e göre, üretilen bit^1 , bit^2 ve bit^3 kullanılarak üç harita sinyalini hesaplayın. m^k , k. hesaplanan harita sinyalini temsil etmektedir.

$$m^k(i) = \sum_{j=1}^8 bit^k(j) \times 2^{j-1}, k \in \{1,2,3\} \quad (4.24)$$

3.4. Denklem 4.25'e göre her harita sinyalinin histogramını çıkarın. h^k , 256 uzunlukta hesaplanan k. histogramdır.

$$h^k(m^k(i)) = h^k(m^k(i)) + 1 \quad (4.25)$$

3.5. Denklem 4.26'ya göre oluşturulan histogramları bileştirin ve 768 uzunluğundaki özellik vektörünü hesaplayın. ov , 768 uzunluğundaki son özellik vektörünün birleştirildiği yerdir.

$$ov((k-1) \times 256 + j) = h^k(j), k \in \{1,2,3\}, j \in \{1,2, \dots, 256\} \quad (4.26)$$

4. Özellik vektörü oluşturulduktan sonra özellik vektörlerin boyutunu azaltmak için mRMR kullanılarak vektörlerin boyutu yarıya indirilmiştir. En iyi 399 özellik seçilmiştir. Denklem 4.27 ve Denklem 4.28'e göre $fc()$, chi2 özellik seçim fonksiyonu olmak üzere 768 uzunluğunda sıralanmış indeksleri ind^i hesaplar. y gerçek çıktıyı, dim gözlem sayısını temsil eder, sX^i 399 uzunluğunda i . özellik vektörü seçilir.

$$ind^i = fc(X^i, y), i \in \{1,2, \dots, 87\} \quad (4.27)$$

$$sX^i(d, j) = X(d, ind^i(j)), j \in \{1,2, \dots, 384\}, d \in \{1,2, \dots, dim\} \quad (4.28)$$

5. Bir sınıflandırıcı kullanarak oluşturulan 87 özellik vektörünün yanlış sınıflandırma oranlarını hesaplayın. Denklem 4.29'da $l(i)$ hesaplanan i . kayıp değeri ve $C(.,.)$ kullanılan sınıflandırıcıyı temsil etmektedir. Burada, doğrusal DVM sınıflandırıcıları bir kayıp değeri hesaplayıcısı olarak kullanılmıştır.

$$l(i) = C(sX^i, y) \quad (4.29)$$

6. Denklem 4.30'a göre 87 özellik vektörünü artan yanlış sınıflandırma oranına göre sıralayın. idx artan nitelikli indekslerdir.

$$idx = sort(l) \quad (4.30)$$

7. Denklem 4.31'e göre en iyi özellik vektörünü birleştirin ve $399 \times 20 = 7980$ olmak üzere özellik elde edin. mf , birleştirilen 7980 uzunluğunda özellikleri temsil eder.

$$mf(d, (h-1) \times 768 + j) = sX^{idx(h)}(d, j), h \in \{1,2, \dots, 20\} \quad (4.31)$$

8. 8. adıma kadar olan kısımda özellik oluşturma teknikleri verilmiştir. Özellik seçme adımında, mRMR özellik seçici kullanılmıştır. mRMR, en anlamlı özelliklerin dizinlerini oluşturur ve bu oluşturulan dizinleri kullanarak, oluşturulan 7980 özellikten en ayırt edici 1000 özellik seçilmiştir.

9. Bu adımda ise elde edilen dizinleri kullanarak ilk 1000 özelliği seçin.

Önerilen modelin performansının testi için GAMEEMO, DEAP ve DREAMER veri seti kullanılmıştır. Bu testler MATLAB (2020b) sınıflandırma öğrencisi kullanılmıştır. Kullanılan üç veri kümesi için en iyi sınıflandırıcının DVM sınıflandırıcı olduğu bulunmuştur ve kullanılan hiper parametreler Tablo 4.1'de verilmiştir.

Tablo 4.1. Kullanılan DVM sınıflandırıcısının parametreleri

Parametre	Değer
Çekirdek fonksiyonu	Polinom
Polinom sırası	3
Çekirdek ölçümü	Otomatik
Standartlaştırma	Doğru
Kodlama	Bire-bir

10. Seçilen 1000 özelliği LOSO [46,47] doğrulamalı bir DVM sınıflandırıcısı ile sınıflandırın. LOSO doğrulamalı DVM sınıflandırıcı kullanılarak tek kanal sonuçları hesaplanmış, EEG veri setinden genel bir sonuç hesaplamak için yinelemeli mod fonksiyon tabanlı çoğunluk oylama yöntemi kullanılmıştır. Çoğunluk oylama yöntemi ile tek kanallı sonuçları kullanarak daha yüksek sınıflandırma oranı ve genel bir sonuç elde edilmiştir. Bu modelin adımları aşağıda listelenmiştir.
11. Tahmin vektörlerini sıralayın.
12. Sıralanan tahmin vektörüne yinelemeli mod işlevini uygulayın. Yinelemeli modeli kullanmak için 3'ten kanal sayısına kadar bir döngü aralığı seçilmiştir. GAMEEMO, DEAP ve DREAMER veri seti için maksimum iterasyon değerleri sırasıyla 14, 32 ve 14 olarak tanımlanmıştır. Denklem 4.30'da tv oylanan tahmin vektörünü, t , doğruluklarına göre sıralanmış tahmini değerleri ve $mod(.)$ mod işlevini göstermektedir.

$$tv^{j-2} = mode(p^1(h), p^2(h), \dots, p^j(h)), j \in \{3, 4, \dots, nc\}, h \in \{1, 2, \dots, 1000\} \quad (4. 32)$$

13. Oluşturulan oylanan tahmini vektörleri kullanarak oylanan doğruluğu hesaplayın.
14. En iyi sonuçları seçin. Çoğunluk oylaması, önerilen model olan PrimePatNet87'nin son aşamasıdır.

Önerilen modelin performansı için doğruluk OA , hassasiyet Pr , hatırlama Rec ve F1 skor $F1$ olmak üzere metrik değerleri hesaplanmıştır. Sınıflandırma performans ölçümlerini hesaplamak için doğru pozitif dp , doğru negatif dn , yanlış pozitif yp , yanlış negatif yn kullanılmıştır.

5. BULGULAR VE TARTIŞMA

Bu bölümde önerilen yöntemlerin sonuçları verilmiş ve diğer çalışmalarla karşılaştırılmıştır.

5.1. Bir Boyutlu Yerel İkili Örüntü ile Ayrık Dalgacık Dönüşümü Yöntemi

Önerilen yöntem her bir kanala tek tek uygulanmış ve her bir kanalın metrik değeri Denklem (4.6-4.9) verilen matematiksel yöntemlerle hesaplanmıştır. Hesaplama sonuçları Tablo 5.1’de gösterilmiştir. Tablo 5.1’deki gibi F3, F8, AF4, FC6, O2, T8, P7 ve P8 kanalları olmak üzere 8 kanalda sınıflandırma doğruluk, hassasiyet, hatırlama ve F1 skor değerleri %100 elde edilmiştir. Doğruluk değeri diğer kanallara göre en kötü olan %96,43 olmak üzere F7 kanaldır. Ayrıca önerilen yöntemde duyguları en doğru şekilde tanıyan yani iki kanalda da doğruluk değeri %100 olan kanallar parietal loba takılan P7 ve P8 kanallarıdır.

Tablo 5.1. Önerilen yöntemin her bir kanala ait metrik değeri

Kanal	Doğruluk (OA)	Hassasiyet (Pr)	Hatırlama (Rec)	F1 Skor
F3	100	100	100	100
F4	99.11	99.14	99.11	99.12
F7	96.43	96.51	96.43	96.47
F8	100	100	100	100
AF3	99.11	99.14	99.11	99.12
AF4	100	100	100	100
FC5	99.11	99.14	99.11	99.12
FC6	100	100	100	100
O1	99.11	99.14	99.11	99.12
O2	100	100	100	100
T7	98.21	98.21	98.21	98.21
T8	100	100	100	100
P7	100	100	100	100
P8	100	100	100	100

Önerilen yöntemin aynı veri seti kullanarak yapılan çalışmalara göre performans karşılaştırılması Tablo 5.2’deki gibidir. Tablo 5.2’ye bakıldığında önerilen yöntemin diğer iki çalışmalara göre en yüksek doğruluk değerleri koyu ile gösterilmiştir. AF3, F4, FC5 ve O1 kanallarında doğruluk değeri %99,11 olmak üzere Tuncer vd. [55] ve Alakus vd. [1] göre daha yüksek sonuç elde edilmiştir.

F3, F8, AF4, FC6, O2, T8, P7 ve P8 kanallarının doğruluk değeri %100 olmakla birlikte en iyi sonuç elde edilmiştir. Sadece F7 ve T7 kanallarında Tuncer vd.'nin [55] yöntemi önerilen yöntemle göre sırasıyla %1,96 ve %0,72 olmak üzere daha yüksek sonuç elde etmiştir. Diğer 12 kanalda ise önerilen yöntemde Tuncer vd. [55] göre daha yüksek sonuç elde edilmiştir.

Tablo 5.2. Önerilen yöntemin diğer çalışmalarla karşılaştırılması

GAMEEMO VERİ SETİ	Kanal	Tuncer vd.'nin yöntemi [55]	Alakus vd.'nin yöntemi [1]	Önerilen yöntem
	AF3	97.86	80	99.11
	AF4	98.39	75	100
	F3	98.21	75	100
	F4	98.04	82	99.11
	F7	98.39	71	96.43
	F8	98.75	71	100
	FC5	98.04	75	99.11
	FC6	98.39	74	100
	O1	98.57	71	99.11
	O2	97.68	65	100
	T7	98.93	65	98.21
	T8	98.39	79	100
P7	98.04	70	100	
P8	98.75	72	100	

5.2. Asal Örüntü Yöntemi

Önerilen model DEAP ve DREAMER veri seti kullanılarak uyarılma, değerlik ve baskınlık olmak üzere üç durum kullanarak değerlendirilmiştir. Bu nedenle, her bir durum için tek kanallı sonuçlar tabloda gösterilmiştir. GAMEEMO veri setinde birden fazla durum olmadığından 14 kanalın sonuçları Tablo 5.3'te verilmiştir.

Tablo 5.3'te, önerilen PrimePatNet87'nin 13. kanal hariç %100 sınıflandırma doğruluğuna ulaştığı görülmüştür. Elde edilen doğruluk oranları %99,11 ile %100 arasındadır. Ayrıca 12 oy çokluğu sonucu hesaplanmış ve oylama doğruluğu %100 elde edilmiştir.

Tablo 5.3. Önerilen modelde GAMEMO veri seti kullanılarak elde edilen sonuçlar (%)

Kanal	OA	Pr	Rec	F1	Kanal	OA	Pr	Rc	F1
1	100	100	100	100	8	100	100	100	100
2	100	100	100	100	9	100	100	100	100
3	100	100	100	100	10	100	100	100	100
4	100	100	100	100	11	100	100	100	100
5	100	100	100	100	12	100	100	100	100
6	100	100	100	100	13	99.11	99.11	99.14	99.13
7	100	100	100	100	14	100	100	100	100

DREAMER veri setinde önerilen model kullanılarak elde edilen sonuçlar (%) Tablo 5.4 ve Tablo 5.5'te gösterilmiştir. DREAMER veri seti kullanılarak uyarılma, değerlik ve baskınlık durumlarının hesaplanan 14 kanal performansları verilmiştir. En iyi sonuç veren kanallar koyu renk ile gösterilmiştir. Önerilen model olan PrimePatNet87, Tablo 5.4'teki gibi 13. kanal kullanılarak uyarılma durumu için %99,66 doğruluk, 14. kanal kullanılarak değerlik durumu için %99,69 doğruluk, Tablo 5.5'teki gibi 7. kanal kullanılarak baskınlık durumu için %98,64 doğruluk elde edilmiştir.

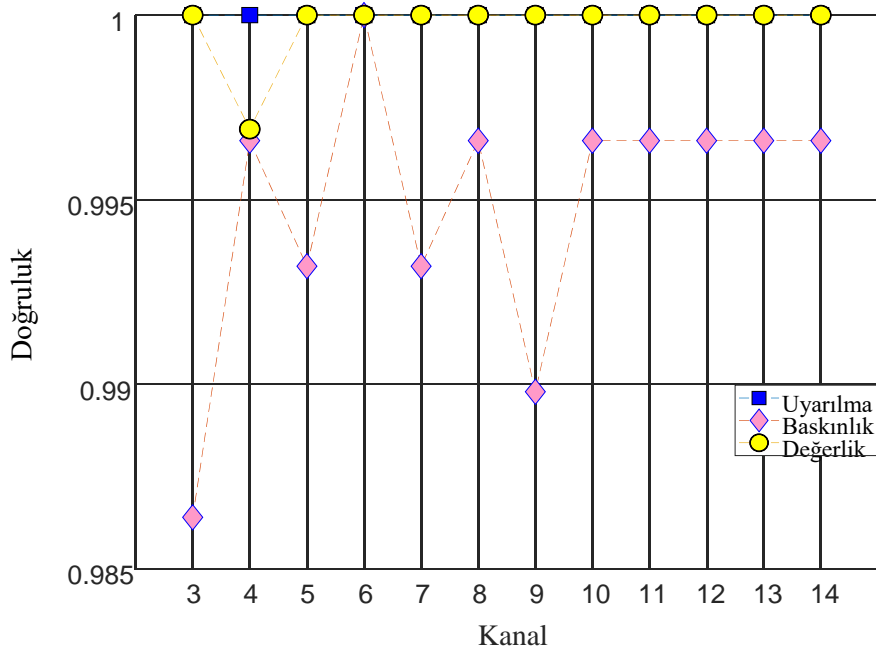
Tablo 5.4. Önerilen model kullanılarak DREAMER veri setinin her bir kanala ait uyarılma ve değerlik (%) performansı

Uyarılma					Değerlik				
Kanal	OA	Rec	Pr	F1	Kanal	OA	Rec	Pr	F1
1	98.98	98.68	99.18	98.92	1	96.60	96.61	96.62	96.60
2	99.32	99.12	99.45	99.28	2	96.60	96.62	96.68	96.60
3	98.64	98.25	98.92	98.56	3	97.53	97.54	97.55	97.53
4	98.98	98.68	99.18	98.92	4	99.07	99.08	99.07	99.07
5	98.31	97.98	98.46	98.20	5	96.91	96.92	96.94	96.91
6	99.32	99.45	99.14	99.29	6	96.60	96.63	96.80	96.60
7	98.98	98.85	99.01	98.93	7	97.53	97.54	97.59	97.53
8	98.31	97.81	98.66	98.20	8	99.07	99.08	99.07	99.07
9	98.64	98.41	98.73	98.57	9	99.38	99.39	99.39	99.38
10	99.32	99.12	99.45	99.28	10	98.46	98.45	98.48	98.46
11	98.98	98.68	99.18	98.92	11	98.46	98.46	98.46	98.46
12	98.64	98.25	98.92	98.56	12	98.46	98.46	98.46	98.46
13	99.66	99.72	99.57	99.64	13	97.22	97.22	97.23	97.22
14	96.61	98.68	96.94	96.39	14	99.69	99.69	99.70	99.69

Tablo 5.5. Önerilen model kullanılarak DREAMER veri setinin her bir kanala ait baskınlık (%) performansı

Kanal	Baskınlık			
	OA	Rec	Pr	F1
1	98.30	97.37	98.77	98.03
2	97.62	96.32	98.30	97.22
3	98.30	97.37	98.77	98.03
4	96.94	95.26	97.84	96.41
5	96.94	95.26	97.84	96.41
6	97.96	97.12	98.22	97.64
7	98.64	97.89	99.01	98.43
8	97.62	96.32	98.30	97.22
9	96.26	94.21	97.38	95.58
10	96.94	95.54	97.49	96.43
11	97.96	97.12	98.22	97.64
12	98.30	97.37	98.77	98.03
13	98.30	97.37	98.77	98.03
14	97.28	95.79	98.07	96.82

Ayrıca, DREAMER veri seti için oylanan sonuçlar Şekil 5.1’de gösterilmiştir. Önerilen PrimePatNet87’nin tüm durumlar için %100 doğruluk elde ettiği görülmüştür. Değerlilik ve uyarılma durumunda, yalnızca ilk üç kanal kullanılarak %100 sınıflandırma doğruluğuna, baskınlık durumunda, ilk altı kanal kullanılarak mükemmel sınıflandırma doğruluğuna ulaşılmıştır.



Şekil 5.1. DREAMER veri setini kullanan uyarılma, baskınlık ve değerlik durumları için çoğunluk oylaması sonuçları

Önerilen model DEAP veri seti kullanılarak hesaplanan 32 kanalın uyarılma ve değerlik performansları Tablo 5.6'da, baskınlık performansları Tablo 5.7'de gösterilmiştir. Tablo 5.6'da 19. kanal kullanılarak uyarılma durumu %86,34, 11. kanal kullanılarak değerlik durumu 89.40, Tablo 5.7'de 15. kanal kullanılarak baskınlık durumu %88,24 doğruluk elde edilmiş ve en iyi sonuç veren sonuçlar koyu renk ile gösterilmiştir.

Tablo 5.6. Önerilen modelin DEAP veri seti kullanılarak her bir kanala ait uyarılma ve değerlik (%) performansı

Uyarılma					Değerlik				
Kanal	OA	Pr	Rec	F1	Kanal	OA	Pr	Rc	F1
1	81.61	80.80	81.14	80.95	1	83.90	81.89	84.41	82.70
2	84.69	83.58	84.66	84.00	2	87.08	85.26	87.86	86.14
3	84.36	83.38	84.19	83.71	3	84.67	82.85	85.05	83.60
4	83.81	82.52	83.89	83.01	4	81.93	80.24	81.76	80.79
5	84.58	83.68	84.36	83.97	5	84.78	83.12	84.97	83.78
6	84.36	83.53	84.07	83.77	6	85.10	83.53	85.25	84.16
7	80.51	79.00	80.45	79.48	7	84.78	83.03	85.08	83.74
8	85.24	84.36	85.05	84.65	8	84.34	82.62	84.54	83.30
9	82.71	81.38	82.70	81.86	9	85.65	83.85	86.17	84.64
10	82.16	80.84	82.09	81.29	10	85.98	83.99	86.85	84.91
11	82.93	82.04	82.58	82.27	11	89.27	88.17	89.40	88.67
12	82.05	80.98	81.76	81.29	12	87.08	85.67	87.30	86.29
13	83.81	83.06	83.43	83.23	13	82.48	80.48	82.72	81.21
14	82.71	81.66	82.46	81.98	14	85.65	84.25	85.67	84.80
15	82.93	82.04	82.58	82.27	15	83.35	81.61	83.43	82.25
16	85.24	84.48	84.96	84.69	16	85.32	83.71	85.55	84.37
17	84.80	84.03	84.50	84.24	17	83.24	81.25	83.61	82.02
18	81.17	79.91	80.95	80.30	18	84.88	83.34	84.96	83.94
19	86.34	85.66	86.08	85.85	19	81.60	79.52	81.80	80.25
20	84.36	83.57	84.04	83.78	20	85.43	83.80	85.69	84.48
21	85.68	84.97	85.40	85.16	21	85.65	84.12	85.82	84.75
22	81.50	80.47	81.14	80.74	22	82.91	80.94	83.21	81.68
23	84.03	83.02	83.85	83.35	23	85.32	83.84	85.39	84.43
24	84.03	83.21	83.71	83.43	24	85.87	84.12	86.35	84.90
25	82.93	81.69	82.86	82.12	25	85.65	84.16	85.77	84.77
26	83.92	83.04	83.63	83.29	26	83.13	81.12	83.52	81.89
27	81.17	79.56	81.29	80.11	27	87.51	85.94	88.01	86.69
28	84.14	82.92	84.18	83.38	28	82.15	80.70	81.81	81.13

Tablo 5.6. (Devamı)

Uyarılma					Değerlik				
Kanal	OA	Pr	Rec	F1	Kanal	OA	Pr	Re	F1
29	82.49	81.24	82.39	81.66	29	85.43	84.52	85.02	84.74
30	82.38	81.65	81.91	81.77	30	86.09	84.39	86.53	85.15
31	84.80	83.79	84.69	84.15	31	87.73	86.30	88.07	86.97
32	85.24	84.17	85.23	84.58	32	86.09	84.44	86.47	85.16

Tablo 5.7. Önerilen modelin DEAP veri seti kullanılarak her bir kanala ait baskınlık (%) performansı


Baskınlık									
Kanal	OA	Rec	Pr	F1	Kanal	OA	Rec	Pr	F1
1	84.10	81.68	84.43	82.61	17	83.09	81.18	82.71	81.77
2	84.43	82.27	84.53	83.09	18	85.78	83.80	85.92	84.59
3	82.19	80.50	81.54	80.93	19	85.44	83.36	85.63	84.19
4	85.11	82.60	85.77	83.66	20	83.87	81.71	83.87	82.49
5	86.23	84.21	86.48	85.05	21	84.88	82.58	85.23	83.51
6	83.65	81.52	83.56	82.27	22	85.67	83.49	86.02	84.39
7	82.31	80.22	81.95	80.87	23	87.57	85.68	87.92	86.53
8	85.67	83.49	86.02	84.39	24	86.34	84.31	86.64	85.17
9	86.56	84.17	87.42	85.26	25	84.43	82.59	84.20	83.22
10	84.10	82.05	84.01	82.78	26	82.31	79.57	82.64	80.54
11	84.55	83.01	84.08	83.46	27	84.55	82.42	84.62	83.22
12	83.43	80.81	83.87	81.80	28	84.55	82.90	84.16	83.42
13	82.75	81.01	82.20	81.49	29	87.01	85.66	86.72	86.11
14	85.78	83.31	86.55	84.39	30	86.00	83.82	86.43	84.75
15	88.24	87.25	87.81	87.51	31	85.67	83.06	86.63	84.21
16	86.45	84.66	86.49	85.38	32	86.11	84.28	86.14	85.00

DREAMER ve GAMEMO veri setleri için %100 oylanan sonuçlar elde edilmiştir. Ancak DEAP veri seti için mükemmel sınıflandırma doğruluğuna ulaşamamıştır. DEAP veri seti için elde edilen çoğunluk oylama sonuçları Tablo 5.8'deki gibidir.

Tablo 5.8. Önerilen modelde DEAP veri seti kullanılarak elde edilen çoğunluk oylama sonuçları

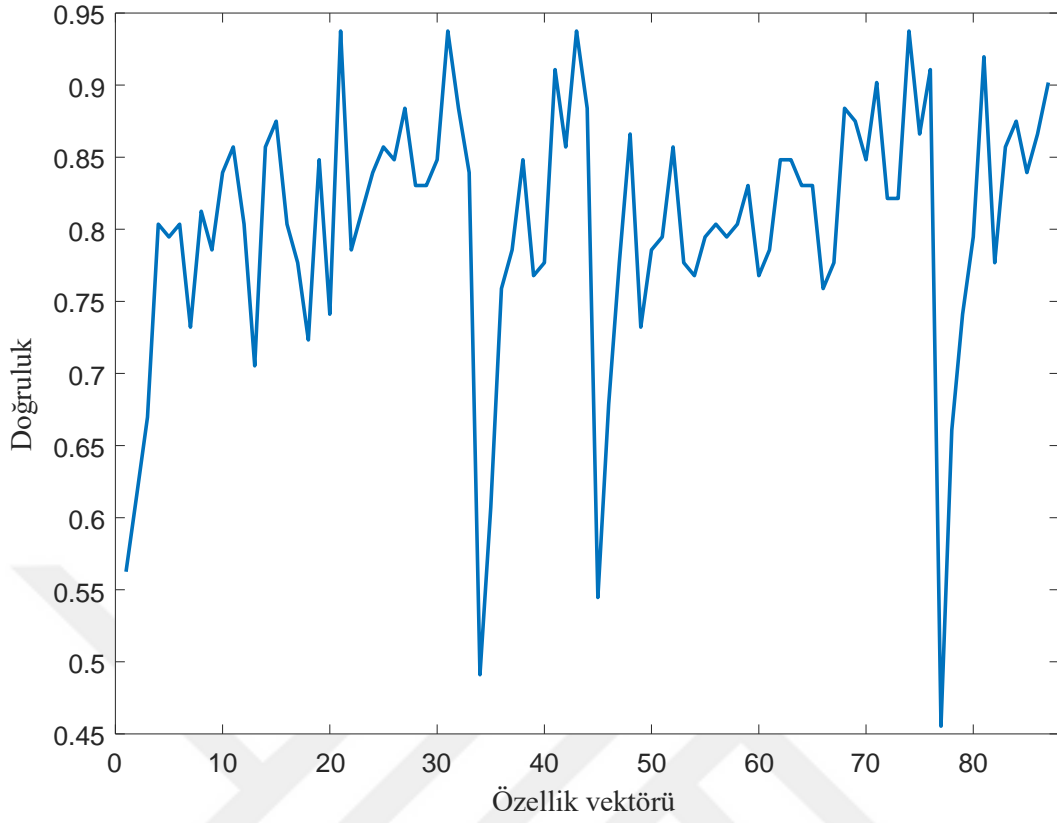
Durum	Kanal	OA	Rec	Pr	F1
Uyarılma	12	99.56	99.47	99.63	99.55
Baskınlık	32	99.55	99.42	99.64	99.53
Değerlik	22	99.67	99.59	99.73	99.66

DEAP veri seti için oylanan sınıflandırma doğrulukları Şekil 5.2’de gösterilmiştir. Sırasıyla uyarılma, baskınlık ve değerlik durumları için %99,56, %99,55 ve %99,67’lik en iyi sınıflandırma doğrulukları elde edilmiştir.




Şekil 5.2. Yinelemeli çoğunluk oylaması kullanılarak elde edilen kanal sayısına karşı doğruluk grafiği

Bu yöntemde, yeni bir histogram tabanlı özellik üretici tabanlı öğrenme modeli sunulmuştur. Asal sayıların özellik üretme yeteneği araştırılmış, asal indeksler kullanılarak, histogram tabanlı bir özellik oluşturucu sunulmuştur. Ayrıca, önerilen asal modelde bilgilendirici özellikler oluşturmak için çoklu çekirdekler kullanılmıştır ve sunulan üretici, düşük seviyelerde özellik çıkarmaktadır. Yüksek düzeyde özellik oluşturmak için, alt bantları oluşturmak için TQWT (özellik çıkarımı için verimli bir ayrıştırma yöntemi) ve TQWT radix ayrıştırma yöntemleri kullanılmıştır. Önerilen model, bu alt bantlardan yüksek seviyeli özellik üretmiştir. TQWT’de tanımlanan yüksek ve düşük salınım parametreler kullanılmıştır. Bu ayrıştırma yöntemlerini dağıtarak 86 alt bant oluşturulmuştur. Özellik oluşturma aşamasında, ilk 20 özellik vektörü TQWT, TQWT radix, asal model, mRMR seçici ve DVM sınıflandırıcı kullanılarak seçilmiştir. Özellik üretme aşamasında, her bir özellik vektörünün yanlış sınıflandırma oranı üretilmiş ve özellik vektörleri, yanlış sınıflandırma oranı kullanılarak nitelenmiştir. Şekil 5.3’te GAMEEMO veri seti için ilk EEG kanalı kullanılarak elde edilen özellik sayısına karşı yanlış sınıflandırma oranları (%) gösterilmiştir.



Şekil 5.3. GAMEMO veri seti için ilk EEG kanalı kullanılarak elde edilen özellik sayısına karşı yanlış sınıflandırma oranları (%) grafiği


En iyi özellik vektörü kullanarak %93,75 sınıflandırma oranı elde edilmiştir. Sınıflandırma yeteneğini artırmak için en iyi 20 özellik birleştirilmiş ardından özellik seçme aşamasında literatürdeki etkin özellik seçicilerden biri olan mRMR kullanılmıştır [88,89]. Bu nedenle, sınıflandırma için bir DVM sınıflandırıcı ile birleştirilmiş özellik seçici olarak kullanılmıştır. Özellik birleştirme, özellik seçimi ve Bayes optimizasyonu ile DVM ayarlaması kullanılarak doğruluk oranı %93,75'ten %100'e çıkarılmıştır. Ayrıca karar ağacı (KA) [97], lineer diskriminant (LD) [96], DVM [95], k en yakın komşu (kNN) [98] ve torbalı ağaç (TA) [90] olmak üzere birçok sınıflandırıcı kullanılmıştır. En iyi sonuçlar DVM sınıflandırıcı kullanılarak elde edilmiş, örnek test sonucu Şekil 5.4'te gösterilmiştir.



Şekil 5.4. GAMEMO veri seti için birinci kanalın beş sınıflandırıcı ile önerilen model kullanılarak elde edilen doğruluklar

Özellik seçim aşamasında evrişimli sinir ağlarında olduğu gibi 1000 özellik seçilmiş ve bu 1000 özellik DVM kullanılarak kanal bazında sonuçlar elde etmek için kullanılmıştır. Ayrıca, önerilen modeli çeşitli boyutlu özellik vektörleri kullanarak test edilmiş, Burada 250, 500, 750 ve 1000 özellikler kullanılarak DREAMER uyarılma durumu için elde edilmiş, sonuçlar Şekil 5.5'teki gibi gösterilmiştir.

Sunulan model olan PrimePatNet87, DREAMER veri setini kullanarak uyarılma, baskınlık ve değerlik durumları için %100 sınıflandırma doğruluğu elde etmiştir. Bu model DEAP veri setini kullanarak uyarılma, değerlik ve baskınlık durumlarında %99,56, %99,55 ve %99,67 doğruluklar elde edilmiştir. GAMEMO kullanılan üçüncü veri seti de %100 sınıflandırma doğruluğu elde edilmiştir.



Şekil 5.5. 250, 500, 750 ve 1000 özellikleri kullanılarak DREAMER uyarılma durumu için elde edilen doğruluklar

Önerilen modelin başarısı son teknoloji EEG duygu tanıma çalışmalarıyla karşılaştırılmıştır. GAMEEMO veri seti kullanılarak yapılan çalışmalar incelendiğinde Alakus vd. [1] ayrık dalgacık dönüşümü ve çok katmanlı algılayıcı sinir ağı yöntemini kullanarak %72,73; Tuncer vd. [55] Fraktal Fırat Örüntü yöntemini kullanarak %98,94 ve önerilen yöntem %100 doğruluk değeri olmak üzere en iyi sonuç vermiştir.

DREAMER veri seti kullanılarak yapılan çalışmalar incelendiğinde Topic ve Russo[50] uyarılma %90,43, değerlik %88,20; Liu vd. [91] uyarılma %89, değerlik %90,60, baskınlık %90,70; Song vd. [92] uyarılma %93,09, değerlik %92,82; Wang vd.[93] uyarılma %87,67, değerlik %89,91, baskınlık %90,28; önerilen yöntemde ise tek kanal DVM ile sınıflandırılarak uyarılma %99,66, değerlik %98,64, baskınlık %99,69; DVM ve çoğunluk oylaması ile sınıflandırılarak uyarılma, değerlik ve baskınlık %100 olmak üzere bu veri setinde de en iyi sonuç vermiştir.

DEAP veri seti kullanılarak yapılan çalışmalar incelendiğinde Khateeb vd. [99] %65,92, %65,72; Topic ve Russo[50] uyarılma %77,72, değerlik %76,61; Javidan vd. [100] değerlik %67,45; Al-Nafjan vd. [101] uyarılma %69,97, değerlik %84,62; Islam vd. [102] uyarılma %78,22, değerlik %74,92; Joshi ve Ghongade [103] uyarılma %76, değerlik %75,50; Joshi ve Ghongade [104] uyarılma %75, değerlik %73,50; Wang vd. [105] uyarılma %69,79, değerlik %66,47, değerlik %71,11; önerilen yöntemde ise tek kanal DVM ile sınıflandırılarak uyarılma %86,34, değerlik %88,24, baskınlık %89,27; DVM ve çoğunluk oylaması ile sınıflandırılarak uyarılma %99,56, değerlik %99,55 ve baskınlık %99,67 olmak üzere bu veri setinde de en iyi sonuç vermiştir.



6. SONUÇLAR

Bu tez çalışmasında EEG tabanlı duygu tanımada iki yeni yöntem önerilmiştir. Önerilen ilk yöntemin basit olması ve karmaşık bir hesaplama olmaması ayrıca düşük maliyetli olması, yöntemi avantaj haline getirmiştir. Bu çalışmada EEG duygu veri seti olarak GAMEEMO seçilmiştir. GAMEEMO veri seti 14 kanal içerdiği için 14 kanalın da doğruluk, hassasiyet, hatırlama ve f1 skor metrik performansları hesaplanmıştır. Önerilen yöntemin doğruluk değeri Tuncer vd. [55] ve Alakus vd. [1]'nin yöntemleriyle karşılaştırılmış, bu çalışmalara kıyasla yüksek başarıma sahip olduğu sonucuna ulaşılmıştır. Elde edilen bu sonuçlar önerilen yöntemin gerçek zamanlı uygulamalarda kullanılabileceğini göstermiştir.

İlk yöntemdeki eksiklik önerilen yöntem tek bir setine yani GAMEEMO uygulanarak doğrulama hesaplanmıştır. Gelecekteki çalışmalarda önerilen yöntem birden fazla EEG veri setlerine uygulanıp duygu tanıma yapılacaktır. Ayrıca otizim, parkinson, psikiyatri gibi duygularını göstermekte zorlanan hastaların yeni yöntemler geliştirerek önerilen yöntemle entegre edilmesi planlanmaktadır.

Önerilen ikinci yöntemde duygusal EEG veri setlerinde tek boyutlu sinyaller için yeni bir öğrenme modeli ile yüksek doğruluğa sahip otomatik duygu tanıma gerçekleştirilmiştir. Önerilen model özellik çıkarımı, özellik seçimi, sınıflandırma ve yinelemeli çoğunluk oylaması olmak üzere dört ana aşamadan oluşmaktadır. Sunulan modelin yeniliği, özellik üretimidir. Burada yeni bir özellik çıkarıcı asal örüntü önerilmiştir. Asal sayılar genellikle bilgi güvenliğinde kullanılmaktadır. Bu çalışmada, asal sayıların özellik üretme yeteneklerini araştırmaktadır. Önerilen model, DREAMER ve GAMEMO kullanılarak %100 doğruluğa ulaşmış ve DEAP veri seti ile %99,67 doğruluk sağlamıştır. Önerilen model olan PrimePatNet87'nin en son tekniklerle karşılaştırılmış en yüksek sınıflandırma doğruluğuna ulaştığı görülmüştür. Bu model, hastaların duygularını bulmak için tıp merkezlerinde ve psikiyatri kliniklerinde kullanılmaya hazırdır.

Önerilen model üç veri kümesi kullanarak geliştirilmiştir. Önerilen modelin sağlamlığını artırmak için daha fazla veri seti kullanılarak doğrulanması gerekmektedir. Ayrıca gelecekte, EEG sinyallerini kullanarak diğer duygu türlerinin sınıflandırılması hedeflenmektedir.

KAYNAKLAR

- [1] Alakus, T. B., Gonen, M., Turkoglu, I. (2020). Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO. *Biomedical Signal Processing and Control*, 60, 101951. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.101951>
- [2] Er, M. B., Çiğ, H., Aydılek, İ. B. (2021). A new approach to recognition of human emotions using brain signals and music stimuli. *Applied Acoustics*, 175, 107840. <https://doi.org/https://doi.org/10.1016/j.apacoust.2020.107840>
- [3] Hassouneh, A., Mutawa, A. M., Murugappan, M. (2020). Development of a Real-Time Emotion Recognition System Using Facial Expressions and EEG based on machine learning and deep neural network methods. *Informatics in Medicine Unlocked*, 20, 100372. <https://doi.org/https://doi.org/10.1016/j.imu.2020.100372>
- [4] Mehmood, R. M., Lee, H. J. (2016). A novel feature extraction method based on late positive potential for emotion recognition in human brain signal patterns. *Computers & Electrical Engineering*, 53, 444-457. <https://doi.org/https://doi.org/10.1016/j.compeleceng.2016.04.009>
- [5] Tivatansakul, S., Ohkura, M., Puangpontip, S., Achalakul, T. (2014). Emotional healthcare system: Emotion detection by facial expressions using Japanese database. 2014 6th computer science and electronic engineering conference (CEECE), pp. 41-46
- [6] Nakisa, B., Rastgoo, N., Tjondronegoro, D., Chandran, V. (2017). Evolutionary Computation Algorithms for Feature Selection of EEG-based Emotion Recognition using Mobile Sensors. *Expert Systems with Applications*, 93. <https://doi.org/10.1016/j.eswa.2017.09.062>
- [7] Zualkernan, I., Aloul, F., Shapsough, S., Hesham, A., El-Khorzaty, Y. (2017). Emotion recognition using mobile phones. *Computers & Electrical Engineering*, 60, 1-13. <https://doi.org/https://doi.org/10.1016/j.compeleceng.2017.05.004>
- [8] Krithika, L. B., Lakshmi Priya, G. G. (2016). Student Emotion Recognition System (SERS) for e-learning Improvement Based on Learner Concentration Metric. *Procedia Computer Science*, 85, 767-776. <https://doi.org/https://doi.org/10.1016/j.procs.2016.05.264>
- [9] ELEKTROENSEFALOGRAFİ, <http://www.itfnoroloji.org/semi2/eeg.htm>, Erişim: 12 Mart 2021
- [10] Iacoviello, D., Petracca, A., Spezialetti, M., Placidi, G. (2015). A real-time classification algorithm for EEG-based BCI driven by self-induced emotions. *Computer Methods and Programs in Biomedicine*, 122(3), 293-303. <https://doi.org/https://doi.org/10.1016/j.cmpb.2015.08.011>
- [11] Khezri, M., Firoozabadi, M., Sharafat, A. R. (2015). Reliable emotion recognition system based on dynamic adaptive fusion of forehead biopotentials and physiological signals. *Computer Methods and Programs in Biomedicine*, 122(2), 149-164. <https://doi.org/https://doi.org/10.1016/j.cmpb.2015.07.006>
- [12] Atkinson Lahane, P., Sangaiah, A. K. (2015). An Approach to EEG Based Emotion Recognition and Classification Using Kernel Density Estimation. *Procedia Computer Science*, 48, 574-581. <https://doi.org/https://doi.org/10.1016/j.procs.2015.04.138>
- [13] Placidi, G., Avola, D., Petracca, A., Sgallari, F., Spezialetti, M. (2015). Basis for the implementation of an EEG-based single-trial binary brain computer interface through the disgust produced by remembering unpleasant odors. *Neurocomputing*, 160, 308-318. <https://doi.org/https://doi.org/10.1016/j.neucom.2015.02.034>
- [14] Zheng, W., Lu, B. (2015). Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. *IEEE Transactions on Autonomous Mental Development*, 7(3), 162-175. <https://doi.org/10.1109/TAMD.2015.2431497>
- [15] Zhang, Y., Ji, X., Zhang, S. (2016). An approach to EEG-based emotion recognition using combined feature extraction method. *Neuroscience Letters*, 633, 152-157. <https://doi.org/https://doi.org/10.1016/j.neulet.2016.09.037>
- [16] Koelstra, S., Muhl, C., Soleymani, M., Lee, J., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., Patras, I. (2012). DEAP: A Database for Emotion Analysis ;Using Physiological Signals. *IEEE*

- Transactions on Affective Computing, 3(1), 18-31. <https://doi.org/10.1109/T-AFFC.2011.15>
- [17] Atkinson, J., Campos, D. (2016). Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers. *Expert Systems with Applications*, 47, 35-41. <https://doi.org/https://doi.org/10.1016/j.eswa.2015.10.049>
- [18] Kumar, N., Khaund, K., Hazarika, S. M. (2016). Bispectral Analysis of EEG for Emotion Recognition. *Procedia Computer Science*, 84, 31-35. <https://doi.org/https://doi.org/10.1016/j.procs.2016.04.062>
- [19] Bhatti, A. M., Majid, M., Anwar, S. M., Khan, B. (2016). Human emotion recognition and analysis in response to audio music using brain signals. *Computers in Human Behavior*, 65, 267-275. <https://doi.org/https://doi.org/10.1016/j.chb.2016.08.029>
- [20] Bradley, M., Cuthbert, B., Lang, P. (2005). International Affective Picture System: Technical manual and affective ratings. NIMH Center for the Study of Emotion and Attention.
- [21] Bong, S. Z., Wan, K., Murugappan, M., Ibrahim, N. M., Rajamanickam, Y., Mohamad, K. (2017). Implementation of wavelet packet transform and non linear analysis for emotion classification in stroke patient using brain signals. *Biomedical Signal Processing and Control*, 36, 102-112. <https://doi.org/https://doi.org/10.1016/j.bspc.2017.03.016>
- [22] Lang, P. J. (2005). International affective picture system (IAPS): Affective ratings of pictures and instruction manual. Technical report.
- [23] Bradley, M. M., Lang, P. J. (1999). International affective digitized sounds (IADS): Stimuli, instruction manual and affective ratings (Tech. Rep. No. B-2). Gainesville, FL: The Center for Research in Psychophysiology, University of Florida.
- [24] Alhagry, S., Fahmy, A. A., El-Khoribi, R. A. (2017). Emotion recognition based on EEG using LSTM recurrent neural network. *Emotion*, 8(10), 355-358.
- [25] Zheng, W.-L., Zhu, J.-Y., Lu, B.-L. (2017). Identifying stable patterns over time for emotion recognition from EEG. *IEEE Transactions on Affective Computing*.
- [26] Mert, A., Akan, A. (2018). Emotion recognition based on time–frequency distribution of EEG signals using multivariate synchrosqueezing transform. *Digital Signal Processing*, 81, 106-115. <https://doi.org/https://doi.org/10.1016/j.dsp.2018.07.003>
- [27] Al Zoubi, O., Awad, M., Kasabov, N. K. (2018). Anytime multipurpose emotion recognition from EEG data using a Liquid State Machine based framework. *Artificial Intelligence in Medicine*, 86, 1-8. <https://doi.org/https://doi.org/10.1016/j.artmed.2018.01.001>
- [28] Kaur, B., Singh, D., Roy, P. P. (2018). EEG Based Emotion Classification Mechanism in BCI. *Procedia Computer Science*, 132, 752-758. <https://doi.org/https://doi.org/10.1016/j.procs.2018.05.087>
- [29] Chakladar, D. D., Chakraborty, S. (2018). EEG based emotion classification using “Correlation Based Subset Selection”. *Biologically Inspired Cognitive Architectures*, 24, 98-106. <https://doi.org/https://doi.org/10.1016/j.bica.2018.04.012>
- [30] Su, Y., Chen, P., Liu, X., Li, W., Lv, Z. (2018). A spatial filtering approach to environmental emotion perception based on electroencephalography. *Medical Engineering & Physics*, 60, 77-85. <https://doi.org/https://doi.org/10.1016/j.medengphy.2018.07.009>
- [31] Shawky, E., El-Khoribi, R., Shoman, M., Wahby Shalaby, M. (2018). EEG-Based Emotion Recognition using 3D Convolutional Neural Networks. *International Journal of Advanced Computer Science and Applications*, 9, 329.
- [32] Taran, S., Bajaj, V. (2019). Emotion recognition from single-channel EEG signals using a two-stage correlation and instantaneous frequency-based filtering method. *Computer Methods and Programs in Biomedicine*, 173, 157-165. <https://doi.org/https://doi.org/10.1016/j.cmpb.2019.03.015>
- [33] Pandey, P., Seeja, K. R. (2019). Subject independent emotion recognition from EEG using VMD and deep learning. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/https://doi.org/10.1016/j.jksuci.2019.11.003>

- [34] Liang, Z., Oba, S., Ishii, S. (2019). An unsupervised EEG decoding system for human emotion recognition. *Neural Networks*, 116, 257-268. <https://doi.org/https://doi.org/10.1016/j.neunet.2019.04.003>
- [35] Zangeneh Soroush, M., Maghooli, K., Setarehdan, S. K., Nasrabadi, A. M. (2019). Emotion recognition through EEG phase space dynamics and Dempster-Shafer theory. *Medical Hypotheses*, 127, 34-45. <https://doi.org/https://doi.org/10.1016/j.mehy.2019.03.025>
- [36] Qayyum, H., Majid, M., Haq, E. u., Anwar, S. M. (2019). Generation of personalized video summaries by detecting viewer's emotion using electroencephalography. *Journal of Visual Communication and Image Representation*, 65, 102672. <https://doi.org/https://doi.org/10.1016/j.jvcir.2019.102672>
- [37] Masruroh, A. H., Imah, E. M., Rahmawati, E. (2019). Classification of Emotional State Based on EEG Signal using AMGLVQ. *Procedia Computer Science*, 157, 552-559. <https://doi.org/https://doi.org/10.1016/j.procs.2019.09.013>
- [38] Lan, Z., Sourina, O., Wang, L., Scherer, R., Müller-Putz, G. R. (2019). Domain Adaptation Techniques for EEG-Based Emotion Recognition: A Comparative Study on Two Public Datasets. *IEEE Transactions on Cognitive and Developmental Systems*, 11(1), 85-94. <https://doi.org/10.1109/TCDS.2018.2826840>
- [39] Qing, C., Qiao, R., Xu, X., Cheng, Y. (2019). Interpretable Emotion Recognition Using EEG Signals. *IEEE Access*, 7, 94160-94170. <https://doi.org/10.1109/ACCESS.2019.2928691>
- [40] Hou, H.-R., Zhang, X.-N., Meng, Q.-H. (2020). Odor-induced emotion recognition based on average frequency band division of EEG signals. *Journal of Neuroscience Methods*, 334, 108599. <https://doi.org/https://doi.org/10.1016/j.jneumeth.2020.108599>
- [41] Zhou, J., Chu, S., Li, X., Xiao, F., Sun, L. (2021). An EEG emotion recognition method based on transfer learning and echo state network for HilCPS. *Microprocessors and Microsystems*, 87, 103381. <https://doi.org/https://doi.org/10.1016/j.micpro.2020.103381>
- [42] Chen, T., Ju, S., Ren, F., Fan, M., Gu, Y. (2020). EEG emotion recognition model based on the LIBSVM classifier. *Measurement*, 164, 108047. <https://doi.org/https://doi.org/10.1016/j.measurement.2020.108047>
- [43] Garg, D., Verma, G. K. (2020). Emotion Recognition in Valence-Arousal Space from Multi-channel EEG data and Wavelet based Deep Learning Framework. *Procedia Computer Science*, 171, 857-867. <https://doi.org/https://doi.org/10.1016/j.procs.2020.04.093>
- [44] Wei, C., Chen, L.-l., Song, Z.-z., Lou, X.-g., Li, D.-d. (2020). EEG-based emotion recognition using simple recurrent units network and ensemble learning. *Biomedical Signal Processing and Control*, 58, 101756. <https://doi.org/https://doi.org/10.1016/j.bspc.2019.101756>
- [45] Wang, F., Wu, S., Zhang, W., Xu, Z., Zhang, Y., Wu, C., Coleman, S. (2020). Emotion recognition with convolutional neural network and EEG-based EFDMs. *Neuropsychologia*, 146, 107506. <https://doi.org/10.1016/j.neuropsychologia.2020.107506>
- [46] Moon, S.-E., Chen, C.-J., Hsieh, C.-J., Wang, J.-L., Lee, J.-S. (2020). Emotional EEG classification using connectivity features and convolutional neural networks. *Neural Networks*, 132, 96-107. <https://doi.org/https://doi.org/10.1016/j.neunet.2020.08.009>
- [47] Yin, Z., Liu, L., Chen, J., Zhao, B., Wang, Y. (2020). Locally robust EEG feature selection for individual-independent emotion recognition. *Expert Systems with Applications*, 162, 113768. <https://doi.org/https://doi.org/10.1016/j.eswa.2020.113768>
- [48] Maheshwari, D., Ghosh, S. K., Tripathy, R. K., Sharma, M., Acharya, U. R. (2021). Automated Accurate Emotion Recognition System using Rhythm-Specific Deep Convolutional Neural Network Technique with Multi-Channel EEG Signals. *Computers in Biology and Medicine*, 104428. <https://doi.org/https://doi.org/10.1016/j.compbimed.2021.104428>
- [49] Salankar, N., Mishra, P., Garg, L. (2021). Emotion recognition from EEG signals using empirical mode decomposition and second-order difference plot. *Biomedical Signal Processing and Control*, 65, 102389. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.102389>

- [50] Topic, A., Russo, M. (2021). Emotion recognition based on EEG feature maps through deep learning network. *Engineering Science and Technology, an International Journal*. <https://doi.org/https://doi.org/10.1016/j.jestch.2021.03.012>
- [51] Huang, D., Chen, S., Liu, C., Zheng, L., Tian, Z., Jiang, D. (2021). Differences first in asymmetric brain: A bi-hemisphere discrepancy convolutional neural network for EEG emotion recognition. *Neurocomputing*, 448, 140-151. <https://doi.org/https://doi.org/10.1016/j.neucom.2021.03.105>
- [52] Yin, Y., Zheng, X., Hu, B., Zhang, Y., Cui, X. (2021). EEG emotion recognition using fusion model of graph convolutional neural networks and LSTM. *Applied Soft Computing*, 100, 106954. <https://doi.org/https://doi.org/10.1016/j.asoc.2020.106954>
- [53] Naser, D. S., Saha, G. (2021). Influence of music liking on EEG based emotion recognition. *Biomedical Signal Processing and Control*, 64, 102251. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.102251>
- [54] Cheng, J., Chen, M., Li, C., Liu, Y., Song, R., Liu, A., Chen, X. (2021). Emotion Recognition From Multi-Channel EEG via Deep Forest. *IEEE Journal of Biomedical and Health Informatics*, 25(2), 453-464. <https://doi.org/10.1109/JBHI.2020.2995767>
- [55] Tuncer, T., Dogan, S., Subasi, A. (2021). A new fractal pattern feature generation function based emotion recognition method using EEG. *Chaos, Solitons & Fractals*, 144, 110671. <https://doi.org/https://doi.org/10.1016/j.chaos.2021.110671>
- [56] Tuncer, T., Dogan, S., Tanko, D., Sakoglu, U. (2021). EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier. *Biomedical Signal Processing and Control*, 68, 102648. <https://doi.org/https://doi.org/10.1016/j.bspc.2021.102648>
- [57] Scherer, K. R. (2005). What are emotions? And how can they be measured? *Social science information*, 44(4), 695-729.
- [58] Ekman, P. (1992). An argument for basic emotions. *Cognition & emotion*, 6(3-4), 169-200.
- [59] Russell, J. (2003). Core Affect and the Psychological Construction of Emotion. *Psychological review*, 110, 145-172. <https://doi.org/10.1037//0033-295X.110.1.145>
- [60] Klimesch, W. (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. *Brain Research Reviews*, 29(2), 169-195. [https://doi.org/https://doi.org/10.1016/S0165-0173\(98\)00056-3](https://doi.org/https://doi.org/10.1016/S0165-0173(98)00056-3)
- [61] Zheng, W., Zhu, J., Peng, Y., Lu, B. (2014). EEG-based emotion classification using deep belief networks. 2014 IEEE International Conference on Multimedia and Expo (ICME), pp. 1-6
- [62] Dadebayev, D., Goh, W. W., Tan, E. X. (2021). EEG-based emotion recognition: Review of commercial EEG devices and machine learning techniques. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/https://doi.org/10.1016/j.jksuci.2021.03.009>
- [63] Javaid, M. M., Yousaf, M., Sheikh, Q., Awais, M., Saleem, S., Khalid, M. (2015). Real-Time EEG-based Human Emotion Recognition. https://doi.org/10.1007/978-3-319-26561-2_22
- [64] Brody, L. R., & Hall, J. A. (2008). Gender and emotion in context. *Handbook of emotions*, 3, 395-408.
- [65] Demenescu, L. R., Mathiak, K. A., Mathiak, K. (2014). Age- and Gender-Related Variations of Emotion Recognition in Pseudowords and Faces. *Experimental Aging Research*, 40(2), 187-207. <https://doi.org/10.1080/0361073X.2014.882210>
- [66] Liu, Y., Sourina, O. (2013). EEG Databases for Emotion Recognition, pp. 302-309. <https://doi.org/10.1109/CW.2013.52>
- [67] Emotiv, <https://www.emotiv.com/get-started/>, Eriřim: 20.04.2021.
- [68] Sarac, M., Koyas Kalafat, E., Erdogan, A., Cetin, M., Patoglu, V. (2013). Brain Computer Interface based robotic rehabilitation with online modification of task speed. *IEEE ... International Conference on Rehabilitation Robotics : [proceedings]*, 2013, 1-7. <https://doi.org/10.1109/ICORR.2013.6650423>
- [69] Sousa Galito, M. (2018). An Essay on Populism. In (pp. 88-133).

- [70] NeuroSky, <http://neurosky.com/biosensors/eeg-sensor/biosensors/>, Erişim: 22.04.2021.
- [71] Alarcão, S. M., Fonseca, M. J. (2019). Emotions Recognition Using EEG Signals: A Survey. *IEEE Transactions on Affective Computing*, 10(3), 374-393. <https://doi.org/10.1109/TAFFC.2017.2714671>
- [72] Nicolas-Alonso, L. F., Gomez-Gil, J. (2012). Brain computer interfaces, a review. *sensors*, 12(2), 1211-1279.
- [73] Liu, Y.-J., Yu, M., Zhao, G., Song, J., Ge, Y., Shi, Y. (2017). Real-time movie-induced discrete emotion recognition from EEG signals. *IEEE Transactions on Affective Computing*, 9(4), 550-562.
- [74] Li, Z., Qiu, L., Li, R., He, Z., Xiao, J., Liang, Y., Wang, F., Pan, J. (2020). Enhancing BCI-Based emotion recognition using an improved particle swarm optimization for feature selection. *Sensors*, 20(11), 3028.
- [75] Katsigiannis, S., Ramzan, N. (2017). DREAMER: A database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices. *IEEE journal of biomedical and health informatics*, 22(1), 98-107.
- [76] Soleymani, M., Lichtenauer, J., Pun, T., Pantic, M. (2011). A multimodal database for affect recognition and implicit tagging. *IEEE transactions on affective computing*, 3(1), 42-55.
- [77] Jenke, R., Peer, A., Buss, M. (2014). Feature Extraction and Selection for Emotion Recognition from EEG. *IEEE Transactions on Affective Computing*, 5(3), 327-339. <https://doi.org/10.1109/TAFFC.2014.2339834>
- [78] Pradhan, N., Dutt, D. N. (1993). Use of running fractal dimension for the analysis of changing patterns in electroencephalograms. *Computers in biology and medicine*, 23(5), 381-388.
- [79] Chatlani, N., Soraghan, J. (2010). Local binary patterns for 1-D signal processing. 95-99.
- [80] Kaya, Y., Uyar, M., Tekin, R., Yıldırım, S. (2014). 1D-local binary pattern based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*, 243, 209-219. <https://doi.org/https://doi.org/10.1016/j.amc.2014.05.128>
- [81] Lantz, B. (2013). *Machine learning with R*. Packt publishing ltd.
- [82] Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of translational medicine*, 4(11).
- [83] Murugappan, M., Ramachandran, N., Sazali, Y. (2010). Classification of human emotion from EEG using discrete wavelet transform. *Journal of biomedical science and engineering*, 3(04), 390.
- [84] Zubair, M., Yoon, C. (2018). EEG based classification of human emotions using discrete wavelet transform. In *IT Convergence and Security 2017* (pp. 21-28). Springer.
- [85] Baldi, P., Brunak, S., Chauvin, Y., Andersen, C. A. F., Nielsen, H. (2000). Assessing the accuracy of prediction algorithms for classification: an overview. *Bioinformatics*, 16(5), 412-424. <https://doi.org/10.1093/bioinformatics/16.5.412>
- [86] Arlot, S., Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics surveys*, 4, 40-79.
- [87] Selesnick, I. W. (2011). Wavelet Transform With Tunable Q-Factor. *IEEE Transactions on Signal Processing*, 59(8), 3560-3575. <https://doi.org/10.1109/TSP.2011.2143711>
- [88] Ding, C., Peng, H. (2005). Peng, H.: Minimum Redundancy Feature Selection from Microarray Gene Expression Data. *Journal of Bioinformatics and Computational Biology* 3(2), 185-205. *Journal of bioinformatics and computational biology*, 3, 185-205. <https://doi.org/10.1142/S0219720005001004>
- [89] Wang, J., Zhang, D., Li, J. (2013). PREAL: Prediction of allergenic protein by maximum Relevance Minimum Redundancy (mRMR) feature selection. *BMC systems biology*, 7 Suppl 5, S9. <https://doi.org/10.1186/1752-0509-7-S5-S9>
- [90] Hothorn, T., Lausen, B. (2003). Lausen, B.: Bagging tree classifiers for laser scanning images: a data- and simulation-based strategy. *Artificial Intelligence in Medicine* 27(1), 65-79. *Artificial intelligence in medicine*, 27, 65-79. [https://doi.org/10.1016/S0933-3657\(02\)00085-4](https://doi.org/10.1016/S0933-3657(02)00085-4)

- [91] Liu, W., Qiu, J. L., Zheng, W. L., Lu, B. L. (2021). Comparing recognition performance and robustness of multimodal deep learning models for multimodal emotion recognition. *IEEE Transactions on Cognitive and Developmental Systems*, 1-1. doi:10.1109/TCDS.2021.3071170
- [92] Song, T., Liu, S., Zheng, W., Zong, Y., Cui, Z., Li, Y., Zhou, X. (2021). Variational instance-adaptive graph for eeg emotion recognition. *IEEE Transactions on Affective Computing*, 1-1. doi:10.1109/TAFFC.2021.3064940
- [93] Wang, Z., Gu, T., Zhu, Y., Li, D., Yang, H., Du, W. (2021). Fldnet: Frame-level distilling neural network for eeg emotion recognition. *IEEE Journal of Biomedical and Health Informatics*, 25(7), 2533-2544. doi:10.1109/JBHI.2021.3049119
- [94] Bradley, M. M., Lang, P. J. (1994). Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry*, 25(1), 49-59. doi:https://doi.org/10.1016/0005-7916(94)90063-9
- [95] Vapnik V. (1998) The Support Vector Method of Function Estimation. In: Suykens J.A.K., Vandewalle J. (eds) *Nonlinear Modeling*. Springer, Boston, MA. https://doi.org/10.1007/978-1-4615-5703-6_3
- [96] Zhao, W., Chellappa, R., Nandhakumar, N. (1998, 25-25 June 1998). Empirical performance analysis of linear discriminant classifiers. Paper presented at the Proceedings. 1998 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (Cat. No.98CB36231).
- [97] Safavian, S. R., Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 660-674. doi:10.1109/21.97458
- [98] Maillo, J., Ramírez, S., Triguero, I., Herrera, F. (2017). Knn-is: An iterative spark-based design of the k-nearest neighbors classifier for big data. *Knowledge-Based Systems*, 117, 3-15. doi:https://doi.org/10.1016/j.knosys.2016.06.012
- [99] Khateeb, M., Anwar, S. M., Alnowami, M. (2021). Multi-domain feature fusion for emotion classification using deep dataset. *IEEE Access*, 9, 12134-12142. doi:10.1109/ACCESS.2021.3051281
- [100] Javidan, M., Yazdchi, M., Baharlouei, Z., Mahnam, A. (2021). Feature and channel selection for designing a regression-based continuous-variable emotion recognition system with two eeg channels. *Biomedical Signal Processing and Control*, 70, 102979. doi:https://doi.org/10.1016/j.bspc.2021.102979
- [101] Al-Nafjan, A., Alharthi, K., Kurdi, H. (2020). Lightweight building of an electroencephalogram-based emotion detection system. *Brain Sciences*, 10(11), 781.
- [102] Islam, M. R., Islam, M. M., Rahman, M. M., Mondal, C., Singha, S. K., Ahmad, M., Awal, A., Islam, M. S., Moni, M. A. (2021). EEG Channel Correlation Based Model for Emotion Recognition. *Computers in Biology and Medicine*, 136, 104757. https://doi.org/https://doi.org/10.1016/j.compbimed.2021.104757
- [103] Joshi, V., Ghongade, R. (2021). Eeg based emotion detection using fourth order spectral moment and deep learning. *Biomedical Signal Processing and Control*, 68, 102755. doi:10.1016/j.bspc.2021.102755
- [104] Joshi, V. M., Ghongade, R. B. (2020). Idea: Intellect database for emotion analysis using eeg signal. *Journal of King Saud University - Computer and Information Sciences*. doi:https://doi.org/10.1016/j.jksuci.2020.10.007
- [105] Wang, Y., Qiu, S., Ma, X., He, H. (2020). A prototype-based spd matrix network for domain adaptation eeg emotion recognition. *Pattern Recognition*, 110, 107626. doi:10.1016/j.patcog.2020.107626

