

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTROENSEFALOGRAFİ (EEG) SİNYALİ KULLANILARAK
YAPAY ZEKA TABANLI DUYGU KESTİRİMİ

YÜKSEK LİSANS TEZİ

Elif ÇAVUŞ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

TEMMUZ 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTROENSEFALOGRAFİ (EEG) SİNYALİ KULLANILARAK
YAPAY ZEKA TABANLI DUYGU KESTİRİMİ

YÜKSEK LİSANS TEZİ

Elif ÇAVUŞ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Mehmet Recep BOZKURT

TEMMUZ 2024

Elif ÇAVUŞ tarafından hazırlanan “ELEKTROENSEFALOGRAFİ (EEG) SİNYALİ KULLANILARAK YAPAY ZEKA TABANLI DUYGU KESTİRİMİ” adlı tez çalışması 16.07.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik Mühendisliği Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : Unvan Adı SOYADI (Danışman)
..... Üniversitesi

Jüri Üyesi : Unvan Adı SOYADI
..... Üniversitesi

Jüri Üyesi : Unvan Adı SOYADI
..... Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “**ELEKTROENSEFALOGRAFİ (EEG) SİNYALİ KULLANILARAK YAPAY ZEKA TABANLI DUYGU KESTİRİMİ**” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

Elif ÇAVUŞ

28.05.2024





Sevgili aileme...



TEŞEKKÜR

Bu tez çalışmasının her aşamasında bana rehberlik eden, bilgi ve tecrübelerini cömertçe paylaşarak desteğini hep yanımda hissettiren değerli tez danışmanım Prof. Dr. Mehmet Recep BOZKURT'a sonsuz teşekkürlerimi sunarım.

Ayrıca bu zorlu süreçte sabır ve anlayışlarıyla yanımda olan aileme ve sevdiklerime minnettarlığımı ifade etmek isterim.

Elif ÇAVUŞ





İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Genel Bilgiler	1
1.2. Tezin Amacı ve Önemi	2
1.3. Literatür İncelemesi	2
1.4. Tez Organizasyonu	6
2. EEG TABANLI DUYGU TANIMA	7
2.1. Merkezi Sinir Sistemi ve Beyin	7
2.2. Beyin Aktivitesinin Ölçümü	12
2.3. Elektroensefalografi	14
2.4. EEG Elektrot Sistemi	17
2.5. Duyusal Durumlar ve Modelleme	18
2.6. EEG Tabanlı Duygu Tanıma Süreci	22
2.6.1. Katılımcıların seçilmesi ve deney kurgusu	24
3. MALZEME VE YÖNTEM	27
3.1. Duygu Durum Veri Kümesi	27
3.2. Duygu Durum Analizi	29
3.2.1. EEG ön işleme süreci	29
3.2.1.1. Kanal seçimi	30
3.2.1.2. Örneklem hızının Düşürülmesi	30
3.2.1.3. Filtreleme	30
3.2.2. Özellik çıkarma	31
3.2.3. Özellik sıralama	35
3.2.4. Sınıflandırma	35
3.3. Sınıflandırma Performansı	38
4. BULGULAR VE SONUÇLAR	41
5. SONUÇ VE TARTIŞMA	53
KAYNAKLAR	59
ÖZGEÇMİŞ	65



KISALTMALAR

ACF	:Otokorelasyon Fonksiyonu
BCI	:Beyin-Bilgisayar Arayüzü
CNN	:Evrişimsel Sinir Ağları (Convolutional Neural Networks)
EEG	:Elektroensefalografi
EKG	:Elektrokardiyogram
EMG	:Elektromiyogram
EOG	:Elektrookülogram
FN	:Yanlış Negatif (False Negative)
FP	:Yanlış Pozitif (False Positive)
fMRI	:Fonksiyonel Manyetik Rezonans Görüntüleme
GBM	:Gradient Boosting Machines
HR	:Kalp Atış Hızı
IADS	:Uluslararası Duygusal Dijital Sesler
IAPS	:Uluslararası Duygusal Resim Sistemi
ICA	: Bağımsız Bileşen Analizi
IQR	: Çeyrekler Arası Genişlik
MEG	: Manyetoensefalografi
NIR	: Yakın Kızılötesi Işık
NN	: Sinir Ağları
PANAS	: Pozitif ve Negatif Duygulanım Ölçeği
PACF	: Parsiyel Otokorelasyon Fonksiyonu
PET	: Pozitron Emisyon Tomografisi
RF	: Rastgele Orman
SEED IV	: The SJTU Emotion EEG Dataset IV
SVD	: Tekil Değer Ayırımı
SVM	: Destek Vektör Makinesi
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
VR	: Sanal Gerçeklik



SİMGELER

α	: Alfa Dalgası
B	: Bootstrap örneği
β	: Beta Dalgası
d_i	: i . terim sıralama farkı
δ	: Delta Dalgası
$f_{avg}(x)$	: x için yapılan tahmin değeri
Fs	: Örnekleme frekansı
G	: Geometrik ortalama
γ	: Gama Dalgası
Hz	: Hertz
K	: Deneme sayısı
n	: Veri setindeki örnek sayısı
ρ	: Spearman korelasyon katsayısı
s	: Saniye
S	: Standart sapma
T	: Ensemble modeli
θ	: Teta Dalgası



TABLO LİSTESİ

Sayfa

Tablo 2.1. EEG frekans alt bantları ve özellikleri [25].	15
Tablo 2.2. Uluslararası 10-20 sistemine ait gösterimler [31].	17
Tablo 2.3. Duygu durum modellemeleri ve özellikleri.	22
Tablo 3.1. Deneyde kullanılan klipler ve sınıfları [44]	28
Tablo 3.2. Çıkarılan özellikler ve tanımlayıcı denklemler.	33
Tablo 4.1. Model karmaşıklık matrisi.	41
Tablo 4.2. Model performans değerlendirmesi.	42
Tablo 4.3. Delta bandı için karmaşıklık matrisi.	48
Tablo 4.4. Delta bandı performans değerlendirmesi	48
Tablo 4.5. Teta bandı için karmaşıklık matrisi	49
Tablo 4.6. Teta bandı performans değerlendirmesi	49
Tablo 4.7. Alfa bandı için karmaşıklık matrisi	49
Tablo 4.8. Alfa bandı performans değerlendirmesi	50
Tablo 4.9. Beta bandı için karmaşıklık matrisi	50
Tablo 4.10. Beta bandı performans değerlendirmesi	50
Tablo 4.11. Gama bandı için karmaşıklık matrisi	51
Tablo 4.12. Gama bandı performans değerlendirmesi	51
Tablo 5.1. Ensemble Bagged Trees modeli performans değerlendirmesi	55



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. İnsan beyninin ana bölümleri	8
Şekil 2.2. Tipik bir sinir hücresinin bölümleri	9
Şekil 2.3. Aksiyon potansiyelinin yayılımı.....	11
Şekil 2.4. Gerçek zamanlı EEG verisi	15
Şekil 2.5. EEG alt bantlarının genlik, frekans ve dalga formları.....	16
Şekil 2.6. Uluslararası 10-20 elektrot sistemi	18
Şekil 2.7. Uluslararası 10-20 sistemi yerleşimi	18
Şekil 2.8. Valans-uyarılma 2B duygu düzlemi	20
Şekil 2.9. 3 Boyutlu duygu modeli	21
Şekil 2.10. EEG tabanlı duygu durum analizi adımları.	23
Şekil 3.1. Gerçekleştirilen deney planı	27
Şekil 3.2. SEED EEG duygu durum analizi adımları	29
Şekil 3.3. Seçilen simetrik temporal elektrotlar	30
Şekil 3.4. Band geçiren filtre diyagramı	31
Şekil 3.5. Spearman korelasyon katsayısı hesaplama	35
Şekil 3.6. Ensemble Bagged Trees modeli.	37
Şekil 4.1. Değerlendirme matrisi “TPR ve FNR”.....	43
Şekil 4.2. Değerlendirme matrisi “PPV ve FDR”	44
Şekil 4.3. Nötr sınıfı için elde edilen ROC eğrisi.	45
Şekil 4.4. Üzüntü sınıfı için elde edilen ROC eğrisi.....	45
Şekil 4.5. Korku sınıfı için elde edilen ROC eğrisi.	46
Şekil 4.6. Mutluluk sınıfı için elde edilen ROC eğrisi.....	47
Şekil 4.7. Tüm sınıflar için elde edilen ROC eğrileri.	47



ELEKTROENSEFALOGRAFİ (EEG) SİNYALİ KULLANILARAK YAPAY ZEKA TABANLI DUYGU KESTİRİMİ

ÖZET

Duyguların nörolojik temellerini anlamak ve tanımlamak, insan-makine etkileşimi alanında her geçen gün artan bir öneme sahiptir. Bu bağlamda, EEG (Elektroensefalografi), duygusal durumları analiz etmek için yüksek zamansal çözünürlüklü bir yöntem olarak dikkat çekmektedir ve Yapay Zekâ yöntemlerinin çeşitlenmesiyle birlikte yapılan çalışmalar hız kazanmıştır. EEG sinyalleri, beynin elektriksel aktivitelerini ölçerek duygusal ve zihinsel durumları objektif bir şekilde değerlendirme imkânı sunar. Ancak EEG sinyallerinin karmaşıklığı ve dış etkenlerden kolayca etkilenmesi nedeniyle doğru ve tutarlı analiz metodlarına ihtiyaç vardır. Bu çalışmada, SEED EEG veri seti kullanılarak EEG tabanlı duygu tanıma için Ensemble Bagged Trees modeli önerilmiştir.

SEED veri seti, 15 sağlıklı katılımcının 62 kanallı EEG sinyallerini içermektedir. Katılımcılara çeşitli duygusal tepkileri tetiklemek amacıyla belirli film klipleri izletilmiş ve bu sırada EEG verileri 1000 Hz örnekleme hızında kaydedilmiştir. Verilerin ön işleme sürecinde, EEG sinyalleri filtrelenmiş, örnekleme hızı 200 Hz'e düşürülmüş ve artefaktlar (örneğin, göz kırpması ve kas hareketleri) giderilmiştir. Bu işlemler, sinyal/gürültü oranını artırarak, verilerin daha doğru ve güvenilir analiz edilmesini sağlamıştır.

Özellik çıkarma aşamasında, EEG verileri delta, teta, alfa, beta ve gama olarak temel frekans bantlarına ayrılmıştır. Her bir bant için zaman domeni ve istatistiksel özellikler hesaplanmış ve bu özellikler, duygu tanıma modellerinin eğitiminde kullanılmıştır. Özellikle otokorelasyon ve toplam harmonik bozulma gibi zaman serisi özellikleri de hesaplanarak sinyalin zaman içindeki bağımlılıkları ve harmonik bileşenleri analiz edilmiştir. Özellik sıralaması için Spearman korelasyon katsayısı kullanılmış, bu sayede en anlamlı özellikler belirlenmiştir.

Sınıflandırma aşamasında, iki farklı yöntem izlenmiştir. İlk sınıflama işleminde, tüm frekans bantlarından çıkarılan özellikler kullanılarak genel bir duygu durumu kestirimi yapılmıştır. İkinci işlemde ise her bir frekans bandı ayrı ayrı değerlendirilerek tek bir frekans bandı ile duygu kestiriminin nasıl olacağı araştırılmıştır. Bu yaklaşım, belirli frekans bantlarının belirli duyguların tespitinde daha etkili olabileceğini göstermiştir. Özellikle, farklı bantların etkinlikleri karşılaştırıldığında, Beta bandı korku (%91.40) ve mutluluk (%84.30) sınıflarında yüksek doğruluk oranları sağlamıştır. Buna karşılık, Delta bandı tüm sınıflar için en düşük doğruluk oranlarını sunmuştur, bu da düşük frekanslı bantların duygu tespitinde sınırlı katkı sağlayabileceğini göstermektedir.

Elde edilen sonuçlar, Ensemble Bagged Trees modelinin genel doğruluk oranını %94.4 olarak göstermiştir. Model, nötr durum için %96.94 doğruluk oranına ulaşmış, üzüntü sınıfında %97.78 ve korku sınıfında %97.13 doğruluk oranları elde edilmiştir. Mutluluk sınıfında ise doğruluk oranı %97.04 olarak hesaplanmıştır. Tüm frekans

bantlarının bir arada kullanılması, genel olarak en yüksek doğruluk oranını sunmuş, bu da frekans bantlarının kombinasyonunun model performansını artırmada etkili olduğunu göstermektedir.

Elde edilen bulgular, EEG tabanlı duygu tanıma sistemlerinin, insan-makine etkileşimi, psikolojik araştırmalar ve pazarlama stratejileri gibi çeşitli alanlarda geniş uygulama potansiyeline sahip olduğunu göstermektedir. Bu çalışma, EEG verilerinin duygu tanıma ve analizinde etkili bir şekilde kullanılabileceğini kanıtlayarak, gelecekteki araştırmalar ve uygulamalar için önemli katkılar sunmaktadır.



EMOTION PREDICTION USING ARTIFICIAL INTELLIGENCE BASED ON ELECTROENCEPHALOGRAPHY (EEG) SIGNALS

SUMMARY

Understanding and defining the neurological foundations of emotions is increasingly important in the field of human-machine interaction. EEG (Electroencephalography) signals stand out as a high temporal resolution method for analyzing these emotional states. EEG enables the objective assessment of individuals' emotional and mental states by measuring the brain's electrical activities. However, the inherent complexity of EEG signals and their susceptibility to external factors make accurate and consistent analysis challenging. Therefore, the use of artificial intelligence methods in EEG-based emotion recognition systems has gained significant momentum in recent years. In this study, emotion recognition processes were carried out based on EEG signals using the SEED EEG dataset, and in this context, the Ensemble Bagged Trees model was proposed.

The SEED dataset, which forms the basis of this study, contains 62-channel EEG signals from 15 healthy participants. These participants were shown 72 film clips to evoke various emotional responses, and EEG data were recorded at a sampling rate of 1000 Hz during the sessions. In the preprocessing stage, EEG signals were filtered with a bandpass filter of 0.3-50 Hz, downsampled to 200 Hz, and various artifacts (such as eye blinks and muscle movements) were removed. These preprocessing steps enhanced the signal-to-noise ratio, allowing for more reliable and accurate analyses. Specifically, after downsampling, the signals from critically identified six symmetric temporal electrodes (FT7, FT8, T7, T8, TP7, TP8) were analyzed.

In the feature extraction stage, EEG data were divided into fundamental frequency bands known as delta (0.5-4 Hz), theta (4-8 Hz), alpha (8-12 Hz), beta (12-30 Hz), and gamma (30-50 Hz). For each band, time domain, frequency domain, and statistical features were calculated, and these features were used to train emotion recognition models. A total of 34 different features were extracted, including parameters such as autocorrelation, total harmonic distortion, kurtosis, skewness, standard deviation, and median. Especially, features such as Crest Factor and Impulse Factor are crucial for understanding the peak values and impulsive characteristics of the signal. The Autocorrelation Function (ACF) and Partial Autocorrelation Function (PACF) help us analyze the dependencies of the signal over time. Time-domain features express how the signal changes over time, considering the values at specific points and their distribution over time. Frequency-domain features represent the frequency components of the signal, taking into account the energy distribution in the frequency spectrum and the frequency characteristics of the signal.

Features that include basic statistical parameters describe the distribution and overall characteristics of the signal. Spearman's correlation coefficient was used to rank the features, and the most significant features were identified. In this process, the impact of each extracted feature on emotion recognition success was evaluated, and features with the highest correlation coefficients were selected.

In the classification stage, two different approaches were followed. In the first classification, features extracted from all frequency bands were used to estimate a general emotional state. In this process, 80% (2160 samples) of the 2700 samples were used for training, while 20% (540 samples) were set aside for testing. The overall model accuracy was calculated as 94.4%. This high accuracy indicates that the model can successfully distinguish between the four main emotion classes (neutral, sadness, fear, and happiness) and generally demonstrates reliable performance.

In the second classification, each frequency band was analyzed separately to investigate how emotion estimation could be achieved using a single frequency band. In these analyses, the Beta band provided high accuracy rates in the fear (91.40%) and happiness (84.30%) classes. In contrast, the Delta band showed the lowest accuracy rates across all classes, indicating that low-frequency bands might contribute less to emotion detection. For example, the accuracy rates were calculated as 69.9% for the Delta band, 74.8% for the Theta band, 73.8% for the Alpha band, 75.0% for the Beta band, and 73.1% for the Gamma band.

Examining the effects of different frequency bands on emotion recognition tasks is a significant dimension of this study. The combined use of all frequency bands generally provided higher accuracy rates, as this method creates a richer data representation by combining the different information provided by each band. For instance, the use of all bands together resulted in an accuracy of 96.94% in detecting the neutral state. Similarly, accuracy rates of 97.78%, 97.13%, and 97.04% were achieved for sadness, fear, and happiness, respectively. These results indicate that the model can classify emotional states quite accurately by using all bands together.

When individual bands were considered, the low accuracy rate of 69.9% provided by the Delta band suggests that this band offers limited information, particularly in the analysis of low-frequency signals. The Delta band may reflect slower brain activities associated with deep thinking or resting states, but it has limited impact on distinguishing emotional states. In contrast, the Beta band provided high accuracy rates of 91.40% in fear detection and 84.30% in happiness detection. The Beta band is associated with high-frequency brain activities, indicating that it may be more decisive in detecting emotional responses. The Theta (74.8%), Alpha (73.8%), and Gamma (73.1%) bands provided similar accuracy rates, showing effectiveness in general emotion detection, though no significant superiority was observed among these bands.

The findings of the study indicate that EEG-based emotion recognition systems have broad application potential in fields such as human-machine interaction, psychological research, and marketing strategies. These AI-based methods contribute significantly to future research and applications by enabling the accurate detection of emotional states.

The high accuracy rates of the Ensemble Bagged Trees model, in particular, support the effective use of such systems in practical applications. This study not only demonstrates that EEG data can be effectively used in emotion recognition and analysis but also highlights how the combination of different frequency bands can enhance model performance. These findings suggest that EEG-based AI methods can be applied more widely and contribute significantly to the literature in this field.

In conclusion, the Ensemble Bagged Trees model used in this study has demonstrated overall high accuracy and successful performance in the EEG-based emotion recognition process. However, considering the different effects of specific frequency bands on emotion detection, there are various avenues for further optimization and

improvement of these systems. Future studies may focus on testing this model with different datasets and artificial intelligence methods, as well as exploring enhancement methods for bands with lower performance. Each new study in this field will contribute to further developing EEG-based emotion recognition systems and increasing their application potential across various domains.





1. GİRİŞ

Duygular, sosyal yaşamın önemli bir parçasıdır ve zihinsel durumlarımızı etkileyerek fizyolojik tepkilerimize yansır. İçinde bulunduğumuz bağlama bağlı olarak bir tepki şeklinde ortaya çıkarlar ve bu tepki, insanın içsel durumlarını, deneyimlerini ifade eden bir dizi karmaşık süreç içerir.

Öyle ki, temel duygu tipleri kültür farkına bakılmaksızın sevinç, üzüntü, iğrenme, korku, öfke, şaşkınlık, ve küçümseme olmak üzere yedi ana grupta tanımlanmıştır [1].

Toplumsal etkileşimlerde duygusal durumlar büyük bir öneme sahiptir. Günümüz insanı çeşitli bilgisayar türlerini sıkça kullanmaktadır. Bu dijital gelişmelerle birlikte, insanlar arasındaki etkileşimi ve iletişimi kolaylaştıran akıllı sistemler de çeşitli yöntemler ve teknolojilerle gelişmeye devam etmektedir. Böylelikle artan insan-makine etkileşimiyle birlikte, duygu durumu analizi de önem kazanmaktadır. Duygu durumu analizinin ana amacı, insanların çeşitli duygusal durumlarını tanımlamak ve kullanıcıların ihtiyaçlarını anlamak için farklı arayüzleri kişiselleştirmektir. Başka bir ifadeyle, duygusal hesaplama, bilgisayarların kullanıcının duygusal durumlarını tanımayı, anlamayı, uyarlamayı ve bu yetilerin akabinde dijital cihazlar aracılığıyla kullanıcılarla etkileşimlerini geliştirme yeteneği kazandırmayı hedefler.

Duygularımızın fiziksel ve mental sağlık, sosyal ilişkiler, karar verme sürecimiz, iş performansı ve genel refah gibi pek çok yönden hayatımıza etkisi göz önüne alındığında duyguları tanımlamak, insan davranışını anlama ve yorumlama açısından oldukça değerlidir. Farklı duygusal veri tiplerinin sunduğu ipuçları çeşitli tekniklerle incelenerek öne çıkan duygu durumunun belirlenmesini amaçlayan duygu tanıma sistemleri, yapay zeka teknolojilerinin yaygınlaşmasıyla birlikte, Bilgisayar bilimi, Elektronik Mühendisliği, Psikoloji, Sinirbilim ve Tıp bilimi gibi çeşitli disiplinlerin gelişimi için önemli bir çalışma alanına dönüşmüştür.

1.1. Genel Bilgiler

Duygu durumunun belirlenmesinde elektrokardiyogram (EKG), EEG, elektrookülogram (EOG) ve elektromiyogram (EMG) gibi elektriksel nitelikteki biyo-

sinyallerden faydalanılmasının yanı sıra yüz ifadeleri, jestler, konuşmadaki ses tonu, deri direnci gibi birçok fizyolojik veri de çalışmalara dahil edilebilmektedir. Yüz ifadeleri, jestler gibi fiziksel tepkileri temel alan çalışmalara kıyasla EEG sinyalleriyle yapılmış olanlar daha yüksek doğruluk ve objektif bir değerlendirme sunması sebebiyle daha güvenilir bulunmaktadır [2]. Ayrıca katılımcılar otomatik olarak kaydedilen EEG sinyalini kontrol etme yetisine sahip değildirler. Bunun yanı sıra, duygularını konuşamayan veya duruşuyla ifade edemeyen bireyler için ses, jest ve duruştan duygu tanıma mümkün olmamaktadır. Dolayısıyla EEG, insan duygularını ortaya çıkarmak ve tanımlamak için uygun bir araç olarak kabul edilebilir. Merkezi sinir sisteminin otonom sinir sistemini düzenlediğini ve kontrol ettiğini göz önünde bulundurduğumuzda doğrudan beyin faaliyetlerinin bir ürünü olan EEG sinyalini duygu durumunu belirlemek üzere incelemek oldukça makul bir tercihtir.

1.2. Tezin Amacı ve Önemi

İnsan- makine etkileşimi her geçen gün artmakta ve beyin bilgisayar arayüz çalışmaları daha da önem kazanmaktadır. Bu kapsamda duygu durumunun tespiti için mevcut sistemlerin önemli bir kısmı duygusal verileri inceleyerek ortaya net bir sonuç koyma konusunda henüz yeterli değildir. Bu tez çalışması; insan- makine etkileşim sistemleri için duygusal zeka kazanımına EEG sinyallerinin incelenmesi ve bu sinyallerden duygu durumunu öne çıkaran özniteliklerin belirlenmesi ve duygu durum tahmininin EEG alt frekans bantları dikkate alınarak yapılması noktasında katkı sunmayı hedeflemektedir. Her bir bandın duygu durumunu belirlemede yetkinliğinin saptanması ve alt frekans bantları bileşiminin başarımlarıyla kıyaslanması hedeflenmektedir. Elde edilen özelliklerin sınıflandırma yöntemiyle performans değerlendirmesinin yapılması ve tasarlanan modelin güvenilirliğinin değerlendirilmesi planlanmaktadır.

1.3. Literatür İncelemesi

Duygu durum analizi için çeşitli alanlardaki araştırmacılar bu konuyu ortak bir hedef çerçevesinde farklı alanlarda iyileştici bir etken olarak kullanmayı hedeflediler.

Bu analiz sonuçları, sürüşte güvenliği artırmada, ruh sağlığının izlenmesinde, sosyal güvenlik önlemlerinin iyileştirilmesi veya eğitim başarısının artırılması gibi pek çok fayda sağlayacak çalışmada kullanılmaktadır. Duygu tanıma, özellikle tıbbi ölçümler

ve sađlık izleme alanında, örneđin ruh sađlığı deđerlendirmesi, hasta geri bildirimleri, stres ve kaygı yönetimi ve kişiselleştirilmiş sađlık müdahalelerinde önemli bir rol üstlenmektedir.

EEG tabanlı duygu tanıma için kayda deđer bir çalışma sahası söz konusudur. Örneđin, Otomobil sürücülerinin trafik anındaki stres seviyesini tespit etmek ve bunları izlemek için bir çerçeve geliştirmeye odaklanan [3] sürüş destek sistemleri oluşturma ve sürüş güvenliđini artırmak üzere çözümler üretebilmeyi hedefledikleri çalışmada, yüksek stres seviyesinin araç sürücülerinin kontrol yeteneklerini azaltarak trafik kazalarına yol açabileceđi belirtmektedir. Bu bağlamda, sürücülerin duygusal durumlarını izlemek ve deđerlendirmek için modern hesaplama tekniklerinin kullanılmasının önemi vurgulanmaktadır. EEG sinyalleri, sürücülerin duygusal durumlarını tanımlamak üzere bir araç olmuştur ve bu amaçla, Destek Vektör Makinesi (SVM), Yapay Sinir Ağları (ANN) ve Rastgele Orman (RF) gibi üç farklı sınıflandırıcı yöntemi kullanılarak EEG desenlerinin sınıflandırılması gerçekleştirilmiştir. Bulgular, SVM yönteminin dinlenme ve stres durumları arasındaki ayrımı daha etkin bir şekilde yapabildiđini göstermektedir.

Rozgic ve ark. (2014) travma sonrası stres bozukluđu teŗhisini ele aldıkları çalışmada, stresin bilgisayar destekli teŗhisi için, EEG gibi çeŗitli nörofizyolojik tepkilerin kullanıldığı bir sistem önermektedir. Çeŗitli görsel ve işitsel uyaranların kullanılmasıyla elde edilen tepkilerin, Bu problemi yaŗayan hastalar ile stres düzeyleri farklı kontrol grupları arasında farklılık gösterdiđi bulunmuştur. Sonuçlar, özellikle görsel ve işitsel uyaranlardan elde edilen travma ile ilişkili duyguların, travma sonrası stres bozukluđunun bilgisayar destekli teŗhisi için umut verici bir yöntem olduđunu göstermektedir.

Valstar ve ark. (2013) duygu bozuklukları, özellikle unipolar depresyon, deđerlik ve uyarılma gibi duygusal boyutlarla güçlü bir zamansal ilişkinin olduđu gerçeđine dayanarak psikologlar ve psikiyatristlerin hastaları deđerlendirmede yüz ve ses ipuçlarını dikkate aldıđını vurgulanmıştır. Depresyonun genellikle sönük yüz ifadeleri, göz temasından kaçınma ve düz tonlama olarak ifade edilen davranışlarla kendini gösterir. Belirtilen bu belirteçlere göre geliştirilen AVEC2013 ölçeđi ile sürekli deđerlik, uyarılma deđerleri ve depresyonun tahmin edilmesi amaçlanmıştır.

Cai ve ark. (2020) depresyonlu hastaları ve normal kontrol grubunu ayırt etmek için EEG verilerini kullanarak yeni bir çoklu- model oluşturmayı amaçlamıştır. Farklı ses uyarıcıları altında elde edilen EEG verileri, farklı modalitelerden çıkarılan özellikler kullanılarak birleştirilmiştir. 86 depresyonlu hasta ve 92 normal kontrolün EEG verileri kaydedilmiştir. Elde edilen özelliklerin sınıflandırma doğruluğunu artırmak için genetik algoritmalar kullanılmıştır. Sonuçlar, birleştirme modalitesinin bireysel modalite şemalarına kıyasla daha yüksek depresyon tanıma doğruluğu sağladığını göstermektedir. Bu çalışmanın, depresyon hastalarını tanımlamak için etkin bir araç olabileceğinin altı çizilmiştir.

Tespiti yapılan duygu durumunun dikkate alınmasıyla robot destekli terapilerde de araştırmalar söz konusudur. Gümüşlü ve ark. (2020) robot destekli rehabilitasyon sistemlerinin hastaların duygularını tanıyarak görev zorluk seviyelerini değiştirmesi üzerine odaklandıkları çalışmada EEG ve fizyolojik sinyaller kullanılarak bir duygu tanıma modeli geliştirmiştir. Duygular pozitif, negatif veya nötr kategorilere ayrılmıştır. Gradient Boosting Machines (GBM) ve Convolutional Neural Networks (CNN) gibi makine öğrenimi algoritmaları kullanılarak bu duyguların sınıflandırılması gerçekleştirilmiştir. Denekler, hoş, hoş olmayan ve nötr resimlere bakarken EEG ve fizyolojik sinyaller kaydedilmiştir. EEG ve fizyolojik sinyallerin birleştirilmesi ile elde edilen duyuşsal veri kombinasyonunun sınıflandırma doğrulukları değerlendirilmiştir.

Chang ve ark. (2017) ise müzik destekli terapilere destek sağlamak adına stres giderici müziklerin kişiselleştirilmiş önerilerini sunan bir sistem önermektedir. Yeni bir kümeleme algoritması olan K-MeansH kullanılarak müzikler otomatik olarak ön kümeleme işlemine alınır ve bu adım sonunda veri işleme süresinin iyileştirildiği görülmüştür. Kullanıcıların EEG verileri analiz edilerek algılanan stres giderici müzikler belirlenmiş ve kişisel tercihlere göre öneriler sunulmuştur. Bu araştırmaya göre deneysel sonuçlar, K-MeansH'nin diğer algoritmalarından daha iyi sonuç verdiğini ve önerilen müziklerin doğruluğunun arttığını göstermiştir. Bu gibi çalışmalarda görüldüğü üzere duygu durum analizlerindeki iyileştirici adımlar çeşitli duygu bozukluğu terapilerine rehberlik aracı olabilir.

Eğitim sürecinde duyuşsal halin hafıza üzerindeki etkisi Sanal Gerçeklik (VR) uygulamalarında doğrulanmıştır ve bununla birlikte olumlu ruh haline sahip olmanın mekânsal öğrenme üzerinde birtakım olumlu etkileri ortaya çıkmaktadır. Bu bilgiden

yola çıkarak sanal gerçeklik ortamlarında öğrenme sırasında ortaya çıkan duygu durumunun belirlenmesi için yapılan bir çalışma örneğinde Stavroulia ve ark. (2019) öğretmen eğitimini ve sürekli mesleki gelişimi artırmak için sanal gerçeklik (VR) tabanlı bir yöntem önermektedir. VR sistemi, öğretmenlere güvenli bir sanal okul ortamında gerçek hayattaki durumları deneyimleme ve tepki verme imkanı sunmaktadır. Önerilen yöntemin etkinliği, öğretmenlerin öğrencilerin madde kullanımıyla ilgili sorunlu durumlarını anlamalarını teşvik etmek için yapılan bir vaka çalışmasıyla gösterilmiştir. Deneysel araştırma, katılımcıların duygusal ve ruh halleri üzerindeki etkisini EEG ölçümleri ve kalp atış hızı (HR) kayıtları aracılığıyla değerlendirmiştir. Çalışma sonucunda, VR deneyiminin katılımcıların negatif duygusal durumlarında önemli bir değişikliğe neden olduğu gözlemlenmiştir. Önerilen VR tabanlı yaklaşım, öğretmen eğitimine yenilikçi bir çerçeve sağlamayı ve gerçek öğretmenlerin ihtiyaçlarını ele almayı amaçlamaktadır.

Vesisenaho ve ark. (2019) yaptıkları çalışmada öğrenme deneyimlerinde bilişsel ve duygusal boyutların birbirini etkilediğini ve duygusal bağlanmanın bilişsel başarıları artırabileceğini vurgulamaktadır. Sanal gerçeklik (VR), duygusal olarak etkileyici öğrenme ortamları yaratma potansiyeline sahiptir. Makale, VR'nin eğitimdeki kullanımına ilişkin disiplinlerarası araştırma literatürünü incelemekte ve öğretmen eğitiminde yapılan bir VR pilot çalışmasını sunmaktadır. Pilot çalışma sırasında, fizyolojik ölçümler, duygusal katılımın kendinden değerlendirilmesi ve öğrenci geri bildirimleri toplanmıştır. Son olarak, beyin görüntüleme teknikleri gibi yöntemlerin VR'de öğrenme ve duygusal durumları yakalama potansiyeli tartışılmış ve gelecek VR ortamlarının pedagojik tasarımı için rehber ilkeler sunulmuştur.

Eğlence sektöründeki payı giderek artan bilgisayar oyunları alanında da araştırmacılar oyunun zorluk, cezalar ve teşvik edicilik düzeyini dikkate alarak oyuncuların oyuna uyumunu sağlamak üzere duygusal durumlarını tespit etmeye çalışmışlardır. Alakuş ve ark. (2020) duygu tanıma analizi için EEG tabanlı verileri tanıtmayı amaçladılar. 28 farklı katılımcıdan toplanan EEG sinyalleri incelenmiştir. Katılımcılar, farklı duyguları yansıtan 4 bilgisayar oyununu oynamış ve EEG verisi bu süre boyunca kaydedilmiştir. Çalışma, taşınabilir EEG cihazının performansını değerlendirmeyi ve klasik EEG cihazlarıyla karşılaştırmayı ayrıca EEG sinyallerinin desen tanıma ve sinyal işleme yöntemleri kullanılarak duygu boyutunu pozitif/negatif duygulara göre sınıflandırmayı hedeflenmektedir

1.4. Tez Organizasyonu

Bu tez çalışmasında önerilen model ile basit ve etkili bir yöntem sunarak EEG siyalinden öne çıkan öznelilikleri belirlemek, analiz etmek ve duygu durum tahmininin EEG alt frekans bantları dikkate alınarak yapılması hedeflenmektedir.

Önerilen yöntemde deney çalışmaları için kamuya açık olarak paylaşılan SEED IV veri seti kullanılmıştır. Çalışma MATLAB R2023a versiyonu üzerinde gerçekleştirilmiştir.

Tez organizasyonu şu şekilde planlanmıştır: 1. Bölümde tez konusu ile ilgili genel bilgiler ve literatür taraması aktarılmıştır. 2. Bölümde EEG tabanlı duygu tanıma süreci ve sürecin anlaşılması için gerekli literatür üzerinde durulmuştur. 3. Bölümde bu tez çalışmasında kullanılan veri seti irdelenmiş ve önerilen yöntem tanıtılmıştır. 4. Bölümde ise bulgu ve sonuçlar paylaşılmış çalışmanın her adımı için paylaşılmış ve son bölümde ise çalışmada önerilen modele dönük sonuçlar yorumlanarak geleceğe dönük planlamalarla birlikte paylaşılmıştır.

2. EEG TABANLI DUYGU TANIMA

2.1. Merkezi Sinir Sistemi ve Beyin

İnsan beyni, yaklaşık 100 milyar nöronun kompleks bir ağ oluşturmasıyla ortaya çıkan olağanüstü bir yapıdır. Bu yapı beyin sapı, beyincik, orta beyin ve beyin korteksi gibi çeşitli temel unsurlardan oluşur [12].

Beyin sapı, vücudun iletişim ve kontrol merkezi olarak önemli bir rol oynar. Reflekslerin ve otomatik fonksiyonların yanı sıra kan basıncı ve kalp atış hızı gibi temel fonksiyonları kontrol ederken, aynı zamanda uyku düzenini de sağlar.


Beyincik, denge ve hareketle ilgili bilgileri koordine ederek ve ekstremitelerin hareketlerini düzenleyerek bedenin dengesini korur.

Orta beyin, içsel fonksiyonların yanı sıra vücut sıcaklığını ve davranışsal işlevleri kontrol eder. Bu, iştah düzeni, uyku düzeni ve çeşitli duygusal tepkileri içerir.

Beyin korteksi, tüm duyu organlarından gelen bilgileri işleyerek ve tüm motor fonksiyonları kontrol ederek karmaşık bir beyin merkezi oluşturur. Dil, bilişsel işlevler ve bellek gibi daha yüksek düzeyde beyin fonksiyonlarını da içerirken, duyguların işlenmesi de bu bölgede gerçekleşir. Beyin korteksinin korteksi, beyin-bilgisayar arayüzü (BCI) alanında özel ilgi gören bir beyin bölgesidir. Bu kısımdaki sinirsel aktivite, yüksek düzeyde bilişsel işlevlerin yürütülmesinden sorumlu olduğu için özellikle önemlidir. Ayrıca korteksin yüzeye yakınlığı, elektrofizyolojik ve manyetik ölçümlerin kolayca erişilebilir olmasını sağlar. Korteksin işlevselliği bilişsel görevlerin gerçekleştirilmesi belirli kortikal bölgelerle ilişkili olmasına da dayanır. Bu nedenle, kortikal aktivitenin doğru şekilde haritalanması ve anlaşılması, BCI teknolojisinin gelişiminde kritik bir adım olmuştur [13].

Beyin kabuğu, temelde kompleks bir yapı olan beyin korteksinin en dış tabakasını oluşturur, sol ve sağ olmak üzere iki yarımküreye ayırır. Sol yarımküre, vücudun sağ yarısından gelen duyuları algılar ve kontrol ederken, sağ yarımküre ise bunun tam tersini gerçekleştirir. Her iki yarımküre de dört ana loba sahiptir.

Bu yapı Şekil 2.1’de görüldüğü üzere frontal lob, parietal lob, oksipital lob ve temporal lobdan oluşmaktadır [13].



Şekil 2.1. İnsan beyninin ana bölümleri

Frontal lob, hareket kontrolü, problem çözme, düşünme ve karar verme gibi yüksek düzeyde bilişsel işlevlerden sorumludur.

Parietal lob, dokunsal duyuları, uzaysal algıyı ve bedensel konum bilgisini işler.


Oksipital lob, görme işlevleriyle ilişkilendirilmiştir ve görsel bilgiyi işler.

Temporal lob, ise işitme, dil, hafıza ve duygusal tepkiler gibi işlevlerden sorumludur.

Beyin korteksi, görüldüğü üzere belirli alanlara bölünebilmektedir ve bu alanların her biri belirli bir işlevi yerine getirmek için özelleştirilmiştir. Örneğin, motor korteks, vücudun kaslarını kontrol eden nöronları içerirken, somatosensoriyel korteks, dokunsal duyuları işler. Görsel korteks, görsel bilgiyi işlerken, işitme korteksi işitsel bilgiyi işler. Beyin korteksindeki bu farklı bölgeler, karmaşık bir ağ oluşturarak birlikte çalışır ve insan davranışı ve algısının temelini oluşturur [14].

Tüm bu unsurların bir arada olması, insan beyninin işlevsel ve duygusal zenginliğinin anlaşılmasında merak uyandırıcı olmuştur. Bu işlevsel çeşitliliğin anlaşılması, sinir sisteminin temel yapı taşlarına dair bilgi edinmeyi gerektirir. Bu noktada, sinir sisteminin nasıl çalıştığını anlamak için nöronların yapısı ve işleyişi üzerinde durmak önemlidir [14].

Sinir sistemi, sinir hücrelerinden (nöronlar) oluşmaktadır. Her bir sinir hücresi, hücre gövdesi, çekirdek, akson, dentrit, miyelin kılıf ve akson uçları bileşenlerinden oluşur. Nöronlar, dış dünyadan aldıkları bilgiyi hücre içinde veya hücre dışında ilgili hücelere iletmekle görevlidir. Bu bilgiler, nöronun dentritleri aracılığıyla alınır ve iletilir. Bilgi iletimi tek yönlü gerçekleşir. Tipik bir sinir hücresi Şekil 2.2’de görülmektedir.



Şekil 2.2. Tipik bir sinir hücresinin bölümleri.

Hücre gövdesi, sinir hücresinin tüm işlemlerinin merkezidir. Dentritlerden alınan bilgileri işler ve bilgi iletiminde önemli bir rol oynar. Hücre gövdesi, vücuttaki metabolik faaliyetlerden sorumludur. Dentritler, diğer hücrelerden gelen bilgileri veya uyarıları hücre gövdesine ileten dallı yapılar olarak işlev görür.

Aksonlar, bilgilerin sinir hücrelerine iletilmesinde aktif rol oynar. Hücre gövdesinde işlenen bilgi, aksonlar aracılığıyla diğer nöronlara iletilir.

Miyelin kılıf, aksonları koruyan ve sinyal iletim hızını artıran özel bir yapıdır. En önemli özelliği, bilgilerin hızlı bir şekilde iletilmesini sağlamak ve kayıpları önlemektir. Miyelin kılıf, yağdan zengin bir madde olan miyelin ile kaplanmış Schwann hücrelerinden (periferik sinir sistemi için) veya oligodendrositlerden (merkezi sinir sistemi için) oluşur. Miyelin, elektriksel yalıtım sağlayarak akson boyunca aksiyon potansiyelinin (elektriksel sinyalin) sıçrayarak iletilmesini mümkün kılar. Bu iletim süreci, "saltatorik iletim" olarak adlandırılır. Saltatorik iletim, sinyalin miyelinsiz aksonlara kıyasla daha hızlı iletilmesini sağlar. Miyelin kılıfın yapısı,

Ranvier düğümleri denilen düzenli aralıklarla kesintiye uğrar. Bu düğümler, aksiyon potansiyelinin bir düğümden diğerine atlayarak ilerlemesine izin verir, bu da sinyalin daha hızlı hareket etmesini ve enerji tasarrufu sağlamasını mümkün kılar. Böylece miyelin kılıf hem sinyalin hızını artırır hem de elektriksel sinyalin yolda zayıflamasını önler [15].


Sinir hücrelerinin iletimi, kompleks bir süreç olup birçok bileşen içerir. İletim süreci genellikle sinirsel impuls veya aksiyon potansiyeli adı verilen elektriksel sinyallerin iletilmesiyle gerçekleşir. Sinyaller, nöronların içinde elektriksel iletilirken, nöronlar arasında kimyasal olarak sinapslarda iletilmektedir. Nöronlardaki elektrik sinyalleri aksiyon potansiyelleri şeklini alır. Bu adımlar şu sırayla gerçekleşir:

Dendritlerin Alımı: Dendritler, diğer nöronlardan veya duyu hücrelerinden gelen uyarıcıları alır. Bu uyarıcılar, kimyasal sinyaller olarak başlar ve sinir hücresinin zarından geçerek elektriksel sinyallere dönüşür [16].

Hücre Gövdesinde İşleme: Hücre gövdesi, dendritlerden gelen bu elektriksel sinyalleri alır ve işler. Eğer gelen sinyaller yeterince güçlüyse, hücre gövdesi bir sinir impulsu oluşturur [16].

Aksiyon Potansiyelinin Oluşumu: Eğer hücre gövdesindeki işlenmiş sinyaller, birbirini takip eden iyon kanallarındaki değişimler sonucunda bir eşik değerini aşarsa, aksiyon potansiyeli oluşur. Bu, hücre zarındaki elektrik yükünün anlık olarak değişmesidir. Bir başka ifadeyle nöron hücre gövdesinin aksonla birleştiği akson tepciğinden akson boyunca ilerleyerek akson terminallerine kadar iletilen kısa bir elektrik sinyalidir. Bu sinyal, bir nöronun içine veya yakınına voltmetreye bağlı olarak yerleştirilen elektrotlardan ölçülebilir.

Bu süreç sinyalin oluşumu ve yayılımı açısından biraz daha detaylı incelenecektir. Bu işlemler görsel olarak Şekil 2.3’de yer almaktadır [16].



Şekil 2.3. Aksiyon potansiyelinin yayılımı [16].

Aksiyon potansiyeli, bir sinir hücresinin zar potansiyelinde ani bir değişiklikle başlar ve bu değişiklik sinir sinyalinin akson boyunca ilerlemesine olanak tanır.

Başlangıç ve Depolarizasyon: Aksiyon potansiyelleri, hücre gövdesi yakınındaki aksonun başlangıç kısmında yani akson tepeciğinde başlar. Bu bölgede zar potansiyeli yeterince depolarize olursa, voltaj kapılı sodyum kanalları açılır ve sodyum iyonları hücre içine girer. Bu işlem, zarın daha fazla depolarize olmasına ve aksiyon potansiyelinin oluşmasına neden olur [16].

Yayılması: Miyelinsiz Aksonlarda; pozitif yüklü sodyum iyonları, aksiyon potansiyelinin yükselme fazı sırasında hücreye girer ve komşu zar bölgelerine yayılır. Bu komşu bölgelerde de voltaj kapılı sodyum kanalları açılır ve yeni aksiyon potansiyelleri oluşur. Bu şekilde, depolarizasyon ve repolarizasyon dalgası akson boyunca ilerler ve sinyal akson terminallerine kadar ulaşır.

Miyelinli Aksonlarda; Miyelin kılıfı, aksonun büyük bir kısmını sarar ve elektriksel yalıtım sağlar. Aksiyon potansiyeli, Ranvier düğümleri adı verilen miyelinsiz bölgelerde yenilenir. Bu düğümler arasında sinyal, hızlı bir şekilde atlayarak (saltatorik iletim) ilerler. Bu da sinyalin miyelinsiz aksonlara kıyasla daha hızlı iletilmesini sağlar [16].

Tek Yönlü İletim: Sodyum kanallarının inaktivasyonu, aksiyon potansiyelinin hücre gövdesine doğru geri yayılmasını önler. Bu, sinyalin sadece ileri yönde, yani akson boyunca ve hedef hücrelere doğru hareket etmesini sağlar [16].

Sinir hücrelerinin bu yapısı ve işleyişi, beyin korteksindeki farklı bölgelerin birbirleriyle uyum içinde çalışmasını sağlar. Böylece, motor ve duyu işlevlerinden karmaşık bilişsel süreçlere kadar geniş bir yelpazede görevler yerine getirilebilir. Beynin bu karmaşık yapısı, bilişsel ve duygusal deneyimlerin derinliğinin anlaşılmasına yardımcı olur.

2.2. Beyin Aktivitesinin Ölçümü

Anlamlı ve doğru EEG verileri elde etmek için insan beyninin anatomisi hakkında bilgi sahibi olmak önemlidir.

Farklı fenomenlerin farklı yöntemlerle ölçülmesi gerektiğinden beyin aktivitesini ölçmek için çeşitli yöntemler bulunmaktadır. Elektrik akımını, manyetik alanları ölçen doğrudan ölçüm yöntemleri veya metabolizmayı, kan basıncını ölçmek gibi dolaylı ölçümlere kadar çeşitli yaklaşımlar uygulanmıştır. En sık kullanılan yöntemler aşağıda verilmiştir.

EEG, insanların beyin elektriksel aktivitesini saç derisi üzerinden belirli bir süre boyunca kaydeden bir sistemdir. Bu sistem, beyindeki nöronlardan kaynaklanan iyonik akımdan gelen gerilim dalgalanmalarını ölçer [17]. Bu yöntem, yüksek zamansal çözünürlük ve non-invaziv ölçüm avantajına sahipken düşük mekansal çözünürlük ve ayrıca sinyaldeki yüksek değişkenlikler gibi önemli dezavantajlara sahiptir.

EEG'nin yüksek zamansal çözünürlük sağlaması EEG'nin zaman içindeki değişimleri hassas bir şekilde tespit edebilme yeteneğini ortaya koyar. Yani EEG, beyindeki elektriksel aktivitelerdeki hızlı değişiklikleri yakalayabilir. Öte yandan kafatasının yapısından kaynaklanan düşük mekansal çözünürlük ise EEG sinyali beyinden kaydedilirken kafatası yapısından dolayı detayların belirsizleşmesi veya bulanıklaşması durumudur. Kafatası, elektriksel sinyallerin beyinden elektrotlara iletilmesi sırasında sinyalin şeklini etkileyebilir veya bozabilir. Bu durum, ölçülen sinyalin belirli bir kaynağa geri dönüşünü belirsizleştirerek, sinyalin doğru bir şekilde kaynağına atfedilmesini güçleştirebilir. Bundan dolayı kafatası yapısı EEG'nin

mekansal çözünürlüğünü olumsuz etkileyen bir faktördür ve çözünürlüğünün sınırlı olmasına neden olur [17].

Elektrokortikografi (ECoG), beyin dışındaki elektriksel akımların elektrofizyolojik özelliklerini inceleyen bir tekniktir. Bu akımlar, beyin hücreleri arasındaki iletişimi sağlar. ECoG, bu akımları kaydederek beyin aktivitesini incelemeyi amaçlar. Yüksek zaman çözünürlüğüne ve iyi mekansal çözünürlüğe sahiptir, yani beyindeki değişiklikleri zaman içinde ve uzayda hassas bir şekilde izleyebilir. Ancak, elektrotların doğrudan beyne yerleştirilmesi gerektiği için invazivdir. Bu da cerrahi operasyonları gerektirir, hastalar için ciddi güvenlik riskleri taşır ve uygulanması zordur [18].

Pozitron Emisyon Tomografisi (PET), hücresel düzeyde metabolizmayı izleyerek dolaylı olarak ölçen bir yöntemdir. Ölçüm enjekte edilen radyoaktif izotopların takibiyle gerçekleştirilir. Artan aktivite bölgelerinde metabolizmanın daha yüksek olduğu ve böylelikle daha fazla izotopun kan akışıyla taşındığı prensibine dayanır. Buna bakarak hangi bölgelerin etkinlik ürettiği belirlenebilir. PET'in oldukça iyi bir mekansal çözünürlüğü vardır, ancak gerçek zaman çözünürlüğü (yaklaşık 2 dakika) zayıftır çünkü metabolizma yavaş bir süreçtir. Ayrıca, iyonlaştırıcı radyasyonunun varlığı bu yöntemi insan vücudu için zararlı hale getirir ve bu nedenle BCI gibi uygulamalar için uygun değildir [19].

Manyeto Ensefalografi (MEG), kortikal elektrik akımları tarafından üretilen manyetik alanları doğrudan ölçerek beyin aktivitesini inceleyen bir yöntemdir. Bu yöntem, non-invaziv olup iyi bir mekansal ve zamansal çözünürlüğe sahiptir. Ancak, yüksek ekipman maliyeti ve çok zayıf manyetik alanların bile izole edilmesi gerekliliği gibi bazı pratik zorlukları vardır, dolayısıyla gerçek zamanlı analizler için uygun değildir [20, 21].

Manyetik Rezonans Görüntüleme (fMRI), kandaki oksijen seviyesine bağlı (BOLD) sinyalleri kullanarak beyin metabolizması hakkında bilgi sağlayan bir görüntüleme tekniğidir. Bu yöntem, dipozitelerin konumunu belirlemek için güçlü manyetik dalgalar kullanır. fMRI'nin avantajları arasında iyi mekansal çözünürlük ve invaziv olmaması bulunur. Buna karşın zaman çözünürlüğü düşüktür (yaklaşık bir saniye kadar) ve bu nedenle hızlı beyin aktivitesini tam olarak izlemekte zordur. Ayrıca, fMRI ekipmanları ve prosedürleri oldukça maliyetlidir [22, 23]

Yakın Kızılötesi Işık (NIR), insan kafatasına yeterince derinlemesine nüfuz eden yakın kızılötesi ışık kullanarak beyin korteksinin fonksiyonel haritalamasına olanak tanıyan bir yöntemdir. Bu süreç, dokudaki hücreler tarafından ışığın emilimi ve saçılması yoluyla gerçekleşir. Böylece bu değişiklikler ölçülebilir bir sinyal olarak algılanır ve beyin aktivitesinin belirli bir göstergesi olarak kullanılabilir [24].

2.3. Elektroensefalografi

En ideal beyin ölçüm yöntemi yüksek mekansal ve zamansal çözünürlük, düşük maliyet, taşınabilirlik ve invaziv olmayan uygulanabilirlik gibi özelliklere sahip olmalıdır. Ancak bu tür bir yöntem henüz mevcut değildir. EEG, BCI'da en yaygın kullanılan yöntemdir çünkü gerçek zamanlı BCI için gerekli oldukça iyi bir zamansal çözünürlüğe sahiptir. Esasında EEG'nin iki türü vardır: yaygın olarak kullanılan non-invaziv olanıdır. Bu türde elektrotlar kafa derisine yerleştirilir, bu da herhangi bir zamanda herhangi birine kolayca uygulanabilir olmasını sağlar. Diğer bir tür ise invaziv EEG'dir. Bu türde elektrotlar kafatasına yerleştirilmelidir ve daha yüksek mekansal çözünürlük sağlar. Buna karşılık, invaziv EEG'nin uygulanması cerrahi gerektirir, bu da yüksek maliyetler ve güvenlik riskleri anlamına gelir.


Hem invaziv hem de non- invaziv EEG için geçmişte EEG verilerinin elde edilmesi zor ve maliyetliydi, ancak günümüzde taşınabilir cihazların gelişmesiyle bu süreç daha erişilebilir hale geldi. Artık Wi-Fi ve Bluetooth gibi teknolojiler sayesinde EEG verileri kolayca toplanabilmektedir. Bu gelişme, EEG tabanlı araştırmaların artmasına ve beyin-bilgisayar arayüzü uygulamalarının çeşitliliğinin artmasına katkıda bulunmuştur. Elektroensefalograf ile kaydedilen EEG sinyalleri ile bu uygulamalardan biri olan duygu durumunun tespiti yine bu yöntemle yapılabilmektedir [25].


Merkezi sinir sisteminin (Central Nervous System - CNS) çekirdeği kabul edilen beynin kritik işlevlerinden biri, duygusal sürece katılım için tüm vücuttaki fiziksel veya psikolojik aktiviteleri düzenlemektir. Bu düzenleme süreci farklı durumlarda farklı genlik ve frekans seviyelerinde beyin dalgalarının oluşumuyla meydana gelmektedir. EEG sinyalleri, farklı zihinsel durumlar ve koşullarla ilişkilendirilmiş bir bileşimi olarak beş alt bant sinyali olarak incelenmektedir. Bunlar: delta, teta, alfa, beta ve gama bantlarıdır. Tablo 2.1'de farklı frekans alt bantlarının adı, konumu, frekans aralığı ve bu aralıklarda gerçekleşen beyin aktivitesi tanıtılmıştır [26].

Tablo 2.1. EEG frekans alt bantları ve özellikleri [25].

Bantlar	Frekans	Aktivite	Bölge
Delta Dalgası (δ)	(0,5-4) Hz	Derin rüyasız uyku / Derin meditasyon	-
Teta Dalgası (θ)	(4-8) Hz	Normal uyku / Meditasyon	Frontal
Alfa Dalgası (α)	(8-12) Hz	Düşünme /Problem çözme	Parietal
Beta Dalgası (β)	(12-22) Hz	Uyanıklık hali / Konsantrasyon	Frontal
Gama Dalgası (γ)	(22-30) Hz	Aşırı aktif durumlar	-

Tabloda sunulan bilgiler, EEG frekans bantlarının belirli zihinsel ve fizyolojik durumlarla nasıl ilişkilendirildiğini net bir şekilde ortaya koymaktadır. Bu bilgileri desteklemek ve daha iyi görselleştirmek amacıyla Şekil 2.4 ve Şekil 2.5'te yer alan EEG sinyal grafikleri incelenebilir.

**Şekil 2.4.** Gerçek zamanlı EEG verisi [27]



Şekil 2.5. EEG alt bantlarının genlik, frekans ve dalga formları [28].

Şekil 2.4'te, gerçek zamanlı EEG verileri temsil etmektedir. Bu grafik, EEG sinyallerinin zamana karşı genlik değişimlerini gösterir. Sinyalde düşük frekanslı ve yüksek genlikli sinyaller Delta dalgalarını (0,5-4 Hz) temsil ederken, yüksek frekanslı ve düşük genlikli sinyaller Beta dalgalarını (12-22 Hz) temsil eder. Bu temsili EEG sinyali alt bantlara ayrıldığında Şekil 2.5'teki grafik elde edilir. Burada EEG frekans bantları (Delta, Teta, Alfa, Beta ve Gama) zamana karşı genlik değişimleri ile birlikte gösterilmiştir. Her bir dalga şekli, ilgili bandın karakteristik frekans aralıklarını ve bu bantların belirli beyin bölgelerindeki aktivitelerini sergilemektedir. Örneğin, Delta dalgaları (0,5-4 Hz) derin rüyasız uyku ve derin meditasyon durumlarında belirgindir. Teta dalgaları (4-8 Hz) normal uyku ve meditasyon sırasında yaygındır. Bu dalgalar, özellikle frontal bölgede belirginleşir ve daha düşük genlik ile orta frekans aralığında dalgalanma gösterir. Alfa dalgaları (8-12 Hz) meditasyon, rahatlama, düşünme ve problem çözme aktiviteleri sırasında aktiftir. Parietal bölgede yoğunlaşan bu dalgalar, orta frekansta ve genlikte görülür. Uyanıklık hali ve konsantrasyon sırasında Beta dalgaları (12-22 Hz) dominant hale gelir. Bu dalgalar, frontal bölgede yüksek frekanslı ve düşük genlikli sinyaller olarak tespit edilir. Gama dalgaları (22-30 Hz) aşırı aktif durumlarda belirgindir. Bu dalgalar, en yüksek frekans aralığına sahip olup genellikle daha düşük genlikte seyrederek.

2.4. EEG Elektrot Sistemi

EEG elektrot sistemi, kafa derisine yerleştirilen elektrotlar aracılığıyla beyin aktivitesini kaydetmek için hassas bir düzenlemeyi gerektirir. Elektrotların yerleştirilmesi, Uluslararası EEG Federasyon Birliği'nin belirlediği 10-20 sistemine göre gerçekleştirilir. Bu sistemde elektrotlar, kafanın dört ana bölgesine -burun, başın arka kısmı ve iki kulak- aralarında belirli bir mesafe olacak şekilde yerleştirilir. Elektrotlar arasındaki mesafe %10-20-20-20-20-10 düzeninde olur [29].


Her bir elektrotun kafatası yüzeyinde denk geldiği bölge, harf ve sayılarla ifade edilir. Bu düzenleme, sol yarıkürenin tek sayılarla, sağ yarıkürenin çift sayılarla ve orta kısmın "Z" harfi ile belirtildiği şekilde yapılır. Örneğin, Fp (frontopolar) elektrotu alın bölgesini, F (frontal) elektrotları ön bölgeyi, C (santral) elektrotları orta bölgeyi, T (temporal) elektrotları şakak bölgesini, P (parietal) elektrotları arka üst bölgeyi ve O (oksipital) elektrotları ise arka bölgeyi temsil eder. Rakamlar orta hattan uzaklaştıkça büyürken frontopolar ve temporal elektrotların rakamları önden arkaya doğru ilerledikçe artış göstermektedir [30]. Uluslararası 10-20 sistemine ait gösterimler ve temsil ettikleri bölge ve tanımlamalar Tablo 2.2'de görülmektedir.

Tablo 2.2. Uluslararası 10-20 sistemine ait gösterimler [31].


Elektrot gösterimi	Bölge
FP (Frontopolar)	Alın bölgesi
F (Frontal)	Ön bölge
C (Santral)	Orta bölge
T (Temporal)	Şakak bölgesi
P (Parietal)	Arka üst bölge
O (Oksipital)	Arka bölge
A (Auriküler)	Kulak arkası
Z	Orta bölge
Rakamlar	Lateral yerleşim

Bu elektrotlara ek olarak EEG sisteminde kullanılan referans elektrotlar, ölçüm sırasında ortaya çıkan gürültüyü azaltmak için kulak bölgelerine yerleştirilir. Bu referans elektrotlar, ölçümlerin daha doğru ve güvenilir olmasını sağlar. EEG elektrot sisteminin bu dikkatli yerleştirme düzenlemesi, beyin aktivitesinin belirli bölgelerinin izlenmesini ve analiz edilmesini mümkün kılarak nörolojik araştırmalarda, beyin

Bahsedilen elektrot yerleşim planı Şekil 2.6’da, farklı açılardan yerleşim görünümü ise Şekil 2.7’de görülmektedir.



Şekil 2.6. Uluslararası 10-20 elektrot sistemi [29], [32]



Şekil 2.7. Uluslararası 10-20 sistemi yerleşimi [31]

2.5. Duygusal Durumlar ve Modelleme

Duygu, bir kişinin belirli bir anda nasıl davrandığını ortaya koyan, anlık bir hissi ifade eder. Durumlar değiştikçe kişiler mutluluk, korku, öfke, sıkıntı gibi farklı duygular yaşayabilirler. Duygu, bireyin kişisel özellikleri, mevcut zihinsel durumu, davranışı ve

düşüncesiyle birlikte duygusallığını yansıtır. Ancak bununla birlikte duyguların kesin bir nicel ölçümü mümkün değildir.

Duygusal durumların modellenmesi, insan davranışlarını anlamlandırmak ve tahmin etmek için önemli bir çalışma alanı haline gelmiştir. İnsanların duygusal tepkileri, çevresel etkenler, kişisel özellikler ve yaşam deneyimleri gibi birçok faktörden etkilenir. Bu nedenle, duygusal durumların modellenmesi, insanların nasıl hissettiklerini ve belirli bir zamanda ne tür tepkiler verebileceklerini anlamak için kritik bir rol oynar.

Son araştırmalar, insan duygusal durumlarının oldukça çeşitli olduğunu göstermektedir. Bu duygusal durumlar arasında mutluluk, korku, öfke, heyecan, şaşkınlık ve daha pek çok duygu bulunmaktadır. Psikoloji araştırmacıları, bu çeşitliliği anlamak ve sınıflandırmak için çeşitli modeller önermişlerdir.

Duygu modelleri boyut değerlendirmesine göre ikiye ayrılır: 2B (İki Boyutlu) Model ve 3B (Üç Boyutlu) Model. 2B modelleme genellikle duygusal durumları bir eksenle olumlu-olumsuz ve diğer eksenle uyarıcı-düşük uyarıcı boyutlarında sınıflandırır. "Olumlu-olumsuz" boyutu, duygusal deneyimlerin genel değerlendirmesini ifade eder. Bir duygusal deneyim olumluysa, genellikle keyifli veya tatmin edici olarak algılanırken, olumsuzsa, genellikle rahatsızlık veya hoşnutsuzluk ile ilişkilendirilir. "Uyarıcı-düşük uyarıcı" boyutu ise, duygusal deneyimlerin canlılık veya uyarıcılık düzeyini ifade eder. Bir deneyim yüksek uyarıcı ise, genellikle heyecan verici, stimüle edici veya gerginlikle ilişkilendirilirken, düşük uyarıcı ise, genellikle sakin, huzurlu veya sakinleştirici olarak algılanmaktadır. Bu iki boyut birleştirildiği zaman dört farklı kategori oluşur, bunlar: olumlu ve yüksek uyarıcı, olumlu ve düşük uyarıcı, olumsuz ve yüksek uyarıcı, olumsuz ve düşük uyarıcı [33].


Olumlu ve yüksek uyarıcı: Bu durumda, kişi genellikle keyifli ve heyecanlı hisseder. Örneğin, bir tatilde veya eğlenceli bir etkinlikte olabilir.

Olumlu ve düşük uyarıcı: Bu durumda, kişi genellikle huzurlu ve sakin hisseder. Örneğin, dinlenme veya meditasyon sırasında olabilir.

Olumsuz ve yüksek uyarıcı: Bu durumda, kişi genellikle endişeli veya stresli hisseder. Örneğin, bir sınav öncesi veya yoğun bir iş gününde olabilir.

Olumsuz ve düşük uyarıcı: Bu durumda, kişi genellikle hüznü veya depresif hisseder. Örneğin, bir kayıp yaşadktan sonra veya yalnızlık hissettiğinde olabilir.

Bu sınıflandırma, duygusal deneyimleri daha anlaşılır ve ölçülebilir bir şekilde tanımlamak için kullanılır duygusal durumların temel özelliklerini yakalamak için kullanışlı bir yaklaşımdır. Bu modellerden biri olan Russel'in Duygusal Düzlem Modeli [34] 2B modellemeler arasında popüler bir modeldir ve model yapısı Şekil 2.8'de sunulmuştur.



Şekil 2.8. Valans-uyarılma 2B duygu düzlemi


Russell'in Çembersel 2D modeli, duygusal deneyimleri iki boyutlu bir düzlemde değerlendirirken, 3B model üç boyutlu bir uzayda inceler. 3B modelde, duygusal deneyimleri temsil etmek için üç ana boyut kullanılır: Valence, arousal ve dominance [34].

Valence (Olumlu-Olumsuz): Bu boyut, duygusal deneyimin genel değerlendirmesini ifade eder. Olumlu uç, pozitif duyguları ve olumlu deneyimleri temsil ederken, olumsuz uç, negatif duyguları ve olumsuz deneyimleri ifade eder. Bu boyut, duygusal deneyimin temel niteliğini belirler.

Arousal (Uyarılma): Bu boyut, duygusal deneyimin canlılık veya uyarıcılık düzeyini değerlendirir. Yüksek uyarılma ucu, duygusal deneyimin ne kadar uyarıcı veya heyecan verici olduğunu ifade ederken, düşük uyarılma ucu, ne kadar sakin veya durgun olduğunu ifade eder.

Dominance (Baskınlık): Bu boyut, duygusal deneyimin birey üzerindeki kontrol veya hakimiyet seviyesini ifade eder. Yüksek baskınlık, bireyin deneyimi üzerinde daha fazla kontrol sahibi olduğunu veya daha aktif olduğunu gösterirken, düşük baskınlık, bireyin deneyimi üzerinde daha az kontrol sahibi olduğunu veya daha pasif olduğunu ifade eder.

Bu üç boyut bir araya geldiğinde, duygusal deneyimler üç boyutlu bir uzayda temsil edilir ve bu model Şekil 2.9’da görülmektedir.



Şekil 2.9. 3 Boyutlu duygu modeli

Model, 3 boyutlu olması sebebiyle duygusal deneyimlerin daha kapsamlı ve ayrıntılı bir şekilde analiz edilmesine olanak tanır. Bu modelin kullanımı, duygusal deneyimlerin karmaşıklığını ve çeşitliliğini daha iyi anlamak için önemli bir araç sağlar. 3B model, duygusal deneyimleri daha kapsamlı bir şekilde analiz etmemizi sağlar, duygusal deneyimlerin karmaşıklığını ve çeşitliliğini daha iyi anlamamıza önemli bir araç oluşturur [35].

Bu temel iki modele ek olarak duygu durumunun tespit edilmesi amacıyla çalışmalara öncülük eden önemli modellemeleri Tablo 2.3’de özetlenmiştir.

Tablo 2.3. Duygu durum modellemeleri ve özellikleri.


Model ismi	Mucit	Yıl	Duygu Durumları
Paul Ekman Modeli [36]	Paul Ekman	1972	Mutluluk, Üzüntü, Kızgınlık, Korku, Şaşkınlık, İğrenme
PAD Modeli [37]	Mehrabia, J. Russell	1974	3 Boyutlu. Keyif, Uyarılma ve Hakimiyet'e dayalıdır
Russell'in Karmaşıklık Modeli [38]	James Russell	1980	2 Boyutludur ve duyguları Açıklık (Directness) ve Yoğunluk (Intensity) boyutunda değerlendirir
Plutchik'in Çarkıfeleği [39]	Robert Plutchik	1980	Öfke, Korku, Şaşkınlık, Üzüntü, Sevinç, İğrenme, Beklenti, İlgi
PANA Modeli [40]	Watson, Tellegen	1985	2 Boyutludur ve duyguların altında yatan sebepleri pozitif ve negatif olarak değerlendirir

2.6. EEG Tabanlı Duygu Tanıma Süreci

Duygusal psikolojinin keşfi ve insan davranışlarının daha derinlemesine incelenmesi, araştırmacılar arasında büyük bir ilgi konusu olmuştur. Bu bağlamda, beyin aktivitesini analiz etmek için kullanılan EEG gibi tekniklerin önemi giderek artmaktadır. Son yıllarda yapılan araştırmalar, merkezi sinir sisteminin duygusal süreçlerle doğrudan bağlantılı olduğunu göstermiştir. EEG tabanlı duygu tanıma teknolojisinin gelişimi, bu alanda önemli bir potansiyel sunmaktadır. Bu bölümde, EEG tabanlı duygu tanıma sürecinin detaylı bir şekilde incelenmesi amaçlanmaktadır.

İnsan duygularının anlaşılması için genellikle iki yöntem kullanılır. Bunlardan ilki; görseller, sesler, videolar, işitsel-görsel materyaller, dokunsal uyarılar, koku gibi dış etkenlerin kullanılması ikincisi ise katılımcılara geçmiş duygusal deneyimleri hakkında sorular yöneltilmesidir. Günümüzde, araştırmacıların çoğu bu ilk yöntemi tercih etmektedir. Duygu tanıma çalışmaları için temel bir gereklilik, EEG verilerinin toplanması veya kaydedilmesidir.

EEG tabanlı duygu durum tespiti, beş ana adımdan oluşan kapsamlı bir süreç içerir. Bu süreci özetleyen bir şema, EEG tabanlı duygu durum analizinin temel adımları Şekil 2.10'da görülmektedir. Bu adımlar; veri toplama, ön işleme, özellik çıkarma, sınıflandırma ve sonuçların değerlendirilmesini içerir.



Şekil 2.10. EEG tabanlı duygu durum analizi adımları.

İlk adım, kişiye duygusal bir tepki oluşturacak bir uyarının verilmesini içerir. Bu uyarı, video, ses, resim gibi birçok türde olabilir. Amacı, katılımcının belirli bir duygusal duruma girmesini sağlamaktır. Bu adımla paralel olarak kayıtların alınması aşamasına geçilir. EEG sinyalleri bir kişinin kafa derisi üzerine yerleştirilen elektrotlar aracılığıyla toplanır ve kaydedilir. EEG cihazları, beyin elektriksel aktivitelerini kaydederek duygusal durumların analizine olanak tanır. Katılımcının belirli bir duygusal uyarıya karşılaştığında beyin dalgalarında meydana gelen değişiklikler, elektrotlar aracılığıyla kaydedilir. Bu adımda elektrotların doğru konumlandırılması ve sinyal kalitesinin yüksek olması, elde edilecek verilerin doğruluğu açısından kritiktir. Toplanan EEG verileri, ham haliyle birçok gürültü ve artefakt içerir. Artefaktlar, istenmeyen dış etkenlerden kaynaklanan ve analiz sonuçlarını yanıltabilecek anomalilerdir. Hareket artefaktları, göz kırpması, kalp atışı gibi faktörler, EEG sinyalini bozarak güvenilirliği azaltabilir [41]. Bu nedenle, ön işleme aşaması büyük önem taşır. Bu aşamada gürültü azaltma teknikleri, sinyal filtresyonu ve bağımsız bileşen analizi (ICA) gibi yöntemler kullanılır. Örneğin, bir katılımcının göz kırpması sırasında oluşan elektriksel aktivite, bağımsız bileşen analizi ile ayrıştırılarak

temiz EEG sinyali elde edilebilir. Ön işleme adımının ardından, EEG sinyallerinden anlamlı özellikler çıkarılır. Bu özellikler, genellikle zaman ve frekans domeninde hesaplanan çeşitli metriklerdir. Güç spektrumu, bant güçleri (alfa, beta, teta, delta, gama), dalga şekilleri ve korelasyonlar gibi özellikler, duygusal durumların tanımlanmasında kullanılır. Örneğin, bir kişinin alfa dalga aktivitesinin artışı, rahatlama veya düşük uyarılma durumu ile ilişkilendirilebilir. Bu özellikler, EEG sinyallerinin karmaşıklığını azaltarak sınıflandırma aşamasında kullanılabilir hale getirir. Çıkarılan özellikler, bir sınıflandırma modeli kullanılarak duygusal durumların tanınması ve tespit edilmesi amacıyla işlenir. Makine öğrenimi algoritmaları, sinir ağları, destek vektör makineleri(SVM), k-en yakın komşu(k-NN) ve karar ağaçları gibi yöntemler, EEG tabanlı duygu durum tespitinde yaygın olarak kullanılır. Bu aşamada, eğitim verileri kullanılarak modelin öğrenmesi sağlanır ve ardından test verileriyle modelin doğruluğu değerlendirilir. Örneğin, bir sinir ağı modeli, eğitim aşamasında farklı duygusal durumlara ait EEG verilerini öğrenir ve test aşamasında yeni verilerle bu durumları doğru bir şekilde sınıflandırabilir.

Son aşamada, sınıflandırma modeli tarafından elde edilen sonuçlar değerlendirilir ve yorumlanır. Bu değerlendirme, modelin doğruluğunu, hassasiyetini, özgüllüğünü ve genel performansını içerir. Ayrıca, elde edilen sonuçlar, duygusal durumların tespiti için klinik ve araştırma amaçlı kullanımlar açısından da analiz edilir. Örneğin, modelin belirli bir duygusal durumu %90 doğrulukla tespit edebilmesi, bu yöntemin klinik uygulamalarda kullanılabilirliğini artırır [25, 35, 42, 43].

2.6.1. Katılımcıların seçilmesi ve deney kurgusu

Duygu tanıma sürecini incelemek için uygun katılımcıların seçimi ve deney kurgusu son derece önemlidir. Katılımcılar, genellikle genç yetişkinler arasından, nörolojik ve psikolojik olarak sağlıklı bireyler olarak seçilir ve dengeli bir cinsiyet dağılımı sağlanır. Deney kurgusu, katılımcılara deney hakkında ayrıntılı bilgi verilmesi ve yazılı onaylarının alınmasıyla başlar. Daha sonra, katılımcıların rahat bir ortamda bulunmalarını sağlamak ve doğru sinyal alımını garanti etmek için EEG başlığı dikkatlice yerleştirilir ve gerekli ayarlamalar yapılır. Ön testlerle katılımcıların başlangıç duygu tanıma yetenekleri belirlenir. EEG tabanlı duygu tanıma çalışmalarında farklı duygu uyandırma teknikleri kullanılmıştır. Bunlar arasında standartlaştırılmış duygusal uyarıcılar (resimler, filmler ve sesler), hayal gücü teknikleri (rehberli imgeleme ve otobiyografik hatırlama), sosyal etkileşimler

(oyunlar) ve yönlendirilmiş yüz hareketleri görevleri bulunur. Birden fazla uyarının kullanılması, tek bir uyarının kullanılmasından daha etkili olabilir. Duygusal uyarılar genellikle güvenilir kaynaklardan, örneğin Uluslararası Duygusal Resim Sistemi (IAPS) ve Uluslararası Duygusal Dijital Sesler (IADS) gibi veri tabanlarından alınır. Ayrıca, hatırlama paradigması ve kolaylaştırıcı destekli diyalog etkileşimi gibi yöntemler de kullanılır. Katılımcıların bu uyarılara verdikleri tepkiler EEG ile kaydedilir. Veri toplama sürecinde, EEG sinyalleri ve katılımcıların davranışsal tepkileri (örneğin, düğmeye basma, sözel yanıtlar) kaydedilebilir. Deney sonrasında, katılımcılara son testler uygulanarak duygusal durumlarındaki değişiklikler değerlendirilir, deney hakkında geri bildirim toplanır ve sonuçlar raporlanır. Bu süreçler, deneyin geçerliliğini ve güvenilirliğini artırmak için dikkatlice planlanır ve uygulanır [42, 44].




3. MALZEME VE YÖNTEM

Bu aşamada tez çalışmasında kullanılan veri seti özellikleri ve duygu durum analizi adımları tanıtılacaktır.

3.1. Duygu Durum Veri Kümesi

Bu çalışmada, SEED-IV veri seti kullanılmıştır. SEED-IV veri seti, dört temel duyguyu (mutlu, üzgün, korku ve nötr) uyandırmak amacıyla bir dizi süreçten geçirilerek seçilmiş film kliplerini kullanarak gerçekleştirilen deneylerden elde edilen verileri içermektedir. Bu veri seti, araştırmacılar tarafından sağlanan ve akademik topluluğa açık olarak sunulan bir kaynaktır. Şekil 3.1’de veri setinin toplama süreci ve özellikleri detaylı olarak anlatılmaktadır.

Araştırmacılar, dört temel duyguyu uyandırmak amacıyla 168 film klipi belirlemiş ve klipler 44 üniversite öğrencisi katılımcıya izletilmiştir. Klipler görsel yorgunluğa neden olmayacak kadar kısa, anlaşılır ve tek bir hedef duyguyu uyandıracak şekilde seçilmiştir. Bu katılımcılar, izledikleri klipleri anahtar kelimelerle (mutlu, üzgün, nötr ve korku) ve iki boyutta (valans ve uyarılma) değerlendirmiştir. Valans, üzgünden mutluluğa, uyarılma ise sakinlikten heyecanlıya kadar uzanmaktadır [44].



Şekil 3.1. Gerçekleştirilen deney planı [44]

Değerlendirme sonuçlarına göre, araştırmacılar en yüksek eşleşmeye sahip 72 film klipini seçmiştir ve bu kliplerin her biri yaklaşık iki dakika sürmektedir. Veri kaydetme deneyleri, 20-24 yaş aralığında sağlıklı, sağ elini kullanan 15 katılımcı ile gerçekleştirilmiştir. Her film klipi yalnızca bir kez sunulmuş ve tekrardan kaçınmak


için her katılımcıya üç farklı günde üç farklı oturum düzenlemişlerdir. Her oturum 24 denemeden oluşmuş ve her deneme altı farklı duygusal klipi içermektedir. Bu kliplerin listesi her birinin dahil olduğu sınıf ile birlikte Tablo 3.1’de görülmektedir. Her klipten önce 5 saniyelik bir başlangıç ipucu ve ardından 45 saniyelik PANAS ölçekleri ile öz değerlendirme yapılmıştır. Katılımcılardan, izledikleri sırada hissettikleri duyguları değerlendirmeleri de istenmiştir. Her katılımcı, farklı günlerde üç kez deney yapmış ve toplamda 45 deney değerlendirilmiştir. Uluslararası 10-20 sistemine göre yerleştirilmiş 62 kanaldan simetrik temporal elektrotlar (FT7, FT8, T7, T8, TP7, TP8) EEG tabanlı duygu tanıma için kritik kanallar olarak seçilmiş ve kayıtlar alınmıştır. Ayrıca kıyaslama yapmak üzere 62 kanalın tamamından da EEG kaydı alınmıştır. Ham EEG verileri, ESI NeuroScan Sistemi kullanılarak 1000 Hz örnekleme hızında kaydedilirken göz hareketleri de eş zamanlı olarak SMI ETG göz izleme gözlükleri ile kaydedilmiştir [44].

Tablo 3.1. Deneyde kullanılan klipler ve sınıfları [44]

No	Sınıf	Klip İsmi
1	0	A Bite of China
2	0	A Bite of China
3	0	A Bite of China
4	0	A Bite of China
5	0	A Bite of China S1EP1
6	0	A Bite of China S1EP2
7	1	Black Keys
8	1	Very Happy
9	1	A Wedding Invitation
10	1	Dearest
11	1	Aftershock
12	1	Foster Father- Episode 3
13	2	The Eye
14	2	The Child's Eye
15	2	Bunshinsaba II
16	2	Bunshinsaba III
17	2	Hungry Ghost Ritual
18	2	Hungry Ghost Ritual
19	3	Rob-B-Hood
20	3	Promo for applying the Olympic Winter Games
21	3	Very Happy- Episode 64
22	3	You are my life more complete- Episode 10
23	3	Hear Me
24	3	Very Happy- Episode 5

3.2. Duygu Durum Analizi

Bu bölümde, EEG tabanlı duygu durum tespitinin nasıl gerçekleştirildiği adım adım irdelenecektir. İlk olarak kullanılan veri seti temel alınarak EEG tabanlı duygu durum tespitinin dört temel aşaması ayrıntılı olarak ele alınacaktır: veri toplama, ön işleme, özellik çıkarma, sınıflandırma. Ardından her bir adımın sonunda elde edilen bulgular ve sonuçlar paylaşılacaktır. Bu adımların veri seti oluşumundan sınıflandırma aşamasına kadar hangi sırayla gerçekleşeceğini gösteren akış diyagramı Şekil 3.2’de görülmektedir.




Şekil 3.2. SEED EEG duygu durum analizi adımları

3.2.1. EEG ön işleme süreci

Ön işlemede amaç performansı artırmak, iyileştirmektir. EEG verilerinin ön işlenmesinde kullanılan yaygın yöntemlerden biri, filtreleme işlemidir. Filtreleme, istenmeyen frekans bileşenlerini (örneğin, elektrik hattı gürültüsü) ortadan kaldırmak veya önemli sinyal bileşenlerini (beyin aktivitesi) korumak için kullanılır. Alçak geçiren filtreler, yüksek frekanslı gürültüyü filtrelerken, yüksek geçiren filtreler düşük frekanslı artefaktları azaltır. Bu sayede, sinyal-gürültü oranı artar ve analiz daha doğru hale gelir. Bir diğer önemli yöntem ise artefakt giderme işlemidir. Bu işlemde, EEG sinyaline eklenen artefaktlar, örneğin göz hareketleri veya kas aktivitesi gibi, tanımlanır ve giderilir. Böylece, beyin aktivitesine daha doğru bir şekilde odaklanılır ve analiz sonuçları güvenilir hale gelir.

3.2.1.1. Kanal seçimi

SEED-IV veri seti deney sürecini gerçekleştiren araştırmacılar, duygu tanımada üstün özellik gösteren simetrik temporal elektrotları (FT7, FT8, T7, T8, TP7, TP8) belirlemiş ve buna göre bir kayıt gerçekleştirmiştir [27]. Seçilen (FT7, FT8, T7, T8, TP7, TP8) simetrik temporal elektrotları Şekil 3.3'te işaretlenmiştir.



Şekil 3.3. Seçilen simetrik temporal elektrotlar [44]


3.2.1.2. Örneklem hızının Düşürülmesi

Örneklem hızının düşürülmesi bir sinyalin frekansını azaltarak daha az sayıda veri noktasıyla temsil edilmesi işlemidir. Bu işlem, genellikle işlemci yükünü azaltmak ve veri depolama gereksinimlerini düşürmek amacıyla kullanılır. EEG gibi zaman serisi verilerinde örneklem hızının düşürülmesi, sinyaldeki yüksek frekanslı bileşenlerin önemli olmadığı durumlarda kullanışlıdır. Örneğin, daha yavaş dalga formlarını analiz edilmek istendiğinde gereksiz verileri elemek ve analiz sürecini basitleştirmek için bu işlem yapılır. SEED-IV EEG veri seti 1000 Hz'de kaydedilmiş ve 200 Hz örnekleme hızına indirilmiştir.

3.2.1.3. Filtreleme

Gürültü bileşenlerini azaltmak amacıyla, EEG verilerine 0,3 ile 50 Hz arasında olan frekans bileşenlerini koruyacak şekilde bir bant geçiren filtre uygulanmıştır [27]. Band geçiren filtreler, belirli bir frekans aralığındaki sinyal bileşenlerini geçirip bu bandın dışındaki frekans bileşenlerini bastırarak çalışır. Amaçları arasında, istenmeyen frekans bileşenlerini bastırarak gürültüyü azaltmak, belirli frekans aralıklarındaki sinyal bileşenlerini izole ederek özellik çıkarma ve sinyalin kalitesini artırmak yer alır.

EEG sinyallerinde, alt frekans sinyallerini (alfa, beta, delta, teta, gama) izole ederek analiz edilmesini sağlar. Bant geçiren bir filtrenin frekans yanıtını temsil eden bir grafik Şekil 3.4'te görülmektedir.



Şekil 3.4. Band geçiren filtre diyagramı

3.2.2. Özellik çıkarma

Bu çalışmada özellik çıkarımı sürecinde, EEG verileri farklı alt frekans bantlarına (alfa, beta, gama, delta, teta) ayrılarak her bir bant için zaman domeni özellikleri, frekans domeni özellikleri ve istatistiksel özellikler hesaplanmıştır. EEG'nin geometrik özelliklerini incelemek üzere zaman domeni özellikleri çıkarılır [45].

EEG alt bantlarında farklı özellikler seçmek, her bir bandın beynin farklı aktivite türlerini yansıtmassından dolayı çeşitli bilişsel ve duygusal durumları daha iyi temsil etmesi açısından etkili olacaktır [46].

Kullanılan özellikler arasında ortalama, basıklık, çarpıklık, standart sapma, medyan, maksimum, minimum, Hijort aktivite, hareketlilik ve karmaşıklık katsayıları gibi istatistiksel özellikler ile otokorelasyon ve parsiyel otokorelasyon fonksiyonları gibi zaman serisi özellikleri bulunmaktadır.

Her bir sinyal için bu özellikler hesaplanarak tek bir özellik vektörü oluşturulmuş ve bu vektörler modelin eğitimi ve performans değerlendirmesi için kullanılmıştır. Bu süreç, ham EEG verilerinden anlamlı ve ayırt edici özelliklerin elde edilmesini sağlayarak modelin doğruluğunu artırmayı hedeflemektedir.

Çıkarılan özellikler, zaman domeni, frekans domeni ve istatistiksel özellikler olarak üç ana başlık altında sınıflandırılabilir. Her bir özellik, veri setindeki sinyallerin belirli bir yönünü karakterize eder. İstatistiğe dayalı özellik çıkarımının amacı, ham veriyi anlamlı ve kullanılabilir bir formata dönüştürmektir. Bu süreçte, ham veriden bilgi ve

kalıplar elde edilerek bu bilgilerin analiz ve modelleme süreçlerinde kullanılabilmesi sağlanır. Özellik çıkarımının amaçları şunlardır: Veri temsiliyi iyileştirme, boyut azaltma, karmaşıklığı azaltma, gürültüyü azaltma ve performans artışı.

Bu özelliklerden Autokorelasyon ve Toplam Harmonik Bozulma değerlerinin hesaplanma aşamaları aşağıda yer almaktadır.

Autokorelasyon (ACF1): Autokorelasyon fonksiyonu (ACF), bir zaman serisinin kendi geçmiş değerleriyle olan korelasyonunu ölçer. ACF1, bir zaman serisinin birinci gecikme autokorelasyonunu ifade eder. Hesaplama adımları aşağıda verilmiştir:

1. Veri Seti: $x = [x_1, x_2, \dots, x_n]$
2. Ortalama değerini hesaplanır: $\frac{1}{n} \sum_{i=1}^n x_i^2$
3. Her bir gecikme için autokorelasyon buundur: $ACF1 = \frac{\sum_{i=1}^{n-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$
4. İlk 10 ACF'nin karelerinin toplamını bulunur: $\sum_{k=1}^{10} (ACF(k))^2$

Toplam Harmonik Bozulma (THD): Toplam Harmonik Bozulma (THD), Toplam Harmonik Bozulma (THD), bir sinyalin harmonik bileşenlerinin gücünün, temel frekans bileşeninin gücüne oranı olarak ifade edilir. Bu metrik, sinyaldeki harmonik distorsiyonun seviyesini belirlemek için kullanılır. Hesaplama adımları aşağıda verilmiştir:

1. Harmonik bileşenlerin RMS değerlerinin bulunur:
 V_1 : Temel frekans bileşeninin (birinci harmonik) RMS değeri.
 V_k : k. harmonik bileşenin RMS değeri.
2. Harmonik oranlarının karelerinin hesaplanır ve toplam değer elde edilir: $(\frac{V_2}{V_1})^2 + (\frac{V_3}{V_1})^2 + \dots + (\frac{V_k}{V_1})^2$
3. THD hesaplanır: $THD = \sqrt{\sum_{k=2}^{\infty} (\frac{V_k}{V_1})^2}$

Çıkarılan tüm özelliklerin detaylı listesi ve tanımları Tablo 3.2'de verilmiştir.

Tablo 3.2. Çıkarılan özellikler ve tanımlayıcı denklemler.

No	Özellik	Denklem
1	Açıklık Faktörü (Clearance)	$CF = \frac{\max(x)}{\left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i }\right)^2}$
2	Tepe Faktörü (Crest)	$CrF = \frac{\max(x)}{RMS(x)}$
3	Darbe Faktörü (Impulse)	$IF = \frac{\max(x)}{\frac{1}{n} \sum_{i=1}^n x_i }$
4	Basıklık (Kurtosis)	$x_{kur} = \frac{\sum_{i=1}^n (x(i)-\bar{x})^4}{(n-1)S^4}$
5	Çarpıklık (Skewness)	$x_{ske} = \frac{\sum_{i=1}^n (x_i-\bar{x})^3}{(n-1)S^3}$
6	* Çeyrekler Arası Genişlik (IQR)	$IQR = iqr(x)$
7	Değişim Katsayısı (CV)	$DK = (S/\bar{x})100$
8	Geometrik Ortalama	$G = \sqrt[n]{x_1 + \dots + x_n}$
9	Harmonik Ortalama	$H = n / \left(\frac{1}{x_1} + \dots + \frac{1}{x_n} \right)$
10	Hijort Aktivite Katsayısı	$A = S^2$
11	Hijort Hareketlilik Katsayısı	$M = S_1^2 / S^2$
12	Hijort Karmaşıklık Katsayısı	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
13	* Maksimum	$x_{max} = \max(x_i)$
14	* Medyan	$x_{media} median = median(x)$
15	* Medyan Mutlak Sapma (MAD)	$MAD = mad(x)$
16	* Minimum	$x_{min} = \min(x_i)$
17	* Moment	$CM = moment(x, 10)$
18	Ortalama	$x = \frac{1}{n} * \sum_{i=1}^n x_i = \frac{1}{n} * (x_1 + \dots + x_n)$
19	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
20	Ortalama Karekök Değeri	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
21	Standart Hata	$S_{\bar{x}} = S/\sqrt{n}$

Tablo 3.2.(Devamı) Çıkarılan özellikler ve tanımlayıcı denklemler.

22	Standart Sapma	$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
23	Şekil Faktörü	$SF = X_{mms} / \left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)$
24	Tekil Değer Ayırışımı (SVD)	$SVD = \text{svd}(x)$
25	%25 için Kırpılmış Ortalama	$T25 = \text{trimmean}(x, 25)$
26	%50 için Kırpılmış Ortalama	$T50 = \text{trimmean}(x, 50)$
s27	Toplam Harmonik Bozulma (THD)	$THD = \sqrt{\sum_{k=2}^{\infty} \left(\frac{V_k}{V_1} \right)^2}$
28	Birinci Çeyrek (Q1)	$Q1 = \text{Alt de\u011fer} + (\text{Kesir} \times (\text{Üst de\u011fer} - \text{Alt de\u011fer}))$
29	Üçüncü Çeyrek (Q3)	$Q3 = \text{Alt de\u011fer} + (\text{Kesir} \times (\text{Üst de\u011fer} - \text{Alt de\u011fer}))$
30	Otokorelasyon (ACF1)	$ACF1 = \frac{\sum_{i=1}^{n-1} (x_i - \bar{x})(x_{i+1} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$
31	İlk 10 ACF'nin Toplamı	$\sum_{k=1}^{10} (ACF(k))^2$
32	Parsiyel ACF (PACF1)	$PACF1 = \text{parsiyel otokorelasyon}(x, 1)$
33	İlk 5 PACF'nin Toplamı	$\sum_{k=1}^5 (PACF(k))^2$
34	95. Yüzdelik (Quantile 0.95)	$\text{quantile}(x, 0.95)$

* Simgesi Matlab ile hesaplanan özellikleri ifade etmektedir.

Özellikle, Tepe Faktörü ve Darbe Faktörü gibi özellikler, sinyalin tepe değerlerini ve darbe özelliklerini anlamak için önemlidir. Otokorelasyon fonksiyonu (ACF) ve parsiyel otokorelasyon fonksiyonu (PACF) ise sinyalin zaman içindeki bağımlılıklarını analiz etmemize yardımcı olur. Zaman domeni özellikleri, sinyalin zamanla nasıl değiştiğini ifade eder ve özellikler, sinyalin belirli noktalarındaki değerleri ve bu değerlerin zaman içindeki dağılımını dikkate alır. Frekans domeni özellikleri, sinyalin frekans bileşenlerini ifade eder, sinyalin frekans spektrumundaki enerji dağılımını ve frekans karakteristiklerini dikkate alır. Temel istatistiksel parametrelerini içeren özellikler ise sinyalin dağılımını ve genel özelliklerini ifade eder.


3.2.3. Özellik sıralama

Özellik sıralama, büyük veri setlerinde model performansını artırmak için kritik olup, bu tez çalışmasında Spearman korelasyon katsayısı kullanılarak yapılmıştır. Bu yöntemde asıl amaç, bağımsız değişkenlerin bağımlı değişkenle olan ilişki düzeyini belirlemektir. Öncelikle her bir özelliğin bağımlı değişkenle olan korelasyon katsayısı hesaplanır, ardından bu katsayılar sıralanır ve en yüksek korelasyona sahip özellikler seçilir. Bu sayede, modelin karmaşıklığı azaltılır. Sonuç olarak, Spearman korelasyon katsayısı kullanımı, modelin performansını artırmak ve en anlamlı özellikleri belirlemek için etkili bir yöntemdir [47].

Spearman korelasyon katsayısının matematiksel ifadesi şu şekildedir:

$$\rho = 1 - \frac{6 \sum di^2}{n(n^2 - 1)} \quad (3.1)$$

Burada ρ , Spearman korelasyon katsayısı; di , her bir çift için sıralama farklarının farkı ve n , veri setindeki örnek sayısıdır [47]. İşlem basamaklarına ait akış diyagramı Şekil 3.5’de görülmektedir.



Şekil 3.5. Spearman korelasyon katsayısı hesaplama

SEED EEG verilerinden çıkarılan 34 adet özellik, Spearman korelasyonu ile incelenerek modelin performansının artırılması hedeflenmiştir. Bu süreç, duyguların EEG verilerinden etkili bir şekilde analiz edilmesini sağlayarak duygu tanıma sistemlerinin geliştirilmesine katkı sağlamaktadır.

3.2.4. Sınıflandırma

Sınıflandırma aşamasında elde edilen özellik vektörü çözümlenerek duygusal durum belirlenir. Duygu kestirimi için önceki çalışmalarda K-en yakın komşu, Destek Vektör Makinesi, Diskriminant Analizi gibi pek çok sınıflandırıcı yöntem kullanılmıştır.

Topluluk sınıflandırıcılar daha kararlı olduğu için fazlaca tercih edilmektedir [48]. Topluluk sınıflandırıcılar birden fazla modelin yaptığı tahminleri toplama esasına dayanır ve doğruluğu artırdığı görülmüştür [49].

Çalışmada yüksek doğruluk oranı ortaya koyan Ensemble Bagged Trees (Bootstrap Aggregating Trees) topluluk sınıflandırıcı kullanılmıştır. Bu yöntem, birçok karar ağacının bir araya getirilerek oluşturulmuş bir ensemble (topluluk) yöntemidir. Matematiksel olarak, bu algoritma aşağıdaki adımları içerir:


İlk olarak Bootstrap Örnekleme denilen süreç gerçekleşir. Eğitim veri setinden tekrarlı rastgele örneklem alınır. Her bir örnek, orijinal veri setinden rastgele örneklendiği için aynı veri noktaları tekrar tekrar seçilebilir. Ardından ağaçların oluşturulması sürecine geçilir. Burada her örnek veri kümesi için bir karar ağacı oluşturulur. Karar ağaçları, veri kümesindeki özellikler arasında bölünmeler yaparak sınıflandırma yapar. Bu adımda, her bir ağaç aynı anda ve bağımsız olarak inşa edilir. Ağaç oluşumunun tamamlanmasıyla birlikte topluluk oluşturma süreci başlar. Bu adımda oluşturulan karar ağaçları bir araya getirilir ve toplu bir tahmin yapmak için kullanılır. Sınıflandırma yapılırken, her ağaç kendi tahminini yapar ve ardından tüm ağaçların tahminleri birleştirilir. En yaygın tahmin alınarak nihai tahmin belirlenir. Test veri seti üzerinde model eğitildikten sonra, her bir ağaç tarafından yapılan tahminlerin ortalaması alınarak son tahmin yapılır. Ensemble Bagged Trees modeli, birçok avantajı beraberinde getirmektedir. Aynı zamanda farklı veri alt kümelerinde eğitilmiş birden fazla modelin tahminlerinin ortalaması alınarak, modelin sapmasını düşürür ve daha tutarlı sonuçlar elde edilmesine yardımcı olur.

Bagged modeller, eğitim veri kümesindeki değişikliklere daha az duyarlıdır, bu da genel modelin daha kararlı olmasını sağlar. Yüksek varyansa sahip algoritmalar için etkili olan bu yöntem, yüksek değişkenliği yönetmede avantaj sağlar. Ayrıca, paralel işleme ve hesaplama kaynaklarının etkin kullanımını mümkün kılar. Yöntem, basit bir kavram üzerine kurulmuştur ve uygulanması kolaydır. Gürültülü verilerde daha iyi performans gösterir ve dengesiz veri kümeleriyle başa çıkmada etkilidir, böylece model performansını artırır [50].

Bu yöntemle toplamda 34 özellikten oluşan özel SEED veri seti eğitilmiştir. Ensemble Bagged Trees yönteminin matematiksel ifadesi şu şekildedir:

$$f_{avg}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (3.2)$$

Denklem 3.2.'de yer alan $f_{avg}(x)$ ifadesi test örneği x için yapılan tahmini; B , ağaçların sayısını ve $T_b(x)$ ise her bir ağaca ait x değeri için tahmini ifade etmektedir [50]. Modelin şematik gösterimi Şekil 3.6'da yer almaktadır.



Şekil 3.6. Ensemble Bagged Trees modeli.

Elde edilen özellikler bu tez çalışmasında iki şekilde sınıflandırma işlemine alınarak iki farklı sonuç değerlendirmesi yapılmıştır.

İlk sınıflama işleminde deneklere ait EEG sinyalinin beş alt frekans bandının tamamından çıkarılan özellikler dikkate alınarak inceleme yapılmıştır. İkinci işlemde ise beş alt frekans bandından çıkarılan özellikler her bir frekans bandının ayrı ayrı sınıflandırma işleminden geçirilerek her bir bandın duygu durumu kestiriminde etkinliği araştırılmıştır. Yani duygu durumu tek bir frekans bandı ele alınarak tespit edilmek istenmiş ve beş farklı frekans bandı için (Delta, Teta, Alfa, Beta ve Gama) beş farklı sonuç değerlendirmesi yapılmıştır.

3.3. Sınıflandırma Performansı

Sınıflandırma modellerinin performansını değerlendirmede kullanılan karmaşıklık matrisi, kullanılan modeli açıklamada oldukça önemlidir. Bu matris, modelin sınıflandırma sonuçlarını detaylı bir şekilde görselleştirir ve hangi sınıfların ne kadar doğru veya yanlış sınıflandırıldığını net bir şekilde ortaya koyar. Doğruluk değeri, modelin toplam doğru sınıflandırma oranını ifade ederken, hata değeri ise modelin yapmış olduğu hatalı sınıflandırmaların oranını gösterir. Özellikle karmaşıklık matrisi, modelin performansını anlamak ve iyileştirmek için önemli bir araçtır [51].

Bu ölçütlere TP: Doğru Pozitif (True Positive), TN: Doğru Negatif (True Negative), FP: Yanlış Pozitif (False Positive), FN: Yanlış Negatif (False Negative) tanımlamalarını dikkate alarak bakacak olursak;

Doğruluk, modelin doğru tahmin ettiği örneklerin toplam tahminlere oranıdır. Tüm sınıflar arasında doğru tahminlerin oranını gösterir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.3)$$

Kesinlik, modelin gerçekten pozitif olan örnekleri doğru bir şekilde sınıflandırma yeteneğini ölçer.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.4)$$

Duyarlılık, gerçekten pozitif olan örneklerin ne kadarının doğru bir şekilde pozitif olarak tahmin edildiğini ölçen bir metriktir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.5)$$

F1-Skoru, bir sınıflandırma modelinin kesinlik (3.4) ve duyarlılık (3.5) performanslarını dengeli bir şekilde ve aynı anda değerlendirmemize olanak sağlar.

$$F1 - \text{Skoru} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.6)$$

ROC Eğrisi, modelin karar sınırını değiştirdikçe doğru pozitif oranı (True Positive Rate - TPR) ve yanlış pozitif oranı (False Positive Rate - FPR) arasındaki ilişkiyi gösterir. AUC (Area Under the Curve) ise ROC eğrisinin altında kalan alanı ifade eder. AUC değeri 0.5'e yaklaştıkça model tahminlerinin rastgele olduğu, 1'e yaklaştıkça model tahmin yeteneğinin mükemmele yaklaştığı anlaşılır.

TPR (True Positive Rate), modelin belirli bir sınıfı doğru tanıma oranını gösterir, modelin bir sınıfa ait örneklerin ne kadarını doğru bir şekilde tanımladığını ifade eder.

FNR (False Negative Rate), modelin yanlış negatif oranını gösterir. Modelin, pozitif olarak tanımlaması gereken ancak yanlışlıkla negatif olarak tanımladığı örneklerin oranını yansıtır.

PPV (Positive Predictive Value), modelin pozitif tahminlerinin ne kadarının doğru olduğunu gösterir. Diğer bir deyişle, modelin pozitif olarak tahmin ettiği sınıfların ne kadarının gerçekte doğru olduğunu yansıtır.

FDR (False Discovery Rate), modelin yanlış pozitif oranını gösterir. Pozitif olarak tahmin edilen sınıfların ne kadarının yanlış olduğunu yansıtır.



4. BULGULAR VE SONUÇLAR

Aşağıda Matlab ortamında Ensemble Bagged Trees modeli ile eğitilerek test edilen veri setine ait sonuçlar yer almaktadır. İlk değerlendirme deneklere ait EEG sinyalinin beş alt frekans bandının tamamından çıkarılan özellikler dikkate alınarak yapılmış sınıflama sonuçlarını göstermektedir. İkinci değerlendirmede ise beş alt frekans bandından çıkarılan özellikler her bir frekans bandının ayrı ayrı sınıflandırma işleminden geçmesiyle elde edilmiştir.

İlk sınıflandırma işlemine ait bulgular aşağıda paylaşılmıştır.

Modelin genel doğruluk oranı yaklaşık %94.4 olarak hesaplanmıştır. Bu yüksek doğruluk oranı, modelin dört duygu sınıfını (Nötr, Üzüntü, Korku ve Mutluluk) başarılı bir şekilde ayırt edebildiğini ve genel olarak güvenilir bir performans sergilediğini ortaya koymaktadır.

Yüksek genel doğruluk oranı, modelin sadece belirli bir sınıfta değil, tüm sınıflar genelinde dengeli ve doğru tahminler yapabildiğini göstermektedir. Özellikle karmaşık ve birbirine yakın özelliklere sahip olan duyguların doğru bir şekilde sınıflandırılması, modelin üstün genel performansının bir göstergesidir. Bu sonuçlar, modelin geniş bir duygu spektrumunda başarılı bir şekilde çalışabildiğini ve pratik uygulamalarda güvenilir sonuçlar verebileceğini göstermektedir. Özellikle duygusal analiz ve tanıma gibi alanlarda, modelin yüksek doğruluk oranı, duygusal durumların doğru bir şekilde tespit edilmesine katkıda bulunabilir.

Tablo 4.1’de modele ait karmaşıklık matrisi, Tablo 4.2’de ise model performans değerleri görülmektedir.

Tablo 4.1. Model karmaşıklık matrisi.

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	514	17	2	7
Üzüntü (1)	10	521	7	2
Korku (2)	17	3	504	16
Mutluluk (3)	13	9	17	501

Tablo 4.2. Model performans deęerlendirmesi.

Sınıf	Örnek Sayısı	Doęruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	540	0.9694	0.9519	0.9278	0.9397
Üzüntü (1)	540	0.9778	0.9648	0.9473	0.9560
Korku (2)	540	0.9713	0.9333	0.9509	0.9421
Mutluluk (3)	540	0.9704	0.9278	0.9525	0.9400

Modelde toplamda 2700 örnek alınmış ve %80- %20 oranında eğitim ve test olarak ayrılmıştır. 2160 örnek eğitim için kullanılırken 540 örnek Ensemble Bagged Trees modelinin performansını test etmek üzere kullanılmıştır. Modelde 34 adet öznitelik kullanılmış ve Ensemble Bagged Trees %94.4 doęruluk oranı sergilemiştir. Sınıflandırma sonuçları, karmaşıklık matrisinden elde edilen metriklerle detaylandırılmıştır. Her bir duygu durumu için hesaplanan doęruluk, kesinlik, duyarlılık ve F1 skoru aşağıda yorumlanmıştır:

Nötr durum için modelin kesinlik ve duyarlılık deęerleri oldukça yüksektir. Kesinlik, modelin nötr durumları yanlış pozitif olarak tahmin etme olasılığının düşük olduğunu gösterirken; duyarlılık, modelin nötr durumları doęru bir şekilde tanımlama kabiliyetinin yüksek olduğunu ortaya koymaktadır. Bu sonuçlar, nötr durumun model tarafından güvenilir bir şekilde tespit edilebildiğini göstermektedir.


Üzüntü sınıfı için elde edilen doęruluk ve F1 skoru deęerleri, bu duygunun yüksek bir doęrulukla tanımlandığını ve modelin bu sınıfı tanımlamada başarılı olduğunu göstermektedir. Duyarlılığın yüksek olması, modelin üzüntü durumlarını genellikle kaçırmadığını, kesinliğin yüksek olması ise modelin üzüntü durumunu yanlış bir şekilde dięer duygularla karıştırma olasılığının düşük olduğunu göstermektedir.

Korku sınıfı için de modelin performansı genel olarak yüksektir. Duyarlılık, modelin korku durumlarını tanımlamada başarılı olduğunu, kesinlik ise bu sınıfı tanımlarken dięer sınıflarla karışma olasılığının düşük olduğunu göstermektedir. F1 skoru, modelin korku sınıfındaki genel performansının dengeli olduğunu ortaya koymaktadır. Bununla birlikte, bu sınıf için duyarlılık, kesinlikten biraz daha düşük, bu da korku durumlarının tanımlanmasında küçük bir hata payı olabileceğini göstermektedir.

Mutluluk sınıfı için modelin duyarlılığı, dięer sınıflara göre nispeten daha düşük olmasına rağmen, genel doęruluk ve kesinlik yüksektir. Bu, modelin mutluluęu

tanımada başarılı olduğunu ancak bu sınıf için yanlış negatiflerin (mutluluğu tanımada başarısız olma) biraz daha fazla olabileceğini göstermektedir. Kesinlik değeri, modelin mutluluğu yanlış bir şekilde başka bir duygu durumu olarak tanımlama olasılığının düşük olduğunu ortaya koymaktadır.


Modelin TPR ve FNR değerlerini gösteren matris yapısı Şekil 4.1’de görülmektedir.



Şekil 4.1. Değerlendirme matrisi “TPR ve FNR”.

Sınıf 1 (Üzüntü) için en yüksek TPR değeri görülürken, Sınıf 3(Mutluluk) için biraz daha düşük bir oran görülmektedir. FNR değerleri ise modelin yanlış negatif oranlarını ortaya koyar. Burada, Sınıf 3 için FNR en yüksek değere sahipken, Sınıf 1 için en düşük FNR oranı gözlemlenmiştir.

Benzer şekilde model sonuçlarını yorumlayan PPV ve FDR değerlendirme matrisi Şekil 4.2’de mevcuttur.




Şekil 4.2. Değerlendirme matrisi “PPV ve FDR”.

PPV değerleri, modelin doğru pozitif tahminlerde oldukça başarılı olduğunu göstermektedir. Sınıf 2 (Korku) ve Sınıf 3 (Mutluluk) için PPV en yüksekken, Sınıf 0 (Nötr) için biraz daha düşük bir değer görülmektedir. FDR değerleri ise yanlış pozitif oranlarının oldukça düşük olduğunu ve modelin pozitif tahminlerde genellikle isabetli olduğunu göstermektedir.

ROC eğrileri, modelin performansını görselleştirmek ve değerlendirmek için kullanılan önemli araçlardır. ROC eğrisi, farklı kesme (threshold) değerleri için modelin doğru pozitif oranı (TPR, duyarlılık) ve yanlış pozitif oranı (FPR) değerlerini gösterir.


Modele ait Nötr sınıfı için elde edilen ROC eğrisi Şekil 4.3’de görülmektedir.



Şekil 4.3. Nötr sınıfı için elde edilen ROC eğrisi.

Nötr durumlar için ROC eğrisi, sol üst köşeye oldukça yakındır ve eğri altında kalan alan (AUC) 0.994 olarak hesaplanmıştır. Bu yüksek AUC değeri, modelin nötr durumları doğru bir şekilde tanıma kabiliyetinin çok yüksek olduğunu göstermektedir. Yanlış pozitif oranı oldukça düşük ve duyarlılık neredeyse 1'e yakındır, bu da modelin nötr sınıfını diğer sınıflardan ayırmada başarılı olduğunu göstermektedir.

Modele ait Üzüntü sınıfı için elde edilen ROC eğrisi Şekil 4.4'de görülmektedir.




Şekil 4.4. Üzüntü sınıfı için elde edilen ROC eğrisi.

Üzüntü sınıfı için AUC değeri 0.9962'dir. Bu, modelin üzüntü durumlarını tanıma performansının son derece yüksek olduğunu gösterir. ROC eğrisinin sol üst köşeye yakın olması, modelin üzüntü sınıfında hem düşük yanlış pozitif oranına hem de yüksek doğru pozitif oranına sahip olduğunu belirtir. Üzüntü durumlarını diğer

duygulardan ayırt etme konusunda modelin güçlü bir performans sergilediği görülmektedir.


Korku sınıfı için AUC değeri 0.9948, modelin mükemmel yakın bir performans sergilediğini vurguluyor. Eğri, modelin düşük hata oranıyla doğru şekilde korku sınıfını tanımlayabildiğini ortaya koyuyor, bu da modelin güvenilir ve güçlü bir sınıflandırıcı olduğunu işaret ediyor. Modele ait Korku sınıfı için elde edilen ROC eğrisi Şekil 4.5’de görülmektedir.



Şekil 4.5. Korku sınıfı için elde edilen ROC eğrisi.


Mutluluk sınıfı için Ensemble Bagged Trees modelinin performansını gösteren ROC eğrisinde, AUC değeri 0.9947 olarak verilmiştir, bu da modelin çok yüksek bir doğrulukla çalıştığını gösterir. Model, düşük bir yanlış pozitif oranıyla yüksek doğru pozitif oranı elde etmiştir. Bu, mutluluk sınıfını çok başarılı bir şekilde tanımladığını gösterir.

Mutluluk sınıfı için elde edilen ROC eğrisi Şekil 4.6’da görülmektedir.



Şekil 4.6. Mutluluk sınıfı için elde edilen ROC eğrisi.

Sınıfların birbiriyle performanslarını kıyaslamak üzere çizdirilen ROC eğrisi Şekil 4.7’de görülmektedir.



Şekil 4.7. Tüm sınıflar için elde edilen ROC eğrileri.

Tüm sınıflar için AUC değerlerinin 0.994 ile 0.9962 arasında değişmesi, modelin her bir duygu durumunu oldukça yüksek doğrulukla sınıflandırabildiğini göstermektedir. Bu yüksek AUC değerleri, modelin duygu tanıma görevinde genel olarak başarılı olduğunu ve ROC eğrilerinin eğimi, modelin düşük yanlış pozitif oranlarıyla yüksek duyarlılık sağladığını göstermektedir. ROC eğrilerinin sol üst köşeye yakınlığı, modelin sadece bir sınıfta değil, tüm sınıflarda etkili bir performans gösterdiğini ortaya koymaktadır.

İkinci sınıflandırma işlemine ait bulgular sırasıyla Delta, Teta, Alfa, Beta ve Gama bantları için aşağıda yer almaktadır. Her bir frekans bandına özel olarak veri seti %80-%20 oranında eğitim ve test olarak ayrılmıştır. Her bir frekans bandı için olarak çıkarılan özellikler ilgili bandın değerlendirmesine alınmıştır. İlk sınıflamada olduğu gibi Ensemble Bagged Trees modeli kullanılmıştır.

- **Delta (0,5-4) Hz:**

Delta bandı için yapılan sınıflama işleminde Ensemble Bagged Trees modeli %69.9 doğruluk oranı sergilemiştir. Modelin Delta bandı için karmaşıklık matrisi **Tablo 4.3**'de görülmektedir.

Tablo 4.3. Delta bandı için karmaşıklık matrisi

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	81	12	8	7
Üzüntü (1)	23	76	7	2
Korku (2)	7	0	86	15
Mutluluk (3)	21	9	19	59

Modelin performans verileri **Tablo 4.4**'de verilmiştir.

Tablo 4.4. Delta bandı performans değerlendirmesi

Sınıf	Örnek Sayısı	Doğruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	108	0.819	0.750	0.614	0.675
Üzüntü (1)	108	0.877	0.704	0.784	0.741
Korku (2)	108	0.870	0.796	0.717	0.754
Mutluluk (3)	108	0.831	0.546	0.711	0.618

- **Teta (4-8) Hz:**

Teta bandı için yapılan sınıflama işleminde Ensemble Bagged Trees modeli %74.8 doğruluk oranı saptanmıştır. Modelin ortaya koyduğu sonuçlara göre oluşturulmuş karmaşıklık matrisi **Tablo 4.5**'de görülmektedir.

Tablo 4.5. Teta bandı için karmaşıklık matrisi

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	84	11	1	12
Üzüntü (1)	16	77	6	9
Korku (2)	5	1	88	14
Mutluluk (3)	11	8	15	74

Modelin performans verileri **Tablo 4.6**'da verilmiştir.

Tablo 4.6. Teta bandı performans değerlendirmesi

Sınıf	Örnek Sayısı	Doğruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	108	0.870	0.778	0.724	0.750
Üzüntü (1)	108	0.882	0.713	0.794	0.751
Korku (2)	108	0.903	0.815	0.800	0.807
Mutluluk (3)	108	0.840	0.685	0.679	0.682

- **Alfa (8-12) Hz:**

Alfa bandı için yapılan sınıflama işleminde Ensemble Bagged Trees modeli %73.8 doğruluk oranı sergilemiştir.

Modelin alfa bandı için karmaşıklık matrisi **Tablo 4.7**'de görülmektedir.

Tablo 4.7. Alfa bandı için karmaşıklık matrisi

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	88	7	2	11
Üzüntü (1)	25	71	3	9
Korku (2)	2	2	90	14
Mutluluk (3)	12	4	22	70

Modelin performans verileri **Tablo 4.8**'de verilmiştir.

Tablo 4.8. Alfa bandı performans değerlendirmesi

Sınıf	Örnek Sayısı	Doğruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	108	0.863	0.815	0.693	0.749
Üzüntü (1)	108	0.884	0.657	0.845	0.740
Korku (2)	108	0.896	0.833	0.769	0.800
Mutluluk (3)	108	0.833	0.648	0.673	0.660

- **Beta (12-22) Hz:**

Beta bandı için yapılan sınıflama işleminde Ensemble Bagged Trees modeli %75.0 doğruluk oranı sergilemiştir. Modelin alfa bandı için karmaşıklık matrisi **Tablo 4.9**'da görülmektedir.

Tablo 4.9. Beta bandı için karmaşıklık matrisi

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	76	18	1	13
Üzüntü (1)	12	81	5	10
Korku (2)	4	0	90	14
Mutluluk (3)	11	7	13	77

Modelin performans verileri **Tablo 4.10**'da verilmiştir.

Tablo 4.10. Beta bandı performans değerlendirmesi

Sınıf	Örnek Sayısı	Doğruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	108	0.863	0.704	0.738	0.720
Üzüntü (1)	108	0.880	0.750	0.764	0.757
Korku (2)	108	0.914	0.833	0.826	0.829
Mutluluk (3)	108	0.843	0.713	0.675	0.694

- **Gama (22-30) Hz:**

Beta bandı için yapılan sınıflama işleminde Ensemble Bagged Trees modeli %73.1 doğruluk oranı sergilemiştir. Modelin alfa bandı için karmaşıklık matrisi **Tablo 4.11**'de görülmektedir.

Tablo 4.11. Gama bandı için karmaşıklık matrisi

Gerçek \ Tahmin	Nötr (0)	Üzüntü (1)	Korku (2)	Mutluluk (3)
Nötr (0)	76	19	2	11
Üzüntü (1)	13	85	5	5
Korku (2)	9	0	84	15
Mutluluk (3)	6	8	23	71

Modelin performans verileri **Tablo 4.12**'de verilmiştir.

Tablo 4.12. Gama bandı performans değerlendirme

Sınıf	Örnek Sayısı	Doğruluk	Duyarlılık	Kesinlik	F1-Skoru
Nötr (0)	108	0.861	0.704	0.731	0.717
Üzüntü (1)	108	0.884	0.787	0.759	0.773
Korku (2)	108	0.875	0.778	0.737	0.757
Mutluluk (3)	108	0.843	0.657	0.696	0.676



5. SONUÇ VE TARTIŞMA

Bu tez çalışmasında, EEG tabanlı duygu durum tespiti amacıyla SEED-IV veri seti üzerinde çeşitli ön işleme, özellik çıkarma ve sınıflandırma adımları uygulanmıştır.

Bölüm 3'te, ön işleme aşamasında, EEG verilerinin kalitesini artırmak ve analiz sonuçlarını iyileştirmek amacıyla çeşitli yöntemler kullanılmıştır. İlk olarak, filtreleme işlemi uygulanmış ve istenmeyen frekans bileşenleri ortadan kaldırılarak beyin aktivitesi gibi önemli sinyal bileşenlerinin korunması sağlanmıştır. Bu sayede, sinyal-gürültü oranı artırılmış ve analizler daha güvenilir hale getirilmiştir. Ön işlemeye dahil edilen bir diğer önemli adım ise artefakt giderme işlemidir. Bu adımda, EEG sinyaline eklenen göz hareketleri veya kas aktivitesi gibi artefaktlar tanımlanmış ve bu sinyallerden çıkarılmıştır. Böylece, beyin aktivitesine daha doğru bir şekilde odaklanılarak analiz sonuçlarının doğruluğu artırılmıştır.

Kanal seçimi aşamasında, SEED-IV veri seti üzerinde yapılan deneylerde, duygu tanımda üstün performans gösteren simetrik temporal elektrotlar (FT7, FT8, T7, T8, TP7, TP8) seçilerek kayıtlar alınmıştır. Bu, duygu durum tespiti için kritik olan EEG sinyallerinin doğru bir şekilde yakalanmasına olanak sağlamıştır.

Önişleme sürecinde son olarak, örneklem hızının düşürülmesi işlemi gerçekleştirilmiş ve SEED-IV EEG veri seti 1000 Hz'den 200 Hz'e indirilmiştir. Bu adım, veri boyutunu ve işlemci yükünü azaltarak, analiz sürecini daha verimli hale getirmiştir.

Özellik çıkarma adımı, modelin performansını kayda değer ölçüde artıran kritik bir aşama olmuştur. EEG verileri, farklı alt frekans bantlarına (Delta, Teta, Alfa, Beta, Gama) ayrılarak her bir bant için zaman domeni, frekans domeni ve istatistiksel özellikler hesaplanmıştır. Bu özelliklerin hesaplanması, sinyallerin belirli yönlerini karakterize ederek duygu durumlarını daha iyi temsil etmeyi hedeflemiştir.

Özellik çıkarma sürecinde elde edilen özellikler, modelin eğitimi ve performans değerlendirmesi için tek bir özellik vektörü oluşturulması amacıyla kullanılmıştır. Özellikle, zaman domeni özellikleri, sinyalin zamanla nasıl değiştiğini ve belirli noktalarındaki değerlerin zaman içindeki dağılımını ifade ederken, frekans domeni

özellikleri, sinyalin frekans spektrumundaki enerji dağılımını dikkate almıştır. Temel istatistiksel parametreler ise sinyalin genel dağılımını ve özelliklerini ifade etmiştir.

Bu çalışmada, otokorelasyon ve toplam harmonik bozulma gibi zaman serisi özellikleri de hesaplanarak sinyalin zaman içindeki bağımlılıkları ve harmonik bileşenleri analiz edilmiştir. Ayrıca tepe faktörü ve darbe faktörü gibi özellikler, sinyalin tepe değerlerini ve darbe özelliklerini anlamak açısından önem arz etmektedir. Bu özelliklerin çıkarılması, modelin duygu durumlarını daha hassas bir şekilde ayırt etmesine katkı sağlamıştır.

Elde edilen özellikler, iki farklı sınıflama işleminde değerlendirilmiştir. İlk sınıflama işleminde, deneklere ait EEG sinyalinin beş alt frekans bandının tamamından çıkarılan özellikler kullanılarak genel bir duygu durumu kestirimi yapılmıştır. Bu işlem, modelin tüm frekans bantlarını bir arada kullanarak yüksek doğruluk oranlarına ulaşmasını sağlamıştır. İkinci sınıflama işleminde ise her bir frekans bandı ayrı ayrı değerlendirilmiş ve her bandın duygu durumu kestiriminde etkinliği incelenmiştir. Bu yaklaşım, belirli frekans bantlarının belirli duyguların tespiti konusunda daha etkili olabileceğini göstermiştir. Böylelikle tek bir bant ile duygu durumu keşfinin daha düşük maliyetle (işlem hacmi vs.) yapılması hedeflenmiş ve belli ölçüde başarımlar elde edilmiştir.

Çalışmada EEG tabanlı duygu durum tespiti amacıyla kullanılan SEED-IV veri seti üzerine Ensemble Bagged Trees modeli uygulanmıştır. Elde edilen bulgular, modelin dört duygu sınıfını (nötr, üzüntü, korku, mutluluk) başarılı bir şekilde ayırt edebildiğini göstermektedir. Modelin genel doğruluk oranı %94.4 olarak hesaplanmış olup, bu oran literatürdeki benzer çalışmalarla uyumlu ve yüksek bir performansı işaret etmektedir.

Model, tüm frekans bantları birlikte değerlendirildiğinde, duygu sınıfları arasında yüksek doğruluk oranları sergilemiştir. Nötr ve üzüntü sınıflarında özellikle yüksek doğruluk ve duyarlılık oranlarına ulaşılmıştır. Bununla birlikte, korku ve mutluluk sınıflarında da tatmin edici sonuçlar elde edilmiştir, ancak özellikle mutluluk sınıfı için duyarlılık oranı diğer sınıflara kıyasla biraz daha düşük kalmıştır. Bu durum, modelin mutluluğu tanımlamada diğer duygulara göre daha az başarılı olabileceğini düşündürmektedir.

Modelin ortaya koyduğu performans **Tablo 5.1**'de derlenmiştir.

Tablo 5.1. Ensemble Bagged Trees modeli performans deęerlendirmesi

Doęruluk	Tüm Bantlar	Delta (δ)	Teta (θ)	Alfa (α)	Beta (β)	Gama (γ)
Nötr (0)	0.9694	0.8190	0.8700	0.8630	0.8630	0.8610
Üzüntü (1)	0.9778	0.8770	0.8820	0.8840	0.8800	0.8840
Korku (2)	0.9713	0.8700	0.9030	0.8960	0.9140	0.8750
Mutluluk (3)	0.9704	0.8310	0.8400	0.8330	0.8430	0.8430
Genel	0.9440	0.6990	0.7480	0.7380	0.7500	0.7310

Tablo 5.1'de yer alan Ensemble Bagged Trees modeli performans deęerlendirmesi, farklı frekans bantları (Delta, Teta, Alfa, Beta, Gama) ve tüm bantlar kullanılarak yapılan sınıflandırma işlemlerinde modelin gösterdiği doęruluk oranlarını sunmaktadır. Tablo, modelin her bir duygu durumu (Nötr, Üzüntü, Korku, Mutluluk) için doęruluk performansını ayrıntılı bir şekilde ele almaktadır.

- **Nötr Durum**

Nötr durum için model, tüm bantlar bir arada kullanıldığında %96.94 gibi oldukça yüksek bir doęruluk oranına ulaşmıştır. Bu, nötr durumun model tarafından doęru bir şekilde sınıflandırıldığını göstermektedir. Ancak frekans bantları ayrı ayrı deęerlendirildiğinde, özellikle Delta bandı (%81.90) ve Gama bandı (%86.10) için doęruluk oranlarında düşüş gözlemlenmiştir. Bu, düşük frekans bantlarının (Delta ve Gama) nötr duygunun tespitinde daha az etkili olduğunu göstermektedir.

- **Üzüntü Durumu**

Üzüntü durumunda da model, tüm bantlar bir arada kullanıldığında %97.78 gibi çok yüksek bir doęruluk oranı göstermiştir. Bu, üzüntünün tespiti konusunda modelin oldukça başarılı olduğunu işaret etmektedir fakat frekans bantları ayrı deęerlendirildiğinde, Delta bandı (%87.70) ve Teta bandı (%88.20) dışında diğer bantlarda benzer şekilde yüksek doęruluk oranları elde edilmiştir. Üzüntü durumu için Beta (%88.00) ve Gama (%88.40) bantları, doęruluk oranlarında benzer performans göstermiştir, bu da bu bantların üzüntü tespitinde etkili olduğunu göstermektedir.

- **Korku Durumu**

Korku durumu için tüm bantlar bir arada kullanıldığında modelin doğruluk oranı %97.13 olarak belirlenmiştir. Bu, modelin korkuyu doğru bir şekilde sınıflandırma yeteneğinin güçlü olduğunu göstermektedir. Ancak, Delta bandı (%87.00) ve Gama bandı (%87.50) için tüm bantların dahil edildiği çalışmaya oranla yine düşük doğruluk oranları gözlemlenmiştir. Teta (%90.30), Alfa (%89.60), ve özellikle Beta (%91.40) bantları korku sınıflandırmasında yüksek performans sergilemiştir. Bu da yüksek frekans bantlarının (Teta, Alfa, Beta) korku tespitinde daha belirleyici olduğunu düşündürülebilir.

- **Mutluluk Durumu**

Mutluluk durumu için modelin genel doğruluk oranı %97.04 olup, yine oldukça yüksek bir başarı sergilenmiştir. Ancak bununla birlikte farklı frekans bantları ayrı değerlendirildiğinde, özellikle Delta bandı (%83.10) ve Gama bandı (%84.30) için daha düşük doğruluk oranları gözlemlenmiştir. Bununla birlikte Beta bandı (%84.30) mutluluk durumunun tespitinde diğer bantlara göre daha yüksek bir doğruluk oranı sunmaktadır. Bu, mutluluk durumunun tespitinde yüksek frekansa sahip bantların daha etkili olabileceğini düşündürmektedir.

- **Bantlar Arası Karşılaştırma**

Farklı frekans bantları incelendiğinde, Delta bandı tüm sınıflar için en düşük doğruluk oranlarına sahiptir. Bu durum, Delta bandının duygu durum tespitinde sınırlı bir katkı sağladığını göstermektedir. Buna karşın, Beta bandı birçok sınıf için en yüksek doğruluk oranlarını sunmakta olup, özellikle korku (%91.40) ve mutluluk (%84.30) sınıflarında üstün performans göstermiştir. Tüm bantların bir arada kullanılması, en yüksek doğruluk oranını sağlamakta olup, bu durum farklı frekans bantlarının kombinasyonunun model performansını artırabileceğini işaret etmektedir.

Ensemble Bagged Trees modelinin genel performansı dikkate alındığında, modelin dört temel duygu sınıfını ayırt etmede etkili olduğu söylenebilir. Ancak, bazı sınıflar arasında doğruluk oranlarında gözlemlenen farklar, modelin belirli duygular için daha az hassas olabileceğini göstermektedir. Bu durum, farklı duyguların beyin aktivitesindeki yansımalarının farklı olmasıyla açıklanabilir. Özellikle mutluluk ve korku gibi duyguların, EEG sinyalleri üzerindeki etkileri diğer duygulara göre daha az belirgin olabilir.

Ayrıca, farklı frekans bantlarının ayrı ayrı değerlendirilmesi, duygu durum tespitinde hangi frekans bantlarının daha etkili olduğunu ortaya koymuştur. Beta bandının yüksek doğruluk oranı, bu bandın özellikle duygu durum tespiti için kritik bir öneme sahip olabileceğini göstermektedir. Bununla birlikte, Delta bandı gibi düşük frekanslı bantların daha düşük performans sergilemesi, bu bantların duygu durum analizinde sınırlı bir katkı sağladığını düşündürülebilir.

Bu çalışmanın bulguları, EEG tabanlı duygu durum tespitinde kullanılan model ve yöntemlerin, frekans bantlarına özgü performans farklılıklarını dikkate alarak optimize edilebileceğini göstermektedir. Gelecekteki çalışmalar, bu tür farklılıkların daha derinlemesine analiz edilmesi ve özellikle düşük performans sergileyen bantlar için iyileştirme yöntemlerinin araştırılması yönünde ilerleyebilir.

Sonuç olarak, bu tez çalışmasında kullanılan Ensemble Bagged Trees modeli, EEG tabanlı duygu durum tespitinde yüksek bir doğruluk oranı ile başarılı bir performans sergilemiştir. Elde edilen sonuçlar, modelin geniş bir duygu yelpazesinde etkili olabileceğini ve pratik uygulamalarda kullanılabilirliğini desteklemektedir. Ancak, belirli duygular için performans iyileştirmeleri gerektirebileceği de göz önünde bulundurulmalıdır. Gelecekte yapılacak çalışmalar, modelin daha da geliştirilmesi ve farklı EEG veri setleri üzerinde test edilmesiyle bu alandaki literatüre katkı sağlayabilir.



KAYNAKLAR

- [1] Ekman P ve Friesen W, “Constants Across Cultures in The Face and Emotion”, *Journal of Personality and Social Psychology*, c. 17, sy 2, ss. 124-129, 1971.
- [2] Ahernt G ve Schwartz G, “Differential Lateralization for Positive and Negative Emotion in the Human Brain: EEG Spectral Analysis”, *Neuropsychologia*, c. 23, sy 6, ss. 745-755, Nis. 1985, doi: 10.1016/0028-3932(85)90078-9.
- [3] Halim Z ve Rehan M, “On Identification of Driving-Induced Stress Using Electroencephalogram Signals: A framework Based on Wearable Safety-Critical Scheme and Machine Learning”, *Information Fusion*, c. 53, ss. 66-79, Oca. 2020, doi: 10.1016/j.inffus.2019.06.006.
- [4] Rozgic V, Vazquez-Reina A, Crystal M, Srivastava A, Tan V, ve Berka C, “Multi-Modal Prediction of PTSD And Stress Indicators”, *2014 IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP)*, c. 4, sy 14, ss. 3636-3640, 2014.
- [5] Valstar M vd., “The Continuous Audio/Visual Emotion and Depression Recognition Challenge”, içinde *AVEC 2013 - Proceedings of the 3rd ACM International Workshop on Audio/Visual Emotion Challenge*, Association for Computing Machinery, 2013, ss. 3-10. doi: 10.1145/2512530.2512533.
- [6] Cai H, Qu Z, Li Z, Zhang Y, Hu X, ve Hu B, “Feature-Level Fusion Approaches Based on Multimodal EEG Data for Depression Recognition”, *Information Fusion*, c. 59, ss. 127-138, Tem. 2020, doi: 10.1016/j.inffus.2020.01.008.
- [7] Gümüslü E, Erol Barkana D, ve Köse H, “Emotion Recognition Using EEG and Physiological Data for Robot-Assisted Rehabilitation Systems”, içinde *ICMI 2020 Companion - Companion Publication of the 2020 International Conference on Multimodal Interaction*, Association for Computing Machinery, Inc, Eki. 2020, ss. 379-387. doi: 10.1145/3395035.3425199.
- [8] Chang H, Huang S, ve Wu J, “A Personalized Music Recommendation System Based on Electroencephalography Feedback”, *Multimed Tools Appl*, c. 76, sy 19, ss. 19523-19542, Eki. 2017, doi: 10.1007/s11042-015-3202-4.
- [9] Stavroulia K, Christofi M, Baka E, Michael-Grigoriou D, Magnenat-Thalmann N, ve Lanitis A, “Assessing the Emotional Impact of Virtual Reality-Based Teacher Training”, *International Journal of Information and Learning Technology*, c. 36, sy 3, ss. 192-217, May. 2019, doi: 10.1108/IJILT-11-2018-0127.
- [10] Vesisenaho M vd., “Virtual Reality in Education: Focus on the Role of Emotions and Physiological Reactivity”, *J Virtual Worlds Res*, c. 12, sy 1, Şub. 2019, doi: 10.4101/JVWR.V12I1.7329.

- [11] T. B. Alakus, M. Gonen, ve I. Turkoglu, “Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO”, *Biomed Signal Process Control*, c. 60, ss. 1-13, Tem. 2020, doi: 10.1016/j.bspc.2020.101951.
- [12] M. Chauvel vd., “Comparative analysis of the chimpanzee and human brain superficial structural connectivities”, *Brain Struct Funct*, Tem. 2024, doi: 10.1007/S00429-024-02823-2.
- [13] H. L. Atwood ve D. C. Sandeman, *Neurobiology, Structure and Function*, c. 3. Academic Press, A Subsidiary of Harcourt Brace Jovanovich, Publishers, 1982.
- [14] J. M. Fuster, *Cortex and mind: Unifying Cognition*. Oxford University Press., 2003.
- [15] B. Paprocki, J. Szczepanski, ve D. Kolbuk, “Information transmission efficiency in neuronal communication systems”, *BMC Neurosci*, c. 14, sy Suppl 1, s. P217, Tem. 2013, doi: 10.1186/1471-2202-14-S1-P217.
- [16] D. C. N. Hall, “Neuronal transmission”, *Introduction to Biological Psychology*, Şub. 2023, doi: 10.20919/ZDGF9829/5.
- [17] M. Teplan, “Fundamentals of EEG Measurement”, *MEASUREMENT SCIENCE REVIEW*, c. 2, sy 2, ss. 1-11, 2002.
- [18] A. Dubey ve S. Ray, “Cortical Electroencephalogram (EEG) Is a Local Signal”, *Journal of Neuroscience*, c. 39, sy 22, ss. 4299-4311, May. 2019, doi: 10.1523/JNEUROSCI.2917-18.2019.
- [19] P. E. Valk, D. L. Bailey, D. W. Townsend, ve M. N. Maisey, *Positron Emission Tomography: Basic Science and Clinical Practice*, Springer., c. 26, sy 9. New York: American Society of Neuroradiology, 2004. Erişim: 24 Mayıs 2024. [Çevrimiçi]. Erişim adresi: /pmc/articles/PMC7976168/
- [20] P. Bannier, A. Bertrand, Q. Salmon, ve A. Gramfort, “Electromagnetic neural source imaging under sparsity constraints with SURE-based hyperparameter tuning”, Université Paris Saclay. Erişim: 24 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://arxiv.org/abs/2112.12178v1>
- [21] Y. Bekhti, F. Lucka, J. Salmon, ve A. Gramfort, “A hierarchical Bayesian perspective on majorization-minimization for non-convex sparse regression: Application to M/EEG source imaging”, *Inverse Probl*, c. 34, sy 8, Haz. 2018, doi: 10.1088/1361-6420/AAC9B3.
- [22] M. Xia vd., “Reproducibility of functional brain alterations in major depressive disorder: Evidence from a multisite resting-state functional MRI study with 1,434 individuals”, *Neuroimage*, c. 189, ss. 700-714, Nis. 2019, doi: 10.1016/j.neuroimage.2019.01.074.
- [23] T. Hinterberger, N. Weiskopf, R. Veit, B. Wilhelm, E. Betta, ve N. Birbaumer, “An EEG-driven brain-computer interface combined with functional magnetic resonance imaging (fMRI)”, *IEEE Trans Biomed Eng*, c. 51, sy 6, ss. 971-974, Haz. 2004, doi: 10.1109/TBME.2004.827069.

- [24] S. Coyle, T. Ward, C. Markham, ve G. McDarby, “On the suitability of near-infrared (NIR) systems for next-generation brain–computer interfaces”, *Physiol Meas*, c. 25, sy 4, s. 815, Tem. 2004, doi: 10.1088/0967-3334/25/4/003.
- [25] M. Teplan, “Fundamentals of EEG Measurement”, *MEASUREMENT SCIENCE REVIEW*, c. 2, sy 2, 2002.
- [26] Z. Wang ve P. Mengoni, “Seizure classification with selected frequency bands and EEG montages: a Natural Language Processing approach”, *Brain Inform*, c. 9, sy 1, ss. 1-31, Ara. 2022, doi: 10.1186/S40708-022-00159-3/TABLES/16.
- [27] W. L. Zheng ve B. L. Lu, “Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks”, *IEEE Trans Auton Ment Dev*, c. 7, sy 3, ss. 162-175, Eyl. 2015, doi: 10.1109/TAMD.2015.2431497.
- [28] A. Ahangi ve R. Ebrahimpour, “Using Combining Classifiers in Brain-Computer Interfacing”, 2017. doi: 10.13140/RG.2.2.20472.75522.
- [29] H. Jasper, “Ten-twenty Electrode System of the International Federation”, *Electroencephalogr Clin Neurophysiol*, c. 10, ss. 371-375, 1958, Erişim: 05 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://cir.nii.ac.jp/crid/1571698600671094016>
- [30] American Electroencephalographic Society, “American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature”, *Journal of Clinical Neurophysiology*, c. 8, sy 2, ss. 200-202, 1991.
- [31] R. Shriram, M. Sundhararajan, M. Sundhararajan, ve N. Daimiwal, “EEG Based Cognitive Workload Assessment for Maximum Efficiency”, SICETE. [Çevrimiçi]. Erişim adresi: www.iosrjournals.org
- [32] Brain-Like Computing and Machine Intelligence Laboratory, “SEED Dataset: A dataset collection for various purposes using EEG signals”, Brain-Like Computing and Machine Intelligence Laboratory. Erişim: 05 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://bcmi.sjtu.edu.cn/~seed/seed.html>
- [33] R. A. Calvo ve S. D’Mello, “Affect detection: An interdisciplinary review of models, methods, and their applications”, *IEEE Trans Affect Comput*, c. 1, sy 1, ss. 18-37, Oca. 2010, doi: 10.1109/T-AFFC.2010.1.
- [34] J. A. Russell, “A circumplex model of affect”, *J Pers Soc Psychol*, c. 39, sy 6, ss. 1161-1178, Ara. 1980, doi: 10.1037/H0077714.
- [35] M. R. Islam vd., “Emotion Recognition from EEG Signal Focusing on Deep Learning and Shallow Learning Techniques”, *IEEE Access*, c. 9, ss. 94601-94624, 2021, doi: 10.1109/ACCESS.2021.3091487.
- [36] P. Ekman, W. Friesen, ... M. O.-J. of personality, ve undefined 1987, “Universals and cultural differences in the judgments of facial expressions of emotion.”, *psycnet.apa.org* P Ekman, WV Friesen, M O’sullivan, A Chan, I Diacoyanni-Tarlatzis, K Heider, R Krause *Journal of personality and social psychology*, 1987•*psycnet.apa.org*, Erişim: 22 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://psycnet.apa.org/fulltext/1988-04343-001.html>

- [37] “An approach to environmental psychology.” Erişim: 22 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://psycnet.apa.org/record/1974-22049-000?ref=nepopularna.org>
- [38] J. R.-J. of personality and social psychology ve undefined 1980, “A circumplex model of affect.”, *psycnet.apa.orgJA RussellJournal of personality and social psychology, 1980*•*psycnet.apa.org*, Erişim: 22 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://psycnet.apa.org/journals/psp/39/6/1161/>
- [39] R. P.-A. psychoevolutionary synthesis ve undefined 1980, “Emotion”, *cir.nii.ac.jp*, Erişim: 22 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://cir.nii.ac.jp/crid/1573950399239730304>
- [40] D. Watson ve A. Tellegen, “Toward a Consensual Structure of Mood”, *Psychol Bull*, c. 98, sy 2, ss. 219-235, Eyl. 1985, doi: 10.1037/0033-2909.98.2.219.
- [41] E. K. St. Louis vd., “Appendix 4. Common Artifacts During EEG Recording”, 2016, Erişim: 19 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <https://www.ncbi.nlm.nih.gov/books/NBK390358/>
- [42] A. Al-Nafjan, M. Hosny, Y. Al-Ohali, ve A. Al-Wabil, “Review and Classification of Emotion Recognition Based on EEG Brain-Computer Interface System Research: A Systematic Review”, doi: 10.3390/app7121239.
- [43] E. Tzyy ve P. Jung, “Introduction to”.
- [44] W. L. Zheng, W. Liu, Y. Lu, B. L. Lu, ve A. Cichocki, “EmotionMeter: A Multimodal Framework for Recognizing Human Emotions”, *IEEE Trans Cybern*, c. 49, sy 3, ss. 1110-1122, Mar. 2019, doi: 10.1109/TCYB.2018.2797176.
- [45] R. Jenke, A. Peer, ve M. Buss, “Feature extraction and selection for emotion recognition from EEG”, *IEEE Trans Affect Comput*, c. 5, sy 3, ss. 327-339, Tem. 2014, doi: 10.1109/TAFFC.2014.2339834.
- [46] K. Vytal ve S. Hamann, “Neuroimaging Support for Discrete Neural Correlates of Basic Emotions: A Voxel-based Meta-analysis”, *J Cogn Neurosci*, c. 22, sy 12, ss. 2864-2885, Ara. 2010, doi: 10.1162/JOCN.2009.21366.
- [47] S. E. Fienberg ve A. C. Thomas, “Network Models in Probability and Statistics”, *International Encyclopedia of Statistical Science*, ss. 939-941, 2011, doi: 10.1007/978-3-642-04898-2_403.
- [48] R. S. Wahono, “A Systematic Literature Review of Software Defect Prediction: Research Trends, Datasets, Methods and Frameworks”, *Journal of Software Engineering*, c. 1, sy 1, 2015, Erişim: 19 Temmuz 2024. [Çevrimiçi]. Erişim adresi: <http://journal.ilmukomputer.org>
- [49] S. Finlay, “Multiple classifier architectures and their application to credit risk assessment”, *Eur J Oper Res*, c. 210, sy 2, ss. 368-378, Nis. 2011, doi: 10.1016/J.EJOR.2010.09.029.
- [50] T.-H. Lee, A. Ullah, ve R. Wang, “Bootstrap Aggregating and Random Forest”.

- [51] K. Riehl, “Hierarchical confusion matrix for classification performance evaluation”, 2023, Eriřim: 22 Mayıs 2024. [Çevrimiçi]. Eriřim adresi: <https://github.com/DerKevinRiehl/HierarchicalConfusionMatrix>





ÖZGEÇMİŞ

Ad-Soyad : Elif ÇAVUŞ

ÖĞRENİM DURUMU:

- **Lise** : 2014, Çukurova Toroslar Anadolu Lisesi, Çukurova, Adana
- **Lisans** : 2019, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü
- **Yükseklisans** : 2024, Sakarya Üniversitesi, Elektrik Elektronik Anabilim Dalı, Elektrik Programı

MESLEKİ DENEYİM:

- Mart 2024'ten bu yana Kocaeli Üniversitesi'nde Araştırma Görevlisi olarak görev yapmaktadır.
- 2023 – 2024 yılları arasında MEB Teknokent Koleji'nde Proje Koordinatörlüğü ve Elektrik Öğretmenliği yaptı.
- 2022 – 2023 yılları arasında Bersis Elektrik Ltd. Şti.'de Proje Mühendisliği görevini yürüttü.
- 2021 – 2022 yılları arasında MEB Teknokent Koleji'nde Elektrik Öğretmenliği yaptı.

TEZDEN TÜRETİLEN ESERLER:

- Çavuş, E., Kandaz, D., & Bozkurt, M. R. (2024). EEG tabanlı duygu durumu analizi: Ensemble Bagged Trees modelinin SEED veri seti üzerindeki performansı. 4th International Graduate Studies Congress, 5-8 Haziran (ss. 252-260), 2024. ISBN: 978-625-94317-2-7.