



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BEYİN BİLGİSAYAR ARAYÜZÜ(BBA) İLE
KOMUT ELDE ETME

Nuriye Berna YÜZÜGÜL

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Eylül-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Nuriye Berna YÜZÜGÜL tarafından hazırlanan “Beyin Bilgisayar Arayüzü (BBA) ile Komut Elde Etme” adlı tez çalışması 24/09/2024 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Rahime CEYLAN
(Konya Teknik Üniversitesi)

.....

Danışman

Prof. Dr. Seral ÖZŞEN
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Esra KAYA
(Selçuk Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Nuriye Berna YÜZÜGÜL

Tarih:

ÖZET

YÜKSEK LİSANS BEYİN BİLGİSAYAR ARAYÜZÜ(BBA) İLE KOMUT ELDE ETME

Nuriye Berna YÜZÜGÜL

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Seral ÖZŞEN

2024, 65 Sayfa

Jüri

Prof. Dr. Seral ÖZŞEN
Doç. Dr. Rahime CEYLAN
Dr. Öğr. Üyesi Esra KAYA

EEG, beynin elektriksel aktivitesini kaydeden bir izleme yöntemi olup ilk olarak epilepsi bozukluklarını teşhis etmek için Nörobilim alanında ortaya çıkmıştır. Son zamanlarda yapılan çalışmalarda, EEG sinyalleri, insan beyni ile bilgisayar arasında direkt bir yol oluşturduğundan, kişinin belirli uyaranlara verdiği tepkiyi tespit etmek için birçok çalışmada kullanılmıştır. BBA’da, beyinde oluşan elektriksel potansiyeller giriş sinyali olarak kullanılmaktadır. Bu sinyallerden birisi de durağan hal görsel uyarılmış potansiyellerdir (DHGUP). DHGUP tabanlı BCI, genellikle kullanıcının dikkatini belirli frekansta ışık yanıp sönen veya değişen görsel uyarıcılara vererek beyin aktivitesini izler. Bu görsel uyarılar genellikle bir bilgisayar ekranında yer alır. Kullanıcının dikkati, beyindeki belirli frekanstaki bu görsel uyarıcılara yanıt olarak SSVEP sinyallerinin değişmesine neden olur. BCI sistemi, bu SSVEP sinyallerini algılayarak kullanıcının dikkatini tahmin edebilir ve belirli komutları gerçekleştirmek için bir arayüz sağlayabilir. Çalışma 8 kişi ile yapılmış olup katılımcıların yaş ortalaması 25,62’dir. Hazırlanan görsel uyarılar; sağ, sol, ileri ve geri ok simgeleri olup sırasıyla 7,8,9,10 Hz. olarak kullanıcıya sunulmuş ve EEG kayıtları alınmıştır. EEG kayıtları Emotiv EPOC+ 14 kanallı başlık ile alınmış olup örnekleme frekansı 256Hz’dir. Toplam EEG kayıt süresi 1152sn olup kişi başı kayıt süresi 144sn’dir. Yapılan kayıtlar sonucunda bu çalışma için oksipital bölge kayıtlarının kullanılması için P7, P8, O1 ve O2 kanallarının sinyalleri alınarak 2-15 Hz. aralığında butterworth bant geçiren filtre ile filtrelenmiş ve normalize edilerek 5 saniyelik dilimlere ayrılmıştır. Daha sonrasında sinyaller FFT yöntemi ile frekans ortamına taşınmış ve PSD’leri alınmıştır. Sınıflandırma aşamasında SVM, YSA, KA ve NB algoritmaları kullanılarak ikili ve dörtlül sınıflandırmalar gerçekleştirilmiştir. İkili sınıflama KA algoritmasıyla %63,90 doğruluk oranı elde edilmiştir. Dörtlül sınıflandırma çalışmasında DVM algoritması ile %31,20’lik doğruluk oranına erişilmiştir.

Anahtar Kelimeler: BBA, EEG, DHGUP, FFT, FİLTRELEME, PSD, SINIFLAMA, WELCH YÖNTEMİ

ABSTRACT

MS THESIS

COMMAND CONTROL WITH BRAIN COMPUTER INTERFACE(BCI)

Nuriye Berna YÜZÜGÜL

**Konya Technical University
Institute of Graduate Studies
Department of Electrical Electronics Engineering**

Advisor: Prof. Dr. Seral ÖZŞEN

2024, 65 Pages

**Jury
Prof. Dr. Seral ÖZŞEN
Assoc. Prof. Dr. Rahime CEYLAN
Asst. Prof. Dr. Esra KAYA**

The electroencephalogram (EEG) is a monitoring method that records the electrical activity of the brain, initially emerging in the field of Neuroscience to diagnose epilepsy disorders. In recent studies, EEG signals have been used in many investigations to detect an individual's response to specific stimuli, as they establish a direct pathway between the human brain and computers. In Brain-Computer Interfaces (BCI), electrical potentials generated in the brain serve as input signals. One of these signals is the steady-state visually evoked potentials (SSVEP). SSVEP-based BCI typically tracks brain activity by directing the user's attention to visual stimuli that flicker or change at specific frequencies. These visual stimuli are usually presented on a computer screen. The user's attention to these visual stimuli at specific frequencies in the brain causes changes in SSVEP signals. By detecting these SSVEP signals, a BCI system can predict the user's attention and provide an interface to execute specific commands. The study involved 8 participants with an average age of 25.62. Prepared visual stimuli consisted of right, left, forward, and backward arrow symbols presented to the user at frequencies of 7, 8, 9, and 10 Hz, respectively, with EEG recordings taken. EEG recordings were obtained using an Emotiv EPOC+ 14-channel headset with a sampling frequency of 256 Hz. The total EEG recording duration was 1152 seconds, with a recording duration of 144 seconds per person. Subsequently, the signals from channels P7, P8, O1, and O2 were filtered using a Butterworth bandpass filter in the 2-15 Hz range and normalized, then segmented into 5-second epochs for use in the study. Next, the signals were transformed into the frequency domain using the Fast Fourier Transform (FFT) method, and their Power Spectral Densities (PSDs) were obtained. In the classification phase, SVM (Support Vector Machines), ANN (Artificial Neural Networks), KNN (K-Nearest Neighbors), and NB (Naive Bayes) algorithms were applied for both binary and four-class classifications. An accuracy rate of 63.90% was achieved with the Decision Tree (DT) algorithm in the binary classification study. In the four-class classification study, an accuracy rate of 31.20% was reached using the Support Vector Machine (SVM) algorithm.

Keywords: BCI, CLASSIFICATION, EEG, FILTERING, SSVEP, PSD, WELCH METHOD

ÖNSÖZ

Bu çalışmanın gerçekleştirilmesinde, kıymetli bilgilerini ve zamanını benimle paylaşan, kıymetli danışman hocam Prof. Dr. Seral ÖZŞEN'e teşekkürlerimi sunarım. Yine çalışmamda bana sürekli yardımda bulunup destek olan, kıymetli Arş. Gör. Tuğçe Kılıç'a da sonsuz teşekkürlerimi sunarım.

Ayrıca kıymetli zamanını ayırıp her konuda bana destek olan arkadaşım Ali'ye ve benden desteğini hiçbir zaman esirgemeyen bu hayattaki en büyük şansım olan aileme sonsuz teşekkürler.

Nuriye Berna YÜZÜGÜL
KONYA-2024



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. EEG Sinyalleri ve Temel Kavramlar	1
1.2. Beyin Bilgisayar Arayüzü (BBA) Sistemleri.....	3
1.3. Beyin Bilgisayar Arayüzü Sistemi Temelleri	4
1.4. EEG Sinyal Çeşidine Göre BBA Uygulamaları	5
1.5. Durağan Hal Görsel Uyarılmış Potansiyel (DHGUP) Tabanlı Beyin Bilgisayar Arayüzleri	6
2. KAYNAK ARAŞTIRMASI	9
3. MATERYAL VE YÖNTEM.....	15
3.1. Görsel Uyarın Tasarımı.....	15
3.2. EEG Kayıtları	18
3.3. Sinyal Temizleme ve Önışleme	21
3.3.1 Butterworth Filtre	22
3.3.2. Z-Score Normalizasyon	22
3.4. Frekans Analizi	24
3.4.1. Filtreleme Metodu.....	24
3.4.2. Fast Fourier Transform (FFT).....	25
3.4.3. Welch Metodu.....	26
3.5. Özellik Çıkarma Yöntemleri.....	26
3.5.1. Zaman Özellikleri	27
3.5.2. Frekans Özellikleri.....	28
3.6. Özellik Seçme Yöntemi	28
3.6.1. Temel Bileşen Analizi (Principal Component Analysis-PCA).....	29
3.7. Sınıflandırma Yöntemleri	29
3.7.1. Karar Ağaçları (KA)	29
3.7.2. Destek Vektör Makineleri (DVM).....	30
3.7.3. Yapay Sinir Ağları (YSA)	31
3.7.4. Doğal Bayes (DB).....	32
3.8 Performans Değerlendirme Ölçütleri.....	33
3.9. Sınıflandırma Verileri	34
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	35
4.1. Sınıflandırma Çalışması 1	36

4.1.1 Sinyal Filtreleme	36
4.1.2. Güç Spektral Yoğunluğu (Power Spektral Density -PSD)	36
4.1.3. Welch Metodu ile PSD Hesapları	40
4.1.4. Özellik Çıkarma	41
4.1.5. İkili Sınıflandırma	42
4.2. Sınıflandırma Çalışması 2	47
4.3. Sınıflandırma Çalışması 3	54
5. SONUÇLAR VE ÖNERİLER	60
KAYNAKLAR	62



SİMGELER VE KISALTMALAR

Simgeler

F	: Frekans
J	: Karmaşık sayı birimi
N	: Örnekleme sayısı
PSD(f)	: Sinyalin PSD'si
T	: Zaman aralığı
X(f)	: Sinyalin Fourier dönüşümü
X(n)	: Zaman alanında verilen giriş sinyalinin n. örneği
X(k)	: Frekans alanında elde edilen sinyalin k. Bileşeni
Z(i)	: i'inci sinyaldeki işaret değişimi (zero-crossing rate)
α	: Alfa
β	: Beta
δ	: Delta
θ	: Teta
γ	: Gamma
z	: Normalleştirilmiş değer (Z-score)
x	: Normalleştirilecek değer
μ	: Özelliğin ortalaması
σ	: Özelliğin standart sapması
x_{std}	: Sinyalin standart sapması
x_m	: Sinyalin ortalaması
x_{ske}	: Eğiklik

Kısaltmalar

ALS	: Amyotrofik lateral skleroz
Ark	: Arkadaş
BBA	: Beyin Bilgisayar Arayüzü
DAA	: Doğrusal Ayırtaç Analizi
DFT	: Discrete Fourier Transform
DHGUP	: Durağan hal görsel uyarılmış potansiyel
EEG	: Elektroensefalografi
EKG	: Elektrokardiyogram
EMG	: Elektromiyografi
FFT	: Fast Fourier Transform/Hızlı Fourier Dönüşümü
Hz	: Hertz
KA	: Karar Ağaçları
kNN	: k-en yakın komşuluk
LIS	: Lock in sendromu
MLPNN	: Çok katmanlı ceptron başına sinir
NB	: Naive Bayes
PCA	: Principal Component Analysis/ Temel bileşen analizi
PSD	: Power Spektral Density
SSVEP	: Steady-state visual evoked potentials
SVM	: Support Vector Machine/ Destek Vektör Makineleri
YKP	: Yavaş Kortikal Potansiyel
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Nörolojik rahatsızlıklardan veya nörodejeneratif hastalıklara sahip olan insanlar, kaslarını kontrol edemezler. Amyotrofik lateral skleroz (ALS), LIS (Lock in Sendromu), omurilik yaralanması, inme ve diğer birçok durum, kasları kontrol eden nöral yolları bozar. (Erkan ve Akbaba,2018) Beyin bilgisayar arayüz sistemleri, bu insanlara kendi sinir yollarından başka bir alternatif yol sunar. (Erkan ve Akbaba,2018)

Günümüzde, teknolojinin hızla gelişmesiyle birlikte beyin-bilgisayar arayüzleri (BBA) alanında büyük ilerlemeler kaydedilmiştir. BBA, insan beyninin doğrudan bilgisayarlarla etkileşimini sağlayan teknolojik sistemlerdir. Bu sistemler, engellilerin iletişim ve hareket etme yeteneklerini artırmanın yanı sıra, oyunlar, eğlence ve tıbbi uygulamalar gibi birçok alanda potansiyel uygulamalar sunmaktadır.

BBA sistemlerinde, beyinde farklı tür aktiviteler esnasında oluşan elektriksel potansiyeller giriş sinyali olarak kullanılmaktadır. Bu sinyallerden biri de durağan hal görsel uyarılmış potansiyellerdir (DHGUP). DHGUP temelli BBA sistemlerinde, kişi, gözlerini, kendisine sunulan belirli frekansta tekrarlanan görsel uyarana odakladığında beyinde oluşan sinyaller, giriş sinyali olarak kullanılmaktadır. (Sözer ve ark., 2014) DHGUP, görsel uyarıcılara yanıt olarak beyin sinyallerinin oluşturduğu bir tür potansiyeldir. DHGUP tabanlı BBA sistemleri, bu potansiyeli kullanarak kullanıcıların görsel uyarıcılara odaklanmalarını ve belirli komutlar verme yeteneklerini algılayabilir. Bu sistemler, geleneksel BCI sistemlerine göre daha doğru ve hızlı yanıtlar sağlayabilir ve kullanıcıların daha doğal bir etkileşim deneyimi yaşamalarını sağlayabilir.

Bu tez çalışmasında, DHGUP tabanlı BBA sistemlerinin geliştirilmesi ve uygulanması üzerine odaklanacaktır. Farklı DHGUP frekanslarının ve görsel uyarıcıların BBA sistem performansı incelenecektir.

1.1. EEG Sinyalleri ve Temel Kavramlar

EEG, beynin elektriksel aktivitesini kaydeden bir izleme yöntemidir ve ilk olarak epilepsi veya uyku bozukluklarını teşhis etmek için Nörobilim alanında ortaya çıkmıştır. (Albano ve ark.,2018) Son zamanlarda yapılan çalışmalarda, EEG sinyalleri, kullanıcının beyni ile bilgisayar arasında doğrudan bir yol oluşturduğundan, bir kişinin belirli uyaranlara verdiği duygusal tepkiyi tespit etmek için birçok çalışmada kullanılmıştır.

Kaydedilen EEG sinyalleri beynin limbik bölümünde üretilir ve beş ana frekans bandından oluşur (Albano ve ark.,2018): Delta (δ : 4 Hz'e kadar), Teta (θ : 4-8 Hz)

dalgaları, Alfa (α : 8 -15 Hz) dalgaları, Beta (β : 15-32 Hz) dalgaları ve Gamma (γ : $\geq$ 32 Hz) dalgaları. (Moschona ve ark.,2020) Her bir dalganın beyin aktivitesinin farklı yönlerini temsil ettiği düşünülmektedir. EEG dalgalarının temsil ettiği aktiviteler:

Delta Dalgaları (0.5-4 Hz.): En yavaş dalgalar arasında olan delta dalgaları, derin uykuda ve rüya görmeyen uyku sırasında baskındır.

Theta Dalgaları (4-8 Hz.): Theta dalgaları, hafif uykuda, rüya görmek için derin uyku aşaması ve dikkatin azaldığı durumlarda yaygındır.

Alfa Dalgaları (8-12 Hz.): Alfa dalgaları, gözler kapalıyken ve kişi dinlenirken belirgindir. Uyanık ama dinlenmiş bir zihinsel durumu temsil eder.

Beta Dalgaları (12-30 Hz.): Beta dalgaları, uyanık, dikkatli ve aktif zihinsel aktivitelerin olduğu durumlarda hakimdir. Dikkat, odaklanma, problem çözme gibi süreçlerde artar.


Gamma Dalgaları (30-100 Hz.): Gamma dalgaları, daha yüksek düşünme süreçlerine, bilgi işlemeye ve bilişsel işlevlere ilişkilendirilir. Özellikle dikkat, hafıza, dil ve bilinçli işlemlerle bağlantılıdır.

Bu frekans dalgalarının her biri, belirli beyin durumlarını temsil eder ve farklı zihinsel aktivitelerle ilişkilendirilir. EEG, bu dalgaların aktivitesini izleyerek beyin durumlarını değerlendirmek için yaygın olarak kullanılır.

EEG sinyallerinin temininin doğru yapılabilmesi için EEG cihazının elektrotlarının kafa derisi üzerine montaj şekillerinin de önemi büyüktür. Genel olarak klinik vakalarda ve bilimsel araştırmalarda 10-20 ve 10-10 montaj sistemleri tercih edilmektedir. (Ilyas ve ark., 2015) (Maracine ve ark., 2017). (Haltaş ve ark.,2018)

Bu sistem, elektrotların kafa derisine yerleştirilmesi sırasında belirli bir desene göre konumlandırılmasını sağlar. Adı, elektrotların kafa derisindeki konumlarını belirlemek için kullanılan ölçümlerin yüzde 10 veya 20'sine dayanır.

Şekil 1.1'de EEG bağlantı noktaları gösterilmiştir.



Şekil 1.1. Uluslararası kabul gören 10-20 elektrot yerleşimi (Haltas ve ark.,2018)

Bu sistem, elektrotların yerleştirilmesini standartlaştırarak EEG sonuçlarının klinik ve araştırma ortamlarında karşılaştırılabilirliğini artırır. Ayrıca, belirli beyin bölgelerine odaklanmak veya geniş bir kapsamda beyin aktivitesini izlemek için elektrotların belirli konumlara yerleştirilmesine izin verir. EEG 10-20 sistemi, elektrotların yerleştirilmesi sırasında kullanılan bir rehberdir ve beyin aktivitesini kaydetmek için standart bir tekniktir.

1.2. Beyin Bilgisayar Arayüzü (BBA) Sistemleri

1.2.1. Beyin Bilgisayar Arayüzü Nedir?

Sağlıklı bireyler iletişim sağlama veya bir sistemi kontrol etmek için çevresel sinir ve kaslarını kullanırlar. Çevresel sinir sistemi kişinin kendi isteği doğrultusunda hareket etme(somatik) ve istemsiz hareket etme (otonom) olarak ikiye ayrılır. Somatik sistem; merkezi sinir sistemine duyuşsal durum gönderen sinirler ile kemik kaslarını uyaran motor sinirlerden oluşur. Bunlar duyuşsal ve motor kısımlardan meydana gelir. Duyuşsal kısım kas ve herhangi duyu organlarından gelen uyarıları alır; motor kısım da bu uyarıların değerlendirilmesiyle hareket kontrolünden sorumludur (Oralhan, 2016).

BBA sistemleri çeşitli sektörlerde kendine yer edinmiş olup başta sağlık sektörü olmak üzere pek çok alanda kullanılmaktadır. Sağlık sektöründe, özellikle engelli bireylerin hayatlarının kolaylaştırılması üzerine çalışmalar yapıldığı yapılan araştırmalar sonucunda görülen bir durumdur. BBA teknolojisinin uygulamaları çeşitleri:

İletişim: BBA, felçli veya nöromüsküler bozukluğu olan bireylerin iletişim kurmalarına yardımcı olabilir. Örneğin, düşünce tabanlı yazılım aracılığıyla,

kullanıcıların düşünce yoluyla harf veya kelime seçmelerine ve bu şekilde iletişim kurmalarına izin verilebilir.

Hareket kontrolü: BBA, kullanıcıların düşüncelerini kullanarak eklem protezlerini veya tekerlekli sandalyeleri kontrol etmelerine yardımcı olabilir. Beyin sinyalleri, belirli hareketlerin gerçekleşmesi için bir arayüze aktarılabilir.

Oyun ve eğlence: BBA, oyun deneyimlerini zenginleştirmek veya interaktif eğlence uygulamaları oluşturmak için kullanılabilir. Örneğin, kullanıcıların bir video oyununu düşünceleriyle kontrol etmelerine olanak tanır.

Bilişsel ve duygusal durum izleme: BBA, kullanıcıların dikkat seviyelerini, duygusal durumlarını veya zihinsel yorgunluklarını izlemelerine yardımcı olabilir.

1.3. Beyin Bilgisayar Arayüzü Sistemi Temelleri

Elektroensefalografi (EEG) kullanarak çalışan bir beyin-bilgisayar arayüzü (BBA) sistemleri, insanların beyin aktivitelerini kullanarak düşüncelerini, duygularını veya niyetlerini dış dünyayla iletişim kurmak için bir araç olarak kullanabilecekleri heyecan verici bir teknolojidir. Bu sistemlerin gelişimi, insan-bilgisayar etkileşimi ve nörobilim alanlarında önemli ilerlemelere yol açmaktadır. EEG tabanlı BCI sistemlerinin temelleri genellikle şu unsurları içerir:

EEG Sinyallerinin Kaydedilmesi: Kullanıcının kafa derisi üzerine yerleştirilmiş elektrotlar aracılığıyla beyin aktivitesini ölçmek için EEG sinyalleri kaydedilir. Bu sinyaller, beyin aktivitesindeki elektriksel değişiklikleri ölçer ve bilgisayar arayüzüne iletilir.

Sinyal İşleme ve Analizi: Kaydedilen EEG sinyalleri sinyal işleme teknikleriyle analiz edilir. Bu adım, sinyallerin gürültüsünü azaltmayı, özelliklerini belirlemeyi ve istenen bilgileri çıkarmayı içerir.


Özellik Çıkarımı ve Sınıflandırma: İşlenmiş EEG sinyalleri genellikle belirli özelliklerin çıkarılmasını gerektirir. DHGUP gibi belirli potansiyellerin algılanması için sinyal özellikleri belirlenir. Daha sonra, bu özellikler sınıflandırma algoritmaları kullanılarak belirli komutlar veya niyetlerle ilişkilendirilir.

Bilgisayar Arayüzü ve Geri Bildirim: Sınıflandırılan beyin aktivitesi bilgisayar arayüzü üzerinden yorumlanır ve belirli komutlar veya işlevler gerçekleştirilir. Kullanıcıya geri bildirim sağlanabilir, böylece beyin aktivitesinin nasıl değiştiği ve hangi komutların algılandığı hakkında bilgi edinilebilir.

1.4. EEG Sinyal Çeşidine Göre BBA Uygulamaları

EEG tabanlı BBA sistemleri şekil 1.2’ de EEG sinyal türüne göre isimlendirilmiştir. Temel olarak olaya ilişkin beyin sinyalleri, potansiyellerin elde edilmesiyle ortaya çıkan; P300 sinyalleri, durağan hal görsel uyarılmış potansiyelleri ve yavaş kortikal potansiyelleridir. Bu potansiyellerin de ortaya çıkması için oluşturulacak düzenek yani zihinsel strateji “seçici odaklanmadır”. Yani belirli bir uyarana karşı odaklı olmaktır (Oralhan, 2016). Kortikal osilasyonlar ise beynin duyuşal motor korteksinden elde edilen duyuşal motor ritimleridir. Bu duyuşal motor ritimleri, örneğin bir uzuv hareketinin hayali ile ortaya çıkmaktadır. Bundan dolayı zihinsel stratejisi hareket tahayyülü olarak isimlendirilmiştir (Oralhan, 2016).

Bu bilgiler, EEG tabanlı BBA sistemlerinin farklı beyin sinyali türlerini nasıl tanımladığını ve bu sinyallerin nasıl elde edildiğini açıklar. Ayrıca, bu sistemlerin kullanıcıların zihinsel stratejilerini nasıl kullanarak etkili bir şekilde çalıştığını gösterir.



Şekil 1.2. Beyin sinyali özelliğine ve zihinsel stratejiye göre EEG tabanlı BBA sistemleri (Oralhan,2016)

Pratikte kullanılan / kullanılabilecek EEG sinyali tabanlı beyin bilgisayar arayüzü sistemleri şunlardır:

- Duyusal Motor Ritimleri tabanlı BBA sistemleri
- Yavaş Kortikal Potansiyel (YKP) tabanlı BBA sistemleri
- P300 Sinyali tabanlı BBA sistemleri
- Durağan Hal Görsel Uyarılmış Potansiyel tabanlı BBA sistemleri (Oralhan,2016).


Bu tez çalışmasında durağan hal görsel uyarılmış potansiyel (DHGUP)'e dayalı BBA kullanılarak sinyal işleme yöntemlerinin kıyaslanması yapılmıştır.

1.5. Durağan Hal Görsel Uyarılmış Potansiyel (DHGUP) Tabanlı Beyin Bilgisayar Arayüzleri

DHGUP, görsel uyarıcıya odaklanma sırasında beyinde oluşan elektriksel potansiyel değişikliklerdir. Bir görsel uyarıcı belirli bir frekansta tekrarlandığında, bu potansiyeller belirli bir ritimde görülür ve beyin-bilgisayar arayüzü sistemlerinde giriş sinyali olarak kullanılabilir.

Durağan hal görsel uyarılmış potansiyel (DHGUP) temelli beyin bilgisayar arayüzlerinde beyindeki uyarılmış potansiyel/cevap mekanizmasından faydalanılmaktadır (Sözer ve ark.,2014). Uyarılmış potansiyel, EEG kaydı ile kişiye uygulanmış bir uyarının ardından sinir sisteminden kaydedilmiş beynin normal işleyişindeki elde edilen potansiyellerden farklı olan potansiyeldir. Uyarılmış potansiyel, bir dış uyarana karşı merkez sinir sisteminin elektriksel aktivitesinde ortaya çıkan değişim olarak da tanımlanabilir (Sözer ve ark.,2014).

DHGUP temelli BBA sistemlerinde, kullanıcıya bilgisayar monitörü veya harici ışık kaynağı aracılığı ile belirli bir frekansta tekrarlanan görsel uyaranlar sunulur (Sözer ve ark., 2014). Deneğe sunulan görsel uyaranların hepsi farklı özellikler barındırmaktadır ve sistem çıkışında ayrı bir komut ile ilişkilidir. Denek bakışlarını sunulan görsel uyaranlardan birine yoğunlaştırdığında, özellikle görme ile ilişkili bölge olan oksipital bölgeden alınan EEG sinyallerinde, görsel uyarının frekansı ile eşleşen periyodik sinyaller gözlemlenebilmektedir. Kişiden alınan EEG sinyallerine birden fazla sinyal işleme metodu (önişleme, öznitelik çıkarma, sınıflandırma) uygulanarak, DHGUP sinyalinin özellikleri, deneğin odaklandığı uyaran tespit edilmeye çalışılır. Kişinin odaklandığı görsel uyaran tespit edilebildiğinde, tespit edilen görsel uyaran ile ilişkili komut gerçekleştirilir. Şekil 1.3' de BBA sisteminin temel yapısı gösterilmiştir.



Şekil 1.3. BBA sistemi temel yapısı (Oralhan,2016)

Genel olarak, DHGUP tabanlı bir BBA'nın yapısı kabaca dört aşamaya ayrılabilir:

- Veri toplama,
- Sinyal işleme,
- Komut oluşturma
- Uygulama (Carvalho ve ark.,2015).

DHGUP'un temel özelliği, uyarının frekansı ile doğrudan ilişkilendirilebilmesidir. Örneğin, bir kişiye 10 Hz. frekansında yanıp sönen bir ışık gösterildiğinde, beyindeki DHGUP aktivitesi de 10 Hz. frekansında artar. Bu özelliği kullanarak, BCI sistemleri belirli frekanslardaki DHGUP aktivitesini algılayarak kullanıcının dikkatini belirli bir görsel uyarana verdiğini belirleyebilir. DHGUP tabanlı BBA sistemleri genellikle şu adımları içerir:

Görsel Uyarıcılar: Sistem, kullanıcıya sunulan görsel uyarıcılara sahiptir. Bu uyarıcılar genellikle farklı frekanstaki ışıkların veya desenlerin yanıp sönmeleri şeklinde olabilir.

EEG Sinyal Algılama: Kullanıcının beyin aktivitesini ölçmek için EEG elektrotları kullanılır. Bu elektrotlar, beyin aktivitesinin özellikle görsel uyarıcılara yanıt verdiği bölge olan oksipital bölgeye yerleştirilir.

DHGUP'un Algılanması: Kullanıcının görsel uyarıcılara yanıtı EEG sinyalleri aracılığıyla kaydedilir. DHGUP, belirli frekanslardaki görsel uyarıcılara beyin dalgalarının senkronize bir şekilde yanıt vermesi olarak görülür.

Sınıflandırma ve Yorumlama: Sistem, kaydedilen EEG sinyallerini işleyerek hangi görsel uyarıcıya odaklandığını veya hangi frekansın DHGUP'ünü ürettiğini belirler. Bu, kullanıcının belirli bir komutu veya niyeti belirttiğini gösterir.

İşlemeye Dayalı Etkileşim: Sistem, kullanıcının beyin sinyallerini belirli komutlara veya işlemlere dönüştürerek etkileşim sağlar. Örneğin, kullanıcının görsel uyarıcılardan birine odaklandığında belirli bir aksiyon gerçekleşebilir veya bir arayüzde bir kontrol sağlanabilir.




2. KAYNAK ARAŞTIRMASI

EEG, beynin elektriksel aktivitesini kaydeden bir izleme yöntemidir ve ilk olarak epilepsi veya uyku bozukluklarını teşhis etmek için Nörobilim alanında ortaya çıkmıştır (Albano ve ark.,2018). Son zamanlarda yapılan çalışmalarda, EEG sinyalleri, kullanıcının beyni ile bilgisayar arasında doğrudan bir yol oluşturduğundan, bir kişinin belirli uyaranlara verdiği duygusal tepkiyi tespit etmek için birçok çalışmada kullanılmıştır. Kaydedilen EEG sinyalleri beynin limbik bölümünde üretilir ve beş ana frekans bandından oluşur (Albano ve ark.,2018): Delta (δ : 4 Hz'e kadar), Teta (θ : 4-8 Hz) dalgaları, Alfa (α : 8) -15 Hz) dalgaları, Beta (β : 15-32 Hz) dalgaları ve Gamma (γ : ≥ 32 Hz) dalgaları (Moschona,2020). Örneğin bir alfa dalgası, rahatlamış, yansıtan bir zihin ve bilinç durumunu gösterebilirken, beta dalgaları yoğun, stresliden hafif saplantılıya kadar farklı bir aralık gösterebilir. Gama dalgaları, tanınan nesnelerin, seslerin veya dokunma duyularının kısa süreli hafıza eşleştirmesi sırasında bulunabilir ve bilişsel işlev, öğrenme, problem çözme görevleri ve bilgi işlemeden sorumludur (Moschona,2020). Ayrıca, bir duygunun gücü (baskınlığı), alfa/beta aktivite oranındaki bir artışla bulunabileceği gibi, beta aktivitesindeki bir artış olarak da bulunabilir (Moschona,2020).

Beyin Bilgisayar Arayüzü, insan beyni ile dış dünya arasında köprü kuran, sessiz düşüncelerini çözen ve bilgiyi iletmenin ortak yollarına olan talebi ortadan kaldıran verimli bir etkileşim teknolojisidir (Kaur ve Singh, 2017). Beyin-bilgisayar arayüzü (BBA) teknolojisi, özellikle klinik uygulamalarda son birkaç on yıldır yükselişte. Bu teknolojinin kayda değer kullanımı, ciddi şekilde engelli kişilerin çevreleriyle etkileşime girmesini sağlıyor. Bununla birlikte, son çalışmalar non-invaziv EEG cihazlarının kullanımını vurgulayarak, BBA'nın kontrollü bir laboratuvar sistemi dışında kullanılabileceğini göstermektedir (Douibi ve ark. 2021).


Duygu tanıma, BBA'nın çok önemli bir görevidir. İnsan duygularının konuşma, yüz ifadesi, metin, elektrokardiyogram (EKG) ve elektroensefalografi (EEG) gibi çeşitli tepkiler ve fizyolojik sinyallerle yakın ilişkisi vardır. Bunlardan EEG doğrudan beyinden toplanır ve duyguları nesnel olarak temsil edebilir. Günümüzde EEG tabanlı duygu tanıma konusunda kapsamlı çalışmalar ve uygulamalar ilerlemektedir. İnsanların farklı duygu durumlarının BBA sistemleri aracılığıyla yorumlanması ve duyguların otomatik olarak tanımlanması, robotik sistemlerin insanlardan alınabilen ve duyguları anlamak için işlenebilen duygusal kaynaklara ulaşmasını sağlayabilir (Özerdem ve ark., 2017).

EEG sinyalleri, her bir duygusal durum için spesifik modeller sergiler. EEG sinyali alımının elektrot konumu, Şekil 2.1'de gösterilmektedir (Gao ve ark., 2015).



Şekil 2.1. EEG sinyali ediniminin elektrot yerleştirme yapısı (Gao ve ark., 2015)

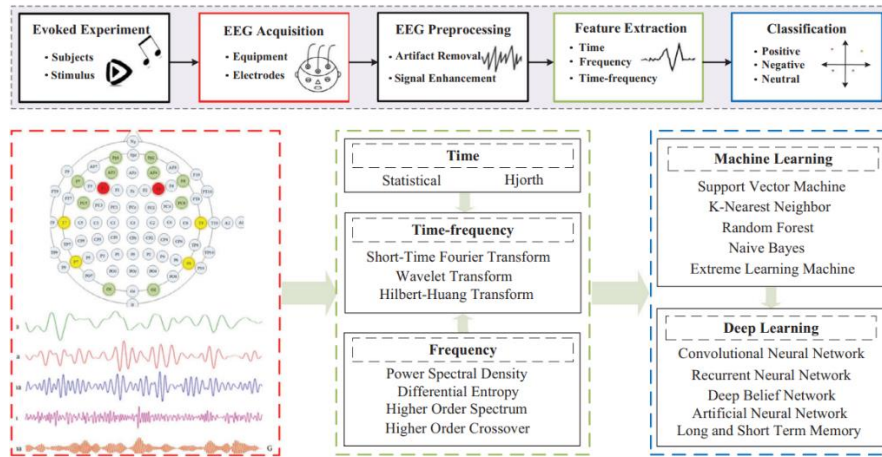
Kimmatkar ve Babu yaptıkları araştırmada EEG sinyallerinin işleme mimarisi Şekil 2.2.' de gösterildiği gibi önermişlerdir



Şekil 2.2. Önerilen mimari (Kimmatkar ve Babu,2017)

Önerilen mimarinin amacı, insanların EEG sinyallerini kullanarak beyin aktivitelerini analiz etmek, kişinin duygularını/zihinsel durumlarını tespit etmek ve gerekli aksiyon potansiyelini oluşturmak ve zihinsel engelli kişiler için non-invaziv teknolojiyi kullanarak düşük seviyede bir iletişim yolu sağlamaktır.


Wang ve ark., yaptıkları çalışmada EEG sinyallerini kullanarak duygusal özellik çıkarma ve sınıflandırmaya genel bakış diyagramını Şekil 2.3'teki gibi belirtmişlerdir (Wang ve ark., 2021).



Şekil 2. 3. EEG sinyallerini kullanarak duygusal özellik çıkarma ve sınıflandırmaya genel bakış diyagramı (Wang ve ark., 2021)

Özerdem ve ark., yaptıkları çalışmada olumlu ve olumsuz duygularla ilgili EEG sinyalleri, kanal seçimi ön işlemesi ile sınıflandırmışlardır. Duygu durumlarını belirlemek için Öz Değerlendirme Mankenleri kullanmış ve EEG sinyallerini sınıflandırmak için çok katmanlı ceptron başına sinir ağı (MLPNN) ve k-en yakın komşuluk (kNN) algoritması gibi ayrık dalgacık dönüşümü ve makine öğrenme teknikleri kullanarak her iki algoritma ile elde edilen doğruluklar sırasıyla %77,14 ve %72,92 olarak elde etmişlerdir (Özerdem ve ark., 2017).

Huang ve Wang yaptıkları çalışmada beyin kontrollü robotlarda EEG sinyal işleme yöntemlerini daha iyi geliştirmek için EEG sinyallerini kullanma sürecini beş aşamaya ayırabildiğini göstermişlerdir. EEG sinyallerini kullanma sürecini Şekil 2.4’ de gösterilmiştir (Huang ve Wang, 2021).



Şekil 2.4. BCI sistem yapı şeması (Huang ve Wang, 2021)

Do ve ark., EEG sinyallerinin analizi ile Fonksiyonel Elektrik Uyarma Sistemi (Functional Electrical Stimulation System) adı verilen ve ayak hareketlerini yitirmiş hastaların ayak hareketlerini yönetebilen sistem ile ilk başarılı uygulamayı gerçekleştirmişlerdir (Do ve ark., 2011).

C. Liu ve ark., sağ el hareketinin hayali ile sol el hareketinin hayalini C3 / C4 ve P3 / P4 kanallarına ait EEG verilerinin ortalama güçlerini kullanarak sınıflandırmışlardır. Kesikli Dalgacık Dönüşümü ve Fisher Doğrusal Ayrımı Analizi yöntemlerini kullanarak %75,5 doğrulukla, Kesikli Dalgacık Dönüşümü ve Destek Vektör Makinası yöntemlerini kullanarak %82,1 doğrulukla sınıflandırma yapmışlardır (Liu ve ark., 2012).

Çağlayan ve ark., yaptıkları çalışmada beynin elektriksel etkinliğindeki olaya bağlı potansiyel değişimlerin temel alındığı bir BCI gerçekleştirilmesi amaçlanmıştır. Bunun için P300 adı verilen ve belirli bir uyarı dizisinde hedeflenen uyarının diğerlerine göre nadiren vurgulanması sonucu ortaya çıkan bir olaya bağlı potansiyel bileşeni kullanılmıştır. Robot kolundaki servo motorları temsil eden numaralandırılmış imgeler rastgele sırada vurgulanırken denek seçmek istediğine odaklanmaktadır. Böylece odaklanılan imge her vurgulandığında beyinde P300 bileşeni oluşmaktadır. Son aşamada ise tespit edilen uyarı, robot kolundaki kaç numaralı servo motoru temsil ediyorsa o motor hareket ettirilmektedir. Süregiden beyin etkinliğine göre düşük genlikli olan P300 cevabının güçlendirilmesi için ortalama alma ve dalgacık dönüşümü kullanılmıştır (Çağlayan ve ark., 2013).

Koyaş ve ark., felçli hastaların rehabilitasyonu sürecinde kullanılmak üzere tasarlanmış olan robotik bir sistem ile birleştirilmiş ve hastaların yapmak istedikleri sağ kol hareketlerini zihinlerinde canlandırarak robot sistemini kontrol etmeleri sağlanmıştır. Deneyler sırasında kaydedilen EEG verilerinden, frekans bantlarındaki güç yoğunluğu öznel olarak seçilmiş ve hastanın hayali motor hareketleri Doğrusal Ayırtaç Analizi (DAA) yöntemi ile sınıflandırılmıştır. (Koyaş ve ark., 2013) Bu çalışmaya özgün olarak, sınıflandırıcıdan elde edilen sonsal olasılık değerleri BBA uygulamalarında alışlageldiği gibi ayrık sınıflandırıcı çıktıları olarak değil, doğrudan sürekli değere sahip çıktılar halinde rehabilitasyon robotu sisteminin hızını kontrol etmek için kullanılmıştır (Koyaş ve ark., 2013).

Aydemir ve Kayıkçıoğlu, yaptıkları çalışmada ellerinin hareketinin hayaline dayalı EEG sinyalleri sınıflandırılması için hızlı ve doğruluğu yüksek bir yöntem önerilmiştir. (Aydemir ve Kayıkçıoğlu, 2014) Yöntem üç adımla sunulmuştur. Birinci adımda ön işleme olarak EEG verilerine normalleştirme uygulanmış, ikinci adımda

Fourier Dönüşümü kullanarak öznitelikler çıkarılmıştır. Son adımda ise çıkarılan öznitelikler Destek Vektör Makineleri, k-En Yakın Komşu ve Doğrusal Ayırıcı Analizi ile sınıflandırılmıştır. (Aydemir ve Kayıkçıoğlu, 2014) Önerilen yöntem BCI Competition 2003 isimli yarışmada Data Set III veri kümesine başarılı bir şekilde uygulanmış ve sınıflandırma yapılarak %91.4 oranında doğruluk elde edilmiştir (Aydemir ve Kayıkçıoğlu, 2014).

Bevilacqua ve ark., “Konvolüsyonel Sinir Ağı kullanarak Sanal Ortamda yürümenin kontrolü için yeni bir BCI-SSVEP tabanlı yaklaşım” adlı çalışmada Bir Konvolüsyonel Sinir Ağı'na (CNN) dayalı invaziv olmayan bir Beyin Bilgisayar Arayüzü (BCI), Sanal Ortamda (VE) navigasyon için yeni bir yaklaşım olarak sunulmaktadır. Önerilen SSVEP navigasyon paradigması, sırasıyla ilerlemek, sola dönmek, sağa dönmek ve yürümeyi durdurmak için sırasıyla üç navigasyon komutu artı bir dinlenme durumundan oluşan dört sınıf seçimine dayanmaktadır. Katılımcının, sunulan sanal senaryo üzerinde üst üste bindirilmiş üç farklı sembolden birine dikkatini odaklayarak gezinme komutlarından birini seçmesi amaçlanmıştır. Önerilen yaklaşımı doğrulamak için iki deney gerçekleştirmişlerdir: ilki, bir eğitim ve test oturumu sırasında alınan EEG sinyalleriyle beslenen CNN'nin çevrimdışı performansını değerlendirmek; ikincisi, VE'deki bir navigasyon görevine uygulanan tüm önerilen yöntemi değerlendirmeyi amaçlamıştır. Çevrimdışı veriler üzerindeki ilk deneyin sonuçları, EEG'deki SSVEP özelliklerinin tanımlanması için bir CNN'nin oldukça yüksek doğruluk ve güvenilirlikle uygulanabileceğini göstermiştir (Bevilacqua ve ark., 2014).

Kaya ve ark. uyarlanmış taşınabilir bir Epoc Emotiv EEG başlığı ve makine öğrenme metotlarından biri olan destek vektör makineleri kullanarak, EEG verilerinden sağ ve sol el hareketlerinin düşüncesini tespit edebilecek bir BBA sistemi tasarlanmışlardır (Kaya ve ark., 2017). Uygulanan BBA, yaklaşık olarak %80 doğrulukla, sağ/sol hareket düşüncesinin ayrılmasını sağlamış (Kaya ve ark., 2017).

Öztürk ve Yılmaz yaptıkları çalışmada, bir kadın denekten 39 denemede alınan verilerle dinlenim, hareket hayalinin ve hareketin, sinyallerin çarpıklık, logaritma enerji entropisi, enerji, Shannon entropi ve basıklık gibi istatistiksel özellikleri kullanılarak %97,4 doğrulukta sınıflandırılması sağlanmıştır. Bu çalışmada, söz konusu sistemin BBA uygulamalarında kullanılmasında yüksek başarı elde edilebileceği gösterilmiştir (Öztürk ve ark., 2018).

M. Tosun ve ark., Sağ elini kullanan ve sağlıklı 21 yaşında bir erkeğin gözleri kapalı olarak EEG verilerini kaydetmiş. Bu verilerin bir kısmı sol ve sağ elin ileri-geri

hareketleri iken bir kısmı fiziksel hareket yapmadan hareketin hayal edilmesi ile ilgili kayıtlar alınmış. Hayal ile hareket verilerinden oluşan test veri seti eğitilen ağa uygulandığında, hayal ile hareket verileri %99,9975 doğrulukla sınıflandırmışlardır (Tosun ve ark., 2018).

K. Karadağ ve ark., bilgisayar ekranındaki imlecin sağa ve sola hareketinin doğru tahmin edilmesi üzerine dalgacık dönüşümü kullanmışlardır. EEG işaretlerinin sınıflandırma işlemini yalnız tek elektroda uygulayarak çalışma yapmış ve C3 için %95, CZ için %97,5 ve C4 için %100 doğrulukla sınıflandırmışlardır (Karadağ ve ark., 2020).

M. Değirmenci ve ark., internetten açık erişim ile deneklerin yedi farklı frekansta (6- 6.5-7-7.5-8.2-9.3-10Hz) yanıp sönen bir frekansa baktıklarında kaydedilen EEG sinyallerini içeren bir veri seti elde etmiş ve makine öğrenimine dayalı yaklaşımda Wigner-Ville Dağılımı (WVD) kullanarak EEG sinyallerinin Zaman-Frekans (ZF) gösterimlerinden öznitelikler çıkarmışlardır. Bu öznitelikler ile Karar Ağacı, Doğrusal Ayırım Analizi (DAA), k-En Yakın Komşu (k-NN), Destek Vektör Makinesi (DVM), Naive Bayes, Topluluk Öğrenme sınıflandırıcılarıyla sınıflandırmışlar ve maksimum doğruluğu %47,60 ile topluluk öğrenme sınıflandırıcısında elde etmişlerdir (Değirmenci ve ark., 2021).

R. Kumar ve ark., yaptıkları deneyde beş mor kutu, aynı anda beş farklı frekansta yanıp sönmelerini sağlayarak (6.66, 7.50, 8.57, 10.00 ve 12.00 Hz) gönüllülere hareketlerini minimumda tutmaları, yutkunmamaları ve göz kırpmamaları talimatı vermişler ve elde ettikleri veri setini Yapay Sinir Ağı sınıflayıcısı uygulayarak %90 doğruluk oranına erişmişlerdir (Kumar ve ark.,2022).

3. MATERYAL VE YÖNTEM

Gerçekleştirilen çalışmada Emotiv EPOC + 14 kanallı başlık ile 4 erkek ve 4 kız olmak üzere toplamda 8 kişiden alınan EEG kayıtları kullanılmıştır.

BBA sistemlerinin en önemli kısmı görsel uyaran programlama yazılımıdır. Görsel uyarıcı programlama yazılımı, BBA sistemlerinin kritik bir bileşenidir çünkü kullanıcıların dikkatini çekmek ve belirli komutları iletmek için kullanılan görsel stimülasyonun doğru bir şekilde oluşturulmasını sağlar. Bu yazılım, kullanıcı deneyimini optimize etmek için dikkat dağıtmadan ve etkileşimi artırarak, belirli frekanslarda yanıt veren görsel uyarıcılara yönelik tasarlanmalıdır.


Bu alıřmada üretilen uyaran görsellerinin oksipital bölgeden alınan EEG sinyalleri üzerindeki etkilerini deęerlendirmek için çeřitli analiz yöntemleri kullanılmıştır.

3.1. Görsel Uyaran Tasarımı

Bu çalışmada DHGUP tabanlı beyin bilgisayar arayüzü sistemi tasarımı için PsychoPy programı kullanılmıştır. PsychoPy, psikolojik deneylerin ve nörobilimsel arařtırmaların tasarımı için popüler bir açık kaynaklı yazılım platformudur. Sistemin görsel uyarıcılarının oluşturulması, kullanıcı arayüzlerinin tasarlanması ve deney protokollerinin programlanması için PsychoPy'nin esnek ve kullanıcı dostu arayüzü kullanılmıştır.

Bu yazılım, deneysel koşulların programlanması, zamanlama kontrolü, uyaran sunumu ve veri toplama gibi işlemleri kolaylaştırır. Ayrıca, PsychoPy'nin Python tabanlı yapısı, kullanıcıların özelleştirilmiş deneyler oluşturmak için geniş bir kütüphane ve esneklik sunar. Bu çalışmada PsychoPy'nin kullanılması, DHGUP tabanlı BBA sistemlerinin tasarımında etkili ve verimli bir yaklaşım sunmuştur. Aynı zamanda PsychoPy'nin emotiv programı ile koordineli çalışması avantaj sağlamıştır.


Şekil 3.1'de PsychoPy programında oluşturulan görsel tasarım ekranı görülmektedir.



Şekil 3.1. PsychoPy programında oluşturulan görsel tasarım ekranı

Görsel uyarının çalışma süresi toplamda 144sn olup her 20sn'de dinlenme boşluğu bırakılmıştır. Programın başlatılmasıyla Deneyde karşılama yazısıyla beraber bir uyarı sesi verilmiş ve kişinin gösterilen görsellere belli bir sırada bakması, hangi görsele ne zaman bakması gerektiği ise yine uyarıcı sesler ile bildirilmiştir.

Yapılan tasarım ve yazılımla sağ, sol, yukarı ve aşağı oklarının 20sn boyunca belirli frekanslarda titreşimi sağlanmıştır. Şekil 3.2' de görsel uyarın tasarımı verilmiştir.



Şekil 3. 2. Kullanıcılara sunulan görsel tasarım

Kullanılacak DHGUP frekanslarını seçmek önemlidir. DHGUP frekansları, görsel uyarıcıların yanıp sönme frekanslarıdır ve kullanıcının beyin aktivitesinin belirli bir görsel uyarıcıya nasıl tepki verdiğini belirlemek için kullanılır. Klinik deneyime göre, 15 ila 25 Hz. arasında olan görsel uyarımlar kolayca bir epileptik sendromu tetikleyebilir. 6 Hz.' in altındaki titreşim frekansları, kullanıcının kolayca yorgun hissetmesine neden olur (Chen ve ark., 2017).

SSVEP frekanslarını seçerken dikkate almanız gereken bazı faktörler şunlardır:

Görsel Tolerans: İnsan gözü, belirli bir frekanstaki yanıp sönme hızlarını farklı derecelerde tolere edebilir. Genellikle 6 ila 30 Hz. aralığındaki frekanslar kullanılır. Ancak, kullanıcıların konforu ve rahatlığı göz önünde bulundurulmalıdır.

Ayırma Gücü: SSVEP sinyallerinin algılama bilirliliği ve ayırt edilebilirliği, seçilen frekanslara bağlıdır. Genellikle birkaç farklı frekans seçilir ve bunların birbirinden net bir şekilde ayrılması sağlanır.

Duyarlılık ve Güvenilirlik: Bazı frekanslar, diğerlerine göre daha güçlü veya daha güvenilir SSVEP sinyalleri üretebilir. Bu, sistemin doğruluğunu ve güvenilirliğini etkiler.

Uygulama Bağlamı: Hangi uygulama için SSVEP tabanlı BBA sistemi kullanılacaksa, bu uygulamanın gereksinimlerini göz önünde bulundurmak önemlidir. Örneğin, bir oyun veya eğlence uygulaması için farklı frekanslar seçilebilirken, bir iletişim arayüzü için farklı frekanslar daha uygun olabilir.

Sistem Performansı: Seçilen frekanslar sistemin performansını etkileyebilir. Bazı frekanslar, donanım veya yazılım kısıtlamalarına bağlı olarak daha iyi işlenebilir veya daha az gürültüye duyarlı olabilir.

SSVEP frekanslarının seçimi, sistemin performansı, kullanıcı konforu ve uygulama gereksinimleri göz önünde bulundurularak dikkatlice yapılmalıdır. Optimal frekanslar seçilerek SSVEP tabanlı BBA sisteminin etkinliği ve kullanılabilirliği artırılabilir.

Bu çalışmada, katılımcıların sağlığı göz önünde bulundurularak frekans aralığı 6-10 Hz. olarak belirlenmiştir. Bu seçim, literatür taramaları sonucunda elde edilen

bulgulara dayanmaktadır ve katılımcı güvenliğini sağlama amacı taşımaktadır. Klinik deneyimlere göre, 15-25 Hz. arasındaki görsel uyarımlar epileptik semptomları tetikleyebilirken, 6 Hz.'nin altındaki frekanslar katılımcıların hızlı bir şekilde yorulmasına yol açabilmektedir (Chen ve ark., 2017). Bu doğrultuda, kullanılan görsel uyarımların frekansları şu şekilde ayarlanmıştır: Sağ ok = 7Hz.

Sol ok= 8Hz.

İleri ok = 9Hz.

Geri ok= 10Hz.

Olarak ayarlanmıştır.


3.2. EEG Kayıtları

Bu tez çalışmasının deney aşamasında Emotiv EPOC+ 14 Kanallı EEG cihazı kullanılmıştır. Kullanılan Emotiv EPOC+ cihazı şekil 3.3'te gösterilmiştir.



Şekil 3.3. Emotiv EPOC+ 14 Kanallı EEG kayıt cihazı

Bu cihaz, EEG sinyallerini kaydetmek için kullanılan taşınabilir bir sistemdir. Cihazın sahip olduğu 14 kanal, farklı bölgelerdeki beyin aktivitesini ölçmek için tasarlanmıştır. Kanalların isimleri şunlardır: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4. Ayrıca, P3 ve P4 kanalları referans kanalı olarak kullanılmıştır. Referans kanalları, kaydedilen beyin sinyallerini diğer kanalların sinyalleriyle karşılaştırmak için kullanılır ve genellikle bir referans noktası olarak işlev görürler. Şekil 3.4'te kayıt alınan bölgeler gösterilmiştir.



Şekil 3.4. Emotiv EPOC+ cihazının yerleştirildiği ve kayıt aldığı bölgeler

EEG kayıtları alınmadan önce Emotiv başlığının elektrotlarına geçirilen padler tuzlu su ile ıslatılmış ve kişinin başına bu şekilde takılarak Emotiv uygulamasında en iyi sinyal algılanana kadar başlığın oturtulması sağlanmıştır.

Deneye katılan tüm katılımcılara, deneyin başlangıcında göz kırpmamaları gerektiği bilgisi verilmiştir. Bu bilgi, deney süresince EEG sinyallerinin mümkün olan en düşük miktarda gürültü ile kaydedilmesini sağlamak amacıyla önemlidir. Deney düzeni, katılımcıların göz kırpmalarını en aza indirmek için optimize edilmiştir. Katılımcılar, deney boyunca kendilerini rahat hissetmeleri için uygun bir konumda oturarak yerleştirilmişlerdir. Ayrıca, deney sırasında herhangi bir rahatsızlık durumunda katılımcıların rahatça mola verebilmeleri için uygun araç ve imkanlar sağlanmıştır. Bu düzenlemelerin amacı, deneyin verimli ve güvenilir bir şekilde gerçekleştirilmesini sağlamak ve elde edilen verilerin doğruluğunu artırmaktır.

Bu doğrultuda, deneye katılan katılımcılara, deneyin başlaması için öncelikle bir uyarı sesi verilmiştir. Ardından, katılımcılara sağ oka odaklanmaları istenerek ilk 5 saniyelik odaklanma dönemi başlatılmıştır. Her bir katılımcı, sonraki uyarı sesini duyduğunda sırasıyla sol, yukarı ve aşağı oklara odaklanmak üzere yönlendirilmiştir. Bu odaklanma süreleri 5'er saniye olarak belirlenmiştir. Toplamda 20 saniyelik bu süreç tamamlandıktan sonra, katılımcılara 10 saniyelik bir göz dinlendirme molası verilmiştir. Bu deney prosedürü, her bir katılımcı için 5 kez tekrarlanmıştır. Şekil 3.5'te deney sırasında alınan görüntüler verilmiştir.




Şekil 3.5. Katılımcıların deney sırasında alınan görüntüleri.

Çizelge 3.1. Katılımcı Bilgileri

Katılımcı	Erkek	Kadın
Kişi Sayısı	4	4

Elde edilen EEG kayıtlarında oksipital bölgeye ait olan kanallardan P7, P8, O1 ve O2 kanallarına ait sinyaller işleme alınmıştır. Bu kanallar, görsel uyaranlara yanıt olarak oksipital bölgede oluşan beyin aktivitesini ölçmek için seçilmiştir. MATLAB programında, işlenmiş bu sinyaller üzerinde çeşitli analizler ve işlemler gerçekleştirilmiştir. Şekil 3.6'da P7, P8, O1 ve O2 kanallarına ait sinyal kayıtları gösterilmiştir.



Şekil 3.6. P7, P8, O1 ve O2 kanallarına ait sinyal kayıtları

Bu sinyal kayıtları, oksipital bölgedeki beyin aktivitesini temsil eder ve görsel uyarıcılara yanıt olarak elde edilmiştir. Her bir kanalın sinyal kaydı, zamanın işlevi olarak grafiksel olarak sunulmuştur. Bu grafiklerde, zamanın ilerleyişi boyunca her bir kanaldaki elektriksel aktivitenin değişimi gösterilmiştir. P7, P8, O1 ve O2 kanallarının her biri farklı bir reaksiyon gösterirken, bu sinyallerin karakteristik özellikleri incelenmiş ve analiz edilmiştir.

3.3. Sinyal Temizleme ve Önişleme

Sinyal temizleme ve önişleme, bir sinyaldeki istenmeyen bileşenleri filtreleyerek veya düzenleyerek sinyali daha anlamlı veya daha kullanışlı hale getirme işlemidir. Önişleme adımları genellikle şunları içerir:

- **Filtreleme:** Gürültüyü azaltmak veya sinyaldeki istenmeyen frekans bileşenlerini ortadan kaldırmak için filtreler kullanılır.
- **Örnekleme:** Sinyalin örnekleme frekansını ayarlamak, daha yüksek frekanslı sinyalleri almak veya sinyali daha düşük bir çözünürlükle işlemek için yapılır.
- **Normalizasyon:** Sinyali bir standart formata veya aralığa dönüştürmek için kullanılır.

- **Düzenleme:** Verileri temizlemek ve düzenlemek için kullanılır. Bu, eksik verileri doldurma, aykırı değerleri düzeltme veya dönüştürme işlemlerini içerebilir.
- **Özellik Çıkarma:** Sinyalden anlamlı özellikler çıkarmak için kullanılır. Bu, frekans bileşenlerini tanımlama, zaman serisi özelliklerini belirleme veya sinyaldeki diğer önemli desenleri ortaya çıkarma sürecini içerir.

Bu adımlar, EEG verilerinin doğru bir şekilde analiz edilmesi için önemlidir ve güvenilir sonuçlar elde etmek için dikkatle uygulanmalıdır. İyi bir sinyal temizleme ve ön işleme, analiz sürecinde doğruluk ve güvenilirlik sağlar ve sonuçların yorumlanmasını kolaylaştırır.

Bu çalışmada sinyal temizleme için filtreleme ve normalizasyon işlemleri yapılmış olup sinyale 2-15 Hz. 4. Dereceden butterworth bant geçiren filtre ve Z-score normalizasyon uygulanmıştır.

3.3.1 Butterworth Filtre

Butterworth filtresi, elektronik ve dijital sinyal işleme alanlarında yaygın olarak kullanılan bir filtre türüdür. Butterworth filtresi, belirli bir geçiş bölgesindeki frekans tepkisini maksimum düzeyde düz yapmak için tasarlanmıştır.

Butterworth bant geçiren filtre, belirli bir frekans aralığını geçiren bir filtre türüdür. Yani, belirli bir alt ve üst frekans sınırı arasındaki frekansları geçirir, ancak bu sınırların dışındaki frekansları engeller. Bu, sinyalin istenmeyen frekans bileşenlerini filtreleyerek istenilen frekans bandını izole etmek için kullanılır. Bu çalışmada 0-30 Hz. arasındaki frekansları geçiren bir Butterworth bant geçiren filtre kullanarak, bu frekans aralığındaki sinyaller korunur ve dışındaki frekans bileşenleri filtrelendir. Filtreleme işlemi 4. dereceden Butterworth filtresi ile gerçekleştirilmiştir. 4. derece, geçiş bandının daha keskin olmasını sağlar, bu da filtreleme işleminde yüksek hassasiyet ve doğruluk sunar.

3.3.2. Z-Score Normalizasyon

Z-score normalizasyonu, bir veri setindeki her bir özelliğin ortalaması ve standart sapması kullanılarak verilerin standartlaştırılmasını sağlayan bir normalizasyon yöntemidir. Bu yöntem, veri setindeki her bir özelliğin dağılımını standart normal dağılıma dönüştürür.

Z-score normalizasyonu, her bir veri noktasının, o özelliğin ortalamasından çıkarılması ve ardından o özelliğin standart sapmasına bölünmesiyle yapılır. Bu işlem, veri setindeki her bir özellik için ayrı ayrı gerçekleştirilir.

Formül olarak, Z-puanı normalizasyonu şu şekildedir:

$$z = \frac{x - \mu}{\sigma} \quad (3.1)$$

Burada:

z = Normalleştirilmiş değer (Z-score)

x = Normalleştirilecek değer (örneğin, bir veri noktası)


μ = Özelliğin ortalaması

σ = Özelliğin standart sapması

Z-puanı normalizasyonu, veri setindeki her bir özellik için bir merkezleme (ortalama değeri 0) ve bir ölçeklendirme (standart sapması 1) sağlar. Bu, veri setindeki değişkenlik arasındaki farklılıkları dengelemeye yardımcı olur ve makine öğrenimi algoritmalarının daha iyi performans göstermesine katkıda bulunabilir.

Özellikle, Z-score normalizasyonu, makine öğrenimi modellerinde kullanılan özelliklerin birbiriyle karşılaştırılabilir hale getirilmesinde ve bazı algoritmaların daha iyi performans göstermesinde önemli bir rol oynar. Bu nedenle, veri ön işleme aşamasında sıkça kullanılan bir tekniktir.

Normalizasyon uygulanmış ve bant geçiren filtre uygulanmış sinyal görüntüleri şekil 3.7' de verilmiştir.



Şekil 3.7. (a): P7 Kanalına ait ham ve filtrenilmiş sinyal görüntüsü (b): O1 Kanalına ait ham ve filtrenilmiş sinyal görüntüsü (c): O2 Kanalına ait ham ve filtrenilmiş sinyal görüntüsü (d): P8 Kanalına ait ham ve filtrenilmiş sinyal görüntüsü

3.4. Frekans Analizi

Frekans analizi, bir sinyalin frekans bileşenlerini inceleyerek sinyalin frekans alanındaki özelliklerini anlamaya ve yorumlamaya yönelik bir işlemdir. Bu çalışmada frekans analizi için;

- Filtreleme
- Fast Fourier Transform(FFT)
- Welch Metodu, kullanılmıştır.

3.4.1. Filtreleme Metodu

Filtreleme ve frekans analizi, birbirini tamamlayan iki önemli işlemdir ve sinyal işleme uygulamalarında genellikle birlikte kullanılırlar.

Filtreleme, bir sinyalin belirli frekans bileşenlerini bastırarak veya izole ederek sinyalin özelliklerini değiştirmeyi amaçlar. Öte yandan, frekans analizi, bir sinyalin frekans bileşenlerini inceleyerek sinyalin frekans alanındaki özelliklerini ortaya çıkaran bir araçtır. Filtreleme işlemi sırasında, filtre tipine bağlı olarak, belirli bir frekans aralığındaki bileşenler geçirilebilir veya bastırılabilir. Örneğin, düşük geçiren bir filtre yüksek frekans bileşenlerini bastırırken, yalnızca düşük frekans bileşenlerini geçirebilir.

Yüksek geçiren bir filtre ise tam tersini yapar, düşük frekansları bastırırken yüksek frekans bileşenlerini geçirir. Bant geçiren filtreler, belirli bir frekans bandındaki bileşenleri geçirirken diğerlerini bastırmak için kullanılır.

Frekans analizi, bir sinyalin frekans bileşenlerini görselleştirmek ve analiz etmek için kullanılır. Bu, sinyalin hangi frekanslarda güçlü olduğunu, belirli frekans bileşenlerinin varlığını veya değişimlerini belirlemeyi sağlar. Bu bilgi, filtreleme işlemi için hangi tür filtrelerin kullanılacağını belirlemede yardımcı olabilir.

Bu nedenle, filtreleme ve frekans analizi sıklıkla birlikte kullanılır. Filtreleme, sinyalin belirli bileşenlerini işlemek için kullanılırken, frekans analizi, işlenen sinyalin frekans bileşenlerini anlamak ve yorumlamak için kullanılır.

Bu çalışmada filtreleme metodunda bant geçiren filtre kullanılmış olup her bir komut için gerçekleştirilen sinyaller;

- Sağ: 6.5Hz.-7.5Hz.
- Sol: 7.5 Hz.-8.5 Hz.
- İleri: 8.5 Hz.-9.5 Hz.
- Geri: 9.5 Hz.-10.5 Hz. aralığında filtrelenmiştir.

3.4.2. Fast Fourier Transform (FFT)

Fast Fourier Transform (FFT), ilk olarak Cooley ve Tukey tarafından 1965'te tanıtılan, karmaşık Fourier serilerinin hesaplanması için geliştirilen bir algoritmadır. Bu algoritma, özellikle sinyal işleme ve analiz alanında önemli bir yer tutar. Fourier dönüşümünün etkili bir şekilde uygulanmasını sağlar, böylece verilerin zaman alanından frekans alanına hızlı bir şekilde dönüştürülmesine olanak tanır.

FFT algoritması, bir zaman serisini frekans alanı temsiline dönüştürür. Dijital bir sinyalin frekans spektrumu, örnekleme hızı/FFT noktası olarak ifade edilen bir frekans çözünürlüğü ile temsil edilir; burada FFT noktası, zaman serisi uzunluğundan büyük veya ona eşit olan seçilmiş bir skalar değerdir. Basitliği ve etkinliği nedeniyle, FFT sıklıkla diğer spektrum analiz yöntemlerine karşı karşılaştırılan temel bir yöntem olarak kullanılır. (Schneider, 2022)

FFT'nin matematiksel formülü, sinyalin zaman alanından frekans alanına dönüştürülmesini ifade eden genel formülasyonu içerir. FFT'nin temelinde, DFT vardır ve DFT'nin genel formülü şu şekildedir:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-2j\pi nk/N} \quad (3.2)$$

Bu formülde:

- $X(k)$: Frekans alanında elde edilen sinyalin k. bileşeni,
- $x(n)$: Zaman alanında verilen giriş sinyalinin n. örneği,
- N : Örnekleme noktalarının sayısı (genellikle 2'nin üssü olarak seçilir),
- J : Karmaşık sayı birimidir ($j^2=-1$).

3.4.3. Welch Metodu

Welch yöntemi, bir sinyalin güç spektrumunun (veya enerji spektrumunun) tahmin edilmesi için kullanılan bir spektral yoğunluk tahmin yöntemidir. Özellikle sinyal işleme ve spektral analiz alanlarında yaygın olarak kullanılan bir tekniktir.

EEG verileri üzerinde uygulandığında, veriler 256 veri noktasından oluşan çerçevelere gruplandırılır ve bu çerçeveler üzerinde yöntem uygulanır. Welch'in yöntemi, FFT'ye dayanan klasik spektrum tahmin yöntemlerinden biridir (Polat ve ark., 2008).

FFT tabanlı Welch yöntemi, klasik bir yöntem olarak tanımlanır. Bu yöntem, periyogram spektral tahmincisinin ikinci bir modifikasyonunu gerçekleştirir; bu modifikasyon, periyogramı hesaplamadan önce veri segmentlerini pencereleme işlemidir. Veri segmentlerinin pencerelenmesi, spektral tahminin gürültüden arındırılmasına yardımcı olur ve daha stabil ve güvenilir spektrum tahminleri elde edilmesini sağlar. Bu sayede, özellikle EEG gibi karmaşık sinyallerde, belirli frekans bileşenlerinin daha doğru bir şekilde analiz edilmesi mümkün hale gelir (Evans,2000), (Vaitkus ve ark. 1988). Formül olarak ifade etmek gerekirse, Welch yöntemi genellikle aşağıdaki adımlarla ifade edilir:

1. Sinyal pencere uzunluğuna ve örtüşme miktarına göre bölünür.
2. Her pencere için FFT uygulanır ve güç spektrumu hesaplanır.
3. Her bir güç spektrumu penceresi birleştirilerek ortalama alınır ve genel güç spektrumu tahmini elde edilir.

3.5. Özellik Çıkarma Yöntemleri

Bu tez çalışmasında elde edilen EEG sinyallerinden zaman özellikleri, frekans yöntemi özellikleri olarak; FFT ile PSD sinyalinin özellikleri elde edilmiştir. Elde edilen özellikler aşağıdaki alt başlıklarda sunulmuştur.

3.5.1. Zaman Özellikleri

Zaman alanı özellikleri, sinyallerin doğrudan zaman ekseninde analiz edilmesini sağlayan önemli ölçütlerdir. Bu tez çalışmasında kullanılan zaman özellikleri;

1. Standart Sapma: Bir sinyalin değerlerinin ortalama etrafında ne kadar dağıldığını ölçen bir özelliktir. Sinyalin değişkenliğini veya yayılmasını gösterir.

$$x_{std} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_m)^2} \quad (3.3)$$

Burada N, x sinyalinin uzunluğunu belirtmektedir.

2. Eğrilik (Skewness): Sinyalin dağılımının simetrikliğini ölçen bir özelliktir. Pozitif eğrilik, dağılımın sağa doğru eğimli olduğunu, negatif eğrilik ise sola doğru eğimli olduğunu gösterir.

$$x_{ske} = \frac{\sum_{n=1}^N (x(n) - x_m)^3}{(N-1)x_{std}^3} \quad (3.4)$$

3. Basıklık (Kurtosis): Sinyalin dağılımının sivriliğini veya "zirve" eğilimlerini ölçen bir özelliktir. Yüksek basıklık, verilerin ortalamaya yakın toplandığını, düşük basıklık ise daha yaygın bir dağılım olduğunu gösterir.

$$x_{kurt} = \frac{\sum_{n=1}^N (x(n) - x_m)^4}{(N-1)x_{std}^4} \quad (3.5)$$

4. Sinyal Enerjisi: Bir sinyalin güç içeriğini ölçen bir özelliktir. Genellikle sinyalin karesinin toplamı olarak hesaplanır.

$$x_{enerji} = \sum_{n=-\infty}^{\infty} |x[n]|^2 \quad (3.6)$$

5. Sıfır Geçiş Noktası (Zero Crossing Rate): Sinyalin sıfır çizgisini kaç kez geçtiğini ölçen bir özelliktir. Sinyalin hızlı değişimlerini veya frekans içeriğini yansıtabilir.

$$Z(i) = \frac{1}{2W_L} \sum_{n=1}^{W_L} |sgn[x_i(n)] - sgn[x_i(n-1)]| \quad (3.7)$$

Burada,

$$\text{sgn}[x_i(n)] = \begin{cases} 1, & x_i(n) \geq 0, \\ -1, & x_i(n) < 0. \end{cases} \quad (3.8)$$

3.5.2. Frekans Özellikleri

Frekans özelliklerini çıkarmak için FFT yöntemi ile elde edilen güç spektral yoğunluğu (PSD) (0-30Hz arası) kullanılmıştır.

Elde edilen frekans özellikleri:

1. Güç spektral yoğunluğunun ortalama değeri
2. Güç spektral yoğunluğunun standart sapması
3. Güç spektral yoğunluğunun eğrilik değeri
4. Güç spektral yoğunluğunun basıklık değeri
5. Sağ ok (7 Hz) için güç toplamı (6.5-7.5Hz arası güç toplamı)
6. Sol ok (8 Hz) için güç toplamı (7.5-8.5Hz arası güç toplamı)
7. İleri ok (9 Hz) için güç toplamı (8.5-9.5Hz arası güç toplamı)
8. Geri ok (10 Hz) için güç toplamı (9.5-10.5Hz arası güç toplamı)
9. Sağ ok (7 Hz) için relatif güç toplamı (6.5-7.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
10. Sol ok (8 Hz) için relatif güç toplamı (7.5-8.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
11. İleri ok (9 Hz) için relatif güç toplamı (8.5-9.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
12. Geri ok (10 Hz) için relatif güç toplamı (9.5-10.5Hz arası güç toplamı/0-30Hz arası güç toplamı)

Her bir kanal için toplam 17 özellik çıkarılarak özellik seçme yöntemi işlemine devam edilmiştir.

3.6. Özellik Seçme Yöntemi

Özellik seçme yöntemi (feature selection), makine öğrenimi modellerinin performansını artırmak ve modelin daha açıklanabilir olmasını sağlamak amacıyla, veri setindeki en önemli ve ilgili özelliklerin (değişkenlerin) seçilmesi sürecidir. Özellik seçme, gereksiz veya ilgili olmayan özelliklerin çıkarılmasıyla modelin karmaşıklığını azaltır ve overfitting (aşırı uyum) riskini düşürür.

Bu tez çalışmasında temel bileşen analizi (Principal Component Analysis-PCA) kullanılmıştır.

3.6.1. Temel Bileşen Analizi (Principal Component Analysis-PCA)

Temel Bileşen Analizi; tanıma, sınıflandırma, görüntü sıkıştırma alanlarında kullanılan, bir değişkenler setinin varyans kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak, boyut indirgenmesi ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir (Yıldız ve ark., 2010). PCA, verideki en önemli bilgi bileşenlerini (yani, varyansı en yüksek olan yönleri) bulur ve bu bileşenleri kullanarak veriyi yeniden ifade eder. Bu sayede hem veri setinin boyutunu küçültür hem de veri setindeki en önemli yapısal bilgiyi korur. Bu yaklaşım, verideki önemli özellikleri daha iyi izole ederek sınıflandırma performansını artırmaya yardımcı olur (P. Uddin ve ark., 2021).

Bu çalışmada PCA %75 oranında seçilmiştir. PCA'nın %75 seçim oranı, verilerdeki toplam varyansın %75'ini açıklayan temel bileşenlerin seçilmesi anlamına gelir. %75 seçim oranıyla, toplam varyansın %75'ini açıklayan temel bileşenler seçilir. Bu, veri kümesinin çoğunluğunu temsil eden daha az sayıda özellik elde etmemizi sağlar. Örneğin, eğer 10 temel bileşen varsa ve ilk 5'inin toplam varyansı %75 ise, bu 5 bileşen seçilir. Bu seçim, boyut azaltma amacıyla yapılır; verilerdeki gereksiz veya fazla bilgi kaynağını ortadan kaldırarak, hesaplama verimliliğini artırır ve modelin genelleme yeteneğini geliştirir.

3.7. Sınıflandırma Yöntemleri

Sınıflandırma yöntemleri, verileri önceden belirlenmiş sınıflara ayırmak için kullanılan makine öğrenimi teknikleridir. Bu yöntemler, eğitim verilerinden öğrendikleri kalıplar ve özellikler aracılığıyla yeni verilerin hangi sınıfa ait olduğunu tahmin ederler.

Bu tez çalışmasında: Karar ağaçları(KA), Destek vektör makineleri(DVM) ve yapay sinir ağları(YSA) ve Doğal Bayes(DB) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

3.7.1. Karar Ağaçları (KA)

Karar ağaçları, ağaç biçiminde yapılandırılmış denetimli bir sınıflandırma modelidir (Javaid ve ark.,2022). Ağaçtaki her düğüm bir özneliliğin testini temsil eder, her dal testin çıktısını temsil eder ve her yaprak bir sınıf veya sınıf dağılımı anlamına gelir. Birden fazla dala sahip karar düğümleri, bir yaprak düğümü tarafından temsil edilen bir sınıflandırma veya karar olarak çıktıyı oluşturacak bir dizi karar formüle eder (Kaminski ve ark.,2018).

Avantajlar:


1. Kolay anlaşılır ve görselleştirilebilir.
2. Hem sayısal hem de kategorik verilerle çalışabilir.
3. Özellik seçme gereksinimi azdır, çünkü karar ağacı kendisi özellikleri seçer.

3.7.2. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri, Vapnik tarafından geliştirilmiş ve istatistiksel öğrenme teorisi alanında ortaya çıkmış bir öğrenme metodudur (Cortes ve Vapnik, 1995). DVM, verilen bir veri noktasını iki sınıftan birine sınıflandırmayı amaçlayan en popüler makine öğrenimi algoritmasıdır (Arora ve ark.,2024). DVM'nin temel amacı, farklı sınıflardan en yakın veri noktaları arasındaki mesafeyi maksimize eden optimal hiper düzlemi bulmaktır (Arora ve ark.,2024).

DVM, basit bir yapısı olması ve pratik uygulamalarda yüksek performans göstermesi bakımından oldukça kullanışlıdır. DVM'lerde kullanılacak örnek sayısı önemli değildir. DVM eğitim esnasında görülmemiş verileri de sorunsuz olarak sınıflandırır. Bu DVM'nin genelleştirebilme yeteneğini gösterir. Genelleştirebilme özelliği DVM' yi diğer tekniklere göre iyi bir alternatif yapmaktadır (Karakoyun ve ark., 2014).

Sınıflandırılacak örnekler Şekil 3.8'deki gibi doğrusal bir düzlemle ayrıştırılabilecek seviyede olabilir. DVM analizi, olayları ayıran 1-boyutlu düzlemi, hedef kategorilerini temel alarak bulmaya çalışır. Mümkün çizgilerin sınırsız sayısı vardır. Hangi çizginin, daha iyi olduğunu bulmak ve optimal çizgiyi nasıl bulacağımız önemlidir. Noktalı gösterilen çizgiler en yakın vektörler arasında mesafeyi ayıran çizgiye paralel olarak çekilir. Noktalı çizgilerin arasındaki mesafe kenarı çağırır. Kenarın genişliğini zorlayan vektörler, destek vektörleridir (Karakoyun ve ark., 2014).




Şekil 3.8. Destek vektörlerinin gösterimi

3.7.3. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları, yoğun bir şekilde birbirine bağlı, uyarlanabilir basit işlem elemanlarından (nöronlardan) oluşan yapılar olarak tanımlanabilir. Bu yapılar, veri işleme ve bilgi temsiliinde büyük ölçekli paralel hesaplamalar yapabilme yeteneğine sahiptir. Her bağlantıyla ilişkili ağırlıkların uyarlanması sayesinde, sinirsel model öğrenme kapasitesine sahiptir. YSA, kalıpları tanımak için eğitilebilir ve eğitim sırasında geliştirilen doğrusal olmayan modeller, sinir ağlarının sonuçlarını genelleştirmesine ve daha önce karşılaşılmamış kalıplara uygulama yapmasına olanak tanır (Haykin ve ark.,1994) (Chaudhuri ve ark.,2000) (Übeyli, 2009).

Yapay Sinir Ağları (YSA), biyolojik nöronların çalışma prensibine benzer şekilde işleyen yapay nöronlardan oluşan bir modeldir. YSA'da, her bir yapay nöron, girdileri işleyerek bir çıktı üretir ve bu işlemi yaparken ağırlıklar ve aktivasyon fonksiyonları kullanır. Bu ağ yapısı, öğrenme sürecinde girdiler ile çıktı arasındaki ilişkiyi öğrenmek amacıyla ağırlıkları günceller. Amaç, verilen girdiler için en iyi çıktıyı elde etmektir. Şekil 3.9'da yapay sinir hücresine ait bir algılayıcının temel yapısı verilmiştir.




Şekil 3.9. Yapay sinir hücresine ait bir algılayıcının temel yapısı (Öztürk ve ark., 2018)

Algılayıcı, girdi ve çıktıları olan, yapay sinir ağlarının temel işlemci birimidir. x_j : $j = 1, \dots, d$ girdi birimlerini gösterir. x_0 her zaman 1 değerini alan ek girdidir. w_j , x_j girdi biriminin ağırlığı, y de çıktı birimidir. y çıktı birimi en basit durumda girdilerin ağırlıklı toplamı olarak hesaplanır. Denklem 3.9 ile bir algılayıcıya ait giriş ve çıkışların değer hesaplaması yapılır (Karakoyun ve ark., 2014).

$$y = \sum_{j=1}^d w_j x_j + w_o \quad (3.9)$$

Şekil 3.10’de YSA’nın temel yapısı gösterilmiştir.



Şekil 3.10. YSA’nın temel yapısı (Karakoyun ve ark., 2014)

Bu çalışmada ikili sınıflamada gizli katman sayısı 10’dan başlatılarak ikişer artımla 100’e kadar çıkarılıp sonuçları elde edilmiştir.

3.7.4. Doğal Bayes (DB)

Doğal Bayes, etiketli verilerle tahmin yapabilen denetimli bir yöntem olarak gruplandırılır. Çeşitli uygulamalar için en iyi 10 sınıflandırma yönteminden biridir. (Atkinson ve Campos, 2016) Naïve Bayes’in bir avantajı, olasılık tahminleri hesaplanırken özellikler arası bağımlılıkları göz ardı ederek eksik değerleri işleyebilmesidir. Ayrıca, eğitim örnek verisi açısından, küçük bir eğitim veri seti kullanabilmesi, bu yöntemi belirli veriler için uygun hale getirir (Ramirez ve Vamvakousis, 2012) (Oktavia ve ark., 2019).

Doğal Bayes, bir sınıflandırma modeli oluşturmak için Bayes teoremi uygulanarak çalışır. Doğal Bayes’teki temel varsayım, veri setindeki özellikler arasında bağımsızlık olduğudur. Sonuç olarak, bir sınıf etiketinin belirli bir özelliğinin varlığı, başka bir özelliğın varlığıyla ilişkili değildir. Her özellik, sınıf etiketinin olasılık tahminine bağımsız olarak katkıda bulunur. Basitliği ile tanınmasına rağmen, Doğal Bayes, belirli uygulamalar için diğer gelişmiş sınıflandırma yöntemlerini geride bırakabilir (Oktavia ve ark., 2019).

3.8 Performans Değerlendirme Ölçütleri

Sınıflandırma performansını değerlendirmek için kullanılan çeşitli ölçütler vardır. Bu ölçütler, modelin doğruluğunu ve başarımını farklı açılardan değerlendirir. Sınıflandırma modellerinde sıkça kullanılan başlıca performans değerlendirme ölçütleri: Doğruluk, hassasiyet, duyarlılık, F1 skoru, özgüllük, karmaşıklık matrisidir. Bu çalışmada Karmaşıklık matrisi ve doğruluk değerlendirmesi yapılmıştır.

1. Karmaşıklık Matrisi:

Modelin doğru ve yanlış sınıflandırdığı örneklerin sayısının özetlendiği 2x2'lik bir tablodan oluşur. TP (True Positive), TN (True Negative), FP (False Positive), FN (False Negative) değerlerini içerir.

Çizelge 3.2'de karmaşıklık matrisi verilmiştir.

Çizelge 3.2. Karmaşıklık matrisi		
		Tahmin Edilen
	Pozitif	Negatif
	Gerçek	
Gerçek	Pozitif Doğru Pozitif (True Positive: TP)	Yanlış Negatif (False Negative: FN)
	Negatif Yanlış Pozitif (False Positive: FP)	Doğru Negatif (True Negative: TN)

2. Doğruluk (Accuracy):

Modelin doğru sınıflandırdığı örneklerin, tüm örneklere oranıdır.

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP} \quad (3.10)$$

3. Duyarlılık (Sensitivity):

Modelin gerçekten pozitif olan örnekleri doğru şekilde pozitif olarak tanımlama yeteneğidir.

$$Sensitivity = \frac{TP}{TP+FN} \quad (3.11)$$

4. Özgüllük (Specificity)

Modelin gerçekten negatif olan örnekleri doğru şekilde negatif olarak tanımlama yeteneğidir.

$$Specificity = \frac{TN}{TN+FP} \quad (3.12)$$

3.9. Sınıflandırma Verileri

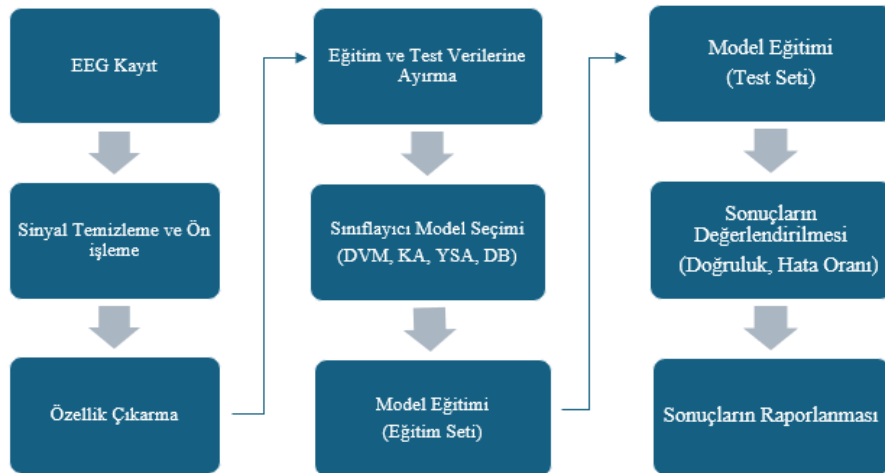
Bu çalışmada veri setinin ikili sınıflandırma amacıyla hazırlanması sürecinde, çeşitli adımlar izlenmiştir. Her biri 40 örnek içeren 4 farklı sınıfa ait veriler, birleştirilerek iki sınıf haline getirilmiştir. 1. ve 3. sınıflar "Grup 1" olarak birleştirilirken, 2. ve 4. sınıflar "Grup 2" olarak birleştirilmiştir. Böylece, her biri 80 örnekten oluşan iki sınıf elde edilmiştir.

Veri kümesi, eğitim ve test setlerine rastgele seçilen indeksler kullanılarak ayrılmıştır. Her sınıf için, toplam 80 örnekten 72'si eğitim setine dahil edilmiş, kalan 8 örnek ise test seti olarak ayrılmıştır. Bu yöntem, her grubun temsiliyi dengeli bir şekilde sağlamak amacıyla uygulanmıştır. Toplamda 160 örnekten oluşan bir veri kümesi, 144 eğitim ve 16 test örneğine ayrılmıştır. Tablo 3.1'de verilerin nasıl bölündüğü gösterilmektedir.

Tablo 3.1 Eğitim ve test verilerinin sayıları

SINIF	Eğitim Verisi	Test Verisi	Toplam Örnek Sayısı
Grup 1 (Sınıf 1 ve 3)	72	8	80
Grup 2 (Sınıf 2 ve 4)	72	8	80
Toplam	144	16	160

Hazırlanan veri seti MATLAB uygulamasında sınıflandırma işlemlerine alınmıştır. Sınıflandırma işleminin nasıl gerçekleştirildiğine dair yapılan işlemlerin anlatıldığı şema şekil 3.11'de verilmiştir.



Şekil 3.11. Tez çalışmasındaki tüm aşamaları gösteren blok şema

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez çalışmasında üç çalışma gerçekleştirilmiştir.

Çalışmaların öncesinde veriler üzerinde bir ön işleme aşaması gerçekleştirilmiş olup bu aşama normalizasyon ve filtreleme adımlarını içermektedir. Verilerin daha sağlıklı ve anlamlı hale getirilmesi amacıyla yapılan bu işlemlerden sonra sinyallerin belirli özellikleri çıkarılmıştır. 8 kişiden elde edilen EEG sinyalleri, filtreleme işlemi sonrasında güç spektral yoğunluğu (PSD) hesaplamalarına tabi tutulmuş ve her bir veri seti için toplamda 17 farklı özellik çıkarılmış ve çalışmalara başlanmıştır.

Birinci uygulamada, bu özellikler arasından en anlamlı olanlarını belirlemek amacıyla özellik seçme yöntemi olarak Temel Bileşenler Analizi (TBA) uygulanmıştır. Bu sayede, verilerin boyutu küçültülerek önemli özellikler belirlenmiştir. Ardından, ikili sınıflandırma yöntemi kullanılarak farklı makine öğrenmesi algoritmaları ile ikili sınıflandırma işlemi gerçekleştirilmiştir. Bu aşamada Destek Vektör Makineleri (SVM), Karar Ağaçları (KA), Yapay Sinir Ağları (YSA) ve Naive Bayes (NB) yöntemleri kullanılmıştır. Bu algoritmaların her birinde sınıflandırma başarıları ölçülerek karşılaştırmalar yapılmıştır. İkinci uygulamada ise aynı sınıflayıcılar kullanılarak dörtlü sınıflandırma işlemine tabi tutulmuştur.


İkinci uygulamada, ilk uygulamadan farklı olarak daha zorlu bir sınıflandırma problemi ele alınarak dört sınıf üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Yine aynı sınıflayıcılar (SVM, KA, YSA, NB) kullanılarak dörtlü sınıflandırma yapılmış ve bu yöntemlerin dört sınıf üzerinde gösterdiği performanslar incelenmiştir. Her bir sınıflayıcının başarı oranları karşılaştırılarak bu aşamada sınıflandırmanın zorluk derecesi ve sınıflayıcıların farklı sınıflar üzerindeki yetenekleri değerlendirilmiştir.

Üçüncü ve son uygulamada ise kanal seçimi gerçekleştirilmiştir. Bu aşamada, biyomedikal sinyallerin her bir kanalı ayrı ayrı ele alınarak, her bir kanal üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Her bir kanalın ayrı ayrı sınıflandırılması sonucunda elde edilen başarı oranları incelenmiş ve her kanalın sınıflandırma performansına olan katkısı değerlendirilmiştir. Bu sayede, sinyallerin her bir kanalının sınıflandırma sürecine olan etkisi detaylı bir şekilde analiz edilmiş ve hangi kanalların sınıflandırma açısından daha belirleyici olduğu tespit edilmeye çalışılmıştır.

4.1. Sınıflandırma Çalışması 1

4.1.1 Sinyal Filtreleme

Sinyallere bant geçiren filtre uygulanarak yüksek frekanslı gürültülerin ve istenmeyen düşük frekanslı bileşenlerin ortadan kaldırılması sağlanmıştır. Bu işlem sonucunda sinyallerin daha temiz ve analize uygun hale gelmesi hedeflenmiştir. Filtreleme işlemi sonrasında sinyallerin güç spektral yoğunlukları (PSD) hesaplanmış, böylece sinyallerin farklı frekans bileşenlerindeki güç dağılımları elde edilmiştir. Şekil 4.1’de, bir kişiden alınan dört farklı hareket sinyalinin filtrelenmiş hali sunulmuştur. Bu sinyaller, belirli bir frekans aralığında, istenmeyen bileşenler çıkarıldıktan sonra daha net bir görünüme kavuşmuştur ve her bir hareketin sinyali arasında belirgin farklar gözlemlenebilmektedir. Bu görseller, her bir hareketin kendine özgü frekans bileşenlerini ortaya koyarak, sinyallerin analitik süreçlerde nasıl kullanıldığını görsel olarak açıklamaktadır.



Şekil 4.1 Bir kişiden alınan 4 hareket sinyalinin filtrelenmiş görüntüleri

4.1.2. Güç Spektral Yoğunluğu (Power Spektral Density -PSD)

Güç spektral yoğunluğu (PSD), bir sinyalin frekans bileşenlerinin güçlerini gösteren bir ölçümdür. Genellikle bir sinyalin frekans domainindeki dağılımını belirtmek için kullanılır. PSD, bir sinyalin frekans bileşenlerinin enerji yoğunluğunu ifade eder ve sinyalin hangi frekanslarda güçlü olduğunu gösterir. PSD'nin matematiksel formülasyonu, sinyalin fourier dönüşümü kullanılarak elde edilir.

$$PSD(f) = \lim_{T \rightarrow \infty} \frac{1}{T} |X(f)|^2 \quad (4.1)$$


- $PSD(f)$ Sinyalin PSD'sini ifade eder.
- f : Frekansı temsil eder.
- T zaman aralığını temsil eder
- $X(f)$: Sinyalin Fourier dönüşümünü ifade eder.

Bu formül, sinyalin frekans bileşenlerinin gücünü frekansa göre hesaplar. Ancak, pratik uygulamalarda bu integrali hesaplamak zor olabilir ve bu nedenle PSD genellikle spektral analiz araçları kullanılarak hesaplanır. Örneğin, sinyalin örnekleme periyodu TTT ise, gerçekleşmiş bir sinyalin PSD'si genellikle şu şekilde hesaplanır:

$$S_{XX}(f) = \frac{1}{N} |X(f)|^2 \quad (4.2)$$

Burada N örnek sayısını ifade eder. Bu formül, tek bir sinyal örneği üzerinden hesaplanan bir tahmindir ve gerçek PSD'nin tam değerini vermek için bir tahminci olabilir.

Katılımcı 1'den alınan sinyallere ait örnek PSD grafikleri şekil 4.2' de gösterilmiştir.



Şekil 4.2. Katılımcı 1'in P7 Kanalına ait 1. Denemesinin her frekans değeri için oluşturulan grafikleri

Tablo 4.1'de Katılımcı 1'e ait P7 kanalının PSD değerlerini göstermektedir.

Tablo 4. 1. Katılımcı 1'e ait P7 kanalının PSD değerleri

Katılımcı	Kanal Seçimi	Trial	Action	MAX PSD Değerine Sahip Frekans/Hz	Beklenen Frekans/Hz
Kişi 1	P7	1	1	9.7323	7hz
			2	10.920	8Hz
			3	9.7923	9Hz
			4	10.1920	10HZ
	P7	2	1	9.7923	7hz
			2	9.7923	8Hz
			3	10.1920	9Hz
			4	9.7923	10HZ
	P7	3	1	9.7923	7hz
			2	10.1920	8Hz
			3	9.7923	9Hz
			4	9.5925	10HZ
	P7	4	1	10.1920	7hz
			2	9.7923	8Hz
			3	9.7923	9Hz
			4	9.7923	10HZ
	P7	5	1	9.9921	7hz
			2	10.3918	8Hz
			3	9.9921	9Hz
			4	9.7923	10HZ

Tablo 4.2'de Katılımcı 1'e ait O1 kanalının PSD değerlerini göstermektedir.

Tablo 4. 2. Katılımcı 1'e ait O1 kanalının PSD değerleri

Katılımcı	Kanal Seçimi	Trial	Action	MAX PSD Değerine Sahip Frekans/Hz	Beklenen Frekans/Hz
Kişi 1	O1	1	1	10.1920	7hz
			2	9.9921	8Hz
			3	9.7923	9Hz
			4	9.7923	10HZ
	O1	2	1	10.1920	7hz
			2	9.5925	8Hz
			3	9.7923	9Hz
			4	9.7923	10HZ
	O1	3	1	9.7923	7hz
			2	10.1920	8Hz
			3	10.1920	9Hz
			4	9.7923	10HZ

	O1	4	1	10.1920	7hz
			2	9.7923	8Hz
			3	9.7923	9Hz
			4	9.7923	10HZ
	O1	5	1	9.9921	7hz
			2	9.5925	8Hz
			3	9.9921	9Hz
			4	9.7923	10HZ

Tablo 4.3’ de Katılımcı 1’e ait O2 kanalının PSD değerlerini göstermektedir.

Tablo 4.3. Katılımcı 1’e ait O2 kanalının PSD değerlerini

Katılımcı	Kanal Seçimi	Trial	Action	MAX PSD Değerine Sahip Frekans	Beklenen Frekans
Kişil	O2	1	1	9.7923	7hz
			2	9.9921	8Hz
			3	10.1920	9Hz
			4	9.7923	10HZ
	O2	2	1	10.1920	7hz
			2	10.1923	8Hz
			3	10.1920	9Hz
			4	9.7923	10HZ
	O2	3	1	10.1920	7hz
			2	9.9921	8Hz
			3	9.9921	9Hz
			4	9.5925	10HZ
	O2	4	1	10.1920	7hz
			2	8.9929	8Hz
			3	9.7923	9Hz
			4	9.7923	10HZ
	O2	5	1	8.9929	7hz
			2	8.9929	8Hz
			3	8.1935	9Hz
			4	9.7923	10HZ

Tablo 4.4. Katılımcı 1’e ait P8 kanalının PSD değerleri


Katılımcı	Kanal Seçimi	Trial	Action	MAX PSD Değerine Sahip Frekans	Beklenen Frekans
Kişil	P8	1	1	9.7923	7hz
			2	9.9921	8Hz
			3	10.1920	9Hz

		4	9.7923	10HZ
P8	2	1	10.1920	7hz
		2	10.1920	8Hz
		3	10.1920	9Hz
		4	9.7923	10HZ
P8	3	1	10.1920	7hz
		2	9.9921	8Hz
		3	9.9921	9Hz
		4	9.9926	10HZ
P8	4	1	10.1920	7hz
		2	8.9929	8Hz
		3	9.7923	9Hz
		4	9.7923	10HZ
P8	5	1	9.9921	7hz
		2	8.9929	8Hz
		3	10.1920	9Hz
		4	10.3918	10HZ

Verilen tablolar yalnızca bir katılımcıya ait sinyallerin analiz sonuçlarını yansıtmaktadır. Bununla birlikte, tüm katılımcılardan elde edilen sinyaller de benzer işlemlerden geçirilmiş ve aynı yöntemlerle analiz edilmiştir. Her bir katılımcının sinyalleri için aynı filtreleme ve PSD hesaplamaları yapılmıştır.

4.1.3. Welch Metodu ile PSD Hesapları

Bir katılımcıdan elde edilen sinyallere ait örnek Welch metodu ile hesaplanmış güç spektral yoğunluğu (PSD) grafikleri, Şekil 4.3'te gösterilmiştir. Welch metodu, sinyallerin frekans bileşenlerini daha düzgün bir şekilde tahmin etmek amacıyla kullanılan bir teknik olup, veriyi bölümlere ayırarak her bir bölümün PSD'sini hesaplayıp bunları ortalama alır. Şekil 4.3'teki grafikler, sinyallerin frekans bileşenlerine göre güç dağılımlarını görselleştirmekte ve sinyallerin hangi frekans aralıklarında yoğunlaştığını göstermektedir.



Şekil 4.3. Bir katılımcıdan alınan sinyallere ait welch metodu grafikleri

Matlab'da bulunan Welch metodu algoritması kullanılarak tüm katılımcılardan elde edilen sinyallerin güç spektral yoğunluğu (PSD) hesaplamaları gerçekleştirilmiştir.

4.1.4. Özellik Çıkarma

Zaman özelliklerini çıkarmak için çeşitli metrikler hesaplanmış ve bu özellikler sinyallerin zaman domainindeki davranışını analiz etmek amacıyla kullanılmıştır. Elde edilen zaman özellikleri şunlardır:

1. Sinyalin Standart sapması
2. Sinyalin eğrilik değeri
3. Sinyalin basıklık değeri
4. Sinyalin enerjisi
5. Sıfır geçiş noktası

Frekans özelliklerini çıkarmak için Fast Fourier Transform (FFT) yöntemi kullanılarak 0-30 Hz. aralığındaki güç spektral yoğunluğu (PSD) hesaplanmıştır. Elde edilen PSD verileri kullanılarak çeşitli frekans özellikleri çıkarılmıştır. Bu özellikler şunlardır:

1. Güç spektral yoğunluğunun ortalama değeri
2. Güç spektral yoğunluğunun standart sapması
3. Güç spektral yoğunluğunun eğrilik değeri

4. Güç spektral yoğunluğunun basıklık değeri
5. Sağ ok (7 Hz) için güç toplamı (6.5-7.5Hz arası güç toplamı)
6. Sol ok (8 Hz) için güç toplamı (7.5-8.5Hz arası güç toplamı)
7. İleri ok (9 Hz) için güç toplamı (8.5-9.5Hz arası güç toplamı)
8. Geri ok (10 Hz) için güç toplamı (9.5-10.5Hz arası güç toplamı)
9. Sağ ok (7 Hz) için relatif güç toplamı (6.5-7.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
10. Sol ok (8 Hz) için relatif güç toplamı (7.5-8.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
11. İleri ok (9 Hz) için relatif güç toplamı (8.5-9.5Hz arası güç toplamı/0-30Hz arası güç toplamı)
12. Geri ok (10 Hz) için relatif güç toplamı (9.5-10.5Hz arası güç toplamı/0-30Hz arası güç toplamı)

4.1.5. İkili Sınıflandırma

Makine öğrenmesi işlemine alınan değerler önce PCA kullanılmadan işleme tabi tutulmuş ve ardından PCA kullanılarak varyansın %75 seçilmesiyle özellikler seçilmiştir. Bu özelliklerin ardından, Destek Vektör Makineleri (DVM) sınıflayıcısı çeşitli fonksiyonlarıyla test edilmiştir. Sınıflandırma işlemi sonucunda elde edilen doğruluklar dikkate alınarak çeşitli performans ölçütleri hesaplanmıştır. Bu ölçütler, sınıflandırma modelinin genel başarımını değerlendirmek için önemli bilgiler sunmaktadır. Her bir sınıf için duyarlılık (sensitivity) ve özgüllük (specificity) parametreleri ayrı ayrı hesaplanmıştır. Kullanılan fonksiyonları ve sınıflandırma türleri şunlardır:

1. Linear Kernel
2. Quadratic Kernel
3. Cubic Kernel
4. Fine Gaussian Kernel
5. Medium Gaussian Kernel

Tablo 4.5'te DVM algoritmasına ait sınıflama ve performans sonuçları verilmiştir.

Tablo 4.5. DVM algoritmasına ait sınıflama ve performans sonuçları

DVM				
Tür	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
LİNEAR	49.3	75.0	51.3	47.2

QUADRATIC	56.6	56.2	55.5	55.5
CUBIC	50.0	50.0	50.0	50.0
FINE GAUSSIAN	47.9	56.2	45.8	50.0
MEDIUM GAUSSIAN	56.2	75.0	62.5	50.0

Tablo 4.6’da PCA uygulanmış DVM algoritmasına ait sonuçlar verilmiştir.

Tablo 4.6. PCA uygulanmış DVM algoritmasına ait sonuçlar

DVM				
PCA				
Tür	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
LİNEAR	49.3	50.0	79.1	19.4
QUADRATIC	50.7	50.0	37.5	63.8
CUBIC	52.1	68.8	40.2	63.8
FINE GAUSSIAN	50.7	31.2	76.3	25.0
MEDIUM GAUSSIAN	49.3	50.0	58.3	40.2

Karar ağaçları sınıflayıcısı kullanılarak yapılan sınıflandırma işlemi sonucunda, farklı karar ağaçları parametreleri ile elde edilen sonuçlar, PCA %75 seçim oranı uygulanarak değerlendirilmiştir. Karar ağaçları sınıflayıcısında kullanılan parametreler ve özellikler şunlardır:

1. Fine Tree
2. Medium Tree
3. Course Tree

Tablo 4.7’de KA algoritmasına ait sonuçlar verilmiştir.

Tablo 4.7. KA Algoritması sonuçları

Karar Ağaçları				
Tür	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
Fine Tree	54.9	50.0	52.7	56.9
Medium Tree	54.9	50.0	52.7	56.9


Coarse Tree	63.9	75.0	75.0	52.7

Tablo 4.8’de PCA uygulanmış KA algoritması sonuçları verilmiştir.

Tablo 4.8. PCA Uygulanmış KA algoritması sonuçları

Karar Ağaçları				
Tür	PCA			
	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
Fine Tree	50.7	56.2	50.0	51.3
Medium Tree	50.0	56.2	51.3	48.6
Coarse Tree	42.4	50.0	63.8	20.8

Şekil 4.3’te Coarse Tree algoritmasına ait karmaşıklık matrisi verilmiştir.



Şekil 4.3. Coarse Tree algoritmasına ait karmaşıklık matrisi

Doğal Bayes sınıflayıcısında Gaussian ve Kernel fonksiyonları kullanılarak yapılan sınıflandırma işlemlerinin sonuçları, PCA %75 seçim oranı ile değerlendirilmiştir. Doğal Bayes sınıflayıcısı ile elde edilen sonuçlar Tablo 4.9’da verilmiştir.

Tablo 4.9. DB Algoritması sonuçları

Doğal Bayes				
Tür	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
Gaussian D. B	46.5	62.5	65.2	27.7
Kernel D. B	40.3	81.2	47.2	33.3

Tablo 4.10’da DB algoritmasının PCA ile yapılan sınıflandırma sonuçları verilmiştir

Tablo 4.10. PCA uygulanmış DB Algoritması sonuçları

Doğal Bayes				
Tür	PCA			
	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
Gaussian D. B	49.3	50.0	88.8	9.7
Kernel D. B	45.8	43.8	43.05	50.0

Yapay Sinir Ağları (YSA) yönteminde narrow neural network (dar sinir ağı) kullanılarak yapılan sınıflandırma işleminde, gizli katman sayısının etkisi araştırılmıştır. Gizli katman sayısı, başlangıç olarak 10’dan başlanmış ve her seferinde 2 artırılarak 50’ye kadar çıkarılmıştır. Her bir yapılandırma için doğruluk oranı ve performans parametreleri hesaplanmış ve sonuçlar Tablo 4.11’de verilmiştir.

Tablo 4.11. YSA Algoritmasına ait sonuçlar

Yapay Sinir Ağları (Narrow Neural Network)				
Gizli Düğüm Sayısı	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
10	52.1	68.8	54.1	50.0
12	56.2	62.5	56.9	55.5
14	57.6	75.0	59.7	55.5
16	43.8	62.5	41.6	45.8
18	48.6	62.5	38.8	58.3
20	53.5	75.0	47.2	59.7
22	51.4	81.2	51.3	51.3
24	52.1	68.8	50.0	54.1

26	52.1	75.0	51.3	52.7
28	45.8	68.8	44.4	47.2
30	52.8	62.5	50.0	55.5
32	48.6	62.5	48.6	48.6
34	51.4	68.8	47.2	55.5
36	50.0	43.8	45.8	54.1
38	50.0	68.8	41.6	58.3
40	51.4	75.0	54.1	48.6
42	55.6	56.2	47.2	63.8
44	51.4	62.5	51.3	51.3
46	50.7	62.5	54.1	47.2
48	56.2	62.5	51.3	61.1
50	51.4	68.8	45.8	56.9


Tablo 4.12’de PCA uygulanmış YSA algoritmasının sonuçları verilmiştir.

Tablo 4.12. PCA uygulanmış YSA algoritmasının sonuçları

Yapay Sinir Ağları				
Gizli Düğüm Sayısı	PCA			
	Accuracy (%)	Test Accuracy (%)	Özgüllük (%)	Duyarlılık (%)
10	50.7	37.5	58.3	43.0
12	52.8	56.2	51.3	54.1
14	52.1	31.2	56.9	47.2
16	51.4	43.8	55.5	47.2
18	47.9	62.5	50.0	45.8
20	44.4	56.2	47.2	41.6
22	47.9	43.8	51.3	44.4
24	50.0	37.5	51.3	48.6
26	43.1	62.5	45.8	40.2
28	44.4	56.2	33.3	55.5
30	50.0	43.8	50.0	50.0
32	50.0	50.0	47.2	52.7
34	43.8	68.8	44.4	43.0
36	43.8	37.5	38.8	48.6
38	50.0	37.5	47.2	52.7
40	50.7	56.2	47.2	54.1
42	44.4	18.8	44.4	44.4
44	41.7	43.8	45.8	37.5
46	50.0	37.5	52.7	47.2

48	54.2	56.2	50.0	59.7
50	50.0	31.2	45.8	54.1

YSA sonuçlarına ait grafik Şekil 4.4'te verilmiştir.



Şekil 4.4. İkili sınıflandırma düğüm sayısına göre accuracy ve test accuracy sonuçları

Yapay Sinir Ağları (YSA) sınıflandırmasının doğruluk oranlarını gösteren bu grafikler, gizli katman sayısının artırılmasına bağlı olarak modelin doğruluk oranlarındaki değişiklikleri görselleştirir.

4.2. Sınıflandırma Çalışması 2

Dörtlü sınıflandırma işlemi, DVM, Karar Ağaçları (KA), Doğal Bayes (DB) ve Yapay Sinir Ağları (YSA) yöntemleriyle gerçekleştirilmiştir. Ancak, yapılan analizler sonucunda beklenen doğruluk oranlarına ulaşamamıştır. Bu durumun ardından, özellikle YSA yöntemi üzerinde daha detaylı bir çalışma yapılmıştır. YSA modelinde, düğüm katman sayısının doğruluk oranlarına etkisi incelenmiş ve modelin performansını iyileştirmek amacıyla gizli katmanlardaki düğüm sayısı artırılmıştır.

Bu çalışma kapsamında, YSA modelinde gizli katman düğüm sayısı başlangıçta 10 olarak belirlenmiş ve her adımda 2'şer artırılarak denemeler yapılmıştır. Son deneme

ise 50 düğüm içeren katmanda gerçekleştirilmiştir. Her bir adımda modelin doğruluk oranları kaydedilmiş ve bu sonuçlar detaylı olarak incelenmiştir.

Bu süreçte, düğüm katman sayısının artırılmasına rağmen yine de beklenen doğruluk oranlarına ulaşamamıştır. Ortalama doğruluk oranı %23.86 olarak hesaplanmıştır.

Yapılan çalışmalar sonucu DVM algoritmasına ait alınan doğruluk değerleri tablo 4.13'te verilmiştir.

Tablo 4.13. DVM Algoritmasına ait dörtlü sınıflandırma sonuçları


DVM				
Tür	Accuracy (%)	Test Accuracy (%)	PCA	
			Accuracy (%)	Test Accuracy (%)
LİNEAR	25.7	31.2	22.9	25.0
QUADRATIC	30.6	18.8	25.7	25.0
CUBIC	28.5	18.8	25.0	25.0
FINE GAUSSIAN	25.0	25.0	22.9	31.2
MEDIUM GAUSSIAN	31.2	25.0	22.9	25.0

Dörtlü sınıflama KA algoritmasına ait sonuçlar Tablo 4.14'te verilmiştir.

Tablo 4.14. KA algoritmasına ait sonuçlar

KA				
Tür	Accuracy (%)	Test Accuracy (%)	PCA	
			Accuracy (%)	Test Accuracy (%)
Fine Tree	31.9	18.8	25.0	25.0
Medium Tree	31.2	25.0	26.4	31.2
Coarse Tree	30.6	31.2	23.6	31.2

Dörtlü sınıflandırma fine tree algoritmasına ait karmaşıklık matrisi şekil 4.5'te verilmiştir.



Şekil 4.5. Dörtlü sınıflandırma fine tree algoritmasına ait karmaşıklık matrisi

Dörtlü sınıflama DB algoritmasına ait sonuçlar Tablo 4.15'te verilmiştir.

Tablo 4.15. DB algoritmasına ait sonuçlar

DB				
Tür	Accuracy (%)	Test Accuracy (%)	PCA	
			Accuracy (%)	Test Accuracy (%)
Gaussian D. B.	20.8	18.8	26.4	25.0
Kernel D. B.	25.0	12.5	24.3	31.2

Dörtlü sınıflama YSA algoritmasına ait sonuçlar Tablo 4.16'da verilmiştir.


Tablo 4.16. YSA algoritmasına ait sonuçlar

YSA					
Gizli Düğüm Sayısı	Accuracy (%)	Test Accuracy (%)	Gizli düğüm sayısı	PCA	
				Accuracy (%)	Test Accuracy (%)
10	21.5	12.5	10	21.5	25.0
12	20.1	18.8	12	26.4	37.5
14	27.8	25.0	14	24.3	37.5
16	21.5	6.2	16	23.6	18.8
18	19.4	12.5	18	27.1	25.0
20	23.6	31.2	20	25.0	31.2

22	22.2	31.2	22	23.6	18.8
24	25.0	25.0	24	24.3	25.0
26	24.3	31.2	26	23.6	31.2
28	23.6	31.2	28	25.0	31.2
30	20.8	12.5	30	23.6	18.8
32	25.0	18.8	32	27.1	18.8
34	25.7	25.0	34	25.7	25.0
36	25.7	31.2	36	22.9	18.8
38	24.3	25.0	38	25.7	25.0
40	22.9	18.8	40	24.3	25.0
42	24.3	12.5	42	27.8	25.0
44	29.9	18.8	44	26.4	25.0
46	23.6	18.8	46	25.7	25.0
48	23.6	18.8	48	25.0	31.2
50	26.4	31.2	50	26.4	25.0

Dörtlü sınıflama YSA sonuçlarına ait grafik şekil 4.6’da verilmiştir.

Dörtlü Sınıflandırma Gizli Düğüm Sayısına Göre Accuracy ve Test Accuracy



Şekil 4.6 Dörtlü sınıflandırma düğüm sayısına göre accuracy ve test accuracy sonuçları

Dörtlü sınıflandırma işlemi sonucunda elde edilen doğruluklar dikkate alınarak çeşitli performans ölçütleri hesaplanmıştır. Bu ölçütler, sınıflandırma modelinin genel başarımını değerlendirmek için önemli bilgiler sunmaktadır. Her bir sınıf için duyarlılık (sensitivity) ve özgüllük (specificity) parametreleri ayrı ayrı hesaplanmıştır. Yapılan

hesaplamalar sonucu elde edilen DVM algoritmasının performans değerleri tablo 4.17’de verilmiştir.

Tablo 4.17. DVM algoritmasına ait performans değerleri

DVM			
Model	Sınıf	Özgüllük (%)	Duyarlılık (%)
Linear	Sınıf 1	58.92	11.11
	Sınıf 2	59.42	27.77
	Sınıf 3	50.00	19.44
	Sınıf 4	44.68	44.44
Quadratic	Sınıf 1	55.22	19.44
	Sınıf 2	57.89	30.55
	Sınıf 3	62.50	25.0
	Sınıf 4	51.92	47.22
Cubic	Sınıf 1	55.22	11.11
	Sınıf 2	55.35	27.77
	Sınıf 3	54.54	30.55
	Sınıf 4	52.08	44.44
Fine G.	Sınıf 1	25.31	44.44
	Sınıf 2	76.92	13.88
	Sınıf 3	47.36	25.00
	Sınıf 4	75.00	16.66
Medium G.	Sınıf 1	60.93	16.66
	Sınıf 2	55.93	33.33
	Sınıf 3	61.01	25.00
	Sınıf 4	51.92	50.00

KA algoritmasına ait performans sonuçları tablo 4.18’de verilmiştir.

Tablo 4.18. KA algoritmasına ait performans değerleri

KA			
Model	Sınıf	Özgüllük (%)	Duyarlılık (%)
Fine Tree	Sınıf 1	54.09	36.11
	Sınıf 2	49.20	41.66
	Sınıf 3	67.24	19.44
	Sınıf 4	64.81	30.55
Medium Tree	Sınıf 1	50.81	38.88
	Sınıf 2	50.81	38.88
	Sınıf 3	55.88	19.44
	Sınıf 4	64.81	27.77
Coarse Tree	Sınıf 1	53.33	33.33
	Sınıf 2	53.33	33.33
	Sınıf 3	78.84	08.33
	Sınıf 4	40.90	47.22

DB algoritmasına ait performans sonuçları tablo 4.19’da verilmiştir.

Tablo 4.19. DB algoritmasına ait performans değerleri

DB			
Model	Sınıf	Özgüllük (%)	Duyarlılık (%)
Gaussian	Sınıf 1	56.52	11.11
	Sınıf 2	21.21	44.44
	Sınıf 3	65.11	05.55
	Sınıf 4	44.89	22.22
Kernel	Sınıf 1	58.82	16.66
	Sınıf 2	51.02	30.55
	Sınıf 3	49.20	13.88
	Sınıf 4	41.50	38.88

YSA algoritmasına ait performans sonuçları tablo 4.20’de verilmiştir.

Tablo 4.20. YSA algoritmasına ait performans değerleri

Yapay Sinir Ağları			
Gizli Katman Sayısı	Sınıf	Özgüllük (%)	Duyarlılık (%)
10	Sınıf 1	39.06	16.66
	Sınıf 2	48.00	19.44
	Sınıf 3	46.15	19.44
	Sınıf 4	50.00	30.55
12	Sınıf 1	46.29	11.11
	Sınıf 2	47.05	13.88
	Sınıf 3	39.28	19.44
	Sınıf 4	39.02	36.11
14	Sınıf 1	57.37	13.88
	Sınıf 2	59.61	25.00
	Sınıf 3	48.38	27.77
	Sınıf 4	48.97	44.44
16	Sınıf 1	48.21	11.11
	Sınıf 2	51.16	25.00
	Sınıf 3	40.67	19.44
	Sınıf 4	41.66	30.55
18	Sınıf 1	35.18	25.00
	Sınıf 2	41.07	13.88
	Sınıf 3	48.97	11.11
	Sınıf 4	43.90	27.77
20	Sınıf 1	45.00	19.44
	Sınıf 2	48.88	33.33
	Sınıf 3	46.55	19.44
	Sınıf 4	53.06	22.22
22	Sınıf 1	46.77	08.33
	Sınıf 2	55.81	22.22
	Sınıf 3	40.67	22.22
	Sınıf 4	43.18	36.11
24	Sınıf 1	43.07	22.22

	Sınıf 2	53.70	19.44
	Sınıf 3	53.70	19.44
	Sınıf 4	50.00	38.88
26	Sınıf 1	47.61	13.88
	Sınıf 2	50.00	27.77
	Sınıf 3	51.92	22.22
	Sınıf 4	46.93	33.33
28	Sınıf 1	47.61	11.11
	Sınıf 2	46.93	30.55
	Sınıf 3	50.98	22.22
	Sınıf 4	48.93	30.55
30	Sınıf 1	51.02	13.88
	Sınıf 2	45.28	16.66
	Sınıf 3	40.67	16.66
	Sınıf 4	39.53	36.11
32	Sınıf 1	48.43	13.88
	Sınıf 2	49.05	27.77
	Sınıf 3	51.85	22.22
	Sınıf 4	51.11	36.11
34	Sınıf 1	48.38	19.44
	Sınıf 2	51.85	25.00
	Sınıf 3	50.00	25.00
	Sınıf 4	54.34	33.33
36	Sınıf 1	47.61	19.44
	Sınıf 2	49.05	30.55
	Sınıf 3	52.63	19.44
	Sınıf 4	55.55	33.33
38	Sınıf 1	46.03	16.66
	Sınıf 2	45.28	30.55
	Sınıf 3	48.21	22.22
	Sınıf 4	59.52	27.77
40	Sınıf 1	52.63	08.33
	Sınıf 2	67.50	25.00
	Sınıf 3	44.23	19.44
	Sınıf 4	39.58	38.88
42	Sınıf 1	46.03	16.66
	Sınıf 2	48.14	25.00
	Sınıf 3	54.71	16.66
	Sınıf 4	47.72	38.88
44	Sınıf 1	56.66	25.00
	Sınıf 2	57.89	27.77
	Sınıf 3	57.62	25.00
	Sınıf 4	50.90	41.66
46	Sınıf 1	43.75	16.66
	Sınıf 2	54.00	19.44
	Sınıf 3	43.85	25.00
	Sınıf 4	53.65	33.33
48	Sınıf 1	50.00	16.66
	Sınıf 2	52.08	25.00
	Sınıf 3	47.27	22.22
	Sınıf 4	43.39	30.55
50	Sınıf 1	54.23	16.66

	Sınıf 2	49.05	33.33
	Sınıf 3	55.35	19.44
	Sınıf 4	48.07	36.11

4.3. Sınıflandırma Çalışması 3

Üçüncü ve son çalışma olan bu bölümde, her bir kanal ayrı ayrı işleme alınarak sınıflandırma işlemi gerçekleştirilmiş ve doğruluk oranları hesaplanmıştır. Bu aşamada, her kanalın tek başına sınıflandırma performansı değerlendirilmiş ve hangi kanalın en yüksek doğruluk oranına sahip olduğu belirlenmiştir.

Bu çalışmanın amacı, verinin hangi kanaldan elde edildiğine göre sınıflandırma performansının nasıl değiştiğini incelemek ve en yüksek başarı oranını sağlayan kanalı tespit etmektir. Her bir kanal için ayrı ayrı uygulanan sınıflandırma algoritmaları sonucunda elde edilen doğruluk oranları kıyaslanmış ve en yüksek doğruluk oranı veren kanal P8 olarak belirlenmiştir.

Yapılan bu çalışmalar sonucunda, her bir kanal için performans parametreleri hesaplanmış ve ayrıca doğruluk oranlarının görsel grafiksel gösterimi aşağıda verilmiştir. Bu grafiklerde, her bir kanalın sınıflandırma başarısı açıkça görülmekte ve en yüksek başarı oranını sağlayan kanal öne çıkmaktadır. Bu bulgular, sınıflandırma algoritmalarının sadece bazı kanallar üzerinde daha iyi performans sergileyebileceğini ve bu kanalların belirlenmesinin önemli olduğunu göstermektedir.

Tablo 4.21’de Tüm kanallara ait DVM algoritmasına ait sonuçlar verilmiştir.

Tablo 4.21. Tüm kanallara ait DVM algoritmasına ait sonuçlar

DVM								
Tür	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)
LİNEAR	25.0	25.0	23.6	6.2	20.8	12.5	21.5	18.8
QUADRATIC	29.2	18.8	25.0	6.2	25.7	25.0	27.1	18.8
CUBIC	23.6	12.5	21.5	31.2	25.7	18.8	31.2	25.0
FINE GAUSSIAN	27.1	25.0	26.4	25.0	25.7	6.2	30.6	18.8
MEDIUM GAUSSIAN	29.2	43.8	26.4	25.0	25.0	6.2	29.9	18.8

Tablo 4.22’de Tüm kanallara ait DVM algoritmasının performans sonuçları verilmiştir.

Tablo 4.22. Tüm kanallara ait DVM algoritmasının performans sonuçları

DVM									
Model	Sınıf	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
		Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)
Linear	Sınıf 1	47.05	33.33	50.94	19.44	60.97	13.88	63.41	13.88
	Sınıf 2	52.94	25.0	50.00	33.33	40.00	16.66	28.57	41.66
	Sınıf 3	59.25	10.81	45.90	16.66	50.00	16.66	56.60	02.77
	Sınıf 4	41.66	30.55	46.29	25.00	30.90	36.11	37.50	27.77
Quadratic	Sınıf 1	55.35	30.55	48.21	25.00	59.64	08.33	63.04	27.77
	Sınıf 2	50.00	27.77	51.02	30.55	51.11	38.88	43.54	33.33
	Sınıf 3	57.37	19.44	47.45	22.22	46.66	25.00	57.89	16.66
	Sınıf 4	59.57	38.88	53.84	22.22	46.42	30.55	49.12	30.55
Cubic	Sınıf 1	54.00	19.44	44.00	25.00	54.09	11.11	62.06	25.00
	Sınıf 2	47.27	22.22	46.00	22.22	48.07	33.33	50.00	44.44
	Sınıf 3	44.44	16.66	50.00	16.66	52.72	22.22	63.93	16.66
	Sınıf 4	47.72	36.11	41.07	22.22	48.0	36.11	54.38	38.88
Fine G.	Sınıf 1	62.50	25.0	57.14	27.77	75.60	16.66	35.06	47.22
	Sınıf 2	45.90	30.55	55.55	22.22	67.34	11.11	71.73	30.55
	Sınıf 3	37.31	38.88	50.00	33.33	22.50	52.77	55.55	25.00
	Sınıf 4	73.91	13.88	46.15	22.22	60.41	22.22	80.43	19.44
Medium G.	Sınıf 1	57.40	30.55	51.85	27.77	57.69	16.66	61.40	22.22
	Sınıf 2	49.20	30.55	57.14	27.77	55.10	25.0	72.97	44.44
	Sınıf 3	66.07	13.88	51.78	25.00	53.70	19.44	67.85	13.88
	Sınıf 4	49.09	41.66	47.54	25.00	36.06	38.88	54.71	38.88

Tablo 4.23’te Tüm kanallara ait KA algoritmasına ait sonuçlar verilmiştir.

Tablo 4.23. Tüm kanallara ait KA algoritmasına ait sonuçlar

KA								
Tür	P7		O1		O2		P8	
	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)
Fine Tree	25.0	6.2	25.0	18.8	25.7	18.8	16.7	18.8
Medium Tree	24.3	31.2	25.0	25.0	25.7	18.8	22.9	25.0
Coarse Tree	22.2	37.5	27.1	25.0	25.0	18.8	21.5	18.8

Tablo 4.24'te Tüm kanallara ait KA algoritmasının performans sonuçları verilmiştir.

Tablo 4.24. Tüm kanallara ait KA algoritmasının performans sonuçları

KA									
Model	Sınıf	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
		Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)
Fine Tree	Sınıf 1	49.09	25.0	45.09	36.11	59.25	13.88	32.55	27.77
	Sınıf 2	50.84	16.66	53.57	16.66	46.55	27.77	48.83	08.33
	Sınıf 3	46.66	22.22	50.00	19.44	45.45	33.33	28.33	19.44
	Sınıf 4	54.76	37.14	50.98	27.77	52.94	27.77	43.47	11.11
Medium Tree	Sınıf 1	46.42	25.0	47.05	33.33	59.25	13.88	32.55	27.77
	Sınıf 2	48.33	16.66	53.57	16.66	46.55	27.77	48.83	08.33
	Sınıf 3	47.45	19.40	50.00	16.66	45.45	33.33	28.33	19.44
	Sınıf 4	56.41	36.11	48.97	33.33	52.94	27.77	43.47	11.11
Coarse Tree	Sınıf 1	63.63	11.11	35.48	47.22	40.00	27.77	57.77	19.44
	Sınıf 2	42.18	13.88	58.00	27.77	46.55	30.55	45.59	27.77
	Sınıf 3	50.00	19.44	25.00	19.44	80.0	05.55	34.92	30.55
	Sınıf 4	32.00	44.44	19.66	13.88	44.23	36.11	58.33	13.88

Tablo 4.25'te Tüm kanallara ait DB algoritmasına ait sonuçlar verilmiştir.

Tablo 4.25. Tüm kanallara ait DB algoritmasına ait sonuçlar

DB								
Tür	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)
Gaussian D.B	20.1	25.0	22.9	18.8	18.1	25.0	29.2	12.5
Kernel D.B	20.1	43.8	25.7	37.5	29.2	25.0	24.3	18.8

Tablo 4.26'te Tüm kanallara ait DB algoritmasının performans sonuçları verilmiştir.

Tablo 4.26. Tüm kanallara ait DB algoritmasının performans sonuçları

DB									
Model	Sınıf	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
		Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)
Gaussian	Sınıf 1	64.10	11.11	30.64	38.88	64.86	05.55	80.43	13.88
	Sınıf 2	46.15	13.88	44.23	27.77	11.53	47.22	35.38	52.77
	Sınıf 3	64.10	11.11	63.04	11.11	65.78	02.77	67.85	11.11

	Sınıf 4	18.05	44.44	56.00	13.88	46.51	16.66	45.90	38.88
Kernel	Sınıf 1	44.44	25.00	84.84	25.00	68.62	19.44	72.34	02.77
	Sınıf 2	40.74	19.44	61.70	22.22	40.0	50.0	27.18	52.77
	Sınıf 3	41.50	19.44	58.69	27.77	65.51	11.11	60.37	08.33
	Sınıf 4	46.00	16.66	42.18	27.77	49.15	36.11	41.81	33.33

Tablo 4.27’de Tüm kanallara ait YSA algoritmasına ait sonuçlar verilmiştir.

Tablo 2.27. Tüm kanallara ait YSA algoritmasına ait sonuçlar

YSA								
Gizli Düğüm Sayısı	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)	Accuracy (%)	Test Accuracy (%)
10	19.4	37.5	22.2	31.2	23.6	12.5	25.7	37.5
12	20.1	37.5	22.9	37.5	27.1	18.8	28.5	31.2
14	21.5	18.8	22.2	25.0	29.9	18.8	25.0	50.0
16	22.2	12.5	18.8	18.8	25.7	12.5	22.2	12.5
18	29.2	25.0	20.8	25.0	27.1	6.2	12.5	25.0
20	23.6	37.5	25.0	18.8	24.3	12.5	24.3	31.2
22	18.8	18.8	24.3	37.5	22.2	25.0	26.4	37.5
24	21.5	25.0	23.6	25.0	29.2	12.5	25.7	43.8
26	28.5	25.0	25.7	25.0	27.1	12.5	22.2	31.2
28	24.3	50.0	24.3	18.8	34.0	18.8	17.4	37.5
30	23.6	6.2	24.3	37.5	22.9	12.5	23.6	31.2
32	25.0	31.2	19.4	31.2	26.4	18.8	24.3	25.0
34	22.9	18.8	27.1	18.8	26.4	25.0	21.5	31.2
36	26.4	18.8	26.4	25.0	32.6	12.5	22.2	37.5
38	27.8	31.2	28.5	37.5	24.3	12.5	22.9	37.5
40	20.1	18.8	22.9	12.5	25.7	18.8	24.3	18.8
42	22.9	25.0	27.1	12.5	27.8	18.8	25.0	37.5
44	20.1	31.2	23.6	25.0	31.2	25.0	21.5	18.8
46	29.2	31.2	22.2	18.8	27.1	18.8	23.6	25.0
48	21.5	18.8	25.7	18.8	37.8	18.8	17.4	25.0
50	26.4	18.8	25.0	31.2	29.9	12.5	20.1	37.5

Tablo 4.28’de Tüm kanallara ait YSA algoritmasının performans sonuçları verilmiştir.

Tablo 4.28. Tüm kanallara ait YSA algoritmasının performans sonuçları

YSA									
Gizli Katman Sayısı	Sınıf	Kanal P7		Kanal O1		Kanal O2		Kanal P8	
		Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)	Özgüllük (%)	Duyarlılık (%)
10	Sınıf 1	40.42	25.00	43.33	16.66	49.15	13.88	51.78	22.22
	Sınıf 2	39.21	22.22	51.02	19.44	43.47	38.88	55.10	27.77
	Sınıf 3	45.61	05.55	67.74	30.55	50.90	16.66	48.27	25.00
	Sınıf 4	38.00	25.00	51.06	22.22	48.07	25.00	49.09	27.77
12	Sınıf 1	48.00	13.88	49.12	13.88	58.83	25.00	51.72	30.55
	Sınıf 2	37.03	25.00	52.27	27.77	55.55	25.00	64.0	25.0
	Sınıf 3	37.70	16.66	46.15	25.00	53.70	27.77	57.37	16.66
	Sınıf 4	54.05	25.00	72.72	25.00	47.45	30.55	45.61	41.66
14	Sınıf 1	47.05	19.44	20.75	05.55	67.85	13.88	51.02	30.55
	Sınıf 2	35.18	33.33	63.33	36.11	42.02	38.88	47.36	25.00
	Sınıf 3	44.64	16.66	44.44	22.22	62.26	27.77	44.06	27.77
	Sınıf 4	55.55	16.66	46.0	25.00	55.76	13.88	58.82	16.66
16	Sınıf 1	44.82	16.66	62.85	13.88	47.54	22.22	47.45	11.11
	Sınıf 2	48.14	16.66	56.09	11.11	52.0	30.55	35.29	38.88
	Sınıf 3	43.63	22.22	32.14	25.00	50.90	25.00	50.00	13.88
	Sınıf 4	48.78	33.33	40.90	25.00	53.84	25.00	52.27	25.00
18	Sınıf 1	50.84	33.33	44.06	11.11	55.76	27.77	48.21	22.22
	Sınıf 2	55.35	30.55	57.89	22.22	46.03	27.77	51.11	33.33
	Sınıf 3	53.96	22.22	38.59	22.22	57.14	19.44	52.45	08.33
	Sınıf 4	62.00	30.55	39.21	27.77	52.94	33.33	44.23	33.33
20	Sınıf 1	51.92	19.44	24.40	13.88	45.45	27.77	56.86	25.00
	Sınıf 2	42.10	27.77	46.93	36.11	50.00	22.22	50.00	30.55
	Sınıf 3	41.66	25.00	51.66	13.88	48.00	30.55	46.66	27.77
	Sınıf 4	60.46	22.22	50.0	36.11	52.72	16.66	54.54	22.22
22	Sınıf 1	42.00	16.66	49.20	11.11	50.98	16.66	41.26	33.33
	Sınıf 2	33.33	27.77	54.00	22.22	50.00	22.22	57.14	27.77
	Sınıf 3	42.85	08.33	53.06	25.00	39.68	19.44	54.09	13.88
	Sınıf 4	46.34	22.22	40.38	38.88	45.65	30.55	57.44	30.55
24	Sınıf 1	34.42	27.77	49.15	13.88	62.50	19.44	45.61	30.55
	Sınıf 2	47.05	19.44	47.91	30.55	53.70	36.11	58.69	27.77
	Sınıf 3	43.63	19.44	41.37	27.77	63.63	19.44	46.96	16.66
	Sınıf 4	58.53	19.44	55.31	22.22	42.85	41.66	55.10	27.77
26	Sınıf 1	49.18	30.55	55.93	11.11	58.82	25.00	44.64	19.44
	Sınıf 2	51.72	30.55	48.97	36.11	54.54	25.00	54.54	22.22
	Sınıf 3	52.54	27.77	89.65	30.55	52.63	25.00	47.36	13.88
	Sınıf 4	66.66	25.00	50.90	25.00	50.0	33.33	43.47	33.33
28	Sınıf 1	42.18	22.22	50.90	19.44	61.29	30.55	35.55	25.00
	Sınıf 2	50.00	22.22	54.16	25.00	64.40	30.55	38.29	19.44
	Sınıf 3	51.85	19.44	47.45	19.44	66.66	30.55	66.66	08.33
	Sınıf 4	54.76	33.33	44.23	33.33	51.56	44.44	40.42	16.66

30	Sınıf 1	45.76	19.44	43.93	16.66	50.00	22.22	46.42	22.22
	Sınıf 2	47.27	22.22	40.32	27.77	45.65	33.33	53.06	22.22
	Sınıf 3	46.55	19.44	50.84	13.88	49.12	13.88	49.05	22.22
	Sınıf 4	55.00	33.33	48.83	38.88	43.85	22.22	48.00	27.77
32	Sınıf 1	44.26	25.00	42.10	11.11	49.12	27.77	50.00	19.44
	Sınıf 2	42.7	27.77	40.00	27.77	52.72	25.00	53.06	25.00
	Sınıf 3	53.70	19.44	41.81	13.88	57.69	22.22	48.27	19.44
	Sınıf 4	56.52	27.77	44.18	25.00	48.21	30.55	45.09	33.33
34	Sınıf 1	43.33	19.44	48.52	16.66	58.92	13.88	46.29	16.66
	Sınıf 2	42.85	25.00	59.57	30.55	53.84	27.77	43.13	25.00
	Sınıf 3	47.05	19.44	56.60	25.00	43.39	41.66	52.83	08.33
	Sınıf 4	56.09	27.77	48.14	36.11	50.84	22.22	36.00	36.11
36	Sınıf 1	55.55	22.22	51.56	13.88	63.79	27.77	47.05	22.22
	Sınıf 2	45.16	27.77	56.00	27.77	55.00	38.88	43.47	33.33
	Sınıf 3	55.55	22.22	47.27	33.33	64.91	27.77	47.45	11.11
	Sınıf 4	52.00	33.33	52.94	30.55	53.96	36.11	46.15	22.22
38	Sınıf 1	44.44	33.33	48.48	25.00	47.45	19.44	50.00	16.66
	Sınıf 2	53.44	25.00	55.76	33.33	56.52	25.00	46.80	30.55
	Sınıf 3	57.14	22.22	57.14	25.00	44.82	25.00	49.18	08.33
	Sınıf 4	61.70	30.55	57.69	30.55	49.01	27.77	41.66	36.11
40	Sınıf 1	44.00	19.44	41.42	11.11	48.21	27.77	45.45	27.77
	Sınıf 2	38.18	22.22	57.14	25.00	53.84	25.00	47.16	27.77
	Sınıf 3	48.07	11.11	46.15	25.00	55.76	22.22	51.66	11.11
	Sınıf 4	42.22	27.77	47.82	30.55	46.55	27.77	52.17	30.55
42	Sınıf 1	41.81	16.66	55.00	16.66	57.40	25.00	60.86	22.22
	Sınıf 2	47.82	19.44	61.70	27.77	59.61	25.00	48.00	33.33
	Sınıf 3	40.35	16.66	46.66	30.55	49.12	33.33	44.77	16.66
	Sınıf 4	43.18	27.77	49.09	33.33	49.18	27.77	49.05	27.77
44	Sınıf 1	39.21	25.00	43.33	22.22	57.62	30.55	47.16	16.66
	Sınıf 2	41.07	16.66	45.09	30.55	61.11	33.33	44.00	25.00
	Sınıf 3	44.89	19.44	54.54	11.11	57.62	30.55	45.09	22.22
	Sınıf 4	47.82	19.44	50.00	30.55	54.83	30.55	44.23	22.22
46	Sınıf 1	53.84	19.44	43.07	11.11	53.33	19.44	50.0	19.44
	Sınıf 2	93.33	38.88	46.93	25.00	62.00	22.22	46.93	30.55
	Sınıf 3	60.71	22.22	49.05	16.66	51.78	27.77	50.87	13.88
	Sınıf 4	59.18	36.11	46.34	36.11	44.64	38.88	44.23	30.55
48	Sınıf 1	48.07	16.66	53.33	13.88	58.62	16.66	35.29	19.44
	Sınıf 2	45.59	22.22	47.16	33.33	55.10	36.11	42.85	19.44
	Sınıf 3	73.52	16.66	51.85	25.00	49.18	27.77	40.38	11.11
	Sınıf 4	48.78	30.55	50.98	30.55	51.78	30.55	36.73	19.44
50	Sınıf 1	48.27	27.77	50.81	13.88	59.25	30.55	43.75	22.22
	Sınıf 2	56.60	22.22	45.28	33.33	54.09	27.77	40.81	25.00
	Sınıf 3	48.38	22.22	52.83	22.22	53.33	30.55	47.91	16.66
	Sınıf 4	55.31	33.33	51.02	30.55	58.18	30.55	46.93	16.66

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada oluşturulan bütün algoritmaların analizleri MATLAB programı kullanılarak incelenmiştir. DHGUP tabanlı BBA çalışmalarına katkıda bulunmak ve birden fazla yöntem geliştirmek için üç farklı sinyal analizi yapılmış ve sınıflandırma aşaması için hazırlık yapılmıştır. Bu doğrultuda, üç farklı sinyal analizi yöntemi uygulanmış ve sınıflandırma aşaması için hazırlık yapılmıştır. Uygulanan sinyal analizi yöntemleri sırasıyla filtreleme, Fourier Dönüşümü (FFT) ve Welch Metodu'dur. Filtreleme yöntemi, belirli frekans aralıklarını geçiren veya geçirmeyen sinyallerin işlenmesine olanak tanırken, FFT sinyalin frekans spektrumunu hızlı ve etkili bir şekilde analiz eder. Welch Metodu ise sinyalin spektral analizini iyileştirerek daha güvenilir PSD tahminleri sağlar.

Sınıflandırma aşamasında FFT yöntemi ile elde edilen PSD sinyalleri kullanılmıştır ve bu sinyallerden elde edilen 17 özellik, çeşitli sınıflayıcı algoritmaların performansını değerlendirmek için kullanılmıştır. İkili Sınıflama algoritmalarının performans analizinde en yüksek doğruluk oranı %63.9 KA algoritması tarafından sağlanmıştır PCA uygulamasının etkisi, her algoritma için farklı sonuçlar ortaya koymuş; özellikle DB algoritması için performansı artırmış fakat SVM ve KA algoritmalarında PCA uygulanması doğruluk oranlarını düşürmüştür. Yapay Sinir Ağları (YSA) ise gizli düğüm sayısına bağlı olarak değişen performanslar sergilemiştir; 14 gizli düğüm sayısı ile %57.6 doğruluk oranı elde edilmiştir.

Sonuç olarak, Genel olarak, SVM en yüksek doğruluk oranını sağlarken, Karar Ağaçları da belirli bir başarı göstermiştir. PCA uygulaması, özellikle DB algoritmasının performansını artırmada etkili olmuştur. Bu çalışma, sinyal işleme ve sınıflama yöntemlerinin kombinasyonlarının etkinliğini vurgulamakta ve PCA gibi tekniklerin algoritma performansları üzerindeki etkilerini detaylı bir şekilde incelemektedir. Gelecekte, farklı veri setleri ve sınıflayıcı algoritmalarla yapılacak çalışmalarda; daha temiz bir EEG kaydı alınarak ve farklı özellikler belirlenerek ve belirlenen özelliklerden PCA ile seçim yapılarak bu tekniklerin genel başarısı ve sınıflama doğruluğu daha da artırılabilir.

Çizelge 5.1’de BBA ile yapılan örnek çalışmalar ve doğruluk oranları verilmiştir.

Çizelge 5.1. Örnek çalışma ve doğruluklar

Çalışmayı Yapan	Kullanılan Algoritmalar	Veri Seti	Denek Sayısı	Sınıflandırma Doğruluğu
Aydemir ve ark. (2011)	DAA	Açık erişim veri seti	1 Kadın	91,4%
Liu ve ark. (2012)	DVM	Deney veri seti	1 Kadın 2 Erkek	82,1%
Kaya ve ark. (2017)	DVM	Deney veri seti	3 Kişi	80%
Tosun ve ark. (2018)	DVM	Açık erişim veri seti	1 Erkek	99,99%
Karadağ ve ark. (2020)	YSA	Açık erişim veri seti	1 Kadın	100%
Değirmenci ve ark. (2021)	TOPLULUK ÖĞRENME	Açık erişim veri seti	3 Erkek 1 Kadın	47,6%
Kumar ve ark. (2022)	YSA	Deney veri seti	-	90%
Sınıflama Çalışması-1	KA	Deney veri seti	4 Kadın 4 Erkek	63,9%
Sınıflama Çalışması-2	DVM	Deney veri seti	4 Kadın 4 Erkek	31,20%

Sonuç olarak, tezde gerçekleştirilen sınıflama çalışmaları literatürdeki benzer araştırmalarla karşılaştırıldığında ortalama bir performans sergilemiştir. İkili sınıflama KA algoritmasıyla elde edilen %63,90 doğruluk oranı tatmin edici olsa da dörtlü sınıflandırma algoritmasının %31,20'lik performansı iyileştirilmesi gereken bir alandır. Gelecekteki çalışmalarda, model optimizasyonu, daha karmaşık algoritmaların kullanımı ve veri ön işleme tekniklerine odaklanmak, sınıflandırma doğruluğunu artırmak için kritik adımlar olacaktır. Bu sayede, elde edilen sonuçlar daha rekabetçi hale gelebilir ve daha yüksek doğruluk oranlarına ulaşılabilir.

KAYNAKLAR

- Albano, F., Longobradi T., Maldonato N. M., Moretto, E., Orco, S.D., Sarno, A. D., Sperandeo, R., Tedesco, Y., 2018, Co-regulation of the voice between patient and therapist in psychotherapy: machine learning for enhancing the synchronization of the experience of anger emotion, *9th IEEE International Conference on Cognitive Infocommunications, Budapest*, 22-44.
- Atkinson, J., Campos, D., 2016, Improving BCI-based emotion recognition by combining EEG feature selection and Kernel classifiers R, *Expert Syst. Appl.*, vol. 47, pp. 35–41.
- Aydemir, Ö., Kayıkçılı, T., 2011, Sağ/Sol El Hareketi Düşünümlere Kaydedilmiş EEG İşaretlerinin Fourier Dönüşümü Esaslı Öznitelikler Kullanarak Sınıflandırılması, *IEEE 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*
- Arora, Y., Gupta, K., S., 2024, Intuitionistic fuzzy twin proximal SVM with fuzzy hyperplane and its application in EEG signal classification, Indian Institute of Technology Roorkee, Roorkee 247667, India.
- Bevilacqua, V., Tattoli, G., Buongiorno, D., 2014, A novel BCI-SSVEP based approach for control of walking in Virtual Environment using a Convolutional Neural Network, *International Joint Conference on Neural Networks (IJCNN)*, Beijing-China, 6-11.
- Carvalho, S., N., Costaa T., B., S., Uribea L. F.S, Sorianoc, D., C., Yaredb , G., F., G., Coradine, L., C., Attux, R., 2015, “Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs”, *Biomedical Signal Processing and Control*, 21, 34-42.
- Chan, A., Dascalu, S., 2017, Using Brain Computer Interface Technology in Connection with Google Street View, *2017 21st International Conference on Control Systems and Computer Science (CSCS)*, Bucharest
- Chaudhuri, B., B., Bhattacharya, U., 2000, Efficient training and improved performance of multilayer perceptron in pattern classification, *Neurocomputing*, 34 (2000), 11–27.
- Çağlayan, O., Arslan, R. B., 2013,” Robotic Arm Control using Brain Computer Interface”, *16th National Biomedical Engineering Meeting, Innsbruck/Austria*,
- Değirmenci, M., Sayılğan, E., İşler, Y., 2021, Evaluation of Wigner-Ville Distribution Features to Estimate Steady-State Visual Evoked Potentials' Stimulation Frequency, *Akıllı Sistemler ve Uygulamaları Dergisi* 4(2), 133-136.
- Douibi, K., Bars, Lee, S., Lemontey, A., Nag, L., Balp, R., Breda, G., 2021, “o and EEG-Based BCI Applications for Industry 4.0: Challenges and Possible Applications”, *rontiers in Human Neuroscience*, τ. 15,

- Do, A., H., Wang, P., T., King, C., E., Abiri, A., and Nenadic, Z., 2011, "Brain-computer interface controlled functional electrical stimulation system for ankle movement," *Journal of neuroengineering and rehabilitation*, vol. 8, no. 1, 49.
- Erkan, E., Akbaba, M. 2018, A study on performance increasing in SSVEP based BCI application, *Engineering Science and Technology, An International J Journal*,3,421-427.
- Gao, Y., Lee, H., J., Mehmood, R., M., 2015, Deep learning of EEG signals for emotion recognition, *IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, Turin-Italy
- Haltaş K., Ergüzen, A., Erdal, E. , Lüy M., 2018, Yardımcı Sistem Olarak BCI ve EEG Sinyallerinin BCI Sistemlerde Kullanım Şekilleri, *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*,3:72-79.
- Haykin, S., 1994, *Neural Networks: A Comprehensive Foundation*, Macmillan, New York.
- Huang, Z., Wang, M., 2021, "A review of electroencephalogram signal processing methods for brain-controlled robots", *Cognitive Robotics*,111-124.
- Ilyas, M. Z., Saad, P., & Ahmad, M. I., 2015, A Survey of Analysis and Classification. of EEG Signals for Brain-Computer Interfaces. *2nd International Conference on Biomedical Engineering (ICoBE)*., Penang.
- Kaminski, B., Jakubczyk, M., 2017, A framework for sensitivity analysis of decision trees *SGH Warsaw School of Economics, Al. Niepodległo'sci* 162, 02-554 Warsaw, Poland.
- Karadağ, K., Tenekeci, M.E., Gümüştü, A., 2020, Yapay sinir ağları kullanılarak imleç yönü tespiti, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, Niğde,172-179.
- Karakoyun, M., Hacıbeyoğlu, M., 2014, Biyomedikal Veri Kümeleri ile Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması, *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 16(48),30-41, İzmir.
- Kaur, T., E., Prof. Singh, B., 2017, Brain Computer Interface: A Review, *International Research Journal of Engineering and Technology (IRJET)*, Vol -04, Issue 04,
- Kaya, M., Cömert, M., Mıshchenko, Y., 2017, Beyin Bilgisayar Arayüzü İçin Dvm Makine Öğrenme Yöntemi Kullanılarak Eeg Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti, *Tübvav Bilim Dergisi*, 10(3), 1-20.
- Kimmatkar, V., N., Babu, Vijaya, B., 2017, Initial Analysis of Brain EEG Signal for Mental State Detection of Human Being, *International Conference on Trends in Electronics and Informatics (ICEI)*, Tirunelveli- India.

- Koyaş, E., S., M., Erdoğan, A., Çetin M. ve Patoğlu, V., 2013, BBA Tabanlı üst uzuv rehabilitasyon sistem'in sonsal olasılık değerleri kullanılarak kontrolü, *IEEE Signal Processing and Communications Applications Conference (SIU)*.
- Kumar, P., R., SaiCharan, K., Vandana, S., S., Tejaswi, D., Janapati, R., Desai, U., 2022 Classification of SSVEP Signals using Neural Networks for BCI Applications, *2022 International Conference on Intelligent Controller and Computing for Smart Power*, Hyderabad-India.
- Liu, C., Wang, H., Pu, H., Zhang, Y., and Zou, L., 2012, "EEG feature extraction and pattern recognition during right and left hands motor imagery in brain-computer interface, in *2012 5th International Conference on BioMedical Engineering and Informatics*, Chongqing, 506-510.
- Maracine, M., Radu, A., Ciobanu, V., & Popescu, N., 2017, Brain Computer Interface Architectures and Classification Approaches, *21st International Conference on Control Systems and Computer Science (CSCS)*, Bucharest, 217-222.
- Moschona D., 2020, An Affective Service based on Multi-Modal Emotion Recognition, using EEG enabled Emotion Tracking and Speech Emotion Recognition, *IEEE International Conference on Consumer Electronics*, Seoul
- Oktavia, Y., N., Pane, S., E., Wibawa, D., A., Punomo, H., M., 2019, Human Emotion Classification Based on EEG Signals Using Naïve Bayes Method, *2019 International Seminar on Application for Technology of Information and Communication*, Semarang, Indonesia.
- Oralhan, Z., 2016, "Durağan Hal Görsel Uyarı Tabanlı Beyin Bilgisayar Arayüzü İçin Optimum Uyarı Özelliklerinin Belirlenmesi ve Gerçeklenmesi", Doktora Tezi, *Elektrik- Elektronik Mühendisliği Anabilim Dalı*, Kayseri.
- Özerdem, M., S., Polat, H., 2017 "Emotion recognition based on EEG features in movie clips with channel selection", *Brain Informatics*, 3, 241–252
- Öztürk, N., Yılmaz, B., 2018, "Beyin Bilgisayar Arayüzü Uygulamaları için Dinlenme, Harekete Niyet ve Hareket Ayırma" *Biyomedikal Mühendisliği ve Uygulamaları*, 1:11, sf.651
- Ramirez, R., Vamvakousis, Z., 2012, Detecting Emotion from EEG Signals Using the Emotive Epoc Device, *Lect. Notes Comput. Sci.*, 175–184.
- Sözer, A., T., Fidan, C., B., 2014, Durağan Hal Görsel Uyarılmış Potansiyel Temelli Beyin Bilgisayar Arayüzleri, *Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, Bursa.
- Tosun, M., Erginli, M., Kasım, Ö., Uğraş, B., Tanrıverdi., Ş., Kavak, T., 2018, EEG Verileri Kullanılarak Fiziksel El Hareketleri ve Bu Hareketlerin Hayalinin Yapay Sinir Ağları ile Sınıflandırılması, *Sakarya University Journal Of Computer And Information Sciences*, Vol. 1, No. 2, A2.

- Uddin, P., Mamun, A., Hossain, A., 2020, PCA-based Feature Reduction for Hyperspectral Remote Sensing Image Classification, *IETE Technical Review*, 38:4, 377-396.
- Übeyli, D., E., 2009, Analysis of EEG signals by implementing eigenvector methods/recurrent neural networks, *Digital Signal Processing* 19, 134-143, *Ankara*.
- Yıldız, K., Çamurcu, Y., Doğan, B., 2010, Veri Madenciliğinde Temel Bileşenler Analizi ve Negatifsiz Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi, *Akademik Bilişim '10- XII. Akademik Bilişim Konferansı, Muğla*.
- Wang, J., Wang, M., 2021, Review of the emotional feature extraction and classification using EEG signals, *Cognitive Robotics, China*, 29-40.

