

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**EL İLE KAVRAMA HAREKETİNİN DÜŞÜNÜLMESİ SIRASINDA KAYDEDİLEN EEG
İŞARETLERİNİN PSO TABANLI SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisi Osman Kerem ATEŞ

**NİSAN 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**EL İLE KAVRAMA HAREKETİNİN DÜŞÜNÜLMESİ SIRASINDA KAYDEDİLEN EEG
İŞARETLERİNİN PSO TABANLI SINIFLANDIRILMASI**

Elektrik Elektronik Mühendisi Osman Kerem ATEŞ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
" ELEKTRONİK YÜKSEK MÜHENDİSİ "
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 18 / 03 / 2021

Tezin Savunma Tarihi : 05 / 04 / 2021

Tez Danışmanı : Doç. Dr. Önder AYDEMİR

Trabzon 2021

ÖNSÖZ

Bu tez çalışması, Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalı, Elektronik Bilim Dalı Yüksek Lisans Programı'nda hazırlanmıştır. Yapılan tez çalışmasında, Beyin Bilgisayar Arayüzü sistemlerinin geliştirilmesine yönelik sağ ve sol elin kavramayı deneme hareketinin hayaliyle kaydedilmiş EEG işaretlerinin sınıflandırılması işlemi gerçekleştirilmiştir.

Tez çalışma sürecinde değerli bilgi, birikim ve deneyimleri ile bana ışık tutan danışman hocam sayın Doç. Dr. Önder AYDEMİR'e desteklerinden dolayı teşekkürlerimi sunarım.

Mezunu olmaktan her zaman gurur duyduğum ODTÜ'ye ve lisans eğitimim süresince nitelikli bir akademik eğitim sağlayarak gelişimimde büyük katkısı olan sayın hocalarıma çok teşekkür ederim.

Çalışmanın başladığı ilk günden son güne kadar sabır ve destekleriyle yanımda olan değerli eşim Aslıhan ATEŞ'e, vakitlerinden ödünç aldığım güzel evlatlarım Kağan Ali ve Asrem Ada'ya ve sevgili aileme ayrıca teşekkür ederim.

Tez çalışmamın yapılacak çalışmalara katkı sağlamasını temenni ederim.

Osman Kerem ATEŞ

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “El ile Kavrama Hareketinin Düşünülmesi Sırasında Kaydedilen EEG İşaretlerinin PSO Tabanlı Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Önder AYDEMİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 05/04/2021

Osman Kerem ATEŞ

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. İnsanda Sinir Sistemi	1
1.3. Aksiyon Potansiyeli	2
1.4. İnsan Beyninin Yapısı	3
1.5. Elektroensefalografi.....	4
1.5.1. EEG Sinyal Özellikleri	5
1.5.2. EEG Elektrotları	5
1.6. Beyin Bilgisayar Arayüzü (BBA)	6
1.7. Literatür Taraması	9
2. YAPILAN ÇALIŞMALAR.....	15
2.1.1. Materyal.....	15
2.1.2. Deney Protokolü	15
2.1.3. Veri Edinme.....	16
2.1.4. Deney Katılımcıları	17
2.2. Literatürde Aynı Veri Seti ile Yapılan Çalışmalar	18
2.3. Tezin Amacı ve Kapsamı	21
2.4. Elektrot Seçimi	22
2.5. Öznitelik Çıkarma Yöntemleri	22
2.5.1. Hjorth Parametreleri	22

2.5.2.	Bant Güçleri.....	23
2.5.3.	Hilbert Dönüşümü	24
2.5.4.	Hızlı Walsh-Hadamard Dönüşümü	24
2.5.5.	Willison Genliği	25
2.5.6.	Modifiye Sıfır Geçiş Sayısı	25
2.5.7.	Modifiye Mutlak Değer Ortalama	26
2.6.	Parçacık Sürü Optimizasyonu	26
2.7.	Sınıflandırma Yöntemleri	29
2.7.1.	k En Yakın Komşuluk Yöntemi (k-EYK)	29
2.7.2.	Destek Vektör Makineleri Yöntemi (DVM)	30
2.7.3.	Doğrusal Ayırma Analizi Yöntemi (DAA)	31
2.7.4.	Torbalama Karar Ağaçları (TKA)	32
2.8.	Kullanılan Yöntemin Akış Diyagramı.....	33
3.	BULGULAR	37
3.1.	Katılımcı 1 İçin Elde Edilen Bulgular	37
3.2.	Katılımcı 2 İçin Elde Edilen Bulgular	39
3.3.	Katılımcı 3 İçin Elde Edilen Bulgular	41
3.4.	Katılımcı 4 İçin Elde Edilen Bulgular	42
3.5.	Katılımcı 5 İçin Elde Edilen Bulgular	44
3.6.	Katılımcı 6 İçin Elde Edilen Bulgular	46
3.7.	Katılımcı 7 İçin Elde Edilen Bulgular	47
3.8.	Katılımcı 8 İçin Elde Edilen Bulgular	49
3.9.	Katılımcı 9 İçin Elde Edilen Bulgular	51
3.10.	Katılımcı 10 İçin Elde Edilen Bulgular	52
4.	SONUÇLAR VE TARTIŞMA	55
5.	ÖNERİLER	60
6.	KAYNAKLAR.....	61
7.	EKLER	688
ÖZGEÇMİŞ		

Yüksek Lisans Tezi

ÖZET

EL İLE KAVRAMA HAREKETİNİN DÜŞÜNÜLMESİ SIRASINDA KAYDEDİLEN EEG
İŞARETLERİNİN PSO TABANLI SINIFLANDIRILMASI

Osman Kerem ATEŞ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Önder AYDEMİR
2021, 67 Sayfa, 6 Sayfa Ek

Beyin bilgisayar arayüzü (BBA) uygulamalarının önemli amaçlarından biri de engelli ve hasta bireyler için iyileştirme veya hayatlarını kolaylaştıracak yenilikçi çözümlerin araştırılmasıdır. Bundaki motivasyonlardan biri de felç veya kaza gibi durumlarla motor sinirlerinin zarar görmesi, insanların kas ve hareket kabiliyetlerini kısıtlasa da beyin düşünsel görevlerini yerine getirebilmesidir. Farklı tarzda temel düşünsel görevlerin otomatik çözülmesi bu tarz rahatsızlıkları olan kişiler için rehabilitasyon ve robot destekli teknolojilerine dayalı BBA sistemlerinin geliştirilmesine büyük fayda sağlayacaktır. Bu yüzden sağlıklı bireyler yerine hasta ve engelli bireylerden alınan veriler başarılı BBA uygulamaları için daha yol gösterici olacaktır. Bu tez çalışmasında da el hareket ve fonksiyon yetersizliği olan 10 gönüllü katılımcının sağ ve sol elinin kavramayı deneme hareketlerinin düşünülmesiyle kaydedilmiş ve ayrıca Clinical BCI Challenge WCCI 2020 yarışmasında da kullanılmış olan Elektroensefalografi (EEG) verileri üzerinde çalışılmıştır.

Yüksek sınıflandırma başarımları amacıyla etkin elektrotlar ve öznitelikler önerilen yöntemle seçilmiştir. Öznitelik seçim aşamasında Parçacık Sürü Optimizasyonu (PSO) algoritması kullanılmıştır. Seçilen etkin parametreler sayesinde sağ ve sol elin hareketinin hayalinin ayrımı k-en yakın komşuluk, doğrusal ayırma analizi, destek vektör makineleri ve torbalama karar ağaçları algoritmaları ile sırasıyla %84.32, %80.25, %77.25 ve %83.08 oranında başarımlar elde edilerek sağlanmıştır.

Anahtar Kelimeler: Elektroensefalografi, Hareket hayali, Parçacık sürü optimizasyonu, Öznitelik seçimi, Sınıflandırma

Master Thesis

SUMMARY

PSO BASED CLASSIFICATION OF EEG SIGNALS RECORDED DURING IMAGERY OF HAND GRASP MOVEMENT

Osman Kerem ATEŞ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program

Supervisor: Assoc. Prof. Önder AYDEMİR

2021, 67 Pages, 6 Pages Appendix

One of the important objective of the Brain Computer Interface (BCI) systems is to search innovative solutions like rehabilitation scenario for disabled or patient subjects. People who have stroke or have an accident still can provide accurately some imagery movements. Automated decoding of these imagery movements from brain signals will be very helpful for rehabilitation and the development of robot-assisted technologies based on BCI systems. Then, work on the patient's data instead of using healthy subject's data can be more meaningful for these interfaces. In this thesis work, a dataset that of EEG brain imaging data for 10 stroke patients having hand functional disability was used. This current data was also used in Clinical BCI Challenge WCCI 2020 competition.

With proposed method, the effective electrodes and features were selected for high classification accuracy purpose. In feature selection stage, the Particle Swarm Optimization (PSO) algorithm was used. Through selected effective parameters, discrimination of imagery of right and left hand movement was done with 84.32%, 80.25%, 77.25% and 83.08% accuracy rate by using respectively k-nearest neighbors, linear discriminant analysis, support vector machines and bagging decision tree algorithms.

Key Words: Electroencephalography, Imagery movement, Particle swarm optimization, feature selection, classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Sinir hücresinin yapısı	2
Şekil 2. Aksiyon potansiyeli	3
Şekil 3. Beynin beş ana lobu	4
Şekil 4. 10-20 sistemine göre elektrotların yerleşimi	6
Şekil 5. Beyin bilgisayar arayüzü sistemi.....	8
Şekil 6. Bir EEG denemesinin kaydedilmesi süreci	16
Şekil 7. Deney aşamasından bir görüntü	16
Şekil 8. Deneyde kullanılan elektrotların bağlanma şekli	17
Şekil 9. PSO tabanlı öznelik seçim algoritması	28
Şekil 10. k en yakın komşuluk yöntemi ile sınıflandırma	29
Şekil 11. Destek vektör makineleri yöntemi ile sınıflandırma	31
Şekil 12. Topluluk öğrenmesi yöntemi	32
Şekil 13. Kullanılan yöntemin akış diyagramı	33
Şekil 14. Katılımcı 1 için sınıflandırma doğrulukları.....	38
Şekil 15. Katılımcı 1 için test ve eğitim verisinden çıkarılan etkin öznelikler	38
Şekil 16. Katılımcı 2 için sınıflandırma doğrulukları.....	39
Şekil 17. Katılımcı 2 için test ve eğitim verisinden çıkarılan etkin öznelikler	40
Şekil 18. Katılımcı 3 için sınıflandırma doğrulukları.....	41
Şekil 19. Katılımcı 3 için test ve eğitim verisinden çıkarılan etkin öznelikler	42
Şekil 20. Katılımcı 4 için sınıflandırma doğrulukları.....	43
Şekil 21. Katılımcı 4 için test ve eğitim verisinden çıkarılan etkin öznelikler	43
Şekil 22. Katılımcı 5 için sınıflandırma doğrulukları.....	44
Şekil 23. Katılımcı 5 için test ve eğitim verisinden çıkarılan etkin öznelikler	45
Şekil 24. Katılımcı 6 için sınıflandırma doğrulukları.....	46
Şekil 25. Katılımcı 6 için test ve eğitim verisinden çıkarılan etkin öznelikler	47
Şekil 26. Katılımcı 7 için sınıflandırma doğrulukları.....	48
Şekil 27. Katılımcı 7 için test ve eğitim verisinden çıkarılan etkin öznelikler	48
Şekil 28. Katılımcı 8 için sınıflandırma doğrulukları.....	49
Şekil 29. Katılımcı 8 için test ve eğitim verisinden çıkarılan etkin öznelikler	50

Şekil 30. Katılımcı 9 için sınıflandırma doğrulukları.....	51
Şekil 31. Katılımcı 9 için test ve eğitim verisinden çıkarılan etkin öznitelikler	52
Şekil 32. Katılımcı 10 için sınıflandırma doğrulukları.....	53
Şekil 33. Katılımcı 10 için test ve eğitim verisinden çıkarılan etkin öznitelikler	53



TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Elektrotların adlarının numaralandırılması	17
Tablo 2. Hastaların istatistikleri	18
Tablo 3. Chowdhury ve diğerlerinin elde ettiği SD sonuçları	18
Tablo 4. Raza ve diğerlerinin elde ettiği SD sonuçları	19
Tablo 5. Ateş ve Aydemir'in elde ettiği SD sonuçları	20
Tablo 6. WCCI Competition 2020 yarışmasının 1. uygulama sonuçları	20
Tablo 7. WCCI Competition 2020 yarışmasının 2. uygulama sonuçları	21
Tablo 8. WCCI Competition 2020 yarışmasının toplam değerlendirme sonuçları	21
Tablo 9. Öznitelik çıkarım yöntemlerinin numaralandırılması	35
Tablo 10. Katılımcı 1 için DAA sınıflandırıcısının karışıklık matrisi	39
Tablo 11. Katılımcı 2 için DAA sınıflandırıcısının karışıklık matrisi	40
Tablo 12. Katılımcı 3 için k-EYK sınıflandırıcısının karışıklık matrisi	42
Tablo 13. Katılımcı 4 için k-EYK sınıflandırıcısının karışıklık matrisi	44
Tablo 14. Katılımcı 5 için TKA sınıflandırıcısının karışıklık matrisi	45
Tablo 15. Katılımcı 6 için TKA sınıflandırıcısının karışıklık matrisi	47
Tablo 16. Katılımcı 7 için TKA sınıflandırıcısının karışıklık matrisi	49
Tablo 17. Katılımcı 8 için k-EYK sınıflandırıcısının karışıklık matrisi	50
Tablo 18. Katılımcı 9 için TKA sınıflandırıcısının karışıklık matrisi	52
Tablo 19. Katılımcı 10 için TKA sınıflandırıcısının karışıklık matrisi	54
Tablo 20. Tüm katılımcılar için sınıflandırıcılara göre ortalama SD sonuçları	56
Tablo 21. Veri Seti ile yapılan çalışmalar ve ortalama SD sonuçları	57
Tablo 22. Yapılan çalışmanın benzer çalışmalar ile kıyaslanması	58
Ek Tablo 1. k-EYK yöntemi için etkin ve tüm öznitelikler ile SD sonuçları	68
Ek Tablo 2. DAA yöntemi için etkin ve tüm öznitelikler ile SD sonuçları	68
Ek Tablo 3. DVM yöntemi için etkin ve tüm öznitelikler ile SD sonuçları	69
Ek Tablo 4. TKA için etkin ve tüm öznitelikler ile SD sonuçları	69
Ek Tablo 5. k-EYK yöntemi için tüm elektrotların SD sonuçları	70

Ek Tablo 6. DAA yöntemi için tüm elektrotların SD sonuçları	71
Ek Tablo 7. DVM yöntemi için tüm elektrotların SD sonuçları	72
Ek Tablo 8. TKA yöntemi için tüm elektrotların SD sonuçları.....	73



SEMBOLLER DİZİNİ

ALS	: Amyotrofik Lateral Skleroz
AR	: Özbağlaşım
BBA	: Beyin Bilgisayar Arayüzü
BPNN	: Geri Yayımlı Sinir Ağı
CNN	: Evrişimli Sinir Ağları
CSP	: Ortak Uzamsal Örüntü
ÇKA	: Çok Katmanlı Algılayıcı
DAA	: Doğrusal Ayırma Analizi
DNN	: Derin Sinir Ağı
DVM	: Destek Vektör Makineleri
ECoG	: Elektrokortikografi
EEG	: Elektroensefalografi
FLDA	: Fisher doğrusal ayırma analizi
fMRI	: Fonksiyonel Manyetik Rezonans Görüntüleme
fNIRS	: Fonksiyonel Yakın-kızılötesi Spektroskopisi
GA	: Genetik Algoritma
GNB	: Gaussian Naive Bayes
HSVM	: Hiyerarşik Destek Vektör Makinaları
INR	: İntrakortikal Nöron Kaydı
KAA	: Karesel Ayırma Analizi
k-EYK	: k-En Yakın Komşuluk
MEG	: Magnetoensefalografi
MI	: Motor Hayali
MMDO	: Modifiye Mutlak Değer Ortalama
ms	: Milisaniye
MSGs	: Modifiye Sıfır Geçiş Sayısı
mV	: Milivolt
PNN	: Olasılıksal Sinir Ağı
PSO	: Parçacık Sürü Optimizasyonu
RMS	: Karekök Ortalama

RR	: Ridge Regresyon
SF	: Uzamsal Filtre
SP	: Serebral Palsi
TBA	: Temel Bileşen Analizi
TKA	: Torbalama Karar Ağaçları
WG	: Willison Genliği
YSA	: Yapay Sinir Ağları
α	: Alfa dalgası
β	: Beta dalgası
θ	: Teta dalgası
δ	: Delta Dalgası

1. GENEL BİLGİLER

1.1. Giriş

İnsanların günlük yaşamlarında dış çevreyle iletişimde bulunmaları sosyal yaşamları açısından büyük önem arz etmektedir. Fakat bazı insanlar bu iletişimi gerçekleştirirde zorluklar çekebilir yani görerek, duyarak, düşünerek veya hareket etmek isteseler de bu etkileşimleri sağlayamayabilirler. Karşılaştıkları hastalık veya kazalar sonucu kişilerde oluşan felç ve uzuv kaybı gibi durumlar bu bireylerin iletişim ve hareketlerini ciddi oranda kısıtlar. Yaşanan zorluklar hareketlerini kısıtlasa bile zihinsel olarak bu hareketlerin hayalini beyinlerinde canlandırabilirler. Bu durumda olan insanların yaşam standartlarının iyileştirilmesi için yapılan çalışmalar teknolojinin gelişmesine paralel olarak artarken çözüm olarak üretilen ve beyin bilgisayar arayüzü (BBA) adı verilen uygulamaların önemi de git gide artmaktadır. BBA sistemlerinin geliştirilmesindeki en büyük sebeplerden biri bu gibi iletişim güçlüğü çeken ve uyarılara karşı herhangi bir tepki veremeyen insanların beyin aktivitelerine bağlı iletişim kurularak robot-destekli tedavilerin veya rehabilitasyon amacıyla yapılacak çalışmalara katkı sağlayabilmektir.


BBA çalışmalarında gerekli olan beyin aktivitelerinin ölçümü için mevcut birçok yöntem vardır. İnvazif ve invazif olmayan olarak ikiye ayrılan yöntemler için; invazif olanlar da cerrahi müdahale ile beyin içerisine elektrot yerleştirirken, invazif olmayanlar da ise kafa derisine yerleştirilmiş elektrotlar kullanılır. İnvazif yöntemlerin uygulanmasında Elektrokortikografi (ECoG) ve İntrakortikal nöron kaydı (INR) ölçüm teknikleri kullanılır. İnvazif olmayan yöntemlerde elektroensefalografi (EEG), magnetoensefalografi (MEG), fonksiyonel manyetik rezonans görüntüleme (fMRI) ve fonksiyonel yakın-kızılötesi spektroskopisi (fNIRS) olarak sıralanabilir. Uygulanan ölçüm teknikleri arasında en popüler olanlardan biri EEG tabanlı beyin bilgisayar arayüzü uygulamalarıdır. EEG tabanlı yapılan çalışmaların öne çıkmasının sebebi de ölçüm sırasında cerrahi müdahale gerektirmemesi, pratik ve hızlı olmasıdır.

1.2. İnsanda Sinir Sistemi

İnsan beyni yaklaşık olarak 100 milyar kadar sinir hücresinden oluşur. Sinir hücresi

yani nöronlar insan vücudunda bilgi taşımaktan sorumlu olan beynin yapısal birimleridir. Nöronların birbiriyle iletişime geçmesi bilgi işlemelerine olanak sağlar. Nöronlar dendrit, akson ve hücre gövdesi (soma) adı verilen bölümlerden oluşmaktadır. Nöronların gövdesinden çıkan ve duyu almaya yarayan ince uzantı yapısındaki bölüme dendrit, bilgiyi ileten ve tek olarak çıkan uzantılara akson, hücre çekirdek ve organellerin bulunduğu bölüm ise soma olarak adlandırılır.

Şekil 1’de örnek bir nöron yapısı verilmektedir. Şekilden de görüldüğü gibi sinirsel iletimin yönü dendritten akson uçlarına doğrudur ve uyartıların alındığı kısım olan dendrit, akson vasıtasıyla alınan uyartıları başka bir sinir hücresine iletirler. Aksonların üzerinde bulunan yalıtıcı tabaka da miyelin kılıf olarak adlandırılır ve bilgilerin daha hızlı taşınmasını sağlar.




Şekil 1. Sinir hücresinin yapısı

Nöronların görevlerine göre ayrımı da duyu, ara ve motor nöron olmak üzere üç şekilde yapılır. Duyu organlarından alınan uyartıları merkezi sinir sistemine iletene duyu nöronu, duyu nöronundan gelen uyartıları anlamlandırıp bağlantıyı sağlayan nöronlara ara nöron ve işlenen bilgiyi kas gibi efektör organlara ulaştıran nöronlara da motor nöronlar denir.

1.3. Aksiyon Potansiyeli

Hücrelerde bulunan iyonların hareketleri sırasında meydana gelen elektrokimyasal aktiviteler hücre içi ve dışında potansiyel farklara neden olmaktadır. Hücre zarında oluşan

bu potansiyel farkların ani olarak azalması veya yükselmesi durumunda ortaya çıkan voltaj değişimleri aksiyon potansiyeli olarak adlandırılmaktadır. Oluşan sinyal sinir hücrelerinin bilgi alış verişinde görev alır. Şekil 2’de aksiyon potansiyel oluşumu görülmektedir.



Şekil 2. Aksiyon potansiyeli

Depolarizasyon durumunda; hücreye eşik seviyesinin (-55 mV) üzerinde bir uyarının verildiği durumda Na^+ (sodyum iyonları) difüzyon yoluyla hareket ederek hücre içinin, hücre dışına göre daha pozitif hale gelmesini sağlar. Sodyum iyonları hücre içi potansiyelini +35 mV ile +40 mV yapana kadar hücreye girer.


Depolarizasyondan sonra hücre içine Na^+ girişi durdurulurken, K^+ (potasyum iyonları) hücre dışına doğru çıkmaya başlar. Bu durumun sonunda hücre içi negatif ve dışı da pozitif yüklü olurken dinlenme seviyesine geri döner. Bu olay da “repolarizasyon” olarak isimlendirilir.

Açılan K^+ kanallarının yavaş kapanması sebebiyle hücrenin dışına bu iyonlardan daha fazla çıkış olur. Sonuç olarak, dinlenme seviyesi olan -70 mV değerini geçip -85 mV değerine kadar düşebilir ve bu durum da “hiperpolarizasyon” olarak adlandırılır.

1.4. İnsan Beyninin Yapısı

Beyin, insan sinir sisteminin komuta merkezidir. Neredeyse insanın tüm işlevlerini düzenleyip, sinir ve omurilik sayesinde bu sistemi kontrol eder. Duyu organlarından gelen

bilgileri değerlendirip kaslara iletir. İnsan beyinde, her biri farklı görev ve işleve sahip olan beş ana lob bulunur. Şekilde de görüldüğü gibi; beyin ön (front) lobu bilinçli düşünme gibi görevleri yaparken, ön lobun arkasında kalan yan (parietal) lob ise çevre ile beden arasındaki ilişkiyi kaydeder. Beyin arka kısmında arka (oksipital) lob bulunur. Bu lob ise, kısaca görme merkezidir, görme duyusuyla ilgili bilgilerin işlendiği bölümdür. Şakak (temporal) lobunda duyma ve yüz tanıma gibi uyaranların işlenmesi sağlanır. Son olarak ense hizasında yer alan beyincik (serebellum) koordinasyon ve denge sağlanmasında rol oynar. Beynin bu beş ana lobunun bulundukları yerler ve bazı görevleri aşağıda Şekil 3’de detaylıca gösterilmiştir.



Şekil 3. Beynin beş ana lobu

1.5. Elektroensefalografi

Elektroensefalografi (EEG) üzerine ilk denemeler, beyin üzerinde elektriksel akımların varlığının ilk kez bazı hayvan deneyleri sonucunda 1875 yılında Richard Caton tarafından ortaya çıkarılmasıyla başlamıştır. İnsan beyinde elektriksel aktivitelerin varlığı ise 1929 yılında Alman psikiyatrist Hans Berger ile keşfedilmiştir. Berger’in yaptığı çalışma beyin üzerine yerleştirilen elektrotlara bağlı bir galvanometre düzeneği sayesinde beyin aktivitesinin meydana getirdiği EEG verilerinin kaydedilmesidir.

EEG kısaca 1-400 μV gibi düşük genliğe sahip olan ve beyin yüzeyinden elektrotlar sayesinde ölçülen işaretlere denmektedir [1]. Temelinde nöronlardan kaynaklı üretilen elektrik potansiyellerinin ölçülmesini sağlamak vardır. Kafa derisine yerleştirilen bu elektrotlarla, nöronların faaliyetine dayalı olarak EEG sinyallerini gerçek zamanlı olarak kaydeder. EEG ölçümleri birçok beyin rahatsızlığının teşhis ve tedavisinde düşük

maliyetli ve hastaya acı vermemesi gibi avantajları sebebiyle önemli bir kullanım alanına sahiptir. EEG kayıtlarının alınması sırasında gürültü gibi dışarıdan kaynaklanacak durumların da minimuma indirilmesi sağlıklı bir ölçüm için çok önemlidir.

1.5.1. EEG Sinyal Özellikleri

EEG sinyalleri geniş frekans bandına sahip olmasının yanında, çoğunlukla 0.5-30 Hz arasında değişen alt sinyaller kullanılmaktadır. Bu sinyaller sırasıyla delta, teta, alfa ve beta dalgalarıdır.

Delta (δ) dalgaları: 0.5-4 Hz arasında frekans ve 20-400 μ V arasında değişen yüksek genliğe sahip olan bir beyin dalgasıdır. Bu dalgalar, genişliği en büyük olan dalga tipidir ve yavaştır. Derin uyku esnasında veya beynin çok düşük aktivite gösterdiği zamanlarda görüntülenir.

Teta (θ) dalgaları: 4-8 Hz arasında frekans ve 5-100 μ V arasında değişen genliğe sahiptir. Normal uyku veya stres gibi gerginlik anlarında beynin düşük aktivite gösterdiği zamanlarda görüntülenir.

Alfa (α) dalgaları: 8-13 Hz arasında frekans ve 2-10 μ V arasında değişen genliğe sahip beyin dalgalarıdır. Bilinçli olarak rahat hissedilen, dış uyaranların olmadığı, gözlerin kapalı olduğu durumlarda görüntülenir.


Beta (β) dalgaları: 13 Hz den büyük frekans ve 1-5 μ V arasında genliğe sahiptir. Günlük yaşantının büyük kısmında bu dalgalar vardır. Yüksek dikkat ve aktivite gerektiren durumlarda ve uyanık olduğumuz zamanlarda görüntülenir.

1.5.2. EEG Elektrotları

Beyin sinyallerine dayanan çalışmalarda, kafa derisine yerleştirilen elektrotlar ile EEG verileri ölçülür. Elektrotlar, Uluslararası Elektroensefalogram ve Klinik Nörofizyoloji Federasyon Birliği (International Federation of Societies for Electroencephalography and Clinical Neurophysiology) tarafından tanımlanmış olan standart bir metot olan 10-20 elektrot sistemine göre yerleştirilir. Bu sisteme göre elektrot isimlerinin temsilinde harf ve rakamlar kullanılmaktadır:

Beynin ön tarafındaki bölgenin isminin frontal lop olmasından dolayı beynin ön tarafına yerleştirilen elektrotlar beynin bu lobunun ismini temsil eden “F” harfi ile temsil edilir. Aynı şekilde beynin ön lopunun arka kısmı da parietal lop olarak adlandırıldığı için buradaki elektrotlarda “P” harfi ile başlar. Oksipital ve temporal loplarda sırasıyla arka ve yan tarafları temsil eden bölgeler olduğundan bu bölgelerde sırasıyla “O” ve “T” elektrot isimleri ile ifade edilir. Beynin orta hattın merkezinde olan elektrotlar içinde central’i temsil ettiğinden “C” harfi kullanılır.

Yerleştirilen elektrotların bir diğer temsili de harflerin yanında yer alan rakamlardır ve bu rakamların kullanılışı elektrotların bulundukları yerlerine göre sağ tarafta olanlar çift sayılar ile, sol tarafta olanlar tek sayılar ile gösterilirken orta hat boyunca yerleştirilenler ise “z” harfi ile gösterilir. 10-20 EEG elektrot yerleşimi Şekil 4’de gösterildiği gibidir.



Şekil 4. 10-20 sistemine göre elektrotların yerleşimi

1.6. Beyin Bilgisayar Arayüzü (BBA)


Dünyadaki milyonlarca insan, amyotrofik lateral skleroz (ALS), beyin sapı felci, Serebral palsi (SP), kas distrofisi ve doku sertleşmesi gibi birçok çeşit nöromüsküler hastalıklardan mustarıptır [2]. Bu tarz kas ve sinir hastalığına sahip olan insanların büyük bir kısmı da olası yollarla iletişim kuramayıp farklı iletişim yollarına gerek duyarlar. Bunun sebebi de, daha klasik yöntemler olan ve çok fazla kas kontrolü gerektiren klavye, fare gibi arayüzleri kullanamamalarıdır. BBA, kişilerin kas aktivitesine gerek kalmadan yani motor sinir sistemleri kullanılmadan, bilgisayarın, elektromekanik bir kol ya da farklı nöroprotezlerin kullanımını olanaklı hale getirmektedir [1]. BBA sistemleri, elektrotlardan

alınan sinyallerin analiz edilmesiyle elde edilirler. Kullanıcının beyin dalgalarını kaydederek, verilen görevi tamamlamak için bu sinyalleri bilgisayar sistemine gönderir. İletilen dalga veya sinyaller sayesinde fikir veya nesnenin kontrolü sağlanabilir [3].

BBA uygulamalarında bu beyin dalgalarını ölçmek için birçok yöntem kullanılmaktadır. İnvazif yöntemler, cerrahi tekniklerle beynin içerisine yerleştirilen elektrotlar sayesinde sinyallerin toplanması sağlanır. Bu yöntemlerde, ağrı oluşması durumu varken, beyin ile direk temas sayesinde güvenilir veriler toplamak mümkündür. İnvazif olmayan yöntemlerde ise beyindeki dalgalar kafa derisine yerleştirilmiş olan elektrotlar sayesinde ölçülürken, herhangi bir cerrahi müdahale gerekliliği olmadığı için ağrısız bir yöntemdir [4].

İnvazif yöntemlerden olan, Elektrokortikografi (ECoG) tekniğinde elektriksel sinyallerin kaydı için kafatası üzerinde bir kesi yapılarak elektrotlar bölgeye yerleştirilerek kayıt sağlanıyor iken, diğer bir yöntem olan intrakortikal nöron kaydı (İNR) ise beyindeki nöronsal aktivitenin kaydedilmesiyle sağlanır. İnvazif olmayan yöntemler de başlıca elektroensefalografi (EEG), magnetoensefalografi (MEG), fonksiyonel manyetik rezonans görüntüleme (fMRI) ve fonksiyonel yakın-kızılötesi spektroskopisi (fNIRS) olarak sıralanabilir. MEG tekniği, iyi bir yalıtım gerektirmesi ile birlikte fazlaca nöronun aktifleşmesiyle manyetik alanı ölçmek için kullanılırken, fMRI ise kandaki oksijen miktarındaki değişiklikleri ölçmektedir. Bu yönetime benzer diğer bir yöntem fNIRS, kandaki hemoglobin miktarı ile ölçülmektedir. Elektroensefalografi (EEG), en yaygın olarak kullanılan kayıt tekniklerindendir. İnvazif olmaması, pratik ve hızlı olması gibi nedenlerden dolayı BBA sistemleri araştırmalarında oldukça sık kullanılmaktadır.

Klasik bir beyin bilgisayar arayüzü sisteminin ana bileşenleri sinyallerin toplanması, ön işlem aşaması, öznitelik çıkarımı ve sınıflandırma olarak sıralanabilir. Şekil 5’de BBA sisteminin adımları gösterilmiştir.



Şekil 5. Beyin bilgisayar arayüzü sistemi

Sinyallerin Toplanması: BBA arayüzündeki ilk aşama budur. Belirli sensörler yardımıyla (örnek olarak saç derisine yerleştirilen elektrotlar) beyindeki elektriksel sinyallerin ölçülmesi işlemidir.

Ön İşlem Aşaması: Toplanan sinyaller gürültü adı verilen bozucu kaynakları da bulundurur. Bunlar örneğin, ışığın açık olması, gözünü kırpması veya kişinin dikkatinin dağılması gibi etkenlerden kaynaklanmaktadır. Bu aşamada; bazı istatistiksel normalizasyon tekniklerinin (örneğin min-max normalizasyonu) kullanımı, veri sıkıştırma veya veride önemsiz olanların ayrıştırılması işlemi gerçekleştirilir. Ön işleme sayesinde veri, diğer aşamalarda kullanımı için uygun hale getirilir. Burada iyi bir işlem gerçekleştirildiği zaman sonuçta başarılı olacaktır.

Öznitelik Çıkarımı: Kaydedilen sinyallerdeki en iyi temsil eden özelliklerin belirlenmesi ve önemli özelliklerin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Bu aşamada önemli nokta; değerli özelliklerin seçilip verinin boyutu azaltılsa bile seçilen özelliklerin yine de orijinal veriyi doğru bir şekilde ve tamamen tanımlaması istenir. BBA arayüzlerinde genellikle çoklu elektrot kullanılır. Beynin farklı bölgelerinin farklı işlevler görmesi ve kaydedilen sinyallerin de kişiden kişiye farklılık göstermesi, doğru elektrotların kullanımının önemini artırmaktadır.

Sınıflandırma: Kaydedilen sinyallerden oluşturulan öznitelik vektörlerini kullanarak, bir sınıflandırıcı yardımıyla bu verinin hangi sınıfa ait olduğunun belirlenmesidir.

1.7. Literatür Taraması

Beyin bilgisayar arayüzü (BBA) uygulamalarına olan ilginin artmasıyla bu sistemlere yönelik yenilikçi çözümlerin gelişmesinin de önü açılmıştır. BBA uygulamaları kişilerin beyin dalgalarından kaydedilen sinyallerle çalıştığı için bu sinyallerin kaydının nasıl yapıldığı da önemlidir. Kullanılan yöntemler arasında EEG ölçümü kolay elde edilebilir ve ağrısız bir yöntem olduğundan dolayı BBA çalışmalarında sıklıkla kullanılmaktadır [5], [6], [7], [8]. Bunun yanı sıra ECoG [9], MEG [10], fNIRS [11], [12], ve fMRI [13] gibi farklı ölçüm tekniklerinin kullanıldığı çalışmalar da literatürde mevcuttur.

BBA sistemlerinin en önemli amaçlarından olan engelli ve hasta bireylerin iyileşme süreçlerini kısaltacak ve hayatlarını kolaylaştıracak güncel çalışmalar sürekli olarak yapılmaya devam etmektedir [14-19]. Motor sinirlerinin hastalık veya yaşanan kaza durumlarında çeşitli nedenlerle zarar görmesi, insanların kas ve hareket kabiliyetlerini kısıtlasa da, beyin düşünme ve algılama gibi fonksiyonlarını yine de yerine getirebilir. Literatürde sinyallerin kullanılmasıyla birlikte çeşitli hastalıkların tespitinin yapılmasına dair birçok çalışma vardır. Mesela bu rahatsızlıklar arasında, insanlarda sıkça görülen ve nörolojik bir hastalık olan epilepsinin tanısı için yapılmış çalışmalar mevcuttur. Bunlardan biri Kaya ve Türk'ün yapmış olduğu epilepsi hastalığının tespiti için kaydedilen sinyallerin normal ve epileptik olarak sınıflandırılmasına yönelik çalışmadır [20]. Kişilerin ön korteks bölgesine yerleştirilen elektrotlar ile kaydedilen 257 adet verinin 172'si hasta kişilere aittir. Kullandıkları üç katmanlı yapay sinir ağı (YSA) tekniği ile hastaların 164'ünün tespiti yapılmıştır. YSA algoritması ile yapılan diğer bir çalışmada [21] Tzallas ve diğerleri de yine epilepsi teşhisi için yumuşatılmış (smoothed) sahte (pseudo) wigner-ville dağılımını hem sağlıklı hem epilepsi olan beş kişiden sağlanan EEG işaretlerine uygulayarak yüksek doğruluk sonucu sağlamışlardır.

Farklı tarz düşünsel görevler esnasında kaydedilen sinyallerin yüksek başarımlarla sınıflandırılması BBA sistemleri için oldukça önemlidir. Düşünsel görevler; el açma kapama, el sıkma, kol ve ayakların hareketi, dil hareketi, göz kırpması veya göz açıp kapatma gibi çeşitli hareketlerin hayaliyle oluşabilir. Literatürde farklı düşünsel görevler ile hareket hayalinin ve gerçek hareketin sınıflandırılmasıyla ilgili yapılmış pek çok çalışma vardır:

Dong ve diğerkleri [22], dokuz kiři için sol el, sağı el, ayak ve dil hareketlerinin motor hayali görevlerini içeren bir veri seti kullanmışlardır. Çalışmada dört sınıflı olarak verilen bu verileri sınıflandırmak için bir Hiyerarşik Destek Vektör Makinaları (Hierarchical Support Vector Machine - HSVM) algoritması önerilmiştir. Ham EEG verisi, dalgacık dönüşümü ile ayrıştırıldıktan sonra etkili frekans alt bantları yeniden oluşturuldu. 5 kat çapraz doğrulama yöntemi ile tüm kişiler için ortalama sınıflandırma başarısı %64.4 olarak elde edilmiştir. Temel olarak sağı ve sol el EEG işaretlerinden oluşan veriyi DVM ile ayırmayı amaçlayan çalışmalardan biri de Hajibabazadeh ve Azimirad [23] tarafından gerçekleştirilmiştir. Bu EEG işaretlerinin 6 elektrottan toplanmasıyla birlikte alçak geçiren filtre ile filtreleme işlemini gerçekleştirdiler. Sağı ve sol el hayalini bu teknikle %75 SD ile sınıflandırmışlardır. Bhattacharyya ve diğerkleri [24] ise yaptıkları çalışmada doğrusal ayırma analizi (DAA), karesel ayırma analizi (KAA) ve k-EYK teknikleriyle sağı ve sol kol hareketinin sınıflandırılma performansını analiz etmişlerdir. Dalgacık dönüşümü, PSD ve ortalama bant gücü ile fazla sapma olmadan sırasıyla ortalama %80, %80 ve %75.71'i bulan sonuçlar elde edilmiştir. Ortalama güç bandı vektörü ise k-EYK ile birlikte %84.29 ile en yüksek SD sonucunu vermiştir. Amanpor ve Erfanian [25] yaptıkları çalışmada amaç olarak el kavrama ve el açma motor hayalinin ayrımının araştırılması olarak belirlemişlerdir. BBA tarafından gerçekleştirilen aksiyonun, kiři tarafından gerçekleştirilen zihinsel görevle uyumlu olması gerektiğini vurgulamışlardır. Çalışmalarında, bir eldeki EEG işaretlerini kullanarak el kavrama ve el açmanın hayalini sınıflandırılması amacıyla öznitelik çıkarımı için dalgacık dönüşümü, Ortak Uzamsal Örüntü (Common Spatial Pattern - CSP) ve Ortak Bilgi (Mutual Information) özelliklerine bağı bir yöntem sunmuşlardır. Önerilen metot sayesinde %77.6 ortalama doğruluk elde etmişlerdir. Ergun ve Aydemir [26] ise çalışmalarında yaygın olarak kullanılan EEG yerine yakın kızıl ötesi spektroskopi tabanlı ve iki sınıflı (el açma - kapama) motor hareket hayaline dayanan bir veri seti kullanmışlardır. Ön işlem den geçirilen işaretlerden, katz fraktal boyutu esasına dayanan özellikler çıkarılmıştır. Çıkarılan özellikler k-EYK yöntemi ile sınıflandırılıp, literatürde bu veri seti ile bulunan ortalama SD'leri geride bıraktığı görülmüştür. Yine aynı veri seti ile yaptıkları başka bir çalışmada ise öznitelikler hilbert dönüşümü ve ortalama türev metotları kullanılarak çıkarıldıktan sonra aynı sınıflandırıcı yöntemi ile sınıflandırılmıştır ve ortalama SD olarak %82.13 elde edilmiştir [27].

Motor hayali ve gerçek hareketlerin sınıflandırmasında literatürde kullanılan makine öğrenme tabanlı çalışmaların yanında derin öğrenme ve sinir ağıları algoritmaları

ile de çalışmalar yapılmaktadır. Bunlardan biri de Kant ve diğerlerinin yapmış oldukları çalışmadır [28]. Yaptıkları çalışmaya motivasyon olarak derin öğrenmenin birçok alanda başarılı sonuçlar vermesine rağmen, EEG sinyalleri bakımından oldukça az çalışmalar yapıldığını savunmuşlardır. Buna ek olarak k-en yakın komşuluk (k-EYK) ve doğrusal ayırma analizi (DAA) yöntemlerinin iyi sonuçlar vermesine rağmen derin öğrenme (Deep learning systems) bazlı sistemlerinde bu yöntemleri geçebilecek potansiyeli olduğunu belirtmişlerdir. BBA uygulamalarında, motor hayali sınıflandırması için daha iyi doğruluğa ulaşmanın esas amaç olduğunu vurgulayarak derin öğrenme ile sürekli dalgacık dönüşümü kombinasyonuna bağlı bir yöntem önermişlerdir. Sonuç olarak aynı veri seti kullanılarak yapılan bir diğer çalışmayı %5.71 oranında geçerek, beyin bilgisayar arayüzü çalışmalarında önerilen yöntemin kullanılabileceğini göstermişlerdir. Tang ve arkadaşları [29], motor hayali (Motor Imagery - MI) esnasında kaydedilen EEG işaretlerinin (sağ ve sol el hareketi) özneteliğinin çıkarımı ve sınıflandırması için Evrişimli Sinir Ağları (Convolutional Neural Network - CNN) analizine bağlı yeni bir yöntem önermişlerdir. Önerilen yöntemin kıyası için üç farklı klasik sınıflandırma aynı eğitim ve test setleri üzerinde kullanılmıştır. Yeni yöntemle ortalama doğruluğu diğerlerinden %9.24, %3.80 ve %5.16 üzerinde elde etmişlerdir. Ramadhan ve diğerleri [30] ise sağ-sol el kavrama hareketine bağlı olarak kaydedilen EEG sinyallerinin en iyi duyarlılık sonucu için uygun bir birleşim bulmayı hedeflemişlerdir. Maksimum mü ve beta band gücünün frekansları, sınıflandırmada özellik olarak kullanılmıştır ve en iyi sınıflandırıcı sonucu Olasılıksal Sinir Ağı (Probabilistic Neural Network - PNN) ile %61.96 olarak elde edilmiştir.

Motor hayaline dayalı yapılan çalışmaların bazılarında ise sınıflandırma yönteminden ziyade başarımlar için kaydedilen elektrotların önemini belirten araştırmalarda literatürde mevcuttur. Bu amaçla Robinson ve Vinod [31], motor kontrollü BBA sistemi geliştirmek için kısıtlı sayıda elektroda sahip bir EEG yükseltici yapılabilişliğini çalışmışlardır. Çalışmadaki amaç, motor aktivitesine ve motor hayaline bağlı beyin sinyallerini çıkarmaktır. Beş kişi üzerinde yapılan çalışmada, kişilerin baskın elinin iki yönlü hareketlerini %81.3 ve bu hareketlerin hayalini ise %82.4 ortalama SD ile sınıflandırmışlardır. Bu çalışmaya benzer şekilde fakat kısıtlı elektrot yerine en uygun elektrotları otomatik seçen bir metot Ghaemi ve arkadaşları [32] tarafından sunulmuştur. Bu sınıflandırıcı ile sekiz kişi için en yüksek doğruluğu %80 olarak hesaplamışlardır. Sağ-sol el hareketlerinin hayalinin sınıflandırılmasına yönelik diğer bir çalışmada Chatterjee ve Bandyopadhyay [33], hareket hayali için veri çıkarımında özellikle C3 ve C4

elektrotlarından faydalanırken, istenmeyen sinyallerden kurtulmak için Eliptik bant geçiren filtre kullanmışlardır. Özellik vektörlerini oluşturmak için ise EEG verisi üzerinde istatistiksel tabanlı, dalgacık dönüşüm tabanlı enerji-entropi ve karekök ortalama (RMS) gibi çeşitli özellik çıkarma teknikleri kullanmışlardır. Sınıflandırma aşamasında DVM kullanılmış olup, bulunan sonuçlar Çok Katmanlı Algılayıcı (ÇKA) ile karşılaştırılmıştır. Çıkan sonuçlara göre özellikle dalgacık-tabanlı metotların her ikisi için de iyi sonuçlar verdiğini görmüşlerdir.

BBA çalışmalarında dikkat edilmesi gereken önemli konulardan biri de özniteliklerin seçimi konusudur. Literatürde etkin öznitelik seçimi için farklı öznitelik yöntemlerinin seçimi kadar boyut azaltma ve optimizasyon gibi algoritmalarının da önemi sıkça vurgulanmış ve araştırmalar yapılmıştır. Aydemir ve Kayıkçıoğlu [34], BBA sistemlerinde az sayıda elektrot ve öznitelik kullanımının önemine dikkat çekerek, sağ veya sol el hareketinin hayaline dayalı EEG işaretlerini sınıflandırılması için yüksek sınıflandırma doğruluğuna sahip bir yöntem önermişlerdir. Ön işlemden geçirilen EEG verilerinin, fourier dönüşümü yardımıyla özellikleri çıkarılmıştır. DAA ile %91.14 sınıflandırma doğruluğu elde edilmiştir. Önerilen bu yöntemin aynı veri setiyle yapılan çalışmalar ile karşılaştırılıp başarılı olduğu gösterilmiştir. Saka ve diğerleri [35] ise bütün BBA uygulamaları için tatmin edici performans veren genel bir öznitelik çıkarım yönteminin olmadığını belirtmişlerdir. Bundan dolayı, sağ veya sol el hareket hayali esnasında kaydedilen EEG işaretlerinin sınıflandırılması için Hızlı Walsh Hadamard Dönüşümüne bağlı yeni bir özellik çıkarma yöntemi önermişlerdir. Önerilen yöntemle %88.87 sınıflandırma doğruluğu elde etmişlerdir ve çıkan bu iyi sonucun var olan özellik çıkarım yöntemlerine alternatif olarak kullanılabileceğini kanıtladığını savunmuşlardır. Bhattacharyya ve arkadaşları da BBA ile özellikle engelli bireylerin hayatlarını kolaylaştırabilecek sistemlerin geliştirebileceğini ve ayrıca ileriye dönük büyük bir potansiyele sahip olduğunu belirterek sağ ve sol el hareketi sınıflandırmasının performansını, esas özellikler ve indirgenmiş özellikler kullanarak çalışmışlardır. Özellik indirgenmesi temel bileşen analizi (TBA) kullanılarak gerçekleştirilirken, özellik çıkarımı için dalgacık dönüşümü, spektral güç yoğunluğu ve ortalama bant gücü teknikleri kullanılmıştır. Çıkarılan özellikler farklı sınıflandırıcı yöntemleriyle değerlendirilmiştir ve özelliklerin indirgenmesi sayesinde k-EYK sınıflandırıcısının doğruluğu %5 kadar artırdığı görülmüştür [36]. Rejer de bu konuya farklı bir çözüm üreterek, ham EEG verisinden çıkarılan özelliklerin boyutunu nasıl azaltabileceği hakkında bir çalışma gerçekleştirmiştir.

Genetik Algoritmanın (Genetic Algorithms - GA) yüksek sınıflandırma doğruluğunu veren özellik setini elde ettiğini ama bu setin boyutunun sıklıkla çok yüksek olduğunu öne sürmüştür ve bu yüzden çalışmasında Genetik Algoritma yönteminin değiştirilmiş bir sürümünü sunmuştur. SVM sınıflandırıcısı ile yalnızca beş veya altı özellik kullanarak bütün durumlarda %92'yi geçen doğruluk elde etmiştir [37].

Hareket hayaline dair yapılan diğer sınıflandırma çalışmalarının birinde Chatterjee ve diğerleri, elin hareketinin hayal edilmesiyle oluşan EEG verisi üzerinde farklı öznitelik çıkarma ve sınıflandırma yöntemleri kullanmışlardır. Ham EEG verisinin çok gürültülü olmasından dolayı, filtreler kullanarak gürültüyü giderip farklı öznitelik çıkarma tekniklerinin yardımıyla bu sinyallerden öznitelik vektörlerini oluşturmuşlardır. Dalgacık tabanlı öznitelik kullanarak en iyi sınıflandırma doğruluğu olarak %85 bulmuşlardır [38]. Sağ-sol el hareket hayaliyle ilgili başka bir çalışmada Xu ve arkadaşları sınıflandırmada daha yüksek doğruluk sağlaması amacıyla üç aşamadan oluşan yeni bir yöntem sunmuşlardır. Dalgacık dönüşümü ve özbağlaşım (AR) modeli kullanarak öznitelik vektörünü oluşturmuşlardır. Son olarak doğrusal bir algoritma ile sınıflandırmayı gerçekleştirerek, sağ-sol el hareket hayalinde yalnız bir özellik kullanımından daha iyi bir ortalama doğruluk sonucu elde etmişlerdir [39].

Hayale dayalı yapılan çalışmalar için veriler sağlıklı veya engelli kişilerden oluşabilir. Tosun ve arkadaşları [40] sağlıklı bir erkek bireyin sağ ve sol elinin ileri-geri hareketi esnasında ve hareketin sadece hayal edilmesi esnasında kaydedilen EEG verilerini kullanmışlardır. Welch yöntemi ile 1-48 Hz arasındaki frekansların güç yoğunlukları hesaplanıp, bu veri setleri geri yayımlı sinir ağına (Backpropagation Neural Network - BPNN) uygulanmıştır. Hayal edilen hareket verileri %99.99 gibi yüksek bir doğrulukla sınıflandırılmıştır. Bu sonuçlarla, BBA uygulamalarında robotik sistemlerin düşünce ile kontrol edilebileceğini gösteren bir çalışma olabileceğini çıkarmışlardır. Cho ve diğerlerinin yaptığı çalışmada [41], katılan beş sağlıklı bireyden, gerçekten veya sadece hayal ederek el sıkma, eli sağa-sola çevirme veya hiçbir el hareketi yapmadan 25 adet deneme yapmaları istenmiştir ve bu hareketler 20 kanal üzerinden kaydedilmiştir. Veri analizinde doğruluk, ortak uzamsal örüntü (CSP) ve doğrusal ayırma analizi (LDA) algoritmaları kullanılarak, gerçek ve motor hayali sınıflandırmasında ortalama olarak sırasıyla %56.83 ve %51.01 olarak elde edilmiştir. Liu ve arkadaşları ise sağlıklı üç kişi üzerinden toplanan EEG sinyallerini kullanarak, sağ ve sol el hareket hayalini sınıflandırmak için bir yöntem sunmuşlardır. Ayırık dalgacık dönüşümü metodunu

kullanarak Fisher doğrusal ayırma analizi (FLDA) ve DVM sınıflandırıcısıyla karşılaştırdılar. Sonuç olarak, DVM'nin SD oranında daha yüksek değere ulaştığını belirtmişlerdir [42].

Yapılan çalışmalara göre motor hayaline dair birçok çalışma mevcut olsa da, genelde sağlıklı bireylerden alınan kayıtların kullanılması, engelli bireylerin verilerinin kullanılmasıyla tasarlanacak BBA sistemlerinin geliştirilmesine ihtiyacın olduğunu göstermektedir.



2. YAPILAN ÇALIŞMALAR

2.1.1. Materyal


Çalışmada kullanılan veri seti; el hareket ve fonksiyon yetersizliği olan 10 kişiden elde edilmiş sinyallerden oluşmaktadır. Veriler, “*Clinical BCI Challenge-WCCI 2020*” yarışmasında kullanılmıştır [43]. Veriler kişilerin sağ (sınıf1) veya sol (sınıf2) elinin kavramayı deneme hareketinin hayal edilmesiyle ortaya çıkan işaretlerden alınmıştır.

2.1.2. Deney Protokolü

Yapılan deneysel çalışma, iki aşamalı bir sensörimotor ritim beyin bilgisayar arayüzü yapısıyla işlenmiştir. Birinci aşama sınıflandırıcının geri bildirimi olmadan çıkarılmış öznitelikleri kullanarak eğitilmesi evresidir. Bu aşamada verilerin edinim süresi yaklaşık olarak 7 dakika 30 saniye sürerken, iki defa ve 40 deneme olarak koşum yapılmıştır. İkinci aşama ise sınıflandırıcının çevrim dışı modda eğitildiği ve yaklaşık 30 saniye süren diğer bir evredir. Bu evrelerin devamında çevrim içi modda geri bildirim olacak şekilde 40 deneme olarak sürdürülür. Her koşum 20 denemesi sağ ve 20 denemesi sol motor hayali olacak şekilde ayarlanmıştır.

Çalışma sınıflandırıcının doğruluk şansının %50 olduğu bir dengeli sınıflandırma problemi olarak düşünülebilir. Kalibrasyondan (eğitim kaydı), geri bildirim (test kaydı) evresine geçiş 16 dakika sürmektedir. Bu süre gayet yeterli bir süredir çünkü hastaların yorulmasını ve dikkatlerinin bozulması istenmemektedir.

Eğitilme evresi toplamda sekiz saniye sürmektedir. Bunun ilk üç saniyesi hazırlık aşamasıdır ve hazır ol mesajı içeren bir yazı bilgisayar ekranının ortasında görülmektedir. İki saniyenin sonunda, bip sesi oluşmasıyla beraber üçüncü saniyenin sonuna doğru ekranın sağ veya sol tarafında el görüntüsü şeklinde bir işaret belirlemektedir. Daha sonra katılımcılardan işaretin belirttiği yönle ilgili sağ veya sol elin kavramayı deneme hareketi temelli bir görev yapılması istenmiştir. Bu evre sekiz saniyenin sonuna kadar sürerken, daha sonra ekran diğer denemenin başlamasından önce iki-üç saniye kadar bir süre için kararmıştır. Bu aşamada yapılan EEG verilerin kaydedilme işlemi Şekil 6’da verilmiştir.



Şekil 6. Bir EEG denemesinin kaydedilmesi süreci


2.1.3. Veri Edinme

EEG sinyalleri, uluslararası 10-20 sistemine göre kafa derisine yerleştirilmiş olan 12 elektrot üzerinden kaydedilmiştir. Veri edinme sırasında işaretler 512 Hz frekansı ile örneklenmiştir. 0.1-100 Hz arasında bant geçiren filtre ile daha sonra da 50 Hz frekansında bant durduran filtre ile filtreleme işlemi yapılmıştır. Deney aşamasından bir görüntü Şekil 7’de verilmiştir.



Şekil 7. Deney aşamasından bir görüntü [44].

EEG işaretlerinin kaydı için kafaya yerleştirilen elektrotların pozisyonları Şekil 8’de gösterildiği gibidir. Ayrıca kullanılan elektrotların numaralandırılması da aşağıdaki Tablo 1’de verildiği şekilde yapılmıştır.



Şekil 8. Deneyde kullanılan elektrotların bağlanma şekli

Tablo 1. Elektrotların adlarının numaralandırılması

Elektrot Numarası	1	2	3	4	5	6	7	8	9	10	11	12
Elektrot Adı	F3	FC3	C3	CP3	P3	FCz	CPz	F4	FC4	C4	CP4	P4

2.1.4. Deney Katılımcıları

Deneye katılan tüm hastaların BBA ile yapılmış olan çalışmalarla ilgili bir deneyimi yoktur. Kişiler arasında daha önce epilepsi geçmişi olmayan katılımcılar seçilmişlerdir. Ayrıca bilişsel bozukluk durumlarına da bakılmış olup, yapılacak deney için “Hodgekinson’s mini mental test” sonucu olarak 10 üzerinden en az 7 alan kişilerle çalışılmıştır [45]. Çalışmaya gönüllü olarak katılan kişilerin yaş, cinsiyet, baskın ve felçli olan elinin hangisinin olduğu ve felçten kayıt gününe kadar geçen süre gibi bilgiler Tablo 2’de detaylı bir şekilde verilmiştir.

Tablo 2. Hastaların istatistikleri

Katılımcılar	Yaş (Yıl)	Cinsiyet	FE (Sağ/Sol)	BE (Sağ/Sol)	FSZ (Ay)
1	48	Erkek	Sol	Sağ	8
2	71	Erkek	Sol	Sağ	20
3	63	Erkek	Sağ	Sağ	8
4	35	Kadın	Sağ	Sağ	3
5	24	Erkek	Sol	Sağ	8
6	45	Kadın	Sol	Sağ	6
7	48	Erkek	Sol	Sağ	2
8	62	Kadın	Sol	Sağ	6
9	28	Erkek	Sol	Sağ	1
10	51	Kadın	Sağ	Sağ	48

FE: Felçli El, BE: Baskın El, FSZ: Felçten Sonraki Zaman

2.2. Literatürde Aynı Veri Seti ile Yapılan Çalışmalar

Chowdhury ve diğerleri kaydedilen EEG işaretlerinin $\mu = [8-12]$ Hz ve $\beta = [16-24]$ Hz frekans bantları için bant geçiren filtre (bandpass filter) ile filtrelenmesini sağlamışlardır. Aynı frekans bandında daha güçlü sinyallerin olmasına karşın, çoklu kanallı EEG verilerini analiz etmede etkili olan ortak uzamsal örüntü (common spatial pattern - CSP) algoritmasını kullanmışlardır. Uzamsal filtre (spatial filter - SF) kullanıldıktan sonra logaritmik varyansı alınarak öznitelik vektörünü oluşturmuşlardır. Destek vektör makinesi kullanarak gerçekleştirdikleri sınıflandırma işleminden kişilere göre elde ettikleri sonuçlar Tablo 3’de gösterilmiştir. Bu verilerle yapılan çalışmada ortalama SD olarak %75.75 ve standart sapmada ise 3.92 sonucunu elde etmişlerdir [44].

Tablo 3. Chowdhury ve diğerlerinin elde ettiği SD sonuçları

Katılımcılar	SD (%)
1	72.50
2	72.50
3	82.50
4	72.50
5	77.50
6	72.50
7	75.00
8	75.00
9	82.50
10	75.00

Raza ve diğerleri, analizlerinde 8 saniye olarak kaydedilen verinin sadece motor hayaliyle ilgili olan zaman dilimlerini (epok) yani 3 saniyelik kısmını kullanmışlardır. 8-24 frekans aralığında bant geçiren filtre ile filtrelenen işaretlerden, 3 saniye olarak seçilen epokların; 0.03 saniyelik epoklara bölünmesiyle 100 epok, 0.01 saniyelik epoklara bölünmesiyle 300 epok ve 0.006 saniyelik epoklara bölünmesiyle 500 epok elde etmişlerdir. Yaptıkları çalışma sayesinde evrişimli sinir ağıları yöntemiyle buldukları ortalama sınıflandırma başarımı Tablo 4’de verildiği gibi 100, 300 ve 500 epok için sırasıyla %66.75, %68.50 ve %70.25 iken, standart sapması da %15.90, %15.86 ve %16.56 olarak hesaplanmıştır [46].

Tablo 4. Raza ve diğerlerinin elde ettiği SD sonuçları

Katılımcılar	100 Epok - SD (%)	300 Epok - SD (%)	500 Epok - SD (%)
1	67.50	67.50	67.50
2	75.00	92.50	92.50
3	50.00	50.00	52.50
4	57.50	52.50	67.50
5	60.00	57.50	67.50
6	67.50	75.00	75.00
7	97.50	82.50	92.50
8	50.00	65.00	52.50
9	55.00	52.50	52.50
10	87.50	90.00	90.00

Ateş ve Aydemir, paylaşılan veri setinin 9 ve 10. kişiler için eğitim verilerinin paylaşılmayıp sadece test verisinin paylaşılmasından dolayı bu veri setinin ilk 8 kişi için kaydedilen EEG sinyallerini kullanmışlardır. Çalışmalarında ise hem EEG verisine herhangi bir ön işlemde bulunmadan bu çalışmada kullanılan veri setinin sekiz kişi için istatistiksel tabanlı özneliliklerle öznelilik vektörü çıkarıp sınıflandırmayı gerçekleştirmişlerdir. Bu kişiler için üç farklı sınıflandırıcı ile en yüksek ortalama %81.17 SD olarak k-EYK yöntemiyle elde etmişlerdir [47]. Kullandıkları üç sınıflandırıcıya ait sonuçlar Tablo 5’de verilmiştir.

Tablo 5. Ateş ve Aydemir'in elde ettiği SD sonuçları

Katılımcılar	k-EYK	DAA	DVM
1	82.60	66.90	66.50
2	90.95	91.85	92.10
3	80.65	76.55	81.10
4	81.05	70.40	68.95
5	77.70	50.35	47.90
6	81.85	60.30	69.65
7	84.95	85.70	86.70
8	69.60	61.05	59.85

Bu verileri kullanarak Clinical BCI Challenge-WCCI 2020 yarışmasına katılan takımlardan iki farklı değerlendirme yapıp sonuç bulmaları istenmiştir. Birincisinde, ilk sekiz katılımcı için kişiye göre sınıflandırma yapılması, yani bir kişinin eğitim kümesi kullanılarak o kişiye ait test verisinin sınıflandırılması istenmiştir. İkinci uygulama ise geriye kalan iki kişi (9 ve 10. katılımcılar) için önceki sekiz kişinin eğitim kümesi kullanılarak ve genel bir sınıflandırıcı tasarlanarak bu kişilerin test kümesinin sınıflarını bulması istenmiştir.

Katılan gruplar içerisinde bu değerlendirmelere göre en yüksek sonuca 1. uygulama, 2. uygulama ve iki durumun sonuçlarından elde edilen toplam değerlendirme ile başarı gösteren ilk 3 takım aşağıdaki tablolarda sırasıyla Tablo 6, 7 ve 8'de gösterilmiştir [43].

Tablo 6. WCCI Competition 2020 yarışmasının 1. uygulama sonuçları

Sıra No	Takım Adı	Üniversite/Kuruluş	SD (%)	Kappa Değeri
1.	RIGOLETTO	Aramis Project Team, Inria Paris, Paris Brain Institute, Fransa	78.44	0.57
2.	Signal Processing @ LNMIIT	The LNM Institute of Information Technology, Hindistan	74.69	0.49
3.	iBCI	Indian Institute of Technology Kanpur, Hindistan	73.75	0.47

Tablo 7. WCCI Competition 2020 yarışmasının 2. uygulama sonuçları

Sıra No	Takım Adı	Üniversite/Kuruluş	SD (%)	Kappa Değeri
1.	Homunculus Computing Group	Federal University of Juiz de Fora, Brezilya	95	0.90
2.	iBCI	IIT Kanpur, Hindistan	83.75	0.68
3.	Jin	Technical University of Kosice, Slovakya	75	0.50

Tablo 8. WCCI Competition 2020 yarışmasının toplam değerlendirme sonuçları

Sıra No	Takım Adı	Üniversite/Kuruluş	Toplam Değerlendirme
1.	Homunculus Computing Group	Federal University of Juiz de Fora, Brezilya	15.50
2.	iBCI	IIT Kanpur, Hindistan	14.415
3.	Long	Institute of Automation Chinese Academy of Sciences, Çin	8.720

2.3. Tezin Amacı ve Kapsamı

Yapılan tez çalışmasında veri seti olarak “*Clinical BCI Challenge-WCCI 2020*” yarışması için sunulan EEG ile kaydedilmiş kayıtlar kullanılmıştır. Bu veri seti, el fonksiyon yetersizliği olan kişilerin, sağ veya sol elin kavramayı deneme hareketinin hayaliyle ortaya çıkan EEG sinyallerini içermektedir. Tezin ilerleyen bölümlerinde kullanılan veri seti detaylı olarak tanıtılmıştır.

Literatürde yapılan çalışmaların bazılarında kısmi elektrot seçimine gidilmiş yani beynin duyuşal bölgesiyle ilgili olan elektrotların seçimi baştan yapılmış veya bazılarında da tam aksine elektrotların tümü kullanılarak çalışmalar gerçekleştirilmiştir. Yine öznitelik seçiminde de genellikle birbirini tekrar eden ve kısıtlı yöntemler kullanılmıştır. Seçilen özniteliklerin tümünün kullanılması durumunda yetersiz olanlarında sisteme dahil edilip çalışmayı olumsuz etkileyebileceği durumlar olabilir. Tezdeki çalışmanın amaçlarından biri de veri setinin kullanıldığı 2020 yılında yapılan yarışma da en başarılı olan takımla yarışıp sonuçları değerlendirmektir. Tezde genel amaç olarak ise benzer çalışmaları geçebilecek yüksek sınıflandırma başarımları hedeflenmiştir.

Bu yüzden yapılan çalışmada; BBA çalışmasını daha iyi sonuçlandıracak elektrotların yalnızca etkin olanları yöntem dahilinde seçilmiştir. Öznitelikle ilgili olarak

da kullanılan yöntemlere ek olarak farklı alanlar için kullanılan veya daha az kullanılan dönüşümler öznitelik seçimi aşamasında kullanılmıştır. Belirlenen özniteliklerin arasından da yalnızca optimum sonucu sağlayacak olanlar çalışmada uygulanan optimizasyon algoritmasıyla seçilmiştir.

Etkin elektrot ve etkin öznitelikler seçilerek yapılan bu tez çalışmasında; kullanılan veri setinin güncel olmasıyla birlikte öznitelik vektörü boyutlarının da düşük olması ve ayrıca kullanılan makine öğrenmesi tabanlı klasik sınıflandırıcılarla sistemin test edilmesi yöntemlerin uygulanabilir olduğunu ortaya koymaktadır.

Hayal edilen bu hareketlerin otomatik çözümlenmesi işlemi de robot destekli teknolojilerin veya rehabilitasyon amaçlı BBA uygulamalarının geliştirilmesine katkı sağlayacaktır.

2.4. Elektrot Seçimi

Kaydedilen EEG sinyallerinin sınıflandırılma performansını doğrudan etkileyecek faktörlerden biri de elektrotlardır. Özellikle çoklu elektrot kullanılarak yapılan çalışmalarda doğru elektrot veya elektrotların seçimi çok önem arz etmektedir.

Çok elektrot kullanılan verilerde, yapılacak çalışmaya göre beyinsel aktivitenin daha aktif olduğu bölgelerden kaydedilen verileri kullanmak öznitelik seçimi ve sınıflandırma aşamasında başarı ve hız anlamında büyük fayda sağlayacaktır [1].

2.5. Öznitelik Çıkarma Yöntemleri

BBA uygulamalarında kullanılacak olan öznitelik seçim yöntemleri iyi bir sınıflandırma başarımı için oldukça önemlidir. Kullanılan öznitelikler her kişide aynı etkiyi vermeyebilir bu yüzden doğru öznitelik veya öznitelik kombinasyonlarını kullanımı değerlidir. Bu çalışmada kullanılmak üzere seçilen öznitelik yöntemleri aşağıda sıralanmıştır.

2.5.1. Hjorth Parametreleri

Zaman uzayın sinyalin analizinin yapılabilmesini sağlayan istatistiksel özelliklerdir.

Bu parametreler aktivite, mobilite ve karmaşıklıkır.

Aktivite, sinyal gücünü temsil eder ve sinyallerin varyansını belirtir. x_i giriş sinyali ve $\bar{x}$ sinyalin ortalaması ise *Aktivite* denklem 1'deki gibi hesaplanır:

$$Aktivite = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 = var(x) \quad (1)$$

Mobilite ise ortalama frekansını temsil eder. $\dot{x}$ sinyalin 1.türevi olmak üzere *Mobilite* denklem 2'deki gibi bulunur:

$$Mobilite = \sqrt{\frac{Aktivite(\dot{x})}{Aktivite}} = \sqrt{\frac{var(\dot{x})}{var(x)}} \quad (2)$$

Karmaşıklık, sinyaldeki frekans üzerindeki değişimleri ifade eder. $\dot{x}$ sinyalin 1.türevi, $\ddot{x}$ sinyalin 2.türevi ve $var(x)$ ise sinyalin varyansı ise Karmaşıklık denklem 3'de gösterildiği gibidir:

$$Karmaşıklık = \frac{Mobilite(\ddot{x})}{Mobilite} \quad (3)$$

2.5.2. Bant Güçleri

Sinyalin belirli bant aralıklarındaki güç dağılımı, Fourier Dönüşümü yardımıyla bulunabilir. x_k bir zamansal örnek sinyali, b_0 alt bant genişliği, b_1 üst bant genişliği ve $X(f)$ Fourier Dönüşümü ise sinyalin bant gücü P_B aşağıda gösterildiği şekilde hesaplanır.

$$X(f) = \sum_{t=1}^T x_k e^{-j2\pi ft/T} \quad (4)$$

$$P(f) = |X(f)|^2 \quad (5)$$

$$P_B = \sum_{b_0}^{b_1} P(f) \quad (6)$$

Öznitelik seçiminde kullanılan frekans aralıkları teta, alfa ve beta alt bantları için sırasıyla 4-8 Hz, 8-13 Hz ve 13-30 Hz aralığındadır.

2.5.3. Hilbert Dönüşümü

Zamanla değişen bir $x(t)$ sinyalinde, frekans işaretine bağlı olarak fonksiyonun her frekansında ± 90 derece faz kaymasını gerçekleştirir.

Bir $x(t)$ sinyalinin, Hilbert Dönüşümü aşağıdaki denklem 7’de gösterilmiştir:

$$\text{Hilbert Dönüşümü } \{x(t)\} = \hat{x}(t) = x(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(u)}{t-u} du \quad (7)$$

Hilbert dönüşümü yukarıda denklemde görüldüğü gibi $x(t)$ sinyalinin $\frac{1}{\pi t}$ ile konvolüsyon işlemi yapılmasıdır. Dönüşüm sonucu oluşan $\hat{x}(t)$ karmaşık bir sayıdır. Sinyalin gerçek kısmını a ve sanal kısmını ise b temsil etmek üzere işaret denklem 8 ile gösterilmektedir.

$$\hat{x}(t) = a + jb \quad (8)$$

2.5.4. Hızlı Walsh-Hadamard Dönüşümü

Fourier dönüşümünün genelleştirilmiş bir versiyonu olan bu dönüşüm, sinyal işleme uygulamalarında kullanılır.

$2^m \times 2^m$ Hadamard matrisi, H_m ($H_0 = 1$ ve $m > 0$ için) aşağıdaki denklem 9 ile ifade edilmektedir.

$$H_m = \frac{1}{\sqrt{2}} \begin{pmatrix} H_{m-1} & H_{m-1} \\ H_{m-1} & -H_{m-1} \end{pmatrix} \quad (9)$$

Dönüşümden elde edilecek olan çıkış sinyali Y , bu matris ile giriş sinyalinin çarpılmasıyla elde edilir:

$$Y = H_m X \quad (10)$$

2.5.5. Willison Genliđi

Sinyal genliđinin belirtilen bir eřik (threshold) deđeri ile karřılařtırılıp, üzerindeki genliklerinin sayılmasıyla bulunur. N sinyal uzunluđu ve x_k da k .iřareti temsil ederse Willison Genliđi (WG) denklem 11’de gsterildiđi gibi hesaplanır:

$$WG = \sum_{k=1}^N |x_k - x_{k+1}| \quad (11)$$

Yukarıdaki eřitlikte ifade eřik deđerinden bykse 1 deđerini retir.

2.5.6. Modifiye Sıfır Geiř Sayısı

Sinyalin sıfır noktasından geiř sayısıdır. Bu hesaplama orđinalde denklem 12 de yazılan řekilde bulunabilir. N veri sayısı, x_i ise i .veridir.

$$SGS = \sum_{i=1}^N \text{sign}(-x_i x_{i+1}) \quad (12)$$

$$\text{sign}(x) = \begin{cases} 1, & x > 0 \\ 0, & \text{diđer} \end{cases} \quad (13)$$

Modifiye edilmiř srmnde ise kaynaklanan grltnn azaltılması iin bir eřik deđer i dahil edilmiřtir. Eřik deđer i T ise x_k sinyali iin $MSGS$ ařađıdaki řekilde hesaplanır [48].

Ařađıdaki eřitliklerin birinin sađlanması durumunda, 1 deđerini retir.

$$MSGS = x_k > T \text{ ve } x_{k+1} < T \text{ veya } x_k < T \text{ ve } x_{k+1} > T \quad (14)$$

$$T = 4 \left(\frac{1}{10} \sum_{i=1}^{10} x_i \right) \quad (15)$$

2.5.7. Modifiye Mutlak Değer Ortalama

Bu yöntem ortalama mutlak değer ortalamasının (*MDO*) uzantısıdır. *MDO*'nun etkisini geliştirme amacıyla denkleme w_i parametresi eklenmesiyle elde edilmiştir. x_i i.veriyi temsil edecek şekilde *MDO* aşağıdaki şekilde hesaplanır [49]:

$$MDO = \frac{1}{N} \sum_1^N |x_i| \quad (16)$$

Eğer w_i denklem 16'da verilen gibi ise modifiye mutlak değer ortalama (*MMDO*) denklem 17'deki ifade edilir:

$$MMDO = \frac{1}{N} \sum_1^N |x_i| w_i \quad (17)$$

$$w_i = \begin{cases} 1 & \text{eğer } 0.25N \leq i \leq 0.75N \\ 0.5 & \text{diğer seçeneklerde} \end{cases} \quad (18)$$

2.6. Parçacık Sürü Optimizasyonu

Parçacık Sürü Optimizasyonu (PSO), sürü halinde hareket eden hayvanların sosyolojik davranışlarından esinlenerek geliştirilmiş popülasyon temelli bir optimizasyon algoritmasıdır [50]. Algoritmanın temelinde, kuş ve balık gibi hayvan sürülerinin yiyecek bulma veya çevre şartlarına adaptasyon konularında sergiledikleri davranışların, sürünün diğer bireylerini de etkileyip amaçlarına daha kolay ulaşmaları mantığı vardır.

PSO algoritmasında bireylerin bulunduğu bir popülasyon yani sürü ve bu sürünün her bir bireyi olan parçacıklar bulunmaktadır. Her bir birey (parçacık) optimizasyon probleminin optimum veya ona yakın çözümünü sunmaya çalışır. Bu parçacıkların her biri kendi pozisyonlarını sürüdeki en iyi pozisyona sahip parçacığa göre ayarlar ve kendinin bir önceki tecrübesinden de faydalanır. Bu sayede, parçacıklar her hareketinde eskiye göre daha iyi bir konuma gelirler. Kısaca PSO da temel amaç; sürüdeki parçacıkların pozisyonunu, sürünün en iyi pozisyonuna sahip parçacığına yaklaştırmaktır.

Her parçacık için yeni hız ve yeni pozisyonları sırasıyla 19 ve 20 denklemleri kullanılarak hesaplanır:

$$v_i(t+1) = wv_i(t) + c_1r_1[p_{best} - x_i(t)] + c_2r_2[g_{best} - x_i(t)] \quad (19)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (20)$$

Denklem 19 ve 20’de kullanılan değişkenlerin tanımı aşağıda gösterildiği gibidir:

i : Parçacık numarası

w : Eylemsizlik faktörü

$v_i(t)$: i . parçacığın mevcut hızı

$x_i(t)$: i . parçacığın mevcut pozisyonu

c_1 : Parçacığa bağlı faktör

c_2 : Sürüye bağlı faktör

r_1, r_2 : Rasgele üretilen değerler

p_{best} : Parçacığın kendi en iyi değeri (Personal best)

g_{best} : Tüm parçacıkların en iyi değeri (Global best)

Değişken c_1 ve c_2 sırasıyla parçacığın kendi ve sürünün en iyi pozisyonunun yönüne doğru hızlandırma katsayıları olarak da ifade edilebilir ve bu kat sayılar bir iterasyon için parçacığın adım büyüklüğünü belirler. Bu değerler $0 < c_1, c_2 \leq 2$ olacak şekilde seçilir. Eylemsizlik faktörü olan w ise genellikle 0.8 ve 1.2 arasında seçilir. Yüksek değerlerin seçilmesi arama uzayının büyümesini ve çözüme geç ulaşmamızı sağlar. $v_i(t)$ değeri yani parçacığın mevcut hızı; parçacığın arama uzayından uzaklaşmaması için $[-v_{max}, v_{max}]$ olarak seçilen maksimum hız değerlerinin arasında sınırlandırılır. Yukarıda bahsedilen bir başka değişken olan r_1 ve r_2 de $[0, 1]$ arasında seçilmiş rasgele sayılardır. PSO algoritmasının uygulama adımları aşağıda kısaca açıklanmıştır:


Başlangıç sürüsünün oluşturulması: Her parçacık için pozisyon $x_i(t)$ ve hız değerleri $v_i(t)$ rasgele üretilir ve gerekli parametreler (c_1, c_2, w, r_1, r_2) belirlenerek çözümü arayacak başlangıç sürüsü oluşturulur. Parçacıklar için p_{best} değeri olarak geçerli pozisyonları atanırken, o anda en iyi değeri veren parçacık pozisyonu ise g_{best} olarak atanır.

Uygunluk değerlerinin hesaplanması: Uygunluk fonksiyonu tüm parçacıklar için hesaplanır. Parçacıkların çözüme yaklaşmasına göre p_{best} ve g_{best} değeri güncellenir. Yeni hesaplanan değer parçacığın kendi değerinden iyi ise eski değeri, yeni p_{best} ile

değiştirilir. Aynı şekilde yeni p_{best} değerleri içinde g_{best} değerinden daha iyi bir değer varsa, yeni g_{best} bu değer olur.

Parçacıkların yeni pozisyonlarının belirlenmesi: Parçacıkların yeni hız ve pozisyonları sırasıyla 19 ve 20 denklemleri kullanılarak yenilenir. Güncelleme işleminden sonra tekrar uygunluk fonksiyonu kullanılarak çözüme ne kadar yaklaşıldığı kontrol edilir.

Sonlandırma kriteri: Optimizasyon algoritması sonlandırma kriterine ulaşıncaya kadar devam eder. Eğer istenilen şartlara ulaşılmadıysa 1.adımdan itibaren tekrar devam eder ve şartlar sağlanana kadar devam eder. PSO algoritmasının akış diyagramı Şekil 9'da verilmiştir.




Şekil 9. PSO tabanlı öznitelik seçim algoritması

Algoritmada kısaca, sürüdeki tüm parçacıklar belirlenen bir uygunluk fonksiyonuyla test edilir. Sonlandırma kriterinin sağlanması çözümün optimum olduğu anlamına gelir ve parçacıklar arasında çözüme en yakın yani en iyi değeri verenlerin seçimi yapılır.

2.7. Sınıflandırma Yöntemleri

2.7.1. k En Yakın Komşuluk Yöntemi (k-EYK)

Sınıflandırılacak olan etiketsiz denemelerin, k tane en yakın komşusunun durumlarına göre sınıfının tayin edilmesi yöntemidir [51]. Kullanım kolaylığı ve sade anlaşılabilir olması açısından oldukça popüler bir algoritmadır. Etiketli bilinmeyen denemelerin sınıflandırılması, özellikleri çıkarılarak oluşturulan sınıfı bilinen vektörler sayesinde yapılmaktadır.



Şekil 10. k en yakın komşuluk yöntemi ile sınıflandırma

Şekil 10’da “?” işareti ile gösterilen yeni test örneği sınıflandırılmak istenmektedir. Görüldüğü üzere kırmızı yıldız ile gösterilenler SINIF 1’e ait iken, yeşil üçgen ile temsil edilenler SINIF 2’e aittir. $k=3$ ve $k=7$ de bu yöntem için seçilen en yakın komşu değerini göstermektedir.

İlk durum $k=3$ için; yeni test örneğine en yakın noktalarının iki yeşil üçgen olması bu örneğin yeşil üçgen yani SINIF 1’e atanması gerektiğini belirtir. $k=7$ durumunda ise; en yakın yedi komşudan dördünün kırmızı yıldız olması sebebiyle, bu örneğin SINIF 2’e atanması gerektiğini belirtir.

k-EYK sınıflandırıcısının performansında; belirlenecek “k” değeri ve örneğe en yakın komşuların seçilmesinde kullanılacak uzaklık hesaplama yöntemi bu algoritmanın performansını önemli derecede etkiler.

Yeni sınıfı belirleyecek olan k tane en yakın komşu uzaklığının hesaplanmasında birkaç uzaklık ölçütü kullanılır. Bunlara Öklid, Manhattan ve Minkowski uzaklıklarını örnek verebiliriz. Bu çalışmada, sık sık kullanılan Öklid uzaklığı seçilmiştir.

Denklem 21’de n tane x ve y noktaları arasındaki Öklid uzaklığının hesaplanması gösterilmektedir:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (21)$$


Bu yöntemde belirli sabit bir k değeri yoktur. Bu yüzden farklı k değerlerinin denenip optimal bir k değerinin bulunması gerekmektedir. En uygun k parametresinin seçilmesi için birçok yöntem mevcut olup, en çok tercih edilen yöntemlerden istatistiksel bir yöntem olan çapraz doğrulamadır.

Tez çalışmasında en iyi k parametresi için rastgele alt örnekleme çapraz doğrulamadan (random subsampling cross validation) yararlanılmıştır. Bu modelde, veri seti rastgele olacak şekilde yarıya bölünüp hesaplanmıştır. En iyi k seçiminde validasyon sonucunda en yüksek doğruluğu veren k seçilmiştir.

2.7.2. Destek Vektör Makineleri Yöntemi (DVM)

Destek vektör makineleri, parametrik olmayan ve istatistiksel bir öğrenme teorisine bağlı olarak geliştirilen bir sınıflandırma metodudur [52]. DVM algoritmaları, birçok bilim dalında veri setlerinin sınıflandırılmasında kullanılmaktadır. Destek vektör makineleri, hiper düzlemler veya karar sınırlarının belirlenmesiyle birlikte iki sınıfa ait verileri birbirinden ayırt etmek için kullanılır [53]. Bu algorithmada temel amaç, sınıfları birbirinden optimal şekilde ayıracak hiper düzlemini elde etmek yani sınıfların destek vektörlerinin arasındaki uzaklığın maksimum edilmesidir. Yüksek doğruluk oranına sahip olması, uygulanmasının kolay olması ve çok sayıda değişkenle çalışabilmesi bu yöntemin önemli avantajlarındandır.

Başlangıçta iki sınıflı veriler için tasarlansa da daha sonra çok sınıflı veriler için de kullanılması için geliştirilmiştir. İki sınıflı verilerde, doğrusal olarak ayrılan bir veri seti olduğu için veri setini ayıran sonsuz sayıda hiper düzlem olmasına rağmen maksimum sınıra sahip sadece bir hiper düzlem vardır [54].



Şekil 11. Destek vektör makineleri yöntemi ile sınıflandırma

Şekil 11’de iki sınıflı bir örnek veri seti için hiper düzlem ve destek vektörleri gösterilmektedir. SINIF 1 ve SINIF 2 için sınırlar üzerinde bulunan ve sınır genişliğini sınırlandıran noktalar (bu örnekte, bir kırmızı yıldız, iki yeşil üçgen) destek vektörleri olarak adlandırılmaktadır. Sınırlar arasında kalan çizgi ise optimum hiper düzlemdir.

2.7.3. Doğrusal Ayırma Analizi Yöntemi (DAA)

Doğrusal ayırma analizi, hem veri boyutu azaltılmasında hem de veri sınıflandırmasında sıklıkla kullanılan bir yöntemdir. Sınıfların dağılımına göre ortalama değerleri arasındaki farklılığı kullanarak sınıfları birbirinden ayırmak için kullanılır. Bu analizde temel amaç; herhangi bir veri kümesi için sınıflar arası uzaklığı maksimize ederken, sınıf içi uzaklığı minimize etmektir [55].

DAA algoritmasında sınıflar arası farkların belirlenmesinde ayırıcı fonksiyonlar kullanılır. Bu fonksiyonların kullanımı ile etiketsiz olan verilerin sınıflandırmaları gerçekleştirilir. İki sınıflı verilerin sınıflandırma problemlerinin çözümü için kullanılan doğrusal ayırıcı fonksiyonu denklem 22’de verilmiştir.

$$y(x) = w^T x + b \quad (22)$$

Denklem 22’de belirtilen w model parametrelerini ve b sapma değerlerini ifade etmektedir. Bu değerler sırasıyla denklem 23 ve 24’de gösterilmiştir.

$$w = \Sigma^{-1}(\mu_1 - \mu_2) \quad (23)$$


$$b = -\frac{1}{2}w^T(\mu_1 + \mu_2) \quad (24)$$

Denklem 24’de verilen μ_1 ve μ_2 sırasıyla birinci ve ikinci sınıfın ortalama değeri vektörünü belirtir. Giriş vektörü x için $y(x)$ değeri ayırıcı hiperdüzleme olan uzaklıkla tanımlanır. $y(x) = 0$ durumu karar sınır çizgisini gösterirken, $y(x) \geq 0$ durumunda x giriş vektörü birinci sınıf ve diğer durumlarda ise x giriş vektörü ikinci sınıf olarak etiketlenir.

2.7.4. Torbalama Karar Ağaçları (TKA)

Karar ağaçları algoritması, sınıflandırma modelleri arasında yaygın olarak kullanılan ve olayları ağaç yapısı ile temsil eden bir sınıflandırıcıdır. Bu ağaç yapısı; karar düğümleri, dalları ve yapraklarından oluşur. Kolaylıkla anlaşılabilen kurallar oluşturmaları ve yorumlanması açısından da kolay olması sebebiyle popülerliği sürmektedir [56]. Kısaca, bir karar ağacı temel olarak ağacı başlatan bir kök düğümü, giriş verilerinin test edildiği iç düğümler ve verilerin sınıf etiketlerini temsil eden yaprak düğümlerden oluşur.

Topluluk öğrenmesi yöntemlerinde ise çok sayıda model bir araya gelir ve bu modellerden daha doğru ve güçlü sonuçlar elde edilmesi amacıyla birleştirilir. Topluluk öğrenme yöntemlerinden biri olan torbalama (bagging), sınıflandırıcı topluluğu oluşturmak için temel öğrenme algoritmalarının birleştirilmesi işlemine dayanır [57]. Şekil 12’de klasik bir topluluk öğrenmesi yönteminin işlem aşamaları gösterilmiştir.




Şekil 12. Topluluk öğrenmesi yöntemi

Torbalama yönteminde, veri seti rasgele olarak alt kümelerle ayrılır ve birbirinden bağımsız yapıların kurulmasıyla modeller paralel olarak eğitilir. Rasgele eğitim setlerinin oluşturulmasıyla farklı sonuçlar elde ederek başarıyı yükseltebilmektir. Her bir modelden çıkan sonuçlar da ağırlıklı oylama ile birleştirilir. Rasgele orman ve torbalama karar ağaçları bu yöntemle örnek algoritmalarıdır.

Torbalama karar ağaçları (TKA) yönteminde, birçok karar ağacı sonuca ulaşmak için kullanılır. Topluluk yöntemi olarak torbalama seçildiği için paralel karar ağaçlarının birleştirilmesiyle elde edilir. Birkaç modelle çalıştığı için de tekil karar ağaçlarına göre daha başarılı sonuç verirler.

2.8. Kullanılan Yöntemin Akış Diyagramı

Yapılan çalışmada “*Clinical BCI Challenge-WCCI 2020*” veri setine uygulanan yöntemin akış şeması Şekil 13’de gösterilmiştir. Bu şekilde gösterilen adımların açıklamaları aşağıda sırasıyla yapılmıştır:



Şekil 13. Kullanılan yöntemin akış diyagramı

En Etkin Elektrot veya Elektrotlar: Kişilerin EEG sinyallerinin kaydında kullanılan 12 elektrotun her biri için başarımlar hesaplanmıştır. Yukarıda bahsedilen öznitelik çıkarma yöntemlerinin tümü kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Dört farklı sınıflandırıcı kullanılarak bulunan sonuçlara göre en iyi SD sağlayan elektrot veya elektrotlar etkin olarak seçilmişlerdir. k-EYK, DAA, DVM ve TKA teknikleriyle çıkan sonuçlar sırasıyla Ek Tablo 5, 6,7 ve 8’de detaylı bir şekilde verilmiştir.

Öznitelik Çıkarımı: Kullanılan öznitelik çıkarma yöntemlerinden ilki sinyal işleme uygulamalarında da kullanılan hızlı Walsh-Hadamard dönüşümüdür. Bu yöntemle elde edilen dönüşümün varyansının ve standart sapmasının hesaplanmasıyla bir deneme için iki adet öznitelik elde edilmiştir.

Kullanılan diğer bir yöntem de yine sinyal işleme alanında da tercih edilen Hilbert dönüşümüdür. Bu dönüşüm sonucunda ortaya çıkan karmaşık sayının gerçek kısmının varyansı ve standart sapması hesaplanmıştır. Bu dönüşümle de bir deneme için iki adet öznitelik çıkarımı sağlanmıştır.

Seçilen bir başka yöntem de aktivite, mobilite ve karmaşıklıkla oluşan Hjorth parametreleridir. Bu parametreler sayesinde bir deneme için üç adet öznitelik çıkarılmıştır.

Bant güçleri de bu çalışma için seçilen başka bir öznitelik çıkarma yöntemidir. Alt-üst bant sınır frekanslarının sırasıyla teta için 4-8 Hz, alfa için 8-13 Hz ve beta bandı için de 13-30 Hz olduğu yerlerde ilgili bant güçleri hesaplanmıştır. Bir deneme için çıkarılan üç adet öznitelik bulunmaktadır.

Willison genliği de seçilen yöntemlerden biridir. Eşitlik 1’deki ifadenin eşik değeri olarak bu çalışma için seçilen 0.01’den büyük olduğu durumlardaki sayısını belirtir. Bu yöntem ile de her deneme için bir adet öznitelik sağlanmıştır.

Diğer bir yöntem de sıfır geçiş sayısı metodunun geliştirilmiş bir versiyonu olan modifiye sıfır geçiş sayısı (MSGs) ile elde edilmiştir. Aslında EMG işaretlerinin sınıflandırılmasının artırılması için iyileştirilmiş ve önerilmiş bir yöntemdir [48]. Bu çalışmada EEG işaretlerinin sınıflandırılması için öznitelik seçim yöntemi olarak seçilmiş ve deneme başına bir adet öznitelik elde edilmiştir.

Seçilen son yöntemde ortalama mutlak değer ortalamasının etkisinin bir uzantısı olan modifiye mutlak değer ortalamadır (MMDO). Bu da MSGs gibi EMG sinyallerinin özelliklerinin seçimi ve sınıflandırılması amacıyla uygulanmıştır [49]. Kaydedilen sinyallerin öznitelik seçimi eşitlik 1 kullanılarak yapıp, bir deneme için bir adet öznitelik çıkarılmıştır.

Kısaca; seçilen öznitelik yöntemleriyle her bir EEG denemesi ve bir elektrot için 13 boyutlu öznitelik vektörleri oluşturulmuştur. Tablo 9’da verilen şekilde öznitelik yöntemlerinin her biri numaralandırılarak çalışmada detaylı bir şekilde işlenmiştir.

Tablo 9. Öznitelik çıkarım yöntemlerinin numaralandırılması

Öznitelik Seçim Yöntemi		Öznitelik Kodu
Hızlı Walsh-Hadamard Dönüşümü	Dönüşümün Varyansı	1
	Dönüşümün Standart Sapması	2
Hilbert Dönüşümü	Dönüşümün Gerçek Kısımının Varyansı	3
	Dönüşümün Gerçek Kısımının Standart Sapması	4
Hjorth Parametreleri	Aktivite	5
	Mobilite	6
	Karmaşıklık	7
Bant Güçleri	Alfa Bandı	8
	Beta Bandı	9
	Teta Bandı	10
Willison Genliği		11
Modifiye Sıfır Geçiş Sayısı		12
Modifiye Mutlak Değer Ortalama		13

PSO ile Etkin Özniteliklerin Seçimi: Bu çalışmada sağ veya sol elin kavramayı deneme hareketinin hayali sırasında kaydedilen veri setinden çıkarılan özniteliklerin arasından etkin olanların kararında parçacık sürü optimizasyonu (PSO) kullanılmıştır. Kullanılan algoritmanın değişkenlerinin değerleri aşağıda verildiği gibidir:

Parçacığa bağlı faktör $c_1 = 2$, sürüye bağlı faktör $c_2 = 2$, eylemsizlik faktörü $w = 0.9$, maksimum hız $v_{max} = 0.5$, çözümü arayacak parçacık sayısı 10 ve iterasyon sayısı ise 100 seçilmiştir.

Optimizasyon çözümü için seçilen iterasyon sayısı kadar parçacıkların hız ve pozisyon bilgileri güncellenir ve uygunluk değerleri hesaplanır. Belirli iterasyon sonucunda optimum çözümü sağlayan bu parçacıklar aynı zamanda algoritma tarafından seçilen özniteliklerdir. Fakat bu seçilen öznitelikler her koşum da farklı olmaktadır ve bu da test verisinin sınıflandırma sonuçlarını etkilemektedir. Çözüm olarak uygulanan algoritma 100 defa koşturulmuştur ve çıkan sonuçlar her koşum için kaydedilmiştir.

Sonuçlara göre bazı öznitelikler çok baskın olarak seçilirken, bazılarının seçimi az olmuştur. Az seçilenlerin algoritmaya etkisinin az veya hiç olmamasından dolayı, bu çalışmada sonuçlara göre en fazla seçilen veya en fazla seçilenin yarısından az olmamak kaydıyla seçilen tüm öznitelikler etkin öznitelik olarak değerlendirilmiştir.

Uygunluk fonksiyonu için seçilen sınıflandırıcıya bağlı olarak ortaya çıkan hata oranı (error rate) ayarlanmıştır. Sınıflandırıcı olarak k-EYK (k değeri 5 olarak), DAA, DVM ve TKA yöntemleri kullanılmıştır ve sınıflandırıcılara bağlı etkin olan öznitelikler sırasıyla Ek Tablo 1, 2, 3 ve 4’de verilmiştir.

Sınıflandırma: Sınıflandırma aşamasında k-EYK, DAA, DVM ve TKA teknikleri kullanılmıştır. k-EYK sınıflandırıcısında uzaklık parametresi olarak Öklid uzaklığı seçilmiş olup, en uygun k değeri için rastgele alt örnekleme çapraz doğrulamadan yararlanılmıştır. Bu yöntemle 100 koşum sonucu en iyi başarımı veren k değeri seçildikten sonra her koşum için hesaplanan doğrulukların ortalaması bu sınıflandırıcı için sunulan sonuçlardır. Ayırma analizi yöntemi için fonksiyon doğrusal (linear) seçilirken, DVM algoritmasında ise çekirdek fonksiyon olarak gaussian ile hesaplamalar yapılmıştır. TKA yönteminde ise topluluk yöntemi olarak torbalama (bagging), öğrenme şekli karar ağaçları algoritması ve maksimum bölünme sayısı 50 olarak seçilmiştir. k-EYK algoritması gibi 100 koşum sonucunda çıkan sonuçların ortalaması çalışma için kaydedilmiştir.

3. BULGULAR

Yapılan tez çalışması için Şekil 13’de verilen algoritma yukarıda tanıtılan veri setine uygulanmıştır. Katılımcıların sağ ve sol el kavrama hareketinin hayaline dayalı EEG işaretleri için yapılan çalışmalar dört farklı sınıflandırıcı k-EYK, DAA, DVM ve TKA ile sınıflandırılmıştır.


Çalışmada kişiye göre farklı etkin elektrotların ve etkin özniteliklerin seçimi de önerilen yöntem bölümünde detaylıca anlatılmıştır. Kullanılan bu dört sınıflandırıcı için etkin elektrotların hangileri olduğu ayrı ayrı hesaplanmış ve sınıflandırıcı bazlı olarak bulunan sonuçlar sırasıyla Ek Tablo 5, 6, 7 ve 8’de sunulmuştur. Kişilere göre ayrı ayrı değerlendirilen en etkin elektrotların çıkarımında oluşan sonuca göre; çoğunluğunda en etkin olanlar seçilirken bazılarında ise en etkin iki elektrotun seçimi yapılmıştır. Aynı şekilde etkin özniteliklerin seçimi de uygulanan optimizasyon algoritması sayesinde yapılmış, yukarıda Tablo 9’da verilen şekilde numaralandırılan öznitelikler için çıkan sonuçlar da farklı sınıflandırıcılar için Ek Tablo 1, 2, 3 ve 4’de detaylıca gösterilmiştir. Tablolardaki sıralama en etkin olandan az etkine doğrudur. Yani tabloda verilenlerde öznitelik numarası birinci yazılan en etkin, diğerleri ise yöntem dahilinde seçilenlerdir.

Katılımcılar için ayrı olarak hesaplanan sınıflandırma doğruluğu başarıları aşağıda bölümlere ayrılarak detaylı olarak verilmiştir. Her bir kişi için dört farklı sınıflandırıcının performansları değerlendirilirken aynı zamanda tüm elektrot-tüm öznitelik, etkin elektrot-tüm öznitelik ve etkin elektrot-etkin öznitelik (önerilen) durumları karşılaştırılmıştır.

3.1. Katılımcı 1 İçin Elde Edilen Bulgular


Katılımcı 1 için kaydedilen EEG işaretleri için yapılan çalışmalarda sınıflandırma sonuçları karşılaştırıldığında en iyi sonucun; en etkin iki elektrot ve çıkarılan üç özniteliğin kullanımıyla %95.00 olarak DAA sınıflandırıcısı ile olduğu görülmüştür. Ayrıca Şekil 14’de verildiği gibi k-EYK, DVM ve TKA ile de sırasıyla %92.25, %87.50 ve %87.75 olarak yüksek bir SD elde edilmiştir. Yöntemin başarısını test etmek amacıyla etkin elektrotların, tüm özniteliklerle kullanıldığı durumda hesaplanmış ve k-EYK, DAA, DVM ve TKA için sırasıyla %88.25, %87.50, %72.50 ve %85.75 olarak bulunmuştur. Tüm

elektrot ve özniteliklerin kullanımında da aynı sınıflandırıcı sırasına göre %50.00, %70.00, %52.50 ve %50.00 SD hesaplanmıştır. Özellikle iyi bir sonuç veren k-EYK sınıflandırıcısı için kullanılan yöntemle tüm parametrelerin kullanıldığı durumdan %42,25 daha fazla SD başarısı sağlamıştır.



Şekil 14. Katılımcı 1 için sınıflandırma doğrulukları

Bu kişi için en yüksek sınıflandırma doğruluğunun elde edildiği durumda kullanılan etkin öznitelik yöntemlerinden çıkarılan test verisinin ve eğitim verisinin öznitelik vektörünün gösterimi de Şekil 15’de verilmiştir. Aşağıdaki şekilden de anlaşıldığı gibi seçilen öznitelikler test kümesi için iyi bir ayrılmaya sebep olmuşlardır.



Şekil 15. Katılımcı 1 için test ve eğitim verisinden çıkarılan etkin öznitelikler


En yüksek başarımın sağlandığı DAA sınıflandırıcısına ait karışıklık matrisi de Tablo 10’da verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin tamamı ve sol el kavrama hayalinde ise 18 deneme doğru sınıflandırılmıştır.

Tablo 10. Katılımcı 1 için DAA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	20	0
Sol El Kavrama Hayali	2	18


3.2. Katılımcı 2 İçin Elde Edilen Bulgular

Bu kişi için belirlenen yöntem (etkin elektrot-etkin öznelik) ile yukarıda bilgileri verilen dört sınıflandırıcı içinde ve aynı elektrot üzerinden Şekil 16’da belirtildiği gibi %92.50 olarak yüksek bir SD elde edilmiştir. Tüm özneliklerin kullanıldığı diğer durumlarda ise k-EYK, DAA, DVM ve TKA sınıflandırıcıları kullanılarak etkin elektrot ile sırasıyla %88.25, %92.50, %92.50 ve %92.50 olarak bulunurken, tüm elektrotlar ile yapılan çalışmada ise %58.50, %50.00, %60.00 ve %50.00 olarak bulunmuştur. Etkin elektrot kullanıldığı durumda DAA, DVM ve TKA sınıflandırıcıları için tüm öznelikler kullanıldığı zamanda dahi SD değeri aynı kalmıştır.



Şekil 16. Katılımcı 2 için sınıflandırma doğrulukları

Bu kişide en yüksek SD'nin elde edildiği birkaç durum olduğundan en etkin iki özneliğin kullanıldığı DVM sınıflandırıcısı için test ve eğitim kümesi için hesaplanan öznelikler Şekil 17'de gösterilmiştir. Şekil incelendiğinde özneliklerin dağılımının yine gayet ayrıştırılabilir ve yüksek başarımın beklenen bir sonuç olduğu görülmektedir.



Şekil 17. Katılımcı 2 için test ve eğitim verisinden çıkarılan etkin öznelikler


SD sonucuna göre en iyi değer sağlandığı durumdan biri olan DAA sınıflandırıcısına ait karışıklık matrisi de Tablo 11'de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sol el kavrama hayaline ait 20 denemenin tamamı ve sağ el kavrama hayalinde ise 17 deneme doğru sınıflandırılmıştır.

Tablo 11. Katılımcı 2 için DAA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	17	3
Sol El Kavrama Hayali	0	20


3.3. Katılımcı 3 İçin Elde Edilen Bulgular

Katılımcı 3 de en yüksek SD; k-EYK sınıflandırıcısıyla en etkin elektrot ve etkin dört öznitelik kullanılarak %82.50 olarak elde edilirken, DAA, DVM ve TKA için de sırasıyla %77.50, %70.00 ve %65.00 olarak hesaplanmıştır. En etkin bir elektrotun yanında tüm özniteliklerin seçildiği durumda ise; k-EYK için %76.50, DAA için %70.00, DVM için %67.50 ve TKA için de %58.00 olarak hesaplanmıştır. Kayıt yapılan tüm elektrotlar ile 13 özniteliğin hepsinin bir arada kullanıldığı durumda ise başarımlar DAA için %45.00 hesaplanıp %50.00 olası SD değerinin altına düşerken, k-EYK, DVM ve TKA için de sırasıyla %50.00, %55.00 ve %57.50 olarak elde edilmiştir. Hesaplanan tüm sonuçlar aşağıda Şekil 18’de grafiksel olarak gösterilmiştir. Kullanılan ve seçilen parametrelerle; k-EYK, DAA, DVM ve TKA için sırasıyla %32,50, %32,50, %15.00 ve %7.50 kadar SD artırılmıştır.



Şekil 18. Katılımcı 3 için sınıflandırma doğrulukları

Kişi 3 için en yüksek başarımın sağlandığı durum olan k-EYK sınıflandırıcısının en etkin üç özniteliğinin kullanılmasıyla hesaplanan test ve eğitim verisine dayalı öznitelikleri aşağıda Şekil 19’da verilmiştir. Test kümesinden çıkarılan öznitelikler aşağıda şekilden de açıkça görüldüğü gibi sınıf2 için çoğunlukla solda ve sınıf1 için de sağda kümelenmiştir.



Şekil 19. Katılımcı 3 için test ve eğitim verisinden çıkarılan etkin öz nitelikler

En yüksek başarının sağlandığı durum olan k-EYK sınıflandırıcısına ait karışıklık matrisi de Tablo 12’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin tamamı ve sol el kavrama hayalinde ise 13 deneme doğru sınıflandırılmıştır.


Tablo 12. Katılımcı 3 için k-EYK sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	20	0
Sol El Kavrama Hayali	7	13

3.4. Katılımcı 4 İçin Elde Edilen Bulgular


En yüksek SD k-EYK için seçilen en etkin elektrot ile %73.20 ve TKA yöntemi için de seçilen aynı elektrotla %67.50 olarak bulunurken, DAA ve DVM için aynı elektrot üzerinden %60.00 olarak hesaplanmıştır. DVM sınıflandırıcısı için tüm öz niteliklerin kullanıldığı iki durumda da %60.00 başarıma ulaşılmıştır. k-EYK, DAA ve TKA durumları için de SD etkin elektrot ile sırasıyla %60.25, %57.50 ve %66.00 bulunurken, tüm elektrot durumunda başarımlar %54.50, %45.00 ve %50.00 olarak daha az başarımlar sağlanmıştır. Bu kişi için SD’nin en fazla artırıldığı durum k-EYK sınıflandırıcısının kullanıldığı

durumdur ve %18.70 kadar başarımlar artırılmıştır. Şekil 20’de dört sınıflandırıcı sayesinde oluşan tüm durumların sonuçları gösterilmiştir.



Şekil 20. Katılımcı 4 için sınıflandırma doğrulukları

Hesaplanan test ve eğitim verisinin özniteliklerinin gösterilmesi için en yüksek doğruluğu veren k-EYK ile hesaplanan öznitelikler kullanılmıştır ve Şekil 21’de gösterilmiştir. Bu sınıflandırıcı için beş etkin özniteliğin, en etkin üç tanesi gösterim için seçilmiştir.



Şekil 21. Katılımcı 4 için test ve eğitim verisinden çıkarılan etkin öznitelikler


En yüksek başarımın sağlandığı durum olan k-EYK sınıflandırıcısına ait karışıklık matrisi de Tablo 13’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin 11’i ve sol el kavrama hayalinde ise 18 deneme doğru sınıflandırılmıştır.

Tablo 13. Katılımcı 4 için k-EYK sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	11	9
Sol El Kavrama Hayali	2	18


3.5. Katılımcı 5 İçin Elde Edilen Bulgular

Bu kişi ile ilgili yapılan çalışmalarda: TKA sınıflandırıcısı ile etkin parametreler kullanıldığı zaman %92.50 doğruluk elde edilirken, diğer durumlarda (tüm özniteliklerin kullanıldığı) ise %68.00 (etkin elektrot) ve %50.00 (tüm elektrot) ile elde edilmiştir. k-EYK sınıflandırıcısında bu üç durum için sırasıyla %87.25, %86.75 ve %62.50 değerleri hesaplanırken, DAA ile sırasıyla %67.50, %62.50 ve %60.00, DVM ile de yine sırasıyla %70.00, %62.50 ve %60.00 olarak bulunmuştur. Tüm durumlarda bulunan sonuçlar Şekil 22’de verilmiştir. Bu kişi için sonuçlara bakıldığında en başarılı sonucu veren TKA yöntemi diğer sınıflandırıcılardan %24.50 ve %42.50 kadar fazla başarım sağlamıştır.



Şekil 22. Katılımcı 5 için sınıflandırma doğrulukları

Hesaplanan test ve eğitim verisinin özniteliklerinin gösterilmesi için en yüksek doğruluğu veren TKA ile hesaplanan öznitelikler kullanılmıştır ve Şekil 23’de gösterilmiştir. Bu sınıflandırıcı için özniteliklerin en etkin üç tanesi algoritmayla seçilmiştir. İki sınıfın ayrımı da aşağıdaki şekildeki test verisi kısmından da anlaşılabilir gibi gayet iyi sağlanmıştır.



Şekil 23. Katılımcı 5 için test ve eğitim verisinden çıkarılan etkin öznitelikler


Doğrulukta en yüksek değerin sağlandığı durum olan TKA sınıflandırıcısına ait karışıklık matrisi de Tablo 14’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin tamamı ve sol el kavrama hayalinde ise 17 deneme doğru sınıflandırılmıştır.

Tablo 14. Katılımcı 5 için TKA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	20	0
Sol El Kavrama Hayali	3	17


3.6. Katılımcı 6 İçin Elde Edilen Bulgular

Katılımcı 6 için sınıflandırıcı performansına bakıldığında yine Katılımcı 5 gibi en yüksek doğruluk %82.00 ile TKA tarafından sağlanmıştır. Bu sınıflandırıcıda etkin bir elektrot varken, k-EYK ve DAA için en etkin bir elektrot ve DVM için de etkin olan iki elektrot bulunmaktadır. k-EYK, DAA ve DVM için de sırasıyla etkin parametrelerle %80.75, %77.50 ve %65.00 sonuçlarına ulaşılmıştır. Şekil 24’de gösterildiği üzere tüm özniteliklerin kullanımında k-EYK, DAA, DVM ve TKA başarıları %46,75, %62,50, %60 ve %57.50 olurken, kayıt yapılan elektrotların tümü de kullanılırsa bu durumda SD başarısı %43.00, %55.00, %50.00 ve %40.00 seviyelerine gerilemiştir. Başarımda en iyi durumun sağlandığı TKA ile aynı zamanda üçüncü duruma göre de en iyi başarıım artışı %42.00 kadar artırılarak sağlanmıştır.



Şekil 24. Katılımcı 6 için sınıflandırma doğrulukları

Kişi 6 için en yüksek başarımın sağlandığı durum olan TKA sınıflandırıcısının etkin iki özniteliğinin kullanılmasıyla hesaplanan test ve eğitim verisine dayalı öznitelikleri aşağıda Şekil 25’de verilmiştir. Test kümesinden çıkarılan öznitelikler şekilde de verildiği gibi sınıfsal olarak iyi bir şekilde ayrılmışlardır.



Şekil 25. Katılımcı 6 için test ve eğitim verisinden çıkarılan etkin öznitelikler

En yüksek başarımın sağlandığı durum olan TKA sınıflandırıcısına ait karışıklık matrisi de Tablo 15’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin 17 tanesi ve sol el kavrama hayalinde ise 15 deneme doğru sınıflandırılmıştır.


Tablo 15. Katılımcı 6 için TKA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	17	3
Sol El Kavrama Hayali	5	15

3.7. Katılımcı 7 İçin Elde Edilen Bulgular


Bu katılımcıya ait verilerle yapılan çalışma sonucunda; en yüksek başarım yine TKA ile %81.50 olarak elde edilmiştir. Bu başarıma yakın bir sonuç sağlayan k-EYK ve DAA sınıflandırıcısıyla farklı etkin elektrotlarla ama aynı dört etkin özniteliğin kullanılmasıyla %77.50 olarak hesaplanmıştır. Şekil 26’da gösterildiği gibi DVM de ise etkin iki elektrotun kullanımı ile en yüksek SD %72.50 olarak elde edilmiştir. k-EYK,

DAA, DVM ve TKA sınıflandırıcıları ile etkin elektrot ve tüm öznitelik kullanımında %52.00, %52.50, %52.50 ve %52.50 gibi birbirine yakın değerler bulunurken, tüm elektrotların dahil edilmesiyle de %50.00, %50.00, %52.50 ve %50.00 olarak yine yakın başarı sonuçlarına ulaşılmıştır. k-EYK ve DAA ile son duruma göre %27.50, DVM ile %20.00 ve son olarak TKA ile de %31.50 doğruluk artışı kullanılan yöntem dahilinde sağlanmıştır.



Şekil 26. Katılımcı 7 için sınıflandırma doğrulukları

En yüksek sınıflandırma doğruluğunu veren iki yöntemden biri olan k-EYK için seçilen dört özniteliğin en etkin olan üç tanesi kullanılarak test ve eğitim verisinden elde edilen öznitelik vektörü Şekil 27’de verilmiştir.



Şekil 27. Katılımcı 7 için test ve eğitim verisinden çıkarılan etkin öznitelikler


Başarı bakımından en yüksek değere sahip sınıflandırıcı olan TKA sınıflandırıcısına ait karışıklık matrisi de Tablo 16’da verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin 17 tanesi ve sol el kavrama hayalinde ise yine 17 deneme doğru sınıflandırılmıştır.

Tablo 16. Katılımcı 7 için TKA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	17	3
Sol El Kavrama Hayali	3	17


3.8. Katılımcı 8 İçin Elde Edilen Bulgular

Kişi 8’in verileriyle yapılan çalışmada; Şekil 28’de de verildiği üzere aynı en etkin özneliğin yanında farklı etkin özneliklerle elde edilen SD sonuçları k-EYK için %85.50 iken DAA ve DVM kullanılmasıyla %82.50 ve TKA ile de %80.00 hesaplanmıştır. Üç sınıflandırıcı (k-EYK, DAA ve DVM) için aynı elektrot kullanılırken, etkin olanların yerine tüm özneliklerin dahil edilmesiyle de yine aynı sıraya göre %60.75, %57.50 ve %72.50 elde edilmiştir. TKA yönteminde bu durum için farklı elektrot kullanılarak %70.00 sonucu bulunmuştur. Son durum olan tüm elektrotların kullanımının sağlanmasıyla da k-EYK, DAA, DVM ve TKA için de %50.50, %47.50, %70.00 ve %52.50 sonuçları bulunmuştur. Yöntem sayesinde k-EYK ve DAA için son duruma göre en yüksek başarımla karşılaştırıldığında %35.00’lik bir artış olurken, DVM için %12.50 ve TKA için de %27.50 daha başarılı sonuç sağlanmıştır.



Şekil 28. Katılımcı 8 için sınıflandırma doğrulukları

Kişi 8 için en yüksek başarımın sağlandığı durum olan k-EYK sınıflandırıcısının etkin üç özneteliğinin kullanılmasıyla hesaplanan test ve eğitim verisine dayalı öznetelikleri aşağıda Şekil 29’da verilmiştir. Test kümesinden çıkarılan öznetelikler şekilde de verildiği gibi sınıf1 çoğunlukla alt taraflarda toplanırken, sınıf2 üst taraflarda toplanmıştır.



Şekil 29. Katılımcı 8 için test ve eğitim verisinden çıkarılan etkin öznetelikler


SD başarısında en yüksek değere sahip olan k-EYK sınıflandırıcısına ait karışıklık matrisi de Tablo 17’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin 16 tanesi ve sol el kavrama hayalinde ise 18 deneme doğru sınıflandırılmıştır.

Tablo 17. Katılımcı 8 için k-EYK sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	16	4
Sol El Kavrama Hayali	2	18


3.9. Katılımcı 9 İçin Elde Edilen Bulgular

Katılımcı 9 ile yapılan çalışmada; en yüksek SD başarısı TKA ile üç etkin özniteliğin kullanılmasıyla %92.00 olarak hesaplanmıştır. Bu başarıma yakın bir oran sağlayan DAA ve DVM sınıflandırıcıları ile de aynı etkin elektrotun sırasıyla üç ve iki etkin elektrotun kullanımıyla %85.00 olarak sağlanmıştır. k-EYK'nin en yüksek başarımı ise aynı etkin elektrot ile %83.50 olarak hesaplanmıştır. Bu dört sınıflandırıcı için Şekil 30'da belirtildiği gibi etkin elektrot-tüm öznitelik birleşimiyle k-EYK, DAA, DVM ve TKA için sırasıyla %46.25, %55.00, %60.00 ve %59.50 doğruluğu elde edilirken, tüm parametrelerin kullanımında ise başarımlar %43.00, %50.00, %50.00 ve %55.00 olarak bulunmuştur. Dört farklı sınıflandırıcıyla elde edilen en iyi SD sonuçlarının son durumdaki sonuçlara göre k-EYK için %40.50, DAA ve DVM için %35.00 ve son olarak TKA yöntemi için de %37.00 kadar artırılması sağlanmıştır.



Şekil 30. Katılımcı 9 için sınıflandırma doğrulukları

En yüksek sınıflandırma doğruluğunu veren TKA için seçilen en etkin iki öznitelik kullanılarak test ve eğitim verisinden elde edilen öznitelik vektörü Şekil 31'de verilmiştir.



Şekil 31. Katılımcı 9 için test ve eğitim verisinden çıkarılan etkin öz nitelikler

Başarımın en yüksek olduğu durum olan TKA sınıflandırıcısına ait karışıklık matrisi de Tablo 18’de verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin tamamı ve sol el kavrama hayalinde ise 17 deneme doğru sınıflandırılmıştır.


Tablo 18. Katılımcı 9 için TKA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	20	0
Sol El Kavrama Hayali	3	17

3.10. Katılımcı 10 İçin Elde Edilen Bulgular


Bu kişiye ait verilerle yapılan çalışmada etkin elektrot-etkin öz nitelik birleşimiyle en yüksek başarımla yine TKA yöntemi ile %90.00 olarak hesaplanmıştır. Diğer sınıflandırıcılarda; k-EYK sayesinde %88.25 olarak hesaplanırken, DAA ve DVM ile de %87.50 olarak yüksek bir doğruluk elde edilmiştir. Bu seçilen elektrotların tüm öz niteliklerle beraber kullanımında da TKA ile SD değeri %87.50 ve k-EYK ile %41.25 bulunurken, diğer sınıflandırıcılar olan DAA ve DVM yöntemleriyle yine aynı sonuç

olarak %85.00 olarak hesaplanmıştır. Etkin elektrot yerine tümünün kullanıldığı durumda ise TKA %85.00, k-EYK %41.00 ve DAA %80.00 sonuçlarını sağlayıp başarımı düşürürken, DVM sınıflandırıcısında sonuç aynı kalmıştır. Doğrulukta en büyük farkın olduğu sınıflandırıcı k-EYK olmuştur ve yöntemin son duruma göre başarısı %47,25 kadar artmıştır. Şekil 32’de tüm sınıflandırıcılar için üç durum için sonuçlar verilmiştir.



Şekil 32. Katılımcı 10 için sınıflandırma doğrulukları

Kişi 10 için en yüksek başarımın sağlandığı durum olan TKA sınıflandırıcısının etkin iki özneliğinin kullanılmasıyla hesaplanan test ve eğitim verisine dayalı öznelikleri aşağıda Şekil 33’de verilmiştir. Test kümesinden çıkarılan öznelikler, özellikle sınıf1’e ait veriler kümelenmiş halde yerleşmişlerdir.



Şekil 33. Katılımcı 10 için test ve eğitim verisinden çıkarılan etkin öznelikler

En yüksek SD başarısının sağlandığı durum olan TKA sınıflandırıcısına ait karışıklık matrisi de Tablo 19’da verilmiştir. Tablodan da görüldüğü üzere toplam 40 denemeden, sağ el kavrama hayaline ait 20 denemenin 19 tanesi ve sol el kavrama hayalinde ise 18 deneme doğru sınıflandırılmıştır.

Tablo 19. Katılımcı 10 için TKA sınıflandırıcısının karışıklık matrisi

Toplam 40 Deneme	Sağ El Kavrama Hayali	Sol El Kavrama Hayali
Sağ El Kavrama Hayali	19	1
Sol El Kavrama Hayali	2	18

4. SONUÇLAR VE TARTIŞMA

Beyin bilgisayar arayüzleri (BBA) kişilerin kas sistemini kullanmadan yalnızca beyin aktiviteleri yoluyla bir bilgisayarı, protezi ya da elektromekanik bir kolu kullanmalarını olanaklı hale getirirler. BBA sistemlerinin geliştirilmesindeki en önemli sebeplerinden biri amiotrofik lateral skleroz (ALS) veya felç gibi hastalığa sahip olan kişilerin yani beyinlerindeki sinir hücrelerinin hasar görmesi nedeniyle uyarılara karşı herhangi bir kas hareketinde bulunamayan insanların beyin aktiviteleri sayesinde iletişim kurularak rehabilitasyon süreçlerine katkı sağlamalarıdır. Yani yeni analiz yöntemlerinin geliştirilmesi bu tarz motor sinir bozukluğu olan hastaların dış dünyayla iletişim kurmalarında ve onların yaşam standartlarının artırılması açısından önemlidir.

BBA sistemlerinde kullanılması için gereken bilgi el, kol, dil, bacak gibi hareketlerin hayalinin düşünülmesi sırasında oluşan beyin sinyallerinin EEG gibi yöntemlerle toplanıp öğrenme algoritmaları kullanılarak otomatik çözünmesiyle elde edilir. BBA uygulamalarında beyin sinyallerinin aktivitesinin ölçümünde genellikle kullanımının basit olması ve rahatsız edici olmamasından dolayı EEG yöntemi tercih edilir. Ayrıca, geliştirilecek BBA sistemlerinde verinin toplanması kadar sistemin doğruluğu ve çalışma hızı gibi noktalarda önemlidir.

Bu tez çalışmasında sağ veya sol el felci geçiren on hasta bireyden alınan EEG verileri üzerinde çalışılmıştır. Bu kişilerden alınan verilerle kişiye göre çalışmalar gerçekleştirilmiş olup, etkin elektrot ve etkin özniteliklerin seçilmesi kullanılan yöntemler dahilinde gerçekleştirilmiştir. Sınıflandırma aşamasında makine öğrenmesi tabanlı k-EYK, DAA, DVM sınıflandırıcıları ile topluluk yöntemi olan TKA kullanılmıştır. Elde edilen başarımların ve sonuçların özeti Tablo 20’de gösterilmiştir.

Tablo 20. Tüm katılımcılar için sınıflandırıcılara göre ortalama SD sonuçları

Sınıflandırma Doğruluğu (%)				
Katılımcılar	k-EYK	DAA	DVM	TKA
1	92.25	95.00	87.50	87.75
2	92.50	92.50	92.50	92.50
3	82.50	77.50	70.00	65.00
4	73.20	60.00	60.00	67.50
5	87.25	67.50	70.00	92.50
6	80.75	77.50	65.00	82.00
7	77.50	77.50	72.50	81.50
8	85.50	82.50	82.50	80.00
9	83.50	85.00	85.00	92.00
10	88.25	87.50	87.50	90.00
Ortalama SD	84.32	80.25	77.25	83.08

Katılımcı 1 için dört sınıflandırıcı içinde en iyi sonucu veren DAA yöntemi etkin olan iki elektrot ve üç farklı etkin öznitelikle beraber kullanılmış ve sınıflandırmada %95.00 sonucunu vermiştir. Elektrot olarak motor korteksinde olan elektrotlar olan CPz ve C4'ün seçimi başarıya bağlı olarak yapılmıştır. Etkin olan öznitelik bakımından değerlendirildiğinde Ek 2'de de görüldüğü gibi Hjorth parametrelerinin öne çıktığı görülmektedir. Kişi 1'in aksine tüm sınıflandırıcılarda %92.50 olarak en iyi sonucu veren katılımcı 2 için de P4 elektrotu üzerinden yapılan kayıtlarla çalışılmıştır. Bu sınıflandırıcılar için farklı sayıda etkin öznitelik algoritma tarafından belirlense de, yukarıda da belirtildiği gibi aslında EMG kayıtları için önerilen yöntem olan modifiye mutlak değer ortalama (MMDO) yöntemi bu kişi için tüm sınıflandırıcılarla iyi bir başarı sağlamıştır. Diğer bir katılımcı olan 3. kişi için de en iyi sonucun Ek 1'de verildiği şekilde k-EYK sınıflandırıcısı tarafından %82.50 olarak hesaplandığı görülmektedir. Tek elektrot ve dört etkin özniteliğin seçildiği bu kişi için en etkin olanlar MMDO ve modifiye sıfır geçiş sayısı (MSGs) olarak seçilmiştir. 4. kişi için k-EYK ile FC4 elektrotu üzerinden %73.20 ile en iyi sonucu verse de diğer sınıflandırıcılarla arasında çok bir başarı farkı olmamıştır. Bu sınıflandırıcı 5. gönüllü durumunda da yine öne çıkmış ve P3 elektrotu ve üç etkin öznitelikle beraber en yakın başarıyı sağlayan sınıflandırıcı olan DVM yöntemine göre %17.25 daha fazla başarı sağlanmıştır. Fakat TKA yöntemi de bu sınıflandırıcıyı %5.25 oranında geçerek en iyi başarımın sağlandığı durumu vermiştir. Kişi 6 için de en iyi sonucu verenler sırasıyla %82.00 ve %80.75 ile TKA ve k-EYK yöntemleridir. Seçilen aynı etkin elektrot olan C3 ile bu iki sınıflandırıcıda da en etkin özniteliğin beta bant gücü

olduğu ortaya çıkmıştır. Katılımcı 7 de bu sınıflandırıcıların yanında DAA yöntemi de öne çıkarken; TKA en iyi SD olarak %81.50, k-EYK ve DAA ise %77.50 sonucunu vermiştir. Farklı ama tek etkin elektrotun kullanıldığı bu algoritmalar için seçilen en öznelilikler de ağırlıklı olarak bant güçlerine dayalı olarak çıkarılanlardır. 8. kişi için tüm sınıflandırıcılarda en iyi sonucu veren elektrot CP4 olarak seçilmiştir. Gönüllü 8 de sınıflandırıcıların hepsi iyi sonuçlar verirken, k-EYK diğerlerine göre sadece %3 ve %5.50 daha fazla başarımla öne çıkmıştır. 9 ve 10. katılımcı için aynı elektrotların kullanımıyla birlikte TKA sınıflandırıcısı en iyi başarımla sağlamıştır. 9. kişi de en iyi SD olarak %92.00 sonucu elde edilmiştir. Son katılımcı da yine aynı etkin elektrot ama farklı üç öznelilik kullanımıyla %90.00 başarı sağlayan TKA metodu önde gelmiştir. Ayrıca bu kişi için, 8. kişideki gibi üç sınıflandırıcıda ortak seçilen elektrot olan F4 ile k-EYK, DAA ve DVM için sırasıyla %88.25, %87.50 ve %87.50 olarak doğruluk sağlamışlardır.

Çalışmada etkin olarak en fazla seçilen elektrotlar sırasıyla P4, F4 ve C3 olmuştur. Etkin öznelilik çıkarma yöntemi olarak öne çıkanlar ise beta bant gücü, willison genliği, teta bant gücü, MMDO, MSGS ve aktivite olmuştur. Bu tez çalışması ayrıca aynı veri seti kullanılarak yapılan çalışma sonuçlarıyla karşılaştırılmıştır. Bu karşılaştırma Tablo 21’de verilmiştir. Çalışmada kullanılan yöntem ile k-EYK sınıflandırıcısı sayesinde ortalama SD %84.32 hesaplanarak diğer çalışmalar geride bırakılmıştır.

Tablo 21. Veri Seti ile yapılan çalışmalar ve ortalama SD sonuçları

Yapılan Çalışma	Sınıflandırıcı – Ortalama SD (%)
Chowdhury vd. [44]	DVM - %75.75
Raza vd. [46]	CNN - %70.25
Ateş ve Aydemir [47]	k-EYK - %81.17
WCCI 2020 Competition 1. Takım [43]	Ridge Regresyon (RR) - %78.44
Tez çalışması yöntemi	k-EYK - %84.32

Bu tezde ayrıca çalışmanın bazı önemli özellikleri ve SD başarısı, çalışmaya benzer diğer çalışmalarla karşılaştırılmıştır. Karşılaştırma tablosunun detayları Tablo 22’de verilmiştir. Tüm çalışmalarda verilerin ölçümü için EEG’nin kullanılmasının yanında, Gao ve ark. (2016) tarafından adaboost topluluk sınıflandırıcısı kullanılarak yapılan çalışma ile bu tez çalışması en fazla katılımcının katıldığı durum olmuştur. Sreeja ve ark. (2017)

Gaussian Naive Bayes (GNB) sınıflandırıcısı ile yüksek bir ortalama SD elde etmelerine rağmen katılımcı sayısının daha az ve ayrıca bu katılımcıların da sağlıklı bireyler olduğuna dikkat edilmelidir. Cheng ve ark. (2018) ise yapılan tez çalışmasına benzer şekilde hasta bireyler üzerinden çalışma gerçekleştirmişlerdir. Bu çalışmadan farklı olarak el hareketinin hayalinin yerine ekrandaki okun sağ ve sola hareketinin hayali ile kaydedilen EEG verisini kullanmışlardır. Bu tez çalışmasıyla tablodan da görüldüğü gibi yaklaşık %10 kadar fazla bir başarımla elde edilmiştir.

Tablo 22. Yapılan çalışmanın benzer çalışmalar ile kıyaslanması

Yapılan Çalışmaların Özellikleri	Yapılan Çalışmalar					
	<i>Gao ve ark. (2016)</i>	<i>Gaur ve ark. (2015)</i>	<i>Gaur ve ark. (2015)</i>	<i>Sreeja ve ark. (2017)</i>	<i>Cheng ve ark. (2018)</i>	<i>Yapılan Çalışma</i>
Ölçüm Yöntemi	EEG	EEG	EEG	EEG	EEG	EEG
Katılımcı Sayısı	10	9	9	5	5	10
Katılımcının Durumu	Sağlıklı	Sağlıklı	Sağlıklı	Sağlıklı	Hasta	Hasta
Uyarım Şekli	Görsel	Görsel ve Sesli	Görsel	Görsel	Görsel	Görsel ve Sesli
Görevler	Sağ ve Sol Elin Hareketi ve Dinlenmesi	Sağ ve Sol Elin Hareketi	Sağ ve Sol Elin, İki Ayağın ve Dilin Hareketi	Sağ ve Sol Elin Hareketi	Okun Sağ ve Sola Hareketi	Sağ ve Sol Elin Kavraması
Hareket Tipi	Düşünsel (Hayali)	Düşünsel (Hayali)	Düşünsel (Hayali)	Düşünsel (Hayali)	Düşünsel (Hayali)	Düşünsel (Hayali)
Elektrot Sayısı	64	3	22	30	16	12
Bir Katılımcı için Kaydedilen Deneme Sayısı	Toplam 360 (120 sağ) (120 sol) (120 dinlenme)	Toplam 120 (60 sağ) (60 sol)	Toplam 288 (72 sağ el) (72 sol el) (72 ayaklar) (72 dil)	Toplam 280 (140 sağ) (140 sol)	Toplam 80 (40 sağ) (40 sol)	Toplam 80 (40 sağ) (40 sol)
Bir Denemenin Süresi (sn)	6	7.5	6	-	6	8
Örnekleme Frekansı (Hz)	1000	250	250	1000	256	512
Sınıf Sayısı	3	2	4	2	2	2
Sınıflandırıcı	Adaboost	DAA	DAA	GNB	DNN	k-EYK
Ortalama SD (%)	79.50	82.90	75.10	95.47	74.90	84.32

Güncel olan bu veri setiyle yapılan çalışma sonuçlarına göre EEG işaretlerine dayalı sinyaller için tüm elektrotların kullanımına gerek kalmadan daha iyi başarımlar sağlayan ve verileri ayırt etmede daha etkili olanların seçimiyle daha yüksek başarımlar sağlanabildiği görülmüştür. Bunun yanında özniteliklerin de önerilen algoritmayla seçilmesi öznitelik vektörü boyutlarının düşürülmesi ve karmaşıklığın azaltılmasıyla daha basit sistemlerin oluşmasının önü açılmıştır. BBA sistemleri için önemli olan diğer bir husus olan veri hızı da kullanılan yöntemler ile parametre sayısının azaltılmasıyla birlikte büyük oranda azaltılmıştır.

Literatürde de hareket hayali ile ilgili birçok çalışma olmasına rağmen kaydedilen verilerin çoğu sağlıklı bireylerden alınmıştır. Sağlıklı bireylerin aksine felçli kişilerde beyin sinyalleri aktivitesinin daha az kararlı olduğu düşünülürse yapılan yüksek başarımlı çalışmanın BBA uygulamaları için uygulanabilir ve faydalı olabileceği düşünülmektedir.

5. ÖNERİLER

Yapılan bu tez çalışmasında öncelikle kullanılan veri setiyle yüksek başarımlı sağlayan elektrotların seçimi sağlanmıştır. Sonra önerilen tüm özneliklerin arasından etkin olanlar, PSO algoritmasıyla seçilmiştir. Ham EEG verisine uygulanan yöntemlerle yüksek sınıflandırma başarımları hedeflenmiştir.

Normalizasyon ve ön işlem de bulunmamak hız ve işlem yükü açısından bir avantaj sağlasa da istenmeye gürültü ve işaretlerin veriye karışmasıyla da öznelik çıkarımlarında performans kaybı yaratabilir.

Çoklu elektrotlu olan bu veri setinde sadece etkin olan elektrotlarla çalışılmıştır. Etkin elektrot seçimi yerine veriye temel bileşen analizi gibi boyut indirgeme algoritmaları uygulanıp işlemler gerçekleştirilebilir.

Farklı alanlarda kullanılan ve iyi başarımlı sağlayan öznelik seçim yöntemlerinin bu çalışmaya entegresi sağlanabilir. Kullanılan PSO algoritmasında çözüm arayan parçacık sayısının artırılmasıyla daha iyi çözümler bulunabilir. Yalnız bunun yapılması çözüm hızını düşürebilir ve işlemi geciktirebileceği de unutulmamalıdır.

Kişiyeye özgü çıkarılan etkin yöntemlerin üzerinden gidilerek tüm kişiler için iyi başarımlı sağlayacak ortak bir yol oluşturulabilir. Ayrıca makine öğrenmesi tabanlı sınıflandırıcıların yerine derin veya sinir ağı yöntemleri kullanılarak sınıflandırma başarımlarının artırımı sağlanabilir.

6. KAYNAKLAR

1. Aydemir, Ö., ve Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim, Şubat 2009, Türkiye, 11-13.
2. Kennedy, P. R. ve Adams, K. D., A decision tree for brain-computer interface devices, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 11, 2 (2003) 148–150.
3. Van Erp, J., Lotte, F. ve Tangermann, M., Brain-Computer Interfaces: Beyond Medical Applications, Computer, 45, 4 (2012) 26–34.
4. Kayıkçıoğlu, T., Maleki, M., ve Ketenci, S., Biyomedikal Mühendisliği ve Uygulamaları, 241-268, EMO, Türkiye, 2018.
5. Tariq, M., Trivailo, P. M. ve Simic, M., EEG-based BCI control schemes for lower-limb assistive-robots, Frontiers in human neuroscience, 12 (2018) 312.
6. Alazrai, R., Alwanni, H. ve Daoud, M. I., EEG-based BCI system for decoding finger movements within the same hand, Neuroscience letters, 698 (2019) 113-120.
7. Torres P, E. P., Torres, E. A., Hernández-Álvarez, M. ve Yoo, S. G., EEG-based BCI emotion recognition: A survey, Sensors, 20, 18 (2020) 5083.
8. Lazarou, I., Nikolopoulos, S., Petrantonakis, P. C., Kompatsiaris, I. ve Tsolaki, M., EEG-based brain-computer interfaces for communication and rehabilitation of people with motor impairment: a novel approach of the 21st century, Frontiers in human neuroscience, 12 (2018) 14.
9. Brunner, P., Dijkstra, K., Coon, W. G., Mellinger, J., Ritaccio, A. L. ve Schalk, G., Brain-Computer Interface Research: A state of the art summary 5, 7-19, Springer, USA, 2017.
10. Foldes, S. T., Weber, D. J. ve Collinger, J. L., MEG-based neurofeedback for hand rehabilitation, Journal of neuroengineering and rehabilitation, 12, 1 (2015) 1-9.
11. Borgheai, S. B., Abtahi, M., Mankodiya, K., McLinden, J. ve Shahriari, Y., Towards a single trial fNIRS-based brain-computer interface for communication, 9th International IEEE/EMBS Conference on Neural Engineering, March 2019, USA, 1030-1033.

12. Noori, F. M., Naseer, N., Qureshi, N. K., Nazeer, H. ve Khan, R. A., Optimal feature selection from fNIRS signals using genetic algorithms for BCI, Neuroscience letters, 647 (2017) 61-66.
13. Ruiz, S., Buyukturkoglu, K., Rana, M., Birbaumer, N. ve Sitaram, R., Real-time fMRI brain computer interfaces: self-regulation of single brain regions to networks, Biological psychology, 95 (2014) 4-20.
14. Ramakrishnan, J., Mavaluru, D., Sakthivel, R. S., Alqahtani, A. S., Mubarakali, A. Ve Retnadhas, M., Brain-computer interface for amyotrophic lateral sclerosis patients using deep learning network, Neural Computing and Applications, (2020) 1-15.
15. Belkacem, A. N., Jamil, N., Palmer, J. A., Ouhbi, S. ve Chen, C., Brain computer interfaces for improving the quality of life of older adults and elderly patients, Frontiers in Neuroscience, 14 (2020) 692.
16. Cortez, S. A., Flores, C. ve Andreu-Perez, J., Proceedings of the 5th Brazilian Technology Symposium, 131-139, Springer, Switzerland, 2021.
17. Arpaia, P., Duraccio, L., Moccaldi, N. ve Rossi, S., Wearable brain-computer interface instrumentation for robot-based rehabilitation by augmented reality, IEEE Transactions on Instrumentation and Measurement, 69, 9 (2020) 6362-6371.
18. Gannouni, S., Belwafi, K., Aboalsamh, H., AlSamhan, Z., Alebdi, B., Almassad, Y. ve Alobaedallah, H., EEG-Based BCI System to Detect Fingers Movements, Brain Sciences, 10, 12 (2020) 965.
19. Baniqued, P. D. E., Stanyer, E. C., Awais, M., Alazmani, A., Jackson, A. E., Mon-Williams, M. A. ve Holt, R. J., Brain-computer interface robotics for hand rehabilitation after stroke: a systematic review, Journal of NeuroEngineering and Rehabilitation, 18, 1 (2021) 1-25.
20. Kaya, D. ve Türk, M., Biyoelektirksel İşaretlerde Rahatsızlık Teşhisinin Yorumlanması, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 29, 1 (2017) 261-267.

21. Tzallas, A. T., Tsipouras, M. G. ve Fotiadis, D. I., Automatic Seizure Detection Based on Time-Frequency Analysis and Artificial Neural Networks, Computational Intelligence and Neuroscience, 7 (2007) 1–13.
22. Dong, E., Li, C., Li, L., Du, S., Belkacem, A. N. ve Chen, C., Classification of multi-class motor imagery with a novel hierarchical SVM algorithm for brain–computer interfaces, Medical & Biological Engineering & Computing, 55, 10 (2017) 1809–1818.
23. Hajibabazadeh, M. ve Azimirad, V., Brain-robot interface: Distinguishing left and right hand EEG signals through SV, 2nd RSI/ISM International Conference on Robotics and Mechatronics, October 2014, Iran, 813-816.
24. Bhattacharyya, S., Khasnobish, A., Chatterjee, S., Konar, A. ve Tibarewala, D., Performance analysis of LDA, QDA and KNN algorithms in left-right limb movement classification from EEG data, International Conference on Systems in Medicine and Biology, December 2010, India, 126-131.
25. Amanpour, B. ve Erfanian, A., Classification of brain signals associated with imagination of hand grasping, opening and reaching by means of wavelet-based common spatial pattern and mutual information, 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, July 2013, Japan, 2224-2227.
26. Ergun, E. ve Aydemir, O., Classification of motor imaginary based Near-Infrared spectroscopy signals, 26th Signal Processing and Communications Applications Conference, May 2018, Turkey, 1-4.
27. Yavuz, E. ve Aydemir, O., Classification of EEG Based BCI Signals Imagined Hand Closing and Opening, 40th International Conference on Telecommunications and Signal Processing, July 2017, Spain, 425-428.
28. Kant, P., Laskar, S. H., Hazarika, J. ve Mahamune, R., CWT Based Transfer Learning for Motor Imagery Classification for Brain computer Interfaces, Journal of Neuroscience Methods, 345 (2020) 108886.
29. Tang, Z., Li, C. ve Sun, S., Single-trial EEG classification of motor imagery using deep convolutional neural networks, Optik, 130 (2017) 11–18.

30. Ramadhan, M. M., Wijaya, S. K. ve Prajitno, P., Classification of EEG Signals from Motor Imagery of Hand Grasp Movement Based on Neural Network Approach, IEEE International Conference on Signals and Systems, July 2019, Indonesia, 92-96.
31. Robinson, N. ve Vinod, A. P., Bi-Directional Imagined Hand Movement Classification Using Low Cost EEG-Based BCI, IEEE International Conference on Systems, Man, and Cybernetics, October 2015, Hong Kong, 3134-3139.
32. Ghaemi, A., Rashedi, E., Pourrahipi, A. M., Kamandar, M. ve Rahdari, F., Automatic channel selection in EEG signals for classification of left or right hand movement in Brain Computer Interfaces using improved binary gravitation search algorithm, Biomedical Signal Processing and Control, 33 (2017) 109–118.
33. Chatterjee, R. ve Bandyopadhyay, T., EEG Based Motor Imagery Classification Using SVM and MLP, 2nd International Conference on Computational Intelligence and Networks, January 2016, India, 84-89.
34. Aydemir, O. ve Kayikcioglu, T., Classification of EEG signals recorded during right/left hand movement imagery using Fourier Transform based features, IEEE 19th Signal Processing and Communications Applications Conference, April 2011, Turkey, 415-418.
35. Saka, K., Aydemir, O. ve Ozturk, M., Classification of EEG signals recorded during right/left hand movement imagery using Fast Walsh Hadamard Transform based features, 39th International Conference on Telecommunications and Signal Processing, June 2016, Austria, 413-416.
36. Bhattacharyya, S., Khasnobish, A., Konar, A., Tibarewala, D. N. ve Nagar, A. K., Performance analysis of left/right hand movement classification from EEG signal by intelligent algorithms, IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain, April 2011, France, 1-8.
37. Rejer, I., Genetic Algorithms in EEG Feature Selection for the Classification of Movements of the Left and Right Hand, 8th International Conference on Computer Recognition Systems, May 2013, Poland, 579–589.
38. Chatterjee R., Bandyopadhyay T., Sanyal D.K. ve Guha D., Proceedings of First International Conference on Smart System, Innovations and Computing. Smart Innovation, Systems and Technologies, 79, 73-83, Springer, Singapore, 2018.

39. Huaiyu, X., Jian, L., Ruidan, S. ve Erpeng, Z., Feature extraction and classification of EEG for imaging left-right hands movement, 2nd IEEE International Conference on Computer Science and Information Technology, August 2009, China, 56-59.
40. Tosun, M., Erginli, M., Kasım, Ö., Uğraş, B., Tanrıverdi, Ş. ve Kavak, T., EEG Verileri Kullanılarak Fiziksel El Hareketleri ve Bu Hareketlerin Hayalinin Yapay Sinir Ağları İle Sınıflandırılması, Sakarya University Journal of Computer and Information Sciences, 1, 2 (2018) 1-9.
41. 44. Cho, J. H., Jeong, J. H., Shim, K. H., Kim, D. J. ve Lee, S. W., Classification of Hand Motions within EEG Signals for Non-Invasive BCI-Based Robot Hand Control, IEEE International Conference on Systems, Man, and Cybernetics, October 2018, Japan, 515-518.
42. Liu, C., Wang, H., Pu, H., Zhang, Y. ve Zou, L., EEG feature extraction and pattern recognition during right and left hands motor imagery in brain-computer interface, 5th International Conference on BioMedical Engineering and Informatics, October 2012, China, 506-510.
43. <https://sites.google.com/view/bci-comp-wcci/home>, Clinical BCI Challenge WCCI 2020, 25 Temmuz 2020.
44. Chowdhury, A., Raza, H., Meena, Y. K., Dutta, A. ve Prasad, G., Online covariate shift detection-based adaptive brain-computer interface to trigger hand exoskeleton feedback for neuro-rehabilitation, IEEE Transactions on Cognitive and Developmental Systems, 10, 4 (2017) 1070-1080.
45. Hodkinson, H. M., Evaluation of a mental test score for assessment of mental impairment in the elderly, Age & Ageing, 1, 4 (1972) 233-238.
46. Raza, H., Chowdhury, A. ve Bhattacharyya, S., Deep learning based prediction of EEG motor imagery of stroke patients' for neuro-rehabilitation application. International Joint Conference on Neural Networks, July 2020, UK, 1-8.
47. Ateş, O. K. ve Aydemir, Ö., El İle Kavrama Girişiminin Hayali Sırasında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması, Medical Technologies Congress, Kasım 2020, Türkiye, 1-4.

48. Toledo-Perez, D. C., Rodriguez-Resendiz, J. ve Gomez-Loenzo, R. A., A Study of Computing Zero Crossing Methods and an Improved Proposal for EMG Signals, IEEE Access, 8 (2020) 8783–8790.
49. Phinyomark, A., Phukpattaranont, P. ve Limsakul, C., Feature reduction and selection for EMG signal classification. Expert Systems with Applications, 39, 8 (2012) 7420–7431.
50. Kennedy, J. ve Eberhart, R., Particle swarm optimization, International Conference on Neural Networks, November 1995, Australia, 4, 1942–1948.
51. Yazdani, A., Ebrahimi, T. ve Hoffmann, U., Classification of EEG signals using Dempster Shafer theory and a k-nearest neighbor classifier, 4th International IEEE/EMBS Conference, April 2009, Turkey, 327-330.
52. Cortes, C. ve Vapnik, V., Support-vector networks, Machine learning, 20, 3 (1995) 273-297.
53. Foody, G.M. ve Mathur, A., Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification, Remote Sensing of Environment, 93 (2004) 107–117.
54. Sherrod, P. H., Classification ve regression trees and support vector machines for predictive modeling and forecasting, DTREG program manual. (2003) 281-295.
55. Balakrishnama, S., ve Ganapathiraju, A., Linear discriminant analysis-a brief tutorial, Institute for Signal and information Processing, 18 (1998) 1-8.
56. Kaya, Y., Ertuğrul, Ö. ve Tekin, R., Epileptik EEG İşaretlerinin Sınıflandırılmasında Karar Kuralları ve Karar Ağaçlarının Kullanılması, Batman Üniversitesi Yaşam Bilimleri Dergisi, 1, 2 (2012) 403-413.
57. Breiman, L., Bagging predictors, Machine learning, 24, 2 (1996) 123-140.
58. Gao, L., Cheng, W., Zhang, J. ve Wang, J., EEG classification for motor imagery and resting state in BCI applications using multi-class Adaboost extreme learning machine, Review of Scientific Instruments, 87, 8 (2016) 085110.

59. Gaur, P., Pachori, R. B., Wang, H. ve Prasad, G., An empirical mode decomposition based filtering method for classification of motor-imagery EEG signals for enhancing brain-computer interface, International Joint Conference on Neural Networks, July 2015, Ireland, 1-7.
60. Sreeja, S. R., Rabha, J., Nagarjuna, K. Y., Samanta, D., Mitra, P. ve Sarma, M., Motor imagery EEG signal processing and classification using machine learning approach, International Conference on New Trends in Computing Sciences, October 2017, Jordan, 61-66.
61. Cheng, D., Liu, Y. ve Zhang, L., Exploring motor imagery EEG patterns for stroke patients with deep neural networks, IEEE International Conference on Acoustics, Speech and Signal Processing, April 2018, Canada, 2561-2565.



7. EKLER

Ek 1

23. k-EYK yöntemi için etkin ve tüm öznitelikler ile SD sonuçları

Kişiler	Etkin Elektrot	Etkin Öznitelik	(Etkin) SD (%) – Standart Sapması	Tüm Öznitelik SD (%)
1	FCz	13-4	92.25 – 0.79	88.25
2	P4	13-3-5-4	92,50 – 0.00	91
3	F3	12-13-5-8	82.50 – 0.00	76.50
4	FC4	9-10-8-13-11	73.20 – 3.33	60.25
5	P3	9-13-5	87.25 – 1.05	86.75
6	C3	9-4	80.75 – 2.15	46.75
7	F3	10-9-11-2	77.50 – 1.67	52.00
8	F4	9-10-8-1	85.50 – 1.58	60.75
9	F4	9-10-8-12	83.50 – 3.19	46.25
10	P4	10-9	88.25 – 2.37	41.25

24. DAA yöntemi için etkin ve tüm öznitelikler ile SD sonuçları

Kişiler	Etkin Elektrot	Etkin Öznitelik	(Etkin) SD (%)	Tüm Öznitelik SD (%)
1	CPz – C4	6-7-5 / 6-7	95.00	87.50
2	P4	13	92.50	92.50
3	CP3	13-4-3	77.50	70.00
4	F4	9-11-8	60.00	57.50
5	C3 – P4	8-10-6-11 / 8-10-5	67.50	62.50
6	C3	9-6-7	77.50	62.50
7	CPz	10-9-11-12	77.50	52.50
8	F4	9-7-6	82.50	57.50
9	F4	9-10-11	85.00	55.00
10	F4 – P4	9-11 / 9-11-12	87.50	85.00

Ek 1'in devamı

25. DVM yöntemi için etkin ve tüm öznitelikler ile SD sonuçları

Kişiler	Etkin Elektrot	Etkin Öznitelik	(Etkin) SD (%)	Tüm Öznitelik SD (%)
1	F3	5-9-1	87.50	72.50
2	P4	13-12	92.50	92.50
3	F3	13-11-10	70.00	67.50
4	F4	9-11-8	60.00	55.00
5	FC4	9-6-8-3	70.00	62.50
6	C3 – P4	13-10-5-9 / 13-10-5	65.00	60.00
7	FC3 – C3	11-8-9 / 11-8-9	72.50	52.50
8	F4	9-10-8	82.50	72.50
9	F4	9-10	85.00	60.00
10	P4	13-9-11-12	87.50	85.00

26. TKA için etkin ve tüm öznitelikler ile SD sonuçları

Kişiler	Etkin Elektrot	Etkin Öznitelik	(Etkin) SD (%)	Tüm Öznitelik SD (%)
1	FCz	13-4-2	87.75	85.75
2	P4	13-12-11	92.50	92.50
3	FC4	8-11-9-3	65.00	58.00
4	FC4	13-9-5	67.50	66.00
5	P4	13-11-6	92.50	68.00
6	C3	9-11-12-4	82.00	57.50
7	CPz	11-10-9-8	81.50	52.50
8	CP4	9-10-8-1	80.00	70.00
9	CPz	9-10-11	92.00	59.50
10	CPz	9-11-12	90.00	87.50

Ek 2

27. k-EYK yöntemi için tüm elektrotların SD sonuçları

Elektrot	Sınıflandırma Doğruluğu (%) – Standart Sapması (±)									
	Kişiler									
	1	2	3	4	5	6	7	8	9	10
F3	18.50 ±1.29	61.00 ±4.28	76.50 ±8.64	60.00 ±7.67	77.00 ±13.21	43.75 ±9.80	52.00 ±1.05	44.25 ±9.72	46.00 ±2.11	35.50 ±9.73
FC3	50.00 ±0.00	81.75 ±6.90	50.50 ±1.05	47.00 ±5.62	79.25 ±16.99	33.50 ±9.66	50.50 ±1.05	49.25 ±7.17	39.00 ±5.16	36.50 ±5.02
C3	50.00 ±0.00	85.50 ±4.21	64.00 ±7.37	50.00 ±4.56	80.25 ±0.79	46.75 ±1.68	50.00 ±0.00	41.50 ±6.47	42.50 ±4.71	37.75 ±7.11
CP3	29.00 ±3.90	80.00 ±4.71	42.75 ±5.45	57.75 ±4.32	65.00 ±9.64	31.50 ±5.16	50.00 ±0.00	57.25 ±7.11	42.75 ±5.45	33.50 ±4.59
P3	12.00 ±3.49	51.00 ±1.29	64.75 ±6.06	54.50 ±7.88	86.75 ±1.20	38.75 ±9.38	50.00 ±0.00	55.25 ±9.75	44.00 ±6.03	39.25 ±9.69
FCz	88.25 ±1.68	52.25 ±0.89	50.25 ±6.50	47.50 ±7.54	78.75 ±18.11	34.00 ±7.18	51.00 ±1.29	56.25 ±9.03	41.75 ±5.89	37.25 ±6.81
CPz	12.00 ±3.58	70.00 ±7.72	56.00 ±5.16	55.00 ±4.85	78.00 ±17.66	41.25 ±4.89	50.00 ±0.00	38.75 ±9.94	43.25 ±5.27	30.25 ±0.79
F4	48.00 ±4.21	50.50 ±1.05	33.50 ±2.41	57.00 ±6.21	81.75 ±15.45	30.25 ±3.62	50.00 ±0.00	60.75 ±5.27	46.25 ±3.95	30.50 ±2.83
FC4	42.25 ±2.48	55.00 ±0.00	51.00 ±1.29	60.25 ±3.21	71.00 ±11.61	31.50 ±2.68	50.00 ±0.00	56.50 ±5.79	45.00 ±0.00	40.50 ±6.10
C4	65.25 ±2.19	50.25 ±0.79	47.00 ±3.87	43.75 ±6.48	76.25 ±16.42	26.25 ±1.76	50.00 ±0.00	59.50 ±8.80	40.00 ±6.45	40.25 ±9.92
CP4	56.00 ±4.92	50.00 ±0.00	55.25 ±8.45	52.50 ±5.00	82.00 ±10.39	32.00 ±1.58	50.00 ±0.00	63.75 ±9.22	41.00 ±6.89	36.75 ±9.70
P4	36.25 ±4.54	91.00 ±2.41	54.50 ±3.87	51.75 ±5.89	72.00 ±12.51	28.75 ±1.76	50.00 ±0.00	36.50 ±3.94	45.00 ±0.00	41.25 ±2.12

Ek 2'nin devamı

28. DAA yöntemi için tüm elektrotların SD sonuçları

Elektrot	Sınıflandırma Doğruluğu (%) – Standart Sapması (±)									
	Kişiler									
	1	2	3	4	5	6	7	8	9	10
F3	52.50 ±0.00	50.00 ±0.00	50.00 ±0.00	50.00 ±0.00	60.00 ±0.00	52.50 ±0.00	50.00 ±0.00	47.50 ±0.00	50.00 ±0.00	77.50 ±0.00
FC3	52.50 ±0.00	77.50 ±0.00	50.00 ±0.00	52.50 ±0.00	60.00 ±0.00	55.00 ±0.00	50.00 ±0.00	47.50 ±0.00	50.00 ±0.00	77.50 ±0.00
C3	72.50 ±0.00	85.00 ±0.00	50.00 ±0.00	52.50 ±0.00	62.50 ±0.00	62.50 ±0.00	50.00 ±0.00	45.00 ±0.00	50.00 ±0.00	80.00 ±0.00
CP3	50.00 ±0.00	72.50 ±0.00	70.00 ±0.00	50.00 ±0.00	60.00 ±0.00	60.00 ±0.00	47.50 ±0.00	45.00 ±0.00	52.50 ±0.00	82.50 ±0.00
P3	82.50 ±0.00	50.00 ±0.00	47.50 ±0.00	32.50 ±0.00	60.00 ±0.00	55.00 ±0.00	50.00 ±0.00	40.00 ±0.00	52.50 ±0.00	82.50 ±0.00
FCz	82.50 ±0.00	50.00 ±0.00	50.00 ±0.00	47.50 ±0.00	60.00 ±0.00	50.00 ±0.00	50.00 ±0.00	47.50 ±0.00	50.00 ±0.00	80.00 ±0.00
CPz	87.50 ±0.00	62.50 ±0.00	60.00 ±0.00	45.00 ±0.00	60.00 ±0.00	52.50 ±0.00	52.50 ±0.00	45.00 ±0.00	50.00 ±0.00	82.50 ±0.00
F4	50.00 ±0.00	50.00 ±0.00	52.50 ±0.00	57.50 ±0.00	60.00 ±0.00	52.50 ±0.00	50.00 ±0.00	57.50 ±0.00	55.00 ±0.00	85.00 ±0.00
FC4	60.00 ±0.00	90.00 ±0.00	40.00 ±0.00	55.00 ±0.00	60.00 ±0.00	57.50 ±0.00	50.00 ±0.00	47.50 ±0.00	52.50 ±0.00	77.50 ±0.00
C4	87.50 ±0.00	60.00 ±0.00	50.00 ±0.00	47.50 ±0.00	60.00 ±0.00	55.00 ±0.00	45.00 ±0.00	47.50 ±0.00	50.00 ±0.00	77.50 ±0.00
CP4	50.00 ±0.00	50.00 ±0.00	50.00 ±0.00	50.00 ±0.00	60.00 ±0.00	52.50 ±0.00	45.00 ±0.00	47.50 ±0.00	42.50 ±0.00	82.50 ±0.00
P4	50.00 ±0.00	92.50 ±0.00	42.50 ±0.00	50.00 ±0.00	62.50 ±0.00	52.50 ±0.00	47.50 ±0.00	45.00 ±0.00	52.50 ±0.00	85.00 ±0.00

Ek 2'nin devamı

29. DVM yöntemi için tüm elektrotların SD sonuçları

Elektrot	Sınıflandırma Doğruluğu (%) – Standart Sapması (±)									
	Kişiler									
	1	2	3	4	5	6	7	8	9	10
F3	72.50 ±0.00	55.00 ±0.00	67.50 ±0.00	45.00 ±0.00	47.50 ±0.00	55.00 ±0.00	50.00 ±0.00	52.50 ±0.00	45.00 ±0.00	70.00 ±0.00
FC3	50.00 ±0.00	77.50 ±0.00	62.50 ±0.00	50.00 ±0.00	57.50 ±0.00	50.00 ±0.00	52.50 ±0.00	50.00 ±0.00	47.50 ±0.00	60.00 ±0.00
C3	50.00 ±0.00	82.50 ±0.00	65.00 ±0.00	50.00 ±0.00	50.00 ±0.00	60.00 ±0.00	52.50 ±0.00	50.00 ±0.00	47.50 ±0.00	55.00 ±0.00
CP3	70.00 ±0.00	67.50 ±0.00	50.00 ±0.00	52.50 ±0.00	52.50 ±0.00	57.50 ±0.00	50.00 ±0.00	47.50 ±0.00	57.50 ±0.00	70.00 ±0.00
P3	52.50 ±0.00	70.00 ±0.00	62.50 ±0.00	37.50 ±0.00	50.00 ±0.00	55.00 ±0.00	50.00 ±0.00	60.00 ±0.00	55.00 ±0.00	75.00 ±0.00
FCz	57.75 ±0.00	50.00 ±0.00	50.00 ±0.00	50.00 ±0.00	50.00 ±0.00	47.50 ±0.00	50.00 ±0.00	65.00 ±0.00	50.00 ±0.00	82.50 ±0.00
CPz	55.00 ±0.00	85.00 ±0.00	47.50 ±0.00	50.00 ±0.00	50.00 ±0.00	37.50 ±0.00	50.00 ±0.00	62.50 ±0.00	55.00 ±0.00	70.00 ±0.00
F4	50.00 ±0.00	50.00 ±0.00	62.50 ±0.00	55.00 ±0.00	57.50 ±0.00	47.50 ±0.00	50.00 ±0.00	72.50 ±0.00	60.00 ±0.00	70.00 ±0.00
FC4	70.00 ±0.00	50.00 ±0.00	42.50 ±0.00	52.50 ±0.00	62.50 ±0.00	57.50 ±0.00	50.00 ±0.00	55.00 ±0.00	47.50 ±0.00	75.00 ±0.00
C4	52.50 ±0.00	52.50 ±0.00	50.00 ±0.00	52.50 ±0.00	50.00 ±0.00	47.50 ±0.00	50.00 ±0.00	52.50 ±0.00	50.00 ±0.00	72.50 ±0.00
CP4	50.00 ±0.00	50.00 ±0.00	62.50 ±0.00	55.00 ±0.00	57.50 ±0.00	50.00 ±0.00	50.00 ±0.00	62.50 ±0.00	45.00 ±0.00	67.50 ±0.00
P4	50.00 ±0.00	92.50 ±0.00	55.00 ±0.00	47.50 ±0.00	57.50 ±0.00	60.00 ±0.00	50.00 ±0.00	37.50 ±0.00	52.50 ±0.00	85.00 ±0.00

Ek 2'nin devamı

30. TKA yöntemi için tüm elektrotların SD sonuçları

Elektrot	Sınıflandırma Doğruluğu (%) – Standart Sapması (±)									
	Kişiler									
	1	2	3	4	5	6	7	8	9	10
F3	53.75 ±1.76	59.00 ±9.26	45.50 ±8.55	53.00 ±5.96	58.00 ±2.08	35.00 ±5.30	50.00 ±0.00	56.50 ±4.18	52.50 ±1.75	62.50 ±2.50
FC3	50.00 ±0.00	64.00 ±9.24	50.00 ±0.00	53.50 ±1.36	51.50 ±1.37	38.00 ±6.47	45.00 ±0.00	47.00 ±2.73	57.50 ±1.78	76.50 ±7.41
C3	50.00 ±0.00	76.50 ±2.23	54.00 ±2.23	52.00 ±2.09	56.50 ±1.36	55.00 ±7.07	50.00 ±0.00	59.00 ±1.36	57.50 ±4.67	83.00 ±2.09
CP3	37.00 ±8.80	53.00 ±6.70	42.00 ±3.25	56.00 ±2.25	57.50 ±0.00	35.00 ±6.12	45.00 ±0.00	64.00 ±1.37	52.50 ±4.33	82.50 ±2.50
P3	32.75 ±5.70	50.50 ±1.11	41.00 ±4.54	49.50 ±2.09	52.50 ±0.00	31.50 ±1.37	50.00 ±0.00	68.50 ±5.18	49.50 ±4.47	87.00 ±3.06
FCz	85.75 ±0.79	50.00 ±0.00	37.50 ±1.76	52.00 ±2.19	50.00 ±0.00	32.50 ±2.50	50.00 ±0.00	61.00 ±2.85	51.00 ±5.18	84.00 ±6.98
CPz	36.50 ±4.54	51.00 ±1.36	51.00 ±1.36	55.50 ±2.11	50.00 ±0.00	28.50 ±3.79	52.50 ±0.00	65.00 ±3.06	59.50 ±3.25	87.50 ±4.47
F4	50.00 ±0.00	50.00 ±0.00	50.00 ±5.86	50.00 ±1.76	50.50 ±1.25	32.50 ±3.06	50.00 ±0.00	55.50 ±5.96	54.00 ±1.36	83.50 ±4.18
FC4	79.50 ±4.80	53.00 ±1.11	58.00 ±2.73	66.00 ±2.23	50.00 ±0.00	57.50 ±1.76	50.00 ±0.00	44.00 ±3.79	48.50 ±3.79	82.00 ±2.73
C4	71.50 ±1.36	52.00 ±1.12	54.00 ±1.36	56.50 ±1.36	49.50 ±2.29	32.00 ±1.11	47.50 ±0.00	51.50 ±2.24	45.50 ±2.73	84.50 ±3.25
CP4	51.00 ±2.23	50.00 ±0.00	50.50 ±1.13	47.00 ±1.11	47.50 ±1.38	26.00 ±1.26	47.50 ±0.00	70.00 ±1.76	51.00 ±3.35	84.00 ±1.36
P4	64.00 ±7.82	92.50 ±0.00	49.00 ±3.79	47.50 ±0.00	68.00 ±3.25	28.50 ±2.85	50.00 ±0.00	35.00 ±1.77	45.50 ±2.09	81.50 ±8.02

ÖZGEÇMİŞ

İlköğretim eğitimini Gümüşhane’de, lise eğitimini ise Bayburt Anadolu Öğretmen Lisesi’nde tamamlamıştır. Orta Doğu Teknik Üniversitesi Kuzey Kıbrıs Kampüsü Elektrik Elektronik Mühendisliği bölümünde üniversite eğitime başlayıp, Lisans eğitimini tamamladı. Karadeniz Teknik Üniversitesi’nde aynı bölümde yüksek lisans eğitime başladı. Yabancı dil olarak iyi derecede İngilizce bilmektedir.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

1. Ateş, O. K. ve Aydemir, Ö., El İle Kavrama Girişiminin Hayali Sırasında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması, Tıp Teknolojileri Kongresi (TIPTEKNO), Kasım 2020, İzmir, 1-4.