

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MOTOR HAREKET HAYALİ GÖREVLERİNE AİT EEG SİNYALLERİNİN 2-B ÖZİNİTELİKLER
VE YARI OLASILIKSAL DAĞILIM MODELLERİ İLE SINIFLANDIRILMASI**

DOKTORA TEZİ

Bil. Yük. Müh. Çağatay Murat YILMAZ

**MART 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MOTOR HAREKET HAYALİ GÖREVLERİNE AİT EEG SİNYALLERİNİN 2-B
ÖZNİTELİKLER VE YARI OLASILIKSAL DAĞILIM MODELLERİ İLE
SINIFLANDIRILMASI**

Bil. Yük. Müh. Çağatay Murat YILMAZ

ORCID : 0000 -0002 -6513 - 7337

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 18 / 02 / 2021

Tezin Savunma Tarihi : 18 / 03 / 2021

Tez Danışmanı : Prof. Dr. CEMAL KÖSE
ORCID : 0000 -0002 -5982 - 4771

Trabzon 2021

ÖNSÖZ

EEG sinyal örüntülerinin tanınması biyomedikal sinyal işleme sistemlerinin geliştirilmesi için aktif bir araştırma alanıdır ve geleceğe yönelik geniş bir potansiyele sahiptir. Popüler araştırma alanlarından biri motor hareketlerin hayal edilmesi ile yürütülen beyin-makine arayüzleridir. Motor hareket hayali örüntülerini işleyen bu arayüzlerde herhangi bir eylem motor sistem kullanılmadan sadece beyinde simule edilerek yürütülür. Böylelikle nöromusküler yapılar pas geçilerek beyinle elektronik cihazlar arasında kas hareketleri olmadan bir iletişim ve kontrol arayüzü kurulur. Zeki ve otomatik arayüzlerin tasarlanması için sinyal işleme ve örüntü tanıma seviyesinde çözümler önerilmelidir. Bu çalışmada, beyin-makine arayüzlerine ait hareket hayali örüntülerinin sınıflandırılması için yeni, özgün ve problem domainine uygun bazı örüntü tanıma teknikleri tasarlanmıştır. Kuramsal düzenlemelere ek olarak problem domaininde de değişikliklere gidilerek beyinle mobil telefonlar arasında motor hareket hayaline dayalı bir arayüzün performansı araştırılmıştır.

Doktora eğitim-öğretimim, tez çalışmalarım ve akademik yaşantım süresince bilgi, görüş ve tecrübeleriyle bana daima yardımcı olan çok değerli danışmanım Sayın Prof. Dr. Cemal KÖSE'ye minnet ve şükranlarımı sunar,

Tez çalışmalarım sürecinde rehberlik eden tez izleme komitesi üyeleri Sayın Doç. Dr. Önder AYDEMİR ve Sayın Dr. Öğr. Üyesi Murat AYKUT'a,

Doktora hayatımın en zor günlerinde yanımda olan değerli meslektaşım ve sevgili hayat arkadaşım Sayın Bahar HATİPOĞLU YILMAZ'a,

Giresun Bulancak'ta başlayan hayatımda bugünlere gelmemde sonsuz emeği olan çok kıymetli annem Sayın Fatma YILMAZ, babam Sayın Lütfü YILMAZ, abilerim ve ablalarım,

Çalışmaların gerçekleştirilmesi ve tamamlanması için destek veren TÜBİTAK'a, değerli arkadaşlarıma ve veri seti oluşturmamda destek olan çok değerli katılımcılara,

Teşekkürlerimi saygılarımla arz ederim.

Çağatay Murat YILMAZ

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Motor Hareket Hayali Grevlerine ait EEG Sinyallerinin 2-B znelikler ve Yarı Olasılıksal Dađılım Modelleri ile Sınıflandırılması” başlıklı bu alıřmayı bařtan sona kadar danıřmanım Sayın Prof. Dr. Cemal KSE’nin sorumluluđunda tamamladıđımı, verileri/rnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gsterdiđimi, alıřma srecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her trl yasal sonucu kabul ettiđimi beyan ederim. 18/03/2021

ađatay Murat YILMAZ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ŞEKİLLER DİZİNİ	XI
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Elektroensefalografi	2
1.3. Beyin Makine Arayüzleri	4
1.4. Motor Hareket Hayali.....	4
1.5. Motor Hareket Hayali İçin Örüntü Tanıma Yöntemleri.....	6
1.5.1. Öznitelik Çıkarma Yöntemleri	6
1.5.1.1. Zaman Düzlemi Öznitelikleri.....	7
1.5.1.2. Frekans Düzlemi Öznitelikleri	7
1.5.1.3. Zaman-Frekans Düzlemi Öznitelikleri.....	7
1.5.1.4. Uzamsal Düzlem Öznitelikleri	8
1.5.1.5. Uyarlanabilir Yöntem Öznitelikleri.....	9
1.5.1.6. Öznitelik Çıkarma Yöntemlerinin Kombinasyonları	9
1.5.2. Sınıflandırma Yöntemleri.....	9
1.5.2.1. Doğrusal Ayırtaç Analizi Yöntemleri	10
1.5.2.2. Destek Vektör Makineleri ve Türevleri.....	10
1.5.2.3. Yapay Sinir Ağları ve Derin Sinir Ağları.....	11
1.5.2.4. Bayes Sınıflandırıcıları.....	12
1.5.2.5. En Yakın Komşu Sınıflandırıcıları.....	12
1.5.2.6. Uyarlanabilir Sınıflandırıcılar	13
1.5.2.7. Riemann Yaklaşımları.....	13
1.5.2.8. Transfer Öğrenme Yaklaşımları.....	14
1.5.2.9. Karar Ağaçları ve Temel Bazı Sınıflandırıcılar	14

1.5.2.10.	Sınıflandırıcı Kombinasyonları ve Topluluk Öğrenme	15
1.6.	Tezin Kapsamı	15
1.7.	Tekrarlamasız Kombinasyon	17
1.8.	Topluluk Öğrenme Yöntemleri.....	17
1.8.1.	Çoğunluk Oylama	18
1.8.2.	Uniform Ağırlıkları Kullanan Yumuşak Oylama	19
1.9.	Zaman Düzlemi Öznitelikleri.....	20
1.10.	K En Yakın Komşu Algoritması.....	23
1.11.	Destek Vektör Makineleri.....	26
1.12.	Transfer Öğrenme	28
1.12.1.	AlexNet.....	30
1.12.2.	GoogLeNet.....	30
1.12.3.	SqueezeNet.....	31
1.13.	Performans Ölçütleri	31
1.14.	EPOC Flex Salin Sensör EEG Kayıt Cihazı Seti.....	33
1.14.1.	Kit İçeriği	34
1.14.2.	Kaliteli Temasın Sağlanması	35
1.14.3.	Emotiv PRO Yazılımı	37
1.15.	Beyin Makine Arayüzü Veri Setleri.....	38
1.15.1.	BCI Competition II Yarışması Data Set Ia Veri Seti	38
1.15.2.	BCI Competition IV Yarışması Data Set 2a Veri Seti.....	38
2.	YAPILAN ÇALIŞMALAR	41
2.1.	MHH-BMTA Veri Setinin Oluşturulması	41
2.1.1.	Kayıt Cihazının Araştırılması	41
2.1.2.	MHH-BMTA Veri Setinin Oluşturulması	42
2.1.2.1.	Deneysel Paradigmanın Zamanlama Planı	44
2.1.2.2.	Denek ve Kayıt Bilgileri	45
2.1.2.3.	Kayıtların Alınması.....	46
2.1.2.3.1.	Referans Elektrotların Belirlenmesi.....	48
2.1.2.3.2.	Elektrot Sensörlerinin Yerleşim Düzenlerinin Belirlenmesi	49
2.1.2.3.3.	EmotivPro ile EEG Verilerinin Kaydedilmesi ve Analizi	51
2.1.3.	Verilerin Önışlenmesi	54

2.2.	Öznitelik Çıkarma ve Sınıflandırma Yöntemleri	55
2.2.1.	Geçiş Noktalarının Belirlenmesi	55
2.2.2.	Geçiş Noktaları ve Öznitelik Tanımları	56
2.2.2.1.	Öznitelik (1)'in Tanımı	57
2.2.2.2.	Öznitelik (2)'nin Tanımı	58
2.2.3.	2-B Sinyal Özniteliklerinin Oluşturulması	59
2.2.4.	2-B Yarı Olasılıksal Dağılımlar Kullanan Öğrenme Modeli	61
2.2.4.1.	Öğrenme Süreci.....	61
2.2.4.2.	Test Süreci.....	64
2.2.5.	Yarı Olasılıksal Dağılımlar Kullanan Topluluk Öğrenme	66
2.2.5.1.	Frekans Bantlarının Belirlenmesi.....	66
2.2.5.2.	Zaman Dilimlerinin Belirlenmesi	67
2.2.5.3.	Öznitelik Çıkarma ve Sınıflandırma	68
2.2.5.3.1.	Tekil Sınıflandırma.....	69
2.2.5.3.2.	Aynı Zaman Diliminde Geleneksel Oylama	69
2.2.5.3.3.	Aynı Zaman Diliminde Kombinasyonel Oylama	70
2.2.5.3.4.	Aynı Frekans Bandında Oylama	71
2.2.5.3.5.	Tüm Zaman Dilimleri ve Frekans Bantlarında Oylama.....	71
2.2.6.	2-B Modelleme Görüntülerinin Oluşturulması	72
3.	BULGULAR VE İRDELEME	74
3.1.	BCI Competition II Yarışması Data Set Ia Veri Seti İçin Sonuçlar.....	74
3.1.1.	Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi	74
3.1.1.	Parametre Değerlerinin Belirlenmesi	75
3.1.2.	Deneysel Sonuçlar ve Analizler	76
3.2.	BCI Competition IV Yarışması Data Set 2a Veri Seti İçin Sonuçlar	78
3.2.1.	Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi.....	78
3.2.2.	Parametre Değerlerinin Belirlenmesi.....	79
3.2.3.	Deneysel Sonuçlar ve Analizler	81
3.2.3.1.	Sol/Sağ El MHH Görevleri İçin Sınıflandırma Sonuçları	83
3.2.3.2.	Sol El/Ayaklar MHH Görevleri İçin Sınıflandırma Sonuçları.....	87
3.2.3.3.	Sol El/Dil MHH Görevleri İçin Sınıflandırma Sonuçları	90
3.2.3.4.	Sağ El/Ayaklar MHH Görevleri İçin Sınıflandırma Sonuçları.....	93

3.2.3.5. Sağ El/Dil MHH Görevleri İçin Sınıflandırma Sonuçları.....	95
3.2.3.6. Ayaklar/Dil MHH Görevleri İçin Sınıflandırma Sonuçları.....	98
3.2.3.7. Genel Sonuçlar ve Parametre Performans Katkıları.....	100
3.3. MHH-BMTA Veri Setinde Elde Edilen Sonuçlar.....	102
3.3.1. Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi	102
3.3.2. Deneysel Sonuçlar ve Analizler	102
3.3.2.1. YODM Kullanan Topluluk Öğrenme İçin Sonuçlar ve Analizler	103
3.3.2.2. K-EYK ve DVM Sonuçlar ve Analizler.....	114
3.3.2.3. Transfer Öğrenme ile ESA İçin Sonuçlar ve Analizler.....	119
3.3.2.4. Sınıflandırma Sonuçlarının Kıyaslanması.....	123
4. SONUÇLAR	128
5. ÖNERİLER VE TARTIŞMA	132
6. KAYNAKLAR.....	135
7. EKLER.....	151
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

MOTOR HAREKET HAYALİ GÖREVLERİNE AİT EEG SİNYALLERİNİN 2-B
ÖZİNİTELİKLER VE YARI OLASILIKSAL DAĞILIM MODELLERİ İLE
SINIFLANDIRILMASI

Çağatay Murat YILMAZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2021, 150 Sayfa, 5 Sayfa Ek

Beyin makine arayüzlerinin (BMA) geliştirilmesinde sıklıkla başvuru motor hareket hayalinde (MHH) herhangi bir eylem motor sistem kullanılmadan beyinde simule edilerek yapılır. Tez çalışmasında, MHH görevlerinin sınıflandırılması için bazı örüntü tanıma teknikleri önerilmiştir. Bu amaçla ilk olarak, EEG sinyallerindeki geçiş noktalarına ait 2-B öznelikler özelleşmiş bir uzayda çıkarılmıştır. Ardından, 2-B yarı olasılıksal dağılım modelleriyle (YODM) öğrenme modelleri oluşturulmuş ve olasılıksal üyeliklerle sınıflandırma gerçekleştirilmiştir. İlerleyen süreçte veri domaininden faydalanarak YODM temelli alt-sınıflandırıcılar oluşturulmuş ve oylama yaklaşımlarında kombinasyonları da kullanan bazı sınıflandırıcılar önerilmiştir. Dahası sinyal öznelikleri 2-B modelleme görüntülerine dönüştürülmüş ve EEG sinyalleri transfer öğrenmeyle evrişimli sinir ağlarına uygulanmıştır. Tüm bunlara ek olarak, mobil telefonlarda sık kullanılan el hareketlerine ait MHH'ler ile MHH-BMTA adında yeni bir veri seti oluşturulmuş ve problem domainine beyin-mobil telefon arayüzleri de eklenmiştir. Yöntemlerin performansları MHH-BMTA ve BCI Competition yarışmalarında sunulan birçok veri setinde sınanmıştır.

Anahtar Kelimeler: Elektroensefalografi, Motor hareket hayali, Beyin-bilgisayar arayüzleri, Beyin-mobil telefon arayüzleri, 2-B öznelikler, Yarı olasılıksal dağılım modelleri, Örüntü tanıma, Oylama yöntemleri.

PhD. Thesis

SUMMARY

CLASSIFICATION OF EEG-BASED MOTOR IMAGERY TASKS USING 2-D
FEATURES AND QUASI-PROBABILISTIC DISTRIBUTION MODELS

Çağatay Murat YILMAZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KÖSE
2021, 150 Pages, 5 Pages Appendix

Motor imagery (MI) is one of the most frequently used ways of designing brain-computer interfaces (BCIs). In this method, motor actions are performed by stimulating the brain without using the neuromuscular system. In this dissertation, new pattern recognition techniques are presented for the classification of MI tasks. For this purpose, firstly, transition points on the signals are detected and 2-D features are extracted in a specialized feature space. After that, learning models are constructed using 2-D quasi-probabilistic distribution models (QPDM) and classification is carried out with probabilistic memberships. In the following, QPDM-based sub-classifiers are designed using data domain and some classifiers that also adopt the combinations in voting methods are proposed. Moreover, 2-D features are transformed into 2-D modelling images, and in this way, EEG signals are given as input to convolutional neural networks with the assistance of transfer learning. In addition to all these studies, a new data set, abbreviated as MI-BMPI, is introduced that contains MIs of most frequently used hand movements on mobile phones, and thus brain-mobile phone interfaces are added to the problem domain. The performances of proposed methods are tested on MI-BMPI and several BCI Competition data sets.

Key Words: Electroencephalogram, Motor imagery, Brain-computer interfaces, Brain-mobile phone interface, 2-D features, Quasi-probabilistic distribution model, Pattern recognition, Voting methods.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Yüzey elektrot sensörlerinin başlıkla yerleştirilmesi	2
Şekil 1.2. Epoc Flex ile elektrot sensörlerden EEG kayıtlarının alınması	3
Şekil 1.3. MHH görevleri için öznelilik çıkarma yöntemleri	7
Şekil 1.4. MHH görevleri için sınıflandırma yöntemleri.....	10
Şekil 1.5. K-EYK ile örnek bir test verisinin sınıflandırılması	24
Şekil 1.6. Maksimum sınır aralığında en iyi ayırıcı doğru	27
Şekil 1.7. EPOC Flex salin sensör EEG kayıt cihazı seti [67]	33
Şekil 1.8. Data Set 2a veri setinde elektrotların yerleşim düzeni	39
Şekil 2.1. Telefonda tıklama ve baş parmakla kaydırma hareketleri [182, 183].....	43
Şekil 2.2. Deneysel paradigmanın zamanlama planı	44
Şekil 2.3. Kayıt alma ortamı ve elektrot sensörlerin yerleştirilme düzeni	47
Şekil 2.4. EYD-I elektrot yerleşim düzeni	49
Şekil 2.5. EYD-II elektrot yerleşim düzeni	50
Şekil 2.6. EmotivPro kayıt arayüzü	51
Şekil 2.7. EmotivPro ile kaydedilen örnek bir EEG sinyali	52
Şekil 2.8. Temas kalite haritası.....	53
Şekil 2.9. Önışlemler öncesi ve sonrasında sinyaller ve genlik spektrumlarına bir örnek ..	54
Şekil 2.10. Örnek bir EEG sinyali ve belirlenen geçiş noktaları.....	56
Şekil 2.11. Tepe (solda) ve çukur (sağda) nokta modelleri	57
Şekil 2.12. Örnek bir sol el MHH sinyali (solda) ve bu sinyalin 2-B temsili (sağda).....	60
Şekil 2.13. Örnek bir sağ el MHH sinyali (solda) ve bu sinyalin 2-B temsili (sağda)	61
Şekil 2.14. Örnek 2-B Gauss çekirdekleri	63
Şekil 2.15. Bir alt sınıflandırıcının şematik gösterimi.....	68
Şekil 2.16. Yaklaşım 2'nin şematik gösterimi.....	70
Şekil 2.17. Frekans bantlarına göre üçlü sınıflandırıcı kombinasyonları	71
Şekil 2.18. Birleştirilmiş modelleme görüntülerinin oluşturulma diyagramı.....	73
Şekil 3.1. Data set Ia için oluşturulan 2-B örnek öğrenme modelleri	76
Şekil 3.2. Sol/sağ el ve sol el/ayaklar MHH için örnek öğrenme modelleri	80
Şekil 3.3. Sol el/dil ve sağ el/ayaklar MHH için örnek öğrenme modelleri.....	81

Şekil 3.4. Sol/sağ el MHH için literatüre göre doğruluk kıyaslamaları	85
Şekil 3.5. Sol/sağ el MHH için literatüre göre kappa kıyaslamaları	87
Şekil 3.6. Sol el/ayaklar MHH için literatüre göre doğruluk kıyaslamaları	90
Şekil 3.7. Sol el/dil MHH için literatüre göre doğruluk kıyaslamaları	92
Şekil 3.8. Sağ el/ayaklar MHH için literatüre göre doğruluk kıyaslamaları	95
Şekil 3.9. Sağ el/dil MHH için literatüre göre doğruluk kıyaslamaları	97
Şekil 3.10. Ayaklar/dil MHH için literatüre göre doğruluk kıyaslamaları	100
Şekil 3.11. Tıklama ve kaydırma MHH için örnek öğrenme modelleri	105
Şekil 3.12. Elektrot sensör konumları ve geçiş eşiğinin performansa katkıları	111
Şekil 3.13. Olasılık eşiği ve ayırma değerinin performansa katkıları	112
Şekil 3.14. Farklı eğitim test oranlarında sınıflandırma performansları.....	113
Şekil 3.15. Tıklama ve kaydırma görevleri için birleştirilmiş modelleme görüntüleri	121
Şekil 3.16. Farklı oturumlar için sınıflandırma doğruluk kıyaslamaları	124
Şekil 3.17. %50-%50 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları.....	125
Şekil 3.18. %70-%30 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları.....	126
Şekil 3.19. %90-%10 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları.....	127

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. İki sınıflı bir problem için karışım matrisi	31
Tablo 1.2. Kappa ölçütü yorumlama aralıkları.....	33
Tablo 1.3. Temas kalitesine göre gösterge renk değerleri.....	36
Tablo 1.4. Data Set IIa veri setinde deneme sayılarının kategorilere göre dağılımları	40
Tablo 2.1. Oturumlarda kaydedilen deneme sayılarının kategorilere göre dağılımları.....	45
Tablo 2.2. Denek bilgileri.....	46
Tablo 3.1. Data Set Ia için sınıflandırma doğruluk kıyaslamaları.....	77
Tablo 3.2. Sol/sağ el MHH için sınıflandırma doğrulukları ve kappa değerleri	83
Tablo 3.3. Sol/sağ el MHH için sınıflandırma doğruluk kıyaslamaları	84
Tablo 3.4. Sol/sağ el MHH için kappa değerleri kıyaslamaları.....	86
Tablo 3.5. Sol el/ayaklar MHH için sınıflandırma doğrulukları ve kappa değerleri.....	88
Tablo 3.6. Sol el/ayaklar MHH için sınıflandırma doğruluk kıyaslamaları	89
Tablo 3.7. Sol el/dil MHH için sınıflandırma doğrulukları ve kappa değerleri	91
Tablo 3.8. Sol el/dil MHH için sınıflandırma doğruluk kıyaslamaları.....	92
Tablo 3.9. Sağ el/ayaklar MHH için sınıflandırma doğrulukları ve kappa değerleri	93
Tablo 3.10. Sağ el/ayaklar MHH için sınıflandırma doğruluk kıyaslamaları	94
Tablo 3.11. Sağ el/dil MHH için sınıflandırma doğrulukları ve kappa değerleri.....	96
Tablo 3.12. Sağ el/dil MHH için sınıflandırma doğruluk kıyaslamaları.....	96
Tablo 3.13. Ayaklar/dil MHH için sınıflandırma doğrulukları ve kappa değerleri.....	98
Tablo 3.14. Ayaklar/dil MHH için sınıflandırma doğruluk kıyaslamaları	99
Tablo 3.15. Farklı oturumlar ve çeşitli eğitim test oranlarında deneme sayıları.....	103
Tablo 3.16. Farklı oturumlara ait eğitim ve test kümelerinde sınıflandırma sonuçları	107
Tablo 3.17. %50-%50 eğitim test oranında sınıflandırma sonuçları	108
Tablo 3.18. %70-%30 eğitim test oranında sınıflandırma sonuçları	109
Tablo 3.19. %90-%10 eğitim test oranında sınıflandırma sonuçları	110
Tablo 3.20. Farklı eğitim test oranlarında K-EYK ile sınıflandırma sonuçları.....	116
Tablo 3.21. Farklı eğitim test oranlarında DVM ile sınıflandırma sonuçları	118
Tablo 3.22. Farklı ESA'ların sınıflandırma sonuçları	122
Tablo 3.23. ESA'ların çoğunluk oylama sınıflandırma sonuçları	123

SEMBOLLER DİZİNİ

2-B	2 Boyutlu
BMA	Beyin Makine Arayüzü (Brain Machine Interfaces)
BMG	Birleştirilmiş Modelleme Görüntüsü
BMTA	Beyin-Mobil Telefon Arayüzü (Brain-mobile Phone Interface)
CDFCSP	Class Discrepancy-Guided Subband Filter-Based Common Spatial Pattern
CSD	Covariate Shift-Detection
CSD2	Current Source Density
CILK	Conformal-Isometric Linearizing Kernel
DAA	Doğrusal Ayırtaç Analizi (Linear Discriminant Analysis)
DLCSPauto	RCSP Based on Automatic Diagonal Loading
DPA	Dalgacık Paket Ayırıştırması (Wavelet Packet Decomposition)
DSA	Derin Sinir Ağları (Deep Neural Networks)
DVM	Destek Vektör Makineleri (Support Vector Machines, SVM)
EEG	Elektroensefalografi (Electroencephalography)
ESA	Evrışimsel Sinir Ağları (Convolutional Neural Network)
ESVL	Topluluk Destek Vektör Makineleri (Ensemble Support Vector Learning)
FB	Frekans Bandı
FBCSP	Filter Bank CSP
GKA	Görgül Kip Ayrışımı (Empirical Mode Decomposition)
GOR	Genel Ortalama Referans (Common Average Reference)
GSW	Geometric Sample Weighting Algorithm
K-EYK	K En Yakın Komşusu Algoritması (K-Nearest Neighbour Algorithm)
KPCA	Çekirdek Temel Bileşenler Analizi (Kernel PCA)
LLE	Locally Linear Embedding
MDM	Minimum Distance to Mean
MEG	Magnetoensefalografi (Magnetoencephalography)
MEMDBF	Görgül Kip Ayrışımının Çok Değişkenli Uzantısı (Multivariate Extension of Empirical Mode Decomposition)
MG	Modelleme Görüntüsü
MHH	Motor Hareket Hayali (Motor Imagery)

MNN	Değiştirilmiş En Yakın Komşu Algoritması (Modified Version of Nearest Neighbor Algorithm)
OİD	Olayla İlişkili Desen-kronizasyon (Event Related Desynchronization)
OİS	Event Related Synchronization (Olayla İlişkili Senkronizasyon)
ONK	Öznitelik Noktası
ORT	Ortalama
OUÖ	Ortak Uzamsal Örüntüler (Common Spatial Patterns, CSP)
OM	Öznitelik Matrisi
RoCSP	Robust Ortak Uzamsal Örüntüler (Robust Common Spatial Pattern)
RQNN	Recurrent Quantum Neural Network
SMM	Saklı Markov Modelleri (Hidden Markov Models)
SR CSP	Uzamsal Düzenlemeli Ortak Uzamsal Örüntüler (Spatially Regularized Common Spatial Pattern)
SRIT2NFIS	Self-Regulated Interval Type-2 Neuro-Fuzzy Inference System
SS	Standart Sapma
SS _F	Finite Difference Method
SS-MEMDB	Görgül Kip Ayrışımının Kişiyeye Özel Çok Değişkenli Uzantısı (Subject Specific Multivariate Empirical Mode Decomposition)
SSL	Spherical Surface Laplacian
SS _R	SSL Using Realistic Head Model
STDF	Spatiotemporal Discrepancy Feature
STR	Space-Time Recurrence
TBA	Temel Bileşen Analizi (Principal Component Analysis)
TI	Transductive Learning
TLCS D	Transductive Learning with CSD
TRCSP	Tikhonov Düzenlemeli Ortak Uzamsal Örüntüler (Tikhonov Regularization Common Spatial Pattern)
UB	Upper Bound
YODM	Yarı Olasılıksal Dağılım Modeli (Quasi-Probabilistic Distribution Model)
YSA	Yapay Sinir Ağları (Artificial Neural Networks)
ZD	Zaman Dilimi
WOLA-CSP	Weighted Overlap-Add Common Spatial Pattern

WTRCSP

Ağırlıklı Tikhonov Düzenlemeli Ortak Uzamsal Örüntüler) Weighted
Tikhonov Regularized CSP)



1. GENEL BİLGİLER

1.1. Giriş


İnsan düşünce, hareket ve davranışlarının elektronik araçlarla edinilmesi, analizi, günlük yaşamda uygulanabilirliğinin araştırılması, yazılım ve donanım gereksinimlerinin üretilmesi günümüz araştırma-geliştirme çalışmalarının önemli ihtiyaçlarındandır. İnsanların duygu, düşünce, hareket ve davranışlarını anlamada önemli bir araç olan Elektroensefalografi (EEG) insan beyin aktivitelerinin ölçülmesi, kaydedilmesi ve incelenmesine imkân veren bir nörogörüntüleme yöntemidir. Beyindeki farklı uyarılar ve düşünceler beyin yüzeyinde farklı voltaj değişimleri (örüntüler) oluştururlar. Bu biyomedikal elektriksel aktivite sinyalleri beyin fonksiyonlarının tahmin edilmesinde etkilidir [1, 2]. EEG sinyalleri makine öğrenmesi ve sinyal işleme alanlarının kuramsal olarak belirli olgunluk seviyesine ulaşması, yazılım ve donanım imkanlarının artmasıyla, insanları anlama ve yaşamı kolaylaştırmada sıklıkla kullanılmaya başlamıştır.

EEG sinyalleri beyin makine arayüzleri (BMA), tüketici nörobilimi, psikiyatri, hastalık teşhis ve tedavisi gibi geniş bir çalışma alanında kullanılır. Bu araştırma alanlarından BMA'larda nöromusküler sistem pas geçilerek beyinle cihazlar arasında kas hareketleri olmayan bir iletişim ortamı kurulur. Motor hareket hayali (MHH) BMA sistemlerinin tasarlanmasında sık başvurulan yaklaşımlardandır. İpucu temelli MHH yaklaşımları hareketlerin hayal edilmesiyle uyarılan EEG aktiviteleri kullanılır. Herhangi bir eylem motor sistem kullanılmadan sadece beyinde simule edilerek yürütülür. Bu sistemlerin geliştirilmesi için günümüzde kullanılan en başarılı yöntemlerden biri örüntü tanıma teknikleridir. Bu tekniklerin başarısı da örüntü tanımanın iki önemli aşaması olan öznitelik çıkarma ve sınıflandırmanın performansına bağlıdır. Günümüzde EEG tabanlı BMA sistemlerinin performansları iyileştirilmelidir. Çünkü, çok sayıda umut vaat eden sonuçlara rağmen pratik uygulamalar düşünüldüğünde, mevcut BMA'ların gürültü, aykırı değerler, durağan olmayan yapı, uzun kalibrasyon ve eğitim süreleri, denekten-deneğe ve oturumdan-oturuma farklılıklar, düşük sağlamlık ve güvenilirlik gibi birçok problemle aynı anda baş etmesi oldukça zordur. Bu nedenle, EEG temelli arayüz sistemleri için özgün örüntü tanıma tekniklerinin geliştirilmesi ve performanslarının artırılmasına yönelik araştırmalar

yapılmalıdır. Elde edilecek başarılı sonuçlar EEG temelli arayüz sistemlerini daha ileriye götürecektir ve literatüre katkı sağlayacaktır.


1.2. Elektroensefalografi

Beyindeki farklı uyarılar ve düşünceler zamanla farklı örüntüler oluştururlar. Bu biyomedikal elektriksel aktivite örüntüleri beyin fonksiyonlarının tahmin edilmesinde önemli ve etkili öğrenme verisi olarak kullanılabilir [2, 3]. Beyin sinyal aktivitelerini incelemek için birçok nörogörüntüleme yöntemi önerilmiştir. Bu yöntemlerden bazıları EEG, magnetoensefalografi (MEG), elektrokortikografi (ECoG), fonksiyonel manyetik rezonans görüntüleme (fMRI), yakın kızılötesi spektroskopisi (NIRS) ve Pozitron emisyon tomografi (PET) teknikleridir. EEG en bilinen ve farklı alanlarda en sık kullanılan nörogörüntüleme yöntemlerindedir. Yöntemde her biri farklı beyin bölgelerine denk gelecek şekilde yüzey elektrot sensörleri başlık yardımıyla kafaya yerleştirilir (Şekil 1.1) ve EEG sinyalleri kaydedilir (Şekil 1.2). Çoğu nörogörüntüleme sistemi pahalı donanım ve geniş laboratuvar ekipmanına ihtiyaç duyar. Kablosuz ve konforlu sistemlerin tasarlanmasıyla EEG'nin kullanımı ve avantajları son yıllarda daha da artmıştır.



Şekil 1.1. Yüzey elektrot sensörlerinin başlıkla yerleştirilmesi

EEG sinyalleri beyin makine arayüzleri, tüketici nörobilimi, psikoloji, klinik, psikiyatri ve spor gibi farklı alanlarda sıklıkla kullanılır. Tüketici nörobiliminde pazarlamayla ilgili insan davranışlarının analiz edilmesi için market uyarılarına insan beyninin verdiği cevaplar EEG ve göz izleme teknikleriyle belirlenir. Böylelikle, ihtiyaçlara daha uyumlu tasarımlarda ticari ürünler üretilmeye çalışılır [4]. Nöropazarlama alanında kullanıcıların memnuniyet derecesi ölçülür ve geri beslemelere göre ürünlerde geliştirmeler yapılır. Psikolojide ise biyolojik sinyallerin insan duygu ve dikkatlerini ölçmede kabul edilebilir seviyede bilgi içermesinden faydalanarak öğrencilerin öğrenme sürecinde dikkat seviyesi ve konsantrasyonu ölçülür. Ayrıca, yapılan araştırmalarda depresyona giren kişilerin depresyonda olmayanlara göre daha az sol ön EEG aktivitesi gösterdiği, kaygı bozukluğu olan kişilerinse daha yüksek sağ ön EEG aktivitesi gösterdiği gözlenmiştir [2].



Şekil 1.2. EPOC Flex ile elektrot sensörlerden EEG kayıtlarının alınması

Klinik çalışmalarda, epilepsi, kafa travması, hafıza ve uyku bozuklukları gibi hastalıkların teşhisinde kullanılır. Bunların dışında, herhangi bir organı alınan, omuriliği yaralanan, felç ve beyin hasarı olan kişilerin yaşam kalitesini artırmaya yönelik yapay uzuvların geliştirilmesi için de çalışmalar yapılmaktadır. Örneğin, [5] EEG, EMG ve ivmeölçer gibi fizyolojik sinyaller kullanarak protezlerin çok modlu kontrolünü hedeflemektedir. Bilindiği gibi teniste yetenekli sporcular acemilere göre rakiplerinin

hareketlerini önceden tahmin edebilir. [5]'de bu amaca yönelik olarak teniste ileriye dönük yetenekleri ölçen bir video simülasyonu ve EEG sinyalleriyle uzman bilgisinin altında yatan sinirsel süreçlerin değerlendirilmesi amaçlanmaktadır. Bu çalışmaların dışında, yapay EEG verilerinin üretilmesi, beyindeki tümörlerin belirlenmesi, şeker hastalığı ile EEG arasındaki ilişkinin olabilirliğinin irdelenmesi gibi daha özel araştırmalarda yürütülür.

1.3. Beyin Makine Arayüzleri

Beyin makine arayüzleri (BMA) beyin aktivitelerini tanıyarak beyinle bilgisayar, cep telefonu gibi elektronik cihazlar arasında kas hareketleri olmayan bir iletişim ortamı sağlar. Bu arayüz beyin sinyallerinin kontrol ve komutlara dönüştürülmesiyle gerçekleşir. Dönüşüm için öncelikle beyin sinyallerinin elektronik cihazlarla anlamlandırılması gerekir. Anlamlandırmada sinyallerin edinilmesi, kaydedilmesi, yapısının açıklanması ve işlenmesine kadar birçok aşama yürütülmelidir. EEG destekli arayüzlerin tasarlanması için yavaş kortikal, görsel uyarılmış ve P300 uyarılmış potansiyeller gibi tanımlamalar yapılmıştır [2]. Ayrıca, geçmiş otuz yılda birçok invazif ve invazif olmayan BMA çalışması yürütülmüştür [2, 6]. [7, 8, 9, 10] iletişim ve kontrol için bazı BMA'lar; [8, 11, 12] fiziksel ve motor bozukluğa olan hastaların yaşam kalitelerinin artırılmasına yönelik BMA'lar ve [13, 14, 15] ise beyinle ilişkili hastalıkların teşhisi ve tedavisi için önerilen bazı BMA'lardır.

1.4. Motor Hareket Hayali

Motor hareket hayali (MHH) EEG ile arayüz sistemlerinde sık başvurulan bir yaklaşımdır. İpucu temelli bu yaklaşımlarda, herhangi bir eylem motor sistem kullanılmadan beyinde zihnen benzeri simule edilerek gerçekleştirilir [16]. Kişinin kolunu hareket ettirmeden yalnızca zihinsel olarak kolunu hareket ettirdiğini hayal etmesi buna örnek verilebilir. Bu nedenle, kişinin kendini bir eylem yürütürken ilk ağızdan hayal etmesi MHH'nin en önemli parçasıdır [17]. Düşünme ve hareket hayalinin fizyolojik temellerinin araştırılması için birçok nörogörüntüleme ve edinme tekniği kullanılmıştır. İlk çalışmalardan bazıları bölgesel serebral kan akışı (rCBF) ile yürütülmüştür. Beyindeki saf mental aktivitelerle düşünme eylemlerinin serebral kan akışını artırarak farklı türdeki düşünmelerin

farklı kortikal bölgelerde rCBF'yi arttırdığı gözlenmiştir [18]. Örneğin, hareket hayalinde suplementer motor ve premotor alanda akışta bir artış olurken primer duyu ve motor kortekslerdeki akışta farklılık olur [19]. Bu konudaki ilk örneklerden birinde sıralı parmak hareketlerinin hayali sürecinde rCBF'nin özellikle suplementer motor alanda arttığı görülmüştür [20]. Bu dönemdeki diğer araştırmalarda primer motor korteksin de hareket hayalini kapsayacağı düşünülmüştür. Ayrıca, fonksiyonel beyin görüntüleme teknikleri de motor performans sırasında aktif olan çeşitli kortikal ve subkortikal bölgelerin aynı zamanda hareketlerin hayali ve provası sırasında da aktif olduğunu öne sürmüştür [21]. Aynı çalışmada, motor hareketlerin yürütülmesi veya hayali sırasında primer motor korteksin bu akışa dahil olduğu öne sürülmüştür. [22]'de ise FMRG ile suplementer motor alanlarda aktivite değişimleri görülürken primer sensorimotor bölgelerinde değişim gözlenmemiştir.


MHH belirli EEG frekans osilasyonlarında meydana gelir ve ağırlıklı olarak hayal edilen vücut bölümüyle ilişkili sensorimotor kortikal bölgelerdeki spektral güçte azalma gibi olaya ilişkin beyin potansiyellerini ortaya çıkarır [23]. Önceki çalışmalarda, motor hafıza bilgilerinin motor sistemde kaydedildiği ve MHH'nin bir çeşit motor hazırlık sürecine karşılık düştüğü görüşü kabul görmüştür. Bu süreçte, motor programlar motor performansları simule etmek için hareketleri tekrar yürütme yerine hafızadan geri getirir. Bu simülasyon hipotezi psikofiziksel ve nörogörüntüleme teknikleriyle de desteklenmiştir. Ayrıca, psikofiziksel deneyler hayal edilen hareketlerin hız-doğruluk ödünleşmesi gibi aynı motor kurallara ve gerçek hareketler gibi benzer biyomekanik kısıtlar içerdiğini göstermiştir [17]. İzole uzuvların hareketlerinin hayali, bütün vücudun hareketinin hayali, eşyaların hareket ettirilmesinin hayali, sporcular ve müzisyenlere yönelik zihinsel provalar bazı hareket hayali örnekleridir [16, 17]. MHH günümüzde sağlık, rehabilitasyon, spor, dans, müzik gibi birçok alanda hareket öğrenme, pratik yapma ve tedavi amaçlı da araştırılmaktadır. Felç olan uzuvların zihinsel pratik yaparak iyileşmesi bunlardan biridir. Çünkü, herhangi bir motor eylem hem zihinde simule edildiğinde hem de kaslarla fiziksel olarak yapıldığında aynı beyin bölgelerini çalıştırır [23]. Görüleceği gibi, MHH insan hayatını doğrudan etkilemektedir ve getireceği fayda açısından oldukça önemlidir. Bu nedenle, MHH altında yatan sinirsel mekanizmalar ve bu mekanizmaların motor iyileşmeyle ilişkisinin anlaşılmasına yönelik birçok çalışma yürütülmektedir.

1.5. Motor Hareket Hayali İçin Örüntü Tanıma Yöntemleri

EEG tabanlı problemler örüntü tanıma teknikleriyle çözülebilirler ve BMA'ların başarısı bilhassa önerilecek yöntemlerin sınıflandırma performansına bağlıdır. Örüntü tanıma teknikleri önişlemler, öznitelik çıkarma ve sınıflandırma şeklinde üç önemli aşama içerir. Bu aşamaların tamamı performansı doğrudan etkiler. Öznitelik çıkarma sınıflandırma aşamasının başarısında önemli bir role sahiptir [3, 24]. EEG kullanan arayüzlerin insan hayatına kazandırılması için halen birçok problem çözülmelidir. Bu problemlerden bazıları, durağan yapıda ve doğrusal olmama, yüksek boyutluluk, gürültü (göz kırpma, yüz kas hareketleri vb. nedenlerle oluşan), kayıtların yanlış alınması, düşük kaliteli sinyaller, oturumdan-oturuma ve denekten-deneğe farklılıklardır. EEG örüntülerinin sınıflandırılması için bu hususlara dikkat edilmeli, örüntü tanıma aşamalarının performansları arttırılmalı ve sinyallerin gerçek yapısını anlamak için araştırmalar yapılmalıdır [24].

1.5.1. Öznitelik Çıkarma Yöntemleri

Öznitelik çıkarma sinyalleri temsil edecek faydalı bilgi içeren örüntülerin sayısal olarak edinilmesidir. Bu işlemde, sinyalleri özet biçimde tanımlayan bilgiler çıkarılır ve sınıflandırmada kullanılacak öznitelikler hesaplanır. Öznitelik çıkarma ayrıca gürültü ve istenmeyen parçaların elimine edilmesini sağlar [25, 26]. Sinyal analizinin popüleritesi ve ihtiyacı arttıkça, öznitelik çıkarma yöntemlerinin başarıları ve güvenilirliğinin arttırılmasına yönelik çalışmalar yürütülmeye devam etmektedir [27]. Bu çalışmaların birçoğu durağan ve doğrusal olmama, gürültü, aykırı değerler, düşük sinyal-gürültü oranı, yüksek zamansal çözünürlük kaynaklı boyutsallık belası gibi problemleri çözmeyi amaçlamıştır. Motor hareket hayali görevlerine ait sinyal özniteliklerin hesaplanması için önerilen yöntemler altı başlıkta toplanabilir: (1) zaman düzlemi öznitelikleri, (2) frekans düzlemi öznitelikleri, (3) zaman-frekans düzlemi öznitelikleri (4) uzamsal düzlem öznitelikleri, (5) uyarlanabilir yöntem öznitelikleri, (6) öznitelik çıkarma yöntemlerinin kombinasyonları (Şekil 1.3).



Şekil 1.3. MHH görevleri için öznitelik çıkarma yöntemleri

1.5.1.1. Zaman Düzlemi Öznitelikleri

İşaretlerin genlik veya formundaki değişimlerden faydalanarak hesaplanır [28, 29]. Genellikle herhangi bir dönüşüm veya karmaşık hesaplama içermezler. Bu nedenle, gerçek zamanlı BMA'lar için kısmen uygun seçenek olarak görülebilirler [30]. Ortalama, varyans, basıklık, çarpıklık, entropi, sıfırı geçme oranı en bilinen bazı örnekleridir.

1.5.1.2. Frekans Düzlemi Öznitelikleri

Güç spektrum yoğunluğu kaynaklıdır ve sinyallerin salınım aktivitelerindeki değişimlerle ilgilidir. Periodogram veya parametrik yöntemlerle hesaplanırlar. Hesaplama karmaşıklıkları ve maliyetleri zaman düzlemi özniteliklerine göre genellikle daha fazladır [28, 31]. Frekans bileşenleri beyin dinamiklerinin edinilmesi için MHH'de sıklıkla kullanılır [32]. Fourier, hızlı Fourier dönüşümü ve spektral güç yoğunluğu en bilinen bazı örnekleridir [33]. Bu yöntemler ilk olarak durağan yapıdaki sinyallerin analizi için önerilmiştir [34]. Ancak, doğrusal olmayan ve yapısı gereği hem zaman hem de frekans bilgisi içeren EEG sinyallerinin analizi için de sıklıkla kullanılmaya başlamıştır.

1.5.1.3. Zaman-Frekans Düzlemi Öznitelikleri

MHH görevlerine ait EEG sinyalleri doğrusal değildir ve yapıları gereği hem zaman hem de frekans düzlemi bilgileri içerir [35]. Zaman ve frekans düzlemi bilgilerini ayrı ayrı

ele almak EEG sinyallerinin doğrusal olmayan karakteristiği doğru ifade etmez. Bu nedenle, zaman ve frekans düzlemi bilgilerinin birlikte kullanıldığı zaman-frekans düzlemi öznitelikleri bu problemlere belirli seviyede çözüm sunarlar [35]. Bu öznitelikler aynı anda hem sinyallerin frekans bilgilerini hem de ani zamansal değişimlerini yakalarlar. Sinyalin enerjisini zamanın ve frekansın bir fonksiyonu olarak ifade eden bu teknikler boyut arttırmak için de kullanılır [36, 37]. Ayrıca, durağan yapıda olmama problemine belirli seviyede çözüm sunarlar [35]. Kısa zamanlı Fourier dönüşümü, Hilbert-Huang dönüşümü (HHD), dalgacık dönüşümü ve ayrıştırmasıyla EEG sinyalleri zaman-frekans düzleminde ifade edilebilirler [37, 156]. Örneğin, MHH'de belirli frekans bantlarında genlikte güç düşümü (OİD) veya güç artımı (OİS) gerçekleşir. Olay ilişkili bu OİD ve OİS örüntüleri HDD ile ifade edilebilir [38]. Literatürde, hesaplama karmaşıklığı, gereğinden fazla frekans bilgisi içermesi ve doğrusal yapıda olmama gibi problemlerin mevcudiyeti görülür. Dahası, sinyallerin genlik ve frekans değerleri (veya aralıkları) durumdan duruma, denekten-deneğe, yaşa ve cinsiyete göre değişim gösterebilir. Zaman-frekans düzlemi öznitelikleri ile bu problemler çözülmeye çalışılırken iki düzlem arasındaki ödünleşim dikkate alınmalıdır. Çünkü, kısa zamanlı Fourier dönüşümü gibi bazı yöntemlerde zaman ekseninde kesinlik arttıkça (azaldıkça) frekans bilgisi bir o kadar hatalı (doğru) olur.

1.5.1.4. Uzamsal Düzlem Öznitelikleri

Çoğu problemde bir elektrottan kaydedilen sinyaller sınıflandırma ve karar verme için yeterli olmaz [40]. Çünkü aynı elektrot konumunda ve frekans bandında diğer bazı beyinsel kaynaklar daha güçlü sinyaller üretebilir. Bu durum ilgilenilen sinyalin zayıf olması, bozulması, bastırılması ve yanlış örüntülerin elde edilmesine neden olabilir [39]. Sadece hareket hayali bilgisi içeren ve en faydalı bilgilere sahip elektrotların kullanılması bu problem için bir dizi çözüm sunar. Birçok elektrottan alınan sinyallerin seçilmesi, birleştirilmesi ve gürültülerin kaldırılması uzamsal filtrelerle gerçekleştirilebilir. Seçme ve birleştirme elle veya bazı algoritmalarla otomatik yapılabilir [40]. İki sınıflı sinyallerin ayrışma performansını arttırmayı hedefleyen ortak uzamsal örüntüler (OUÖ) en bilinen uzamsal yöntemlerdir. Literatürde, gürültüye dayanıklılık [42], aşırı uyumluluk, durağan olmama [41] ve çok sınıflı sınıflandırma [43] problemleri için birçok OUÖ uzantısı

önerilmiştir. Ayrıca, genel ortalama referans, Laplacian uzamsal filtresi ve bağımsız bileşen analizi tekniklerinin de sınıflandırma performansını arttırdığı görülmüştür.

1.5.1.5. Uyarlanabilir Yöntem Öznitelikleri

Zamanla hızla değişim gösteren EEG sinyallerinin öznitelikleri durağan değildir. Bu gibi problemlerin çözümü için önerilen uyarlanabilir tekniklerde değişkenlikleri daha iyi yansıtmak için öznitelik çıkarma yöntemi sürekli güncellenir. Örneğin, model parametrelerinin zamanla değişmediği özbağlanımlı parametreler tekniği zamanla değişen problemlerde başarısızken uyarlanabilir versiyonu [44] daha başarılıdır. Son yıllarda özellikle OUÖ'nün çok sayıda uyarlanabilir uzantısı önerilmiştir. Örneğin, [45] özyinelemeli en küçük karelerle OUÖ filtresinin katsayılarını iteratif güncellemiştir. Bu yöntemlerin dışında, dalgacık paket ayrıştırması (DPA) ve yarı gözetimli öznitelik çıkarma gibi yöntemlerde de uyarlanabilirliği sağlayacak düzenlemeler yapılmıştır [46].

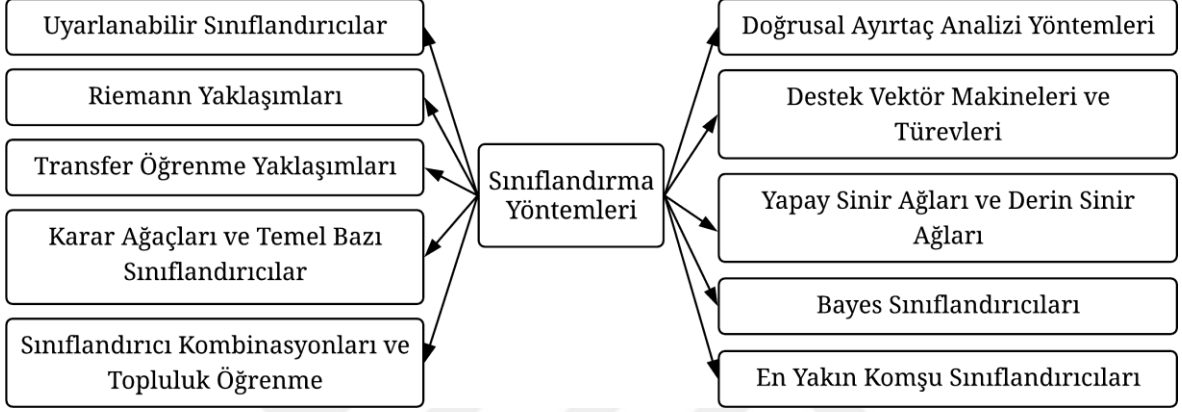
1.5.1.6. Öznitelik Çıkarma Yöntemlerinin Kombinasyonları

Öznitelikler birbirlerini tamamlıyorsa bu özniteliklerin doğru bir şekilde birleştirilmesi doğruluk açısından daha fazla kazanç üretebilir. Örneğin, [30] zaman düzlemine ait istatistiksel özniteliklerin birleştirmiştir. [47] ise karmaşıklık veya düzensizliği ölçebilen öznitelikleri hesaplayıp, kuantum davranışlı parçacık sürüsü optimizasyonu ile önemli alt-öznitelikleri kombinasyonlardan seçmiştir. Öznitelik kombinasyonları tek bir öznitelik çıkarma yönteminin kullanıldığı çalışmalara göre daha başarılı olabilir. Diğer taraftan, kombinasyona dayanan yöntemler öznitelik boyutunu artırır. Bu nedenle, boyutluluk belası gibi problemlerin aşılması için öznitelik seçimi yapılması gerekebilir [3].

1.5.2. Sınıflandırma Yöntemleri

Sınıflandırma yöntemleri beyin aktivite örüntülerini tanımlamak için kullanılır ve güvenilir sistemler için büyük önem arz ederler. MHH görev sinyallerini kullanan BMA'lar için sınıflandırıcılar şu ana başlıklar altında incelenebilir: (1) doğrusal ayırtaç analizi

yöntemleri, (2) destek vektör makineleri ve türevleri, (3) yapay sinir ağları ve derin sinir ağları, (4) Bayes sınıflandırıcıları, (5) en yakın komşu sınıflandırıcıları, (6) uyarlanabilir sınıflandırıcılar, (7) Riemann yaklaşımları, (8) transfer öğrenme, (9) karar ağaçları ve temel bazı sınıflandırıcılar ve (10) sınıflandırıcı kombinasyonları ve topluluk öğrenme (Şekil 1.4).



Şekil 1.4. MHH görevleri için sınıflandırma yöntemleri

1.5.2.1. Doğrusal Ayırtaç Analizi Yöntemleri

Doğrusal ayırtaç analizi (DAA) sınıflar arası dağılımı maksimum ve sınıf içi dağılımı minimum yaparak doğrusal sınır fonksiyonları kullanır. DAA belirlediği sınır ile denetimli boyut indirgeme de yapar [48, 49]. Kolay kullanımı ve düşük hesaplama karmaşıklığı nedeniyle çok sayıda çalışmada kullanılmıştır. Bayes tabanlı, uyarlanabilir ve artırılmış gibi birçok çeşidi literatürde önerilmiştir. Her bir kategorideki eğitim örneği sayısı veriler altında yatan Gauss dağılımını kestirecek yeterlilikteyse DAA genelde iyi sonuçlar üretir [50].

1.5.2.2. Destek Vektör Makineleri ve Türevleri

İyi genelleme kapasiteleri, aşırı öğrenme ve boyutluluk belasına nispeten dayanıklılıkları nedeniyle MHH örüntülerinin sınıflandırılmasında sık kullanılır. Destek vektör makineleri (DVM) bu işlemleri el ile tanımlanabilen birkaç hiper parametreyle (düzenleme ve gevşek değişken parametreleri vb.) gerçekleştirir. Doğrusal DVM sık kullanılan bir yöntemdir ancak karmaşık ve doğrusal olmayan verilerde başarısız olabilir [1].

Gerçek hayat problemlerinde sinyal öznitelikleri belirli bir hatayla doğrusal ayrılmaz. Bu problemler, çekirdek fonksiyonlarıyla yüksek boyutlu başka bir uzaya taşıma ve yeni uzayda ayırıcı hiper düzlemleri belirlemeyle çözülebilir [51]. DVM eğitim sürecinde büyük miktarda hafıza kullanır ve göreceli yavaş yakınsama problemi vardır. Öznitelik vektörlerinin boyutu çok büyük olmadıkça eğitim algoritması optimize edilerek bu problemler ortadan kaldırılabılır [52]. MHH görevleri için bulanık DVM, Kernel Fisher DVM, çapraz korelasyon temelli en küçük kareler içeren DVM ve bileşik çekirdek kullanan DVM [53] gibi birçok yöntem literatürde önerilmiştir.

1.5.2.3. Yapay Sinir Ağları ve Derin Sinir Ağları

MHH görevlerinin sınıflandırılması için sık kullanılan yapay sinir ağları (YSA) yaklaşımlarından bazıları çok katmanlı algılayıcılar, öğrenmeli vektör kuantalama, bulanık sinir ağları ve spiking sinir ağlarıdır. Günümüzde, yapay ağlarda yeni bir eğitim ve mimarinin oluşturulmasında derin sinir ağlarında (DSA) çalışmalar yapılmaktadır. Verinin hiyerarşik temsillerini otomatik öğrenebilecek makine öğrenme modelleri oluşturulmaya çalışan bu yöntemler, son on yılda özellikle bilgisayarla görme alanında yükselen seviyede başarı göstermiştir. DSA'lar hem etkili öznitelikleri hem de sınıflandırıcıları ham veriden eş zamanlı öğrenme potansiyeline sahiptir. Elde ettiği başarılar göz önüne alındığında DSA'ların daha iyi özniteliklere ve sınıflandırıcılara olanak sağlayacağı görülmektedir. MHH görevlerinin sınıflandırılması için evrimsel sinir ağları (ESA), derin Boltzmann makineleri, yinelemeli sinir ağları ve derin inanç ağları gibi yaklaşımlar literatürde önerilmiştir. Bu yaklaşımlar fazla sayıda parametreye sahiptir ve kalibrasyon için oldukça fazla eğitim örneğine ihtiyaç duyarlar [3, 54]. Bilindiği gibi, MHH problemlerine ait veri setleri az sayıda eğitim örneğine sahiptir. Bu nedenle, DSA'ların az sayıda örnek içeren küçük veri setlerinde başarısız olacağı düşünülür. Ayrıca, çevrimiçi sistemler ve kalibrasyon aşamalarında, DSA'ların hem eğitim hem de test kademelerinin hesaplama karmaşıklığı problemleri çözümlenmelidir. Güçlü grafik kartları kullanmak bu problemlerde her zaman yeterli bir çözüm olmaz. Çözüm için kişilere özel eğitim paradigması içermeyen evrensel DSA'ların tasarlanması bir alternatif olabilir [3]. Bunun dışında, DSA'lar MHH problemlerine uygulanırken, katman sayısı, evrimsel ve ortaklama fitrelerin boyutu,

evrişimsel katmandaki filtre sayıları, aktivasyon fonksiyonları gibi hiper parametrelerin en iyi konfigürasyonun bulunması gerekir. Bilindiği gibi, çoğu DSA (doğrudan zaman serilerinden öğrenen yöntemler hariç) görüntü gibi iki boyutlu girdilerin sınıflandırılması prensibiyle çalışır. Bu nedenle, tek boyutlu sinyallerin ESA'lara uygulanması için iki boyutlu öznitelik veya öznitelik dönüştürme yöntemleri gerekir. Literatürde, kısa zamanlı Fourier dönüşümü ve sürekli dalgacık dönüşümü gibi tekniklerle sinyaller görüntülere dönüştürülmüştür. Bu teknikler dışında, yinelemeli sinir ağlarının özel bir biçimi olan uzun-kısa süreli bellek gibi doğrudan zaman serilerinden öğrenen yöntemler de kullanılabilir [55].

1.5.2.4. Bayes Sınıflandırıcıları

Öznitelik vektörünün ait olduğu sınıfı en yüksek olasılıkla tahsis etmeyi amaçlar [56]. Sık kullanılan naive Bayes yöntemi güçlü bağımsızlık varsayımlarına dayanır ve parametre kestirimi en yüksek olasılıkla yapar [57]. MHH görevlerinin sınıflandırılmasında da kullanılan doğrusal olmayan karesel Bayes, ardışık minimal optimizasyon ve saklı Markov modelleri (SMM) belirsiz örneklerin daha kolay reddedilmesini sağlar [58]. SMM'ler özellikle zaman serilerinin sınıflandırılmasını içeren ses tanıma alanında popüler dinamik sınıflandırıcılardır ve MHH görevlerinin sınıflandırılmasında da kullanılır. Doğrusal olmayan Bayes yaklaşımları doğrusal sınıflandırıcılar ve yapay sinir ağları kadar yaygın kullanılmasa da genellikle başarılı sonuçlar üretirler [1, 58, 154].

1.5.2.5. En Yakın Komşu Sınıflandırıcıları

Eğitim kümesindeki en yakın k komşuya göre test örneğinin kategorisini belirleyen uygulaması basit yöntemlerdir. Düşük boyutlu özniteliklerde verimli olabilirler, ancak boyutluluk belası, ilgisiz ve fazla veri problemlerine karşı hassastırlar. Ayrıca, eğitim kümesindeki örnek sayısı arttıkça gerçek zamanlı ve çevrimiçi çalışma olanakları düşer. Zaman düzlemi özniteliklerinin sınıflandırılması için literatürde sıklıkla kullanılırlar.

1.5.2.6. Uyarlanabilir Sınıflandırıcılar

EEG sinyallerinin durağan olmayan yapısı önceki verileri kullanarak oluşturulmuş bir sınıflandırma modelinin daha önce yapılan değişiklikleri iyi yansıtamayabileceği anlamına gelir. Bu nedenle sınıflandırma modeline uyarlanabilir güncellemeler gerekir. Uyarlanabilir sınıflandırıcılarda yeni veriler girdikçe parametreler yeniden tahmin edilir ve güncellenir. Böylelikle, öznitelik dağılımındaki değişimler sınıflandırıcılar tarafından izlenir ve EEG gibi durağan olmayan sinyallerde bile başarı sağlanabilir. EEG sinyallerine ait özniteliklerin çıkarılması ve sınıflandırma için özellikle son çeyrek asırdır kullanılırlar. Literatürde, çevrimiçi ve çevrimdışı deneylerde dahil olmak üzere birçok uyarlanabilir teknik önerilmiş ve başarılı sonuçlar alınmıştır [46]. Uyarlanabilir DAA, DVM, Bayes sınıflandırıcıları ve YSA en yaygın bazı örnekleridir [46]. Bilindiği gibi, geleneksel BMA'lar çevrimdışı analizle sınıflandırıcı parametrelerini hesaplar ve çevrimiçi testlerde bu parametreleri kullanır. Ancak, durağan olmayan yapı nedeniyle öğrenme modelini yeni verilerle güncellemeyen sınıflandırıcıların günlük hayat sistemlerinde kullanımı zordur [59]. Bu nedenle, durağan olmayan sinyaller ve MHH kullanan gerçek zamanlı BMA sistemleri tasarımı için birçok uyarlanabilir sınıflandırıcı yaklaşımı önerilmiştir. Örneğin, [59] çevrimiçi deneylere yönelik uyarlanabilir ve artırılmış bir doğrusal ayırtaç analizi algoritması, [60] ise bir oturumda oluşturulan sınıflandırıcıyı güncellemek için değerlendirme aşamasından alınan bir dizi veriyi kullanan uyarlanabilir aşırı öğrenme makinesi yöntemi önermiştir.

1.5.2.7. Riemann Yaklaşımları

EEG sinyallerinin işlenmesinde yeni öznitelik temsillerinin belirlenmesi, dayanıklı sınıflandırıcıların tasarlanması ve yapay verilerin üretilmesine yönelik yeni bir yaklaşımdır. Sinyallere ait kovaryans matrisleri ve alt uzayların Riemann geometrisiyle doğrudan işlenmesine imkân verir. Ortak uzamsal örüntüler gibi alt uzay yöntemlerini iyileştirmek için kovaryans matrislerini doğrudan işleyerek MHH görevlerinin sınıflandırılmasında kullanılabilir. Kovaryans matrislerinin durağan olmayan yapıya yakınlığı nedeniyle birçok problemde başarılı sonuçlar göstermiştir. Bilindiği gibi, elektrot sayısı arttıkça kovaryans matrisinin boyutu artar ve genellikle başarı düşer. Bu durumlarda öklid geometrisi daha

başarılı olabilir. Ayrıca, Riemann yaklaşımları optimizasyon problemlerinde hesaplama maliyeti yüksek işlemler içerdiğinden gerçek zamanlı sistemler için uygun olmayabilir. Bu yaklaşımlar aykırı değer ve durağan olmayan sinyal yapısı gibi problemlere daha dayanıklı olacak şekilde adaptif yöntemlerle iyileştirilebilirler [61].

1.5.2.8. Transfer Öğrenme Yaklaşımları

Öznitelikleri ve sınıflandırıcıları bir problem domaininden diğerine aktarmak için kullanılırlar. Bu yöntemlerde farklı veya aynı deneğe ait başka görevlerde öğrenilen bilgiler sınıflandırma problemlerinde kullanılabilir [46]. BMA'larda yeni denekler için kişiye özel öznitelikleri ve sınıflandırıcıları oluşturmak gerekir. Bu işlem uzun süren yeniden eğitim aşaması anlamına gelir. Bilindiği gibi, pratik çevrimiçi BMA'lar için sistemin kısa sürede eğitilmesi gerekir. Çünkü kullanıcılarından uzun süre beklemeleri ve BMA'yı kullanmadan zihinsel komutları gerçekleştirmeleri istenemez [3]. Ayrıca, bilişsel bozukluklar ve konsantrasyon problemleri nedeniyle birçok kullanıcı için bu süreç sıkıcı ve zaman alıcı olacaktır [46]. Bunların yanı sıra, farklı oturumlarda alınan kayıtlarda bile farklılıklar olabilir ve eğitim verisi zamanla güncelliğini kaybederek sonraki kullanımlar için elverişsiz olabilir. Transfer öğrenme yaklaşımlarıyla bu gibi problemler çözülebilir, oturumdan-oturuma ve denekten-deneğe eğitim süreleri etkili bir biçimde azaltılabilir [46]. Son yıllarda, görsel tanıma gibi birçok alanlarda elde edilen başarılı sonuçlarla, MHH görevlerinin sınıflandırılması dahil birçok alanda transfer öğrenme oldukça kullanılır olmuştur.

1.5.2.9. Karar Ağaçları ve Temel Bazı Sınıflandırıcılar

Eğitim kümesindeki örneklerden ağaç yapısında karar verme modeli oluşturan kılavuzlu öğrenme yöntemleridir. Sınıflandırma ağaçları olarak da adlandırılan bu yöntemlerde ağaç yapısının oluşturulması kolaydır. Ancak, önemli olan derinliği fazla olmayan (yeterli küçükte) başarılı ağaçların oluşturulmasıdır. İyi yapıda karar ağaçları için ID3 ve C4.5 gibi bilgi kazancına dayalı teknikler kullanılır [62]. Ağaç yapıları literatürde çok farklı şekillerde kullanılmıştır. [63] MHH kullanan arayüzler için on farklı karar ağacı yapısı oluşturmuş, ağırlıkları belirlemiş ve çoğunluk oylamayla karar vermiştir. [53] rastgele

ormanlar gibi karar ağaçları içeren teknikler kullanmıştır. Sinirsel-bulanık karar verme [64] vb. ise MHH görevlerinin sınıflandırılmasında kullanılan diğer başlıca yöntemlerdir.

1.5.2.10. Sınıflandırıcı Kombinasyonları ve Topluluk Öğrenme

Tek sınıflandırıcının kullanıldığı çalışmalara kıyasla artırma, torbalama ve oylama teknikleriyle sınıflandırıcı kombinasyonlarının kullanma son yıllarda oldukça popüler olmuştur [1]. AdaBoost, GentleBoost ve LogitBoost artırma sınıflandırıcıları; Bagging-DT (rastgele orman algoritması), Bagging-K-EYK, Bagging-DAA ve Bagging-DVM torbalama sınıflandırıcıları; (ağırlıklı) çoğunluk ve yumuşak oylama ise sınıflandırıcı kombinasyonları oluşturmak için kullanılan oylama teknikleridir [4, 65]. Bu yöntemler birçok çalışmada tekli sınıflandırıcılara göre daha başarılı sonuç göstermiştir. Ancak, bu yöntemler gerçek zamanlı BMA sistemleri için özellikle eğitim aşamasında zaman alıcı olabilir [66].

1.6. Tezin Kapsamı

Beyin aktivitelerinin EEG nörogörüntüleme tekniğiyle edinilmesi, analizi, kuramsal yöntemlerle anlamlandırılması, uygulamalara yönelik yazılım ve donanım gereksinimlerinin üretilmesi günümüzün önemli ihtiyaçlarından. MHH görevlerini kullanan BMA'ların günlük hayatımıza girmesini engelleyen en önemli sebeplerden bazıları düşük sağlamlık ve güvenilirlikleridir. Mevcut BMA'lar birçok problemten dolayı çok sayıda komutu yanlış tanır ve düşük doğrulukta çalışır. Bu problemler çeşitli seviyelerde çözülebilir. Örneğin, sinirbilim düzeyinde, daha güvenilir nörofizyolojik belirteçler tanımlanabilir ve daha iyi ölçüm yapan sensörler kullanılabilir. İnsan düzeyinde, kullanıcılar eğitilerek MHH örüntülerinde doğru ve istikrarlı kontrol sağlanabilir. Sinyal işleme düzeyinde içerik, gürültü, oturma gibi değişimlere dayanıklı, daha az örnekle eğitilip kalibre edilebilen çevrimiçi öznitelik ve sınıflandırıcılar inşa edilebilir. Günümüzde yeni çözümlerin üretilmesini amaçlayan çalışmalar özellikle sinyal işleme alanında hızla devam etmektedir.

Tez çalışmasında, MHH görevlerini içeren EEG sinyallerinin sınıflandırılması için sinyal işleme ve örüntü tanıma seviyesinde bazı çözümler önerilmiştir. Tezin hipotezi bu nedenle “motor hareket hayali görevlerine ait EEG sinyallerinin sınıflandırma

performansları yarı olasılıksal dağılım modelleriyle arttırılabilir” kuramına dayandırılmıştır. Bu amaçla, örüntü tanıma aşamasında öncelikle geçiş noktalarına ait yeni öznelikler tanımlanmıştır. Sonrasında, sinyal öznelikleri özelleşmiş bir sonlu uzayda 2-B modellenmiş ve özgün sinyal öznelikleri çıkarılmıştır. Sınıflandırma aşamasında 2-B yarı olasılıksal dağılımlar kullanan bir öğrenme modeli önerilmiş ve maksimum olasılık değerlerine dayanan bir yöntemle test sinyallerinin kategorileri belirlenmiştir. Ayrıca, yarı olasılıksal dağılım modelleri kullanan alt-sınıflandırıcılar oluşturulmuş ve topluluk öğrenme yöntemlerine uygulanmıştır. Çalışmanın son kısmında, evrişimli sinir ağlarına görüntü 2-B görüntü girdisi olarak verilebilecek bir sinyal görüntü dönüşümü yöntemi önerilmiş ve modelleme görüntüleri oluşturulmuştur. Önerilen yöntemlerinin performansları literatürde sıklıkla kullanılan ve sağlamlıkları bilinen birçok karşılaştırma veri setlerinde sınanarak olumlu yönde sonuçlar alınmıştır.

Tez çalışmasında, kuramsal teknikler dışında problem domaininde de eklemelere gidilmiştir. Bu kısımda, mobil telefonlar için günümüzde sıklıkla kullanılan bazı el hareket MHH’lerini içeren Motor Hareket Hayaline Dayalı Beyin-Mobil Telefon Arayüzü isimli bir veri seti oluşturulmuştur. Veri seti EPOC Flex Saline Sensor Kit ile müdahalesiz ve pratik BMA’lara yakın yapıda oluşturulmuştur. Mobil telefonlara yönelik böyle bir veri setinin oluşturulmasıyla problem domainindeki beyin-mobil telefon arayüzlerine katkı sağlanmıştır. Ayrıca, kablosuz iletişim kullanan EPOC Flex ile laboratuvar ortamlarına bağımlı modeller bir adım daha ileriye taşınarak pratik arayüz sistemlerinin tasarlanmasına katkı sağlanmıştır. Önerilen yöntemlerin ve literatürde sıklıkla kullanılan bazı öznelik çıkarma ve sınıflandırma yöntemlerinin performansları MHH-BMTA veri setinde sınanmıştır. Bu veri setinde ayrıca, birleştirilmiş modelleme görüntüleri evrişimli sinir ağlarına transfer öğrenme teknikleriyle uygulanarak sonuçlar alınmıştır.

Önceki bölümlerde sırasıyla EEG, beyin makine arayüzleri ve motor hareket hayalinin tanımları yapılarak alt yapı oluşturulmuştur. Sonrasında, MHH için örüntü tanıma yöntemleri başlıklar halinde verilerek bu alandaki araştırmalar detaylandırılmıştır. Genel bilgiler kısmında ayrıca, tezin alt yapısını oluşturan yöntemler, MHH-BMTA veri setinin oluşturulmasında kullanılan EPOC Flex EEG kayıt cihazı, MHH-BMTA veri setinin geçerliliğinin sınaması için kullanılan örüntü tanıma teknikleri ve performans ölçümlerinin yapıldığı veri setleri verilmiştir. Yapılan çalışmalar kısmında, MHH-BMTA veri setinin oluşturulması ve önerilen örüntü tanıma yöntemlerinden başlanarak yapılan çalışmalar

verilmiştir. Bulgular ve irdeleme kısmında ise öncelikle gerçekleştirilen deneyler hakkında bilgiler verilmiş, daha sonra ise elde edilen bulgular sunularak detaylıca irdelenmiştir. Son iki bölümde, elde edilen temel bulgular sonuçlandırılıp, öneriler ve tartışmalar sunulmuştur.

1.7. Tekrarlamasız Kombinasyon

Kombinasyon, n elemanlı bir S kümesinden sıralamaları göz ardı ederek k elemanın seçilmesidir. Tekrarsız kombinasyon S kümesindeki bir elemanın en fazla bir kere seçildiği özel bir durumdur [69, 70]. $S = \{1, 2, \dots, n\}$ kümesi n elemanlı bir küme ve C_k ise S kümesinin k elemanlı tekrarsız kombinasyonlarını içeren küme olsun ($k, 0$ ile n aralığında). Bu durumda, $|C_k| = \binom{n}{k}$ ile ifade edilen S kümesinin tekrarsız k -kombinasyonları eşitlik (1.1)'deki gibi binom katsayıları ve faktöriyeler cinsinden ifade edilebilir [69, 70, 71]. Örneğin, elimizde $S = \{a, b, c, d\}$ kümesi olsun ve C_3 tekrarsız 3-elemanlı kombinasyonları içeren bir küme olsun. Bu durumda tüm 3'lü kombinasyonların sayısı $\binom{4}{3} = 4$ ve S 'in tüm kombinasyonları $C_3 = \{a, b, c\}, \{a, b, d\}, \{a, c, d\}, \{b, c, d\}$ şeklinde olacaktır [71].

$$\binom{n}{k} = \frac{(n)(n-1)(n-2)\dots(n-k+1)}{k!} = \frac{n!}{k!(n-k)!} \quad (1.1)$$

1.8. Topluluk Öğrenme Yöntemleri

Topluluk öğrenme yöntemleri (çoklu sınıflandırıcılar) farklı sınıflandırıcıları kullanan karma tekniklerdir. Sınıflandırıcı çıktılarını karar verme aşamasında birleştirerek daha sağlam sistemleri oluşturmayı amaçlar [72, 73]. Bu yöntemler daha güçlü karar vericiler için alt sınıflandırıcıların sonuçlarını oylarlar. Doğru kullanıldıklarında tekil sınıflandırıcılara göre daha başarılı sonuçlar gösterirler [74, 75]. Her birinin bir karakteristiği vardır ve kullanılmasının amaçlandığı problemlerde bu özelliklere dikkat edilmelidir. Bu yöntemler gerçek zamanlı sistemlerde hesaplama açısından zaman alıcı olabilir [66]. Son yıllarda, oylama, torbalama ve arttırma teknikleri tekli sınıflandırıcılara kıyasla birçok uygulamada başarılı olmuştur [1]. Arttırma için AdaBoost, GentleBoost ve LogitBoost; torbalama için

Bagging-DT, Bagging-K-EYK, Bagging-DAA ve Bagging-DVM; oylama için çoğunluk oylama, yumuşak oylama ve istifleme en bilinen örnekleridir [4, 65, 73].

Oylama yöntemleri aynı veri setinde eğitilmiş farklı alt sınıflandırıcıların tahminlerinin birleştirildiği en basit topluluk öğrenme yaklaşımlarıdır. Çoğunluk oylamada alt sınıflandırıcıların etiketleri, yumuşak oylamada ise sınıf olasılığı gibi sürekli değerler kullanılır. Bu yaklaşımlar temelde doğrusaldır ve değişmeyen ağırlıklar kullanır (eğer ağırlık kullanıyorlarsa) [75]. Daha karmaşık topluluk öğrenme yöntemleri oylamayla bir dizi sınıflandırıcı oluşturan arttırma ve torbalamadır [76]. Torbalamada her bir zayıf sınıflandırıcı birbirinden bağımsız oluşturulur [77] ve birinin performansı diğerini etkilemez. Bu nedenle, zayıf sınıflandırıcıların eşit ağırlıklı çıktılarını birleştirmek bağımsız bir paralel sınıflandırıcı içeren torbalama yapısı oluşturur [74]. Arttırma yöntemleri farklı ağırlıkları kullanır ve bu ağırlıklar algoritma içerisinde adaptif bir şekilde değiştirilir. Daha başarılı modellerin sınıflandırmadaki önemlerini ifade etmek ve bu modellere sınıflandırmada daha fazla etki vermek için farklı oylama güçleri verilir. Farklı oylama güçleri sınıflandırma doğrulukları gibi ölçütlerle verilir [72, 75, 76]. AdaBoost gibi arttırma yöntemleri sıralı bir sınıflandırıcı yapısına sahiptir. Çoğunluk oylama gibi yöntemler ise birbirinden bağımsız sınıflandırıcılar içerdiğinden paralel hesaplanabilir bir mimariye sahiptir.

Tez çalışmasında, çoğunluk ve eşit ağırlıkları kullanan yumuşak oylama yöntemleri bir dizi daha güçlü sınıflandırıcı oluşturmak için kullanılmıştır. Farklı frekans ve zaman dilimlerine uygulanan yarı olasılıksal dağılım modelleri ile alt sınıflandırıcılar oluşturulmuş ve çıktıları topluluk öğrenme yöntemlerine uygulanmıştır. Ayrıca, topluluk öğrenme yöntemleri için tekrarsız sınıflandırıcı kombinasyonları da incelenmiştir.

1.8.1. Çoğunluk Oylama

Çoğunluk oylama topluluk öğrenmenin en sade örneğidir. Tüm sistemin nihai sınıflandırma etiketi \hat{y} , m alt sınıflandırıcının (oylayıcı) en sık öngörülen etiket çıktısı $O_k(x)$ ile eşitlik (1.2)'deki gibi hesaplanır. Her bir sınıflandırıcı eşit ağırlığa sahiptir ve en çok ortaya çıkan alt sınıflandırıcı çıktısı oylanarak nihai sınıflandırıcı kararı belirlenir [78, 79]. Örneğin, ikili bir sınıflandırma problemi için $m = 3$ alt sınıflandırıcı sırasıyla $O_1(x) \leftarrow 1$, $O_2(x) \leftarrow 0$ ve $O_3(x) \leftarrow 1$ şeklinde sonuç üretsin. Çoğunluk oylama bu problemi en sık

görülen etikete göre $\hat{y} = 1$ olarak sınıflandırır [78]. Çoğunluk oylamanın ikili sınıflandırmada doğru çalışması için alt sınıflandırıcı sayısı tek olmalıdır. Çünkü, aynı frekanslarda çıktılarının olması durumunda oylamada galip gelecek bir çoğunluk oluşmaz.

$$\hat{y} = \text{mod}\{O_1(x), O_2(x), \dots, O_m(x)\} \quad (1.2)$$

1.8.2. Uniform Ağırlıkları Kullanan Yumuşak Oylama

Yumuşak oylamada sırasıyla her bir alt sınıflandırıcıya bir ağırlık değeri verilir, her bir alt sınıflandırıcının sınıf olasılıkları ağırlık değerleriyle çarpılır ve ortalama alınır [79]. Prosedür kısaca şu şekildedir: tüm sistemin nihai \hat{y} etiketi m alt sınıflandırıcıdan çıktı olarak alınan ve her bir sınıfa olan üyelikleri ifade eden sınıf olasılıkları birleştirilerek eşitlik (1.3)'deki gibi belirlenir. Bu yöntemde çoğunluk oylamadaki gibi etiketler kullanılmaz. Eşitlikteki w_j her bir j 'nci alt sınıflandırıcı ağırlığı, p_{cj} tahmin edilen sınıf olasılığı ve \hat{y} ise en yüksek olasılığa sahip sınıf çıktısıdır [78]. w_j ağırlığının belirlenmesi için literatürde farklı yaklaşımlar sunulmuştur. Tez çalışmasında, uniform ağırlıklar kullanan yumuşak oylama kullanılmıştır. Bu yaklaşımda, uniform w_j ağırlıkları atanır ve her bir alt sınıflandırıcıya aynı etki gücü verilir [72, 76].

$$\hat{y} = \underset{c}{\text{argmax}} \left(\sum_{j=1}^m w_j p_{cj} \right) \quad (1.3)$$

Bilindiği gibi yumuşak oylama yöntemleri etiket değerlerini kullanan çoğunluk oylama yöntemlerinin aksine sürekli değerler girdisi kullanır. Örneğin, [80] alt sınıflandırıcı olarak lojistik regresyon (LR), rastgele ormanlar (RO, yöntemin kendisi de bir topluluk öğrenme yöntemi), gradyan artırma makineleri (GAM) ve YSA kullanılmış, sonrasında bu yöntemlere ait tahmin sonuçlarının ağırlıklı ortalamalarını alarak karar vermiştir. [75] LR, rastgele ormanlar, DVM ile yeni bir yumuşak oylama yöntemi önermiştir. [81] klasik makine öğrenme yöntemlerinin (Naive Bayes, k-EYK, LR ve DVM) ağaç temelli model (karar ağaçları ile torbalama, RO, AdaBoost, GAM) topluluklarını görevlendirmiştir. [81] ayrıca ilk

kademeden aldığı yumuşak oylama sonuçlarını ikinci kademede yine yumuşak oylayarak karar veren bir yaklaşım da önermiştir. [82] RO, Ada Boosting, gradyan artırma (GA), ekstra ağaç sınıflandırıcısı, LR, K-EYK, karar ağaçları, multinomial Naive Bayes, çok katmanlı algılayıcılar, DVM ve ileri seviye GA yöntemlerinin başarısını ölçmüş, ardından en iyi sonuç veren üç sınıflandırıcının sonuçlarını oylamıştır.

1.9. Zaman Düzlemi Öznitelikleri

Ortalama Mutlak Değer: Sinyal değerlerinin mutlaklarının ortalamasıdır [83].

$$OMD = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (1.4)$$

Kare Kök Ortalama: Sinyal değerlerinin karelerinin ortalamasının kareköküdür [83].

$$KKO = \sqrt{\frac{1}{N} \sum_{k=1}^N (x_k)^2} \quad (1.5)$$

Genliğin Standart Sapması: Sinyalin genlik değerlerinin varyansının kare köküdür. \bar{x} değeri x 'in ortalamasıdır.

$$SS = \sqrt{\frac{1}{N-1} \sum_{k=1}^N |x_k - \bar{x}|^2} \quad (1.6)$$

$$\bar{x} = \frac{1}{N} \sum_{k=1}^N x_k \text{ iken}$$

Ortalama Güç: Zaman düzleminde sinyalin ortalama gücüdür.

$$OG = \frac{1}{N} \sum_{k=1}^N (x_k)^2 \quad (1.7)$$

Genlik Çarpıklığının Mutlağı: Sinyaldeki dağılımın ortalama çevresindeki asimetrisinin derecesidir. Çalışmada asimetrinin büyüklüğü ile ilgilenilmiş ve çarpıklık değerinin mutlağı kullanılmıştır. σ değeri x 'in standart sapması, \bar{x} ise ortalamasıdır [83].

$$GCM = \frac{\sum_{k=1}^N (x_k - \bar{x})^3}{(N - 1)\sigma^3} \quad (1.8)$$

Genlik Basıklığı: Sinyalin sivriliği veya basıklığıdır [83].

$$GB = \frac{\sum_{k=1}^N (x_k - \bar{x})^4}{(N - 1)\sigma^4} \quad (1.9)$$

Ortalama Genlik Değişimi: Dalga formunun kümülatif uzunluğunun ortalamasıdır [84].

$$OGD = \frac{1}{N} \sum_{k=1}^{N-1} |x_{k+1} - x_k| \quad (1.10)$$

Diferansiyel Mutlak Standart Sapma: Kare kök ortalama özneliğine benzer ve sinyalin komşu noktaları arasındaki farkın mutlak standart sapmasıdır [85].

$$DMSS = \sqrt{\frac{1}{N-1} \sum_{k=1}^{N-1} (x_{k+1} - x_k)^2} \quad (1.11)$$

Sıfır Geçiş Oranı: Sinyalin komşu noktalarının genlikleri arasında işaret değişikliklerinin ölçüsüdür ve frekansla ilişkilidir. Düşük seviyedeki gürültü kaynaklı geçişleri saymamak için bir genlik fark eşiği kullanır ve bu değerden büyük olanlar sayılır

[84, 86]. Eğer komşu noktaların genlikleri arası fark bu eşik değerden büyükse bu geçiş sıfır geçişi olarak kabul edilir. Geçiş sayısını tutan SGO eşitlik (1.12)'yi sağlayan $k = 1, 2, \dots, N - 1$ 'inci x_k örnekleri için bir arttırılarak hesaplanır. Çalışmalarda E_{SGO} genlik farkı eşiği 0.01 alınmıştır.

$$\begin{aligned} & ((x_k > 0 \text{ ve } x_{k+1} < 0) \text{ veya } (x_k < 0 \text{ ve } x_{k+1} > 0)) \\ & \text{ve } (|x_k - x_{k+1}| \geq E_{SGO}) \end{aligned} \quad (1.12)$$

Eğim İşareti Değişikliği: Frekans bilgisi ile ilişkili bir özneliktir ve sinyal boyunca eğimin kaç kere değiştiğini gösterir. Düşük seviyede gürültü kaynaklı değişimleri saymamak için bir eşik değer kullanılır ve bu değerden büyük olanlar sayılır [84, 86]. Değişen eğim işareti sayısını tutan EID eşitlik (1.13)'ü sağlayan $k = 2, 3, \dots, N - 1$ 'inci x_k örnekleri için bir arttırılarak hesaplanır. Çalışmada E_{EID} eşiği 0.01 alınmıştır.

$$\begin{aligned} & ((x_k > x_{k-1} \text{ ve } x_k > x_{k+1}) \text{ veya } (x_k < x_{k-1} \text{ ve } x_k < x_{k+1})) \\ & \text{ve } (|x_k - x_{k+1}| \geq E_{EID} \text{ veya } |x_k - x_{k-1}| \geq E_{EID}) \end{aligned} \quad (1.13)$$

Dalga Formu Uzunluğu: Dalga formunun kümülatif uzunluğudur [83] ve sinyal karmaşıklığı hakkında bilgi verir [86]. Eşitlik (1.14)'deki gibi komşu örneklerin genlik farklarının mutlaklarının toplanmasıyla hesaplanır.

$$DFU = \sum_{k=1}^{N-1} |x_{k+1} - x_k| \quad (1.14)$$

Willison Genliği: Sinyal boyunca komşu noktalar arası genlik farkının kaç tanesinin E_{WG} eşik değerinden büyük olduğunu ifade eder [84, 86]. Yeterli büyüklükteki genlik farkı sayısını tutan WG değeri eşitlik (1.15)'i sağlayan $k = 1, 2, \dots, N - 1$ 'inci x_k örnekleri için bir arttırılarak hesaplanır. Çalışmada eşik değer 0.01 alınmıştır.

$$|x_k - x_{k+1}| \geq E_{WG} \quad (1.15)$$

Hjorth Parametreleri: Etkinlik, hareketlilik ve karmaşıklık şeklinde üç istatistik parametreden oluşur. Etkinlik sinyalin standart sapmasının karesidir (varyansı) (1.16). Hareketlilik sinyalin birinci dereceden türevinin varyans değerinin, sinyalin varyansına oranının kareköküdür (eşitlik (1.17)). Karmaşıklık sinyalin saf sinüs dalgasına benzerliğini ölçen bir parametredir. Eşitlik (1.18)'deki gibi sinyalin birinci dereceden türevinden elde edilen hareketliliğin, sinyalin kendinden elde edilen hareketliğe oranıdır [87, 88]. $x(k)$ tek kanallı bir sinyali, $var(.)$ ise varyansı ifade ettiğinde etkinlik, hareketlilik ve karmaşıklık şu şekilde hesaplanır.

$$E = var(x(k)) = \frac{\sum_{k=1}^N (x_k - \bar{x})^2}{N} \quad (1.16)$$

$$H = \sqrt{\frac{var(x'(k))}{var(x(k))}} \quad (1.17)$$

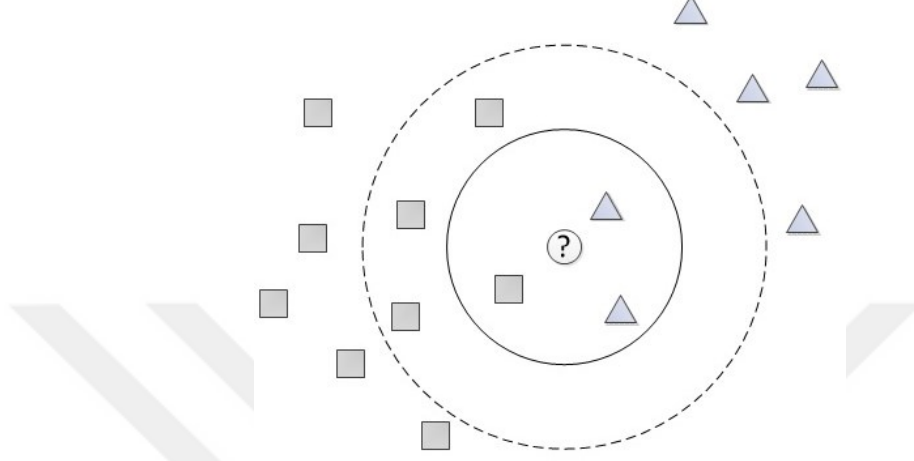
$$K = \frac{Hareketlilik(x'(k))}{Hareketlilik(x(k))} \quad (1.18)$$

Genlik Zarfının Ortalama ve Standart Sapması: Hilbert dönüşümü [89] ile hesaplanan zarf vektörlerinin karesinin ortalama ve standart sapmasıdır.

1.10. K En Yakın Komşu Algoritması

K en yakın komşuluk algoritması (K-EYK) kolay anlaşılabilir ve uygulanabilir bir öğrenme algoritmasıdır. Bu nedenle, veri madenciliği, örüntü tanıma, regresyon alanlarında sıklıkla kullanılır. Öğrenme test isteği geldiğinde gerçekleşir ve bu nedenle durum temelli bir tekniktir [90, 91]. Örneğin; Şekil 1.5'deki gibi 2-B bir uzayda üçgen ve kareyle temsil edilen örnekler sırasıyla Sınıf 1 ve Sınıf 2 kategorilerine ait olsun [92]. Bu uzayda, soru işareti ile gösterilen test örneğinin $k = 3$ 'üncü en yakın komşuluk değerine göre hangi sınıfa ait olacağı şu şekilde belirlenir. Öncelikle, test örneğinin eğitim kümesindeki tüm örneklerle uzaklıkları hesaplanır. Daha sonra, test örneğine en yakın $k = 3$ eğitim örneğinin etiketleri

ile test örneğinin kategorisi belirlenir. Örneğin, bu problemde en yakın 3 komşudan 2 tanesi Sınıf 1'e dahil olduğundan test örneği Sınıf 1 olarak etiketlenir [90, 92].



Şekil 1.5. K-EYK ile örnek bir test verisinin sınıflandırılması

Yukarıda verildiği gibi, K-EYK'da öncelikle test örneği ile eğitim kümesindeki tüm örnekler arasındaki mesafeler hesaplanır. Daha sonra, en yakın k komşunun etiket değerlerinin frekanslarına bakılarak test örneğinin hangi sınıfa dahil olacağı belirlenir [93, 94]. Örneğin, herhangi bir örnek öznitelik vektörü $\langle oznt_vekt(x), c(x) \rangle$ şeklinde ifade edilsin. Bu gösterimde, $oznt_vekt(x)$ vektörü $a_r(x)$ değerlerinden oluşan ve $\langle a_1(x), a_2(x), \dots, a_\varphi(x) \rangle$ ile ifade edilebilecek φ elemanlı vektörü, $c(x)$ ise x örneğinin etiketidir. Öklid uzaklığı için, eğitim kümesindeki x_i ve test kümesindeki q_t vektörü arasındaki $d(q_t, x_i)$ uzaklığı eşitlik (1.19)'daki gibi hesaplanır [94, 95].

$$d(q_t, x_i) = \sqrt{\sum_{r=1}^{\varphi} (a_r(q_t) - a_r(x_i))^2} \quad (1.19)$$

Öğrenme ve test şu şekilde gerçekleştirilir. Öğrenmede, öncelikle t 'nci test örneğiyle her bir $i = 1, 2, \dots, I$ eğitim örneği arasındaki uzaklıklar hesaplanır ve I adet $d(x_i, x_t)$ uzaklığı saklanır. Test aşamasında, x_t test örneğinin kategorisi olan $c(x_t)$ değeri eşitlik (1.20)'deki gibi k en yakın komşuya bakılarak karar verilir [94, 95]. Burada, çoğunluk

oynamaya göre en fazla karşılaşılan etiketle test örneği etiketlenir [96]. Eşitlik (1.20)'deki C etiketi n elemanlı etiket kümesini $\{c_1, c_2, \dots, c_n\}$ ve $c(y_i)$ ise i 'nci en yakın örneğin etiketidir. $\{y_1, y_2, \dots, y_k\}$ tüm eğitim uzayında x_t test örneğine ait en yakın k komşuyu ifade eder. Eğer $c = c(y_i)$ eşitliği varsa, $\delta(c, c(y_i)) = 1$, yoksa $\delta(c, c(y_i)) = 0$ değerini alır [94, 96].

$$c(x_t) = \underset{c \in C}{\operatorname{argmax}} \sum_{i=1}^k \delta(c, c(y_i)) \quad (1.20)$$

K-EYK'da örneklerin birbirlerine uzaklıklarının hesaplanmasında farklı uzaklık ölçütleri kullanılabilir. Bu ölçütler sınıflandırma doğruluğu, hesaplama zamanı ve karmaşıklığı açısından farklılık gösterir [97, 98]. Tez çalışmasında, aşağıda verilen farklı uzaklık ölçütlerinin performansları da değerlendirilmiştir. Notasyonda q_t test kümesindeki t 'nci test örneğinin $(1 \times \varphi)$ boyutlu öznitelik vektörünü, x_i eğitim kümesine ait $(1 \times \varphi)$ boyutlu i 'nci öznitelik vektörünü, $d(q_t, x_i)$ eğitim ve test kümesindeki bu vektörler arası mesafeyi ve j ise $(1 \times \varphi)$ boyutlu öznitelik vektörünün indeksini ifade eder.

Eşitlik (1.21)'de verilen Minkowski uzaklığı $p = 2$ alınrsa öklid ve $p = 1$ alınrsa Manhattan uzaklığına eşit olan genelleştirilmiş bir uzaklıktır. Bu değer daha büyük seçilirse özniteliklerin ağırlıkları değişeceğinden sınıflandırma doğruluğu etkilenir [98, 99].

$$d(q_t, x_i) = \left(\sum_{j=1}^{\varphi} |q_{tj} - x_{ij}|^p \right)^{1/p} \quad (1.21)$$

Eşitlik (1.22)'de verilen Manhattan uzaklığı öznitelik vektörlerinin mutlak farklarının toplamını ifade eder. Benzer vektörler için 0 değerini, az benzerlik gösterenler içinse daha yüksek değer alır [100].

$$d(q_t, x_i) = \sum_{i=1}^{\varphi} |q_{tj} - x_{ij}| \quad (1.22)$$

Eşitlik (1.23)'de verilen Chebychev uzaklığı Minkowski uzaklığının diğer bir versiyonudur (limit p sonsuza giderken) [98].

$$d(q_t, x_i) = \max_{j=1}^{\varphi} \{|q_{tj} - x_{ij}|\} \quad (1.23)$$

Eşitlik (1.24)'de verilen kosinüs uzaklığı iki öznelik vektörü arasındaki kosinüs açısının 1'den çıkarılmasıyla hesaplanır [98, 101].

$$d(q_t, x_i) = \left(1 - \frac{q_t x_i'}{\sqrt{(q_t q_t')(x_i x_i')}} \right) \quad (1.24)$$

Eşitlik (1.25)'de verilen korelasyon uzaklığı iki öznelik vektörü arasındaki doğrusal korelasyonun 1'den çıkarılmasıyla hesaplanır [98].

$$d(q_t, x_i) = 1 - \frac{(q_t - \bar{q}_t)(x_i - \bar{x}_i)'}{\sqrt{(x_i - \bar{x}_i)(x_i - \bar{x}_i)'} \sqrt{(q_t - \bar{q}_t)(q_t - \bar{q}_t)'}} \quad (1.25)$$


$$\bar{x}_i = \frac{1}{\varphi} \sum_j x_{ij} \text{ ve } \bar{q}_t = \frac{1}{\varphi} \sum_j q_{tj} \text{ iken}$$

Spearman uzaklığının hesaplanmasına [98] bağlantısından erişilebilir.

1.11. Destek Vektör Makineleri

İyi genelleme kapasiteleri, aşırı öğrenme ve boyutluluk belasına nispeten dayanıklılıkları nedeniyle farklı araştırma alanlarında örüntü tanıma, makine öğrenme ve regresyon için sıklıkla kullanılır. Destek vektör makinelerinin (DVM) en önemli avantajlarından biri bu görevleri el ile tanımlanabilen birkaç hiper parametreyle (düzenleme ve gevşek değişken parametreleri vb.) yapmasıdır [90]. Eğitimde büyük miktarda hafıza kullanır ve göreceli yavaş yakınsama problemi vardır. Öznelik vektörlerinin boyutu çok büyük olmadıkça eğitim algoritmaları optimize edilerek bu problemler ortadan kaldırılabilir [52]. Literatürde, bulanık DVM, Kernel Fisher DVM, çapraz korelasyon temelli en küçük

kareler kullanan DVM'ler ve bileşik çekirdek kullanan DVM'ler [53] gibi DVM türevi birçok yöntem önerilmiştir. Sınıflandırma problemlerinde özniteliklerin nasıl bir hiper düzlemlerle ayrılabilirliğine göre doğrusal ve doğrusal olmayan DVM'ler kullanılabilir.



Şekil 1.6. Maksimum sınır aralığında en iyi ayırıcı doğru

Doğrusal DVM ile çözülebilecek ikili sınıflandırma problemlerinde, farklı kategorilere ait örnekleri ayırabilecek en başarılı doğrusal hiper düzlemler araştırılır. Örneğin, artı ve eksi sembolleriyle gösterilen iki kategoriye ait öznitelikler 2 boyutlu uzayda Şekil 1.6'daki gibi dağılım. Bu problem çok sayıda ayırıcı doğruyla çözülebilir. Ancak, hangi doğrunun en az hatayla en iyi sınıflandırmayı yapacağı bulunmalıdır. Çünkü, eğer ayırıcı doğru yeterince iyi seçilmez ve bir kategorideki örneklere yakın seçilirse, sınıflandırıcı bu kategori için gürültüye duyarlı olur [90]. Bunun çözümü için karar vermeyi sağlayacak doğruya en yakın destek vektörler (Şekil 1.6'da içi dolu olarak verilen) aranır. En iyi destek vektörler belirlendiğinde aralarındaki alan da en fazla olacağından bu vektörler arasında en geniş sınır aralığı bulunur [90]. Destek vektörler iki kategorideki örneklerin ayrışmasını sağlayacak en iyi ayırıcı doğrunun belirlenmesini sağlar. Son adımda ise tespit edilen ayırıcı doğruyla test örneklerinin kategorileri belirlenir.

Sınıflandırma problemlerin çoğu doğrusal yöntemlerle çözülemez. Çözölmeye çalışılırsa da yanlış veya başarısız olur [90]. Doğrusal DVM'lere gevşek değişkenler eklenerek hataya tolerans sağlanabilir. Ancak, bu problemler için en ideal çözümlerden biri doğrusal olmayan DVM'lerdir. Bu yaklaşımlarda, ayırıcı iyi bir hiper düzlemin bulunmadığı uzaya çekirdek fonksiyonları uygulanır, örnekler yüksek boyutlu başka bir uzaya taşınır ve yeni uzayda ayırıcı hiper düzlemler aranır [51]. Doğrusal, çok terimli, radyal tabanlı, Gauss ve Sigmoid sık kullanılan çekirdek fonksiyonlarındandır. Bu fonksiyonlar uygulanırken çözülmeye çalışılan probleme en uygun parametreler belirlenmelidir. Parametreler el ile veya ızgara tabanlı aramayla belirlenebilir.

1.12. Transfer Öğrenme

MHH kullanan BMA'ların performanslarının iyileştirilmesi günümüzün önemli bir ihtiyacıdır [46]. Uzun kalibrasyon ve eğitim süreleri, denekten-deneğe ve oturumdan-oturuma farklılıklar var olan sorunların en büyük nedenlerinden bazılarıdır. Bu problemlerin çözümü için, sınıflandırma doğruluğuna odaklanarak performansı arttırmaya çalışmak gibi klasik yaklaşımların dışında, öğrenmede farklı tekniklere başvurmak yeni çözüm yollarını aralayabilir. Bu amaca yönelik günümüzün en önemli adaylarından biri transfer öğrenmedir. Transfer öğrenme, bir amaç için hazırlanmış öznitelikleri ve öğrenme modellerini bir problem domaininden diğerine transfer etmek için kullanılır. Bu nedenle, hareket hayali ile çalışan arayüzlerin çözümünde potansiyel taşırlar. Örneğin, BMA'larda yeni kullanıcılar için kişiye özel öznitelik ve sınıflandırıcıların oluşturulması gerekir. Bu işlem, hesaplamalar için çoğunlukla uzun süre isteyen yeniden eğitim anlamına gelir. Pratik çevrimiçi BMA'larda sınıflandırıcılar kısa sürede eğitilmelidir. Çünkü, kullanıcılardan BMA'yı kullanmadan zihinsel komutları gerçekleştirmeleri istenemez [3]. Ayrıca, konsantrasyon vb. problemler nedeniyle sistemin yeniden eğitimi sıkıcı ve zaman alıcı olacaktır. Bu nedenle, BMA'lar için eğitim ve kalibrasyon sürelerinin azaltılması önemlidir [46]. Bunların yanı sıra, farklı oturumlarda alınan kayıtlarda farklılıklar olabilir ve aynı kişi için bile eğitim verileri güncelliğini kaybederek sonraki kullanımlar için elverişsiz olabilir. Bu gibi problemler transfer öğrenmeyle çözümlenerek oturumdan-oturuma ve denekten-deneğe eğitim süreleri azaltılabilir. Örneğin, bir oturumda kaydedilen veriler sonraki oturumlarda

kullanılabilir. Ya da farklı kullanıcılara ait öğrenme verileri yeni bir kullanıcıda görevlendirilebilir [46]. Transfer öğrenme kalibrasyon süresini ve öğrenmenin hesaplama maliyetini azaltmak için de kullanılabilir. Eğitim süresi düşürülerek yeni kullanıcıya ve oturma adaptasyon zamanı azaltılabilir [3].

Evrışimli sinir ağlarında (ESA) transfer öğrenme ilk olarak görüntü sınıflandırma problemleri için önerilmiştir. Özellikle, kategori sayısının fazla olduğu, aynı kategorideki görüntülerin bile çok farklı görünümlere sahip olabileceği, ortam gürültüsü ve değişimlerinden oldukça etkilenen sorunlar göz önüne alındığında, başarılı bir sınıflandırıcı için tüm bu problemlere ait görüntülerin eğitim kümesine eklenmesi gerekir. Eğitim kümesinin bu çeşitlilikte oluşturulması bile başlı başına zordur. Ayrıca, eğitim kümesi oluşturulduktan sonra sınıflandırma modelleri öğrenilmelidir. Ancak, her biri binlerce eğitim görüntüsüne sahip çok sayıda kategori için modellerin öğrenilmesi oldukça zaman alıcı ve çetindir. Çünkü, kategori sayısı arttıkça ayırıcı sınıflandırma modellerinin matematiksel inşası daha da zorlaşır. Ayrıca, öğrenme aşaması tamamlandıktan sonra da yapılacaklar vardır. Örneğin, gerçek zamanlı sistemlerde, eğitim kümesinde bulunmayan örnekler sürekli test edilir. Bu nedenle, yeni örneklerle yeniden eğitim ve öğrenme sürecinin sürekli tekrarlanması gerekir. Bu problemlerin çözümü için eğitim süreleri azaltılmalı ve az sayıda örnek içeren problemlerde bile iyi performans araştırılmalıdır.

Literatürde, EEG sinyallerinin doğrudan kullanan bir boyutlu ESA'lar haricinde, EEG sinyalleri görüntülere çevrilerek de ESA'lara girdi olarak verilmiştir. ESA ile transfer öğrenmede, öğrenilmiş öznitelikler ve modeller yeni bir sınıflandırma problemine az sayıda eğitim verisiyle aktarılabilirdiğinden oldukça elverişli yöntemlerdir. Bu yöntemler ayrıca, ESA'ları rastgele başlangıç ağırlık değerleri, katmanlar ile eğitmekten daha hızlı ve kolaydır. Ancak, modeller ve ağ yapısı farklı bir problem havuzunda oluşturulduğundan, aktarımın yapıldığı probleme ait ağın hiper parametreleri iyi ayarlanmalıdır. Ancak, katman sayısı, türü, sırası, evrışimsel ve ortaklama fitrelerin boyutu, evrışimsel katmandaki filtre sayıları, aktivasyon fonksiyonları gibi hiper parametrelerin en iyi konfigürasyonlarının bulunması zordur [170]. Bu nedenle, ImageNet veri tabanındaki bir milyondan fazla görüntüyle önceden eğitilmiş ESA'lar transfer öğrenmeyle hazır alınmıştır. ESA'larla transfer öğrenme sonrasında, başlangıç öğrenme oranı, mini batch boyutu, öğrenme adım sayısı ve optimizasyon algoritması gibi hiper parametreler ince ayarlama teknikleriyle belirlenmelidir. Bu parametreler iyi ayarlandığında, yeni sınıflandırma görevleri daha az

eđitim verisiyle ESA'lara tařınabilir ve ađ rastgele bařlangıç ađırlık deđerlerine kıyasla daha hızlı ve kolay eđitilir. Tez alıřmasında, AlexNet, GoogLeNet ve SqueezeNet ESA'ları kullanılmıřtır.

1.12.1. AlexNet

ImageNet veri tabanındaki bir milyondan fazla yksek znrlkl grnty 1000 farklı kategoride sınıflandırmak iin nerilmiřtir. 2012 yılındaki ImageNet byk lekli grsel tanıma yarıřmasının galibidir [171]. Klavye, fare, kalem gibi 1000 kategorideki bilgiyi sınıflandırabilen yapıda zengin ieriđe sahiptir. Ađ girdi olarak $227 \times 227 \times 3$ boyutlu renkli grnt alır [177]. Grsel tanıma yarıřmasının problem havuzundaki %26.2'lık sınıflandırma hatasını %15.3'e kadar dřrmřtr ve ESA'ların zorlu grnt sınıflandırma problemlerini bile bařarılı bir řekilde zrebileceđini gstermiřtir. ImageNet yaklařık 60 milyon parametre ve 650,000 nrona sahiptir. İerdiđi 8 katmanın ilk 5 tanesi evriřim ve son 3 tanesi ise tam bađlı katmandır. Evriřim katmanlarının bazılarında sonra maksimum ortaklama katmanları yer alır. Tam bađlı katmanların sonucusu her bir kategoriyle iliřkili olasılıkların tutulduđu 1000 yollu softmax katmanıdır. ImageNet tam bađlantılı katmanlarda oluřabilecek ařırı đrenmenin nne gemek iin bırakma (dropout) adı verilen bir dzenleme tekniđi kullanır. Ayrıca, daha hızlı eđitim iin, grntnn alt ve st kısımlarına ait katman paralarını farklı GPU'larda iřleyen ok verimli bir 2-B evriřim uygulaması sunar. Hiperbolik tanjant (Tanh) aktivasyon fonksiyonu yerine dzleřtirilmiř dođrusal birim (ReLU) fonksiyonu kullanarak ESA'ların daha hızlı alıřmasını sađlar [171].

1.12.2. GoogLeNet

2014 yılındaki ImageNet byk lekli grsel tanıma yarıřmasının galibidir. Ađ girdi olarak $224 \times 224 \times 3$ boyutlu grntleri alır [174]. Parametrelere sahip katmanlar gz nne alındığında 22 katman, ortaklama katmanları sayıldıđında ise 27 katman derinliindedir. Inception adında geniř ve derin yapıda bařarılı bir mimariye sahiptir. Inception modlleri dahil tm evriřim iřlemlerinde ReLU aktivasyon fonksiyonu kullanır. GoogLeNet'in en nemli katkısı hesaplama kaynaklarından faydalanmayı daha da geliřtirilmesidir. Bu

geliştirmede, 1×1 'lik evrişimlerle boyut azaltılıp hesaplama darboğazları engellenir. Böylelikle, ağ derinliği ve genişliği artırılırken hesaplama bütçesi performanstan ödün vermeden sabit tutulur [175]. Normalde, 1×1 'lik evrişim matrisler performansta etkili değildir. Ancak, 1×1 'lik filtreler çok yüksek kanallı matrislere hacimsel düzlemde uygulandığında çıkış matrisinin kanal sayısı filtre sayısına eşit olur. Böylelikle, ESA katmanlarında boyut azaltma ve performansta iyileşme sağlanır [176].

1.12.3. SqueezeNet

ImageNet veri tabanındaki bir milyondan fazla görüntüyü 1000 farklı kategoride sınıflandırmak için önerilmiştir. 50 kat daha az parametreye sahip olmasına rağmen AlexNet ile benzer seviyede performans göstermiştir. ESA'ların FPGA gibi düşük bellek isteyen donanımlara uygulanması için tasarlanmıştır. Daha az parametreyle kabul edilebilir seviyede başarı için ağ mimarisi tasarımında bazı değişikliklere gidilmiştir. 3×3 'lük evrişim katmanların çoğu 9 kat daha az parametre içeren 1×1 'liklerle değiştirilmiştir. Girdi kanalları sayısı squeeze katmanlarla 3×3 'lük filtrelere düşürülmüş ve tam bağlı katman sayısı azaltılmıştır. Aşırı öğrenmeyi engellemek için Fire 9 modülünden sonra %50 oranında bırakma (dropout) tekniğini kullanır. Aktivasyon fonksiyonu olarak ReLU kullanır [178].

1.13. Performans Ölçütleri

Sınıflandırma performanslarının hesaplanmasında ortalama doğruluk ve Cohen'in kappa değerleri kullanılmıştır. Bu ölçütler sınıflandırma performanslarını ifade etmek için sıklıkla kullanılan karışım matrisleriyle hesaplanabilir [102, 103, 104].

Tablo 1.1. İki sınıflı bir problem için karışım matrisi

Sınıflandırıcı Tahmini	Gerçekte		
	Sınıf 0	Sınıf 1	Toplam
Sınıf 0	DP	YP	DP+YP
Sınıf 1	YN	DN	YN+DN
Toplam	DP+YN	YP+DN	

İki sınıflı bir problem için karışım matrisi Tablo 1.1'deki gibidir. Tabloda, Sınıf 0 örnekleri pozitif ve Sınıf 1 örnekleri negatif örnekleri ifade eder. Doğru pozitif (DP) gerçekte pozitif olan ve pozitif olarak doğru sınıflandırılan; doğru negatif (DN) gerçekte negatif olan ve negatif olarak doğru sınıflandırılan; yanlış pozitif (YP) gerçekte negatif olan ancak pozitif olarak sınıflandırılan; ve yanlış negatif (YN) ise gerçekte pozitif olan ancak negatif olarak sınıflandırılan örnek sayılarıdır [102, 104]. Doğruluk eşitlik (1.26)'deki gibi doğru sınıflandırılan örnek sayısının tüm test örnek sayısına bölünmesiyle hesaplanır. Tez çalışmasında, doğruluk değeri 100 ile çarpılarak yüzde olarak kullanılmıştır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1.26)$$

Kappa değeri puanlayıcılar arası güvenilirliği ölçen istatistiksel bir ölçüttür ve keyfi sınıflandırma doğruluğunu elimine etmeye çalışır [105, 106]. Kappa değeri, sınıflandırma doğruluğu $Pr(a)$ ve şansa bağlı uzlaşmayı ifade eden $Pr(e)$ ile aşağıdaki gibi hesaplanır. Denklemden toplam örnek sayısını n ile ifade edilir [106].

$$K = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (1.27)$$

$$Pr(e) = \frac{\left(\frac{(DP + YN) \times (DP + YP)}{n}\right) + \left(\frac{(YP + DN) \times (YN + DN)}{n}\right)}{n} \quad (1.28)$$

Kappa ölçütü -1 ile +1 aralığında değer alır. Değerin negatif olması puanlayıcılar arası güvenilir olmayan uyumsuzluğu ifade eder ve performans için istenmeyen bir durumdur. Sıfır olması tesadüf eseri uyumu gösterir. Yeterli sayılabilecek seviyede bir uyuma ancak 0.40 değeri üzerinde görülür. Ölçütün yorumlanması nispeten basittir ve Tablo 1.2'deki aralıklarla yorumlanır [169].

Tablo 1.2. Kappa ölçütü yorumlama aralıkları

Değer	Durum
<0	Tesadüf eserinden daha kötü
0	Tesadüf eseri
0.01 – 0.20	Önemsiz
0.21 – 0.40	Zayıf
0.41 – 0.60	Orta
0.61 – 0.80	Yüksek
0.81 – 0.99	Çok yüksek
1.00	Tam, mükemmel

1.14. EPOC Flex Salin Sensör EEG Kayıt Cihazı Seti

Emotiv Epoc Flex beyin sinyallerini kablolarla bağlı kalmayarak ve kullanıcıları rahatsız etmeyerek taşınabilir BMA'lara ön ayak olma potansiyeline sahip bir kayıt setidir. Şekil 1.7'de temel hatları verilen başlık seti [67] yüksek çözünürlüklüdür ve 32 konumdan kayıt alabilir. Başlık sayesinde elektrotlar 72 kanal içeren uluslararası 10-20 yerleştirme sistemine göre esnek bir şekilde yerleştirilebilir. Bu esnek yapı MHH için en sağlam sinyallerin alındığı C3, Cz, C4 ve çevreleyen konumlardan kayıt alınmasına olanak sağlar.



Şekil 1.7. EPOC Flex salin sensör EEG kayıt cihazı seti [67]

Sinyallerin alınması için jel sensör kit ve salin solüsyon sensör kit olmak üzere iki teknik kullanılabilir. Tez çalışmasında, salin solüsyon ile ıslanan keçe pedlerini kullanan salin sensör kit kullanılmıştır. Jel yerine salin solüsyon kullanılması başlık setinin kurulum ve bakım süresini azaltır. Başlangıç kurulumu yaklaşık 15-20 dakika arasındadır. Bu kurulum süresi jel sensör kiti göre 5-10 dakika daha kısadır. Ayrıca, elektrotların salin solüsyonla doyurulması başlık takılıken veya takılı olmadığında yapılabilir [67, 68]. Cihaz pratik uygulamalar için kayıtların kolay ve hızlı bir kurulumla gerçek zamanlı edinilmesini sağlar. Yeniden şarj edilerek 9 saate kadar hizmet verebilir. Ayrıca, sinyaller 128 Hz'de kablosuz iletilerek yüksek çözünürlükte aktarılabilir. Böylelikle, taşınabilir sistemlere ön ayak olur ve kullanıcıyı rahatsız etme problemini belirli seviyede ortadan kaldırır.

1.14.1. Kit İçeriği

EPOC Flex Model 1.0 kiti paket içeriğindeki bileşenler aşağıdaki gibidir. Epox Flex'in tüm teknik özellikleri ve kullanım bilgilerine [67] adresinden erişilebilir.

1. Kontrol ünitesi (1 adet)
2. USB PC alıcı-verici dongle (1 adet)
3. USB kablosu (1 adet)
4. Salin solüsyon sıvısı (1 adet)
5. Sağ elektrot ağaçları - kırmızı renkte) (1 adet)
6. Sol elektrot ağaçları - mavi renkte) (1 adet)
7. Hızlı başlangıç kılavuzu (1 adet)
8. Kenar (34 adet)
9. Keçe pedi (80 adet)
10. 58 cm'lik EasyCap başlık (1 adet)

EasyCap başlık uluslararası 10-20 sisteminde tüm konumlardan sinyal alabilecek 72 yerleştirme açıklığına sahiptir. Bu açıklıklar, ihtiyaca göre elektrotların farklı konumlara yerleştirilmesi için kullanılır. Kırmızı renkteki sağ ve mavi renkteki sol elektrot ağaçlar kontrol ünitesine takılarak aldıkları sinyalleri kontrol ünitesine iletir. Kontrol ünitesi sensörlerden aldıkları sinyallerle EEG ölçümü yapar ve kaydedilmesi için bilgisayara iletir.

USB PC alıcı-verici dongle, başlık setinin bir bilgisayara bağlanması ve sinyallerin tescilli 2.4 GHz kablosuz bir protokolle kontrol ünitesinden bilgisayara aktarılması için kullanılır. Cihazın hem uyku hem de uyanıklık gerektiren çalışmalarda kullanılabilmesi için Cz ve Iz konumlarının yakınlarında yer alan ve kontrol ünitesinin yerleştirilebileceği iki cep vardır. Çalışmada Cz ve çevresindeki sinyalleri almak için kontrol ünitesi Iz yakınındaki cebe yerleştirilmiştir [67]. Elektrot sensörler paketinde 32 normal elektrot, 2 referans elektrot (CMS/DLR) ve 80 keçe pedi bulunur. Keçe pedleri sensörlere yerleştirildikten sonra salin çözelti ile ıslatılır. Doğru ölçüm için başlık boyutu uygun seçilmelidir. Çünkü, elektrotların doğru konumlandırılması ancak bu şekilde gerçekleşir. Epoc Flex kafanın yatay daire çevresindeki ölçümle hesaplanan 54, 56 ve 58 cm gibi boyutlarda temin edilebilir. Çalışmalarda, 58 cm'lik başlık 25 ile 33 yaş aralığındaki yetişkin erkek ve kadın deneklerde kullanılmıştır. Son olarak, USB kablosu kontrol ünitesinin şarj edilmesi için kullanılır [67].

1.14.2. Kaliteli Temasın Sağlanması

EEG kayıtlarının alınmasındaki en önemli husus sinyallerin kaliteli alınmasıdır. Sinyallerin kaliteli bir şekilde alınmasında çeşitli problemlerle karşılaşılabilir. Bu problemlerin aşılması için sensör elektrotların yerleştirilmesinden elektronik cihazlara aktarılmasına kadar birçok aşamada birçok duruma dikkat edilmelidir. En önemli aşamalardan biri tüm elektrot sensörlerin doğrudan deriyle temas edecek biçimde yerleştirilmesidir. Erkek deneklerde sensörler saç üstünden yerleştirilse bile salin solüsyon sayesinde çoğu durumda yeterli temas sağlanır. Kadın deneklerde ise, elektrotların yerleştirildiği hatlar boyunca saçların mümkün oldukça toplanması ve doğrudan deriyle temasın sağlanması gerekir. Tez çalışmasında, kadın deneklerde C3, Cz ve C4 doğrultusunda saçlar öne ve arkaya ayrılarak temas kalitesi problemleri en aza indirilmiştir. EmotivPro yazılımı kayıt öncesinde ve sırasında her bir elektrot sensörünün temas kalitesini ölçer ve bir haritada göstererek kontrolünü sağlar. Temas kalitesi için dört olası durum vardır (Tablo 1.3) [67]. Kontrol haritasındaki renkli göstergeler elektrotların deriyle ne kadar temas ettiğini ve daha fazla ayarlama gerekip gerekmediğini gösterir. Eğer bir sensör kontrol haritasında yeşil renkte görünmüyorsa temasta bir problem var demektir. Bu durumda sensörlerin salin solüsyonla yeterince doyurulup doyurulmadığı (keçe pedleri ıslak değilse sinyal iletimi

gerçekleşemez) ve keçe pedlerinin doğru yerleşip yerleşmediği kontrol edilmelidir. Keçe pedleri sensör boşluklarına iyi oturtulmalı, sensör boşluğuna yeterli kadar itilmeli ve içine tam oturduğundan emin olunmalıdır. Çünkü arada boşluk kalırsa iletim gerçekleşmez. Ayrıca, sinyallerin kaydedileceği elektrotların (MHH için C3, Cz ve C4 elektrotları gibi) temas kalitesi kontrol edilmeden önce CMS/DLR referanslarının temas kalitesi kontrol edilmelidir. Çünkü diğer elektrotlardan alınacak sinyallerin kalitesi referanslardan doğrudan etkilenir. Keçe pedleri ilk defa ıslatıldığında salin solüsyonun emilimi zaman alır. Bu nedenle çözelti yavaş yavaş yedirilerek uygulanmalı ve yeterince emilinceye kadar beklenmelidir. Başlık yerleştirildikten sonra kaliteli temas sağlanmazsa sensörler basitçe hareket ettirilerek temas kalitesi artırılmalıdır. Gerekirse başlık seti takılıken sensör yanlarına salin solüsyon dökülmeli ve temas kalitesi artırılmalıdır. Eğer temas kalitesi değişmiyorsa veya sürekli değişiyorsa (aynı veya farklı sensörlerde) başlık kafadan çıkarılmalı ve keçe pedleri tekrar ıslatılmalıdır. Ayrıca, başlık yerleştirilmeden önce saçların sensör temasına engel olup olmadığı kontrol edilmeli ve gerekirse düzeltmeler yapılmalıdır. Islatma tamamlandıktan sonra salin sensörler birkaç saatte kurumaya başlar. Bu nedenle, sensörlerin üst kısmında yer alan boşluklardan faydalanarak yeniden ıslatma yapılmalıdır. Paket içeriğinde yer alan kenarlar kurumunun yavaşlamasında ve salin solüsyonun yayılmasını önlemede fayda sağladığından kayıtlar alınırken mutlaka kullanılmalıdır [67].

Tablo 1.3. Temas kalitesine göre gösterge renk değerleri

Renk	Durum
Siyah	Temas yok
Kırmızı	Zayıf temas
Turuncu	Ortalama temas kalitesi
Yeşil	İyi temas kalitesi

Kayıtların alınması öncesi ve sırasında yapılacak işlemlerin yanı sıra kayıtlar alındıktan sonra da dikkat edilmesi gereken birçok husus vardır. Kayıt sırasında başlık salin solüsyona maruz kalır. Eğer hijyen sağlanmak isteniyorsa farklı kullanıcılar kullanmadan önce temizlenmeli ve kurulanmalıdır. Temizlemeden önce tüm elektrotlar ve kontrol ünitesi başlıktan çıkarılmalıdır. Çünkü kontrol ünitesi su geçirir. Ayrıca, sensörlerin gelişigüzel ıslatılması bağlantılarda bozulmalara neden olur. Eğer istenirse başlık bebek şampuanı gibi

hafif bir deterjanla temizlenebilir ve kurumaya bırakılabilir. Kurulama işlemi temiz havada bırakılarak gerçekleştirilmelidir. Kayıttan sonra elektrotların içi damıtılmış suyla (çeşme suyu değil) temizlenmelidir. Temizlemede, kâğıt havlunun bir kısmı kıvrıldıktan sonra suya batırılmalı, keçe pedlerinin yerleştirildiği sensör iç kısımları hafifçe ovularak temizlenmeli ve temiz havada kurumaya bırakılmalıdır. Keçe pedleri de istenirse temiz suyla durulanıp kurumaya bırakılabilir. Ancak keçe pedleri hassastır ve sürekli yıkama sonucu dağılabilir. Çünkü keçe pedlerinin şekilleri bozulursa sensörlere yerleştirilmeleri zor olur. Sensörler diğer metal parçalar tarafından çizilebilir. Bu nedenle temizleme sert cisimlerle değil kâğıt havlu gibi yumuşak malzemelerle yapılmalıdır. Kuruma sonrasında, sensörler, keçe pedleri ve başlığın kuru ve karanlık ortamlarda saklanması cihaz üreticisi tarafından önerilir. Elektrotların ömrü ne kadar iyi kullanıldıklarına bağlıdır. Sensor, kablo ve kontrol ünitesine bağlanan kısımlarına dikkat edilmelidir. Kullanım sırasında kabloları fazla germe, aşırı kıvrırma ve bükmeden kaçınılmalıdır.

1.14.3. Emotiv PRO Yazılımı

Emotiv PRO kayıtların alınması sürecinde cihaz kontrolü, kaydetme ve analiz gibi işlemlerin yapılmasına yönelik yazılım tabanlı çözümler sunar. Grafiksel arayüzler kayıtların başarılı alınıp veri setinin oluşturulmasındaki hataları en aza indirecek bileşenleri içerir. Emotiv firmasında ait bu yazılım doğru çalışabilirlik konusunda denenmiş ve cihaza uyumluluk konusunda sorun çıkarmayacak şu ana kadarki tek çözümdür. Windows 10 (64-bit) v1607+ ve Mac OSX 10.12 üstü işletim sistemleriyle uyumlu çalışır ve minimum 8 GB RAM belleğe ihtiyaç duyar. Windows işletim sistemi kullanan bilgisayarlarda Core i5-3xxx üstü işlemcilerle ihtiyaç duyar. EmotivPRO veri akışlarını işlemek için CPU'yu kullanır. En iyi veri akışı işleme performansı için maksimum 1920x1080 çözünürlüğün kullanılması önerilir. Ayrıca, üreticisi firma ekranın ölçeğinin %100'e ayarlanmasını önerir [67]. Emotiv PRO ile veri seti oluşturma ve kullanım detayları Bölüm 2.1.2.3.3'de verilmiştir.

1.15. Beyin Makine Arayüzü Veri Setleri

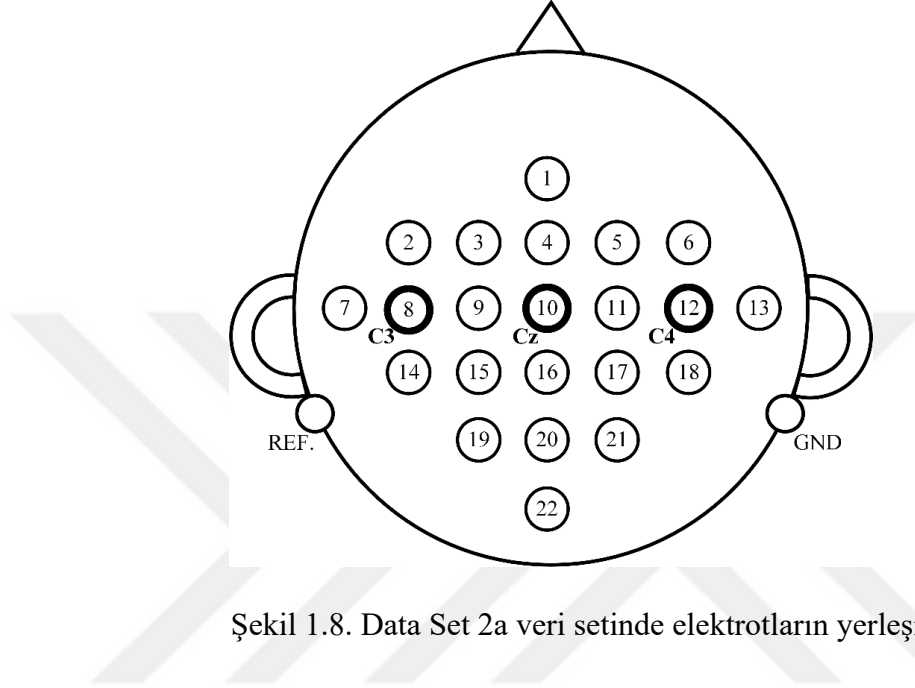
1.15.1. BCI Competition II Yarışması Data Set Ia Veri Seti

Data Set Ia veri seti BCI Competition II yarışmasında Tuebingen Üniversitesi tarafından oluşturulmuştur [24, 107]. Kayıtlar sağlıklı bir bireyden alınmıştır. Kayıt sürecinde, bilgisayar imlecinin ekranda aşağı ve yukarı yönde hareket ettirilmesi istenmiş, bu sırada oluşan yavaş kortikal potansiyeller kaydedilmiştir. Her bir deneme 6 sn uzunluğundadır ve 0.5 sn'lik bir dinlenme süreci ile başlar. Dinlenme süreci sonrasında, kortikal negatiflik veya pozitifliğin belirlenmesi için görsel vurgulanmış bir görev bilgisayar ekranın üst veya altında deneme bitinceye kadar gösterilmiştir. Deneğin görüntü geri beslemesi 2 sn ile 5.5 sn aralığındaki 3.5 sn'lik zaman dilimdedir. Temiz imleç hareket bilgisi içeren bu zaman dilimi sınıflandırmada kullanılabilir. İmleç dikey eksen konumu yavaş kortikal potansiyelinin seviyesini ifade eder. 896 örnek içeren 3.5 sn'lik sinyaller 256 Hz örnekleme oranıyla kaydedilmiştir [108]. Cz konumuna göre yerleştiren elektrotlar 10-20 konumlandırma sistemine göre şu şekilde yerleştirilmiştir: Kanal 1: A1-Cz (A1 = sol mastoid), Kanal 2: A2-Cz, Kanal 3: C3'ün 2 cm frontal konumu, Kanal 4: C3'ün 2 cm parietal konumu, Kanal 5: C4'ün 2 cm frontal konumu ve Kanal 6: C4'ün 2 cm parietal konumu [108, 109]. Eğitim kümesinde 268 ve test kümesinde 293 deneme bulunmaktadır. Eğitim kümesindeki 268 denemenin 168 tanesi ilk günde, 100 tanesi ise ikinci günde kaydedilmiştir. Bu denemelerin 135 tanesi Sınıf 0 ve 133 tanesi ise Sınıf 1 kategorisine aittir. Test kümesindeki 293 denemenin tamamı ikinci günde kaydedilmiştir. Bu denemelerin 147 tanesi Sınıf 0, 146 tanesi ise Sınıf 1 kategorisine aittir.

1.15.2. BCI Competition IV Yarışması Data Set 2a Veri Seti

Graz Teknoloji Üniversitesi tarafından oluşturulmuş ve BCI Competition IV yarışmasında sunulmuştur. Veri seti ipucu tabanlı BMA paradigmasıyla 9 denekten kaydedilen 4 kategorideki MHH görevlerini içerir. Bunlar, sol el, sağ el, ayaklar ve dil MHH'si şeklindedir. Eğitim ve test kümeleri farklı günlerde alınan verilerle oluşturulmuştur. Her bir oturum aralarında kısa zaman boşlukları içeren 6 ayrı koşum, her bir koşumda 48

deneme içerir. Her koşulda her bir kategorideki MHH için 12 deneme olacak şekilde bir oturumda kişi başı toplam 288 deneme bulunur [110].



Şekil 1.8. Data Set 2a veri setinde elektrotların yerleşim düzeni

Denekler kayıtlar sırasında bilgisayar ekranı karşısında konforlu bir koltukta oturmuşlar ve geri besleme verilmemiştir. Her bir denemenin başında göreve konsantre olmak için bir odaklanma işareti gösterilmiştir. Odaklanma işaretinin gösterilmeye başlanmasıyla kısa süreli bir uyarı sesi de verilmiştir. Başlamadan 2 sn sonra, MHH görevini ifade eden ok şeklinde görsel bir ipucu 1.25 sn boyunca ekranda gösterilmiştir. Ekrandaki odaklanma işareti $t=6$ sn de kaybolana kadar MHH görevi yürütülmüştür. Süre bitince ekran karartılmış ve bir sonraki göreve hazırlanmak için kısa bir ara verilmiştir [110]. 10-20 sistemine göre elektrot yerleşim düzeni Şekil 1.8'deki gibidir. Kayıtlar sol mastoid referans ve sağ mastoid ground olacak şekilde 22 elektrottan alınmıştır. Sinyaller 250 Hz ile örneklenmiş ve bant geçiren filtreye 0.5 ile 100 Hz aralığında filtrelenmiştir. Ek olarak, 50 Hz'lik bir çentik filtresi hat gürültülerini bastırmak için kullanılmıştır. Kayıtlar alındıktan sonra uzman tarafından görsel bir denetleme yapılmış ve artefaktları içeren denemeler işaretlenmiştir [110]. Eğitim ve test kümelerindeki deneme sayılarının kategorilere göre dağılımları Tablo 1.4'deki gibidir.

Tablo 1.4. Data Set IIa veri setinde deneme sayılarının kategorilere göre dağılımları

Denek	Eğitim Kümesi					Test Kümesi				
	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Toplam	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Toplam
A01	69	69	68	67	273	71	70	69	71	281
A02	67	69	66	68	270	71	71	69	72	283
A03	69	68	66	67	270	67	70	68	68	273
A04	62	67	67	66	262	59	57	59	53	228
A05	63	66	66	67	262	70	65	72	69	276
A06	56	57	49	57	219	53	55	54	53	215
A07	67	66	67	71	271	71	69	71	66	277
A08	66	66	64	68	264	66	68	69	68	271
A09	53	63	61	60	237	65	65	69	65	264

2. YAPILAN ÇALIŞMALAR

2.1. MHH-BMTA Veri Setinin Oluşturulması

Tez çalışmasında, Data set Ia ve Data set IIa veri setleri dışında, önerilen yöntemlerin performansını ölçmek ve kayıtların alınması konusundaki tecrübeyi arttırmak amacıyla Motor Hareket Hayaline Dayalı Beyin-Mobil Telefon Arayüzü (MHH-BMTA) adlı bir veri seti oluşturulmuştur. Çünkü, EEG sinyallerinin kaydedilmesinden örüntülerin tanınmasına kadar olan sürecin tez çalışmasında tecrübe edilmesi planlanmıştır. Bu amaçla, mobil telefonlarda tıklama ve kaydırma görevlerinin MHH'lerini içeren ve MHH-BMTA olarak adlandırılan bir veri seti EPOC Flex kayıt setiyle oluşturulmuştur. Özgün bir problem domainindeki veri setinin bu şekilde oluşturulmasının pratik BMA'ların oluşturulması ve EEG sinyallerinin gerçek yapısının anlaşılmasına fayda sağlayacağı düşünülmektedir. Kayıt cihazlarının araştırılması, EPOC Flex salin sensör kayıt cihazı seti, kayıtlar sırasında kaliteli temasın nasıl sağlanacağı ve veri seti hakkında detaylı bilgiler alt bölümlerde sunulmuştur.

2.1.1. Kayıt Cihazının Araştırılması

Çalışmalarda ilk olarak, oldukça uygun fiyatlı ve BMA sistemlerinin tasarımına uygun yapıda olan Emotiv EPOC+ kitinin kullanılması planlanmıştır. Bunun nedeni, cihazın bazı projelerde temin edilmiş olması ve MHH görevlerine yönelik [63, 111, 112, 113, 114] çalışmalarda bu kitin kullanılmasıydı. Çalışmalarda MHH görevlerini içeren BMA'ların düşük maliyette tasarlanabilir olup olmadığı sorgulanmış ve EPOC+ için bu amaca yönelik araştırmalar yapılmıştır. EPOC+ uluslararası 10-20 elektrot yerleşim düzenini kullanır ve beyindeki frontal ve prefrontal lobları kapsar [115]. Ancak, MHH için en iyi sinyallerin kaydedileceği elektrotlar C3 ve C4 konumlarındadır. Ancak, EPOC+'ın bu konumlarda sensör elektrotu yoktur. EPOC+ MHH'ye nazaran yüz ifadeleri, duygusal ifadeler ve zihinsel komutları tanıma becerisine sahiptir [116]. MHH görevlerinin sınıflandırılması için elektrot yerleşiminin yeterince uygun olmamasından kaynaklanan problemleri çözmek için önceki çalışmalar bazı değişikliklere gitmiştir. Örneğin, [117] elektrot yerleşiminin durağan hal görsel uyarılmış potansiyellere dayalı BMA tasarımını kısıtladığını görmüştür. Ayrıca,

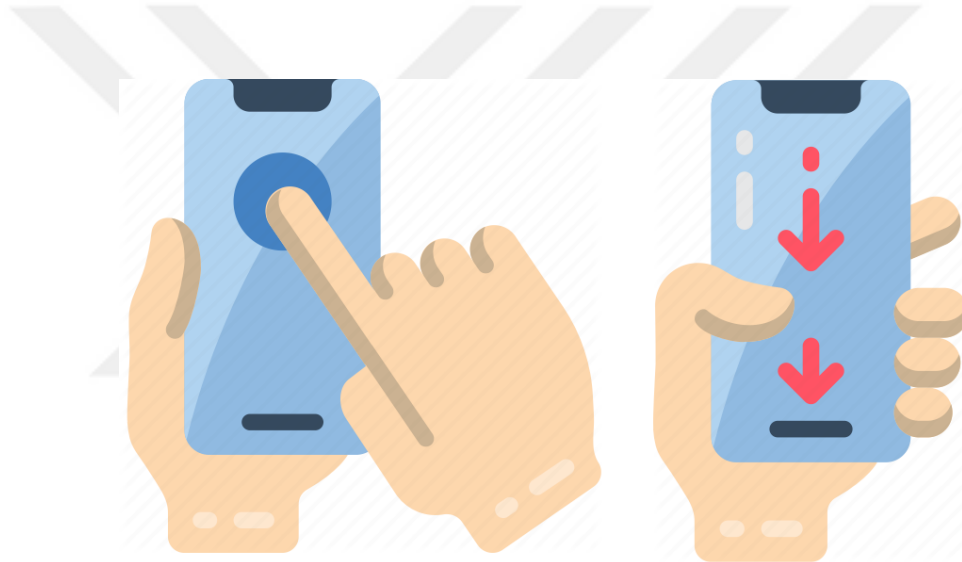
başlığın kol uzunluğunun sabit olması nedeniyle, elektrotlar her denekte istenilen konuma yerleşmemektedir. Çalışmada, cihaz tasarımı kaynaklı kısıtlamaları azaltmak için başlık 180° çevrilerek yerleştirilmiştir. Böylelikle, kafa ön bölgesindeki AF3, F3, F4 ve AF4 konumlarına ait 4 elektrot görsel uyaran bölgelerle temas ettirilmiştir. [118] başlığı söküp yeniden montajlanarak yeni bir başlık tasarlamıştır. [119] 3D yazıcı ile yeni kollar oluşturarak AF3 ve F4 elektrotlarını C3 ve C4'e taşımıştır. Emotiv Epoc'un çalışma için uygun olmadığı anlaşıldıktan sonra, farklı firmalara ait cihazlar araştırılmıştır. Bir kısmı yalnızca tıbbi amaç taşıyan ve 8 elektrottan yüzlercesine kadar elektrot içerebilen BioSemi, CGX A Cognionics Company, Brain Products, ANT Neuro, Neuroelectrics ve OpenBCI firmalarına ait cihazlar 75.000 ABD dolarına kadar ücrete tabi olmaktadır (2019 yılı için). Ayrıca, kablosuz bir kayıt cihazı olan ENOBIO'nun 8, 16 ve 32 elektrottan kayıt yapabilen çeşitleri sırasıyla 3.995 Euro, 12.495 Euro ve 19.995 Euro'dur (gümrük, maliye ücretleri ve özel tüketim vergisi hariç, 2019 yılı için) [120, 121]. Tüm bu cihazlarla kıyaslandığında Emotiv EPOC Flex'in tez amacı ile oldukça uyduğu görülür. Bu cihaz basit bir tasarıma sahiptir ve fiyatı uygundur (yaklaşık 1,699.00 ABD doları, gümrük, maliye ücretleri ve özel tüketim vergisi hariç, 2019 yılı için). Yeterli sayıda, derin yoğunlukta ve esnek sensör yerleştirme kabiliyetinde sahiptir.

2.1.2. MHH-BMTA Veri Setinin Oluşturulması

Günümüzde MHH görevlerinin sınıflandırılması için oluşturulan veri setlerinin çoğu sağ el, sol el, ayaklar, dil gibi vücut uzuvlarına ait hareket hayallerini içerir. Tez çalışmasında, önceki veri setlerinden farklı olarak mobil telefonlarda sıklıkla yapılan bazı el hareket MHH'leri için yeni bir veri seti oluşturulmuştur. Arayüzün bir ucunda beyin diğer ucunda mobil telefonlar olduğundan bu sistem bir "beyin-mobil telefon arayüzü" olur. MHH görevleri şu şekildedir:

1. Mobil bir cihazın ekranına parmakla hafif bir şekilde tıklama (dokunma) hareketine ait MHH (tap) (Şekil 2.1, solda)
2. Mobil bir cihaz ekranındaki nesnelere başparmakla aşağı (veya yukarı) doğru kaydırma (sürükleme) MHH (swipe) (Şekil 2.1, sağda)


Mobil telefonlarda tıklama ve kaydırma hareketleri çeşitli şekillerde yapılabilir. Özellikle kaydırma hareketleri denekten-deneğe oldukça değişim gösterebilir. Örneğin, tek parmakla veya çift parmakla kaydırma, farklı açılarda sağ-sol yönlerinde kaydırma gibi hareketler sık kullanılır. Bu hareketler ayrıca mobil telefonlara ve işletim sistemlerine göre değişim gösterebilir. Bu nedenlerle, kayıtlar öncesinde deneklere tıklama ve kaydırma etkileşimlerini mobil telefonlarda nasıl yürüttükleri sorulmuştur. Ön sorgulamalar sonucunda, deneklerin çoğunun bu etkileşimleri Şekil 2.1'deki gibi yaptıkları belirlenmiştir. Bu nedenle, kayıtların alınması sırasında tıklama ve kaydırma MHH'lerinin bu şekilde gerçekleştirilmesi istenmiştir.



Şekil 2.1. Telefonda tıklama ve baş parmakla kaydırma hareketleri [182, 183]

Tıklama hareketi, galeride bir fotoğrafı açmak için tıklama, bir düğmeye tıklama veya arama yapmak için tuşlara tıklama şeklinde hayal edilebilir. Kaydırma hareketi ise, fotoğraf galerisinde yukarıdan aşağıya gezinmek için kaydırma, sosyal medya uygulamalarının akışında yukarıdan aşağıya gezinme, mobil tarayıcıdaki sayfaları yukarıdan aşağıya kaydırma şeklinde hayal edilebilir. Tıklama ve kaydırma hareketlerine ait MHH sinyallerinin kaydedilmesi sırasında, deneklerden Şekil 2.1'de verilen hareketleri zihinsel olarak simule etmeleri istenmiştir. Ancak, tıklama ve kaydırma hareketlerin MHH'si farklı uygulamalarda farklı şekillerde hayal edilebileceğinden bu kısım deneklere bırakılmıştır. Çünkü, bir denek için sosyal medya uygulama akışında kaydırma MHH'si kolayken, diğeri için galeride, mobil uygulamada, internet tarayıcısında kaydırma MHH'si kolay olabilir. Benzer şekilde,

bir denek için düğmeye tıklama MHH'si kolayken, diğeri için arama tuşlarına tıklama, sosyal medya uygulamasında bir fotoğrafa tıklama veya uygulamaları açmak için simgelere tıklama MHH'si kolay olabilir.



Şekil 2.2. Deneysel paradigmanın zamanlama planı

2.1.2.1. Deneysel Paradigmanın Zamanlama Planı

Bir deneme için deneysel paradigmanın zamanlama planı Şekil 2.2'deki gibidir. Plan Data Set 2a veri seti paradigması örnek alınarak oluşturulmuştur. Tez çalışmasıyla uyumlu olmayan kısımları değiştirilmiş ve kayıtların sağlıklı alınması için uygun hale getirilmiştir. Örneğin, ipucu gösterildikten sonra geri sayım yapılmıştır. Çünkü, ipucu ekrandan kaybolduktan hemen sonra MHH'ye geçişte deneklerin hazırlıksız yakalandıkları görülmüştür. Bu nedenle, görsel ipucundan sonra ekranda geri sayım yapılarak, MHH'ye geçişin daha yumuşak olması ve deneklerin düşünmeye daha hazırlıklı olmaları sağlanmıştır. BMTA'lara yönelik bir veri setinin oluşturulmasında BMA'ların örnek alınması herhangi bir sorun oluşturmaz. Çünkü, arayüzün bir tarafında bilgisayar yerine mobil telefon bulunur.

1. Her deneme bir dinlenme süreci ile başlar. $t=0$ sn'de odaklanma başlangıcında sesli bir uyarı yapılır ve ekranda bir odaklanma işareti 2 sn boyunca gösterilir.
2. Odaklanmadan sonra tıkla veya kaydır şeklinde rastgele bir göreve ait görsel ipucu 1 sn boyunca gösterilir. Böylelikle, denekler MHH görevini yapmaya sevk edilir. Deneklerin daha fazla odaklanmaları için her biri 1 saniye olacak şekilde üçten geriye sayım yapılır.
3. $t=6$ s'de geri sayım bitince MHH görevi boş ekranda metin olarak da ('tıkla' veya 'kaydır' şeklinde) çok küçük puntuyla vurgulanır ve 2.5 sn boyunca deneklerden

MHH görevini yürütmeleri istenir. Uyarının metin olarak da sunulmasının nedeni görsel ipucunun unutulması ihtimali ve MHH görevinin daha da vurgulanmasıdır.

4. $t=8.5$ sn'de sesli bir uyarıyla kayıt biter. Dinlenme için değişen süreli kısa bir ara verilerek sonraki denemeye geçilir.

2.1.2.2. Denek ve Kayıt Bilgileri

Kayıtlar 8 gönüllü denekten alınmıştır. Veriler her denek için bir günde bir oturum olacak şekilde iki farklı günde alınmıştır. Oturum 1 ve oturum 2 sırasıyla birinci ve ikinci günlerdeki deneme kümelerini ifade eder. MHH görevleri rastgele sırada olacak şekilde kaydedilmiştir. MHH zor bir görev olduğundan her oturumda dört veya beş defa kısa aralar verilip deneklerin dinlenmeleri sağlanmıştır. Deneklerin yorulması ve başlığın temas kalitesinin düşmesi (veya sabit olmaması) durumlarında başlık çıkarılıp tekrar takılmıştır. Özellikle kadın deneklerde bu durum sıklıkla görülmüştür. Deneme sayılarının tıklama ve kaydırma görevlerine göre dağılımları Tablo 2.1'deki gibidir. Denemeler rastgele sırada alındığından toplam deneme sayıları farklıdır. Veri seti ilk oluşturulmaya başlandığında oturum başına en az 96 denemenin alınması planlanmıştır. Ancak, deneklerin istekleri ve performansları doğrultusunda bu sayı 120 denemeye kadar çıkarılmıştır.

Tablo 2.1. Oturumlarda kaydedilen deneme sayılarının kategorilere göre dağılımları

Denek	Oturum 1			Oturum 2			Oturumlar Toplamı
	Tıklama	Kaydırma	Toplam	Tıklama	Kaydırma	Toplam	
D01	53	48	101	54	46	100	201
D02	60	60	120	60	60	120	240
D03	51	49	100	47	49	96	196
D04	54	51	105	54	51	105	210
D05	53	54	107	51	49	100	207
D06	56	54	110	55	55	110	220
D07	50	46	96	48	50	98	194
D08	57	53	110	56	54	110	220

İnsana ait veri kullanımı özelinde; ülkemizde yürütülecek olan katılımcısı insan olan araştırmalarda 5237 sayılı Türk Ceza Kanunu Madde 90, 3359 sayılı Sağlık Hizmetleri Kanunu Ek 10. Madde ve Türkiye'nin taraf olduğu anlaşmalar gereğince KTÜ Tıp Fakültesi Bilimsel Araştırmalar Etik Kurulu'ndan etik kurul yönergesine uygun olarak bir Etik Kurul raporu alınmıştır (Ek-2). Veri seti KTÜ'de öğrenim gören öğrenciler, akademisyenler ve çalışanlardan oluşan 8 denekle oluşturulmuştur. Kayıtların alınmasından önce deneklerden çalışmanın amaç, detay ve etik ilkelerini içeren Asgari Bilgilendirilmiş Gönüllü Olur Formu'nu okumaları ve imzalamaları istenmiştir. Kayıtların ve çalışmaların güvenilir olması için en önemli faktörlerden biri deneklerin amaca uygun ve doğru kayıt vermesidir. Bu nedenle, benzer sistemlerde tecrübesi olan (çeşitli deneyler için EEG kayıtları vermiş veya BMA sistemlerinde çalışmalar yapan) ve kayıt sırasında verilecek direktifleri doğru bir şekilde yerine getirecek denekler tercih edilmiştir. Kayıtlar 25-35 yaş aralığında 2 kadın ve 6 erkek denekten alınmıştır. Denek bilgileri Tablo 2.2'deki gibidir.

Tablo 2.2. Denek bilgileri

Denek	Yaş	Cinsiyet	Eğitim durumu	Kullandığı el
D01	35	Erkek	Yüksek Lisans	Sağ el
D02	32	Erkek	Yüksek Lisans	Sağ el
D03	30	Kadın	Yüksek Lisans	Sağ el
D04	30	Erkek	Yüksek Lisans	Sağ el
D05	29	Kadın	Yüksek Lisans	Sağ el
D06	30	Erkek	Yüksek Lisans	Sağ el
D07	34	Erkek	Yüksek Lisans	Sol el
D08	25	Erkek	Lisans	Sağ el

2.1.2.3. Kayıtların Alınması

Mobil telefonlara yönelik MHH görevlerine alışmak için deneklere ön bilgilendirmeler yapılmış ve alıştırma yapmaları istenmiştir. Ayrıca, her oturumdan önce deneklerden test kayıtları alınmıştır. Çünkü, herhangi bir motor hareketin zihinsel olarak hayal edilmesi oldukça zordur ve MHH'nin başarılı bir şekilde yürütülmesi için ön hazırlıklar yapılmalıdır. Ayrıca, mobil telefondaki tıklama ile kaydırma hareketleri gerçek hayatta fiziksel olarak

yapılmaya alışıldığından, zihinsel olarak yapma fikri deneklere oldukça zor gelir. Örneğin, D02 deneği tıklama MHH'si ve gözlerini açık tutmada zorlanmıştır.



Şekil 2.3. Kayıt alma ortamı ve elektrot sensörlerin yerleştirilme düzeni

Deneklerin konsantrasyon seviyesinin yüksek olması başarıda oldukça etkili olduğundan tüm kayıtlar sabah saatlerinde (10:00-13:00 arasında) alınmıştır. D02 ve D08 denekleri için deney ortamı ve elektrot yerleşim düzenleri sırasıyla Şekil 2.3'te üstte ve alttaki gibidir. Denekler konforlu bir koltukta rahat bir şekilde oturmuş ve başlık MHH ilişkili konumlara yerleştirilmiştir. Kayıtların alınması ve bilgisayar ortamına aktarılması kafa derisine yerleştirilen EPOC Flex ile müdahalesiz bir şekilde gerçekleştirilmiştir. Başlık

setiyle ilgili temel bilgiler Bölüm 1.14’te verilmiştir. Bu cihazın kullanılma amacı hem Epoc Flex’in BMA’lara yönelik avantajlarından faydalanmak hem de doğru konumlardan doğru MHH sinyallerini kaydetmek içindir. Epoc Flex pratik BMA’lar için kullanıcıları mümkün oldukça rahatsız etmeden kolay bir şekilde elektrotların yerleştirilmesi ve gerçek zamanlı kaydedilmesine olanak sağlar. Tez çalışmasının yürütülmesi sırasında oluşan cihaz gereksiniminin karşılanması için TÜBİTAK 1002 - Hızlı Destek Programı’na başvurulmuştur. Proje TÜBİTAK tarafından olumlu değerlendirilmiş ve desteklenmiştir.

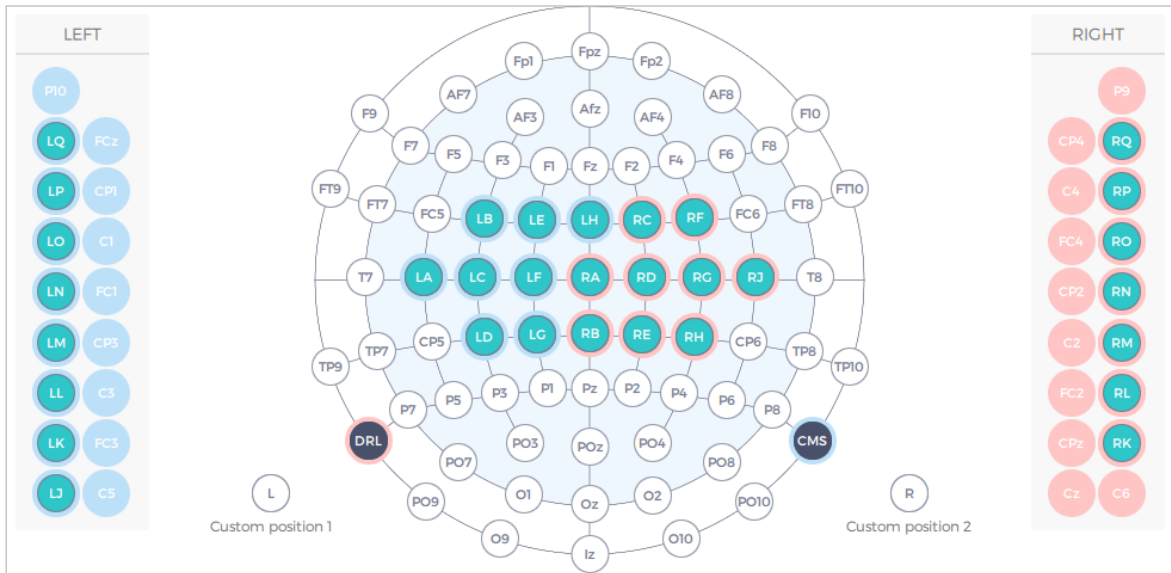
2.1.2.3.1. Referans Elektrotların Belirlenmesi

Kayıtların başarılı bir şekilde alınması için referans elektrotlar doğru konumlara yerleştirilmelidir. EEG kayıt cihazlarının bir kısmı geleneksel sistemlerde kullanılan toprak elektrotları yerine iki ayrı elektrot kullanır. Bunlar Common Mode Sense (CMS) aktif elektrotu ve Driven Right Leg (DRL) pasif elektrotudur. Biosemi firması CMS ve DRL elektrotlarının başlıktaki konumunun çok kritik bir öneme sahip olmadığını öne sürmüştür. CMS elektrotunu ölçüm elektrotlarının ortasına, DLR’yi ise ölçüm elektrotlarından uzağa yerleştirir [122]. Neuroelectrics ise DRL ve CMS referanslarının yüksek kaliteli ölçümler için oldukça önemli olduğunu vurgular. Eğer referans konumları doğru belirlenirse, 50-60 Hz gibi gürültüler ve sinyal kaymalarının azalacağını öne sürer [123].

Data set 2a ve Brain/Neural Computer Interaction Horizon 2020 projesinde yer alan 002-2014 numaralı veri seti gibi MHH görevlerini içeren çalışmalarda referans ve toprak elektrotlar olarak genellikle sırasıyla sol ve sağ mastoidler kullanılır. Epoc Flex ise CMS ve DRL referanslarını kullanır. Ön tanımlı olarak DRL elektrotu AFz ve CMS elektrotu FCz konumuna yerleştirilir. Ancak, AFz konumu referans yapıldığında, MHH ile ilişkili EEG sinyallerini kaydetmek için kullanılamaz. Bu nedenle, P9 ve P10 konumları sırasıyla DRL ve CSM referansları olarak kullanılmıştır. Çünkü, bu konumlar EPOC+ ve EPOC X’te başarılı sonuçlar üretmiştir. Ayrıca, Emotiv tarafından Epoc Flex ile yapılan denemeler, P9 ve P10 referanslarının veri kalitesinde bir değişim oluşturmadığını göstermiştir.

şekildedir. Mavi renkteki sol elektrot ağacına ait LA sensörü C5, LB sensörü FC3, LC sensörü C3, LD sensörü CP3, LE sensörü C1, LF sensörü Cz ve LG sensörü CPz konumlarındadır. Kırmızı renkteki sağ elektrot ağacına ait RA sensörü FCz, RB sensörü C2, RC sensörü FC4, RD sensörü C4, RE sensörü CP4, RF sensörü C6 konumlarındadır. Elektrotların kurulumu EmotivPro ile yapılmıştır [67].

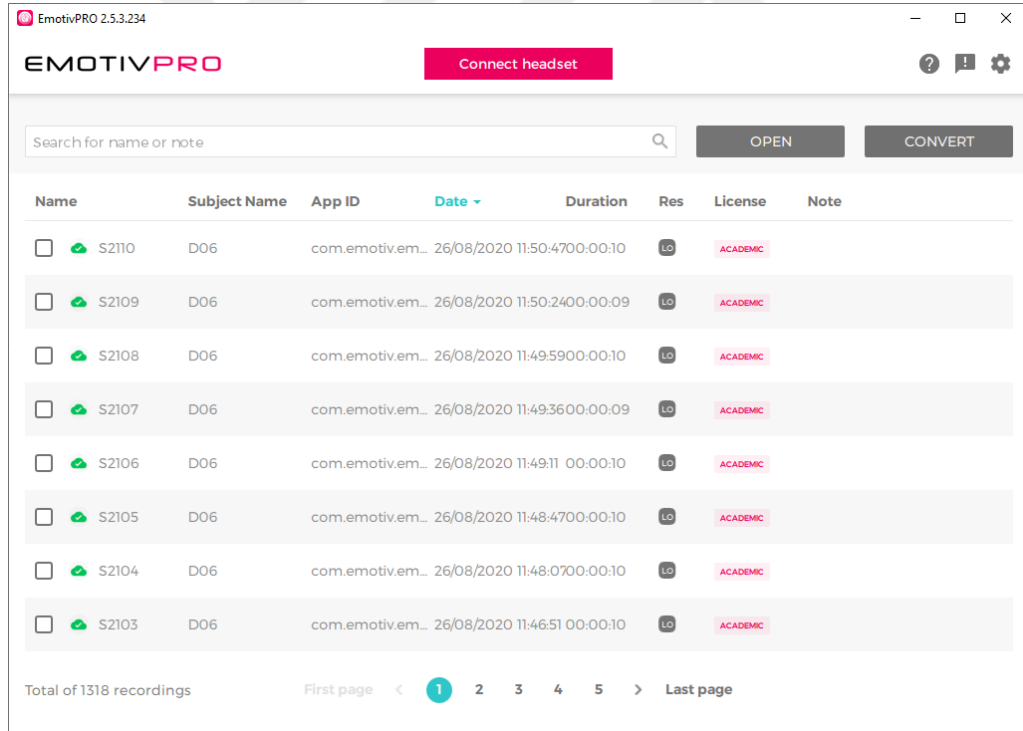
EYD-II daha yoğun bir yerleşim düzenine sahiptir ve referans elektrotlarının dışında 17 elektrot içerir. Bunlar; C3 ve çevresindeki FC3, C1, CP3, C5; Cz ve çevresindeki FCz, C2, CPz, C1; C4 ve çevresindeki FC4, C6, CP4, C2 ile yoğunluğunu arttırmak için eklenen FC1, CP1, FC2 ve CP2 konumlarıdır. EYD-II'nin 10-20 sistemine göre yerleşim şeması Şekil 2.5'teki gibidir. CMS ve DLR referans elektrotları sırasıyla P10 ve P9 konumlarındadır. Diğer elektrotların etiketleri ve yerleşim konumları şu şekildedir. Mavi renkteki sol elektrot ağacına ait LA sensörü C5, LB sensörü FC3, LC sensörü C3, LD sensörü CP3, LE sensörü FC1, LF sensörü C1, LG sensörü CP1 ve LH sensörü FCz konumlarındadır. Kırmızı renkteki sağ elektrot ağacına ait RA sensörü Cz, RB sensörü CPz, RC sensörü FC2, RD sensörü C2, RE sensörü CP2, RF sensörü FC4, RG sensörü C4, RH sensörü CP4 ve RJ sensörü C6 konumlarındadır. Elektrotların kurulumu EmotivPro ile yapılmıştır [67].



Şekil 2.5. EYD-II elektrot yerleşim düzeni

2.1.2.3.3. EmotivPro ile EEG Verilerinin Kaydedilmesi ve Analizi

Veri setinin oluşturulmasındaki en önemli aşamalardan biri EEG sinyallerinin doğru kaydedilmesidir. Çalışmalarda, sinyallerin kontrol ünitesiyle alınması ve bilgisayar ortamına aktarılması EmotivPRO yazılımıyla yapılmıştır. EmotivPRO doğru çalışabilirlik konusunda defalarca denenmiş ve Epoc Flex ile uyumluluk konusunda sorun çıkarmayacak en iyi çözümdür. EmotivPRO ile kaydedilen örnek sinyalleri listeleyen bir arayüz Şekil 2.6'daki gibidir. EmotivPRO veri akışlarını işlemek için CPU'yu kullanır. Bu nedenle, Bölüm 1.14.3'de verilen gereksinimlere uygun olarak, Windows 10 Home Single Language 64 bit işletim sistemi, 2.60 GHz Intel i7-6700HQ CPU, 8 GB RAM ve 1024x768 çözünürlükte kişisel bilgisayarlar kayıtlar alınmıştır.



Name	Subject Name	App ID	Date	Duration	Res	License	Note
<input type="checkbox"/> S2110	D06	com.emotiv.em...	26/08/2020 11:50:4700:00:10	LO	ACADEMIC		
<input type="checkbox"/> S2109	D06	com.emotiv.em...	26/08/2020 11:50:2400:00:09	LO	ACADEMIC		
<input type="checkbox"/> S2108	D06	com.emotiv.em...	26/08/2020 11:49:5900:00:10	LO	ACADEMIC		
<input type="checkbox"/> S2107	D06	com.emotiv.em...	26/08/2020 11:49:3600:00:09	LO	ACADEMIC		
<input type="checkbox"/> S2106	D06	com.emotiv.em...	26/08/2020 11:49:11 00:00:10	LO	ACADEMIC		
<input type="checkbox"/> S2105	D06	com.emotiv.em...	26/08/2020 11:48:4700:00:10	LO	ACADEMIC		
<input type="checkbox"/> S2104	D06	com.emotiv.em...	26/08/2020 11:48:0700:00:10	LO	ACADEMIC		
<input type="checkbox"/> S2103	D06	com.emotiv.em...	26/08/2020 11:46:51 00:00:10	LO	ACADEMIC		

Total of 1318 recordings

First page < 1 2 3 4 5 > Last page

Şekil 2.6. EmotivPro kayıt arayüzü

EmotivPRO kayıt alımındaki hataları en aza indirecek bazı bileşenler içerir. Bu nedenle, sinyallerin hem gerçek zamanlı incelenmesi hem de kaydedilmiş verilerin

görüntülenmesi EmotivPRO ile gerçekleştirilmiştir. D02 deneği için 2. oturumda kaydedilen 9 saniyelik bir deneme Şekil 2.7’deki gibidir.

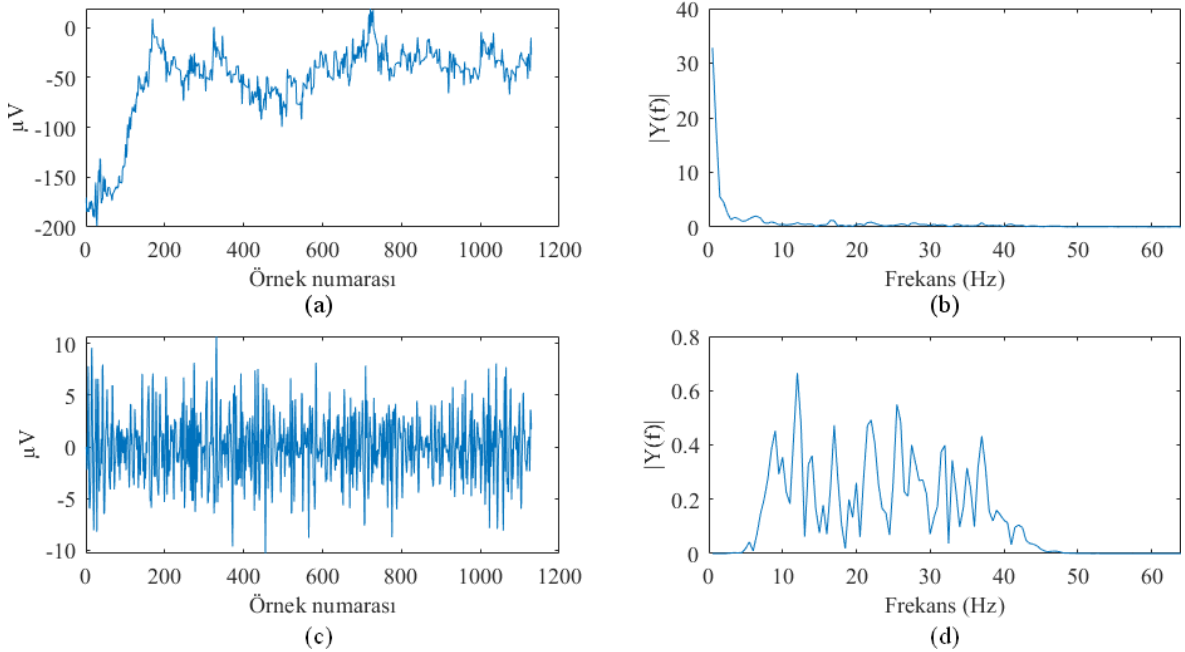


Şekil 2.7. EmotivPro ile kaydedilen örnek bir EEG sinyali

Hareket etme, sensör temas kalitesinde düşme, göz kırpma, referans elektrotlarda temas kalitesinde düşme gibi problemler nedeniyle oluşan bozulmalar kayıt alımı sırasında ham sinyallerde görülebilir. Bu nedenle, elektrotlar doğru konumlara yerleştirilmeli ve temas kalitesi iyi olmalıdır. EmotivPro doğru yerleştirilmemiş ve temas kalitesi düşük elektrotların kontrolüne imkân verir. Çalışmalarda, elektrot kurulum arayüz haritalarıyla bu işlemlerin doğru yapılıp yapılmadığı sürekli gözlenmiştir. Ayrıca, keçe pedlerinin sensör yuvalarına tam yerleşip yerleşmediği de kontrol edilmiştir. Çünkü, eğer keçe pedleri yerlerine doğru oturmazsa, salin solüsyonla yeterince doyurulmaları bile kaliteli temas sağlanamaz [125]. Örnek bir temas kalite haritası Şekil 2.8’deki gibidir. Haritada tüm elektrotların yeşil olarak işaretlenmesi temas kalitesinin %100 olduğunu gösterir. Kayıt alımında kadın deneklerde erkeklere kıyasla daha fazla temas kalitesi değişimi görülmüştür. Temas kalitesinin değiştiği bu gibi durumlarda, öncelikle ilgili sensöre ait keçe pedleri salin solüsyonla tekrar ıslatılmış, sonrasında yuvasına tekrar oturtularak temas kalitesi arttırılmaya çalışılmıştır. Birden fazla sensörün temas kalitesinde sürekli değişiyorsa, başlık seti çıkarılıp keçe pedlerinin tamamı tekrar ıslatılmış ve başlık seti deneğin kafasına yeniden yerleştirilmiştir. Kayıt başında temas kalitesinde bir düşüklük varsa EmotivPro bir uyarı gösterir. Ancak, kayıt sırasında da temas

2.1.3. Verilerin Önışlenmesi

Ortamdaki radyo dalgaları EEG sinyallerini etkiler ve gürültüye neden olabilir. Bu nedenle, kayıt ortamında gürültüye neden olan etmenlere dikkat edilmelidir. Örneğin, sinyallerde daha fazla gürültüye neden olmamak için radyo, bluetooth ve cep telefonu cihazları ortamdaki kaldırılabilir. Tez çalışmasında, ortamdaki elektronik cihazlar mümkün oldukça kapalı konumda tutulmuş. Mümkün olmadığı durumlarda ise kablosuz aktarımda sinyal çakışmasına neden olmayacak şekilde deney ortamında uzak bir konuma yerleştirilmiştir. Ortamındaki düzenlemelere ek olarak, gürültüler ön işlemlerle kaldırılmıştır. Bilindiği gibi, arka plan sinyallerini bastırmak için DC offsetler kaldırılabilir ve yüksek geçiren filtre uygulanabilir. Çalışmalarda, [126]'da üretici firma tarafından verildiği gibi kanalların ortalama değeri her bir kanaldan çıkarılarak DC offset kaldırılmıştır. Ancak, bu yöntem düşük frekanslı gürültülerin artmasına neden olur[126]. Bu nedenle, birinci dereceden 0.16 Hz yüksek geçiren süzgeç uygulanıp arka plan gürültüleri kaldırılmıştır.



Şekil 2.9. Önışlemler öncesi ve sonrasında sinyaller ve genlik spektrumlarına bir örnek

D01 deneğine ait bir tıklama MHH görevi için aşamalar boyunca sinyaller ve genlik spektrumları Şekil 2.9'da sunulmuştur. Şekil 2.9 (a)'da ham bir tıklama MHH sinyali, Şekil 2.9 (b)'de bu sinyalin genlik spektrumu, Şekil 2.9 (c)'de ön işlenmiş ve 8-40 Hz aralığında filtrelenmiş sinyal ve Şekil 2.9 (d)'de bu sinyalin genlik spektrumu verilmiştir. Sinyaller ilk oturumdaki birinci denemeye aittir ve C3 elektrotundan 128 Hz örneklemeyle kaydedilmiştir. Önışlem öncesi sinyal -200 uV ile 0 uV arasında yayılırken, sonrasında 0 μ V etrafında dağılmıştır. Genlik spektrumları Hanning pencereleriyle üretilmiştir. Epoc Flex'in gömülü ürün yazılımı elektriksel güç kaynaklı paraziti gidermek için 50 ve 60 Hz'de çift çentik filtresi uygular. Filtre yaklaşık 45 Hz'e kadar etki ettiğinden üst limit 43 Hz civarındadır. Cihaz ayrıca şehir elektrik şebekeleri kaynaklı harmonikleri kaldırmak için 85 Hz üzeri bir filtre [127] ve 64 Hz de alçak geçiren bir filtre uygular. Tez çalışmasında, önışlemler dışında MHH görevleri için belirli bantlarda filtrelemeler de yapılmıştır.


2.2. Öznitelik Çıkarma ve Sınıflandırma Yöntemleri

2.2.1. Geçiş Noktalarının Belirlenmesi

EEG sinyallerin 2-B modellenmesi için ilk aşama sinyallerdeki tepe (yerel maksimum) ve çukur (yerel minimum) noktalarının tespitidir. Tepe noktası komşu iki çukur nokta arasında en yüksek genliğe sahip nokta olarak tanımlanabilir. Benzer şekilde, bir çukur noktası ise komşu iki tepe nokta arasında en düşük genliğe sahip nokta olarak tanımlanabilir [128, 129]. Tez çalışmasında, tepe ve çukur noktalarının ortak karakteristik özelliklerinin kullanılacağı kısımlarda bu noktalar geçiş noktaları olarak adlandırılmıştır. Biyolojik ve fizyolojik sinyal analiz tekniklerinde geçiş noktaları ve benzer sinyal öznitelikleri genellikle ön işlem veya öznitelik çıkarma için kullanılır. Örneğin, [130] epilepsi tanısı, [131] ECG sinyallerindeki Q, R ve S dalga kombinasyonları, [132] kalp hızı değişimleri, [133, 134] ise göz hareketleri için bu sinyal özniteliklerini kullanmıştır.

Geçiş noktaları tepe ve çukur modellerine ait özniteliklerle zaman, frekans, zaman-frekans ve doğrusal olmayan düzlemlerde tespit edilebilir [134, 135]. Tez çalışmasında, zaman düzleminde çalışan eşik değer tabanlı bir teknikle [129] geçiş noktaları belirlenmiştir. Bu yöntemde, t anındaki herhangi bir nokta, $t - 1$ ve $t + 1$ anındaki komşu çevreleyen

noktalardan δt eşiği kadar daha büyük bir genliğe sahipse tepe noktası olarak nitelendirilir. Benzer şekilde, t anındaki herhangi bir nokta, çevreleyen noktalardan δt eşiği kadar daha küçük bir genliğe sahipse çukur noktası olarak nitelendirilir. Eşik değer gürültü kaynaklı geçiş noktalarını elimine eder. Uygun olmayan küçüklükte seçilirse doğru olmayan geçiş noktaları tespit edilir. Tam tersi yönde, uygun olmayan büyüklükte seçilirse, önemli geçiş noktalarının birçoğu gözden kaçır [136]. Zaman düzleminde 300 örnek içeren bir EEG sinyali ve bu sinyalde tespit edilen geçiş noktaları Şekil 2.10'daki gibidir. Şekilde yukarı yönlü üçgen gösterimleri tepe noktalarını, aşağı yönlü olanlar ise çukur noktalarını ifade eder. Sinyaller Data Set Ia veri setine aittir ve 4. kanaldan kaydedilmiştir.




Şekil 2.10. Örnek bir EEG sinyali ve belirlenen geçiş noktaları

2.2.2. Geçiş Noktaları ve Öznitelik Tanımları

Zaman düzleminde genlik, genişlik ve eğim gibi birçok tepe nokta tanımı ve özniteliği literatürde önerilmiştir. Örneğin, [137] ilk yarım dalgada tepeden tepeye genlik, tepe genişliği, ilk yarım dalgada tepe eğimi ve ikinci yarım dalgada tepe eğimi şeklinde dört farklı tepe nokta özniteliği sunmuştur. [128, 134, 138] ise farklı tepe modellerinden çeşitli tepe öznitelikleri hesaplayarak ön işleme ve öznitelik çıkarma aşamalarında kullanmıştır.

Tez çalışmasında, *Oznelik* (1) ve *Oznelik* (2) olarak adlandırılan iki yeni öznelik tanımlanmıştır. *Oznelik* (1) sol yarım dalgadaki tepe-çukur noktaları arasındaki mesafenin sağ yarım dalgadaki tepe-çukur noktaları arası mesafeye oranıdır. *Oznelik* (2) ise, sol ve sağ yarım dalgadaki kenar vektörleri arasındaki açıdır. Tepe noktalarına ait özneliklerin hesaplanması için Şekil 2.11'de (solda) verildiği gibi P_l , V_k ve V_{k+1} noktalarıyla bir tepe modeli tanımlanır [139]. Bu modelde, P_l sinyaldeki bir tepe noktasını; V_k ve V_{k+1} komşu çukur noktalarını; l ve k ise sırasıyla herhangi bir sinyaldeki tepe ve çukur noktalarının zaman düzleminde indeksleridir. Benzer şekilde, çukur noktası öznelikleri için P_l , V_k ve P_{l+1} noktaları ile Şekil 2.11'de (sağda) gösterildiği gibi bir model oluşturulur. Bu modelde, V_k bir çukur noktasını; P_l ve P_{l+1} komşu tepe noktalarını; l ve k ise sırasıyla herhangi bir sinyaldeki tepe ve çukur noktalarının zaman düzleminde indeksleridir. Çalışmalarda, *Oznelik* (1) ve *Oznelik* (2) değerleri bu modellerle hesaplanmıştır.



Şekil 2.11. Tepe (solda) ve çukur (sağda) nokta modelleri

2.2.2.1. Öznelik (1)'in Tanımı

Herhangi bir geçiş noktasında, sol yarım dalgadaki d_1 öklid mesafesinin sağ yarım dalgadaki d_2 öklid mesafesine oranıdır. Herhangi bir geçiş noktası için şu şekilde hesaplanır.

Adım 1: Sol ve sağ yarım dalgadaki d_1 ve d_2 öklid mesafelerini hesapla. Herhangi bir tepe noktası için, $d_1 = okld(P_l, V_k)$ sol yarım dalgada tepe-çukur noktaları arası mesafeyi, $d_2 = okld(P_l, V_{k+1})$ sağ yarım dalgada tepe-çukur noktaları arası mesafeyi ifade

eder (Şekil 2.11, solda). Benzer şekilde, herhangi bir çukur noktası için, $d1 = okld(V_k, P_l)$ sol yarım dalgada çukur-tepe noktaları arası mesafeyi ve $d2 = okld(V_k, P_{l+1})$ sağ yarım dalgada çukur-tepe noktaları arası mesafeyi ifade eder (Şekil 2.11, sağda).

Adım 2: $d1$ ve $d2$ uzaklıklarından faydalanarak *Oznetelik (1)*'i eşitlik (2.1)'deki gibi hesapla. Bu aşamada öncelikle sol ve sağ yarım dalgalardaki $d1$ ve $d2$ uzaklıklarından küçük olanı büyük olana bölünür. Sonrasında ise, $d1$ uzaklığı $d2$ uzaklığından küçükse bölüm değeri -1 ile çarpılarak $[-1,1]$ aralığındaki *Oznetelik (1)* değeri hesaplanır.

$$Oznetelik(1) = \begin{cases} -1 \times (d2/d1), & d1 > d2 \\ (d1/d2), & d2 > d1 \end{cases} \quad (2.1)$$

2.2.2.2. Öznetelik (2)'nin Tanımı

Herhangi bir geçiş noktasında sağ ve sol yarım dalgalardaki kenar vektörleri arasındaki iç açının kosinüsünü ifade eder. Herhangi bir geçiş noktası için şu şekilde hesaplanır.

Adım 1: Herhangi bir tepe modeli için $u = (P_l, V_k)$ ve $v = (P_l, V_{k+1})$, herhangi bir çukur modeli için ise $u = (V_k, P_l)$ ve $u = (V_k, P_{l+1})$ kenar vektörlerini aynı konumlardan başlayacak şekilde tanımla.

Adım 2: u ve v kenar vektörleri arasındaki θ iç açısını kosinüs benzerliğiyle hesapla.

$$\theta = arccos\left(\frac{\langle u|v \rangle}{\|u\|\|v\|}\right) \quad (2.2)$$

Adım 3: Tepe ve çukur modellerinin her ikisi için θ açısı $[0^\circ, 180^\circ]$ aralığında değer alabilir. Tepe ve çukur modelleri kaynaklı öznetelik değerlerini açı ekseninde zıt yönlerde yerleştirmek için, tepe modelleri kaynaklı açı değerini -1 ile çarp. Bu işlemle, tepe ve çukur modellerinden elde edilecek açı-genlik değerleri 2-B öznetelik düzleminde farklı konumlara yerleştirilir. Çarpma işlemi sonrasında, tepe noktalarından elde edilen açı değerleri $[-180^\circ, 0^\circ]$ aralığında, çukur noktaları için ise $[0^\circ, 180^\circ]$ aralığında yer alır.

$$Oznetelik(2) = \begin{cases} \theta, & \text{herhangi bir çukur noktası için} \\ -\theta, & \text{herhangi bir tepe noktası için} \end{cases} \quad (2.3)$$

2.2.3. 2-B Sinyal Özniteliklerinin Oluşturulması

Tez çalışmasında, EEG sinyallerini farklı bir şekilde ifade etmek için yeni bir modelleme ve yeniden oluşturma yöntemi önerilmiştir. Bu yöntemde öncelikle, $s(t)$ sinyalinin her bir geçiş noktasından elde edilen *Oznitelik* (1) ve *Oznitelik* (2) değerleri 2-B *ONK*(*Oznitelik* (1), *Oznitelik* (2)) öznitelik noktaları şeklinde birleştirilir. Sonrasında, her bir geçiş noktasından elde edilen tüm 2-B noktalarla $M \times N$ boyutlu 2-B *OM*(x, y) matrisleri elde edilir. Bu vektörlerde, x boyutu *Oznitelik* (1), y boyutu ise *Oznitelik* (2) değerlerini ifade eder. Tek kanallı bir $s(t)$ sinyali için $M \times N$ boyutlu 2-B *OM*(x, y) öznitelik matrisi şu şekilde hesaplanır.


Adım 1 (Başlama adımı): $s(t)$ sinyalindeki tüm 2-B *ONK* öznitelik noktalarının yerleştirileceği $M \times N$ boyutlu boş *OM*(x, y) başlama matrisini oluştur. Örnek üzerinden anlatılacak olunursa, 200×360 boyutlu *OM*(x, y) şu şekilde oluşturulur. *Oznitelik* (1) değerleri $[-1, 1]$ aralığında değer alır. Bu nedenle, x eksenini her biri 0.01 değerinde olan $M = 200$ ayrık özdeş aralığa bölünür. Benzer şekilde, *Oznitelik* (2) değerleri $[-180^\circ, 180^\circ]$ aralığında değer alabilir. Bu nedenle, y eksenini her biri 1 derece değerinde $N = 360$ ayrık özdeş aralığa bölünür. Böylelikle, 200×360 boyutlu boş bir başlama matrisi oluşturulmuş olur.

Adım 2: $s(t)$ sinyalindeki tüm geçiş noktalarını ara ve Φ adet geçiş noktasını belirle.

Adım 3: Her bir $\varphi = 1, 2, \dots, \Phi$ geçiş noktası için iki elemanlı *ONK* öznitelik noktalarını hesapla: Örneğin, herhangi bir φ 'nci geçiş noktası için iki elemanlı bir öznitelik noktası $ONK_\varphi(x_\varphi, y_\varphi)$ biçiminde oluşturulur. Notasyonda, x_φ ve y_φ sırasıyla φ 'nci geçiş noktasından elde edilen *Oznitelik* (1) ve *Oznitelik* (2) değerlerini ifade eder.

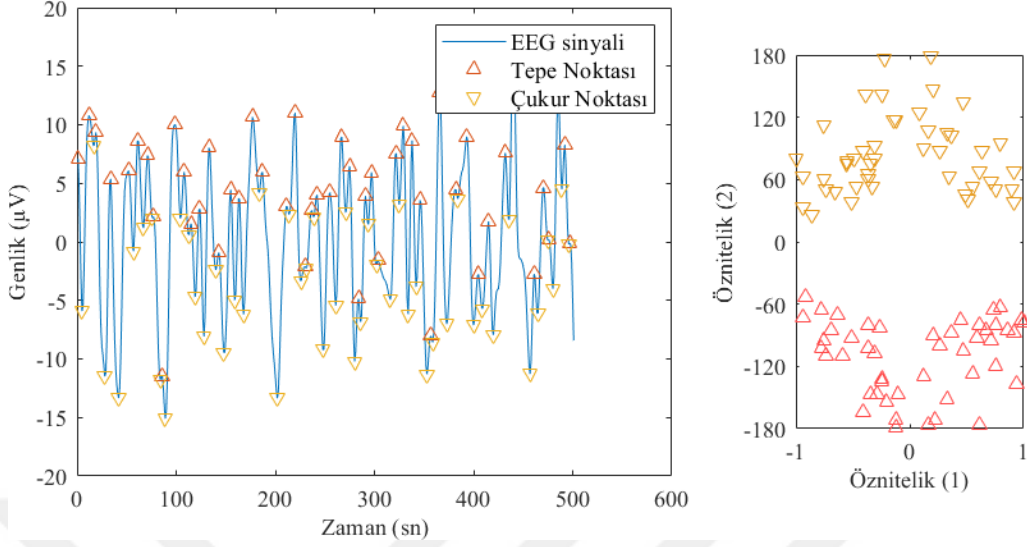
Adım 4: Tüm Φ adet $ONK_\varphi(x_\varphi, y_\varphi)$ öznitelik noktalarıyla $M \times N$ boyutlu *OM*(x, y) matrisini hesapla. Bu adımda, her bir $ONK_\varphi(x_\varphi, y_\varphi)$ için başlatma adımında oluşturulan *OM*(x, y)'deki (i_φ, y_φ) 'nci elemana 1 değeri atanır. Örneğin, φ 'nci $ONK_\varphi(x_\varphi, y_\varphi)$ için $x_\varphi = 0.342$ ve $y_\varphi = 65.5$ olsun. Bu durumda, 200×360 boyutlu *OM*(x, y)'nin $i_\varphi = 135$ ve $j_\varphi = 247$ 'nci eleman değerine 1 atanır. Notasyonda, i_φ indeksi x_φ noktasının *OM*(x, y)'deki konumudur. Bu değer, $i_\varphi = 1 + Yuvarla((x_\varphi + 1) \times 100)$ denkleminle

hesaplanır. Benzer şekilde, j_φ indeksi y_φ noktasının $OM(x, y)$ 'deki konumudur. Bu değer, $j_\varphi = 1 + Yuvarla(y_\varphi + 180)$ ile hesaplanır.



Şekil 2.12. Örnek bir sol el MHH sinyali (solda) ve bu sinyalin 2-B temsili (sağda)

Data set IIa veri seti için sol el kategorisine ait bir EEG sinyali ve elde edilen 100×180 boyutlu öznitelik matrisi Şekil 2.12'deki gibidir. Benzer şekilde, sağ el kategorisine ait bir EEG sinyali ve elde edilen 100×180 boyutlu öznitelik matrisi Şekil 2.13'teki gibidir. Yukarı yönlü üçgenler tepe noktalarından elde edilen öznitelik noktalarını, aşağı yönlüler ise çukurlardan elde edilen öznitelik noktalarını gösterir.



Şekil 2.13. Örnek bir sağ el MHH sinyali (solda) ve bu sinyalin 2-B temsili (sağda)

2.2.4. 2-B Yarı Olasılıksal Dağılımlar Kullanan Öğrenme Modeli

MHH sinyallerinin sınıflandırılması için olasılıksal yöntemler önışleme, öznitelik çıkarma ve sınıflandırma aşamalarında sıklıkla kullanılır. Bu bölümde, EEG sinyallerinin sınıflandırılması için yarı olasılıksal dağılımlar kullanan yeni bir yöntem önerilmiştir. Öğrenme ve test süreci alt bölümlerde verilmiştir.

2.2.4.1. Öğrenme Süreci

Sınıflandırma için öncelikle problemin çözümüne yönelik tutarlı ve yararlı bilgilerin çıkarılması ve öğrenme modellerin oluşturulması gerekir. Amaç girdilerle çıktılar arasındaki ilişkiyi doğru ifade edecek modellerin belirlenmesidir [140, 141]. Tez çalışmasında, ikili sınıflandırma problemlerinin çözülmesi amaçlanmıştır. Bu nedenle, öğrenme yöntemleri her bir $c \in \{0,1\}$ kategorideki eğitim kümesine ayrı ayrı uygulanmış ve her bir kategori için $M \times N$ boyutlu $L_c(x, y)$ öğrenme modelleri oluşturulmuştur. Elimizde MHH görev sinyallerini içeren iki kategorili D_A veri seti olsun. $(s_l(t), y_l)$ veri setindeki l 'nci örneği, $s_l(t)$ l 'nci tek kanallı EEG sinyalini ve $y_l \in \{0,1\}$ ise l 'nci örneğin etiketini ifade etsin.

Adım 1: D_A veri setini y_l etiketlerinden faydalanarak her biri $n_{c \in \{0,1\}}$ sayıda örnek içeren $D_{c \in \{0,1\}}$ alt kümelerine ayır. Bu durumda, D_0 kümesi yalnızca Sınıf 0 denemelerini

içeren $n_0 = |D_0|$ adet örnek içerir. Benzer şekilde, D_1 kümesi yalnızca Sınıf 1 denemelerini içeren $n_1 = |D_1|$ adet örnek içerir.

Adım 2: $D_{c \in \{0,1\}}$ alt veri kümelerinden faydalanarak $M \times N$ boyutlu $L_c(x, y)$ öğrenme matrisleri Adım 2.1 ve 2.5 aralığındaki gibi her bir $c \in \{0,1\}$ kategorisi için oluştur.

Adım 2.1: $D_c = \{s_r(t)\}(r = 1, \dots, n_c)$ kümesindeki tüm örnekler için $M \times N$ boyutlu $OM(x, y)$ öznitelik matrislerini hesapla ve n_c adet $OM(x, y)$ matrisini içeren $\{OM_r(x, y)\}(r = 1, \dots, n_c)$ kümesini oluştur.


Adım 2.2: n_c adet $OM_r(x, y)$ matrisi eşitlik (2.4)'te ki gibi topla ve (aynı indekslerdeki eleman değerlerini kendi aralarında toplayarak) $S_c(x, y)$ matrisini oluştur. Burada, n_c adet özniteliğin 2-B düzlemde nasıl bir dağılım oluşturacağı ve hangi öznitelik değerlerin daha önemli olduğunu belirlenir.

$$S_c(x, y) = \sum_{r=1}^{n_c} OM_r(x, y) \quad (2.4)$$

Adım 2.3: $S_c(x, y)$ matrisine eşitlik (2.5)'deki Gauss çekirdeği uygula ve $S_c(x, y) * G(x, y)$ konvolüsyonu ile yumuşatılmış değerleri içeren $S_c^*(x, y)$ 'yi hesapla.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (2.5)$$

Çalışmalarda farklı pencere genişlik ve standart sapma değerleriyle oluşturulan Gauss çekirdekleri kullanılmıştır. Örneğin, $[w = 11 \times 11]$ pencere genişliği ve $\sigma = 2.0$ standart sapma değerleriyle elde edilen Gauss çekirdeği Şekil 2.14'te soldaki gibidir. Benzer şekilde, $[w = 21 \times 21]$ pencere genişliği ve $\sigma = 4.0$ standart sapma değerleriyle elde edilen Gauss çekirdeği Şekil 2.14'te sağdaki gibidir.



Şekil 2.14. Örnek 2-B Gauss çekirdekleri

Adım 2.4: Tutarsızlıkları önlemek için $S_c^*(x, y)$ matrisi eşitlik (2.6)'da verilen doğrusal minimum-maksimum normalizasyon yöntemiyle $[0, 1]$ aralığına ölçeklendirilir ve normalize edilmiş $S_c'(x, y)$ matrisini oluştur. Bu işlem, $S_c^*(x, y)$ matrisindeki her bir $i = 1, \dots, M$ ve $j = 1, \dots, N$ 'ye ait tüm (i, j) indeksleri için yapılır. Normalize edilmiş matrisin (i, j) 'nci indeksindeki eleman değeri $s_c'(i, j)$ ve normalizasyon öncesi girdi matrisinin (i, j) 'nci elemanı ise $s_c^*(i, j)$ 'dir. $\min(S_c^*(x, y))$ ve $\max(S_c^*(x, y))$ ise $S_c^*(x, y)$ 'deki tüm elemanların minimum ve maksimum değerleridir. Normalizasyonla farklı kategoriler için oluşacak genlik değişimleri yerine dağılıma odaklanılır. Ayrıca, ön performans değerlendirmeleri sonucunda, ayırma sınırıyla eşikleme öncesinde normalizasyon gerekli görülmüş, tüm kategorilerdeki $S_c^*(x, y)$ 'lerin birlikte normalizasyonu başarılı olmamıştır.

$$s_c'(i, j) = \frac{s_c^*(i, j) - \min(S_c^*(x, y))}{\max(S_c^*(x, y)) - \min(S_c^*(x, y))} \quad (2.6)$$

Adım 2.5: En değerli verileri tutmak için $S_c'(x, y)$ 'yi δm ayırma sınırıyla eşikle. $S_c'(x, y)$ matrisinin (i, j) 'nci elemanı $s_c'(i, j)$ olsun. $i \in \{1, \dots, M\}$ ve $j \in \{1, \dots, N\}$ için $v_c(i, j)$ 'leri içeren eşiklenmiş $V_c(x, y)$ çıktı matrisi eşitlik (2.7)'deki gibi hesaplanır. Eşitlikte, $S_c'(x, y)$ 'nin δm ayırma değerinden küçük olan (i, j) 'nci elemanları δm 'ye yuvarlanır.

$$v_c(i, j) = \begin{cases} \delta m, & s_c'(i, j) < \delta m \\ s_c'(i, j), & s_c'(i, j) \geq \delta m \end{cases} \quad (2.7)$$

Adım 3: $L_c(x, y)$ nihai yarı olasılıksal 2-B öğrenme dağılım modellerini her bir $c \in \{0, 1\}$ için ayrı ayrı şu şekilde hesapla: $P(x, y)$ ve $Q(x, y)$ sırasıyla bir önceki adımda hesaplanan $V_0(x, y)$ (Sınıf 0 için) ve $V_1(x, y)$ (Sınıf 1 için) matrislerini ifade etsin. $L_0(x, y)$ öğrenme modeline ait her bir $l_0(i, j)$ eleman değeri $i \in \{1, \dots, M\}$ ve $j \in \{1, \dots, N\}$ indeks değerleri için eşitlik (2.8)'deki gibi hesaplanır. $l_0(i, j)$ olasılık değeri $p(i, j)$ eleman değerinin $p(i, j)$ ve $q(i, j)$ değerlerinin toplamına bölünmesiyle elde edilir. Benzer şekilde, $L_1(x, y)$ öğrenme modeline ait her bir $l_1(i, j)$ eleman değeri $i \in \{1, \dots, M\}$ ve $j \in \{1, \dots, N\}$ indeks değerleri için eşitlik (2.9)'daki hesaplanır. $l_1(i, j)$ olasılık değeri $q(i, j)$ eleman değerinin $p(i, j)$ ve $q(i, j)$ değerlerinin toplamına bölünmesiyle elde edilir. Denklemden, $l_1(i, j)$ değerleri ayrıca $1 - l_0(i, j)$ ile de hesaplanabilir. Denklemlerde, $p(i, j)$ değeri Sınıf 0 için hesaplanan 2-B $P(x, y)$ matrisinin (i, j) 'nci eleman değerini, $q(i, j)$ ise Sınıf 1 için hesaplanan 2-B $Q(x, y)$ matrisinin (i, j) 'nci eleman değerini ifade eder.

$$l_0(i, j) = \frac{p(i, j)}{p(i, j) + q(i, j)} \quad (2.8)$$

$$l_1(i, j) = \frac{q(i, j)}{p(i, j) + q(i, j)} \quad (2.9)$$

2.2.4.2. Test Süreci

Sınıflandırma performansını değerlendirmek için test sinyallerine ait öznitelikler öğrenme modellerine uygulanarak karar verilir. Test süreci aşağıdaki gibi ifade edilebilir.

Adım 1: $s(t)$ test sinyalinin $OM(x, y)$ öznitelik matrisini hesapla.

Adım 2: $OM(x, y)$ ile test sinyalinin her bir c sınıfına olan χ_c olasılık üyeliklerini hesapla. Bu işlemde öncelikle, $OM(x, y)$ ile her bir $c \in \{0, 1\}$ sınıfı için eğitim aşamasında hesaplanan $L_c(x, y)$ öğrenme matrisleri arasındaki ilişkilere bakılır. Daha sonra, test örneğinin her bir sınıfa ait üyeliklerini ifade eden χ_c olasılık değerleri hesaplanır. Tüm bu işlemler her bir $c \in \{0, 1\}$ sınıfı için ayrı ayrı Adım 2.1 ve 2.4 arasındaki gibi hesaplanır.

Adım 2.1: $OM(x, y)$ 'nin değeri sıfır olmayan tüm elemanlarının ikili (i, j) indekslerini Ω dizisinde sakla. $OM(x, y)$ 'de τ adet sıfır olmayan eleman varsa, Ω dizisi şu şekilde tanımlanır.

$$\begin{aligned} \Omega &= \{(i_1, j_1), \dots, (i_\tau, j_\tau)\} \\ &\text{öyleki } om(i, j) > 0 \\ &\text{tüm } i = 1, \dots, M \text{ ve } j = 1, \dots, N \text{ değerleri için} \end{aligned} \quad (2.10)$$

Adım 2.2: Ω dizisindeki r 'nci indeks çifti (i_r, j_r) ile ifade edilsin. $s(t)$ test sinyalinin herhangi bir c sınıfına olan üyeliğini belirlemek için $L_c(x, y)$ öğrenme modelindeki ilişkili eleman değerlerini seç. Bu işlem özetle şu şekilde gerçekleştirilir: (1) c sınıfı için öğrenme modelinden seçilecek değerlerin yerleştirileceği boş ϑ_c dizisi tanımla, (2) test sinyalinden elde edilen Ω vektöründeki tüm $1 \leq r \leq \tau$ ikili indeksler için sırasıyla şu alt adımları yürüt: (2.1) c sınıfına ait $L_c(i_r, j_r)$ öğrenme modelinde aynı ikili indekslerdeki (i_r, j_r) 'nci elemanı seç, (2.2) $L_c(i_r, j_r)$ ve 4 komşuluğunda yer alan $L_c(i_r - 1, j_r)$, $L_c(i_r + 1, j_r)$, $L_c(i_r, j_r - 1)$, $L_c(i_r, j_r + 1)$ eleman değerlerini ϑ_c dizisine ekle. Tüm τ indeks değerleri için yapılan bu işlemler sonucunda, ϑ_c dizisi $L_c(x, y)$ öğrenme modelinden seçilen $5 \times \tau$ adet değer içerir.

Adım 2.3: ϑ_c dizisini azalan bir sırada sırala ve ϑ_c dizisindeki en değerli bilgileri karar verme aşamasında kullanmak için bu dizideki en yüksek η değeri seçerek ϑ_c^S dizisini eşitlik (2.11)'deki gibi oluştur. Denklemde, $\text{maks}_q(\vartheta_c)$ değeri ϑ_c dizisindeki q 'uncu en büyük değerdir. Bu aşamada, η değerinin seçimi oldukça önemlidir. Çünkü, yetersiz bir küçüklükte seçilirse, öğrenme modelinden az sayıda karşılaştırma adayı seçileceğinden sınıflandırma performansı düşer. Benzer şekilde, olması gerekenden büyük bir değer seçilirse, daha az ayırıcı değerler de işlemlere dahil edileceğinden performans yine düşer.

$$\vartheta_c^S = \{\text{maks}_1(\vartheta_c), \dots, \text{maks}_q(\vartheta_c), \dots, \text{maks}_\eta(\vartheta_c)\} \quad (2.11)$$

Adım 2.4: ϑ_c dizisindeki η değeri çarp ve χ_c olasılık üyeliğini eşitlik (2.12)'deki gibi hesapla. Eşitlikteki çarpım sonucu, test verisinin c sınıfına olan üyelik derecesini sayısal olarak ifade eder. Olasılık değerlerinin sıfırlanma problemi en yüksek η değer ve öğrenme aşamasında ayırma sınırıyla eşikleme ile minimize edilmeye çalışılır.

$$\chi_c = \prod_{f=1}^{\eta} \vartheta_c(f) \quad (2.12)$$

Adım 3: $s(t)$ test sinyalini en yüksek $\chi_{c \in \{0,1\}}$ olasılık üyelik değerlerinden faydalanarak $c' \in c$ olarak sınıflandır (eşitlik (2.13)).

$$c' = \underset{c' \in c}{\operatorname{argmax}}(\chi_c) \quad (2.13)$$

2.2.5. Yarı Olasılıksal Dağılımlar Kullanan Topluluk Öğrenme

2.2.5.1. Frekans Bantlarının Belirlenmesi

Önceki çalışmalar incelendiğinde, farklı veya aynı MHH görevleri için çeşitli frekans bantlarının kullanıldığı görülür. Örneğin, [142] içsel mod fonksiyonlarını 4-33 Hz aralığındaki ortalama frekansları kullanarak tanımlamıştır. [42, 143] EEG sinyallerini 5. derece Butterworth bant geçiren filtreye 8-30 Hz aralığında filtrelerken, [144] 8-35 Hz aralığında filtrelemiştir. Benzer şekilde, [145] 8-30 Hz aralığında filtreleme sonrasında çok değişkenli görgül kip ayrışımıyla artefakt ve gürültü kaldırmıştır. Benzer şekilde, [146] sinyalleri bant geçiren equiripple FIR filtresiyle 8-15 Hz aralığında filtreleyerek hem artefaktları kaldırmış hem de MHH ile ilişkili frekans bileşenlerini çıkarmıştır. Bu araştırmalardan farklı olarak, bazı çalışmalarda birden çok frekans bandı kullanılmıştır. Örneğin, [147] mu (8-12 Hz) ve beta (14-30) frekans bantlarını kullanmıştır. [148] ise 10 farklı bant geçiren filtre kümesini 8. dereceden bant geçiren Butterworth filtresiyle oluşturmuştur. Ayrıca, MHH ile ilişkili frekans bantlarının denekten-deneğe değişim gösterebildiği gözlenmiştir. Örneğin, [19] iki denek için en büyük desenkronizasyonları 9-13 Hz ve 10-12 Hz bantlarında, üçüncü denekte ise 22-29 Hz bandında gözlemiştir. Literatür incelendiğinde, eğer frekans bantları doğru belirlenmezse MHH kullanan BMA'ların planlandığı gibi çalışmayacağı ve hatta kararsız arayüzler ortaya çıkarabileceği görülür. Çünkü OİD/OİS sinyallerinin frekans bant stimülasyonu, beyindeki konumu ve sinyal örüntüsü aynı MHH görevini yürütseler bile denekten-deneğe değişiklik gösterebilir [149].

Örneğin, [149] alt bantları kullanan filtre tabanlı bir OUÖ algoritması ile ayırım kapasitesi yüksek frekans bantlarını otomatik olarak tanımayı ve çoğaltmayı amaçlamıştır. Ayrıca, OİD ve OİS'lerde frekans bantlarının lokalizasyonu zahmetli bir iştir ve genellikle yüksek miktarda işlem gücüne ihtiyaç duyar [150].


Tez çalışmasında, yukarıda verilen problemlerin bir kısmına çözüm sunmak için topluluk öğrenme kullanan bazı yaklaşımlar önerilmiştir. Bu nedenle, MHH ile ilişkili frekans bantları araştırılmış ve sinyaller 5. dereceden bant geçiren süzgeçle filtrelenmiştir. Belirlenen frekans bantları şu şekildedir: FB_1 (8-12 Hz), FB_2 (8-30 Hz), FB_3 (8-40 Hz), FB_4 (13-30 Hz) ve FB_5 (4-40 Hz). Bu bant aralıklarının belirlenmesi [19, 42, 142, 143, 144, 147, 148] çalışmaları ve ön sınıflandırma aşamalarıyla gerçekleştirilmiştir.

2.2.5.2. Zaman Dilimlerinin Belirlenmesi

MHH için farklı veri setlerinde farklı deneysel paradigmlar kullanılmıştır. Bu da doğal olarak, farklı uzunluk, zaman ve konumlarda bilgi içeren zaman dilimleri anlamına gelir. Örneğin, Data Set IIA veri setinde, odaklanmadan sonra 2. sn'de bir ipucu 1.25 sn boyunca ekranda gösterilmiş ve MHH görevlerinin 6. sn'ye kadar gerçekleştirilmesi istenmiştir. Diğer çalışmalarda farklı veya aynı MHH görevleri için çeşitli zaman dilimleri kullanılmıştır. [42, 142, 143, 144, 151]'de başlangıç ipucu gösterildikten sonra 0.5-2.5 sn aralığındaki zaman dilimleri kullanılmıştır. [147]'de başlangıç ipucu gösterildikten sonraki 3 sn'lik dilim kullanırken, [146]'da MHH ile ilişkili 3 sn'lik bir zaman dilimi kullanılmıştır. Literatürde, aynı veri setlerinde bile çeşitli uzunluklar ve dilimlerde zaman pencereleri kullanılabilmiştir. Tez çalışmasında bu nedenle ön sınıflandırma aşamaları yürüterek zaman dilimleri şu parametrelerle belirlenmiştir: pencere başlangıç zamanı, pencere uzunluğu ve pencere örtüşme miktarı. Örneğin, Data Set IIA veri setinde, EEG sinyallerinin 2 sn'lik sabit uzunluktaki pencereler ve 0.5 sn'lik örtüşmelerle incelenmesine karar verilmiştir. MHH ile ilişkili bu zaman dilimleri başlangıç ipucu gösterildikten sonraki zaman dilimi temel alındığında şu şekildedir: ZD_1 (0.5 sn ile 2.5 sn arası), ZD_2 (1.0 sn ile 3.0 sn arası) ve ZD_3 (1.5 sn ile 3.5 sn arası). Bu zaman dilimleri MHH için optimum zaman dilimlerinin belirlenmesi ve topluluk öğrenme yöntemlerinde sınıflandırma için kullanılmıştır.

2.2.5.3. Öznitelik Çıkarma ve Sınıflandırma

MHH görevlerinin başarılı bir şekilde sınıflandırılması için halen birçok problem çözülmelidir. Bu kısımda, önceki çalışmalara göre bazı değişikliklere gidilmiş ve topluluk öğrenme yöntemlerinin farklı bir biçimde uygulaması amaçlanmıştır. Örneğin, önceki oylama yöntemlerinde K-EYK, DVM, karar ağaçları gibi klasik yöntemlerinin çıktıları oylanmıştır. Tez çalışmasında, öncelikle çeşitli frekans bantları ve zaman dilimlerine ait veri domainine yarı olasılıksal dağılım modelleri (YODM) uygulanarak alt sınıflandırıcılar oluşturulmuştur. Daha sonra, bu sınıflandırıcılar topluluk öğrenme yöntemlerine uygulanmıştır. Ayrıca, sınıflandırıcıların kombinasyonları da alınarak karar verilmiştir.



Şekil 2.15. Bir alt sınıflandırıcının şematik gösterimi

Bu kısımdaki öznitelik çıkarma ve sınıflandırma yöntemleri Data Set IIA veri seti kullanılarak anlatılmıştır. Bölüm 2.2.5.1 ve 2.2.5.2'de $K_{fb} = \{FB_1, FB_2, FB_3, FB_4, FB_5\}$ frekans bandı ve $K_{zd} = \{ZD_1, ZD_2, ZD_3\}$ zaman dilimi kümelerinin kullanılmasına karar verilmişti. $K_s = \{S_{i1}(\cdot), S_{i2}(\cdot), S_{ij}(\cdot), \dots, S_{i5}(\cdot)\}$ kümesinin YODM ile oluşturulan alt sınıflandırıcıları ifade ettiği varsayalım. $S_{ij}(\cdot)$ alt sınıflandırıcılarının şematik gösterimi Şekil 2.15'teki gibidir. Burada, $s(t)$ girdi sinyalini, E_{ij} ise geleneksel sınıflandırma problemleri ve çoğunluk oylama kullanan yaklaşımlar için çıktı etiket değeridir. Yumuşak oylama kullanan yaklaşımlar için ise çıktı O_{ij} olasılıkları şeklindedir. $S_{ij}(\cdot)$ alt sınıflandırıcısı, K_{zd} kümesindeki i indeksli zaman dilimi ve K_{fb} kümesindeki j indeksli frekans bandıyla oluşturulur. Benzer şekilde, $K_{ce} = \{E_{i1}, E_{ij}, \dots, E_{i5}\}$ bu sınıflandırıcılardan elde edilen etiket değerleri kümesini, $K_{co} = \{O_{i1}, O_{ij}, \dots, O_{i5}\}$ ise olasılık çıktı değerleri kümesini ifade eder. İkili sınıflandırma problemleri için, E_{ij} etiketleri $\{0,1\}$ değerlerini, O_{ij}

ise (o_0, o_1) olasılık değerlerini içerir. Bu düzenleme ve varsayımlar ışığında, önerilen yaklaşımlar başlıklar halinde aşağıdaki gibidir.

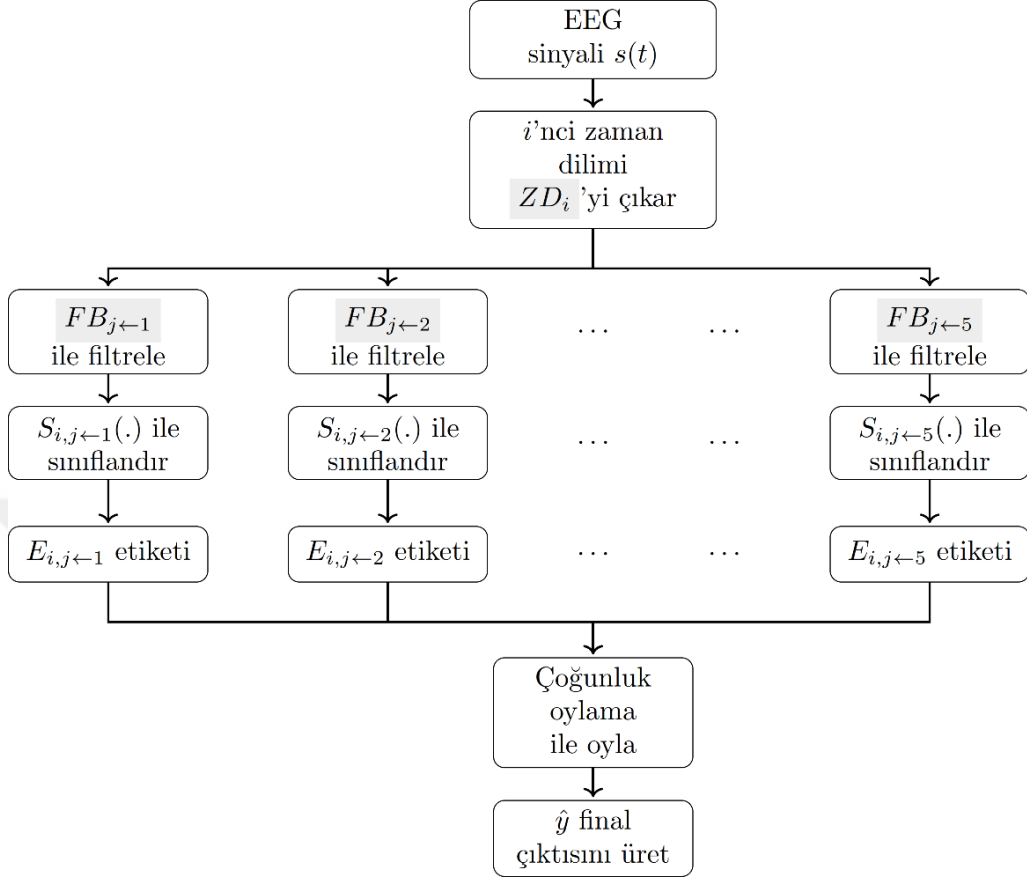
2.2.5.3.1. Tekil Sınıflandırma

Yaklaşım 1 (Y1) tekil $S_{ij}(\cdot)$ sınıflandırıcılarının kullanıldığı temel yöntemdir. Bu yaklaşımda, i 'nci zaman dilimi çıkarılan $s(t)$ sinyali j 'nci frekans bandı ile filtrelenir ve YODM uygulanır. Her bir $i = 1, \dots, 3$ ve $j = 1, \dots, 5$ (i ve $j \in N$) ikilisi için tekil sınıflandırıcılar oluşturulur.

2.2.5.3.2. Aynı Zaman Diliminde Geleneksel Oylama

Yaklaşım 2 (Y2) frekansı en yüksek alt sınıflandırıcı etiketine göre nihai kararın verildiği çoğunluk oylama yaklaşımını kullanır. Öncelikle, K_{zd} kümesindeki her bir i 'nci ZD_i zaman dilimi için $K_{ce} = \{E_{i1}, E_{ij}, \dots, E_{i5}\}$ çıktıları oluşturulur. Daha sonra, \hat{y} nihai sınıflandırıcı çıktısı $j = 1, \dots, 5$ için elde edilen etiketlere çoğunluk oylama uygulanarak hesaplanır. Yaklaşımın şematik gösterimi Şekil 2.16'daki gibidir. Algoritma EEG sinyallerini girdi olarak alır, sinyallerin i 'nci zaman dilimini çıkarır ve izleyen şu adımları paralel bir şekilde yürütür: (1) j 'nci frekans bant filtresi FB_j 'yi uygula, (2) YODM ile sınıflandır ve $S_{ij}(\cdot)$ alt sınıflandırıcılarını oluştur, (3) E_{ij} etiketlerini hesapla. Son aşamadaysa E_{ij} etiketleri çoğunluk oylamayla değerlendirilir.

Yaklaşım 3 (Y3) uniform ağırlıkları içeren yumuşak oylama kullanır. Final sınıflandırma çıktısı için alt sınıflandırıcıların olasılık çıktıları uniform ağırlıklarla birleştirilir. Yaklaşımda her i 'nci ZD_i zaman dilimi için şu adımlar yürütülür: (1) $S_{ij}(\cdot)$ alt sınıflandırıcılarına uniform a_{ij} ağırlıklarını ata, (2) $K_{co} = \{O_{i1}, O_{ij}, \dots, O_{i5}\}$ kümesini oluştur ve (3) O_{ij} sınıf olasılıklarının ortalamasını alarak nihai sınıflandırma sonucunu hesapla. Yaklaşım Şekil 2.16'da verilen diyagramla benzer adımları içerir. Ancak, olasılık değerlerini içeren K_{co} çıktıları kullanır ve son adımda yumuşak oylamayla karar verir.



Şekil 2.16. Yaklaşım 2'nin şematik gösterimi

2.2.5.3.3. Aynı Zaman Diliminde Kombinasyonel Oylama

Topluluk öğrenme yöntemleri için başarı açısından en optimum $S_{ij}(\cdot)$ sınıflandırıcı kombinasyonlarını araştırır. Bu amaçla, K_{ce} (çoğunluk oylama için) ve K_{co} (yumuşak oylama için) kümelerinin 3'lü kombinasyonlarını tekrarlamasız olarak değerlendirir. Diğer bir deyişle, her bir i 'nci zaman dilimi için 5 frekans bandından üretilen sonuçların 3'lü kombinasyonları araştırılır ve $\binom{5}{3} = 10$ farklı sınıflandırıcı oluşturulur. 3'lü kombinasyon kullanılmasının nedeni ikili sınıflandırma problemlerinde oylama yapılmasıdır. Bu değer 2 veya 4 seçildiğinde karar vermede bir eşitlik riskiyle karşılaşılır. Benzer şekilde, 5 seçildiğinde aynı zaman dilimlerinde oylamaya, 1 seçildiğinde ise zaman dilimleri ve frekans bantlarında tekil sınıflandırmaya denk gelir. Herhangi bir i 'nci zaman dilimine ait sinyal için 5 farklı frekans bandından üretilen 3'lü alt sınıflandırıcı kombinasyonları Şekil 2.17'deki gibidir. Bu yaklaşımda, n indeksiyle ifade edilen her bir $KM_3(n)$ sınıflandırıcı

kombinasyonu bir sınıflandırıcı topluluğu olarak ele alınır. Yaklaşım 4 (Y4) çoğunluk, Yaklaşım 5 (Y5) ise uniform ağırlıkları içeren yumuşak oylama konseptini kullanır.

$$\begin{aligned}
 KM_3(1) &= \begin{matrix} S_{i1}(\cdot) & S_{i2}(\cdot) & S_{i3}(\cdot) & S_{i4}(\cdot) & S_{i5}(\cdot) \end{matrix} \\
 KM_3(2) &= \begin{matrix} S_{i1}(\cdot) & S_{i2}(\cdot) & S_{i3}(\cdot) & S_{i4}(\cdot) & S_{i5}(\cdot) \end{matrix} \\
 KM_3(3) &= \begin{matrix} S_{i1}(\cdot) & S_{i2}(\cdot) & S_{i3}(\cdot) & S_{i4}(\cdot) & S_{i5}(\cdot) \end{matrix} \\
 KM_3(n) &= \begin{matrix} \dots & \dots & \dots & \dots & \dots \end{matrix} \\
 KM_3(9) &= \begin{matrix} S_{i1}(\cdot) & S_{i2}(\cdot) & S_{i3}(\cdot) & S_{i4}(\cdot) & S_{i5}(\cdot) \end{matrix} \\
 KM_3(10) &= \begin{matrix} S_{i1}(\cdot) & S_{i2}(\cdot) & S_{i3}(\cdot) & S_{i4}(\cdot) & S_{i5}(\cdot) \end{matrix}
 \end{aligned}$$

Şekil 2.17. Frekans bantlarına göre üçlü sınıflandırıcı kombinasyonları

2.2.5.3.4. Aynı Frekans Bandında Oylama

Bu yaklaşımlar, aynı frekans bandıyla filtrelenen ve tüm zaman dilimleriyle oluşturulan alt sınıflandırıcıları oylar. Örneğin, her bir $i = 1, \dots, 3$ zaman diliminin j 'nci frekans bandıyla filtrelenmesi sonucu oluşan $\{S_{1j}, S_{2j}, S_{3j}\}$ şeklindeki 3'lü sınıflandırıcı kombinasyonlarıyla karar verilir. Yaklaşım 6 (Y6) çoğunluk, Yaklaşım 7 (Y7) ise uniform ağırlıkları içeren yumuşak oylama konseptini kullanır.

2.2.5.3.5. Tüm Zaman Dilimleri ve Frekans Bantlarında Oylama

Tüm frekans bantları ve zaman dilimlerini kullanan en kapsamlı yaklaşımdır. Örneğin, Data Set 2a veri seti için, Yaklaşım 8 (Y8)'de K_{zd} kümesindeki 3 farklı zaman diliminin her birine K_{fb} kümesindeki 5 frekans bandını uygulanarak 15 elemanlı $K_{çe}$ çıktı kümesi oluşturulur. Bu çıktı kümesine çoğunluk oylama uygulanarak nihai sınıflandırma sonucu hesaplanır. Yaklaşım 9 (Y9) ise farklı olarak $K_{ço}$ kümesine uniform ağırlıkları içeren yumuşak oylama uygulanarak karar verilir.

2.2.6. 2-B Modelleme Görüntülerinin Oluşturulması

Evrişimli sinir ağları (ESA) günümüzün en popüler öğrenme yaklaşımlarındandır. ESA hem etkili öznelikleri hem de sınıflandırıcıları ham verilerden eş zamanlı öğrenme potansiyeline sahiptir ve biyomedikal sinyal işleme alanında da oldukça popülerdir. Ancak, EEG sinyallerinin doğrudan kullanan bir boyutlu ESA'lar haricindeki çoğu ESA görüntü sınıflandırma problemleri için geliştirilmiştir ve EEG sinyallerinin bu tarz ESA'lara uygulanması için biyomedikal sinyallerin görüntü gibi iki boyutlu girdilere dönüştürülmesi gerekir. Bu nedenle, özellikle zaman serileri şeklindeki sinyalleri sınıflandırmak için iki boyutlu öznelik veya öznelik dönüştürme yöntemleri gerekir. Literatürde, kısa zamanlı Fourier dönüşümü ve sürekli dalgacık dönüşümü gibi yöntemlerle biyomedikal sinyaller görüntülere dönüştürülüp ESA'lara verilmiştir. Çalışmada, Bölüm 2.2.3'te verilen 2-B $OM(x, y)$ öznelikleri 2-B modelleme görüntülerine çeviren yeni bir teknik önerilmiştir.

$M \times N$ boyutlu $OM(x, y)$ özneliklerin modelleme görüntülerine dönüştürülmesi şu şekilde gerçekleştirilir. Öncelikle, herhangi bir $s(t)$ sinyali MMH ile ilişkili frekans bantlarında ayrı ayrı filtrelenir ve filtrelenmiş sinyallerin her birinden $M \times N$ boyutlu $MG(x, y)$ modelleme görüntüleri oluşturulur. Daha sonra, görüntüler Şekil 2.18'deki gibi birleştirilir ve $BMG(x, y)$ birleştirilmiş modelleme görüntüsü oluşturulur. Modelleme görüntülerinin bu şekilde oluşturulması farklı bantlardan elde edilen bilgilerin birleştirilmesi içindir. Ön performans değerlendirmeleri yalnızca bir frekans bandıyla oluşturulan görüntülerin yeterli başarı üretmediğini göstermiştir. Görüntülerin oluşturulmasında, 2-B yarı olasılıksal dağılımlar kullanan öğrenme modelindeki frekans bantlarına ek olarak 1 – 50Hz'de kullanılmıştır. Böylelikle, hem daha geniş bir frekans bandından gelen öznelik bilgileri eklenmiş hem de yeterli modelleme görüntü sayısı sağlanmıştır.

MHH ile ilişkili frekans bantları $FB_1(8 - 12\text{Hz})$, $FB_2(8 - 30\text{Hz})$, $FB_3(8 - 40\text{Hz})$, $FB_4(13 - 30\text{Hz})$, $FB_5(4 - 40\text{Hz})$ ve $FB_6(1 - 50\text{Hz})$ şeklinde olsun. EEG sinyali $s(t)$ 'den $BMG(x, y)$ görüntüsü bu şartlarda şu şekilde oluşturulur.

Adım 1: $i = 1, \dots, 6$ için alt adımları ayrı ayrı yürüt ve $MG_i(x, y)$ görüntülerini oluştur.

Adım 1.1: $s(t)$ sinyalini FB_i bandıyla filtrele ve $s_f(t)$ filtrelenmiş sinyalini oluştur.

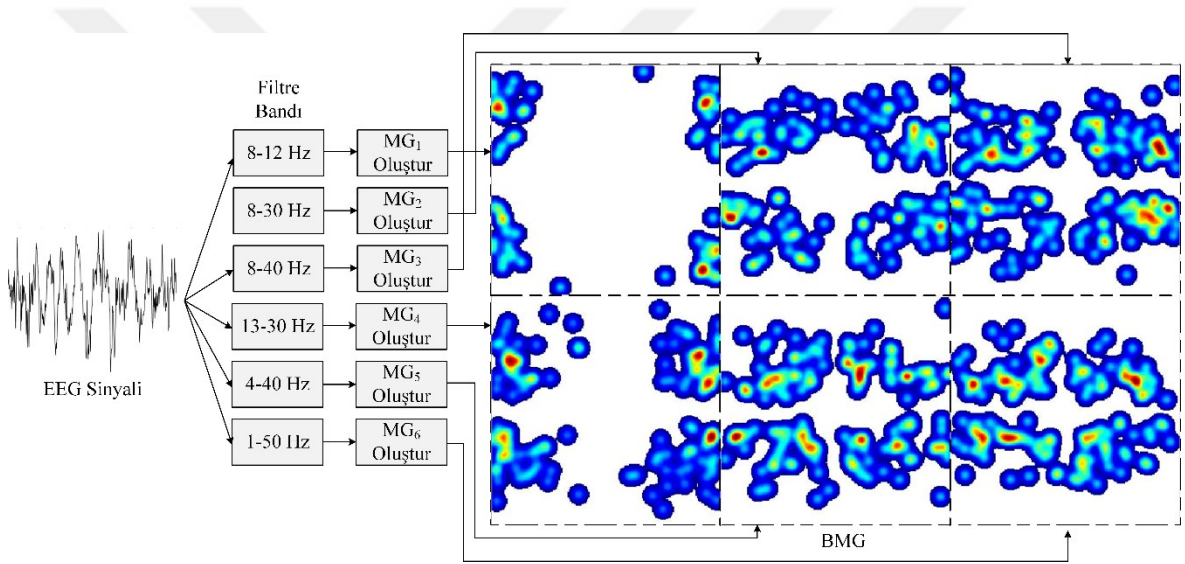
Adım 1.2: $s_f(t)$ 'nin 200×200 boyutlu $OM(x, y)$ öznelik matrisini hesapla. Dikkat edilecek olursa, öznelik oranlarına ait 200×360 gibi bir boyut kullanılmamıştır. Çünkü,

$OM(x, y)$ ile oluşturulacak görüntüler ESA'lara girdi olarak verileceğinden, bütün kenarları eşit uzunlukta olan matrislerle özniteliklerin oluşturulması daha doğru olur.

Adım 1.3: $OM(x, y)$ 'ye Gauss uygula ve $OM(x, y) * G(x, y)$ konvolüsyonu ile yumuşatılmış değerleri içeren $OM^*(x, y)$ 'yi hesapla.

Adım 1.4: $OM^*(x, y)$ 'nin içeriğini aralık değeri 128 olacak şekilde 'jet' renk haritasının tam aralığına ölçeklendirir ve renkli $MG_i(x, y)$ görüntüsünü oluştur.

Adım 2: $i = 1, \dots, 6$ için oluşturulan $MG_i(x, y)$ görüntülerini Şekil 2.18'deki gibi birleştir ve $BMG(x, y)$ birleştirilmiş modelleme görüntüsünü oluştur.



Şekil 2.18. Birleştirilmiş modelleme görüntülerinin oluşturulma diyagramı

MHH-BMTA veri setinde bir tıklama görevine ait MHH sinyalinin birleştirilmiş modelleme görüntüsüne dönüştürülme diyagramı Şekil 2.18'deki gibidir. Görüntünün oluşturulmasında kullanılan EEG sinyali A02 deneğine aittir ve C3 elektrotundan kaydedilmiştir. Geçiş noktaları 0.05 değeriyle tespit edilmiş, ($w = [21 \times 21], \sigma = 4.0$) Gauss çekirdeği uygulanmış ve $MG_i(x, y)$ görüntüleri 100×100 boyutuna ölçeklendirilmiştir. Birleştirilmiş modelleme görüntüleri sınıflandırma aşamasında evrişimli sinir ağlarının girdi boyutuna ölçeklendirilmiştir.

3. BULGULAR VE İRDELEME

Bu bölümde çalışmanın hipotezinin doğrulanması sürecinde elde edilen bulgular irdelenerek sunulmuştur. Deneyle çeşitli veri setindeki birçok problemde yürütülmüş ve sonuçlar çeşitli istatistiksel yöntemlerle değerlendirilmiştir.

3.1. BCI Competition II Yarışması Data Set Ia Veri Seti İçin Sonuçlar

Önerilen yöntemin geçerliliğinin sınanması için ilk çalışmalar Data Set Ia veri setindeki imleç hareket hayali verilerinin sınıflandırılması için yürütülmüştür. Öncelikle frekans bantları, zaman dilimleri ve sensör elektrotlar belirlenmiştir. Ardından, yarı olasılıksal dağılım modelleri (YODM) kullanan alt-sınıflandırıcılar oluşturulmuş ve topluluk öğrenme yöntemlerine uygulanmıştır. YODM yöntemlerinde öncelikle EEG sinyalleri 2-B öznitelikler şeklinde yeniden oluşturulup modellenmiştir (Bölüm 2.2.3). Daha sonra, yarı olasılıksal dağılımlarla öğrenme modelleri oluşturulmuştur (Bölüm 2.2.4.1). Son olarak, eğitim aşamasında kullanılmayan test verilerinin farklı kategorilere olan sınıf olasılık üyelikleri hesaplanarak karar verilmiştir (Bölüm 2.2.4.2).

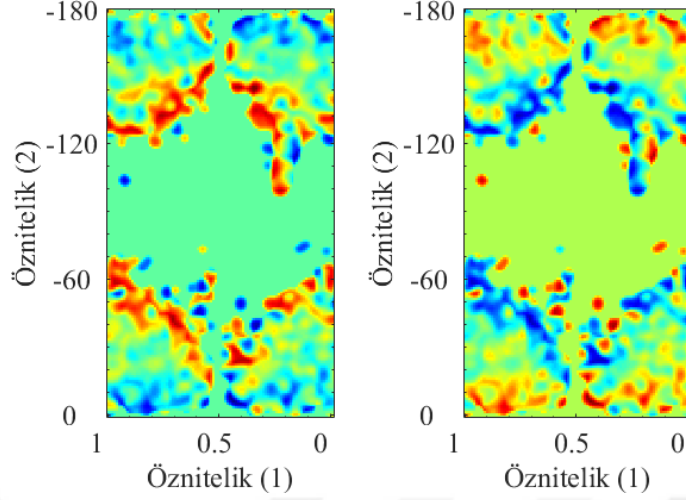
3.1.1. Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi

Frekans bant kümesi $K_{fb}=\{FB_1, FB_2, FB_3, FB_4, FB_5\}$ beşinci dereceden bant geçiren filtreyle oluşturulmuştur. Bu frekans bantları $FB_1=(8-12 \text{ Hz})$, $FB_2=(8-30 \text{ Hz})$, $FB_3=(8-40 \text{ Hz})$, $FB_4=(13-30 \text{ Hz})$ ve $FB_5=(4-40 \text{ Hz})$ şeklindedir. Deneğin görüntü geri beslemesi 2.0 sn ile 5.5 sn aralığındaki 3.5 sn'lik zaman dilimdedir ve bu dilim temiz imleç hareket bilgisi içerdiğinden sınıflandırma için kullanılmıştır. $K_{zd}=\{ZD_1, ZD_2, \dots, ZD_{11}\}$ zaman dilimleri kümesi bu 3.5 sn'lik zaman dilimi içerisinde 1 sn'lik sabit uzunluklu pencereler ve 0.25 sn'lik örtüşmelerle oluşturulmuştur. Başlangıç ipucu gösterildikten sonraki zaman dilimi temel alındığında MHH ilişkili pencereler şu şekildedir: ZD_1 (0.0 sn ile 1.0 sn arası), ZD_2 (0.25 sn ile 1.25 sn arası), ZD_3 (0.5 sn ile 1.5 sn arası), ZD_4 (0.75 sn ile 1.75 sn arası), ZD_5 (1.0 sn ile 2.0 sn arası), ZD_6 (1.25 sn ile 2.25 sn arası), ZD_7 (1.5 sn ile 2.5 sn arası), ZD_8 (1.75 sn ile 2.75 sn arası), ZD_9 (2.0 sn ile 3.0 sn arası), ZD_{10} (2.25 sn ile 3.25 sn arası), ZD_{11} (2.5 sn ile

3.5 sn arası). Sensör elektrotlar şu konumlara yerleştirilmiştir: A1-Cz (A1 = sol mastoid), A2-Cz, C3'ün 2 cm frontal konumu, C3'ün 2 cm parietal konumu, C4'ün 2 cm frontal konumu ve C4'ün 2 cm parietal konumu. Sonuçlar bu konumlar için ayrı ayrı alınmıştır.

3.1.1. Parametre Değerlerinin Belirlenmesi

Öznitelik çıkarma aşamasında çeşitli parametre kombinasyonları sınanmıştır. Bu parametreler, 2-B özniteliklerin oluşturulması için $M \times N$ boyut parametresi ve δt geçiş eşiğidir. $M \times N$ boyutu 180×100 olarak alınmıştır. Farklı denekler, görevler ve frekans bantları için optimum δt farklılık gösterebilir. Bu nedenle, potansiyel eşikler $[0.01 - 0.51]$ aralığında $\Delta t = 0.01$ artımla aranmıştır. Tespit edilen geçiş noktaları yeterli değilse, δt 'nin üst limiti kademeli azaltılmıştır. Öğrenme ve test aşamalarında $M \times N$ boyutu, Gauss çekirdeği, δm ayırma değeri ve ayırım kapasitesi yüksek olasılık bilgilerini seçmek için η değeri belirlenmelidir. Boyut için öznitelik çıkarma aşamasında belirlenen $M \times N$ değeri kullanılmıştır. Öğrenme matrislerinin Gauss çekirdekleri ile yumuşatılmasında Çekirdek 1 ($w = [5 \times 5]$, $\sigma = 0.9$), Çekirdek 2 ($w = [9 \times 9]$, $\sigma = 1.6$), Çekirdek 3 ($w = [11 \times 11]$, $\sigma = 2.0$) ve Çekirdek 4 ($w = [21 \times 21]$, $\sigma = 4.0$) görevlendirilmiştir. $[0 - 1]$ aralığına minimum-maksimum tekniğiyle normalize edilmiş matrisler δm ile $[0.01 - 0.55]$ aralığında 0.01 artımla eşiklenmiştir. Farklı η değeri $[1 - 89]$ aralığında 8 artımla test edilmiştir. Ayrıca, δm ve η değerleri yeterli öznitelik üretmezse, bu aralıkların üst limitleri kademeli olarak azaltılmıştır.



Şekil 3.1. Data set Ia için oluşturulan 2-B örnek öğrenme modelleri

Sınıflandırılma için 0.0 sn ile 1.0 sn zaman dilimindeki sinyallerin 4-40 Hz aralığında filtrelenmesi sonucu oluşan 180×100 boyutlu öğrenme modelleri Şekil 3.1'deki gibidir. Modeller C3'ün 2 cm parietal konumundan kaydedilen verilerin Çekirdek 3'le yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.06 ve ayırma değeri 0.5 alınmıştır.

3.1.2. Deneysel Sonuçlar ve Analizler

Deneysel veri setinde yer alan bir deneğe ait ikili sınıflandırma problemi için 15 koşumun ortalamaları ve standart sapmaları alınarak hesaplanmıştır. Performans değerleri doğruluk ve Cohen'in kappa ölçütleriyle hesaplanmıştır. Veri setinin tanımında verilen ve hiçbir örtüşen elemanın olmadığı eğitim ve test kümesi sonuçların hesaplanmasında kullanılmıştır. Eğitim ve test kümelerinde örtüşen hiçbir eleman yoktur. Bu işlem literatür ile yapılacak kıyaslamaların geçerliliği için önemlidir. Önerilen yöntemlerinin optimum sınıflandırma parametreleri eğitim kümesinden elde edilen alt eğitim ve doğrulama kümeleri ile belirlenmiştir. Test kümesindeki hiçbir örnek eğitim için kullanılmamıştır. Bu bilgiler ışığında, Bölüm 2.2.5.3'te başlıklar halinde verilen dokuz yaklaşımla sonuçlar alınmıştır. Data set Ia veri seti bir deneğe ait bir problem içerdiğinden sadece en başarılısının sonuç verilmiş, önerilen yaklaşımlar boyunca detaylı bir irdeleme yapılmamıştır. Önerilen yaklaşımlara ait detaylı analizler daha geniş problem havuzuna sahip veri setleri için Bölüm 3.1.2 ve 3.2.3'te yapılmıştır.

İmleç hareket hayali görevinin sınıflandırılmasında en iyi sonuçlar tüm zaman dilimleri ve frekans bantlarında çoğunluk oylamayı ifade eden Yaklaşım 8 ile 77.59 ± 0.69 doğruluk ve 0.55 ± 0.01 kappa değerlerinde elde edilmiştir. Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları incelenmiştir. İncelemede, tüm koşullar boyunca en başarılı sonuçlar veren yöntem parametreleriyle bir havuz oluşturulmuş ve her parametrenin veya aralığın ne kadar katkı sağladığı hesaplanmıştır. En iyi sonuçların yaklaşık %15.52'sinde ($w=[5 \times 5]$, $\sigma=0.9$), %14.91'inde ($w=[9 \times 9]$, $\sigma=1.6$), %34.79'unda ($w=[11 \times 11]$, $\sigma=2.0$) ve %34.79'unda ($w=[21 \times 21]$, $\sigma=4.0$) çekirdeği başarılı olmuştur. Geçiş noktalarını belirleyen eşiklerde (0-0.3) aralığındaki küçük değerler en iyi sonuçların yaklaşık %77.50'sini elde etmiştir. Olasılık vektör eşliğinde [1-30] ve [40-50] aralığında en başarılı sonuçlar alınırken diğer değerler için az da olsa başarılı sonuçlar gözlenmiştir. Ayırma değeri için [0.1-0.55] aralığında homojen bir dağılım gözlenmiştir.

Tablo 3.1. Data Set Ia için sınıflandırma doğruluk kıyaslamaları

Çalışma	Yöntem	Doğruluk (%)
Torre [153]	GloBo stokastik algoritması	50.90
Lederman vd. [155]	Kısmi korelasyon katsayıları ve SMM	53.00
Rado vd. [153]	Zaman gecikmeli YSA	65.50
Lederman vd. [155]	LPC-derived cepstrum ve SMM	69.00
Wu vd. [158]	Olasılıksal sinir ağları	75.30
Grabner vd. [153]	Çok katmanlı algılayıcı sinir ağları	75.40
Saffari vd. [153]	YSA	76.50
Tez çalışması	Y8 yaklaşımı	77.59
Erdogmus vd. [153]	Çoğunluk oylama	80.90
Pinto [153]	SMM	84.30
Huang vd. [153]	Doğrusal olmayan DVM	85.00
Mensh [153]	DVM	88.70
Ting vd. [24]	DPA ve Fisher ölçütü	90.80
Duan vd. [159]	TBA, DAA ve çekirdek hiyerarşik aşırı makine öğrenmesi	90.94
Lederman vd. [155]	Enerji filtre bankası katsayıları ve SMM	91.00
Kayikcioglu vd. [161]	Polinom uydurma ve K-EYK	92.15
Duan vd. [157]	TBA ve DAA ve oylama kullanan aşırı öğrenme makinesi	92.30
Wu vd. [158]	Genetik algoritma	93.80

Sonuçlar, aynı veri kümelerinde yürütülmüş çalışmalarla doğruluk ölçütüyle kıyaslanmıştır. Önceki çalışmalarda bu ölçüt kullanılırken kapa değerleri kullanılmamıştır. Y8 yaklaşımı [153, 155 ve 158]'e ait 6 yöntemden %1.10-%25.60 aralığında daha başarılı olmuştur. Diğer yandan, [24, 153, 155, 157, 158, 159 ve 161]'e ait 10 yöntem önerilen yaklaşımdan %4.40-%17.30 aralığında daha başarılı olmuştur. Sonuçlar, performansın artırılması için iyileştirmelerin yapılması gerektiğini ortaya koymaktadır (Tablo 3.1). Önerilen yaklaşımın eğitim ve test için hesaplama süreleri tatmin edici seviyededir. En başarılı sonuçları üreten Y8 yaklaşımının toplam 50 koşulda elde ettiği ortalama eğitim ve test süreleri sırasıyla 18.37 ve 0.0296 saniyedir. Eğitim kümesindeki örnek sayısı ve öğrenme modellerinin oluşturulma maliyetiyle ilintili eğitim süresi kabul edilebilir seviyededir. Dahası, test süresi oldukça kabul edilebilir seviyededir. Uygulamalar Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz işlemci, 16 GB RAM bellek ve Windows 10 Education 64-bit işletim sisteminde MATLAB R2018b ortamında gerçekleştirilmiştir. Veri edinimi ile gürültü kaldırma için BioSig kütüphanesi ve EmotivPro kullanılmıştır.

3.2. BCI Competition IV Yarışması Data Set 2a Veri Seti İçin Sonuçlar

Bu kısımda EEG temelli BMA sistemlerin tasarımı için Data Set 2a veri setindeki MHH görevlerinin sınıflandırılmasına odaklanılmıştır. Öncelikle MHH ile ilişkili frekans bantları, zaman dilimleri ve sensör elektrotlar belirlenmiştir. Ardından, yarı olasılıksal dağılım modelleri (YODM) kullanan alt-sınıflandırıcılar oluşturulmuş ve topluluk öğrenme yöntemlerine uygulanmıştır.

3.2.1. Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi

MHH ilişkili frekans bant kümesi $K_{fb}=\{FB_1, FB_2, FB_3, FB_4, FB_5\}$ beşinci dereceden bant geçiren filtreye oluşturulmuştur. Bu frekans bantları $FB_1=(8-12 \text{ Hz})$, $FB_2=(8-30 \text{ Hz})$, $FB_3=(8-40 \text{ Hz})$, $FB_4=(13-30 \text{ Hz})$ ve $FB_5=(4-40 \text{ Hz})$ şeklindedir. $K_{zd}=\{ZD_1, ZD_2, ZD_3\}$ zaman dilimleri kümesi 2 sn'lik sabit uzunluklu pencereler ve 0.5 sn'lik örtüşmelerle oluşturulmuştur. Başlangıç ipucu gösterildikten sonraki zaman dilimi temel alındığında MHH ilişkili pencereler şu şekildedir: ZD_1 (0.5 sn ile 2.5 sn arası), ZD_2 (1.0 sn ile 3.0 sn


arası) ve ZD₃ (1.5 sn ile 3.5 sn arası). MHH bilgisi düşük olabileceğinden, başlangıç ipucundan sonraki 0.5 sn'lik ve odaklanma sinyalinin kaldırılmasından önceki 0.5 sn'lik zaman dilimleri kullanılmamıştır. Elektrot konumları olarak ise hareket hayaliyle ilişkili C3 ve çevresindeki FC3, C1, CP3, C5; Cz ve çevresindeki FCz, C2, CPz, C1; C4 ve çevresindeki FC4, C6, CP4, C2 kullanılmıştır. Sonuçlar bu konumlar için ayrı ayrı alınmıştır.

3.2.2. Parametre Değerlerinin Belirlenmesi

Öznitelik çıkarma aşamasında çeşitli parametre kombinasyonları sınanmıştır. Bu parametreler, 2-B özniteliklerin oluşturulması için $M \times N$ boyut parametresi ve δt geçiş eşiğidir. Birinci ve ikinci boyutlar sırasıyla $[-180^\circ, 180^\circ]$ ve $[-1, 1]$ aralıklarındadır. Bu nedenle, boyut değerleri 90×50 ve 180×100 olarak tanımlanmıştır. Farklı denekler, görevler ve frekans bantları için optimum δt farklılık gösterebilir. Bu nedenle, potansiyel eşikler $[0.01 - 3.5]$ aralığında $\Delta t = 0.075$ ve $\Delta t = 0.1$ artımlarla aranmıştır. Ayrıca, tespit edilen geçiş noktaları yeterli değilse δt 'nin üst limiti kademeli azaltılmıştır. Örneğin, 8-12 Hz frekans bandında çalışıldığında az sayıda geçiş noktası tespit edilmiş ve parametre üst değeri kademeli azaltılmıştır. Öğrenme ve test aşamalarında $M \times N$ boyutu, Gauss çekirdeği, δm ayırma değeri ve ayırım kapasitesi yüksek olasılık bilgisini seçen η parametre değeri belirlenmelidir. Boyut için öznitelik çıkarmada aşamasındaki $M \times N$ değerleri kullanılmıştır. Öğrenme matrislerinin Gauss çekirdekleriyle yumuşatılmasında Çekirdek 1 ($w = [5 \times 5], \sigma = 0.9$), Çekirdek 2 ($w = [9 \times 9], \sigma = 1.6$), Çekirdek 3 ($w = [11 \times 11], \sigma = 2.0$) ve Çekirdek 4 ($w = [21 \times 21], \sigma = 4.0$) kullanılmıştır. $[0 - 1]$ aralığına minimum-maksimum yöntemiyle normalize edilmiş matrisler δm ile $[0.05 - 0.8]$ aralığında 0.1 artımla eşiklenmiştir. Optimum η değeri $[1 - 150]$ aralığında 5 artımla aranmıştır. δm ve η yeterli öznitelik üretmezse üst limitleri kademeli azaltılmıştır.

Sol el/sağ el MHH görevinin sınıflandırılması için A06 deneğine ait 2.5 sn ile 4.5 sn zaman dilimindeki sinyallerin 8-40 Hz aralığında filtrelenmesiyle oluşan öğrenme modelleri Şekil 3.2 (a)'daki gibidir. Modeller 11 numaralı elektrottan kaydedilen verilerin Çekirdek 3'le yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.11 ve ayırma değeri 0.05 alınmıştır. Benzer şekilde, sol el/ayaklar görevinin sınıflandırılması için A09 deneğine ait 2.5 sn ile 4.5 sn zaman dilimindeki sinyallerin 4-40 Hz aralığında filtrelenmesiyle oluşan modeller Şekil


3.2 (b)'deki gibidir. Modeller 12 numaralı elektrottan kaydedilen verilerin Çekirdek 4'le yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.61 ve ayırma değeri 0.75 alınmıştır.



Şekil 3.2. Sol/sağ el ve sol el/ayaklar MHH için örnek öğrenme modelleri

Sol el/dil MHH görevinin sınıflandırılması için A09 deneğine ait 3.0 sn ile 5.0 sn zaman dilimindeki sinyallerin 8-12 Hz aralığında filtrelenmesiyle oluşan öğrenme modelleri Şekil 3.3 (a)'daki gibidir. Modeller, CP3 elektrotundan kaydedilen verilerin Çekirdek 4'le yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.91 ve ayırma değeri 0.1 alınmıştır. Benzer şekilde, sağ el/ayaklar görevinin sınıflandırılması için A07 deneğine ait 2.5 sn ile 4.5 sn zaman dilimindeki sinyallerin 13-30 Hz aralığında filtrelenmesiyle oluşan modeller Şekil

3.3 (b)'deki gibidir. Modeller C3 elektrotundan kaydedilen verilerin Çekirdek 2 ile yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.11 ve ayırma değeri 0.55 alınmıştır.



Şekil 3.3. Sol el/dil ve sağ el/ayaklar MHH için örnek öğrenme modelleri

3.2.3. Deneysel Sonuçlar ve Analizler

Geniş bir problem domainine sahip Data Set IIa veri seti sol elin, sağ elin, her iki ayağın ve dilin hareket ettirilmesinin hayali şeklinde 4 MHH görevi içerir. Çalışmada bu görevlerin bire karşı bir stratejisiyle ikili sınıflandırılmasına odaklanılmış ve 6 problemde çalışılmıştır. Bunlar; (1) sol/sağ el, (2) sol el/ayaklar, (3) sol el/dil, (4) sağ el/ayaklar, (5) sağ

el/dil ve (6) ayaklar/dil görevlerinin sınıflandırılması şeklindedir. Deneylerin performansları 9 deneğin her biri için 15 koşumun ortalamaları ve standart sapmaları ('n-1' yöntemiyle hesaplanan) alınarak hesaplanmıştır. Ayrıca, denekler boyunca ortalama ve standart sapmalar da hesaplanmıştır. Çalışmalarda veri setinin tanımındaki eğitim ve test kümeleri kullanılmıştır. Eğitim ve test kümelerinde örtüşen hiçbir eleman yoktur. Bu işlem literatürle kıyaslamaların geçerliliği için önemlidir. Her denek ve sınıflandırma problemi için, önerilen yöntemlerinin optimum sınıflandırma parametreleri eğitim kümesinden elde edilen alt eğitim ve doğrulama kümeleri ile belirlenmiştir. Test kümesindeki hiçbir örnek eğitim için kullanılmamıştır. Bu bilgiler ışığında, yukarıda verilen 6 ikili problem için aşağıda başlıklar halinde verilen 9 yaklaşımla sonuçlar alınmıştır. Çalışmanın performansı sol/sağ el görevleri için doğruluk ve Cohen'in kappa ölçütleriyle sunulmuştur. Ayrıca, performans değerlerinin denekler boyunca ortalamaları ve standart sapmaları en sağdaki sütunlarda verilmiştir. Tablolarda denekler boyunca ortalaması en yüksek 10 yaklaşımın sonuçları verilmiştir. Y1'de her bir zaman dilimi için beş sınıflandırıcının en iyilerinin performansları verilmiştir. Y4 ve Y5 için her bir zaman dilimindeki 3'lü kombinasyonlardan elde edilen 10 sınıflandırıcının en iyilerinin performansları sunulmuştur. Benzer şekilde, Y6 ve Y7 için her bir frekans bandının 3'lü kombinasyonlarından elde edilen 5 sınıflandırıcının en iyilerinin performansları verilmiştir. Bazı yaklaşımlardan elde edilen sonuçların yalnızca en iyilerini gösterecek şekilde verilmesinin nedeni sınıflandırıcıların bir kısmının MHH görevleri veya deneklerde kendi başlarına kıyaslanabilir sonuçlar üretmemesidir. Her bir tekil sınıflandırıcı için sonuçların sunulduğu Y2, Y3, Y8 ve Y9 yaklaşımları için bu durum geçerli değildir.

1. Yaklaşım 1 (Y1) ile tekil sınıflandırma
2. Yaklaşım 2 (Y2) ile aynı zaman diliminde geleneksel çoğunluk oylama
3. Yaklaşım 3 (Y3) ile aynı zaman diliminde geleneksel yumuşak oylama
4. Yaklaşım 4 (Y4) ile aynı zaman diliminde kombinasyonel çoğunluk oylama
5. Yaklaşım 5 (Y5) ile aynı zaman diliminde kombinasyonel yumuşak oylama
6. Yaklaşım 6 (Y6) ile aynı frekans bandında çoğunluk oylama
7. Yaklaşım 7 (Y7) ile aynı frekans bandında yumuşak oylama
8. Yaklaşım 8 (Y8) ile tüm zaman dilimleri ve frekans bantlarında çoğunluk oylama
9. Yaklaşım 9 (Y9) ile tüm zaman dilimleri ve frekans bantlarında yumuşak oylama

3.2.3.1. Sol/Sağ El MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01-A09 denekleri için Y8 ile sırasıyla %86.9±2.81, %84.6±3.35, %89.0±2.24, %88.9±2.51, %88.9±2.66, %91.4±2.39, %90.1±2.74, %87.4±1.88 ve %94.0±0.97 doğruluklarında elde edilmiştir. Denekler boyunca ortalama en iyi sonuç yine Y8 yaklaşımıyla %89.0±2.70 oranında elde edilmiştir. Ayrıca, Y2 ile tüm zaman dilimlerinde denek havuzunda ortalama %80'den fazla başarı gözlenmiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütüyle en iyi sonuçlar A01-A09 için Y8 ile sırasıyla 0.74±0.06, 0.69±0.07, 0.78±0.04, 0.78±0.05, 0.78±0.05, 0.83±0.05, 0.80±0.05, 0.75±0.04 ve 0.88±0.02 değerlerinde elde edilmiştir. Denekler boyunca en iyi ortalama ve standart sapma Y8 ile 0.78±0.05 olarak gözlenmiştir. Y2 ile tüm zaman dilimlerinde 0.6 üzeri sonuçlar alınmıştır. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Yaklaşımların hiçbiri önemsiz ve şans ederi sınıflandırmayı ifade eden sonuçlar üretmemiştir. Koşullar boyunca deneklerde ve denekler boyunca ortalamadaki standart sapmalar oldukça kabul edilebilir seviyededir (Tablo 3.2).

Tablo 3.2. Sol/sağ el MHH için sınıflandırma doğrulukları ve kappa değerleri

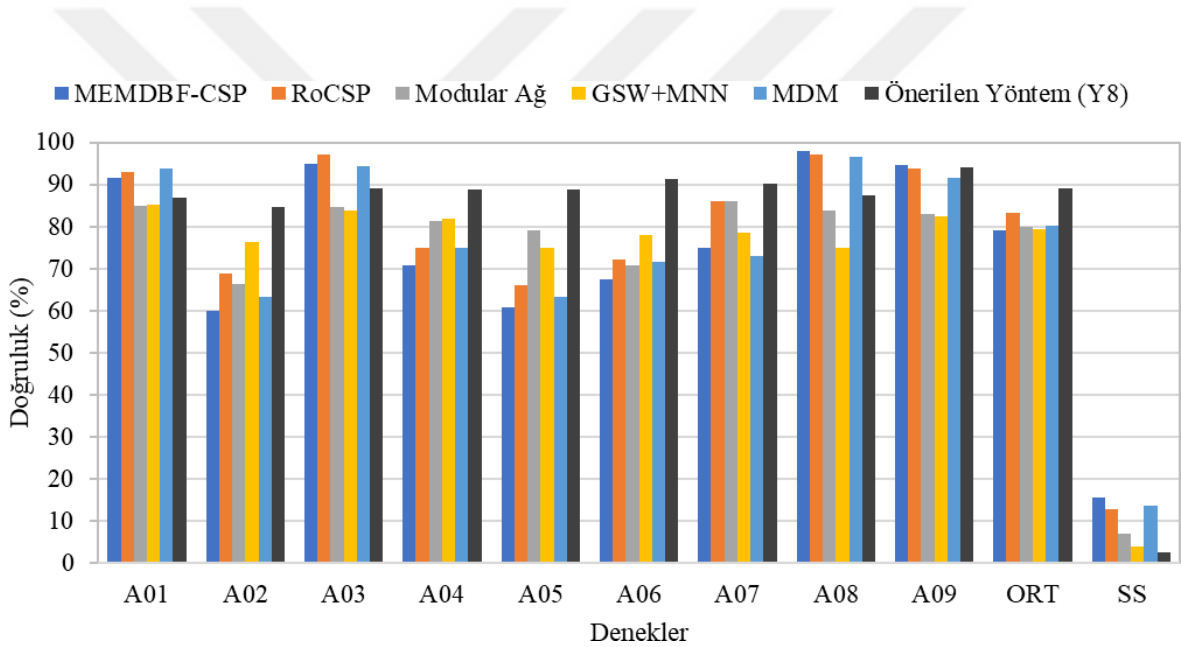
Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT
Y2 ve ZD ₁	76.9±3.01 0.54±0.06	74.8±3.24 0.50±0.06	81.2±2.87 0.62±0.06	78.3±2.68 0.57±0.05	76.6±3.13 0.53±0.06	84.8±2.24 0.70±0.04	78.5±2.30 0.57±0.05	79.8±3.05 0.59±0.06	91.8±0.76 0.84±0.02	80.3±5.20 0.61±0.10
Y2 ve ZD ₂	76.9±2.66 0.54±0.05	76.8±3.03 0.54±0.06	79.4±2.38 0.59±0.05	78.0±2.50 0.56±0.05	76.7±2.64 0.54±0.05	81.7±1.93 0.63±0.04	76.7±2.25 0.53±0.04	81.5±1.81 0.63±0.04	93.0±0.79 0.86±0.02	80.1±5.26 0.60±0.10
Y2 ve ZD ₃	80.0±2.79 0.60±0.06	75.8±1.86 0.52±0.04	83.3±2.36 0.67±0.05	79.2±2.03 0.58±0.04	75.3±1.68 0.51±0.03	80.9±3.04 0.62±0.06	78.3±2.91 0.57±0.06	80.0±2.11 0.60±0.04	90.2±1.66 0.80±0.03	80.3±4.45 0.61±0.09
Y4 ve ZD ₁	75.3±2.29 0.51±0.05	72.6±2.06 0.45±0.04	79.0±1.75 0.58±0.04	74.1±2.43 0.48±0.05	72.9±3.10 0.46±0.06	80.0±1.60 0.60±0.03	75.4±3.19 0.51±0.06	78.7±1.40 0.57±0.03	92.5±0.79 0.85±0.02	77.8±6.12 0.56±0.12
Y4 ve ZD ₂	73.4±1.95 0.47±0.04	73.4±3.39 0.47±0.07	77.8±2.34 0.56±0.05	74.5±2.32 0.49±0.05	74.9±2.42 0.50±0.05	76.9±2.99 0.54±0.06	73.7±1.66 0.47±0.03	81.4±2.29 0.63±0.05	93.4±1.00 0.87±0.02	77.7±6.45 0.55±0.13
Y4 ve ZD ₃	75.9±1.99 0.52±0.04	73.3±1.47 0.47±0.03	82.3±1.50 0.65±0.03	78.0±1.95 0.56±0.04	73.0±2.20 0.46±0.04	77.7±3.01 0.55±0.06	75.2±1.84 0.50±0.04	79.2±2.31 0.58±0.05	90.4±1.51 0.81±0.03	78.3±5.38 0.57±0.11
Y6 ve FB ₁	74.9±3.24 0.50±0.06	70.5±2.24 0.41±0.04	78.9±3.04 0.58±0.06	72.4±2.66 0.45±0.05	70.6±2.25 0.41±0.04	76.3±2.59 0.53±0.05	69.9±2.49 0.40±0.05	81.2±1.80 0.63±0.04	85.0±1.33 0.70±0.03	75.5±5.32 0.51±0.11
Y6 ve FB ₂	72.2±2.45 0.44±0.05	71.4±2.36 0.43±0.05	72.7±2.29 0.45±0.05	72.6±1.91 0.45±0.04	69.7±1.99 0.40±0.04	78.0±2.23 0.56±0.04	76.0±2.59 0.52±0.05	74.5±1.83 0.49±0.04	92.0±0.86 0.84±0.02	75.5±6.68 0.51±0.13
Y6 ve FB ₅	72.0±2.92 0.44±0.06	69.3±2.70 0.39±0.05	75.3±2.09 0.51±0.04	73.9±2.66 0.48±0.05	74.3±3.50 0.49±0.07	75.7±1.58 0.51±0.03	73.4±2.33 0.47±0.05	76.0±2.05 0.52±0.04	91.9±1.51 0.84±0.03	75.8±6.40 0.52±0.13
Y8	86.9±2.81 0.74±0.06	84.6±3.35 0.69±0.07	89.0±2.24 0.78±0.04	88.9±2.51 0.78±0.05	88.9±2.66 0.78±0.05	91.4±2.39 0.83±0.05	90.1±2.74 0.80±0.05	87.4±1.88 0.75±0.04	94.0±0.97 0.88±0.02	89.0±2.70 0.78±0.05

Tablo 3.3. Sol/sağ el MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem		A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS
[142]	MEMDBF-OUÖ+DVM	91.49	59.86	94.89	70.69	60.74	67.59	75.00	97.96	94.62	79.18	15.49
	MEMDBF-OUÖ+DAA	90.78	57.75	97.08	70.69	61.48	70.37	72.14	97.76	94.62	79.19	15.85
	Ham EEG+DAA	69.44	50.00	90.28	59.03	50.00	54.86	65.28	97.92	91.67	69.83	18.12
[42]	DLCSPauto	88.89	51.39	96.53	70.14	56.94	71.53	81.94	93.75	93.75	78.32	16.69
	TRCSP	88.89	54.17	96.53	70.83	62.50	67.36	81.25	95.87	91.67	78.79	15.60
	WTRCSP	88.89	54.86	96.53	70.14	65.97	61.81	81.25	95.83	90.97	78.47	15.66
	SRCSP	88.89	63.19	96.53	66.67	63.19	63.89	78.47	95.83	92.36	78.78	14.78
[143]	RoCSP-SRIT2NFIS	93.06	68.75	97.22	75.00	65.97	72.22	86.11	97.22	93.75	83.26	12.76
	OUÖ-SRIT2NFIS	91.67	63.89	97.22	72.92	63.89	72.22	82.64	96.53	93.75	81.63	13.72
	RoCSP-DAA	90.27	56.25	96.53	71.52	57.63	71.53	81.94	95.83	93.75	79.47	15.92
[105]	Modular Ağ	84.91	66.38	84.74	81.36	79.22	70.67	86.12	83.81	83.04	80.03	6.92
	Monolithic Ağ	83.13	65.45	80.29	81.60	76.70	71.12	84.00	82.66	80.74	78.41	6.27
[144]	KPCA (CILK)	88.89	59.03	90.28	78.47	62.50	75.00	72.92	93.06	87.50	78.63	12.34
	LLE	60.42	47.92	84.03	64.58	54.86	59.03	53.47	84.72	76.39	65.00	13.53
	OUÖ+DAA	88.89	51.39	96.53	70.14	54.86	71.53	81.25	93.75	93.75	78.01	17.01
[147]	TLCSD-1	90.28	57.64	93.06	65.28	59.72	65.28	59.72	90.28	85.42	74.07	15.21
	TLCSD-2	90.28	57.64	95.14	65.97	61.11	65.28	61.11	91.67	86.11	74.92	15.43
	UB	90.28	58.33	97.22	67.36	59.03	65.97	70.83	90.97	90.28	76.70	15.33
[150]	WOLA-CSP	86.81	63.89	94.44	68.75	56.25	69.44	78.47	97.91	93.75	78.86	15.07
	FBCSP-4	87.50	57.63	88.88	61.80	77.08	61.11	85.41	92.36	86.11	77.54	13.68
[148]	Active Scheme C-2	88.89	59.03	96.53	68.06	73.61	66.67	80.56	89.58	88.89	79.09	12.83
	Active Scheme C-3	91.67	63.89	94.44	70.80	77.78	73.61	72.92	93.75	88.89	80.86	11.44
	Passive Scheme C-3	91.67	63.89	94.44	72.22	77.08	75.69	73.61	94.44	90.28	81.48	11.33
[146]	Pearson Korelasyonu	74.00	63.00	85.00	67.00	59.00	63.00	54.00	88.00	75.00	69.78	11.58
	Spearman Korelasyonu	76.00	56.00	84.00	60.00	54.00	63.00	47.00	90.00	78.00	67.56	14.88
	STR	83.00	50.00	94.00	62.00	57.00	63.00	54.00	88.00	75.00	69.56	15.93
[163]	GSW+MNN	85.11	76.27	83.72	81.85	74.87	78.13	78.60	74.87	82.32	79.53	3.85
	MDM	93.75	63.19	94.44	75.00	63.19	71.53	72.92	96.53	91.67	80.25	13.78
	OUÖ+DAA	93.06	50.69	96.53	70.14	59.03	68.06	79.86	93.75	92.36	78.16	16.93
[164]	CSD2	93.06	68.06	93.06	77.08	72.22	65.97	78.47	97.22	90.28	81.71	11.87
	SS _F	91.67	59.03	90.28	77.08	65.97	64.58	64.58	95.83	86.81	77.31	14.12
Önerilen Yönt.	Y8	86.9	84.6	89.0	88.9	88.9	91.4	90.1	87.4	94.0	89.00	2.70

Aynı veri kümelerinde yürütülmüş çalışmalarla doğruluk ve kapa ölçütleriyle kıyaslama yapılmıştır. Çünkü önceki çalışmalarda sıklıkla bu ölçütler kullanılmıştır. Doğruluk için karşılaştırmalar sırasıyla Gaur vd. (2019) [142], Lotte vd. (2011) [42], Das vd. (2016) [143], Olivas vd. (2019) [105], Sadatnejad vd. (2016) [144], Raza vd. (2016) [147], Belwafi vd. (2018) [150], Raza vd. (2019) [148], Rodrigues vd. (2019) [146],

Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] çalışmalarıyla yapılmıştır. Y8 ile tüm denekler boyunca ortalama başarı %83.26'dan %89.00'a (%5.74 oranında) yükseltirken standart sapma %12.76'dan %2.70'e (%10.06 oranında) düşürülmüştür. Bu başarıyı A02 (%76.27'den %84.60'a %8.33), A04 (%81.85'ten %88.90'a %7.05), A05 (%79.22'den %88.90'a %9.68), A06 (%78.13'ten %91.40'a %13.27) ve A07 (%86.12'den %90.10'a %3.98) deneklerindeki performans iyileştirmeleri kaynaklıdır. Diğer taraftan, [142, 143, 163]'e ait MEMDBF-OUÖ+DVM, RoCSP-SRIT2NFIS, OUÖ-SRIT2NFIS, UB ve MDM yöntemleri A01, A03, A08 ve A09 için sırasıyla %6.85, %8.22, %10.56 ve %0.62 oranlarında daha başarılı sonuçlar göstermiştir (**Tablo 3.3**).



Şekil 3.4. Sol/sağ el MHH için literatüre göre doğruluk kıyaslamaları

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.4'te verilmiştir. Başarılı sonuçların çoğu tüm frekans bantları ve zaman dilimlerinde üretilen sınıflandırıcıların çoğunluk oylamasıyla elde edilmiştir. Bu yaklaşım, sınıflandırma başarısı düşük deneklerin performansını yukarı çekerek denekler boyunca standart sapmayı düşürmüştür, denekten-deneğe daha dayanıklı bir sınıflandırıcı oluşturmuştur. A02, A04, A05 ve A06 için doğruluk artışı oldukça önemli seviyededir, A07 için biraz daha düşüktür. Özellikle, A06 denegindeki %13.27 oranındaki doğruluk artımı önemli seviyededir. Literatür çalışmaları %47.00-%97.96 aralığında sonuçlar elde etmiştir. Önerilen yöntemlerle literatüre kıyasla en

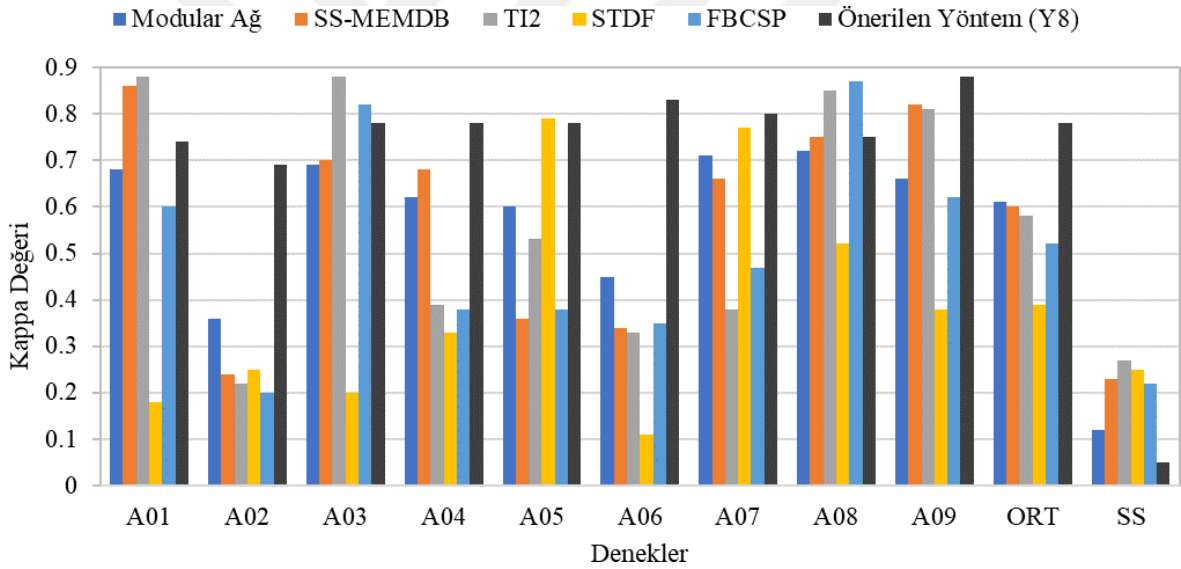
düşükten en yükseğe 2 kata kadar iyileşme sağlanmıştır. Denekler boyunca ortalama doğruluğun %5.74 oranında arttırılması çok önemlidir. Standart sapmasının %10.06 oranında düşürülmesi ise denekten-deneğe kuvvetli bir sınıflandırma için oldukça önemlidir. Çünkü, sınıflandırıcıların farklı deneklerde bile belirli seviyenin üstünde başarı göstermesi gerekir. A09 için literatürle yaklaşık aynı sonuçlar alınmıştır, ancak A01, A03 ve A08 için iyileştirmeler yapılmalıdır. Böylelikle, denekler boyunca performans daha yukarı çekilebilir.

Kappa ölçütüyle kıyaslamalar sırasıyla Olivas vd. (2019) [105], Gaur vd. (2018) [151], Raza vd. (2016) [165], Luo vd. (2020) [166], Luo vd. (2019) [167] ve Gandhi vd. (2014) [168] çalışmalarıyla yapılmıştır. Y8 ile denekler boyunca ortalama kappa 0.61'den 0.78'e yükseltirken standart sapma 0.12'den 0.05'e düşürülmüştür. Bu değerler denek havuzunda yüksek başarıda ve tesadüfi olmayan sınıflandırma anlamına gelir. Ortalamanın bu düzeyde olması Y8 ile A02 (0.37'den 0.69'a 0.32), A04 (0.68'den 0.78'e 0.1), A06 (0.45'ten 0.83'e 0.38), A07 (0.77'den 0.80'e 0.03) ve A09 (0.82'den 0.88'e 0.06) deneklerindeki iyileştirmeler kaynaklıdır. Diğer taraftan, [165, 166, 167] çalışmalarına ait TI_1 , TI_2 , ESVL, STDF ve FBCSP yöntemleri A01, A03, A05 ve A08 için sırasıyla 0.14, 0.10, 0.01 ve 0.12 değerlerinde daha başarılı sonuçlar göstermiştir (Tablo 3.4).

Tablo 3.4. Sol/sağ el MHH için kappa değerleri kıyaslamaları

Çalışma Yöntem	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS	
[105]	Modular Ağ	0.68	0.36	0.69	0.62	0.60	0.45	0.71	0.72	0.66	0.61	0.12
	Monolithic Ağ	0.67	0.35	0.65	0.62	0.58	0.45	0.69	0.70	0.64	0.59	0.11
[151]	SS-MEMDB	0.86	0.24	0.70	0.68	0.36	0.34	0.66	0.75	0.82	0.60	0.23
[165]	TI_1	0.88	0.22	0.76	0.39	0.43	0.33	0.38	0.85	0.81	0.56	0.26
	TI_2	0.88	0.22	0.88	0.39	0.53	0.33	0.38	0.85	0.81	0.58	0.27
	OUÖ	0.56	0.31	0.70	0.44	0.22	0.20	0.61	0.76	0.72	0.50	0.22
	FBCSP (DC)	0.71	0.37	0.66	0.47	0.41	0.26	0.73	0.58	0.50	0.52	0.16
[166]	ESVL	0.63	0.17	0.88	0.38	0.69	0.41	0.76	0.76	0.69	0.60	0.23
	CDFCSP	0.60	0.18	0.87	0.34	0.47	0.37	0.50	0.78	0.69	0.53	0.22
	STDF	0.18	0.25	0.20	0.33	0.79	0.11	0.77	0.52	0.38	0.39	0.25
[167]	FBCSP	0.60	0.20	0.82	0.38	0.38	0.35	0.47	0.87	0.62	0.52	0.22
	CDFCSP (R)	0.60	0.20	0.87	0.40	0.47	0.37	0.50	0.76	0.66	0.54	0.21
	CDFCSP (N)	0.62	0.20	0.87	0.40	0.47	0.37	0.50	0.78	0.66	0.54	0.21
[168]	RQNN	0.22	0.22	0.58	0.21	0.43	0.22	0.17	0.35	0.58	0.33	0.16
	RAW	0.22	0.15	0.56	0.13	0.33	0.22	0.13	0.33	0.50	0.29	0.16
Önerilen Yönt.	Y8	0.74	0.69	0.78	0.78	0.78	0.83	0.80	0.75	0.88	0.78	0.05

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.5'te verilmiştir. Kappa değerindeki iyileştirmelerin çoğu doğrulukla orantılıdır ancak doğruluğa göre daha yüksek orandadır. Kappa değerlerinde de daha düşük sonuçlar gözlenen önceki çalışmalara kıyasla birçok deneğin performansında iyileşmeler elde edilmiştir. Özellikle A02 ve A06 için 0.32 ve 0.38 değerlerindeki iyileştirmeler oldukça önemli seviyededir. Performans kazanımı A04, A07 ve A09 için daha düşük orandadır. Ayrıca, denekler boyunca ortalama çok önemli seviyede yukarı çekilmiş ve standart sapma oldukça iyi derecede düşürülmüştür. Böylelikle, denekten-deneğe daha dayanıklı bir sınıflandırıcı oluşturmuştur. A05 deneği için literatürle yaklaşık aynı sonuçlar alınmıştır, ancak A01, A03 ve A08 için iyileştirmeler yapılmalıdır. Böylelikle, denekler boyunca performans daha yukarı çekilebilir.



Şekil 3.5. Sol/sağ el MHH için literatüre göre kappa kıyaslamaları

3.2.3.2. Sol El/Ayaklar MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01 ve A03 denekleri için Y6 ve FB₁ ile sırasıyla %87.2±0.89 ve %87.6±1.36; A02 ve A04-A08 için Y8 ile sırasıyla %85.7±2.67, %87.9±2.51, %85.3±2.96, %84.0±2.43, %82.5±1.68 ve %87.7±3.19; A09 için ise Y4 ve ZD₂ ile %95.4±0.93 doğruluklarında gözlenmiştir. Denekler boyunca ortalama en iyi sonuç %86.2±3.73 oranında Y8 yaklaşımıyla elde edilmiştir. Ayrıca, Y2 ile iki zaman diliminde ve Y4 ile bir zaman diliminde deneyler boyunca ortalamada %80'den fazla doğruluk ve %5.44-%6.94 aralığında

standart sapma gözlenmiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütüyle en iyi sonuçlar Y6 ve FB₁, Y8, Y4 ve ZD₂ yaklaşımlarıyla A01-A09 denekleri için sırasıyla 0.74±0.02, 0.71±0.05, 0.75±0.03, 0.76±0.05, 0.71±0.06, 0.68±0.05, 0.65±0.03, 0.76±0.06 0.91±0.02 değerlerindedir. Denekler boyunca en iyi ortalama ve standart sapma Y8 ile 0.72±0.07 olarak elde edilmiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar gözlenmiştir (Tablo 3.5).

Tablo 3.5. Sol el/ayaklar MHH için sınıflandırma doğrulukları ve kappa değerleri

Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT±SS
Y1 ve	86.2±0.44	65.2±0.50	85.1±0.88	76.5±1.48	66.5±0.70	72.0±1.30	72.7±0.61	71.0±0.55	92.9±0.39	76.5±9.54
ZD ₂	0.72±0.01	0.30±0.01	0.70±0.02	0.53±0.03	0.33±0.01	0.44±0.03	0.45±0.01	0.42±0.01	0.86±0.01	0.53±0.19
Y2 ve	79.7±3.02	75.0±2.61	78.4±2.44	81.6±1.65	75.6±2.25	80.1±1.99	77.1±1.94	77.6±3.60	92.9±1.16	79.8±5.36
ZD ₁	0.60±0.06	0.50±0.05	0.57±0.05	0.63±0.03	0.51±0.05	0.60±0.04	0.54±0.04	0.55±0.07	0.86±0.02	0.60±0.11
Y2 ve	77.8±2.62	75.1±2.43	81.7±2.55	82.7±2.26	75.9±2.23	76.6±2.58	79.0±3.41	81.3±1.85	94.6±0.90	80.5±5.94
ZD ₂	0.56±0.05	0.50±0.05	0.63±0.05	0.65±0.05	0.52±0.05	0.53±0.05	0.58±0.07	0.63±0.04	0.89±0.02	0.61±0.12
Y2 ve	83.9±2.19	76.0±2.04	78.8±1.34	81.0±2.54	75.2±1.90	79.4±2.72	76.6±2.34	77.2±2.44	92.7±0.94	80.1±5.44
ZD ₃	0.68±0.04	0.52±0.04	0.58±0.03	0.62±0.05	0.50±0.04	0.59±0.05	0.53±0.05	0.55±0.05	0.85±0.02	0.60±0.11
Y4 ve	81.1±2.34	72.9±2.51	79.6±2.47	81.0±1.86	73.1±1.62	77.8±2.33	76.6±1.56	73.6±3.05	93.9±0.89	78.8±6.52
ZD ₁	0.62±0.05	0.46±0.05	0.59±0.05	0.62±0.04	0.46±0.03	0.56±0.05	0.53±0.03	0.47±0.06	0.88±0.02	0.58±0.13
Y4 ve	80.0±3.17	72.2±2.15	84.7±2.40	81.9±1.56	74.3±1.76	75.6±2.73	78.1±2.67	77.7±2.50	95.4±0.93	80.0±6.94
ZD ₂	0.60±0.06	0.44±0.04	0.69±0.05	0.64±0.03	0.48±0.04	0.51±0.05	0.56±0.05	0.56±0.05	0.91±0.02	0.60±0.14
Y4 ve	84.0±1.04	73.2±3.03	79.3±2.38	81.4±1.52	73.0±2.18	78.2±2.31	76.5±2.14	76.2±2.75	92.7±1.58	79.4±6.15
ZD ₃	0.68±0.02	0.46±0.06	0.59±0.05	0.63±0.03	0.46±0.04	0.56±0.05	0.53±0.04	0.53±0.05	0.85±0.03	0.59±0.12
Y6 ve	87.2±0.89	72.0±2.43	87.6±1.36	79.5±1.44	73.0±1.99	73.8±3.15	69.2±2.67	73.0±1.48	90.1±1.00	78.4±7.94
FB ₁	0.74±0.02	0.44±0.05	0.75±0.03	0.59±0.03	0.46±0.04	0.48±0.06	0.38±0.05	0.46±0.03	0.80±0.02	0.57±0.16
Y6 ve	74.7±2.02	71.9±2.21	75.1±1.89	80.7±3.16	70.8±2.52	74.4±1.69	75.5±1.04	73.9±2.37	93.5±0.78	76.7±6.89
FB ₂	0.50±0.04	0.44±0.04	0.50±0.04	0.61±0.06	0.41±0.05	0.49±0.03	0.51±0.02	0.48±0.05	0.87±0.02	0.53±0.14
Y8	84.3±2.13	85.7±2.67	83.2±1.91	87.9±2.51	85.3±2.96	84.0±2.43	82.5±1.68	87.7±3.19	94.8±0.56	86.2±3.73
	0.69±0.04	0.71±0.05	0.66±0.04	0.76±0.05	0.71±0.06	0.68±0.05	0.65±0.03	0.76±0.06	0.90±0.01	0.72±0.07


Sonuçlar önceki çalışmalarla doğruluk ölçütü kullanılarak kıyaslanmıştır. Çünkü önceki çalışmalarda bu ölçüt kullanılırken kappa değeri kullanılmamıştır (Tablo 3.6). Karşılaştırmalar Das vd. (2016) [143], Gaur vd. (2018) [151], Sadatnejad vd. (2016) [144], Rodrigues vd. (2019) [146], Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] çalışmalarıyla yapılmıştır. Y8 ile A05 (%79.53'ten %85.31'e %1.05) ve A06 (83.25'ten 84.05'e %3.67) deneklerinde doğruluk artırılmıştır. Diğer yandan, [143, 144, 151] çalışmalarına ait OUÖ, RoCSP, SS-MEMDB ve KPCA (CILK) teknikleri A01-A04 ve A07-A09 için sırasıyla %11.74, %1.1, %8.93, %3.62, %16.12, %3.97 ve %2.5 oranlarında daha

iyi sonuçlar üretmiştir. Ayrıca, RoCSP tüm denekler boyunca ortalama %2.74 daha iyi sonuç göstermiştir. Ancak, bu yöntemin standart sapması Y8'e kıyasla %7.32 daha yüksektir.

Tablo 3.6. Sol el/ayaklar MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS	
[143]	OUÖ	97.92	69.44	93.06	75.69	61.11	56.94	98.61	86.81	95.14	81.64	16.23
	RoCSP	99.31	83.33	95.83	90.28	70.83	72.22	98.61	91.67	97.92	88.89	11.05
[151]	SS-MEMDB	97.14	78.57	91.11	91.53	68.31	69.16	92.25	88.89	92.54	85.50	10.73
[144]	KPCA (CILK)	97.92	86.81	96.53	81.94	70.14	75.69	88.89	85.42	97.22	86.73	9.73
	OUÖ+DAA	98.61	68.75	94.44	78.47	63.19	59.03	97.92	87.50	95.14	82.56	15.63
[146]	STR	93.00	57.00	88.00	73.00	60.00	61.00	56.00	76.00	81.00	71.67	13.87
[163]	GSW+MNN	93.95	72.55	86.51	87.90	79.53	83.25	83.25	82.78	79.06	83.20	6.05
	MDM	96.53	78.47	89.58	88.89	73.61	71.53	91.67	85.42	93.06	85.42	8.88
	OUÖ+DAA	98.61	68.75	94.44	78.47	63.19	59.03	97.92	87.50	95.14	82.56	15.63
[164]	CSD2	97.92	81.94	90.28	87.50	68.06	70.83	88.89	77.08	91.67	83.80	10.05
	SS _R	87.50	75.00	94.44	75.00	65.97	65.97	84.03	87.50	86.81	80.25	10.17
Önerilen Yönt.	Y4 ve ZD ₂	80.00	72.19	84.69	81.86	74.27	75.58	78.12	77.73	95.42	79.99	6.94
	Y6 ve FB ₁	87.24	72.00	87.60	79.49	73.00	73.77	69.25	73.04	90.10	78.39	7.94
	Y8	84.29	85.71	83.16	87.91	85.31	84.05	82.49	87.70	94.78	86.15	3.73

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.6'da verilmiştir. A05 ve A06 deneklerinde performans artışı gözlenirken, özellikle A01, A03 ve A07 için önceki çalışmalar kayda değer oranlarda daha başarılı sonuçlar göstermiştir. Bu deneklerde başarının artırılması için iyileştirmeler yapılmalıdır. Böylelikle denekler boyunca performans daha yukarı çekilebilecektir. Diğer deneklerdeki sonuçlar benzer orandadır. Önerilen yöntemlerin en önemli katkısı ortalama doğrulukta çok az oranda daha düşük doğruluk elde etmesine rağmen denek havuzundaki standart sapmayı %7.32 oranında oldukça iyi derecede düşürmesidir. Çünkü denekten-deneğe daha kararlı sistemler için standart sapma dikkate alınmalıdır.



Şekil 3.6. Sol el/ayaklar MHH için literatüre göre doğruluk kıyaslamaları

3.2.3.3. Sol El/Dil MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01, A03 ve A08 denekleri için Y6 ve FB₁ ile sırasıyla %86.3±1.27, %91.0±0.85 ve %87.6±1.46; A02 ve A04-A07 için sırasıyla Y8 ile %83.8±2.47, %80.6±1.77, %82.3±3.33, %88.8±2.49 ve %86.3±1.85; A09 için ise Y6 ve FB₂ ile %99.4±0.46 doğruluklarında gözlenmiştir. Denek havuzunda ortalama en iyi sonuç %86.3±5.61 oranında Y8 yaklaşımıyla elde edilmiştir. Ayrıca, Y2 ve Y4 yaklaşımları tüm zaman dilimlerinde, Y6 ise ilk iki frekans bandında denek havuzunda ortalama %80 üstü doğruluk göstermiştir. Bu yöntemlerin standart sapması %7.14-%10.2 aralığındadır. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütü ile en başarılı sonuçlar Y6 ve FB₁, Y6 ve FB₂, Y8 yaklaşımlarıyla A01-A09 denekleri için sırasıyla 0.73±0.03, 0.68±0.05, 0.82±0.02, 0.61±0.04, 0.65±0.07, 0.78±0.05, 0.73±0.04, 0.75±0.03 ve 0.99±0.01 değerlerindedir. Denekler boyunca en iyi ortalama ve standart sapma Y8 ile 0.73±0.11 olarak elde edilmiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar gözlenmiştir (Tablo 3.7).

Tablo 3.7. Sol el/dil MHH için sınıflandırma doğrulukları ve kappa değerleri


Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT±SS
Y2 ve ZD ₁	82.2±2.38 0.64±0.05	72.7±2.43 0.45±0.05	85.4±1.41 0.71±0.03	77.6±2.43 0.55±0.05	72.3±2.98 0.45±0.06	78.8±2.11 0.58±0.04	81.3±0.99 0.63±0.02	84.2±1.46 0.68±0.03	99.0±0.61 0.98±0.01	81.5±8.02 0.63±0.16
Y2 ve ZD ₂	80.6±1.72 0.61±0.03	71.9±2.65 0.44±0.05	83.9±1.66 0.68±0.03	78.2±1.81 0.56±0.04	71.1±2.42 0.42±0.05	79.9±2.56 0.60±0.05	80.3±1.57 0.61±0.03	85.4±1.12 0.71±0.02	99.1±0.27 0.98±0.01	81.1±8.27 0.62±0.17
Y2 ve ZD ₃	82.1±3.26 0.64±0.07	72.7±2.82 0.45±0.06	85.5±1.65 0.71±0.03	78.2±2.54 0.56±0.05	71.4±1.75 0.43±0.03	77.7±2.38 0.55±0.05	83.1±1.53 0.66±0.03	84.5±2.30 0.69±0.05	98.3±0.52 0.97±0.01	81.5±8.04 0.63±0.16
Y4 ve ZD ₁	79.1±2.10 0.58±0.04	75.1±2.99 0.50±0.06	84.1±1.39 0.68±0.03	79.0±2.54 0.58±0.05	74.0±2.58 0.48±0.05	79.7±1.78 0.59±0.04	82.2±1.55 0.65±0.03	81.7±2.37 0.63±0.05	98.5±0.61 0.97±0.01	81.5±7.16 0.63±0.14
Y4 ve ZD ₂	77.2±2.78 0.54±0.06	74.8±2.90 0.50±0.06	83.2±1.65 0.66±0.03	79.7±2.01 0.59±0.04	72.3±2.62 0.45±0.05	82.8±2.53 0.66±0.05	82.2±1.45 0.64±0.03	83.2±2.07 0.67±0.04	99.2±0.00 0.98±0.00	81.6±7.69 0.63±0.15
Y4 ve ZD ₃	79.2±2.26 0.58±0.05	75.7±3.72 0.51±0.07	83.6±1.98 0.67±0.04	78.2±2.41 0.56±0.05	74.8±1.55 0.50±0.03	80.2±2.42 0.60±0.05	83.0±1.88 0.66±0.04	84.8±1.56 0.70±0.03	98.7±0.54 0.97±0.01	82.0±7.14 0.64±0.14
Y5 ve ZD ₁	79.8±4.08 0.60±0.08	65.8±2.35 0.32±0.05	88.1±2.64 0.76±0.05	75.1±1.34 0.50±0.03	66.0±2.92 0.32±0.06	72.4±2.40 0.45±0.05	78.3±1.16 0.57±0.02	85.0±1.67 0.70±0.03	97.6±0.87 0.95±0.02	78.7±10.4 0.57±0.21
Y6 ve FB ₁	86.3±1.27 0.73±0.03	69.9±2.45 0.40±0.05	91.0±0.85 0.82±0.02	75.6±1.81 0.51±0.04	72.8±1.59 0.46±0.03	74.8±2.46 0.50±0.05	71.2±2.40 0.43±0.05	87.6±1.46 0.75±0.03	98.7±0.68 0.97±0.01	80.9±10.2 0.62±0.20
Y6 ve FB ₂	77.1±1.97 0.54±0.04	73.8±2.11 0.48±0.04	80.3±0.88 0.61±0.02	78.3±1.90 0.56±0.04	69.0±2.50 0.38±0.05	78.7±2.17 0.57±0.04	83.2±1.61 0.67±0.03	81.7±1.16 0.64±0.02	99.4±0.46 0.99±0.01	80.2±8.38 0.60±0.17
Y8	81.6±2.85 0.63±0.06	83.8±2.47 0.68±0.05	86.4±1.70 0.73±0.03	80.6±1.77 0.61±0.04	82.3±3.33 0.65±0.07	88.8±2.49 0.78±0.05	86.3±1.85 0.73±0.04	87.4±2.15 0.75±0.04	99.2±0.00 0.98±0.00	86.3±5.61 0.73±0.11

Sonuçlar önceki çalışmalarla doğruluk ölçütü kullanılarak kıyaslanmıştır. Çünkü önceki çalışmalarda bu ölçüt kullanılırken kappa değeri kullanılmamıştır. Karşılaştırmalar Das vd. (2016) [143], Gaur vd. (2018) [151], Sadatnejad vd. (2016) [144], Rodrigues vd. (2019) [146], Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] çalışmalarıyla yapılmıştır. Y8 ile A02 (%78.60'tan %83.78'e %5.18), A05 (%78.47'den %82.30'e %3.83) ve A06 (%76.74'ten %88.81'e %12.07) deneklerinde doğruluk arttırılmıştır. Aynı şekilde, Y6 ve FB₂ ile A09 deneği için sınıflandırma doğruluğu %98.46'dan %99.44'e çıkarılmıştır. Diğer taraftan, [143] çalışmasına ait OUÖ ve RoCSP yöntemleri A01, A03, A04, A07 ve A08 deneklerinde sırasıyla %13.02, %5.57, %11.76, %10.94 ve %8.92 oranlarında daha iyi sonuçlar üretmiştir. RoCSP denekler boyunca ortalama %3.40 daha iyi sonuç göstermiştir. Ancak, bu yöntemin standart sapması Y8'e göre %5.10 daha yüksektir (Tablo 3.8).

Tablo 3.8. Sol el/dil MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem		A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS
[143]	OUÖ	96.53	67.36	94.44	90.28	69.44	71.53	97.22	90.28	95.14	85.80	12.54
	RoCSP	99.31	73.61	96.53	92.36	78.47	75.00	97.22	96.53	97.92	89.66	10.71
[151]	SS-MEMDB	98.59	67.13	88.89	87.50	71.94	73.58	89.05	83.58	98.46	84.30	11.30
[144]	KPCA (CILK)	96.53	71.53	93.75	85.42	77.78	75.00	87.50	88.89	97.92	86.04	9.50
	OUÖ+DAA	98.61	67.36	94.44	86.81	68.75	71.53	95.14	90.97	95.14	85.42	12.62
[146]	STR	91.00	53.00	90.00	75.00	61.00	53.00	62.00	77.00	78.00	71.11	14.54
[163]	GSW+MNN	92.09	78.60	90.69	86.97	77.20	76.74	87.44	88.37	83.72	84.65	5.86
	MDM	98.61	68.06	86.81	88.19	72.22	64.58	88.19	82.64	97.22	82.95	12.21
	OUÖ+DAA	98.61	67.36	94.44	86.81	68.75	71.53	95.14	90.97	95.14	85.42	12.62
[164]	CR	88.19	72.22	93.75	86.11	75.69	66.67	94.44	83.33	97.22	84.18	10.66
	GOR	92.36	68.75	91.67	88.89	75.00	66.67	90.28	79.86	95.14	83.18	10.85
	CSD2	93.06	72.22	93.75	87.50	77.08	70.83	90.28	84.03	97.92	85.19	9.81
	SSR	96.53	65.28	87.50	89.58	62.50	65.97	84.03	76.39	97.22	80.56	13.53
Önerilen Yönt.	Y6 ve FB ₁	86.29	69.93	90.96	75.60	72.81	74.84	71.19	87.61	98.67	80.88	10.22
	Y6 ve FB ₂	77.1	73.8	80.3	78.3	69.0	78.7	83.2	81.7	99.44	80.2	8.38
	Y8	81.60	83.78	86.37	80.60	82.30	88.81	86.28	87.41	99.23	86.26	5.61

En başarılı yöntemlerle kıyaslamalar Şekil 3.7’de verilmiştir. A02 ve A06’da gözlenen artış önemli seviyedeysen, A05 ve A09 için biraz daha düşüktür. Diğer denekler için önceki çalışmalar daha başarılıdır. Bu deneklerde doğrulukların artırılması için iyileştirmeler yapılmalıdır. Böylelikle denekler boyunca sistem performansı yukarı çekilebilir.



Şekil 3.7. Sol el/dil MHH için literatüre göre doğruluk kıyaslamaları

Önerilen yöntemin en önemli katkısı, ortalama doğrulukta çok az oranda düşük doğruluk göstermesine rağmen denek havuzundaki sapmayı %5.10 oranında düşürmesidir. Çünkü denekten-deneğe daha kararlı sistemler için standart sapma dikkate alınmalıdır.

3.2.3.4. Sağ El/Ayaklar MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01 ve A03 için sırasıyla Y6 ve FB₁ ile %95.8±0.81, %86.9±1.12; A02 ve A04-A09 için Y8 ile sırasıyla %86.2±2.30, %87.4±2.86, %85.9±3.43, %82.6±2.81, %84.4±3.03, %87.9±2.86 ve %81.8±2.16 doğruluklarında elde edilmiştir. Denek havuzunda en başarılı ortalama %84.9±2.19 oranında Y8'le gözlenmiştir. Y2 ve Y4 tüm zaman dilimlerinde, Y6 ise ilk iki frekans bandında denekler bazında ortalama %75 üstü doğruluk ve %2.94-%8.63 aralığında standart sapma göstermiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütüyle en başarılı sonuçlar, Y8 ve Y6 & FB₁ ile A01-A09 denekleri için sırasıyla 0.92±0.02, 0.72±0.05, 0.74±0.02, 0.75±0.06, 0.71±0.07, 0.65±0.06, 0.69±0.06, 0.76±0.06 ve 0.64±0.04 değerlerindedir. Denekler boyunca en iyi ortalama ve standart sapma Y8 için 0.70±0.04 değerindedir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir (Tablo 3.9).

Tablo 3.9. Sağ el/ayaklar MHH için sınıflandırma doğrulukları ve kappa değerleri


Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT±SS
Y2 ve ZD ₁	79.9+2.54	72.6+3.56	81.0+1.84	84.4+2.02	76.6+2.15	76.2+3.05	80.0+4.23	78.7+3.17	73.7+2.25	78.1+3.73
Y2 ve ZD ₂	83.4+2.03	75.2+1.98	79.4+1.73	82.1+2.26	74.7+2.77	76.8+1.86	80.5+2.48	78.1+2.93	78.8+3.98	78.8+2.94
Y2 ve ZD ₃	84.8+2.10	73.8+2.62	79.9+1.86	78.7+1.92	75.4+2.80	76.5+1.79	80.7+1.01	77.9+2.30	77.2+2.07	78.3+3.24
Y4 ve ZD ₁	85.1+1.62	70.7+1.95	83.4+1.91	82.4+2.08	72.9+2.02	73.1+2.58	80.2+5.64	74.5+1.85	74.6+2.55	77.4+5.33
Y4 ve ZD ₂	87.7+1.45	73.1+1.52	81.9+1.67	81.7+2.47	72.4+2.59	75.0+3.11	77.6+3.65	74.3+3.05	74.9+2.40	77.6+5.12
Y4 ve ZD ₃	87.8+1.28	71.9+2.32	81.5+1.59	77.6+2.53	72.1+1.90	73.8+2.70	79.1+1.34	74.9+2.19	76.0+1.67	77.2+5.09
Y6 ve FB ₁	95.8+0.81	70.1+5.55	86.9+1.12	79.7+2.72	71.2+2.15	74.4+2.91	73.1+2.27	71.1+2.26	75.1+2.69	77.5+8.63
Y6 ve FB ₂	80.9+1.21	70.1+2.72	76.2+1.51	80.3+2.17	73.5+2.44	73.3+1.90	75.6+3.49	71.7+1.44	75.0+1.78	75.2+3.62
Y8	85.2+1.69	86.2+2.30	82.6+1.70	87.4+2.86	85.9+3.43	82.6+2.81	84.4+3.03	87.9+2.86	81.8+2.16	84.9+2.19
	0.70+0.03	0.72+0.05	0.65+0.03	0.75+0.06	0.71+0.07	0.65+0.06	0.69+0.06	0.76+0.06	0.64+0.04	0.70+0.04

Sonuçlar, önceki çalışmalarla doğruluk ölçütü kullanılarak kıyaslanmıştır. Çünkü önceki çalışmalarda bu ölçüt kullanılırken kappa değeri kullanılmamıştır. Karşılaştırmalar Das vd. (2016) [143], Gaur vd. (2018) [151], Sadatnejad vd. (2016) [144], Rodrigues vd. (2019) [146], Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] ile yapılmıştır. Y8 ile A05 (%75.34'ten %85.89'a %10.06) ve A06 (%82.32'den %87.63'e %0.31) deneklerinde doğruluk arttırılmıştır. Diğer taraftan, [143, 151, 144, 163, 164] çalışmalarına ait RoCSP, SS-MEMDB, KPCA (CILK), OUÖ+DAA ve CSD2 teknikleri A01-A04, A07-A09 için sırasıyla %4.22, %4.73, %10.24, %6.34, %14.93, %4.09 ve %7.74 daha iyi sonuç göstermiştir. RoCSP tüm denekler boyunca ortalama %3.30 daha başarılıdır. Ancak, bu yöntemin standart sapması tez çalışmasında önerilen Y8 yaklaşımına kıyasla %8.34 oranında önemli derecede daha yüksektir (Tablo 3.10).

Tablo 3.10. Sağ el/ayaklar MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS	
[143]	OUÖ	99.31	79.86	91.67	88.19	64.58	63.19	99.31	88.88	81.94	84.10	13.23
	RoCSP	100.0	84.03	95.83	90.97	72.92	70.83	99.30	90.28	89.58	88.19	10.53
[151]	SS-MEMDB	98.56	80.71	97.10	92.24	67.88	66.97	93.57	91.97	79.85	85.43	12.07
[144]	KPCA (CILK)	98.61	90.97	90.97	84.03	67.36	74.31	95.83	88.19	86.11	86.26	9.98
	OUÖ+DAA	97.22	81.25	93.06	88.89	68.75	63.19	99.31	86.81	84.72	84.80	12.20
[146]	STR	96.00	67.00	80.00	69.00	56.00	62.00	55.00	74.00	63.00	69.11	12.89
[163]	GSW+MNN	90.23	77.20	86.51	86.04	75.34	82.32	79.53	79.99	75.81	81.44	5.21
	MDM	97.22	74.31	95.14	92.36	72.22	65.28	90.97	90.28	72.22	83.33	12.12
	OUÖ+DAA	97.22	81.25	93.06	88.89	68.75	63.19	99.31	86.81	84.72	84.80	12.20
[164]	GOR	96.53	76.39	89.58	87.50	65.28	72.92	97.22	74.31	64.58	80.48	12.58
	CSD2	95.14	90.28	86.81	93.75	66.67	74.31	97.92	77.78	65.97	83.18	12.31
Önerilen Yönt.	Y6 ve FB ₁	95.78	70.10	86.86	79.66	71.19	74.37	73.10	71.14	75.07	77.47	8.63
	Y8	85.18	86.24	82.56	87.41	85.89	82.63	84.38	87.88	81.84	84.89	2.19

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.8'de verilmiştir. A05 deneğinde gözlenen doğruluk artışı önemli seviyededeyken, A06 için düşük seviyededir. Diğer deneklerde literatür çalışmaları daha başarılıdır. Bu deneklerde doğrulukların arttırılması için iyileştirmeler yapılmalı ve denekler boyunca performans yukarı çekilmelidir. Önerilen yöntemlerin en önemli katkısı ortalama doğrulukta çok az daha başarılı olmasına rağmen denek havuzundaki standart sapmayı %8.34 oranında düşürmesidir. Çünkü denekten-deneğe daha kararlı sistemler için standart sapma çok önemli bir ölçüttür.



Şekil 3.8. Sağ el/ayaklar MHH için literatüre göre doğruluk kıyaslamaları

3.2.3.5. Sağ El/Dil MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01 ve A03 denekleri için sırasıyla 95.9 ± 0.38 ve 94.0 ± 0.59 ; A02, A04-A09 için ise 86.0 ± 3.27 , 85.6 ± 2.94 , 86.8 ± 2.38 , 90.2 ± 2.71 , 85.6 ± 1.70 , 86.6 ± 1.66 ve 90.2 ± 1.21 doğruluklarında elde edilmiştir. Denek havuzunda en iyi ortalama yine Y8 ile 86.6 ± 2.4 oranındadır. Ayrıca, Y2 ve Y4 tüm zaman dilimlerinde, Y6 ise ilk frekans bandında 80 üstü doğruluk üretmiştir. Bu yaklaşımların standart sapması 3.03 - 9.35 arasındadır. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütüyle en başarılı sonuçlar Y8 ve Y6 & FB₁ yaklaşımlarıyla A01-A09 denekleri için sırasıyla 0.92 ± 0.01 , 0.72 ± 0.07 , 0.88 ± 0.01 , 0.71 ± 0.06 , 0.73 ± 0.05 , 0.80 ± 0.05 , 0.71 ± 0.03 , 0.73 ± 0.03 ve 0.80 ± 0.02 değerlerinde gözlenmiştir. Denekler boyunca en iyi ortalama ve standart sapma Y8 ile 0.73 ± 0.05 olarak elde edilmiştir. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir (Tablo 3.11).

Tablo 3.11. Sağ el/dil MHH için sınıflandırma doğrulukları ve kapp değerleri

Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT±SS
Y2 ve ZD1	82.6±1.59	75.0±3.40	85.3±1.49	82.7±2.66	76.5±1.64	81.5±3.22	82.8±2.38	79.6±1.46	88.9±1.04	81.7±4.23
	0.65±0.03	0.50±0.07	0.70±0.03	0.65±0.05	0.53±0.03	0.63±0.06	0.66±0.05	0.59±0.03	0.78±0.02	0.63±0.08
Y2 ve ZD2	80.9±2.10	76.0±2.19	85.6±1.44	79.2±2.58	77.0±2.49	79.4±2.44	82.4±2.14	82.5±1.58	88.4±0.70	81.3±3.97
	0.62±0.04	0.52±0.04	0.71±0.03	0.58±0.05	0.54±0.05	0.59±0.05	0.65±0.04	0.65±0.03	0.77±0.01	0.62±0.08
Y2 ve ZD3	77.8±2.29	76.2±2.47	83.5±1.23	81.0±2.47	76.3±2.70	79.8±2.59	82.7±1.81	81.4±1.66	84.4±1.74	80.3±3.03
	0.56±0.05	0.52±0.05	0.67±0.02	0.62±0.05	0.52±0.05	0.59±0.05	0.65±0.04	0.63±0.03	0.69±0.03	0.61±0.06
Y4 ve ZD1	85.2±1.47	71.6±1.84	87.5±2.85	82.0±2.62	73.8±1.76	77.5±2.10	81.6±1.83	80.3±2.16	90.1±1.03	81.1±6.10
	0.70±0.03	0.43±0.04	0.75±0.06	0.64±0.05	0.47±0.03	0.55±0.04	0.63±0.04	0.61±0.04	0.80±0.02	0.62±0.12
Y4 ve ZD2	85.7±1.18	72.4±2.43	88.0±2.15	79.9±3.12	73.5±2.37	77.3±1.77	82.4±1.38	82.2±1.35	88.2±0.91	81.1±5.80
	0.71±0.02	0.45±0.05	0.76±0.04	0.60±0.06	0.47±0.05	0.55±0.04	0.65±0.03	0.64±0.03	0.76±0.02	0.62±0.12
Y4 ve ZD3	83.8±2.40	74.0±2.30	86.4±2.69	79.3±3.12	72.9±1.73	76.9±1.50	83.6±2.37	80.2±3.08	87.1±0.79	80.5±5.17
	0.68±0.05	0.48±0.05	0.73±0.05	0.59±0.06	0.46±0.04	0.54±0.03	0.67±0.05	0.60±0.06	0.74±0.02	0.61±0.10
Y5 ve ZD2	94.5±1.99	65.3±3.00	93.3±0.75	72.5±0.61	67.6±2.05	68.8±2.56	78.6±1.58	78.3±1.07	84.5±1.46	78.2±10.8
	0.89±0.04	0.31±0.06	0.87±0.01	0.45±0.01	0.35±0.04	0.37±0.05	0.57±0.03	0.57±0.02	0.69±0.03	0.56±0.22
Y6 ve FB1	95.9±0.38	70.2±3.41	94.0±0.59	76.7±2.14	72.2±1.61	75.4±1.69	74.0±1.49	81.8±0.98	85.2±1.03	80.6±9.35
	0.92±0.01	0.40±0.07	0.88±0.01	0.54±0.04	0.44±0.03	0.51±0.03	0.48±0.03	0.64±0.02	0.70±0.02	0.61±0.19
Y6 ve FB2	78.8±1.24	69.3±2.16	80.5±1.83	78.1±1.59	71.2±3.04	76.7±2.55	83.7±1.71	78.2±1.62	88.0±1.04	78.3±5.71
	0.58±0.02	0.39±0.04	0.61±0.04	0.56±0.03	0.42±0.06	0.53±0.05	0.67±0.03	0.56±0.03	0.76±0.02	0.57±0.12
Y8	82.5±1.31	86.0±3.27	86.0±1.81	85.6±2.94	86.8±2.38	90.2±2.71	85.6±1.70	86.6±1.66	90.2±1.21	86.6±2.4
	0.65±0.03	0.72±0.07	0.72±0.04	0.71±0.06	0.73±0.05	0.80±0.05	0.71±0.03	0.73±0.03	0.80±0.02	0.73±0.05

Sonuçlar önceki çalışmalarla doğruluk ölçütü kullanılarak kıyaslanmıştır. Çünkü önceki çalışmalarda bu ölçüt kullanılırken kapp değerleri kullanılmamıştır. Karşılaştırmalar Das vd. (2016) [143], Gaur vd. (2018) [151], Sadatnejad vd. (2016) [144], Rodrigues vd. (2019) [146], Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] ile yapılmıştır. Y8 ile A05 (%77.08'den %86.67'e %9.69) ve A06 (%79.06'dan %90.21'e %11.15) deneklerinde daha başarılı sonuçlar göstermiştir. Diğer taraftan, [143, 151, 144, 163, 164]'e ait OUÖ, RoCSP, SS-MEMDB, KPCA (CILK), OUÖ+DAA ve CSD2 teknikleri A01-A04 ve A07-A09 için sırasıyla %4.11, %5.00, %5.34, %3.25, %12.98, %5.10 ve %6.38 daha başarılıdır. Ayrıca, RoCSP tüm deneklerde ortalama %2.13 daha başarılıdır. Ancak bu yöntemin standart sapması Y8'e kıyasla %8.82 oranında önemli derecede yüksektir (Tablo 3.12).


Tablo 3.12. Sağ el/dil MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS	
[143]	OUÖ	100.0	63.89	96.53	84.72	65.97	68.75	97.22	90.97	86.11	83.80	14.16
	RoCSP	100.0	72.92	99.30	88.89	77.08	74.31	98.61	91.67	95.83	88.73	11.12
[151]	SS-MEMDB	100.0	68.53	95.65	86.36	70.90	75.00	90.37	83.09	83.85	83.75	10.78
[144]	KPCA (CILK)	98.61	90.97	97.22	85.42	72.92	75.69	95.83	87.50	89.58	88.19	9.05
	OUÖ+DAA	100.0	63.89	96.53	85.42	65.28	65.97	97.22	91.67	81.94	83.10	14.69

Tablo 3.12'nin devamı

[146]	STR	97.00	63.00	92.00	69.00	65.00	56.00	52.00	72.00	74.00	71.11	15.07
[163]	GSW+MNN	90.69	73.94	86.97	87.44	76.74	79.06	82.32	87.90	85.58	83.40	5.71
	MDM	99.31	72.22	97.92	84.72	76.39	63.89	85.42	76.39	81.94	82.02	11.50
	OUÖ+DAA	100.0	63.89	96.53	85.42	65.28	65.97	97.22	91.67	81.94	83.10	14.69
[164]	GOR	97.92	69.44	95.14	86.11	73.61	65.28	97.22	62.50	92.36	82.18	14.45
	CSD2	97.92	70.83	97.22	84.72	72.22	65.28	94.44	68.06	96.53	83.02	13.89
	SS _R	98.61	70.83	88.19	72.22	70.83	67.36	97.92	86.11	77.08	81.02	12.04
Önerilen Yönt.	Y6 ve FB ₁	95.89	70.16	93.96	76.73	72.19	75.40	74.02	81.81	85.18	80.59	9.35
	Y8	82.46	85.97	85.99	85.64	86.77	90.21	85.63	86.57	90.15	86.60	2.38

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.9'da verilmiştir. A05 ve A06 için performans literatüre kıyasla oldukça önemli seviyede iyileştirilmiştir. Diğer deneklerde önceki çalışmalar daha başarılıdır. Bu deneklerde doğruluğun artırılması için iyileştirmeler yapılmalıdır. Böylelikle denekler boyunca sistem performansı yukarı çekilebilecektir. Önerilen yöntemlerin en önemli katkısı ortalama doğrulukta %2.13 oranında az daha başarılı olmasına rağmen, denek havuzundaki standart sapmanın %8.74 oranında önemli seviyede düşürülmesidir. Bu sonuçlar denekten-deneğe daha kararlı sistemlerin geliştirilmesi için oldukça önemlidir.



Şekil 3.9. Sağ el/dil MHH için literatüre göre doğruluk kıyaslamaları

3.2.3.6. Ayaklar/Dil MHH Görevleri İçin Sınıflandırma Sonuçları

En başarılı sonuçlar A01-A08 için sırasıyla %85.5±2.15, %87.2±2.83, %86.4±2.37, %88.5±2.84, %88.0±2.14, %84.0±3.04, %82.0±1.40, %86.2±1.62, %90.2±1.21; A09 için ise Y4 ve ZD₁ ile 88.1±1.52 doğruluklarında elde edilmiştir. Denek havuzunda en iyi ortalama sonuç Y8 ile %86.2±2.09 oranındadır. Ayrıca, Y2 ve Y4 tüm zaman dilimlerinde, Y6 ise 3. ve 5. frekans bandında %75 üstü doğruluk üretmiştir. Bu yaklaşımların standart sapmaları %2.66-%5.27 arasındadır. Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar elde edilmiştir. Kappa ölçütüyle başarılı sonuçlar Y8 ve Y4 & ZD₁ yaklaşımlarıyla A01-A09 denekleri için sırasıyla 0.71±0.04, 0.74±0.06, 0.73±0.05, 0.77±0.06, 0.76±0.04, 0.68±0.06, 0.64±0.03, 0.72±0.03 ve 0.76±0.03 değerlerindedir. Denekler boyunca en iyi ortalama ve standart sapma Y8'le 0.72±0.04 olarak elde edilmiştir (Tablo 3.13). Diğer yaklaşımlarda denekler boyunca daha düşük sonuçlar gözlenmiştir.

Tablo 3.13. Ayaklar/dil MHH için sınıflandırma doğrulukları ve kappa değerleri

Yönt.	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT±SS
Y2 ve	76.9±3.34	76.8±2.40	80.2±1.93	78.7±3.66	76.8±3.19	78.1±2.11	79.9±2.02	82.7±1.90	87.2±1.23	79.7±3.43
ZD ₁	0.54±0.07	0.53±0.05	0.60±0.04	0.57±0.07	0.54±0.06	0.56±0.04	0.60±0.04	0.65±0.04	0.74±0.02	0.59±0.07
Y2 ve	79.0±2.57	76.0±2.31	77.0±2.90	76.3±3.22	77.5±2.12	75.7±2.18	79.2±2.26	83.5±2.40	86.5±0.79	79.0±3.70
ZD ₂	0.58±0.05	0.52±0.05	0.54±0.06	0.52±0.07	0.55±0.04	0.51±0.04	0.58±0.05	0.67±0.05	0.73±0.02	0.58±0.07
Y2 ve	77.2±1.92	73.4±2.71	76.8±1.86	78.8±3.98	75.7±2.45	75.3±3.75	78.7±1.77	80.8±1.57	81.6±1.05	77.6±2.66
ZD ₃	0.54±0.04	0.47±0.05	0.54±0.04	0.57±0.08	0.52±0.05	0.51±0.07	0.57±0.04	0.62±0.03	0.63±0.02	0.55±0.05
Y4 ve	74.8±2.48	72.8±3.04	77.9±1.81	75.3±2.78	73.2±1.92	75.3±2.91	81.8±2.54	83.6±1.87	88.1±1.52	78.1±5.27
ZD ₁	0.50±0.05	0.45±0.06	0.56±0.04	0.51±0.05	0.47±0.04	0.51±0.06	0.64±0.05	0.67±0.04	0.76±0.03	0.56±0.11
Y4 ve	77.0±2.76	72.6±1.75	74.1±2.41	74.9±2.33	72.6±2.45	73.6±3.04	79.6±1.31	83.7±1.65	86.2±1.16	77.2±4.98
ZD ₂	0.54±0.06	0.45±0.03	0.48±0.05	0.50±0.05	0.45±0.05	0.47±0.06	0.59±0.03	0.67±0.03	0.72±0.02	0.54±0.10
Y4 ve	74.0±1.72	68.2±2.47	72.2±2.29	75.9±3.24	73.8±1.61	72.6±2.77	79.5±1.22	80.2±1.06	82.4±1.19	75.4±4.53
ZD ₃	0.48±0.03	0.36±0.05	0.44±0.05	0.51±0.07	0.48±0.03	0.45±0.06	0.59±0.02	0.60±0.02	0.65±0.02	0.51±0.09
Y6 ve	70.2±2.24	72.3±2.37	72.5±1.73	73.3±2.20	70.3±2.87	74.1±1.89	76.3±2.06	78.9±1.53	86.6±1.14	74.9±5.18
FB ₂	0.40±0.05	0.45±0.05	0.45±0.03	0.46±0.05	0.41±0.06	0.48±0.04	0.52±0.04	0.58±0.03	0.73±0.02	0.50±0.10
Y6 ve	73.5±2.21	70.5±2.44	74.2±2.74	73.8±2.20	75.2±2.32	70.8±2.43	77.3±1.62	81.4±0.99	86.9±1.43	76.0±5.26
FB ₃	0.47±0.04	0.41±0.05	0.48±0.05	0.47±0.05	0.50±0.05	0.42±0.05	0.55±0.03	0.63±0.02	0.74±0.03	0.52±0.11
Y6 ve	72.7±2.77	69.0±2.08	73.9±1.94	75.2±2.51	70.7±2.22	74.3±1.57	79.0±1.57	77.6±2.27	86.2±1.12	75.4±5.10
FB ₅	0.45±0.06	0.38±0.04	0.48±0.04	0.51±0.05	0.41±0.04	0.49±0.03	0.58±0.03	0.55±0.05	0.72±0.02	0.51±0.10
Y8	85.5±2.15	87.2±2.83	86.4±2.37	88.5±2.84	88.0±2.14	84.0±3.04	82.0±1.40	86.2±1.62	87.8±0.79	86.2±2.09
	0.71±0.04	0.74±0.06	0.73±0.05	0.77±0.06	0.76±0.04	0.68±0.06	0.64±0.03	0.72±0.03	0.76±0.02	0.72±0.04

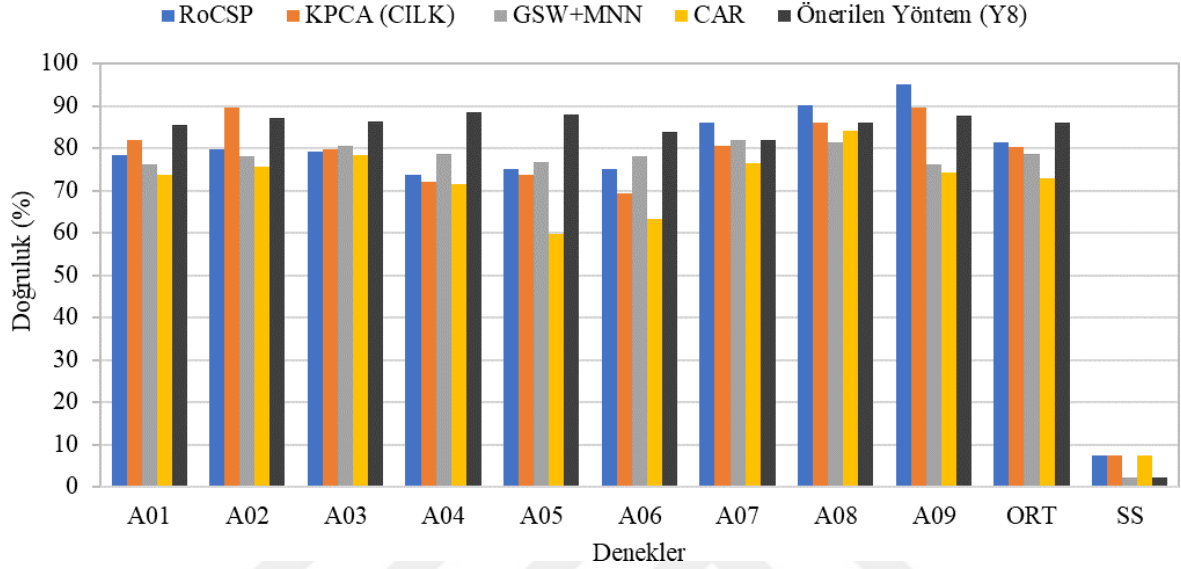
Sonuçlar önceki çalışmalarla doğruluk ölçütü kullanılarak kıyaslanmıştır. Çünkü literatürde bu ölçüt kullanılırken kappa değeri kullanılmamıştır. Karşılaştırmalar Das vd. (2016) [143], Gaur vd. (2018) [151], Sadatnejad vd. (2016) [144], Rodrigues vd. (2019) [146], Alimardani vd. (2017) [163] ve Rathee vd. (2017) [164] ile yapılmıştır. Y8 yaklaşımıyla A01 (%81.94'ten %85.52'ye %3.58), A03 (%80.46'dan %86.42'ye %5.96), A04 (%78.60'tan %88.51'e %9.91), A05 (%76.74'ten %87.99'a %11.25), A06 (%78.13'ten %83.99'a %5.86) ve A07 (%76.39'dan %82.00'a %5.61) deneklerinde daha başarılı sonuçlar alınmıştır. Diğer yandan, [143, 144]'e ait RoCSP, KPCA (CILK) yöntemleri A02, A08 ve A09 için sırasıyla %2.39, %4.10, %7.07 daha başarılıdır. Denek havuzundaki ortalamada, Y8 yaklaşımı literatürde en iyi sonuçları üreten RoCSP'ya kıyasla %4.17 daha başarılıdır. Denek havuzunda standart sapma ise %5.39 düşürülmüştür (Tablo 3.14).

Tablo 3.14. Ayaklar/dil MHH için sınıflandırma doğruluk kıyaslamaları

Çalışma Yöntem	A01	A02	A03	A04	A05	A06	A07	A08	A09	ORT	SS	
[143]	OUÖ	72.22	70.83	68.75	55.55	67.36	66.67	81.94	80.56	90.97	72.76	10.36
	RoCSP	78.47	79.86	79.17	73.61	75.00	75.00	86.11	90.28	95.13	81.40	7.48
[151]	SS-MEMDB	75.00	74.47	69.85	66.07	70.92	67.29	78.83	81.02	89.55	74.78	7.46
[144]	KPCA (CILK)	81.94	89.58	79.86	72.22	73.61	69.44	80.56	86.11	89.58	80.32	7.39
	LLE	58.33	53.47	63.19	53.47	51.39	55.56	67.36	72.92	72.92	60.96	8.45
	OUÖ+DAA	69.44	69.44	69.44	56.94	70.83	67.36	81.25	82.64	88.89	72.91	9.66
[146]	STR	62.00	60.00	64.00	53.00	62.00	58.00	61.00	67.00	60.00	60.78	3.90
[163]	GSW+MNN	76.27	78.13	80.46	78.60	76.74	78.13	81.85	81.39	76.27	78.65	2.14
[164]	GOR	73.61	75.69	78.47	71.53	59.72	63.19	76.39	84.03	74.31	72.99	7.48
	CSD2	76.39	83.33	70.14	68.06	66.67	70.83	79.86	87.50	92.36	77.24	9.12
	SS _R	70.14	79.86	79.86	70.83	61.11	64.58	76.39	71.53	83.33	73.07	7.41
Önerilen Yönt.	Y4 ve ZD ₁	74.81	72.77	77.89	75.30	73.19	75.33	81.75	83.65	88.06	78.08	5.27
	Y8	85.52	87.19	86.42	88.51	87.99	83.99	82.00	86.18	87.76	86.17	2.09

En başarılı yöntemlerle kıyaslamalar grafiksel olarak Şekil 3.10'da verilmiştir. Önceki çalışmalara göre altı denekte performans iyileştirilmiştir. A03-A07 deneklerinde elde edilenler başarılar önemli seviyededir. Önerilen yaklaşımlar denekler boyunca ortalamada %4.77 daha başarılı sonuçlar elde ederken, aynı zamanda standart sapmayı %5.39 oranında düşürmüştür. Elde edilen sonuçlar, literatüre göre daha başarılı ve denekten-deneğe daha kuvvetli bir sınıflandırma anlamına gelir. Diğer yandan, A02, A08 ve A09 deneklerinde literatür çalışmaları daha başarılı olmuştur. Bu deneklerde doğrulukların arttırılması için

iyileştirmeler yapılmalıdır. Böylelikle denekler boyunca sistem performansı daha yukarı çekilebilecektir.



Şekil 3.10. Ayaklar/dil MHH için literatüre göre doğruluk kıyaslamaları

3.2.3.7. Genel Sonuçlar ve Parametre Performans Katkıları

Tüm problem havuzundan elde edilen sonuçlar özetlenecek olursa, dokuz denek ve altı sınıflandırma problemi için oluşan toplam 54 problemde ortalama 86.52 ± 3.43 başarı elde edilmiştir. Bu sonuçlarla, tüm problem havuzunun %40'ında literatüre kıyasla daha başarılı sonuçlar alınmıştır. Elde edilen sonuçların çoğunda önceki çalışmalara kıyasla performans önemli derecede arttırılmıştır. Denekler ve problemler bazında koşullar sonucu ortalama performansların standart sapmaları oldukça kabul edilebilir düzeydedir. Denekler boyunca ortalama doğruluk değerleri düşünüldüğünde, sol/sağ el ve ayaklar/dil MHH problemlerinde daha başarılı sonuçlar alınmıştır. Diğer dört problemde oldukça yakın sonuçlar elde edilmiştir. Denekler boyunca standart sapma değerleri incelendiğinde ise altı problemin tamamında daha düşük sapmalar gözlenmiştir. Bu sonuçlar denekten-deneğe kuvvetli yöntemlerin geliştirilmesine yönelik oldukça umut vericidir. Bu denli düşük standart sapma değerlerinin gözlenmesinin en önemli nedeni farklı zaman dilimleri ve frekans bantlarından üretilen sınıflandırıcılara ait kararlarının oylanmasıdır.

Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları da incelenmiştir. İncelemede, tüm koşullar, denekler ve sınıflandırma problemleri boyunca en başarılı sonuçlar veren yaklaşımların parametreleriyle bir havuz oluşturulmuş ve sonrasında her parametrenin veya aralığın yüzde ne kadar katkı sağladığı hesaplanmıştır. Problem havuzunun %64'ünde 90×50 , %36'sında 180×100 boyutu başarılı olmuştur. Benzer şekilde %27.22'sinde Çekirdek 1, %21.46'sında Çekirdek 2, %21.97'sinde Çekirdek 3 ve %29.34'ünde Çekirdek 4 başarılıdır. Elektrot konumlarında, C3 elektrotu Cz ve C4'e göre daha başarılıdır. Bu konumların çevrelerindeki elektrotlar göz önüne alındığında, C3 ve çevresindeki FC3, C1, CP3, C5 konumları %41.07; Cz ve çevresindeki FCz, C2, CPz, C1 %26.51; C4 ve çevresindeki FC4, C6, CP4, C2 ise %32.42 başarılıdır. Merkezi elektrotlar dışında CP3, CPz ve CP4 da oldukça başarılıdır. Geçiş noktalarını belirleyen eşiklerde [0.05-0.35] aralığındaki küçük değerler daha başarılı olmuş, (0.35-3.5] aralığında ise gittikçe azalan oranlarda başarı gözlenmiştir. Olasılık vektör eşiği için [1-30] aralığı en iyi sonuçları üretmiştir. Ayrıca, (30-105] ve (120-150] değerleri için daha düşük oranda da olsa başarılı sonuçlar gözlenmiştir. Ayırma değerinde, özellikle [0.05-0.1], (0.2-0.4] ve (0.5-0.8] aralıkları başarılıdır ve [0.05-0.8] aralığında değişen bir dağılım bulunur. Bu dağılım problem havuzundaki farklı denekler kaynaklıdır.

Önerilen yaklaşımların eğitim ve test için hesaplama süreleri oldukça tatmin edicidir. En başarılı sonuçları üreten Y8 yaklaşımının toplam 54 farklı görevdeki ortalama eğitim süresi 24.2 sn ve test süresi 0.012 sn'dir. Örnek sayısı ve öğrenme modellerinin oluşturulma maliyetiyle ilintili eğitim süresi oldukça düşüktür. Dahası, test süresi oldukça kabul edilebilir düzeydedir. Her bir sınıf için eğitimde 40 sn'lik geometrik ortalama hesabına ihtiyaç duyan [163]'e göre eğitim süresi düşüktür. Test için ise, bir girdi matrisinin sınıflandırılmasını iki farklı ağda 0.58 ve 1.04 sn'de gerçekleştiren [105], bir denemeyi 0.4 sn'de işleyen [150] ve her bir test çerçevesini 1 sn'den az zamanda test eden [163]'e göre maliyet düşüktür. Uygulamalar Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz işlemci, 16 GB RAM bellek ve Windows 10 Education 64-bit işletim sisteminde MATLAB R2018b ortamında gerçekleştirilmiştir. Veri edinimi ile gürültü kaldırma için BioSig kütüphanesi ve EmotivPro kullanılmıştır.

3.3. MHH-BMTA Veri Setinde Elde Edilen Sonuçlar

Bu kısımda, BMTA veri setindeki mobil bir cihazın ekranına parmakla hafif bir şekilde tıklama ve ekranındaki nesnelere başparmakla kaydırma MHH görevlerin sınıflandırılmasına odaklanılmıştır. Bu amaçla, öncelikle MHH ile ilişkili frekans bantları, zaman dilimleri ve elektrotlar belirlenmiştir. Sonrasında, çeşitli yaklaşımlarla MHH görevlerine ait öznelilikler çıkarılmış ve sınıflandırılmıştır. Tez çalışmasında önerilen yaklaşımların yanısıra literatür yöntemleriyle de sonuçlar alınarak kıyaslamalar yapılmıştır.

3.3.1. Frekans Bantları, Zaman Dilimleri ve Elektrotların Belirlenmesi

MHH ilişkili frekans bant kümesi $K_b = \{FB_1, FB_2, FB_3, FB_4, FB_5\}$ beşinci dereceden bant geçiren filtreyle oluşturulmuştur. Bu frekans bantları $FB_1 = (8-12 \text{ Hz})$, $FB_2 = (8-30 \text{ Hz})$, $FB_3 = (8-40 \text{ Hz})$, $FB_4 = (13-30 \text{ Hz})$ ve $FB_5 = (4-40 \text{ Hz})$ şeklindedir. MHH-BMTA veri setinde $t=6s$ 'de MHH görevi başlamış ve $t=8.5 \text{ sn}$ 'de bitmiştir. Ayrıca $t=3 \text{ sn}$ 'den $t=6 \text{ sn}$ 'ye kadar deneklerin hareket hayaline hazırlanmaları ve odaklanmaları istenmiştir. Her bir deneme için zamanlama planı göz önünde alındığında, 1 sn uzunluğundaki zaman dilimlerinin 0.5 sn'lik örtüşmelerle oluşan $K_{zd} = \{ZD_1, ZD_2, ZD_3, ZD_4, ZD_5\}$ kümesinin kullanılması kararlaştırılmıştır. Bu zaman dilimleri ZD_1 (5.5 sn ile 6.5 sn arası), ZD_2 (6.0 sn ile 7.0 sn arası), ZD_3 (6.5 sn ile 7.5 sn arası), ZD_4 (7.0 sn ile 8.0 sn arası) ve ZD_5 (7.5 sn ile 8.5 sn arası) şeklindedir. Zaman dilimi uzunluğu ve örtüşme miktarı ön performans değerlendirmeleriyle belirlenmiştir. Elde edilen sonuçlar 1 sn'lik dilimlerin 1.5 ve 2. sn'lik dilimlere göre daha başarılı olduğunu göstermiştir. Elektrot konumları C3 ve çevresindeki FC3, C1, CP3, C5; Cz ve çevresindeki FCz, C2, CPz, C1; C4 ve çevresindeki FC4, C6, CP4, C2 olarak belirlenmiştir. Sonuçlar bu konumlar için ayrı ayrı alınmıştır.

3.3.2. Deneysel Sonuçlar ve Analizler

Değerlendirmeler veri setindeki sekiz denek için yürütülmüştür. Çalışmaların ilk kısmı farklı günlere ait oturumlarla oluşturulan eğitim ve test kümelerinde yürütülmüştür (Tablo 3.15, farklı oturumlar sütunu). Burada, ilk oturumda kaydedilen sinyaller eğitim, ikinci

oturumda kaydedilenler ise test için kullanılmıştır. Eğitim ve test kümelerinin bu şekilde oluşturulması literatürle yapılacak kıyaslamalar için önemlidir. Çalışmaların ikinci kısmında, öncelikle iki farklı günde kaydedilen oturum verileri birleştirilmiştir. Daha sonra, tüm veri havuzu %50-%50, %70-%30, %90-%10 oranlarıyla eğitim ve test kümelerine ayrılmıştır. Tablo 3.15’de deneme sayıları verilen bu ayrımlarda eğitim ve test kümelerinde örtüşen hiçbir örnek yoktur. Eğitim ve test kümelerinde farklı kategorilerdeki örnek sayıları neredeyse aynıdır. Sınıflandırma performansları ilk olarak YODM kullanan topluluk öğrenme yaklaşımları için hesaplanmıştır. Daha sonra, zaman düzlemi öznitelikleri K-EYK ve DVM ile sınıflandırılmıştır. Son olarak, evrişimli sinir ağları ve transfer öğrenmeyle sonuçlar alınmıştır.

Tablo 3.15. Farklı oturumlar ve çeşitli eğitim test oranlarında deneme sayıları


Denek	Toplam	Farklı Oturumlar		%50-%50		%70-%30		%90-%10	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
D01	201	101	100	101	100	141	60	181	20
D02	240	120	120	120	120	168	72	216	24
D03	196	100	96	98	98	138	58	177	19
D04	210	105	105	105	105	147	63	189	21
D05	207	107	100	104	103	145	62	187	20
D06	220	110	110	110	110	154	66	198	22
D07	194	96	98	97	97	136	58	175	19
D08	220	110	110	110	110	154	66	198	22

3.3.2.1. YODM Kullanan Topluluk Öğrenme İçin Sonuçlar ve Analizler

Öznitelik çıkarma aşamasında çeşitli parametre kombinasyonları sınanmıştır. Bu parametreler, 2-B özniteliklerin oluşturulması için $M \times N$ boyut parametresi ve δt geçiş eşiğidir. Birinci ve ikinci boyutlar sırasıyla $[-180^\circ, 180^\circ]$ ve $[-1, 1]$ aralıklarındadır. Bu nedenle, boyut değerleri 90×50 ve 180×100 olarak tanımlanmıştır. Farklı denekler, görevler ve frekans bantları için optimum δt farklılık gösterebilir. Bu nedenle, potansiyel eşikler $[0.01 - 3.5]$ aralığında $\Delta t = 0.1$, $\Delta t = 0.15$ ve $\Delta t = 0.3$ artımlarla aranmıştır. Ayrıca, tespit edilen geçiş noktaları yeterli değilse δt 'nin üst limiti kademeli azaltılmıştır. Örneğin, 8-12 Hz aralığında çalışıldığında az geçiş noktasına rastlanılmış ve bu duruma

başvurulmuştur. Öğrenme ve test aşamalarında ise, $M \times N$ boyut değeri, Gauss çekirdeği, önemli değerleri koruyan δm ayırma değeri ve ayırım kapasitesi yüksek olasılık bilgilerini seçen η değeri belirlenmelidir. Boyut için öznitelik çıkarmada aşamasındaki $M \times N$ değerleri kullanılmıştır. Öğrenme matrislerinin Gauss çekirdekleriyle yumuşatılmasında Çekirdek 1 ($w = [5 \times 5], \sigma = 0.9$), Çekirdek 2 ($w = [9 \times 9], \sigma = 1.6$) ve Çekirdek 3 ($w = [21 \times 21], \sigma = 4.0$) kullanılmıştır. Minimum-maksimum yöntemiyle $[0 - 1]$ aralığında normalize edilmiş matrisler, δm ayırma sınırıyla $[0.05 - 0.7]$ aralığında 0.1, 0.15 ve 0.2 artımlarla eşiklenmiştir. η değeri $[1 - 121]$ aralığında 5, 10, 20 ve 25 artımlarla test edilmiştir. δm ve η yeterli öznitelik üretmezse üst limitleri kademeli azaltılmıştır.

D02 deneğine ait 5.5 ile 7.5 sn zaman dilimindeki sinyallerin 8-30 Hz aralığında filtrelenmesiyle oluşan örnek öğrenme modelleri Şekil 3.11 (a)'daki gibidir. Modeller C3 elektrodundan alınan verilerin Çekirdek 3'le yumuşatılmasıyla oluşturulmuştur. Eşik değeri 1.85 ve ayırma değeri 0.2 olarak alınmıştır. Benzer şekilde, D02 deneğine ait 5.5 ile 7.5 sn dilimindeki sinyallerin 4-40 Hz aralığında filtrelenmesiyle oluşan öğrenme modelleri Şekil 3.11 (b)'deki gibidir. Modeller C3 elektrodundan alınan verilerin Çekirdek 2 ile yumuşatılmasıyla oluşturulmuştur. Eşik değeri 0.95 ve ayırma değeri 0.65 alınmıştır.



Şekil 3.11. Tıklama ve kaydırma MHH için örnek öğrenme modelleri

YODM kullanan topluluk öğrenme için sonuçlar aşağıda başlıklar halinde verilen 9 yaklaşımla alınmıştır. Eğitim ve test kümelerinde örtüşen hiçbir eleman yoktur. Önerilen yöntemlerinin optimum sınıflandırma parametreleri her denek ve problem için eğitim kümesinden elde edilen alt eğitim ve doğrulama kümeleriyle belirlenmiştir. Test

kümesindeki hiçbir örnek eğitim için kullanılmamıştır. Tablolarda denekler için verilen değerler 15 koşumun ortalama ve standart sapmaları alınarak hesaplanmıştır. Ayrıca, performans değerlerinin denekler boyunca ortalamaları ve standart sapmaları en sağdaki sütunlarda verilmiştir. Ayrıca, denekler boyunca ortalaması en yüksek 10 yaklaşımın sonuçları verilmiştir. Y1'de her bir zaman dilimi için beş sınıflandırıcının en iyilerinin performansları verilmiştir. Y4 ve Y5 için her bir zaman dilimindeki 3'lü kombinasyonlardan elde edilen 10 sınıflandırıcının en iyilerinin performansları sunulmuştur. Benzer şekilde, Y6 ve Y7 için her bir frekans bandının 3'lü kombinasyonlarından elde edilen 5 sınıflandırıcının en iyilerinin performansları verilmiştir. Bazı yaklaşımlardan elde edilen sonuçların yalnızca en iyilerini gösterecek şekilde verilmesinin nedeni sınıflandırıcıların bir kısmının MHH görevleri veya deneklerde kendi başlarına kıyaslanabilir sonuçlar üretmemesidir. Her bir tekil sınıflandırıcı için sonuçların sunulduğu Y2, Y3, Y8 ve Y9 yaklaşımları için bu durum geçerli değildir.

1. Yaklaşım 1 (Y1) ile tekil sınıflandırma
2. Yaklaşım 2 (Y2) ile aynı zaman diliminde geleneksel çoğunluk oylama
3. Yaklaşım 3 (Y3) ile aynı zaman diliminde geleneksel yumuşak oylama
4. Yaklaşım 4 (Y4) ile aynı zaman diliminde kombinasyonel çoğunluk oylama
5. Yaklaşım 5 (Y5) ile aynı zaman diliminde kombinasyonel yumuşak oylama
6. Yaklaşım 6 (Y6) ile aynı frekans bandında çoğunluk oylama
7. Yaklaşım 7 (Y7) ile aynı frekans bandında yumuşak oylama
8. Yaklaşım 8 (Y8) ile tüm zaman dilimleri ve frekans bantlarında çoğunluk oylama
9. Yaklaşım 9 (Y9) ile tüm zaman dilimleri ve frekans bantlarında yumuşak oylama

Tıklama ve kaydırma MHH görevlerinin sınıflandırılmasında öncelikle farklı günlerde kaydedilen denemelerle oluşturulan yaklaşık %50-%50 oranındaki eğitim ve test kümeleri için sonuçlar alınmıştır. İlk oturumda kaydedilen veriler eğitim için, ikinci oturumdakiler ise test için kullanılmıştır. En iyi sonuçlar D01-D08 denekleri için Y8 ile $\%73.20 \pm 5.77$, $\%77.78 \pm 6.36$, $\%80.14 \pm 4.75$, $\%80.38 \pm 3.94$, $\%81.40 \pm 5.83$, $\%83.76 \pm 2.47$, $\%78.78 \pm 5.06$, $\%76.12 \pm 5.52$ doğrulukları ve 0.44 ± 0.13 , 0.56 ± 0.13 , 0.60 ± 0.09 , 0.60 ± 0.08 , 0.63 ± 0.12 , 0.68 ± 0.05 , 0.58 ± 0.10 , 0.52 ± 0.11 kappa değerlerindedir. Denekler boyunca ortalama en iyi sonuçlar Y8 ile $\%78.94 \pm 3.27$ doğruluk ve 0.57 ± 0.07 kappa değerlerindedir. D01, D02, D05,

D07 ve D08 için standart sapma %5.06-%6.36 aralığında, D03, D04 ve D06 için ise %2.47-%4.75 aralığındadır. Kappa değerleri için de benzer doğrultuda sonuçlar gözlenmiştir. Tüm denekler boyunca standart sapma %3.27 doğruluk ve 0.07 kappa değerlerinde oldukça kabul edilebilir seviyededir (Tablo 3.16).

Tablo 3.16. Farklı oturumlara ait eğitim ve test kümelerinde sınıflandırma sonuçları

Yöntem	D01	D02	D03	D04	D05	D06	D07	D08	ORT/SS
Y2 ve ZD ₂	66.5±4.58 0.30±0.10	66.9±5.41 0.34±0.11	68.4±4.67 0.37±0.09	68.9±3.74 0.37±0.08	67.8±4.71 0.36±0.09	70.5±3.38 0.41±0.07	67.2±4.01 0.35±0.08	67.3±3.41 0.34±0.07	68.0±1.30 0.35±0.03
Y2 ve ZD ₃	69.6±3.64 0.38±0.07	63.8±4.22 0.28±0.08	66.9±4.08 0.34±0.08	70.0±2.52 0.40±0.05	67.5±4.27 0.35±0.08	66.4±2.87 0.33±0.06	65.5±5.31 0.31±0.10	66.7±2.95 0.33±0.06	67.0±2.02 0.34±0.04
Y2 ve ZD ₅	65.7±4.15 0.29±0.09	65.6±3.53 0.31±0.07	67.3±4.72 0.35±0.09	69.7±2.20 0.39±0.04	65.0±4.19 0.30±0.08	67.8±2.52 0.36±0.05	66.2±3.62 0.33±0.07	71.8±1.72 0.43±0.03	67.4±2.34 0.34±0.05
Y4 ve ZD ₂	66.7±4.04 0.32±0.09	65.3±5.32 0.31±0.11	67.8±4.48 0.35±0.09	67.2±3.77 0.34±0.07	66.9±2.03 0.34±0.04	70.7±2.65 0.41±0.05	64.9±3.63 0.30±0.07	66.4±3.50 0.32±0.07	67.0±1.76 0.34±0.04
Y4 ve ZD ₅	65.2±2.51 0.29±0.05	63.7±3.05 0.27±0.06	66.9±3.21 0.34±0.06	69.6±2.05 0.39±0.04	64.6±3.22 0.30±0.06	67.5±2.43 0.35±0.05	66.3±2.63 0.33±0.05	71.1±2.18 0.42±0.04	66.9±2.51 0.34±0.05
Y6 ve FB ₂	67.9±3.65 0.33±0.08	65.1±2.99 0.30±0.06	68.4±4.45 0.37±0.09	69.1±2.88 0.38±0.06	67.3±4.86 0.35±0.10	73.3±3.41 0.47±0.07	70.0±3.63 0.40±0.07	70.7±3.34 0.41±0.07	69.0±2.45 0.38±0.05
Y6 ve FB ₃	66.2±3.36 0.30±0.07	64.6±6.02 0.29±0.12	65.3±3.53 0.31±0.07	72.4±2.62 0.45±0.05	67.7±3.08 0.36±0.06	65.0±2.91 0.30±0.06	65.2±2.95 0.31±0.06	67.6±3.87 0.35±0.08	66.8±2.56 0.33±0.05
Y6 ve FB ₄	68.7±3.98 0.35±0.09	66.7±3.93 0.33±0.08	66.5±4.77 0.33±0.10	69.1±3.30 0.38±0.07	65.6±3.00 0.32±0.06	68.1±2.72 0.36±0.05	67.4±3.00 0.35±0.06	65.4±2.97 0.30±0.06	67.2±1.37 0.34±0.03
Y6 ve FB ₅	65.7±3.03 0.29±0.07	64.8±4.66 0.30±0.09	68.9±5.55 0.38±0.11	69.9±3.75 0.39±0.08	67.6±2.92 0.35±0.06	66.2±3.55 0.32±0.07	65.3±4.85 0.31±0.10	70.2±3.52 0.40±0.07	67.3±2.12 0.34±0.04
Y8	73.2±5.77 0.44±0.13	77.8±6.36 0.56±0.13	80.1±4.75 0.60±0.09	80.4±3.94 0.60±0.08	81.4±5.83 0.63±0.12	83.8±2.47 0.68±0.05	78.8±5.06 0.58±0.10	76.1±5.52 0.52±0.11	78.9±3.27 0.57±0.07

İkinci olarak oturumların birleştirilmesiyle oluşan deneme havuzunun %50-%50 eğitim test oranına bölünmesiyle oluşan kümelerde sonuçlar alınmıştır. En iyi sonuçlar D01-D08 denekleri için Y8 ile %74.81±10.14, %75.00±3.90, %82.24±6.76, %79.24±9.04, %79.94±8.21, %79.21±6.33, %86.05±4.35, %78.00±10.87 doğrulukları ve 0.48±0.21, 0.51±0.07, 0.65±0.13, 0.60±0.16, 0.61±0.15, 0.59±0.12, 0.72±0.09, 0.56±0.21 kappa değerlerindedir. Denekler boyunca ortalama en iyi sonuçlar Y8 ile %79.31±3.68 doğruluk ve 0.59±0.08 kappa değerlerindedir. D01, D03-D06 ve D08 için standart sapma %6.33-%10.87 aralığında, D02 ve D07 için ise %3.90-%4.35 aralığındadır. Kappa değerleri için de benzer oranlarda sonuçlar elde edilmiştir. Tüm denekler boyunca standart sapma %3.68 doğruluk ve 0.08 kappa değerlerinde oldukça kabul edilebilir seviyededir (Tablo 3.17).

Tablo 3.17. %50-%50 eğitim test oranında sınıflandırma sonuçları

Yöntem	D01	D02	D03	D04	D05	D06	D07	D08	ORT/SS
Y2 ve ZD ₁	67.3±4.84 0.33±0.10	68.8±4.88 0.38±0.09	67.9±4.53 0.36±0.08	67.8±6.39 0.37±0.10	70.0±3.91 0.41±0.07	69.2±3.46 0.39±0.07	70.7±2.37 0.41±0.05	68.0±4.74 0.36±0.09	68.7±1.16 0.38±0.03
Y2 ve ZD ₂	68.3±3.70 0.35±0.07	66.5±2.64 0.34±0.05	70.9±4.08 0.42±0.08	67.2±4.47 0.35±0.08	68.4±4.10 0.38±0.08	68.7±4.06 0.38±0.08	70.7±3.16 0.41±0.06	68.5±4.05 0.37±0.08	68.7±1.52 0.38±0.03
Y2 ve ZD ₃	69.2±4.82 0.36±0.10	66.7±3.85 0.34±0.07	72.5±3.67 0.45±0.07	69.0±4.80 0.39±0.08	67.3±3.13 0.36±0.06	66.4±2.80 0.33±0.05	71.6±3.50 0.44±0.07	68.5±4.82 0.37±0.09	68.9±2.21 0.38±0.04
Y2 ve ZD ₄	68.2±3.95 0.35±0.07	65.1±3.58 0.31±0.07	68.6±3.31 0.38±0.06	69.6±3.27 0.40±0.06	69.2±3.47 0.39±0.07	67.7±5.07 0.36±0.09	71.9±3.81 0.44±0.08	68.7±2.85 0.38±0.06	68.6±1.90 0.38±0.04
Y2 ve ZD ₅	68.3±3.97 0.34±0.08	66.7±3.64 0.34±0.07	71.4±3.38 0.43±0.06	70.1±4.26 0.41±0.08	69.3±3.34 0.39±0.06	68.8±4.10 0.38±0.08	70.0±2.35 0.40±0.05	69.4±2.97 0.39±0.06	69.2±1.40 0.39±0.03
Y6 ve FB ₂	69.3±3.68 0.37±0.07	66.5±4.00 0.34±0.07	70.3±3.24 0.41±0.06	66.7±4.21 0.34±0.08	70.3±5.13 0.41±0.10	69.2±3.53 0.39±0.07	74.2±2.40 0.48±0.05	71.0±4.78 0.42±0.09	69.7±2.47 0.40±0.05
Y6 ve FB ₃	68.8±3.45 0.35±0.07	66.4±3.69 0.33±0.07	71.1±4.49 0.43±0.09	70.3±4.65 0.41±0.09	68.6±4.29 0.38±0.08	68.7±5.55 0.38±0.10	70.0±3.81 0.40±0.07	68.9±3.92 0.38±0.08	69.1±1.41 0.38±0.03
Y6 ve FB ₄	68.3±4.63 0.35±0.09	68.3±2.96 0.37±0.06	71.2±3.99 0.43±0.07	69.5±4.99 0.40±0.08	66.2±4.04 0.33±0.07	67.5±4.43 0.36±0.08	71.3±3.42 0.43±0.07	66.6±4.30 0.33±0.08	68.6±1.92 0.38±0.04
Y6 ve FB ₅	65.7±4.42 0.29±0.09	64.9±3.67 0.31±0.07	71.0±5.09 0.43±0.09	70.1±5.64 0.41±0.10	68.0±2.75 0.37±0.05	67.8±3.65 0.36±0.07	70.2±3.00 0.41±0.06	68.0±4.24 0.36±0.08	68.2±2.15 0.37±0.05
Y8	74.8±10.1 0.48±0.21	75.0±3.90 0.51±0.07	82.2±6.76 0.65±0.13	79.2±9.04 0.60±0.16	79.9±8.21 0.61±0.15	79.2±6.33 0.59±0.12	86.0±4.35 0.72±0.09	78.0±10.9 0.56±0.21	79.3±3.68 0.59±0.08

Üçüncü olarak oturumların birleştirilmesiyle oluşan deneme havuzunun %70-%30 eğitim ve test oranında bölünmesiyle oluşan kümelerde sonuçlar alınmıştır. En iyi sonuçlar D02-D08 denekleri için sırasıyla %86.39±5.41, %87.59±4.23, %91.43±4.28, %80.86±9.18, %92.93±3.78, %90.11±6.56, %85.86±6.69 doğrulukları ve 0.73±0.10, 0.75±0.08, 0.83±0.09, 0.63±0.16, 0.86±0.08, 0.80±0.13, 0.72±0.13 kappa değerlerindedir. D01 için Y6 ile üçüncü frekans bandında %75.78±6.84 doğruluk ve 0.50±0.12 kappa değeri gözlenmiştir. Denekler boyunca ortalama en başarılı sonuç %86.26±5.93 doğruluk ve 0.73±0.12 kappa değerindedir. D01, D05 için standart sapma %9.18-%11.49; D02, D07, D08 D06 için %5.41-%6.69; D03, D04 ve D06 için ise %3.78-%4.48 arasındadır. Kappa değerleri için de benzer doğrultuda sonuçlar gözlenmiştir. Tüm denekler boyunca standart sapma %5.93 doğruluk ve 0.12 kappa değerlerindedir (Tablo 3.18).

Tablo 3.18. %70-%30 eğitim test oranında sınıflandırma sonuçları

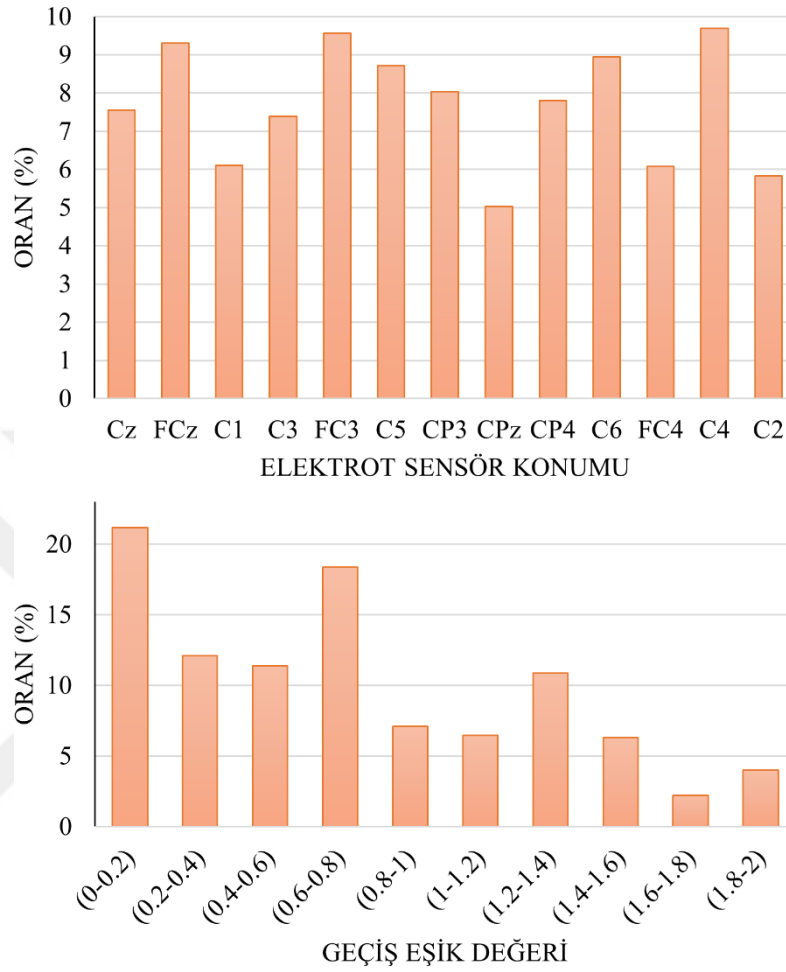
Yöntem	D01	D02	D03	D04	D05	D06	D07	D08	ORT±SS
Y2 ve ZD ₁	72.9±6.25 0.44±0.10	71.8±3.62 0.44±0.06	75.2±5.16 0.51±0.10	77.2±4.14 0.54±0.08	71.0±6.76 0.44±0.11	75.8±3.53 0.52±0.07	71.0±5.65 0.42±0.11	72.4±4.55 0.45±0.10	73.4±2.36 0.47±0.05
Y2 ve ZD ₂	69.9±5.89 0.37±0.11	71.5±3.14 0.44±0.06	77.1±3.71 0.54±0.07	77.7±3.57 0.55±0.07	69.5±8.28 0.40±0.15	74.2±4.69 0.48±0.10	73.8±5.01 0.48±0.09	73.2±4.31 0.46±0.08	73.4±3.04 0.47±0.06
Y2 ve ZD ₃	73.7±8.50 0.46±0.14	72.8±3.51 0.46±0.07	77.2±4.03 0.55±0.08	75.9±3.40 0.52±0.07	70.4±5.84 0.42±0.11	76.9±3.64 0.54±0.07	75.2±4.01 0.51±0.08	71.4±5.46 0.43±0.11	74.2±2.52 0.49±0.05
Y2 ve ZD ₄	70.9±6.42 0.40±0.11	74.6±3.94 0.50±0.07	76.1±4.46 0.52±0.09	80.7±4.24 0.61±0.08	68.6±7.90 0.39±0.14	76.5±4.50 0.53±0.09	75.1±5.33 0.50±0.11	74.2±4.83 0.48±0.10	74.6±3.65 0.49±0.07
Y2 ve ZD ₅	72.7±3.61 0.43±0.06	72.6±4.18 0.46±0.08	73.9±3.12 0.48±0.06	75.2±4.10 0.50±0.08	69.5±7.04 0.41±0.12	74.2±3.19 0.49±0.06	74.1±4.32 0.49±0.08	71.8±3.23 0.44±0.06	73.0±1.81 0.46±0.03
Y6 ve FB ₂	72.0±7.49 0.42±0.13	71.2±3.30 0.43±0.06	75.4±4.68 0.51±0.09	76.0±3.88 0.52±0.08	70.9±6.83 0.43±0.12	76.6±4.16 0.53±0.08	76.4±3.49 0.53±0.07	75.2±4.43 0.50±0.08	74.2±2.42 0.49±0.05
Y6 ve FB ₃	75.8±6.84 0.50±0.12	70.9±4.56 0.43±0.08	77.2±5.10 0.55±0.10	76.3±4.70 0.52±0.09	71.6±7.94 0.45±0.14	75.2±5.18 0.50±0.11	75.4±5.66 0.52±0.11	73.3±4.08 0.47±0.08	74.5±2.27 0.49±0.04
Y6 ve FB ₄	70.2±5.84 0.38±0.10	74.9±6.40 0.51±0.12	75.9±4.47 0.52±0.09	77.4±5.04 0.55±0.10	68.5±6.39 0.39±0.11	75.1±3.96 0.50±0.08	76.1±4.37 0.52±0.08	75.6±3.52 0.51±0.07	74.2±3.11 0.49±0.06
Y6 ve FB ₅	70.8±5.45 0.39±0.10	71.9±4.07 0.45±0.08	78.4±3.18 0.57±0.06	77.8±3.84 0.55±0.08	69.9±4.21 0.41±0.08	78.1±3.96 0.56±0.08	71.8±5.67 0.44±0.11	74.0±4.96 0.48±0.10	74.1±3.51 0.48±0.07
Y8	74.9±11.5 0.49±0.20	86.4±5.41 0.73±0.10	87.6±4.23 0.75±0.08	91.4±4.28 0.83±0.09	80.9±9.18 0.63±0.16	92.9±3.78 0.86±0.08	90.1±6.56 0.80±0.13	85.9±6.69 0.72±0.13	86.3±5.93 0.73±0.12

Son olarak oturumların birleştirilmesiyle oluşan deneme havuzunun %90-%10 eğitim test oranında bölünmesiyle oluşan kümelerde sonuçlar alınmıştır. En iyi sonuçlar D01-D08 denekleri için sırasıyla Y8 ile %92.33±6.51, %98.61±2.57, %98.60±2.41, %98.41±2.32, %99.00±2.07, %98.79±2.08, %99.30±1.85, %97.88±3.38 doğrulukları ve 0.71±0.13, 0.76±0.16, 0.83±0.11, 0.78±0.12, 0.79±0.13, 0.75±0.09, 0.73±0.14, 0.78±0.13 kapa değerlerindedir. Denekler boyunca ortalama başarılı sonuçlar Y8 ile %97.86±2.27 doğruluk ve 0.96±0.05 kapa değerindedir. D01 için standart sapma %6.51, D02-D08 için ise %1.85-%3.38 aralığında oldukça düşük seviyededir. Kapa ölçütü için de benzer doğrultuda sonuçlar gözlenmiştir. Tüm denekler boyunca standart sapma %2.27 doğruluk ve 0.05 kapa değerlerindedir (Tablo 3.19).

Tablo 3.19. %90-%10 eğitim test oranında sınıflandırma sonuçları

Yöntem	D01	D02	D03	D04	D05	D06	D07	D08	ORT/SS
Y2 ve ZD ₁	87.3±7.04 0.73±0.15	86.4±6.77 0.72±0.14	91.2±5.14 0.82±0.11	87.3±5.30 0.75±0.10	93.0±4.55 0.86±0.09	87.6±5.00 0.74±0.10	85.6±7.02 0.72±0.13	87.0±4.50 0.73±0.09	88.2±2.55 0.76±0.05
Y2 ve ZD ₂	87.3±4.95 0.72±0.12	86.4±4.30 0.72±0.09	90.9±5.44 0.81±0.12	86.7±5.46 0.73±0.11	91.0±4.71 0.82±0.09	89.4±5.34 0.78±0.11	89.5±3.98 0.78±0.08	87.9±7.42 0.76±0.14	88.6±1.82 0.76±0.04
Y2 ve ZD ₃	87.3±9.61 0.74±0.19	83.9±6.27 0.68±0.12	89.1±9.43 0.78±0.19	92.4±4.69 0.84±0.10	87.7±4.95 0.75±0.10	89.7±4.02 0.79±0.08	87.7±7.08 0.76±0.14	88.5±6.62 0.77±0.14	88.3±2.40 0.76±0.05
Y2 ve ZD ₄	88.3±8.38 0.75±0.17	89.4±5.65 0.79±0.12	87.7±6.18 0.75±0.13	91.1±6.20 0.82±0.13	90.0±5.98 0.80±0.12	87.0±4.16 0.73±0.09	89.1±7.57 0.78±0.15	88.5±5.92 0.76±0.12	88.9±1.31 0.77±0.03
Y2 ve ZD ₅	86.3±7.90 0.71±0.15	86.7±6.72 0.73±0.14	90.5±4.08 0.81±0.08	85.7±4.02 0.71±0.08	90.3±4.42 0.80±0.09	87.3±5.75 0.74±0.11	90.5±6.35 0.81±0.13	84.5±6.61 0.68±0.14	87.7±2.39 0.75±0.05
Y6 ve FB ₂	88.0±7.75 0.75±0.15	83.6±5.99 0.67±0.13	89.5±5.97 0.78±0.12	94.6±4.72 0.89±0.10	91.7±6.45 0.83±0.13	89.1±5.65 0.77±0.12	91.2±5.86 0.82±0.12	88.2±6.83 0.76±0.13	89.5±3.22 0.78±0.07
Y6 ve FB ₃	86.0±8.49 0.70±0.16	86.4±4.00 0.72±0.08	90.2±6.25 0.80±0.13	88.3±7.17 0.76±0.14	90.0±5.98 0.80±0.12	86.7±5.00 0.72±0.11	87.4±5.90 0.75±0.12	86.1±4.02 0.71±0.08	87.6±1.70 0.75±0.04
Y6 ve FB ₄	85.0±8.24 0.68±0.17	89.4±5.65 0.79±0.12	88.8±7.67 0.77±0.16	87.0±6.09 0.74±0.12	92.7±2.58 0.85±0.05	86.1±5.29 0.71±0.11	88.8±7.41 0.77±0.16	85.5±4.92 0.70±0.10	87.9±2.54 0.75±0.06
Y6 ve FB ₅	86.7±6.45 0.71±0.13	88.1±8.01 0.76±0.16	91.6±5.56 0.83±0.11	89.5±5.75 0.78±0.12	89.7±6.67 0.79±0.13	87.9±4.76 0.75±0.09	86.3±7.65 0.73±0.14	88.8±7.06 0.78±0.13	88.6±1.72 0.77±0.04
M8	92.3±6.51 0.84±0.13	98.6±2.57 0.97±0.06	98.6±2.41 0.97±0.05	98.4±2.32 0.97±0.05	99.0±2.07 0.98±0.04	98.8±2.08 0.97±0.05	99.3±1.85 0.98±0.04	97.9±3.38 0.96±0.07	97.9±2.27 0.96±0.05
M9	79.0±9.10 0.56±0.17	82.2±7.79 0.64±0.16	86.3±5.56 0.73±0.11	82.9±7.80 0.66±0.15	86.3±7.67 0.73±0.16	86.1±6.53 0.72±0.12	85.3±7.76 0.71±0.15	82.1±8.84 0.64±0.17	83.8±2.65 0.67±0.06

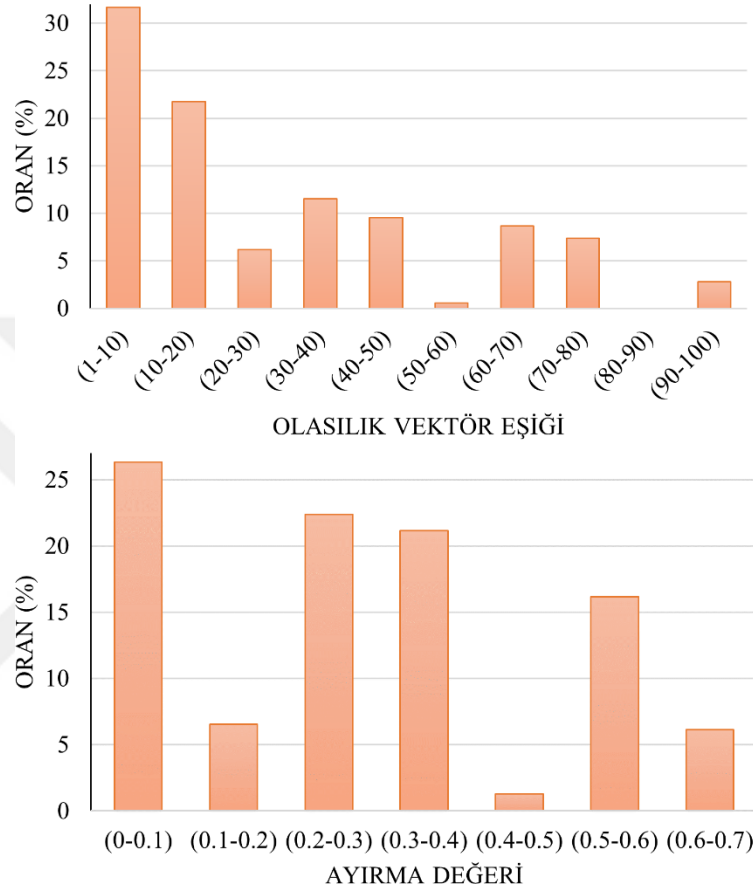
Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları incelenmiştir. İncelemede, tüm eğitim test oranları, koşumlar ve denekler boyunca en başarılı sonuçlar üreten yaklaşımların parametreleriyle bir havuz oluşturulmuş ve sonrasında her parametrenin veya aralığın yüzde ne kadar katkı sağladığı hesaplanmıştır. Toplam problem havuzunun %46'sında 90×50, %54'ünde 180×100 boyutu başarılı olmuştur. Problemlerin %38.58'inde Çekirdek 1, %36.02'sinde Çekirdek 2 ve %25.39'unda Çekirdek 3 başarılıdır. Elektrot sensör konumlarında C4 konumu Cz ve C3'e göre daha başarılıdır (Şekil 3.12). Bu konumların çevrelerindeki elektrotlar göz önüne alındığında, C3 ve çevresindeki FC3, C1, CP3, C5 konumları %35.55; Cz ve çevresindeki FCz, C2, CPz, C1 konumları %30.20; C4 ve çevresindeki FC4, C6, CP4, C2 konumları ise %34.25 oranlarında başarı göstermiştir. Geçiş noktalarını belirleyen eşiklerde (0.05-0.8) aralığındaki küçük değerler daha başarılı olmuştur. Ayrıca, (0.8-1.6) aralığında daha az oranda olsa da kayda değer başarı gözlenmiştir.



Şekil 3.12. Elektrot sensör konumları ve geçiş eşiğinin performansa katkıları

Olasılık vektör eşiğinde (1-20), (30-50) ve (60-80) aralıklarında en başarılı sonuçlar alınmıştır. Ayrıca, (20-30) ve (90-100) değerleri için az da olsa başarılı sonuçlar gözlenmiştir. Ayırma değerinde özellikle (0.0-0.1), (0.2-0.4) ve (0.5-0.6) aralıkları başarılı


olmuş ve (0-0.7) aralığında değişen bir dağılım gözlenmiştir. Dağılımın bu şekilde olmasının nedeni problem havuzundaki farklı deneklerdir (Şekil 3.13).



Şekil 3.13. Olasılık eşiği ve ayırma değerinin performansa katkıları

Farklı oturumlardan oluşturulan eğitim test kümeleri ve oturumların karıştırılması sonucu %50-%50, %70-%30 ve %90-%10 eğitim test oranlarıyla denekler ve denekler boyunca ortalama alınan en başarılı performans değerlerinin kıyaslamaları Şekil 3.14'te verilmiştir. Düşük sonuçların çoğu farklı günlere ait oturumların eğitim ve testte ayrı ayrı kullanıldığı senaryoda gözlenmiştir. Oturumların karıştırılması sonucu oluşturulan %50-%50 eğitim test oranlarında nispeten daha iyi sonuçlar gözlenmiştir. Eğitim kümesindeki örnek sayısı arttıkça tüm deneklerde ve ortalama performans artmıştır. Bunun nedeni, YODM yaklaşımlarında eğitim kümesindeki eleman sayısı ve çeşitliliğinin performansa oldukça etki etmesidir. %50-%50 eğitim test oranındaki farklı oturumlara ait senaryodan %90-%10 eğitim test oranına geçildiğinde D01-D08 için sırasıyla ortalama doğrulukta

%19.1, %20.8, %18.5, %18.0, %17.6, %15.0, %20.5, %21.8 oranlarında, kapa değerinde ise 0.40, 0.42, 0.37, 0.36, 0.35, 0.30, 0.41, 0.44 değerlerinde artış gözlenmiştir. Denekler boyunca ortalama doğrulukta %18.9 ve kapa değerinde 0.38 artış görülmüştür. D07 ve D08 deneklerinde doğrusal bir performans artışı olmuştur. D01 ve D05 deneklerinde %50-%50'den %70-%30'a düşük seviyede, %70-%30'dan %90-%10'a ise sıçrama şeklinde artış meydana gelmiştir. D06 için ise %50-%50'den %70-%30'a büyük oranda, %70-%30'dan %90-%10'a ise düşük oranda artış gerçekleşmiştir. %50-%50 ve %70-%30 eğitim test oranlarında standart sapmalar çoğu denekte yüksektir. Bunun nedeni eğitim havuzunun denekler ve problemler için yeterli çeşitlilikte olmamasıyla açıklanabilir. %90-%10 eğitim test oranında neredeyse tüm deneklerde daha az standart sapma değerleri gözlenmiştir.



Şekil 3.14. Farklı eğitim test oranlarında sınıflandırma performansları

Farklı oturumlara ait eğitim ve test kümeleri için hesaplama süreleri de ölçülmüştür. En başarılı sonuçları üreten Y8 yaklaşımının toplam 50 koşumda elde ettiği ortalama eğitim süresi 4.14 sn ve test süresi ise 0.02 sn'dir. Örnek sayısı ve öğrenme modellerinin oluşturulma maliyetiyle ilintili eğitim süresi oldukça düşüktür. Eğitim süresinin bu denli düşük olmasının en önemli nedenlerinden biri 1 sn'lik zaman dilimlerinin kullanılmasıdır. Benzer şekilde, test süreleri de oldukça kabul edilebilir düzeydedir. Çalışmalar Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz işlemci, 16 GB RAM bellek ve Windows 10 Education 64-bit işletim sisteminde MATLAB R2018b ortamında gerçekleştirilmiştir. Veri edinimi ile gürültü kaldırma için BioSig kütüphanesi ve EmotivPro kullanılmıştır.

3.3.2.2. K-EYK ve DVM Sonuçlar ve Analizler

Tez çalışmasında önerilen yaklaşımların sınanması için literatürde sıklıkla kullanılan bazı zaman düzlemi öznitelikleri ve sınıflandırıcılarla sonuçlar alınmıştır. Örüntülerin ifade edilmesi için ortalama mutlak değer, kare kök ortalama, genliğin standart sapması, ortalama güç, genlik çarpıklığının mutlağı, genlik basıklığı, ortalama genlik değişimi, diferansiyel mutlak standart sapma, sıfır geçiş oranı, eğim işareti değişikliği, dalga formu uzunluğu, Willison genliği, Hjorth'un etkinlik parametresi, Hjorth'un hareketlilik parametresi, Hjorth'un karmaşıklık parametresi, genlik zarfının ortalaması ve genlik zarfının standart sapması olmak üzere 17 zaman düzlemi özniteliği kullanılmıştır. Öznitelikler mümkün oldukça farklı bilgileri içerecek şekilde seçilmiştir ancak yapıları gereği benzer kısımları bulunur. Oluşturulan öznitelik vektörleri $[0, 1]$ aralığına normalize edilerek sınıflandırıcılara girdi olarak verilmiştir. Öğrenmede K-EYK ve DVM yaklaşımları görevlendirilmiş ve bu algoritmaların bazı belirleyici parametre değerlerinin performansları sınanmıştır. Çünkü, bu algoritmaların farklı parametreleri sınıflandırma doğruluğu, hesaplama zamanı ve karmaşıklığı açısından farklı performanslar gösterebilir.

Çalışmaların ilk kısmı farklı günlere ait oturumlarla oluşturulan eğitim ve test kümelerinde yürütülmüştür. Burada, ilk oturumda kaydedilen veriler eğitim, ikinci oturumda kaydedilenler ise test aşamasında kullanılmıştır. Eğitim ve test kümelerinin bu şekilde oluşturulması literatür ile yapılacak kıyaslamaların geçerliliği için önemlidir. Çalışmaların ikinci kısmında öncelikle iki farklı günde kaydedilen oturum verileri birleştirilmiştir. Daha

sonra, tüm veri havuzu %50-%50, %70-%30, %90-%10 oranlarıyla eğitim ve test kümelerine ayrılmıştır. Tablo 3.15'te deneme sayıları verilen bu ayırmda eğitim ve test kümelerinde örtüşen eleman yoktur. Eğitim ve test kümelerinde farklı kategorilerdeki örnek sayıları neredeyse aynıdır. Deneylein performansları 15 koşulmla doğruluk ve Cohen'in kappa değeri ile hesaplanmıştır. %50-%50, %70-%30, %90-%10 eğitim test oranları ile alınan sonuçlarda eğitim test kümeleri 15 kere rastgele oluşturulmuş ve bu kümelere sonuçlar alınmıştır. Her denek ve problem için, K-EYK, DVM ve önerilen yöntemlerinin optimum sınıflandırma parametreleri eğitim kümesinden elde edilen alt eğitim ve doğrulama kümeleri ile belirlenmiştir. Test kümesindeki hiçbir örnek eğitim için kullanılmamıştır. Performans değeriinin koşullar boyunca ortalamaları ve standart sapmaları hesaplanarak nihai sonuçlar hesaplanmıştır. Ayrıca, denekler boyunca ortalama ve standart sapma değeri de hesaplanmıştır.

K-EYK ile sınıflandırmada öznitelik vektörlerinin birbirlerine uzaklıklarının hesaplanmasında kullanılan uzaklık ölçütü ve karar verme aşamasında en yakın kaç komşunun göz önüne alınacağını ifade eden k değeri için performanslar değerlendirilmiştir. Uzaklıkların hesaplanmasında öklid, korelasyon, kosinüs, chebychev, manhattan, minkowski ve spearman ölçütleri kullanılmıştır. Ek olarak, k parametresi için sonuçlar 1 ile eğitim havuzundaki eleman sayısının dörtte birine kadar tek değeri için hesaplanmıştır. En yakın k komşu değeriinin üst limiti ön performans değerlendirmeleriyle belirlenmiştir. Ön performans değerlendirmeleri sonucunda, öznitelik vektörleri [0, 1] aralığında normalize edilerek sınıflandırıcılara girdi olarak verilmiştir. Sınıflandırmada Matlab 2018b ortamındaki ClassificationKNN.fit paketi kullanılmıştır. Güncel hali olan fitcknn paketi [181] benzer işlemlere sahiptir. Farklı oturmlar ve %50-%50, %70-%30 ve %90-%10 eğitim test oranlarında denekler ve denek havuzunda ortalama alınan en başarılı performans değeriinin kıyaslamaları Tablo 3.20'deki gibidir.

Tablo 3.20. Farklı eğitim test oranlarında K-EYK ile sınıflandırma sonuçları

Denek	Farklı Oturumlar		%50-%50		%70-%30		%90-%10	
	Doğruluk	Kappa	Doğruluk	Kappa	Doğruluk	Kappa	Doğruluk	Kappa
D01	%65.4±5.2	0.3±0.1	%66.3±16.1	0.3±0.3	%71.3±13.1	0.4±0.3	%74.0±24.8	0.5±0.4
D02	%67.4±15.2	0.3±0.3	%68.8±10.4	0.4±0.2	%79.3±21.3	0.6±0.4	%79.2±26.8	0.6±0.6
D03	%63.9±19.6	0.3±0.4	%68.9±18.4	0.4±0.4	%67.7±16.4	0.4±0.3	%69.5±19.0	0.4±0.4
D04	%61.7±4.2	0.2±0.1	%63.0±17.4	0.3±0.4	%63.9±28.5	0.3±0.6	%67.6±9.2	0.3±0.2
D05	%66.6±8.9	0.3±0.2	%58.4±12.1	0.2±0.2	%58.6±24.4	0.2±0.5	%68.0±5.7	0.4±0.1
D06	%66.5±13.1	0.3±0.3	%61.6±7.7	0.2±0.2	%65.2±20.4	0.3±0.4	%69.1±13.4	0.3±0.4
D07	%62.2±17.1	0.2±0.3	%64.7±16.2	0.3±0.3	%69.0±15.4	0.4±0.3	%66.3±14.2	0.2±0.3
D08	%75.5±17.1	0.5±0.3	%80.9±6.6	0.6±0.1	%77.9±16.1	0.5±0.4	%80.0±20.0	0.6±0.4
ORT	%66.2±4.3	0.3±0.1	%66.6±6.8	0.3±0.1	%69.1±7.0	0.4±0.1	%71.7±5.4	0.4±0.1

Farklı oturumlar için en iyi sonuçlar D01 ve D04 denekleri için 6.0 sn - 7.5 sn; D02, D03, D05-D08 için ise sırasıyla 7.0 sn - 8.0 sn, 6.5 sn - 8.0 sn, 5.5 sn - 7.5 sn, 5.5 sn - 6.5 sn, 7.0 sn - 8.5 sn, 6.0 sn - 8.0 sn zaman dilimlerinde elde edilmiştir. Frekans bantlarında, D01, D02 ve D04 denekleri için 8-40 Hz; D03, D05 ve D07 için 8-12 Hz; D04 ve D06 için ise 13-30 Hz bantları başarılıdır. %50-%50 eğitim test oranında en başarılı sonuçlar D04 ve D08 denekleri için 5.5 sn - 7.5 sn; D05 ve D07 için 7.0 sn - 8.5 sn; D01-D03 ve D06 için ise sırasıyla 6.5 sn - 8.5 sn, 6.5 sn - 7.5 sn, 7.0 sn - 8.0 sn, 6.5 sn - 8.0 sn zaman dilimlerinde alınmıştır. Frekans bantlarında, D01, D05 ve D08 için 8-40 Hz; D02, D06 ve D07 için 13-30 Hz; D03 ve D04 için ise 8-12 Hz başarılı olmuştur. %70-%30 eğitim test oranında, en iyi sonuçlar D03-D05 denekleri için 7.5 sn - 8.5 sn; D01-D02 ve D06-D08 için ise 6.0 sn - 7.5 sn, 6.0 sn - 8.0 sn, 6.5 sn - 8.0 sn, 6.0 sn - 7.0 sn, 5.5 sn - 7.5 sn zaman dilimlerinde alınmıştır. Frekans bantlarında, D01-D02, D05 ve D08 denekleri için 8-40 Hz; D03 ve D06 için 8-12 Hz; D04 ve D07 için sırasıyla 4-40 Hz ve 13-30 Hz bantları başarılıdır. %90-%10 eğitim test oranında, en iyi performanslar D01 ve D06 için 7.0 sn - 8.0 sn; D02 ve D08 için 6.0 sn - 8.0 sn; D03-D05 ve D07 için ise sırasıyla 7.0 sn - 8.5 sn, 7.0 sn - 8.0 sn, 6.0 sn - 7.0 sn ve 6.5 sn - 7.5 sn dilimlerinde alınmıştır. Frekans bantlarında, D02 ve D04 için 8-40 Hz; D06-D08 için 13-30 Hz; D01, D03 ve D05 için sırasıyla 4-40 Hz, 8-12 Hz ve 8-30 Hz başarılıdır.

Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları incelenmiştir. İncelemede, tüm eğitim test oranları, koşumlar, denekler boyunca en

başarılı sonuçlar üreten yöntemlerin parametreleriyle bir havuz oluşturulmuş ve sonrasında her parametrenin veya aralığın yüzde ne kadar katkı sağladığı hesaplanmıştır. En iyi sonuçların yaklaşık %38'i 8-40 Hz, %28'i 13-30 Hz, %25'i 8-12 Hz bantlarında alınmıştır. Diğer frekans bantları kayda değer sonuç üretmemiştir. Zaman dilimlerinde en başarılı performansların yaklaşık %41'i 1 sn'lik, %31'i 1.5 sn ve %28'i 2 sn'lik zaman dilimlerinde alınmıştır. Bu sonuçlar, MHH görevlerinin K-EYK ile sınıflandırılmasında 1 sn sabit uzunluklu zaman dilimleri ve 8-40 Hz frekans bandının oldukça başarılı olabileceğini gösterir. Farklı oturumlarda en başarılı sonuçlar en yakın ilk komşulukla alınmıştır. Artan komşuluklarda ise gittikçe azalan doğrultuda sonuçlar gözlenmiştir. Tüm senaryolar boyunca en başarılı sonuçlar D08 denegine ait örüntülerde görülmüştür. D01 ve D02 deneklerinde eğitim kümesindeki eleman sayısı arttıkça çoğunlukla performans artmıştır. Bunun nedeni, eğitim kümesindeki eleman sayısı ve çeşitliliğinin performansa olumlu yönde etki etmesi olarak düşünülebilir. Diğer deneklerde doğrusal artan bir eğilim görülmesine rağmen genel olarak yüksek bir başarı elde edilmemiştir. Özellikle tüm deneme havuzunun karıştırılmasıyla oluşturulan eğitim test kümelerinde denekler bazında koşullar boyunca standart sapmalar oldukça yüksektir. Denekler boyunca ortalama standart sapma ise daha düşüktür ama ortalama performans istenen seviyede değildir. Doğruluk ve kapa değerleri için benzer yönde sonuçlar elde edilmiştir, ancak kapa için sonuçlar daha ayrıktır. Kapa ölçütünün keyfi sınıflandırma doğruluğunu elimine etmeye çalışması daha ayrı sonuçların en önemli nedenlerindedir. Ayrıca, eğitim kümesindeki örnek sayısının denekler bazında yetersiz olabilmesi ve örüntü tanımadaki problemler diğer önemli faktörlerdir.

DVM ile sınıflandırma da çekirdek fonksiyonu olarak doğrusal, çok terimli ve radyal tabanlı çekirdekler kullanılmıştır. Ön performans değerlendirmeleri sonucunda, öznelik vektörleri [0, 1] aralığında normalize edilerek sınıflandırıcılara girdi olarak verilmiştir. İki sınıflı problemlerin eğitiminde Matlab 2018b ortamındaki Support Vector Machine kütüphanesinin fitcsvm paketi kullanılmıştır [180]. Örneğin, radyal tabanlı çekirdeklerde 'KernelScale', 'auto' parametre değeriyle otomatik ölçek değeri aranmış, tahmin edicilerin standartlaştırılmasında 'Standardize', 'true' değeri kullanılmıştır. Farklı oturumlar ve %50-%50, %70-%30 ve %90-%10 eğitim test oranlarında denekler ve denek havuzunda ortalama alınan en başarılı performans değerlerinin kıyaslamaları Tablo 3.21'deki gibidir.

Tablo 3.21. Farklı eğitim test oranlarında DVM ile sınıflandırma sonuçları

Denek	Farklı Oturumlar		%50-%50		%70-%30		%90-%10	
	Doğruluk	Kappa	Doğruluk	Kappa	Doğruluk	Kappa	Doğruluk	Kappa
D01	%69.4±13.1	0.4±0.3	%70.4±9.3	0.4±0.2	%70.2±19.1	0.4±0.3	%75.0±26.7	0.6±0.4
D02	%64.9±10.3	0.3±0.2	%76.4±29.1	0.5±0.3	%81.1±24.6	0.6±0.5	%84.2±21.7	0.7±0.5
D03	%73.9±19.5	0.5±0.4	%71.5±18.1	0.4±0.4	%70.3±14.2	0.4±0.3	%70.5±16.1	0.4±0.4
D04	%67.7±5.6	0.4±0.1	%67.8±21.5	0.3±0.5	%71.1±21.2	0.4±0.4	%66.7±38.2	0.3±0.8
D05	%60.1±15.1	0.2±0.3	%58.3±17.2	0.2±0.3	%60.3±20.5	0.2±0.3	%68.7±22.6	0.4±0.3
D06	%64.8±12.7	0.3±0.3	%64.9±12.8	0.3±0.3	%73.9±26.3	0.5±0.5	%76.4±13.8	0.5±0.3
D07	%64.6±7.7	0.3±0.2	%69.1±17.9	0.4±0.4	%70.7±14.5	0.4±0.3	%70.2±27.0	0.4±0.3
D08	%64.7±10.7	0.3±0.2	%67.0±18.6	0.3±0.3	%76.7±16.0	0.5±0.4	%85.5±22.8	0.7±0.5
ORT	%66.2±4.1	0.3±0.1	%68.2±5.3	0.4±0.1	%71.8±6.0	0.4±0.1	%74.6±7.0	0.5±0.2

Farklı oturumlar için en iyi sonuçlar D01-D08 denekleri için sırasıyla 7.0 sn - 8.0 sn, 6.5 sn - 7.5 sn, 6.0 sn - 8.0 sn, 5.5 sn - 7.5 sn, 6.5 sn - 8.5 sn, 5.5 sn - 6.5 sn, 7.5 sn - 8.5 sn, 6.5 sn - 8.0 sn olacak şekilde farklı zaman dilimlerinde alınmıştır. Frekans bantlarında, D03-D04 ve D06-D08 denekleri için 13-30 Hz; D01-D02 ve D05 için sırasıyla 8-30 Hz, 8-12 Hz ve 8-40 Hz başarılıdır. %50-%50 eğitim test oranında, en başarılı performanslar D01 ve D05 denekleri için 7.5 sn - 8.5 sn; D04 ve D08 için 6.5 sn - 8.5 sn; D02-D03 ve D06-D07 için ise sırasıyla 6.0 sn - 7.5 sn, 5.5 sn - 6.5 sn, 6.0 sn - 7.0 sn, 6.5 sn - 7.5 sn dilimlerinde gözlenmiştir. Frekans bantlarında, D02, D07-D08 denekleri için 8-40 Hz; D05-D06 için 8-30 Hz; D01, D03 ve D04 için ise sırasıyla 4-40 Hz, 13-30 Hz ve 4-40 Hz başarılıdır. %70-%30 eğitim test oranında, en iyi performanslar D01 ve D04 denekleri için 7.5 sn - 8.5 sn; D02 ve D05 için 6.5 sn - 8.5 sn; D03 ve D06-D08 için ise sırasıyla 7.0 sn - 8.5 sn, 6.5 sn - 7.5 sn, 6.0 sn - 7.0 sn, 5.5 sn - 7.5 sn dilimlerinde üretilmiştir. Frekans bantlarında, D01 ve D04 denekleri için 4-40 Hz; D02 ve D04 için 8-40 Hz; D06 ve D07 için 13-30 Hz; D03 ve D05 için sırasıyla 8-12 Hz ve 8-30 Hz başarılıdır. %90-%10 eğitim test oranında, en iyi performanslar D01, D04 denekleri için 7.0 sn - 8.0 sn; D05 ve D07 için 7.5 sn - 8.5 sn; D02-D03, D06 ve D08 için ise 6.0 sn - 8.0 sn, 6.5 sn - 8.5 sn, 6.5 sn - 8.0 sn, 5.5 sn - 7.5 sn dilimlerinde elde edilmiştir. Frekans bantlarında, D01 ve D05 denekleri için 4-40 Hz; D07-D08 için 13-30 Hz; D02-D04 ve D06 için 8-40 Hz, 8-12 Hz, 13-30 Hz ve 8-30 Hz başarılıdır.


Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları incelenmiştir. İncelemede, tüm eğitim test oranları, koşumlar, denekler boyunca en başarılı sonuçlar üreten yöntemlerin parametreleriyle bir havuz oluşturulmuş ve sonrasında her parametrenin veya aralığın yüzde ne kadar katkı sağladığı hesaplanmıştır. En iyi sonuçların yaklaşık %35'i 13-30 Hz, %22'si 8-40 Hz, %19'u 4-40 Hz, %16'sı 8-30 Hz ve %9'u 8-12 Hz bantlarında alınmıştır. Zaman dilimlerinde ise tüm problem havuzunun %53'ünde 1 sn'lik, %34'ünde 2 sn ve %13'ünde ise 1.5 sn'lik zaman dilimleri başarılıdır. Bu sonuçlar MHH görevlerinin DVM ile sınıflandırılmasında 1 sn'lik zaman dilimi ve 13-30 Hz bandının daha başarılı sonuçlar üretebileceğini gösterir. Farklı oturumlardan alınan sonuçlar incelendiğinde, en başarılı sonuçların %41'i radyal tabanlı, %37'si doğrusal ve %22'si çok terimli çekirdeklerle alınmıştır. Tüm senaryolarda en başarılı sonuçlar D02 ve D08 denekleri için alınmıştır. Diğer deneklerde de eğitim kümesindeki deneme sayısı arttıkça performans çoğunlukla artmıştır. Bu sonuç, eğitim kümesindeki eleman sayısı ve çeşitliliğinin performansa katkısı olarak düşünülebilir. D04 ve D05 deneklerinde istenen seviyede başarı gözlenmemiştir. Özellikle tüm deneme havuzunun karıştırılmasıyla oluşan eğitim test kümelerinde denekler bazında koşumlar boyunca standart sapmalar oldukça yüksektir. Doğruluk ve kappa ölçütleri için benzer doğrultuda sonuçlar gözlenmiştir, ancak kappa için sonuçlar daha ayrıktır. Kappa ölçütünün keyfi sınıflandırma doğruluğunu elimine etmeye çalışması daha ayrık sonuçların en önemli nedenlerindedir. Ayrıca, eğitim kümesindeki örnek sayısının denekler bazında yetersiz olabilmesi ve örüntü tanımadaki problemler diğer önemli faktörlerdir.

3.3.2.3. Transfer Öğrenme ile ESA İçin Sonuçlar ve Analizler

Evrışimli sinir ağları (ESA) yüksek miktarda eğitim verisi ve hesaplama maliyeti gereksinimleri içerir. Bilindiği gibi BMA'lar genelde az sayıda veri içerir. Tez çalışmasının bu kısmında, bu problemlere belirli düzeyde çözüm sunmak için çeşitli nesne tanıma problemlerde öğrenilmiş modeller transfer öğrenme teknikleriyle MHH-BMTA veri setindeki görevlerinin sınıflandırılmasına uygulanmıştır. ESA'lar özellikle nesne tanıma ve görüntü sınıflandırma problemlerinde oldukça başarılıdır. Bu nedenle, EEG sinyallerinin görüntü sınıflandırma problemleri için önerilen ESA'lara uygulanması için sinyaller

görüntülere dönüştürülmelidir. Tez çalışmasında, EEG sinyalleri 2-B modelleme görüntülerine dönüştürülmüştür. Ayrıca, AlexNet, GoogLeNet ve SqueezeNet ESA'larıyla çeşitli problemlerden öğrenilen öznetelik ve modeller transfer öğrenmeyle hareket hayali görevlerinin sınıflandırılmasına aktarılmıştır. İki kategorili problemlerde çalışıldığından tam bağlı katmanların sonuncusu olan softmax katmanı 2 yollu olarak ayarlanmıştır. Başlangıç öğrenme oranı $1e-4$, optimizasyon yöntemi tipi olasılıksal gradyan alçalma, maksimum eğitim tur sayısı 50 olarak belirlenmiştir. Sınıflandırma da belirli sayıda validasyon sonrasında en başarılı performans geçilmezse ağırlık eğitimi durdurulmuştur. En iyi mini-batch boyutu 8, 32, 64 değerlerinde aranmıştır. Her denek ve problem için eğitim kümesinden elde edilen alt eğitim ve doğrulama kümeleriyle optimum sınıflandırma parametreleri belirlenmiştir. Test kümesindeki hiçbir örnek eğitim için kullanılmamıştır.

Evrişimli sinir ağları için yeterli miktarda eğitim verisi bulundurma gerekliliği problemlerini çözmek için literatürde veri artırımı ve sentetik veri üretme gibi birçok yöntem önerilmiştir. Çalışmalarda öncelikle modelleme görüntülerine öteleme, döndürme ve ölçeklendirme uygulanarak performans gözlenmiştir. Ancak, kayda değer başarı elde edilmemiştir. EEG sinyallerinin aslında görüntü sinyalleri olmaması ve modelleme görüntülerinin aslında yapay temsiller olması bunun nedeni olabilir. Çalışmada veri artırımı için de farklı bir yol denenmiştir. Bu yaklaşımda, öncelikle eğitim kümesindeki tüm denemelerin 6.0 sn ile 8.5 sn aralığında MHH ile ilişkili 2.5 sn'lik zaman dilimleri çıkarılmıştır. Ardından, kayan pencereler 2 sn pencere uzunluğu ve 0.1 sn örtüşme miktarı parametreleriyle uygulanarak 2 sn'lik zaman dilimleri çıkarılmıştır. Test kümesinde ise 2.5 sn'lik MHH görevinin tam ortasına denk gelen 6.25 sn - 8.25 sn aralığına ait zaman dilimi kullanılmıştır. Veri artırımı sonrasında, δt eşik değeri 0.05, matris boyutu 200×200 , Gauss çekirdeği ($w=[21 \times 21]$, $\sigma=4.0$) alınarak sinyaller birleştirilmiş modelleme görüntülerine dönüştürülmüştür. Örneğin, D04 deneği için eğitim kümesine ait tıklama ve kaydıma MHH görevlerinin birleştirilmiş modelleme görüntüleri sırasıyla Şekil 3.15 (a) ve (b)'de, test kümesine ait tıklama ve kaydıma görevlerinin birleştirilmiş modelleme görüntüleri ise sırasıyla Şekil 3.15 (c) ve (d)'deki gibidir.



Şekil 3.15. Tıklama ve kaydırma görevleri için birleştirilmiş modelleme görüntüleri

%90-%10 eğitim test oranlarıyla denekler ve denekler boyunca ortalama alınarak en başarılı performans değerleri Tablo 3.22'deki gibidir. Tablolardaki değerler rastgele oluşturulmuş 5 farklı eğitim test kümesine ait koşumların ortalama ve standart sapmaları alınarak hesaplanmıştır. Ayrıca, denekler boyunca doğruluk ve Cohen'in kappa değerlerinin ortalama ve standart sapmaları da verilmiştir. En başarılı sonuçlar D01, D02, D06 ve D07 denekleri için SqueezeNet'le sırasıyla %84.00±6.52, %82.50±5.43, %81.82±6.43 ve %84.21±5.26; D03 ve D05 için GoogLeNet'le sırasıyla %83.16±5.77 ve %82.00±4.47; D04 ve D08 için ise AlexNet'le sırasıyla %82.86±2.61 ve %80.00±6.10 doğruluklarında elde edilmiştir. Denekler boyunca ortalama en iyi sonuç %81.97±1.88 oranında SqueezeNet'le elde edilmiştir. Kappa ölçütüyle de aynı deneklerde aynı ESA'larla başarılı sonuçlar gözlenmiş ve SqueezeNet ile denekler boyunca ortalama 0.62±0.04 değeri elde edilmiştir. Koşumlar boyunca deneklerde ve denekler boyunca ortalama elde edilen standart sapmalar oldukça kabul edilebilir seviyededir.

Sınıflandırma sonuçlarının hesaplanmasındaki tüm parametrelerin performansa katkıları incelenmiştir. İncelemede, koşumlar ve denekler boyunca en başarılı sonuçlar

üreten yöntemlerin parametreleriyle bir havuz oluşturulmuş ve sonrasında her parametrenin veya aralığın yüzde ne kadar katkı sağladığı hesaplanmıştır. 8, 32 ve 64 mini batch boyutları sırasıyla GoogLeNet'te %30, %42 ve %28; AlexNet'te %35, %33 ve %32; SqueezeNet'te ise %37, %27 ve %36 oranlarında başarı göstermiştir. Elektrotlar konumları göz önüne alındığında, C3 ve çevresindeki FC3, C1, CP3, C5 konumları %38.66; Cz ve çevresindeki FCz, C2, CPz, C1 konumları %28.25; C4 ve çevresindeki FC4, C6, CP4, C2 konumları ise %33.09 oranlarında başarılıdır.

Tablo 3.22. Farklı ESA'ların sınıflandırma sonuçları

Denek	AlexNet		GoogLeNet		SqueezeNet	
	Doğruluk	Kappa	Doğruluk	Kappa	Doğruluk	Kappa
D01	%82.00±8.37	0.60±0.21	%79.00±5.48	0.57±0.12	%84.00±6.52	0.67±0.13
D02	%81.67±6.32	0.62±0.12	%79.17±4.17	0.55±0.12	%82.50±5.43	0.63±0.13
D03	%80.00±2.35	0.58±0.06	%83.16±5.77	0.65±0.11	%82.11±4.71	0.62±0.08
D04	%82.86±2.61	0.63±0.04	%81.90±3.98	0.62±0.07	%80.95±3.37	0.58±0.08
D05	%76.00±5.48	0.49±0.10	%82.00±4.47	0.61±0.09	%82.00±8.37	0.62±0.18
D06	%80.00±4.07	0.56±0.10	%79.09±2.49	0.54±0.05	%81.82±6.43	0.63±0.11
D07	%80.00±6.86	0.59±0.14	%80.00±2.35	0.60±0.04	%84.21±5.26	0.66±0.13
D08	%80.00±6.10	0.60±0.12	%77.27±0.00	0.54±0.01	%78.18±6.74	0.56±0.13
ORT	%80.32±2.08	0.58±0.04	%80.20±1.97	0.59±0.04	%81.97±1.88	0.62±0.04

ESA'ların farklı transfer öğrenme yöntemleriyle uygulanmasının yanısıra çıktılarına çoğunluk oylama uygulanarak da sonuçlar alınmıştır. Elde edilen sonuçlar incelendiğinde, D01-D08 denekleri için ortalama doğruluklar sırasıyla %4.0, %5.83, %8.42, %5.71, %7.0, %4.54, %7.37 ve %6.36 oranlarında arttırmıştır. Denek havuzunda ortalama ise %81.97±1.88'den %88.72±2.01'e yükseltilmiştir. Ayrıca, tüm deneklerde yaklaşık 0.6 değerinde olan kappa değerleri D01-D08 denekleri için sırasıyla 0.75, 0.76, 0.83, 0.75, 0.77, 0.7, 0.83, 0.73 değerlerine çıkarılmıştır. Denekler boyunca ortalama ise 0.62±0.04'ten 0.76±0.04'e çıkarılmıştır (Tablo 3.23).

Tablo 3.23. ESA'ların çoğunluk oylama sınıflandırma sonuçları

Denek	Doğruluk	Kappa
D01	%88.00±2.74	0.75±0.07
D02	%88.33±5.43	0.76±0.10
D03	%91.58±6.00	0.83±0.13
D04	%88.57±4.26	0.75±0.10
D05	%89.00±8.22	0.77±0.17
D06	%86.36±7.19	0.70±0.17
D07	%91.58±2.88	0.83±0.06
D08	%86.36±3.21	0.73±0.06
ORT	%88.72±2.01	0.76±0.04


Dikkat edilecek olursa, başlangıç öğrenme oranı, optimizasyon yöntemi tipi, maksimum eğitim tur sayısı, mini-batch boyutu, durdurma adım sayısına ait parametre değerleri tek değerler ya da çok kısa aralıklarda sınanmıştır. İlerleyen çalışmalarda görüntüye dönüştürme yönteminde iyileştirmeler yapılarak ve daha geniş kapsamlı veri artırımı ile sınıflandırma performanslarının daha yukarı çekileceği düşünülmektedir.

3.3.2.4. Sınıflandırma Sonuçlarının Kıyaslanması

YODM kullanan topluluk öğrenme yöntemleri için kıyaslamalar literatürde sıklıkla kullanılan zaman düzlemi öznitelikleri, K-EYK ve DVM sınıflandırıcıları ile yapılmıştır. Kıyaslamaların ilk kısmı, farklı günlere ait oturumlarla oluşturulan eğitim ve test kümelerinde yürütülmüştür. İkinci kısmı ise, oturum verilerinin birleştirilmesi sonucu oluşan %50-%50, %70-%30, %90-%10 oranlarındaki eğitim test kümelerinde gerçekleştirilmiştir. %90-%10 eğitim test oranında ESA oylama da kıyaslamalar için kullanılmıştır.

Tıklama ve kaydırma MHH görevlerinin sınıflandırılmasında öncelikle farklı günlerde kaydedilen denemelerle oluşturulan yaklaşık %50-%50 oranındaki eğitim ve test kümeleri için kıyaslamalar yapılmıştır. Y8 ile tüm denekler boyunca ortalama doğruluk %66.20'den %78.94'e (%12.74 oranında) oldukça iyi seviyede yükseltilirken, standart sapma %0.83 oranında düşürülmüştür. Ayrıca, denekler bazında koşumlar boyunca standart sapma K-EYK ve DVM'ye göre oldukça düşürülmüştür. Bu başarı, sırasıyla D01-D08 deneklerinde


gözlenen %3.80, %10.38, %6.24, %12.68, %14.80, %17.26, %14.18 ve %0.62 oranlarındaki iyileştirmelerden kaynaklanmaktadır. Özellikle, D02 ve D04-D07 deneklerindeki artım oldukça iyidir. K-EYK ve DVM sadece belirli deneklerde başarılı olurken denekler boyunca genellikle yüksek standart sapma değerleriyle başarısız olmuştur (Şekil 3.16). Bu sonuçların nedeni, özellikle K-EYK ve DVM için eğitim kümesindeki örnek sayısı ve çeşitliliğinin yetersizliğidir. Ayrıca, öznelilikler arası ilişki daha iyi irdelenerek doğruluk arttırılabilir ve koşullar boyunca yüksek seviyedeki sapmalar azaltılabilir. Kappa ölçütü ile de doğrulukla benzer doğrultuda sonuçlar alınmıştır (bkz. Tablo 3.16, Tablo 3.20 ve Tablo 3.21).



Şekil 3.16. Farklı oturumlar için sınıflandırma doğruluk kıyaslamaları

Tıklama ve kaydırma MHH görevlerinin sınıflandırılmasında ikinci olarak %50-%50 oranındaki eğitim ve test kümeleri için kıyaslamalar yapılmıştır. Y8 ile tüm denekler boyunca ortalama doğruluk %68.2'den %79.3'e (%11.1 oranında) oldukça iyi seviyede yükseltilirken, standart sapma %1.62 oranında düşürülmüştür. Ayrıca, denekler bazında koşullar boyunca standart sapma K-EYK ve DVM'ye göre oldukça düşürülmüştür. Bu başarı, sırasıyla D01 ve D03-D07'de gözlenen %4.4, %10.7, %11.4, %21.5, %14.3 ve %16.9 oranlarındaki iyileştirmeler kaynaklıdır. Özellikle, D03-D07 deneklerinde artım oldukça iyi seviyededir. Diğer taraftan, DVM D02 için %1.4 ve K-EYK D08 için %2.9 oranında daha başarılıdır. Ancak, bu yöntemlerin standart sapmaları çoğu denekte oldukça yüksek seviyededir (Şekil 3.17). Bu sonuçların nedeni, özellikle K-EYK ve DVM için eğitim

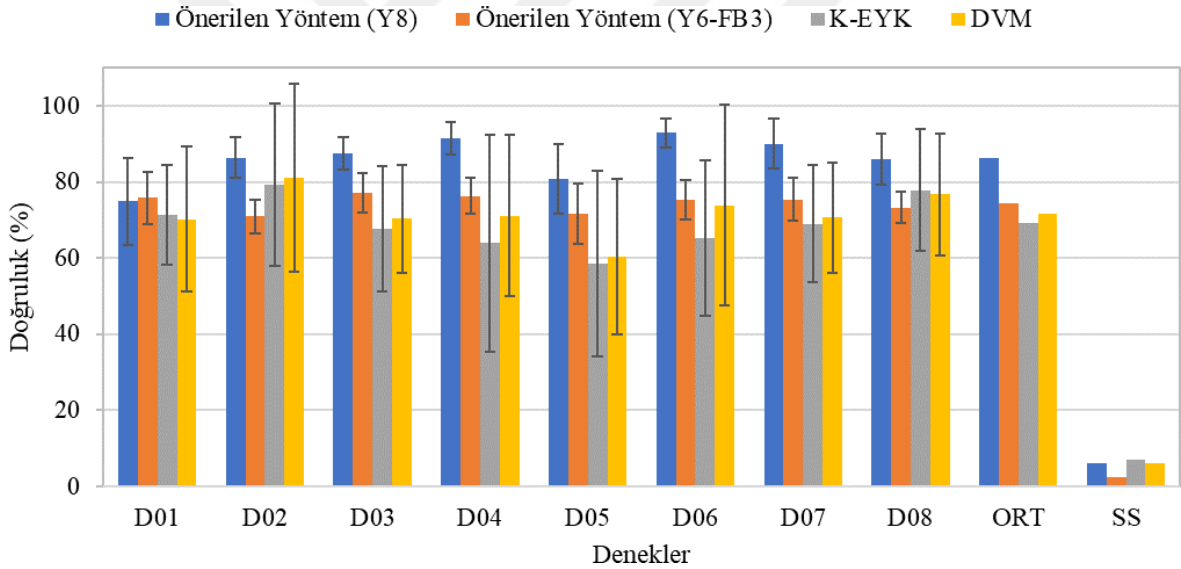
kümesindeki örnek sayısı ve çeşitliliğinin yeterli olmamasıdır. Ayrıca, öznelilikler arası ilişki daha iyi irdelenerek doğruluk artırılabilir ve koşullar boyunca yüksek seviyedeki sapmalar düşürülebilir. Kappa ölçütünde de doğrulukla benzer doğrultuda sonuçlar alınmıştır (bkz. Tablo 3.17, Tablo 3.20 ve Tablo 3.21). Farklı oturumlara ait yaklaşık %50-%50 oranına ait sonuçlar ile karıştırma sonucunda aynı orandaki sonuçlara bakılacak olursa, denekler boyunca ortalama da yaklaşık aynı seviyede performansın elde edildiği görülecektir. Denekler bazında ise bazı deneklerde karıştırılmamış verilerde, bazılarında ise karıştırılmış verilerde daha iyi sonuçlar alınmıştır. Bu sonuçların başlıca nedeni, MHH-BMTA veri seti için kayıtlar alınırken, her oturumda dört veya beş ara verilmesi ve temas kalitesi problemleri nedeniyle çoğu denekte başlığın çıkarılıp takılmasıdır.



Şekil 3.17. %50-%50 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları

Tıklama ve kaydırma MHH görevlerinin sınıflandırılmasında üçüncü olarak %70-%30 oranındaki eğitim ve test kümeleri için kıyaslamalar yapılmıştır. Y8 ile tüm denekler boyunca ortalama doğruluk %71.8'den %86.3'e (%14.5 oranında) oldukça iyi seviyede yükseltirken, standart sapma %0.07 düşürülmüştür. Ayrıca, denekler bazında koşullar boyunca standart sapma K-EYK ve DVM'ye göre oldukça düşürülmüştür. Bu başarı, D01 denegi için Y6 ve FB₃ ile %4.5, D02-D08 deneklerinde için ise sırasıyla %5.3, %17.3, %20.3, %20.6, %19, %19.4 ve %8 oranlarındaki iyileştirmeler kaynaklanır. Özellikle, D03-D07 denekleri için artım oldukça iyi seviyededir (Şekil 3.18). K-EYK ve DVM sadece belirli


deneklerde başarılı olurken denekler boyunca genellikle yüksek standart sapma değerleriyle başarısız olmuştur. Bunun nedeni, özellikle K-EYK ve DVM için eğitim kümesindeki örnek sayısı ve çeşitliliğinin yetersizliğidir. Ayrıca, öznelilikler arası ilişki daha iyi irdelenerek doğruluk artırılabilir ve koşullar boyunca yüksek seviyedeki sapmalar düşürülebilir. Kappa ölçütü için de doğrulukla benzer doğrultuda sonuçlar alınmıştır (bkz. Tablo 3.18, Tablo 3.20 ve Tablo 3.21). Son olarak, %50-%50 eğitim test oranına göre sonuçlar oldukça iyidir, ancak özellikle eğitim ve test kümesinin rastgele karıştırılması sebebiyle koşullar ve denekler boyunca standart sapmalar daha da yükselmiştir. Yarı olasılıksal dağılım modellerindeki bu performans artışı önerilen yaklaşımlar için eğitim kümesindeki eleman sayısı ve çeşitliliğinin pozitif yönde oldukça etkili olduğunu göstermektedir.



Şekil 3.18. %70-%30 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları

Tıklama ve kaydırma MHH görevlerinin sınıflandırılmasında dördüncü olarak %90-%10 oranındaki eğitim ve test kümeleri için kıyaslamalar yapılmıştır. Y8 ile tüm denekler boyunca ortalama doğruluk yine tez çalışmasında önerilen ESA oylamaya göre %88.8'den %97.9'a (%9.1 oranında) oldukça iyi seviyede yükseltilmiştir. Her iki yaklaşımında standart sapmaları oldukça kabul edilebilir seviyededir. Ayrıca, K-EYK ve DVM'ye göre denekler bazında koşullar boyunca ve ortalamada doğruluklar oldukça artırılmış ve standart sapmalar oldukça düşürülmüştür. Bu başarı, sırasıyla D01-D08 için %17.3, %14.4, %28.1, %30.8, %30.3, %22.4, %29.1 ve %12.4 oranlarındaki iyileştirmeler kaynaklanır. Ayrıca, K-

EYK ve DVM sadece belirli deneklerde başarılı olurken denekler boyunca genellikle yüksek standart sapmalarla başarısız olmuştur (Şekil 3.19). Bu sonuçların nedeni, özellikle K-EYK ve DVM için eğitim kümesindeki örnek sayısı ve çeşitliliğinin yetersizliğidir. Öznitelikler arası ilişki daha iyi irdelenerek doğruluk artırılabilir ve koşullar boyunca oldukça yüksek seviyedeki sapmalar düşürülebilir. Kappa ölçütü için de doğrulukla benzer doğrultuda sonuçlar alınmıştır (bknz. Tablo 3.19, Tablo 3.20 ve Tablo 3.21). Son olarak, %70-%30 eğitim test oranına göre performans oldukça iyileştirilmiş ve daha düşük standart sapmalar gözlenmiştir. Yarı olasılıksal dağılım modellerindeki bu performans artışı önerilen yaklaşımlar için eğitim kümesindeki eleman sayısı ve çeşitliliğinin pozitif yönde oldukça etkili olduğunu göstermektedir. Test kümesindeki örnek sayısının azalması bu başarıdaki diğer bir faktör olarak da görülebilir.



Şekil 3.19. %90-%10 eğitim test oranı için sınıflandırma doğruluk kıyaslamaları

4. SONUÇLAR

MHH görevlerine ait EEG sinyallerini kullanan BMA'ların oluşturulmasında örüntü tanıma yöntemlerinin kullanılması en başarılı yaklaşımlardandır. Bu yöntemlerin başarısı özellikle örüntü tanımanın iki önemli aşaması olan öznitelik çıkarma ve sınıflandırmanın performansına bağlıdır. Tez çalışmasında, MHH görevlerini kabul edilebilir seviyede sınıflandırabilecek özgün örüntü tanıma yöntemlerinin geliştirilmesi amaçlanmıştır.

Çalışmaların ilk kısmında, MHH görevlerine ait EEG sinyalleri özelleşmiş bir sonlu uzayda 2-B modellenerek yeniden oluşturulmuş ve YODM kullanan öğrenme modelleriyle sınıflandırılmıştır. Sinyal özniteliklerini çıkarmak için öncelikle iki yeni geçiş noktası özniteliği tanımlanmıştır. Tanımlamalarda yalnızca tepe geçiş noktaları değil çukur noktaları da kullanılmıştır. Daha sonra, sinyal boyunca çıkarılan öznitelik değerleri modellenerek 2-B öznitelikler elde edilmiştir. Öğrenme aşamasında, eğitim kümesindeki tüm örneklerle oluşturulan 2-B öznitelikler ve YODM kullanılmıştır. Karar verme aşamasında, maksimum olasılık değerlerine dayanan bir teknikle test örneklerinin kategori belirlenmiştir. Yöntemin geçerliliği, BCI Competition II yarışmasına ait Data Set Ia, BCI Competition IV yarışmasına ait Data Set Iia ve tez bünyesinde oluşturulan MHH-BMTA veri setlerinde sınanarak olumlu sonuçlar alınmıştır. Çalışmanın bu kısmının ana katkıları şu şekildedir.

1. EEG sinyalleri için yeni zaman düzlemi öznitelikleri önerilmiştir
2. İkili sınıflandırma problemleri için 2-B öznitelikler ve yarı olasılıksal dağılımlara dayanan bir öğrenme modeli sunulmuştur
3. Yöntemler basit bir algoritma üzerine kuruludur ve hesaplamaları kolaydır

Çalışmanın ikinci kısmında, YODM kullanan alt-sınıflandırıcılar oluşturulmuş ve topluluk öğrenme yöntemlerine uygulanmıştır. Ön sınıflandırma aşamasında, MHH ile ilişkisi frekans bantları, zaman dilimleri ve sensör elektrot konumları belirlenmiştir. Daha sonra, YODM uygulanmış alt sınıflandırıcılara ait etiketler veya sınıf olasılık değerleri topluluk öğrenme yöntemlerine girdi olarak verilmiştir. Bu kısımda oylama yöntemlerine bir ek olarak düşünülebilecek kombinyona dayalı oylama da önerilmiştir. Tüm bunlara ek olarak, yumuşak oylamada kullanılan sınıf olasılık değerleri için YODM'un karar vermede kullandığı olasılık çıktıları da kullanılmıştır. İlk deneysel çalışmalar Data Set Ia ve Data Set

IIa veri setlerinde gerçekleştirilmiştir. Data Set Ia veri setinde, sağlıklı bir deneğe ait bilgisayar imleç hareket hayali görevinde literatüre kıyasla ortalama sonuçlar alınmıştır. Özellikle eğitim kümesindeki eleman sayısının test kümesine kıyasla yeterli çeşitlilikte ve sayıda olmadığı bu gibi veri setlerinde performansın artırılması için iyileştirmeler yapılmalıdır. Data Set IIa veri setinde, dokuz denek ve altı sınıflandırma problemi için oluşan toplam 54 problemde ortalama $\%86.52 \pm 3.43$ doğruluk gözlenmiş ve problem havuzunun $\%40$ 'ında literatüre göre daha iyi performans değerleri elde edilmiştir. Bu sonuçların çoğunda, sınıflandırma performansları önceki çalışmalara kıyasla oldukça iyi seviyede artırılmış ve standart sapmalar oldukça iyi seviyede düşürülmüştür. Dokuz denek için ortalama performans değerlerinde, sol/sağ el ve ayaklar/dil MHH görevlerinde daha başarılı sonuçlar alınmıştır. Diğer dört problemde, az seviyede daha düşük sonuçlar elde edilmesine rağmen, ortalama performans ve standart sapma arası ödünleşim kabul edilebilir seviyededir. Denek havuzundaki standart sapma değerleri incelendiğinde, altı problemin tamamında $\%5.10$ - $\%10.06$ aralığında daha düşük standart sapmalar gözlenmiştir. Elde edilen sonuçlar, klasik oylama ve kombinasyona dayalı yöntemlerinin denekten-deneğe, görevden-göreve değişimler gibi problemlerde potansiyeli olduğunu göstermektedir. Çalışmanın bu kısmının belli başlı katkıları şu şekildedir.

1. Veri domaininden faydalanarak oylayıcılar oluşturan yeni bir yöntem önerilmiştir
2. Kombinasyon kullanan topluluk öğrenme teknikleri sunulmuştur
3. Yumuşak oylama için yeni bir sürekli değerler girdisi oluşturulmuştur

Tez çalışmasının üçüncü kısmında, kuramsal araştırmalara ek olarak problem domaininde yeniliklere gidilmiş ve MHH-BMTA veri seti oluşturulmuştur. Veri seti mobil telefonlarda sık kullanılan tıklama ve kaydırma el hareketi görevlerine ait MHH'lerini içermektedir. Mobil telefonlara yönelik böyle bir veri seti oluşturularak beyin-mobil telefon arayüzlerine katkı sağlanmıştır. Kayıtlar EPOC Flex kayıt cihazı ile kablosuz bir şekilde kaydedilerek pratik BMTA sistemleri hedefine de katkı sağlanmıştır. Önerilen yöntemlerin performansı sağlamlığı bilinen yarışma veri setleri dışında MHH-BMTA'da da sınanmıştır. $\%90$ - $\%10$ eğitim test oranında dokuz denek boyunca ortalama $\%97.86 \pm 2.27$ doğruluk elde edilmiştir. $\%50$ - $\%50$ oranındaki farklı oturumlara ait senaryodan $\%90$ - $\%10$ eğitim test oranına geçildiğinde performans önemli derecede artmıştır. Tüm denekler ve eğitim test

oranlarında, koşumlar ve denekler boyunca ortalama doğrulukta başarılı sonuçlar alınmış, standart sapmalar düşürülmüştür. Eğitim kümesindeki örnek sayısı ve çeşitliliği arttıkça performans artışlarının daha fazla olduğu görülmüştür. Ayrıca, 1 sn'lik zaman dilimleri hem MHH görevlerinin sınıflandırma performansında hem de hesaplama maliyetinde başarı sağlamıştır. Bu sonuçlar, mobil telefonlar için el hareketlerine ait MHH görevlerinin örüntü tanına yöntemleriyle sınıflandırılabilirliğini ve beyinle mobil telefonlar arasında bir arayüzün başarılı bir şekilde kurulabileceğini göstermektedir. YODM'da eğitim kümesindeki eleman sayısı ve çeşitliliği performansla oldukça etki etmiştir ve mobil telefonlardaki gibi daha zor hareket hayali görevlerinde bu gereksinimin daha arttığı görülmüştür. Çalışmanın bu kısmının başlıca katkıları şu şekildedir.

1. EPOC Flex ile pratik beyin mobil telefon arayüzleri için yeni bir veri seti oluşturulmuştur
2. Mobil telefonlarda tıklama ve kaydırma hareket hayallerinin sınıflandırılması araştırılmıştır ve geleneksel hareket hayali görevleriyle kıyaslamalar yapılmıştır
3. Beyinle mobil telefonlar arasında bir arayüzün kurulabileceği görülmüştür

Çalışmanın son kısmında, evrişimli sinir ağlarına görüntü girdisi olarak verilebilecek bir sinyal görüntü dönüşüm tekniği önerilmiştir. Dönüşüm çeşitli frekans bantlarına uygulanarak nihai birleştirilmiş modelleme görüntüleri oluşturulmuştur. MHH-BMTA veri seti az sayıda deneme içerdiğinden öncelikle kayan pencerelerle veri artırımı yapılmıştır. Daha sonra, ESA'larla çeşitli problemlerden öğrenilen öznelik ve modeller transfer öğrenmeyle MHH görevlerinin sınıflandırılmasına aktarılmıştır. Tekil ESA'ların yanısıra ESA sonuçları çoğunluk oylanarak da sonuçlar alınmıştır. ESA oylama denekler boyunca ortalama da 88.72 ± 2.01 doğruluk göstermiştir. Koşumlar ve denekler boyunca ortalama standart sapmalar çoğunlukla kabul edilebilir seviyededir. Görüntü sınıflandırma için inşa edilen ESA'larda EEG sinyallerinin görüntülere dönüştürülmesinin fayda sağlayacağı düşünülmektedir. Son yıllarda, ESA ve transfer öğrenme tekniklerinin görüntü sınıflandırmada artan başarıları göz önüne alındığında sinyallerin görüntülere dönüştürülerek ESA'lara uygulanması değerlidir. Çalışmanın bu kısmının belli başlı katkıları şu şekildedir.

1. Yeni bir sinyal-görüntü dönüşüm yöntemi önerilmiştir

2. Veri artırımı için EEG sinyallerinin yapısına daha uygun bir teknik kullanılmıştır
3. Nesne tanımda öğrenilmiş modeller hareket hayali görevlerine aktarılmıştır
4. ESA yöntemlerinin çıktıları oylanarak da sonuçlar alınmıştır

Önerilen yaklaşımların eğitim ve test aşamaları için hesaplama süreleri oldukça tatmin edici seviyededir. En başarılı sonuçları üreten yaklaşımlarla tüm veri setlerinde elde edilen ortalama eğitim süresi 15.51 sn ve test süresi 0.019 sn'dir. Örnek sayısı ve öğrenme modellerinin oluşturulma maliyetiyle ilintili eğitim süresi oldukça düşüktür. Dahası, test süresi oldukça kabul edilebilir seviyededir.



5. ÖNERİLER VE TARTIŞMA

Tez çalışmasında, öznitelik çıkarma ve sınıflandırma için yeni, özgün ve problem domainine uygun yöntemlerin tasarlanmasıyla MHH görevlerine ait EEG sinyallerini kullanan BMA'ların sağlamlıkları arttırılmaya çalışılmıştır. Sonuçlar incelendiğinde, birçok problemde denekler ve koşullar boyunca ortalama doğruluk değerlerinin arttırıldığı ve standart sapmanın da oldukça azaltıldığı görülmüştür. Başarılı sonuçların neredeyse tamamı tüm zaman dilimleri ve frekans bantlarında YODM'la oluşturulan alt sınıflandırıcılara çoğunluk oylama uygulanarak elde edilmiştir. Ancak, MHH görevlerinin sınıflandırılması için hem kuramsal hem de problem domaininde çözülmesi gereken birçok problem halen mevcuttur. Bu nedenle, tez çalışmasında önerilen örüntü tanıma tekniklerinin istatistiksel, deneysel ve uygulama gücü ilerleyen çalışmalarla arttırılmalıdır.

Önerilen yöntemlerde gürültü, durağan olmayan yapı, denekten-deneğe ve oturumdan-oturuma farklılıklar gibi problemler kaynaklı hatalarının düşürülmesi ve daha başarılı sonuçların alınması için düzenlemelere gidilmelidir. Zamanla hızla değişim gösterebilen EEG sinyallerinin öznitelikleri de durağan değildir. Bu gibi problemlerin çözümü önerilen öznitelik çıkarma yöntemleri zenginleştirilmeli ve gerekirse uyarlanabilir güncelleştirmeler yapılmalıdır. Yarı olasılıksal dağılım modelleri de birçok parametreye sahiptir ve eğitim için fazla sayıda örneğe ihtiyaç duyar. Durağan olmayan yapı nedeniyle önceki verilerle oluşturulmuş bir sınıflandırma modeli aynı kişi için farklı oturumlarda bile başarısız olabilir. Bu nedenle, sınıflandırma yöntemleri daha iyi analiz edilerek sağlamlıkları arttırılmalı ve otomatik parametre belirlemeye yönelik uyarlanabilir iyileştirmeler yapılmalıdır. Böylelikle, öznitelik dağılımındaki değişimler sınıflandırıcı tarafından izlenebilir ve EEG gibi durağan olmayan sinyallerde bile denekten-deneğe, oturumdan-oturuma başarı sağlanabilir. Tüm bu iyileştirmeler yapılırken hesaplama maliyeti de göz önüne alınmalı ve sınıflandırıcılar başarı-zaman ödünleşimi dikkate alınarak kısa sürede eğitilmelidir. Çünkü, önerilen örüntü tanıma tekniklerinin en büyük dezavantajı en iyi eğitim parametrelerini belirlemek için gereksinim duyduğu süredir. İkili sınıflandırma dışında daha fazla kategorideki problemler göz önüne alındığında bu sorun daha dikkat çekici hale gelmektedir.

Çalışmalarda, hareket hayali görevlerinin zorluğu ve hassasiyeti artıkça performansın korunması için daha başarılı yöntemlere ihtiyaç duyulduğu görülmüştür. MHH-BMTA veri setinde %90-%10 eğitim test oranında oldukça başarılı performans değerleri gözlenmiştir

ancak, örnek dağılımı %50-%50 oranına doğru azaldıkça başarının düştüğü ve standart sapmanın arttığı gözlenmiştir. Her bir denek için ihtiyaç duyulan eğitim örneği sayısı farklı olabileceğinden, standart sapmadaki artış denekten-deneğe farklılık gösterebilmektedir. YODM'daki performans değerleri eğitim kümesindeki eleman sayısı ve çeşitliliğinin pozitif yönde oldukça etkili olduğunu göstermektedir. MHH görevlerine ait EEG sinyallerini kullanan BMA'ların genelde az sayıda eğitim örneği içerdiği göz önüne alındığında, önerilen yöntemlerde eksik öğrenme problemlerini giderecek düzenlemelere gidilmelidir. Farklı oturumlarda kaydedilen EEG sinyallerinde bile farklılıkların olabileceği, aynı kişi için bile eğitim kümesinin zamanla güncelliğini kaybederek sonraki kullanımlarda elverişsiz olabileceği düşünüldüğünde gereken düzenleme ihtiyacı daha da artar. YODM kullanan topluluk öğrenme yöntemlerinin standart sapmaları oylamanın da katkısıyla denekler boyunca ve denekler bazında koşumlar boyunca ortalamada genelde düşüktür. Ancak, özellikle eğitim ve test kümesinin rastgele karıştırılması sonucunda koşumlar ve denekler boyunca standart sapma değerleri bazı deneklerde yükselmiştir. Bu nedenle, denekten-deneğe ve oturumdan-oturuma farklılıklar içeren problemlerde daha kuvvetli karar vermek için iyileştirmeler yapılmalıdır. MHH-BMTA için K-EYK ve DVM ile alınan sonuçlarda yüksek standart sapma değerleri gözlenmiştir. Öznitelik seçme teknikleriyle öznitelikler arası ilişki daha iyi incelenerek ve öznitelikler zenginleştirilerek bu problemler çözümlenmelidir.

YODM'da yapılması gereken düzenlemelere ek olarak literatürde başarısı bilinen yöntemlerden eklemelerle de önerilen yöntemlerin sınıflandırma başarısı artırılmalıdır. Bu amaçla hem önerilen yöntemlerde iyileştirmeler hem de sınıflandırma akışına eklemeler yapılabilir. Tez çalışmasında, MHH ilişkili konumlardaki sensör elektrotlarla kaydedilen sinyaller sınıflandırma aşamasında ayrı ayrı kullanılmıştır. Ancak, en faydalı elektrotların seçilmesi ve ilişkisiz verilerin kaldırılması OUÖ'lerle gerçekleştirilebilir. 2-B özniteliklerin birbirlerine veya YODM'lara olan olabilirlik kestirimleri beklenti maksimizasyonu ve artan eğim algoritmaları gibi çeşitli tekniklerle yapılabilir. 2-B öznitelikler farklı sınıflandırıcılara veya YODM farklı öznitelik çıkarma tekniklerine uygulanabilir. Örneğin, EEG sinyallerinin zaman-frekans dönüşümleri YODM ile sınıflandırılabilir. YODM başarısı bilinen diğer yöntemlerle birleştirilebilir. Birleştirme öznitelik vektörleri birbirlerine eklenerek veya sınıflandırma çıktıları karar vermede oylanarak yapılabilir. Topluluk öğrenme MHH görevlerinin sınıflandırılmasında diğer alanlardaki kadar detaylı incelenmemiştir ve bu alanda önemli derecede potansiyel içermektedir. Bunlara ek olarak, EEG sinyalleri MEG

gibi çeşitli görüntüleme yöntemlerinin çıktıları ile çok modlu birleştirilebilir. Literatürde özellikle ses tanımada oldukça başarı elde edilmiştir ve elde edilen bu başarının MHH görevlerinin sınıflandırılmasına da katkı sağlayacağı muhtemeldir. Bu nedenle, zaman serilerinin analizi için önerilen yöntemler değiştirilerek veya tez çalışmasında önerilen yöntemlere uyarlanarak MHH görevlerinde kullanılabilir. Ayrıca, çeşitli biyolojik ve fizyolojik sinyal analiz teknikleri için önerilen örüntü tanıma yaklaşımları doğrudan veya EEG sinyallerinin yapısına uyarlanarak MHH görevlerinde kullanılabilir. Son olarak, ESA'lar için önerilen görüntü temsilleri zenginleştirilebilir ve farklı DSA'lara uygulanabilir. Ek olarak, nesne tanımada öğrenilmiş modellerin aktarımı yerine, EEG sinyalleri için oluşturulan ESA'larda önerilen modelleme görüntülerinin performansları test edilebilir.

Sınıflandırma için literatürde oldukça başarılı yaklaşımlar önerilmiştir. Ancak MHH sinyallerine ait örüntülerin çıkarılması için özellikle öznitelik çıkarma aşamasında mevcut birçok problemin çözümü için araştırmalar yapılmalıdır. Gerçek zamanlı çalışması istenen MHH arayüzleri göz önüne alındığında hem öznitelik çıkarma hem de sınıflandırmada performans ve başarıdan ödün vermeden çalışacak kuvvetli teknikler araştırılmalıdır. Çünkü, çok sayıda umut vaat eden sonuçlara rağmen pratik sistemler halen gürültü, aykırı değer, durağan olmayan yapı, uzun kalibrasyon ve eğitim süreleri, denekten-deneğe ve oturumdan-oturuma farklılıklar, düşük sağlamlık ve güvenilirlik gibi birçok problemten muzdariptir. Tez çalışmasında sunulan tekniklerin bu sorunları çözmesi, sağlamlık ve geçerliliğinin tamamen ortaya konması için başka güncel veri setlerinde de başarısı sınanmalıdır. Ayrıca, problem belirleme ve sonrasında tekniklerde iyileştirme yapma döngüsü sürekli yürütülerek kuramsal ve uygulama kaynaklı eksiklikler giderilmelidir. Böylelikle, laboratuvar ortamına bağımlı modeller daha ileri taşınarak pratik arayüzlerin önü açılacaktır.

6. KAYNAKLAR

1. Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F. ve Arnaldi, B., A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces. Journal of Neural Engineering, 4, 2 (2007) 1-13.
2. Nicolas-Alonso, L. F. ve Gomez-Gil, J., Brain Computer Interfaces, A Review, Sensors, 12, 2 (2012) 1211-1279.
3. Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A. ve Yger, F., A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces: A 10 Year Update, Journal of Neural Engineering, 15, 3 (2018) 1-28.
4. Tahernezhad-Javazm, F., Azimirad, V. ve Shoaran, M., A Review and Experimental Study on the Application of Classifiers and Evolutionary Algorithms in EEG-Based Brain-Machine Interface Systems, Journal of Neural Engineering, 15, 2 (2018) 1-39.
5. <https://www.findaphd.com/phds/project/multimodal-control-of-prosthetic-limbs-paralysed-muscles/?p80740> Multimodal Control of Prosthetic Limbs/Paralysed Muscles. 09 Kasım 2020.
6. Wolpaw, J. R., Birbaumer, N., Mcfarland, D. J., Pfurtscheller, G. ve Vaughan, T. M., Brain-Computer Interfaces for Communication and Control, Clinical Neurophysiology, 113, 6 (2002) 767-791.
7. Schalk, G., Mcfarland, D. J., Hinterberger, T., Birbaumer, N. ve Wolpaw, J. R., BCI2000: A General-Purpose Brain-Computer Interface (BCI) System, IEEE Transactions on Biomedical Engineering, 51, 6 (2004) 1034-1043.
8. Kübler, A., Kotchoubey, B., Hinterberger, T., Ghanayim, N., Perelmouter, J., Schauer, M., Fritsch, C., Taub, E. ve Birbaumer, N., The Thought Translation Device: A Neurophysiological Approach to Communication in total Motor Paralysis, Experimental Brain Research, 124, 2 (199) 223-232.
9. Buch, E., Weber, C., Cohen, L. G., Braun, C., Dimyan, M. A., Ard, T., Mellinger, J., Caria, A., Soekadar, S., Fourkas, A. ve Birbaumer, N., Think to Move: A Neuromagnetic Brain-Computer Interface (BCI) System for Chronic Stroke, Stroke, 39, 3 (2008) 910-917.
10. Pan, J. S., Lo, C. C., Tsai, S. H. ve Lin, B. S., Design of Novel Non-Contact Multimedia Controller for Disability by using Visual Stimulus, Computer Methods and Programs in Biomedicine, 122, 3 (2015) 384-392.
11. Hinterberger, T., Kübler, A., Kaiser, J., Neumann, N. ve Birbaumer, N., A Brain-Computer Interface (BCI) for the Locked-in: Comparison of Different EEG

- Classifications for the Thought Translation Device, Clinical Neurophysiology, 114, 3 (2003) 416-425.
12. Furdea, A., Halder, S., Krusienski, D. J., Bross, D., Nijboer, F., Birbaumer, N. ve Kübler, A., An Auditory Oddball (P300) Spelling System for Brain-Computer Interfaces, Psychophysiology, 46, 3 (2009) 617-625.
 13. Adeli, H., Ghosh-Dastidar, S. ve Dadmehr, N., A Wavelet-Chaos Methodology for Analysis of EEGs and EEG Subbands to Detect Seizure and Epilepsy, IEEE Transactions on Biomedical Engineering, 54, 2 (2007) 205-211.
 14. Jeong, J., EEG Dynamics in Patients with Alzheimer's Disease, Clinical Neurophysiology, 115, 7 (2004) 1490-1505.
 15. Grossi, E., Olivieri, C. ve Buscema, M., Diagnosis of Autism Through EEG Processed by Advanced Computational Algorithms: A Pilot Study. Computer Methods and Programs in Biomedicine, 142 (2017) 73-79.
 16. Hamada, H., Matsuzawa, D., Sutoh, C., Hirano, Y., Chakraborty, S., Ito, H., Tsuji, H., Obata, T. ve Shimizu, E., Comparison of Brain Activity Between Motor Imagery and Mental Rotation of the Hand Tasks: A Functional Magnetic Resonance Imaging Study, Brain Imaging and Behavior, 12, 6 (2018) 1596-1606.
 17. Ehrsson, H. H., Geyer, S. ve Naito, E., Imagery of Voluntary Movement of Fingers, Toes, and Tongue Activates Corresponding Body-Part-Specific Motor Representations, Journal of Neurophysiology, 90 (2003) 3304–3316.
 18. Roland, P. E. ve Friberg, L., Localization of Cortical Areas Activated by Thinking, Journal of Neurophysiology, 53 5 (1985) 1219-1243.
 19. Pfurtscheller, G. ve Neuper, C., Motor Imagery Activates Primary Sensorimotor Area in Humans, Neuroscience Letters, 239 (1997) 65-68.
 20. Roland, P. E., Larsen, B., Lassen, N. A. ve Skinhoj, E., Supplementary Motor Area and Other Cortical Areas in Organization of Voluntary Movements in Man, Journal of Neurophysiology, 43 1 (1980) 118-136.
 21. Schnitzler, A., Salenius, S., Salmelin, R., Jousmäki, V. ve Hari, R., Involvement of Primary Motor Cortex in Motor Imagery: A Neuromagnetic Study, Neuroimage, 6 3 (1997) 201-208.
 22. Rao, S. M., Binder, J. R., Bandettini, P. A., Hammeke, T. A., Yetkin, F. Z., Jesmanowicz, A., Lisk, L. M, Morris, G. L., Mueller, W. M., Estkowski, L. D., Wong, E. C., Hauhton, V. M. ve Hyde, J. S., Functional Magnetic Resonance Imaging of Complex Human Movements, Neurology, 43 11 (1993) 2311-2311.

23. Pichiorri, F., Morone, G., Petti, M., Toppi, J., Pisotta, I., Molinari, M., Paolicci, S., Inghilleri, M., Astolfi, L., Cincotti, D. ve Mattia, D., Brain-Computer Interface Boosts Motor Imagery Practice During Stroke Recovery, Annals of Neurology, 77 5 (2015) 851-865.
24. Ting, W., Guo-Zheng, Y., Bang-Hua, Y. ve Hong, S., EEG Feature Extraction Based on Wavelet Packet Decomposition for Brain Computer Interface, Measurement, 41 6 (2008) 618-625.
25. Varone, G., Gasparini, S., Ferlazzo, E., Ascoli, M., Tripodi, G. G., Zucco, C., Calabrese, B., Cannataro, M. ve Aguglia, U., A Comprehensive Machine-Learning-Based Software Pipeline to Classify EEG Signals: A Case Study on PNES vs. Control Subjects, Sensors, 20 4 (2020) 1-12.
26. Emigdio, Z., Trujillo, L., Sotelo, A., Legrand, P. ve Coria, L. N., Regularity and Matching Pursuit Feature Extraction for the Detection of Epileptic Seizures, Journal of Neuroscience Methods, 266 (2016) 107-125.
27. Cheong, L. C., Sudirman, R. ve Hussin, S. S., Feature Extraction of EEG Signal using Wavelet Transform for Autism Classification, ARPN Journal of Engineering and Applied Sciences, 10, 19 (2015) 8533-8540.
28. Martišius, I. ve Damaševičius, R., Class-Adaptive Denoising for EEG Data Classification, International Conference on Artificial Intelligence and Soft Computing, Nisan 2012, Berlin, 302-309.
29. Sharmila, A. ve Geethanjali, P., Evaluation of Time Domain Features on Detection of Epileptic Seizure from EEG Signals, Health and Technology, 10, 3 (2020) 711-722.
30. Khorshidtalab, A., Salami, M. J. E. ve Hamed, M., Robust Classification of Motor Imagery EEG Signals using Statistical Time-Domain Features, Physiological Measurement, 34, 11 (2013) 1563-79.
31. Rechy-Ramirez, E. J. ve Hu, H., Bio-Signal Based Control in Assistive Robots: A Survey, Digital Communications and Networks, 1, 2 (2015) 85-101.
32. Herman, P., Prasad, G., McGinnity, T. M. ve Coyle, D., Comparative Analysis of Spectral Approaches to Feature Extraction for EEG-Based Motor Imagery Classification, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 16, 4 (2008) 317-326.
33. Al-Fahoum, A. S. ve Al-Fraihat, A. A., Methods of EEG Signal Features Extraction using Linear Analysis in Frequency and Time-Frequency Domains, International Scholarly Research Notices, 2014 (2014) 1-7.

34. Xing, K., Yang, P., Huang, J., Wang, Y. ve Zhu, Q., A Real-Time EMG Pattern Recognition Method for Virtual Myoelectric Hand Control, Neurocomputing, 136 (2014), 345-355.
35. Tyagi, A. ve Nehra, V., Time Frequency Analysis of Non-Stationary Motor Imagery EEG Signals, International Conference on Computing and Communication Technologies for Smart Nation (Ic3tsn), Ekim 2017, Gurgaon, 44-50.
36. Qin, L. ve He, B., A Wavelet-Based Time-Frequency Analysis Approach for Classification of Motor Imagery for Brain-Computer Interface Applications, Journal of Neural Engineering, 2, 4 (2005) 65-72.
37. Song, Y., Du, Y., Wu, X., Chen, X. ve Xie, P., A Synchronous and Multi-Domain Feature Extraction Method of EEG and Semg in Power-Assist Rehabilitation Robot, IEEE International Conference on Robotics and Automation (ICRA), Mayıs 2014, 4940-4945.
38. Jerbic, A. B., Horki, P., Sovilj, S., Isgum, V. ve Cifrek, M., Hilbert-Huang Time-Frequency Analysis of Motor Imagery EEG Data for Brain-Computer Interfaces, European Conference of the international Federation for Medical and Biological Engineering, Eylül 2014, Cham, 62-65.
39. Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M. ve Müller, K. R., Optimizing Spatial Filters for Robust EEG Single-Trial Analysis, IEEE Signal Processing Magazine, 25, 1 (2007) 41-56.
40. Hoffmann, U., Vesin, J. M. ve Ebrahimi, T., Recent Advances in Brain-Computer Interfaces, IEEE International Workshop on Multimedia Signal Processing, Ekim 2007, Crete, 17-17.
41. Samek, W., Vidaurre, C., Müller, K. R. ve Kawanabe, M., Stationary Common Spatial Patterns for Brain-Computer Interfacing, Journal of Neural Engineering, 9, 2 (2012), 1-24.
42. Lotte, F. ve Guan, C., Regularizing Common Spatial Patterns to Improve BCI Designs: Unified theory and New Algorithms, IEEE Transactions on Biomedical Engineering, 58, 2 (2010) 355-362.
43. Jafarifarmand, A. ve Badamchizadeh, M. A., Real-Time Multiclass Motor Imagery Brain-Computer Interface by Modified Common Spatial Patterns and Adaptive Neuro-Fuzzy Classifier, Biomedical Signal Processing and Control, 57 (2020) 1-8.
44. Wang, J., Xu, G., Wang, L. ve Zhang, H., Feature Extraction of Brain-Computer Interface Based on Improved Multivariate Adaptive Autoregressive Models, International Conference on Biomedical Engineering and Informatics, Ekim 2010, Yantai, 895-898.

45. Costa, A. P., Møller, J. S., Iversen, H. K. ve Puthusserypady, S., An Adaptive CSP Filter to investigate User Independence in A 3-Class MI-BCI Paradigm, Computers in Biology and Medicine, 103 (2018) 24-33.
46. Sun, S. ve Zhou, J., A Review of Adaptive Feature Extraction and Classification Methods for EEG-Based Brain-Computer Interfaces. International Joint Conference on Neural Networks, Temmuz 2014, Beijing, 1746-1753.
47. Hsu, W. Y., Assembling A Multi-Feature EEG Classifier for Left-Right Motor Imagery Data using Wavelet-Based Fuzzy Approximate Entropy for Improved Accuracy, International Journal of Neural Systems, 25, 8 (2015).
48. Çatalbaş, M. C., Temel Bileşenler Analizi ve Kanonik Korelasyon Analizi ile İmge Tanıma ve Sınıflandırma, Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2014.
49. Kaçar, Ü., Kirci, M., Güneş, E. O. ve İnan, T., A Comparison of PCA, LDA and DCVA in Ear Biometrics Classification using SVM, Signal Processing and Communications Applications Conference, Mayıs 2015, Malatya, 1260-1263.
50. Pang, Y., Wang, S. ve Yuan, Y., Learning Regularized LDA by Clustering, IEEE Transactions on Neural Networks and Learning Systems, 25, 12 (2014) 2191-2201.
51. Fletcher, T., Support vector Machines Explained, <http://www.tristanfletcher.co.uk/> 11 Kasım 2020.
52. Sommer, D. ve Golz, M., A Comparison of Validation Methods for Learning vector Quantization and for Support vector Machines on Two Biomedical Data Sets, from Data and information Analysis to Knowledge Engineering, Mart 2005, 150-157.
53. Miao, M., Zhang, W., Hu, W. ve Wang, R., An Adaptive Multi-Domain Feature Joint Optimization Framework Based on Composite Kernels and Ant Colony Optimization for Motor Imagery EEG Classification, Biomedical Signal Processing and Control, 61 (2020) 1-15.
54. Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W. ve Ball, T., Deep Learning with Convolutional Neural Networks for Brain Mapping and Decoding of Movement-Related information from the Human EEG, <https://arxiv.org/pdf/1703.05051v1.pdf> 11 Kasım 2020.
55. Wang, P., Jiang, A., Liu, X., Shang, J. ve Zhang, L., LSTM-Based EEG Classification in Motor Imagery Tasks, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 26, 11 (2018) 2086-2095.
56. Friedman, N., Geiger, D. ve Goldszmidt, M., Bayesian Network Classifiers, Machine Learning, 29, 2-3 (1997) 131-163.

57. Wang, H. ve Zhang, Y., Detection of Motor Imagery EEG Signals Employing Naïve Bayes Based Learning Process, Measurement, 86 (2016) 148-158.
58. Deepa, V. B., Thangaraj, P. ve Chitra, S., Investigating Principal Component Analysis for Classification of EEG Data, International Conference on Networking and Information Technology, Haziran 2010, 461-464.
59. Wen, Y. ve Huang, Z., online Motor Imagery BCI Based on Adaptive and incremental Linear Discriminant Analysis Algorithm, International Conference on Communication Software and Networks, Mayıs 2017, 962-966.
60. Bamdadian, A., Guan, C., Ang, K. K. ve Xu, J., Improving Session-to-Session Transfer Performance of Motor Imagery-Based BCI using Adaptive Extreme Learning Machine, Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Temmuz 2013, Osaka, 2188-2191.
61. Yger, F., Berar, M. ve Lotte, F., Riemannian Approaches in Brain-Computer Interfaces: A Review, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25, 10 (2016) 1753-1762.
62. Tan, L., Bölüm 17: Code Comment Analysis for Improving Software Quality, the Art and Science of Analyzing Software Data, Elsevier inc, 2015.
63. Batres-Mendoza, P., Ibarra-Manzano, M. A., Guerra-Hernandez, E. I., Almanza-Ojeda, D. L., Montoro-Sanjose, C. R., Romero-Troncoso, R. J. ve Rostro-Gonzalez, H., Improving EEG-Based Motor Imagery Classification for Real-Time Applications using the QSA Method, Computational Intelligence and Neuroscience, 2017 (2017) 1-17.
64. Komijani, H., Parsaei, M. R., Khajeh, E., Golkar, E. J. ve Zarrabi, H., EEG Classification Using Recurrent Adaptive Neuro-Fuzzy Network Based on Time-Series Prediction, Neural Computing and Applications, 31 (2019) 2551–2562.
65. Ahangi, A., Karamnejad, M., Mohammadi, N., Ebrahimpour, R. ve Bagheri, N., Multiple Classifier System for EEG Signal Classification with Application to Brain-Computer Interfaces, Neural Computing and Applications, 23, 5 (2013) 1319-1327.
66. Nadi, A., Moradi, H. ve Taheri, K., Crossbreeding in Random Forest. <https://arxiv.org/abs/2101.08585> 22 Mart 2021.
67. <https://emotiv.gitbook.io/epoc-flex-user-manual/> Epoc Flex User Manual. 09 Kasım 2020.
68. <https://www.emotiv.com/epoc-flex/> Emotiv Epoc Flex. 09 Kasım 2020.

69. Bronshtein, I. N., Semendyayev, K. A., Musiol, G. ve Mühlig, H., Probability Theory and Mathematical Statistics, Handbook of Mathematics, Springer, Berlin, 2015.
70. 28159 – 70 <https://en.wikipedia.org/wiki/combination> Combination. 09 Kasım 2020.
71. Mladenović, P., Combinatorics A Problem-Based Approach, Springer International Publishing, 2019.
72. Talia, D., Trunfio, P. ve Marozzo, F., Introduction to Data Mining, Data Analysis in the Cloud: Models, Techniques and Applications, Elsevier, 2015.
73. Gudivada, V. N., Irfan, M. T., Fathi, E. ve Rao, D. L., Bölüm 5: Cognitive Analytics: Going Beyond Big Data Analytics and Machine Learning, Handbook of Statistics, Elsevier B. V., 2016.
74. Bauer, E. ve Kohavi, R., An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting, and Variants, Machine Learning, 36, 1-2 (1999) 105-139.
75. Kieu, L. M., Ou, Y., Truong, L. T. ve Cai, C., A Class-Specific Soft Voting Framework for Customer Booking Prediction in on-Demand Transport, Transportation Research Part C: Emerging Technologies, 114 (2020) 377-390.
76. Quinlan, J. R., Bagging, Boosting, and C4.5, Association for the Advancement of Artificial Intelligence, 1996.
77. Kotsiantis, S., Combining Bagging, Boosting, Rotation forest and Random Subspace Methods, Artificial Intelligence Review, 35, 3 (2011) 223-240.
78. Raschka, S., Mlxtend, <https://sebastianraschka.com/pdf/software/mlxtend-latest.pdf> 11 Kasım 2020.
79. Hidayati, R., Kanamori, K., Feng, L. ve Ohwada, H., Implementing Majority Voting Rule to Classify Corporate Value Based on Environmental Efforts, International Conference on Data Mining and Big Data, Haziran 2016, Bali, 59-66.
80. Saqlain, M., Jargalsaikhan, B. ve Lee, J. Y., A Voting Ensemble Classifier for Wafer Map Defect Patterns Identification in Semiconductor Manufacturing, IEEE Transactions on Semiconductor Manufacturing, 32, 2 (2019) 171-182.
81. Nayyar Hassan, A. ve El-Hag, A., Two-Layer Ensemble-Based Soft Voting Classifier for Transformer Oil Interfacial Tension Prediction, Energies, 13, 7 (2020) 1-11.
82. Mahabub, A., A Robust Technique of Fake News Detection using Ensemble Voting Classifier and Comparison with Other Classifiers, Sn Applied Sciences, 2, 4 (2020) 1-9.

83. Hatipoglu, B., Yılmaz, Ç. M., Köse, C. ve Aydemir, Ö., Classification of Wrist Movements in Different Directions Based on Meg Signals, Signal Processing and Communications Applications Conference (Siu), Mayıs 2018, İzmir, 1-4.
84. Too, J., Abdullah, A. R. ve Saad, N. M., Classification of Hand Movements Based on Discrete Wavelet Transform and Enhanced Feature Extraction, Int. J. Adv. Comput. Sci. Appl., 10, 6 (2019) 83-89.
85. Yu, S., Jeong, E., Hong, K. ve Lee, S., Classification of Nine Directions using the Maximum Likelihood Estimation Based on Electromyogram of Both forearms, Biomedical Engineering Letters, 2, 2 (2012) 129-137.
86. Tkach, D., Huang, H. ve Kuiken, T. A., Study of Stability of Time-Domain Features for Electromyographic Pattern Recognition, Journal of Neuroengineering and Rehabilitation, 7, 1 (2010) 1-13.
87. Bablani, A., Edla, D. R. ve Dodia, S., Classification of EEG Data using K-Nearest Neighbor Approach for Concealed information Test, Procedia Computer Science, 143 (2018) 242-249.
88. Oh, S. H., Lee, Y. R. ve Kim, H. N., A Novel EEG Feature Extraction Method using Hjorth Parameter, International Journal of Electronics and Electrical Engineering, 2, 2 (2014) 106-110.
89. Van Drongelen, W., Chapter 13: LTI Systems Convolution, Correlation, Coherence, and the Hilbert Transform, Signal Processing for Neuroscientists, Academic Press, 2018.
90. Yılmaz, Ç. M., Görünüm Temelli Yöntemlerle Gerçek Zamanlı Göz Bakış Yönü Kestirimi ve insan Bilgisayar Etkileşimi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon, 2014.
91. Yılmaz, C. M., Yılmaz, B. H. ve Kose, C., Prediction of Eye States using K-NN Algorithm: A Comparison Study for Different Distance Metrics and Number of Neighbour Parameters, Medical Technologies Congress, Ekim 2019, Antalya, 1-4.
92. https://en.wikipedia.org/wiki/k-nearest_neighbors_algorithm K-Nearest Neighbors Algorithm. 10 Kasım 2020.
93. Barrientos, R. J., Gómez, J. I., Tenllado, C. ve Prieto, M., Heap Based K-Nearest Neighbor Search on Gpus, Congreso Espanol De informática, Eylül 2010, 559-566.
94. Jiang, L., Cai, Z., Wang, D. ve Jiang, S., Survey of Improving K-Nearest-Neighbor for Classification, International Conference on Fuzzy Systems and Knowledge Discovery, Ağustos 2007, Haikou, 679-683.

95. Batista, G. E. A. P. A. ve Silva, D. F., How K-Nearest Neighbor Parameters Affect Its Performance, Argentine Symposium on Artificial Intelligence, 2009, 1-12.
96. Ma, L., Crawford, M. M. ve Tian, J., Local Manifold Learning-Based K-Nearest-Neighbor for Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 48, 11 (2010) 4099-4109.
97. Ooi, H. L., Ng, S. C. ve Lim, E., ANO Detection with K-Nearest Neighbor using Minkowski Distance, International Journal of Signal Processing Systems, 1, 2 (2013) 208-211.
98. <https://www.mathworks.com/help/stats/classification-using-nearest-neighbors.html> Classification using Nearest Neighbors. 10 Kasım 2020.
99. Cunningham, P. ve Delany, S. J., K-Nearest Neighbour Classifiers–2nd Edition <https://deepai.org/publication/k-nearest-neighbour-classifiers-2nd-edition> 11 Kasım 2020.
100. Li, D., Deogun, J., Spaulding, W. ve Shuart, B., towards Missing Data Imputation: A Study of Fuzzy K-Means Clustering Method, International Conference on Rough Sets and Current Trends in Computing, Haziran 2004, 573-579.
101. Chomboon, K., Chujai, P., Teerarassamee, P., Kerdprasop, K. ve Kerdprasop, N., An Empirical Study of Distance Metrics for K-Nearest Neighbor Algorithm, International Conference on industrial Application Engineering, Mart 2015, 280-285.
102. El-Baz, A. H., Hybrid Intelligent System-Based Rough Set and Ensemble Classifier for Breast Cancer Diagnosis, Neural Computing and Applications, 26, 2 (2015) 437-446.
103. Polat, K. ve Güneş, S., An Expert System Approach Based on Principal Component Analysis and Adaptive Neuro-Fuzzy inference System to Diagnosis of Diabetes Disease, Digital Signal Processing, 17, 4 (2007) 702-710.
104. Masood, K., Rajpoot, N. M. ve Nasir, M., Spatial Analysis for Colon Biopsy Classification from Hyperspectral Imagery, Ann. BMVA, 4 (2008) 1-16.
105. Olivas-Padilla, B. E. ve Chacon-Murguia, M. I., Classification of Multiple Motor Imagery using Deep Convolutional Neural Networks and Spatial Filters, Applied Soft Computing, 75 (2019) 461-472.
106. Mchugh, M. L., Interrater Reliability: The Kappa Statistic, Biochemia Medica, 22, 3 (2012) 276-282.
107. Hu, D., Li, W. ve Chen, X., Feature Extraction of Motor Imagery EEG Signals Based on Wavelet Packet Decomposition, International Conference on Complex Medical Engineering, Mayıs 2011, Harbin Heilongjiang, 694-697.

108. http://www.bbci.de/competition/ii/tuebingen_desc_i.html Data Set Ia: ‹Self-Regulation of SCPs›. 10 Kasım 2020.
109. http://www.bbci.de/competition/ii/tuebingen_desc_ii.html Data Set Ib: ‹Self-Regulation of SCPs›. 10 Kasım 2020.
110. http://www.bbci.de/competition/iv/desc_2a.pdf BCI competition 2008 – Graz Data Set A. 10 Kasım 2020.
111. Lin, J. S. ve Lo, C. H., Mental Commands Recognition on Motor Imagery-Based Brain Computer Interface, international Journal of Computing, Consumer and Control, 25 (2016) 18-25.
112. Fakhruzzaman, M. N., Riksakomara, E. ve Suryotrisongko, H., EEG Wave Identification in Human Brain with Emotiv Epoc for Motor Imagery, Procedia Computer Science, 72 (2015) 269-276.
113. Hurtado-Rincon, J., Rojas-Jaramillo, S., Ricardo-Cespedes, Y., Alvarez-Meza, A. M. ve Castellanos-Domínguez, G., Motor Imagery Classification using Feature Relevance Analysis: An Emotiv-Based BCI System, Symposium on Image, Signal Processing and Artificial Vision, Eylül 2014, 1-5.
114. Kranczoch, C., Zich, C., Schierholz, I. ve Sterr, A., Mobile EEG and Its Potential to Promote the theory and Application of Imagery-Based Motor Rehabilitation, International Journal of Psychophysiology, 91, 1 (2014) 10-15.
115. <https://www.emotiv.com/epoc/> Emotiv Epoc+. 10 Kasım 2020.
116. <https://www.emotiv.com/comparison/> Headset Comparison Chart. 10 Kasım 2020.
117. Sözer, A. T., Durağan Hal Görsel Uyarılmış Potansiyel Temelli Beyin Bilgisayar Arayüzü Tasarımı ve Uygulaması, Doktora Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük, 2017.
118. Kaya, M., Cömert, M. ve Mishchenko, Y., Beyin Bilgisayar Arayüzü için DVM Makine Öğrenme Yöntemi Kullanılarak EEG Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti, Türk Bilim Araştırma Vakfı, 10, 3 (2017) 1-20.
119. Takehara, D., Kayanuma, H., Matsubara, M., Seki, N., Wada, K., Kurata, M. ve ono, Y., Development of an ERDMeasurement System using Emotiv Epoc, Transactions of Japanese Society for Medical and Biological Engineering, 55 (2017) 556-559.
120. Avelar, M. C. T., Intellwheels–Controlling an Intelligent Wheelchair using A Brain Computer Interface, Tez, Porto Üniversitesi, 2019.

121. Rashid, M., Sulaiman, N., Pp Abdul Majeed, A., Musa, R. M., Ab Nasir, A. F., Bari, B. S. ve Khatun, S., Current Status, Challenges, and Possible Solutions of EEG-Based Brain-Computer Interface: A Comprehensive Review, *Frontiers in Neurorobotics*, (2020), 1-36.
122. <https://www.biosemi.com/faq/cms&drl.htm> Biosemi, Frequently Asked Questions. 10 Kasım 2020.
123. https://www.neuroelectrics.com/wiki/index.php/neuroelectrics_frequently_asked_questions_faqs#what_is_a_differential_reference.3f Neuroelectrics Frequently Asked Questions (Faqs). 10 Kasım 2020.
124. <http://bnci-horizon-2020.eu/database/data-sets> Bnci Horizon 2020. 10 Kasım 2020.
125. <https://www.emotiv.com/knowledge-base/how-to-get-good-contact-quality-with-epoc/> How to Get Good Contact Quality with Epoc+?. 10 Kasım 2020.
126. https://emotiv.gitbook.io/emotivpro/notes_on_the_data/dc_offset Dc offset. 10 Kasım 2020.
127. <https://www.emotiv.com/knowledge-base/follow-why-does-emotiv-epoc-stop-at-43-hz-in-range-is-there-a-way-to-expand-this-somehow/> Follow Why Does Emotiv Epoc+ Stop at 43 Hz in Range? Is there A Way to Expand This Somehow?. 10 Kasım 2020.
128. Adam, A., Ibrahim, Z., Mokhtar, N., Shapiai, M. I., Cumming, P. ve Mubin, M., Evaluation of Different Time Domain Peak Models using Extreme Learning Machine-Based Peak Detection for EEG Signal, *Springerplus*, 5, 1 (2016) 1036.
129. <http://www.billauer.co.il/peakdet.html> Peakdet: Peak Detection using Matlab. 10 Kasım 2020.
130. Acir, N., Oztura, I., Kuntalp, M., Baklan, B., & Guzelis, C., Automatic Detection of Epileptiform Events in EEG by A Three-Stage Procedure Based on Artificial Neural Networks, *IEEE Transactions on Biomedical Engineering*, 52, 1 (2004) 30-40.
131. Park, S. B., Noh, Y. S., Park, S. J. ve Yoon, H. R., An Improved Algorithm for Respiration Signal Extraction from Electrocardiogram Measured by Conductive Textile Electrodes using Instantaneous Frequency Estimation, *Medical & Biological Engineering & Computing*, 46, 2 (2008) 147-158.
132. Lishner, M., Akselrod, S., Avi, V. M., Oz, O., Divon, M. ve Ravid, M., Spectral Analysis of Heart Rate Fluctuations. A Non-invasive, Sensitive Method for the Early Diagnosis of Autonomic Neuropathy in Diabetes Mellitus, *Journal of the Autonomic Nervous System*, 19, 2 (1987) 119-125.

133. Aungsakun, S., Phinyomark, A., Phukpattaranont, P. ve Limsakul, C., Robust Eye Movement Recognition using EOG Signal for Human-Computer Interface, International Conference on Software Engineering and Computer Systems, Haziran 2011, Kuantan,714-723.
134. Adam, A., Shapiai, M. I., Mohd Tumari, M. Z., Mohamad, M. S. ve Mubin, M., Feature Selection and Classifier Parameters Estimation for EEG Signals Peak Detection using Particle Swarm Optimization, the Scientific World Journal, 2014 (2014), 1-14.
135. <https://www.ni.com/en-tr/support/documentation/supplemental/06/peak-detection-using-labview-and-measurement-studio.html> Peak Detection using Labview and Measurement Studio. 10 Kasım 2020.
136. <https://terpconnect.umd.edu/~toh/spectrum/> A Pragmatic* Introduction to Signal Processing. 10 Kasım 2020.
137. Dumpala, S. R., Reddy, S. N. ve Sarna, S. K., An Algorithm for the Detection of Peaks in Biological Signals, Computer Programs in Biomedicine, 14, 3 (1982) 249-256.
138. Adam, A., Ibrahim, Z., Mokhtar, N., Shapiai, M. I. ve Mubin, M., Evaluation of Different Peak Models of Eye Blink EEG for Signal Peak Detection using Artificial Neural Network, Neural Network World, 26, 1 (2016) 67-89.
139. Yilmaz, C. M., Kose, C. ve Hatipoglu, B., A Quasi-Probabilistic Distribution Model for EEG Signal Classification by using 2-D Signal Representation, Computer Methods and Programs in Biomedicine, 162 (2018) 187-196.
140. Fei-Fei, L. ve Perona, P., A Bayesian Hierarchical Model for Learning Natural Scene Categories, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 2005, San Diego, Pp. 524-531.
141. Kotsiantis, S. B., Zaharakis, I. ve Pintelas, P., Supervised Machine Learning: A Review of Classification Techniques, Emerging Artificial Intelligence Applications in Computer Engineering, 160, 1 (2007) 3-24.
142. Gaur, P., Pachori, R. B., Wang, H. ve Prasad, G., An Automatic Subject Specific Intrinsic Mode Function Selection for Enhancing Two-Class EEG-Based Motor Imagery-Brain Computer Interface, IEEE Sensors Journal, 19, 16 (2019) 6938-6947.
143. Das, A. K., Sundaram, S. ve Sundararajan, N., A Self-Regulated Interval Type-2 Neuro-Fuzzy inference System for Handling Nonstationarities in EEG Signals for BCI, IEEE Transactions on Fuzzy Systems, 24, 6 (2016) 1565-1577.
144. Sadatnejad, K. ve Ghidary, S. S., Kernel Learning Over the Manifold of Symmetric Positive Definite Matrices for Dimensionality Reduction in A BCI Application, Neurocomputing, 179 (2016) 152-160.

145. Gaur, P., Mccreadie, K., Pachori, R. B., Wang, H. ve Prasad, G., Tangent Space Features-Based Transfer Learning Classification Model for Two-Class Motor Imagery Brain–Computer Interface, International Journal of Neural Systems, 29, 10 (2019) 1-17.
146. Rodrigues, P. G., Stefano Filho, C. A., Attux, R., Castellano, G. ve Soriano, D. C., Space-Time Recurrences for Functional Connectivity Evaluation and Feature Extraction in Motor Imagery Brain-Computer Interfaces, Medical & Biological Engineering & Computing, 57, 8 (2019) 1709-1725.
147. Raza, H., Cecotti, H., Li, Y. ve Prasad, G., Adaptive Learning with Covariate Shift-Detection for Motor Imagery-Based Brain–Computer Interface, Soft Computing, 20, 8 (2016) 3085-3096.
148. Raza, H., Rathee, D., Zhou, S. M., Cecotti, H. ve Prasad, G., Covariate Shift Estimation Based Adaptive Ensemble Learning for Handling Non-Stationarity in Motor Imagery Related EEG-Based Brain-Computer Interface, Neurocomputing, 343 (2019) 154-166.
149. Luo, J., Wang, J., Xu, R. ve Xu, K., Class Discrepancy-Guided Sub-Band Filter-Based Common Spatial Pattern for Motor Imagery Classification, Journal of Neuroscience Methods, 323 (2019) 98-107.
150. Belwafi, K., Romain, O., Gannouni, S., Ghaffari, F., Djemal, R. ve Ouni, B., An Embedded Implementation Based on Adaptive Filter Bank for Brain–Computer Interface Systems, Journal of Neuroscience Methods, 305 (2018) 1-16.
151. Gaur, P., Pachori, R. B., Wang, H. ve Prasad, G., A Multi-Class EEG-Based BCI Classification using Multivariate Empirical Mode Decomposition Based Filtering and Riemannian Geometry, Expert Systems with Applications, 95 (2018), 201-211.
152. Martisius, I., Damasevicius, R., Jusas, V. ve Birvinskas, D., using Higher Order Nonlinear Operators for SVM Classification of EEG Data, Elektronika IR Elektrotechnika, 119, 3 (2012) 99-102.
153. <http://www.bbci.de/competition/ii/results/index.html> BCI Competition II - Final Results. 10 Kasım 2020.
154. Sun, S. ve Zhang, C., Assessing Features for Electroencephalographic Signal Categorization, IEEE International Conference on Acoustics, Speech, and Signal Processing, Mart 2005, Philadelphia, V417-V420.
155. Lederman, D. ve Tabrikian, J., Classification of Multichannel EEG Patterns using Parallel Hidden Markov Models, Medical & Biological Engineering & Computing, 50, 4 (2012) 319-328.

156. Wang, B., Jun, L., Bai, J., Peng, L., Li, G. ve Li, Y., EEG Recognition Based on Multiple Types of information by using Wavelet Packet Transform and Neural Networks, IEEE Engineering in Medicine and Biology Annual Conference, Ocak 2006, Shanghai, 5377-5380.
157. Duan, L., Zhong, H., Miao, J., Yang, Z., Ma, W. ve Zhang, X., A Voting Optimized Strategy Based on Elm for Improving Classification of Motor Imagery BCI Data, Cognitive Computation, 6, 3 (2014) 477-483.
158. Wu, T., Yang, B. ve Sun, H., EEG Classification Based on Artificial Neural Network in Brain Computer Interface, Life System Modeling and Intelligent Computing, (2010) 154-162.
159. Duan, L., Bao, M., Cui, S., Qiao, Y. ve Miao, J., Motor Imagery EEG Classification Based on Kernel Hierarchical Extreme Learning Machine, Cognitive Computation, 9, 6 (2017) 758-765.
160. Bostanov, V., BCI Competition 2003-Data Sets Ib and Iib: Feature Extraction from Event-Related Brain Potentials with the Continuous Wavelet Transform and the T-Value Scalogram, IEEE Transactions on Biomedical Engineering, 51, 6 (2010) 1057-1061.
161. Kayikcioglu, T. ve Aydemir, O., A Polynomial Fitting and K-NN Based Approach for Improving Classification of Motor Imagery BCI Data, Pattern Recognition Letters, 31, 11 (2010) 1207-1215.
162. Hettiarachchi, I. T., Nguyen, T. T. ve Nahavandi, S., Motor Imagery Data Classification for BCI Application using Wavelet Packet Feature Extraction, International Conference on Neural information Processing, Kasim 2014, Kuching, 519-526.
163. Alimardani, F., Boostani, R. ve Blankertz, B., Weighted Spatial Based Geometric Scheme as An Efficient Algorithm for Analyzing Single-Trial EEGs to Improve Cue-Based BCI Classification, Neural Networks, 92, (2017) 69-76.
164. Rathee, D., Raza, H., Prasad, G. ve Cecotti, H., Current Source Density Estimation Enhances the Performance of Motor-Imagery-Related Brain-Computer Interface. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25, 12 (2017) 2461-2471.
165. Raza, H., Cecotti, H. ve Prasad, G., A Combination of Transductive and Inductive Learning for Handling Non-Stationarities in Motor Imagery Classification, International Joint Conference on Neural Networks, Temmuz 2016, Vancouver, 763-770.

166. Luo, J., Gao, X., Zhu, X., Wang, B., Lu, N. ve Wang, J., Motor Imagery EEG Classification Based on Ensemble Support Vector Learning, Computer Methods and Programs in Biomedicine, 193, (2020) 1-9.
167. Luo, J., Wang, J., Xu, R. ve Xu, K., Class Discrepancy-Guided Sub-Band Filter-Based Common Spatial Pattern for Motor Imagery Classification, Journal of Neuroscience Methods, 323, (2019) 98-107.
168. Gandhi, V., Prasad, G., Coyle, D., Behera, L. ve Mcginnity, T. M., Quantum Neural Network-Based EEG Filtering for A Brain-Computer Interface. *IEEE Transactions on Neural Networks and Learning Systems*, 25, 2 (2013) 278-288.
169. Mancar, S. A., Performansa Dayalı Durum Belirlemede Puanlayıcılar Arası Güvenirlik Tekniklerinin Karşılaştırılması, Yüksek Lisans Tezi, Ankara Üniversitesi, Eğitim Bilimleri Enstitüsü, Ankara, 2019.
170. Basha, S. H., Vinakota, S. K., Dubey, S. R., Pulabaigari, V. ve Mukherjee, S., Autofcl: Automatically Tuning Fully Connected Layers for Transfer Learning. <https://arxiv.org/abs/2001.11951> 17 Aralık 2020.
171. Krizhevsky, A., Sutskever, I. ve Hinton, G. E., Imagenet Classification with Deep Convolutional Neural Networks, *Communications of the ACM*, 60, 6 (2017) 84-90.
172. <https://www.mathworks.com/help/deeplearning/ref/resnet50.html> Resnet. 25 Aralık 2020.
173. He, K., Zhang, X., Ren, S. ve Sun, J., Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2016, Las Vegas, 770-778.
174. <https://www.mathworks.com/help/deeplearning/ref/googlenet.html> Googlenet. 25 Aralık 2020.
175. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D. ve Rabinovich, A., Going Deeper with Convolutions, *IEEE Conference on Computer Vision and Pattern Recognition*, Haziran 2015, Boston, 1-9.
176. <https://ayyucekizrak.medium.com/> Derine Daha Derine: Evrişimli Sinir Ağları. 25 Aralık 2020.
177. <https://www.mathworks.com/help/deeplearning/ref/alexnet.html> Alexnet. 25 Aralık 2020.
178. Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J. ve Keutzer, K., SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and <0.5MB Model size. <https://arxiv.org/abs/1602.07360> 29 Aralık 2020.

179. <http://biosig.sourceforge.net/> The BioSig Project. 21 Şubat 2021.
180. <https://www.mathworks.com/help/stats/fitcsvm.html> fitcsvm. 26 Mart 2021.
181. <https://www.mathworks.com/help/stats/fitcknn.html> fitcknn. 26 Mart 2021.
182. https://www.iconfinder.com/icons/4089139/mobile_single_tap_icon Mobile, single, tap icon. 26 Mart 2021.
183. https://www.iconfinder.com/icons/4089140/down_mobile_swipe_thumb_icon Down, mobile, swipe, thumb icon. 26 Mart 2021.



7. EKLER

Ek 1. Elektrot Sensör Konumları

MHH-BMTA veri setinde tüm frekans bantları ve zaman dilimlerini kullanan Y8 ile 5 frekans bandı ve 5 zaman dilimiyle oluşturulan 25 alt sınıflandırıcı için ilk koşulunda kullanılan elektrot konumları Tablo 7.1-7.4'teki gibidir.

Ek Tablo 7.1. Farklı oturumlara ait eğitim ve test kümeleri için elektrot konumları

D01	FC3, FC4, FC4, CP3, CP4, C3, C3, C2, C4, C3, FC4, FCz, C2, FC4, FCz, FC3, CP3, CP3, CPz, C5, FCz, C3, C5, CP3, CP3
D02	C1, FC3, CP3, FC3, FC3, Cz, C5, FC4, FC3, CP4, CP3, C3, CP4, C5, Cz, C6, C5, CP4, CP4, C5, FCz, C3, C2, C1, CP4
D03	CP4, FC3, C2, CP4, FC4, C3, C6, FC4, C4, C4, CP4, Cz, FCz, Cz, C4, FC4, CP3, C1, C4, Cz, CP3, CP4, CP4, C5, C5
D04	C2, CPz, FC3, C4, FC3, FCz, FC3, CP3, C1, C5, CP4, FCz, C6, C4, C5, CPz, C6, C6, FCz, C2, C5, C6, CPz, C6, C6
D05	CP3, C2, C5, C4, C4, CP3, C4, FC4, FC3, CP3, C1, C1, CP4, Cz, FCz, CPz, C6, CP3, Cz, CP3, C6, CPz, C5, FC3, C1
D06	C6, FC3, C6, C5, C4, CPz, C6, FC3, C5, CPz, FCz, C5, C3, C6, CP4, FC4, CP3, FCz, C6, FCz, FCz, FCz, C1, C1, C2
D07	C3, C6, C3, C4, CPz, C1, FCz, Cz, C6, FC4, C6, FCz, C1, C1, CP3, C2, C3, C2, CPz, FCz, C4, FC4, CP4, CP4, C4
D08	FC3, FC4, C2, CP4, FC3, Cz, C4, C5, C4, Cz, C6, C1, CP3, FC3, Cz, C6, C6, C2, C2, C4, FCz, C2, C5, CP4, C2

Ek Tablo 7.2. %50-%50 eğitim test oranı için elektrot konumları

D01	C6, FCz, FC3, C2, FC3, CP3, FC4, FCz, C2, CP4, CPz, FCz, FC4, C3, C4, FC3, C1, FCz, Cz, CPz, FCz, C5, C1, CP3, C4
D02	C3, FC1, C1, C4, C1, Cz, C6, FC4, FC1, C5, C3, CP3, C6, C3, C1, C2, FC4, C3, FC3, FC1, C5, FC1, FC1, CP4, C3
D03	C2, FC3, Cz, C4, Cz, CP3, FC4, C4, C4, C3, C5, FC1, C4, C6, CP3, C5, C6, C4, CP4, C4, Cz, C6, C1, Cz, CP3
D04	C3, CP4, CP4, Cz, C3, FC1, FC1, C6, FC3, C1, FC4, FC3, FC3, FC3, FC3, C6, FC3, FC3, FC3, CPz, Cz, C6, C3, C6, C6
D05	C4, C1, C4, C4, CP4, C6, FC3, C1, Cz, Cz, C4, C2, Cz, C6, C5, C2, FC3, C6, FC3, FC3, C3, C5, CP3, FC4, C5
D06	CP4, C1, FC3, CP3, C3, C6, C3, CP3, Cz, CP3, C5, CP4, C4, FC3, C6, FC3, CPz, FC3, FC3, FC3, C5, CPz, C1, FC1, FC1
D07	C6, FC3, CPz, FC1, C6, C4, C5, Cz, CP4, Cz, FC3, C6, FC4, FC1, C6, C2, Cz, CP4, Cz, C6, Cz, FC4, C2, CPz, C6
D08	FC1, CP3, FC3, C2, FC3, C2, CP4, C5, C4, C2, CPz, CP4, Cz, C2, C3, Cz, Cz, C2, FC4, C5, C3, C3, FC3, FC3, C5

Ek Tablo 7.3. %70-%30 eğitim test oranı için elektrot konumları

D01	FC4, C3, FCz, FC4, FC3, CP3, FC4, C3, C4, C2, Cz, FCz, FCz, FC4, FCz, C1, CP3, C3, Cz, CP4, C3, CPz, C2, CPz, CP3
D02	C1, FC4, C5, C6, C6, C2, FC3, FC4, C5, C1, CPz, C6, C5, FCz, C5, C1, C3, CP4, CPz, C6, CPz, Cz, FC3, C5, C5
D03	C1, CPz, FC4, FCz, CP4, CP3, C6, CP3, CP3, CP4, CP4, C1, CP3, C4, FC4, FCz, CP3, C1, C4, C3, C4, Cz, FC3, C5, CP4
D04	CP4, C2, FC3, C1, CP3, Cz, FC3, CP3, C6, CP3, C4, FC4, C6, C4, C5, CPz, C6, C4, C1, FC3, C5, C6, CPz, C6, C2
D05	C5, Cz, CP3, C4, FC3, C3, C5, FCz, C4, CPz, FC3, FCz, FCz, C5, CP3, FC3, C2, Cz, C6, Cz, FC4, CP4, C6, C3, C4
D06	C3, C4, FCz, C3, C4, C5, C6, FC3, C6, FC4, FC4, C5, C6, C5, C3, Cz, FC4, C2, FC3, C5, FCz, C1, C6, Cz, FC3
D07	FC3, CP3, CPz, CP4, FC3, FC3, C6, FC4, C6, C6, FC3, FC4, Cz, C5, C5, C3, FC4, C5, CPz, Cz, C4, C3, CP4, C4, C6
D08	FC3, CP4, CP4, C1, CP4, Cz, C4, CP4, C4, Cz, FC3, CPz, CP3, CP4, FC3, FC4, C5, FC3, CPz, FC4, Cz, FC3, FC3, C2, C5

Ek Tablo 7.4. %90-%10 eğitim test oranı için elektrot konumları

D01	C6, C2, Cz, CPz, FC3, CP3, CP4, Cz, FC3, Cz, FC4, FC4, C2, C4, FC4, FC3, C1, C4, Cz, FC4, FCz, FC4, CP3, FCz, CP3
D02	C5, C5, C1, FC3, Cz, C6, C6, C4, FCz, C3, CPz, C6, C4, C5, FC3, C1, C5, CP4, CP4, C4, FC4, CP4, FC4, CP4, C1
D03	Cz, CPz, FCz, C4, C3, CP4, CP4, CP3, CP3, CP4, CP4, C4, FC3, C4, C5, C4, CP3, C6, C6, CP3, C1, CP4, C6, FCz, C4
D04	C2, CP4, C4, C6, C6, C2, FC3, C6, C4, C2, C6, C6, FC3, C4, C5, CP4, CP4, C4, FCz, FC4, FC4, C3, CPz, C1, C6
D05	C5, C2, C3, FC4, FC4, CP3, C3, C3, FCz, CPz, CP3, C1, Cz, Cz, CP3, FC3, C5, FC4, Cz, Cz, CPz, C3, C5, Cz, FC3
D06	C5, C4, FC3, CP3, FCz, CPz, CPz, FC3, FC3, CPz, FC4, C1, FCz, Cz, C4, CP3, FC4, C1, FC3, C5, FCz, CP3, FCz, CP3, FCz
D07	CP3, C3, FCz, C4, C1, C3, FCz, Cz, Cz, FCz, Cz, FC4, CP3, C5, C6, FC3, C4, C5, CP3, FCz, CP4, C6, CP4, FC4, C4
D08	C2, CP4, C3, Cz, FC3, Cz, C3, FCz, C4, C2, FC3, FCz, CP3, C4, FC3, FC4, Cz, CP3, C5, FCz, FCz, C1, C5, CP3, C2

Data Set 2a veri setinde tüm frekans bantları ve zaman dilimlerini kullanan Y8 ile 5 frekans bandı ve 3 zaman dilimiyle oluşturulan 15 alt sınıflandırıcı için ilk koşulunda kullanılan elektrot konumları Tablo 7.5-7.10'daki gibidir.

Ek Tablo 7.5. Sol/sağ el MHH için elektrot konumları

A01	CP3, CP3, C1, CP3, FC3, FC3, FC3, CP3, FCz, CP4, CP3, FC3, C1, CPz, C1
A02	FC4, CPz, CP4, CP4, CP3, FC3, CP4, C5, FCz, C1, C3, Cz, FCz, FC4, C6
A03	C3, CP4, CP4, C6, C3, C3, C4, C2, C4, CP4, C4, C4, C6, C1, CP3
A04	CP4, FC4, FCz, FCz, CP4, FC4, FC3, CP4, FC3, Cz, C1, FC3, FCz, C6, C3
A05	CP3, C6, C6, C2, FCz, C6, C6, C3, FC3, FC3, C6, CP3, C6, C2, FCz
A06	C6, FCz, C2, C4, CPz, CP4, C5, C2, FCz, C1, C4, FCz, C6, C6, CPz
A07	C5, C6, C1, C6, C2, C2, C5, CP4, C6, C2, C6, C4, C5, FC4, FC3
A08	CP4, CP4, C3, CP3, Cz, C6, CP4, CP4, C2, C3, C6, CP4, CP4, Cz, Cz
A09	C4, C4, C4, C4, C4, CP4, C4, C4, C4, C4, CP3, C4, C4, CP4, C4

Ek Tablo 7.6. Sol el/ayaklar MHH için elektrot konumları

A01	CP4, CP4, CP4, CP3, C3, CP4, CP3, C3, Cz, CP3, CP4, CP4, CP4, C5, CP3
A02	CP4, CPz, FC3, FC3, FC3, Cz, C2, C4, FC3, CP3, C3, C5, C4, CP3, C5
A03	C4, C3, CP4, CP4, CP4, C4, C6, C6, CP3, CP4, CP4, C4, C4, C4, C4
A04	CP4, CP3, C1, Cz, CP3, CPz, CPz, CP3, Cz, CP3, CP3, CP3, CPz, CPz, CPz
A05	C4, CPz, FC3, Cz, C6, C4, C6, C3, C3, C6, C6, C1, CP3, C2, C1
A06	C6, FCz, C4, C4, C6, FCz, CP4, CP4, C4, CPz, FC3, C2, C3, C5, Cz
A07	C4, C3, C3, C3, C3, FC3, C3, C3, C3, C3, FCz, C3, C3, C3, C3
A08	FCz, C5, C1, C5, CP3, CP4, CP4, FC3, C6, Cz, CP4, CP4, C1, Cz, C4
A09	CP3, C3, C4, C4, C4, CP3, C4, CP3, C4, C4, C3, C4, C4, CP3, C4

Ek Tablo 7.7. Sol el/dil MHH için elektrot konumları

A01	CP3, CP4, CP4, C4, CP4, CP3, CP3, CP4, CP4, CP3, CP4, CP3, CP4, C2, CP4
A02	FC3, C4, Cz, FC3, CPz, FC3, FC3, C4, CPz, C2, FC3, FC3, C1, C6, C6
A03	CP4, CP4, C4, CPz, CP4, C4, C4, C4, CP4, CP4, C4, C4, C4, CP3, C3
A04	CP4, CP4, CP4, CP4, C4, CP4, CP4, CP4, CPz, CP4, CP4, CP4, CP3, CPz, CP4
A05	C4, CP3, FCz, C6, C5, FC4, C5, FC3, C6, C5, C6, FC4, Cz, FCz, Cz
A06	CP4, C4, C4, C4, C4, FC4, CP4, CP4, C4, CP3, CP3, C4, C3, Cz, C3
A07	C6, C3, C3, C3, C3, C4, C3, C3, C3, C3, CP3, C3, C3, C4, C3
A08	CP4, CP4, CPz, CPz, CP4, CP4, CP4, CP4, CPz, CPz, CPz, CP4, CP4, C1, CPz
A09	CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, C3, CP3, C3, C3, CP3, CP3, CP3

Ek Tablo 7.8. Sağ el/ayaklar MHH için elektrot konumları

A01	CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, C3, C4, CP3, CP3, CP3, C5, CP3
A02	CP4, Cz, CP4, FCz, Cz, C6, C5, FCz, C2, C1, Cz, C1, FCz, C4, C2
A03	C3, C3, CP3, FC3, CP3, C3, C3, CP3, CP3, CP3, C3, C3, C3, CP3, CP3
A04	CP3, CP3, CP3, CP3, CP3, C3, CP3, CP3, CP3, CP3, CP3, C1, CP3, C5, CP3
A05	C1, C2, FC4, C6, C6, C4, C4, CP4, C2, C5, C6, C3, Cz, FC4, CP3
A06	CP4, CP3, C5, FC3, C3, C5, C3, FCz, Cz, C1, FCz, C1, C3, C6, FC4
A07	CPz, CPz, C3, C3, FC3, CPz, Cz, C3, Cz, C3, CP4, C3, C3, C3, C3
A08	CPz, FC4, FC3, C5, C3, FC4, CP4, CPz, C1, FC3, C4, C3, Cz, CP3, Cz
A09	FC3, CP3, C3, C3, C2, FC3, C2, CPz, C3, Cz, C3, C6, C4, C3, C4

Ek Tablo 7.9. Sağ el/dil MHH için elektrot konumları

A01	CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3, CP3
A02	C6, CP4, C1, C5, CPz, FC3, CP3, CP3, CP4, C3, C6, Cz, C4, C4, C6
A03	C3, C3, C3, C3, C3, C3, FC3, C3, C6, C3, C3, FC3, C3, CP3, C3
A04	CP3, CP3, C1, C1, CP3, CP3, CP3, CP4, CP3, CP3, CP4, CP4, CP3, CP3, CP3
A05	C4, CP3, CPz, C5, FCz, C4, C3, FC3, C3, C2, C3, C5, FC3, C6, C5
A06	C2, FCz, C5, CPz, FC4, C3, CPz, CP3, FC4, C3, C6, CP3, C4, C2, C2
A07	C3, C3, C3, C3, C3, C3, C3, C3, C3, CP3, C3, C3, C3, CP3, C3
A08	CP3, CPz, CPz, C1, CP3, CP3, CPz, CPz, CPz, C2, CPz, C1, CPz, CPz, Cz
A09	C3, CPz, CP3, C3, CPz, C3, CP3, CP3, CP3, CP3, C1, CP3, CP3, CP3, CP3


Ek Tablo 7.10. Ayaklar/dil MHH için elektrot konumları

A01	FC4, Cz, C3, FC3, CPz, FCz, FC4, C5, C1, FC3, FCz, C4, C2, C2, CP4
A02	C1, C4, C3, C3, CPz, FCz, C2, C4, C5, C3, FC3, FCz, FC4, FCz, C2
A03	CPz, CPz, Cz, CPz, CPz, FC3, CP3, C1, CPz, C4, C1, FCz, C1, CPz, Cz
A04	CPz, C1, C6, FC4, C6, C3, FC3, C1, C6, CP4, Cz, FCz, C6, C5, CP4
A05	C6, C5, C5, CPz, C3, FC4, C1, FCz, FCz, C6, CP4, FCz, Cz, Cz, C6
A06	FCz, CPz, FCz, C6, FC3, CPz, Cz, CPz, Cz, FCz, CPz, CP4, CPz, C2, C2
A07	CPz, CPz, CPz, CPz, Cz, CP3, CPz, CPz, CPz, Cz, CPz, CPz, CPz, Cz, CPz
A08	CPz, CPz, CPz, CP4, C2, Cz, CPz, CPz, C1, CPz, CPz, CPz, CPz, C5, CPz
A09	CPz, CPz, CPz, CP3, CPz, CPz, CPz, CPz, CPz, CPz, CPz, CPz, CPz, CPz

MHH-BMTA veri setine ait D01 denegi için farklı oturumlara ait eğitim ve test kümelerinde, tüm frekans bantları ve zaman dilimlerini kullanan Y8 ile 5 frekans bandı ve 5 zaman dilimiyle oluşturulan 25 alt sınıflandırıcı için sırasıyla ilk koşulda elde edilen eğitim ve test doğrulukları şu şekildedir: %82-%65, %81-%63, %83-%63, %82-%64, %83-%62, %83-%61, %82-%63, %82-%64, %83-%65, %82-%64, %82-%62, %83-%67, %83-%61, %80-%63, %81-%68, %83-%63, %82-%64, %84-%60, %80-%65, %82-%62, %84-%63, %81-%64, %82-%65, %81-%62, %83-%61.

Ek 2. MHH-BMTA Veri Seti İçin Etik Belgesi

Motor hareket hayaline dayalı beyin-mobil telefon arayüzü veri setinin oluşturulması için alınan tıbbi etik açıdan uygunluk belgesi şu şekildedir.



T.C.
KARADENİZ TEKNİK ÜNİVERSİTESİ REKTÖRLÜĞÜ
KTÜ TIP FAKÜLTESİ
BİLİMSEL ARAŞTIRMALAR ETİK KURUL
BAŞKANLIĞI

Sayı : 24237859- 635
Konu: Etik Kurul onay belgesi | 15.10.2018

Sayın; Prof. Dr. Cemal KÖSE
Bilgisayar Mühendisliği Bölümü

“Beyinde Üretilen EEG Sinyallerinden Öznitelik Çıkarımı ve Sınıflandırılması” başlıklı etik kurul 2018/233 protokol numaralı çalışma önerisi raporör ve etik kurul görüşleri doğrultusunda; tıbbi etik açıdan uygun olduğuna karar verilmiştir.

Bilginizi ve gereğini rica ederim.

Prof. Dr. Faruk AYDIN
Etik kurul Başkanı

Ek: 1 adet onay belgesi |

ÖZGEÇMİŞ

Kocaeli Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans eğitimine başladı ve 2011 yılında mezun oldu. Aynı yıl KTÜ Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine ve Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaya başladı. ODTÜ Yabancı Diller Yüksekokulu'nda İngilizce dil eğitimi aldı. 2014 yılı aralık ayında yüksek lisans eğitimini tamamladı ve 2015 yılında KTÜ Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen KTÜ Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaktadır. Yabancı dil olarak iyi seviyede İngilizce bilmektedir. Akademik yayınları aşağıdadır.

Projeler

1. 119E397 nolu “EEG Temelli Beyin Bilgisayar Arayüzü Sistemlerine ait Motor Hareket Hayali Görevlerinin Sınıflandırılmasına Yönelik Örüntü Tanıma Yöntemlerin Geliştirilmesi” başlıklı TÜBİTAK 1002 Hızlı Destek Programı projesi, Proje Yürütücüsü, Danışman: Prof. Dr. Cemal KÖSE, Devam ediyor.

SCI, SSCI, AHCI İndekslerine Giren Dergilerde Yayınlanan Makaleler

1. Yılmaz Ç.M., Köse C. ve Hatipoğlu B., A Quasi-probabilistic Distribution Model for EEG Signal Classification by using 2-D Signal Representation. Comput Meth Prog Bio, 162, (2018) 187-196.
2. Hatipoğlu B., Yılmaz Ç.M. ve Köse C., A Signal-to-Image Transformation Approach for EEG and MEG Signal Classification. Signal Image Video P, 13, 3 (2019) 483-490.
3. Yılmaz, B.H., Yılmaz, C.M. ve Köse, C., Diversity in a Signal-to-Image Transformation Approach for EEG-based Motor Imagery Task Classification. Med Biol Eng Comput, 58, (2020) 443-459.

Hakemli Kongre / Sempozyumların Bildiri Kitaplarında Yer Alan Yayınlar

1. Ç. M. Yılmaz, B. H. Yılmaz ve C. Köse, Prediction of Eye States using k-NN Algorithm: A Comparison Study for Different Distance Metrics and Number of Neighbour Parameters, 2019 Tıp Teknolojileri Kongresi (TIPTEKNO), Ekim 2019, İzmir, 1-4, DOI: 10.1109/TIPTEKNO.2019.8895170.
2. B. H. Yılmaz, Ç. M. Yılmaz ve C. Köse, Classification of the EEG Signals for the Cursor Movement with the Signal-to-Image Transformation, 2019 Tıp Teknolojileri Kongresi (TIPTEKNO), Ekim 2019, İzmir, DOI: 10.1109/TIPTEKNO.2019.8895246.
3. B. Hatipoğlu, Ç. M. Yılmaz, C. Köse ve Ö. Aydemir, Classification of Wrist Movements in Different Directions based on MEG Signals, 26. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2018, İzmir, DOI: 10.1109/SIU.2018.8404268.
4. B. Hatipoğlu, Ç. M. Yılmaz ve C. Köse, A Comparison of Two Appearance based Methods for Gender Recognition, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2017, Antalya, DOI: 10.1109/SIU.2017.7960398.
5. Ç. M. Yılmaz ve C. Köse, A New Appearance based and User Independent Eye State Detection Method using Eigeneyes, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2017, Antalya, DOI: 10.1109/SIU.2017.7960267.
6. Ç. M. Yılmaz ve C. Köse, Local Binary Pattern Histogram Features for on-screen Eye-Gaze Direction Estimation and a Comparison of Appearance based Methods, 39th International Conference on Telecommunications and Signal Processing (TSP), Haziran 2016, Viyana, 693-696, DOI: 10.1109/TSP.2016.7760973.
7. Ç. M. Yılmaz ve C. Köse, Eye Gaze Direction Detection using Principal Component Analysis and Appearance based Methods, 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2015, Malatya, 1050-1053, DOI: 10.1109/SIU.2015.7130013.
8. Ç. M. Yılmaz ve C. Köse, Computer Control and Interaction using Eye Gaze Direction Detection, 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Nisan 2014, Trabzon, 1658-1661, DOI: 10.1109/SIU.2014.6830565.