

Daha verimli noninvaziv beyin makine arayüzlerinin geliştirilmesi

Program Kodu: 1001

Proje No: 113E611

Proje Yürütücüsü:
Doç. Dr. Yuriy MİSHCHENKO

Araştırmacı(lar):
Doç. Dr. Zehra YILMAZ

Danışman(lar):
Prof. Dr. Aynur ÖZGE

Bursiyer(ler):
Hilmi YANAR
Erkan ÖZBAY
Murat KAYA
Emre SAĞLAM
Umut SÜRMEİ

ÖNSÖZ

Bu proje Toros Üniversitesi Bilgisayar Mühendisliği Bölümünde 1 Temmuz 2014 –31 Ağustos 2016 ve daha sonra İzmir Ekonomi Üniversitesi Biyomedikal Mühendisliği Bölümünde 1 Eylül 2016 – 31 Aralık 2017 tarihleri arasında Doç. Dr. Yuriy MİSHCHENKO yürütücülüğünde gerçekleştirilmiştir. Proje TÜBİTAK tarafından, 1001 Bilimsel Ve Teknolojik Araştırma Projelerini Destekleme Programı kapsamında desteklenmiştir.

Projede yapılan çalışmalar bursiyer-lisans/lisansüstü öğrencileri Hilmi YANAR, Erkan ÖZBAY, Murat KAYA, Emre SAĞLAM ve Umut SÜRMEİ ve yürütücü olarak Doç. Dr. Yuriy MİSHCHENKO tarafından gerçekleştirilmiştir. Ayrıca, projede araştırmacı olarak çalışan Doç.Dr. Zehra YILMAZ beyin-makine arayüzünün DVM-tabanlı veri analizlerine ve bursiyer-lisans öğrencisi Emre SAĞLAM'ın çalışmalarının yürütülmesine katkıda bulunmuş, projede danışman olarak çalışan Prof.Dr. Aynur ÖZGE laboratuvarın kurulması, laboratuvar donanımının kurulması ve denetlenmesi, deneylerin tasarlanması ve raporların hazırlanmasına katkıda bulunmuştur. Bursiyer-lisans öğrencisi Murat KAYA proje kapsamında lisans programlarından mezun olmuş ve şimdi projeye bağlı bir tez konusu ile Mersin Üniversitesi Elektrik Elektronik Mühendiliği bölümünde yüksek lisans yapmaktadır. Bursiyer-yüksek lisans öğrencisi Erkan ÖZBAY proje kapsamında yüksek lisans programını tamamlamış ve şimdi Mersin Üniversitesi Biyofizik programında doktora yapmaktadır. Bursiyer-doktora öğrencisi Hilmi YANAR şu anda tez yazım aşamasındadır.

İÇİNDEKİLER

ÖZET	v
ABSTRACT	v
ŞEKİL LİSTESİ.....	vi
TABLO LİSTESİ	x
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	2
3. YÖNTEM.....	11
3.1 Proje Kapsamı.....	11
3.2 Veri Toplama	11
3.2.1 Deneysel Çalışmalar.....	11
3.2.2 BBA Etkileşme Modelleri	13
3.2.3 Ham Veri Elde Edilmesi.....	16
3.3 Veri Analizi	20
3.3.1 EEG BBA İçin Veri Analiz Yaklaşımları.....	20
3.3.2 EEG BBA Imge Sembollerinin Sınıflandırılması	29
3.3.3 EEG BBA Veri Analizi İçin Öznitelik Ön-Seçilmesi.....	31
3.3.4 Bütünleşik EEG BBA Veri İşleme Tasarımlarının Sistematik İncelenmesi	33
3.4 EEG Veri İçin Saklı Markov Modeli Tabanlı Analizi	34
3.4.1 EEG Beyin Aktivitesinin Saklı Markov Modeli	35
3.4.2 EEG Sinyal Modeli.....	35
3.4.3 EEG Kaynak Modeli	35
3.4.4 Empirik EEG Modellerinin Parametre Tahmin Edilmesi	37
3.4.4.1 Saklı Durum Örneklerinin Üretilmesi	37
3.4.5 EEG BBA Zihinsel Durumların Tahmin Edilmesi	42
4. BULGULAR VE TARTIŞMA	43
4.1 Yeni EEG BBA Veri Seti	43
4.2 EEG BBA Sinyal ve Veri İşleme Yazılım Altyapısı	56

4.3 EEG BBA Kullanılarak Kullanıcı Dikkat Durumu Tespit Etme Sistemi.....	60
4.4 Motor Niyet Tabanlı Genel EEG BBA Uygulaması.....	66
4.4.1 EEG BBA Sinyal Çözücünün Optimizasyonu.....	69
4.4.2 Frekans Aralığı İle İlgili EEG Sinyalinin Bilgi İçeriği.....	73
4.4.3 Katılımcıların EEG BBA Performanslarının Tutarlılığı ve “BBA Okur-Yazarlık”.....	74
4.4.4 EEG BBA Kullanılarak Sanal Robotun Online Kontrolü.....	75
4.5 EEG BBA İçin Makine Öğrenme Tabanlı Sinyal Çözücülerinin İyileştirilmesi	80
4.5.1 Genel Giriş	80
4.5.2 EEG BBA Performans İçin Referans Düzeyi.....	80
4.5.3 EEG BBA Uygulamalarında En İyi Makine Öğrenme Algoritması.....	81
4.5.4 EEG BBA Uygulamalarında En İyi Öznitelik Uzayı.....	83
4.5.5 EEG BBA Uygulamalarında En İyi Öznitelik Ön-Seçim Yaklaşımı	84
4.5.6 Optimize Edilmiş EEG BBA Sinyal Çözme Yaklaşımı	85
4.5.7 Uyarlanabilir Veri-Çerçevesinin Etkisi	85
4.5.8 Özet.....	86
4.6 EEG BBA Sinyalinin Temel Özellikler Konusunda Veri Toplamı	88
4.6.1 Elektrotlar Arasındaki Mesafenin Fonksiyonu Olarak EEG Montajındaki EEG Elektrotlar Arasındaki Bağımlılık.....	88
4.6.2 Geleneksel EEG Düzeni Dışında Elektrotların Aralarındaki Mesafe Daha Kısa Olacak Şekilde Yerleştirilmesi EEG Kayıtlanmasına Fayda Sağlar mı?	92
4.6.3 BBA Uygulamasında EEG Ölçümünde Hangi Elektrotlar Bilgi İçermektedir?	94
4.6.4 BBA Uygulamasındaki Elde Edilmek İstenilen Sinyaller EEG Ölçümünde Hangi Frekanslarda Kapsanmaktadır?.....	97
4.6.5 BBA Uygulamasında Belli Elektrotlardan Daha Fazla Bilgi Elde Edilebilir mi?	100
4.6.6 Elektrotlar Arası Mesafenin Standart 10/20 Sistemindeki Elektrotlar Arası Mesafeden Daha Az Mesafede Yerleştirilmesinin EEG Kaydı Açısından Bir Faydası Var mı?	102
4.6.7 Sık Elektrot Yerleştirilmiş Modelde Farklı Frekanslarda EEG Verileri Değişmekte midir?	107
4.6.8 Elektrotlar Arası Uzaklığın BBA Uygulaması İçin Önemi Nedir?	108

4.6.9 Özet.....	110
4.7 EEG Sinyali İçin Saklı Markov Model Tabanlı İstatistiksel Modellenme ve Analiz Yaklaşımının Geliştirilmesi.....	111
4.7.1 Yapay EEG Verileri Modellenmesi.....	111
4.7.2 Gerçek EEG Verilerinin Modellenmesi ve Analizi.....	115
4.7.3 Özet.....	121
5. SONUÇ	122
6. KAYNAKLAR.....	123

ÖZET

Son yıllarda nöral aktivite görüntüleme ve analiz tekniklerinin hızlı gelişimi, beyinde bilginin nasıl işlendiğinin temellerini anlamamıza yardımcı olmuştur. Aynı zamanda, beyinde bilgi işleyişi hakkında bilgi elde eden yeni yaklaşımlar ve bunlara bağlı gelişmeler birçok tıbbi nörolojik durumların yeni tedavisine yol açmıştır. Beyin-Makine veya Beyin-Bilgisayar Arayüzleri (BMA/BBA) böyle gelişmelerden bir tanedir. BMA, nörobilim, istatistik ve sayısal yöntemler ile birlikte ortaya çıkan araştırma alanı olup, insanlarla iletişim ve kontrol için beyindeki nöral aktiviteyi doğrudan kullanmaya hedeflenmektedir. BMA, son 15 yılda hızlı ilerleyip, sanal ve gerçek durumda robotik manipulatörün kontrolü gibi imkanları felçli insanlara sağlamaktadır. Noninvaziv BMA da görüntüleme için kafatası-dışı beyin aktivite görüntüleme teknikleri, başlıca elektroensefalografi (EEG), kullanır ve son yıllarda çok hızlı gelişmiştir. Bu projede, EEG beyin görüntüleme tekniği kullanılarak orijinal bir BMA sistemi geliştirilmekte ve bu sistem kapsamında yeni EEG veri analiz ve modelleme teknikleri araştırılmaktadır. Proje süresince, tam bir EEG BMA sistemi geliştirilmekte, EEG veri analizi için yeni yöntemler araştırılmakta, EEG veri konusunda EEG BMA ile ilgili temel yeni bilgiler toplanmakta ve EEG verileri için yeni istatistiksel veri modelleme yöntemi incelenmektedir.

ABSTRACT

In recent years, the rapid development of neural activity imaging and analysis techniques have helped us to understand the basics of how information is processed in the brain. At the same time, new approaches which acquire knowledge about processing of information in the brain and related developments have led to new treatments for many medical neurological conditions. Brain-Machine or Brain Computer Interfaces (BMI or BCI) is one of such developments. BMI is an emerging field of research merging neuroscience, statistics and numerical sciences, and aiming to directly use neural activity in the brain for communication and control purposes. Over the last 15 years, BMI has developed rapidly and created new opportunities for people with disabilities including virtual computer systems and real robotic manipulators by tetraplegic paralyzed individuals. Extracranial brain imaging techniques such as electroencephalography (EEG) are used in Noninvasive BMI. These techniques have developed rapidly in recent years. In this project, an original new such a BMI system is developed by using EEG brain imaging technique and developing new methods for EEG data analysis and modelling. In the project, a complete EEG-BMI system has been developed, new methods for EEG data analysis have been investigated, novel basic informations about EEG signals have been collected, and a new statistical method for modeling EEG data has been examined.

ŞEKİL LİSTESİ

Şekil 1. Deneysel veri toplama prosedürlerinin şematik gösterimi.....	12
Şekil 2. BBA etkileşimleri deneylerinde kullanılan deneyin grafiksel kullanıcı arayüzleri (eGUI)	12
Şekil 3. Bu çalışmada deneylerin çoğunda kullanılan 19+2 elektrotlu standart uluslararası 10/20 elektrot yerleştirme sistemi	17
Şekil 4. Online deney programında Sağ/Sol El Sağ/Sol Ayak Dil Hareket modeli için kullanılan ara-yüz ve katılımcı pozisyonu.....	19
Şekil 5. Deneysel programımızda kullanılan deney Anahtar Değişmeli Sağ/Sol El Hareket modeli için ara-yüz ve sanal robot simülasyon arayüzü	19
Şekil 6. Online deneylerin çalışma prensibinin şematize edilmiş hali	20
Şekil 7. DVM yaklaşımında iki tür veri noktaları ayırt etmek için azami-margin düzlem kullanılmaktadır	23
Şekil 8. Sağ el, sol el ve pasif zihinsel durumların C3-C4 (sol) ve Fp1-Fp2 (sağ) elektrotların üzerindeki ERP ayırımı ve DVM algoritmanın eğitim doğruluk eğrileri	46
Şekil 9. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar	49
Şekil 10. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar.....	50
Şekil 11. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar.....	51
Şekil 12. Geliştirdiğimiz yazılım yardımıyla elde edilen ortalama ERP eğrilerin ve ERP eğrilerin dağılım hesaplamalarının bazı örnekleri.....	57
Şekil 13. Geliştirdiğimiz yazılım yardımıyla elde edilen EEG BBA dekoderin eğitim eğrileri örnekleri	58
Şekil 14. Geliştirdiğimiz yazılım yardımıyla elde edilen öznelik önem ölçüm örnekleri.....	59
Şekil 15. EEG ve DVM tabanlı "operatör durum tespiti" BBA sisteminin çalışma diyagramı.	60

Şekil 16. Operatör durum tespiti BBA için elde edilen verilerin örneği.....	60
Şekil 17. Farklı zihinsel dikkat durumlarıyla ilişkili elektroensefalografik kayıtların örnekleri.65	
Şekil 18. EEG verilerinde farklı dikkat durumlarının tanımlanması için DVM tarafından oluşturulan ağırlık vektörleri w'ye bir örnek.	65
Şekil 19. EEG veri setinde kullanılan EEG elektrotlarının sayısının bir fonksiyonu olarak zihinsel dikkat durumu saptamasının doğruluğu	66
Şekil 20. EEG BBA verilerinde zihinsel görüntü durumlarını çözmek için kullanılan trial onset kilitli veri çerçevesinin gösterimi.....	69
Şekil 21. İki durumlu BBA ayrımı için sinyal çözücünün veri çerçevesi seçiminin parametrelerine göre doğruluğunu gösteren diyagramlar	71
Şekil 22. 0-80 Hz aralığında dar 5 Hz frekans bantları kullanmaya kısıtlanmış EEG BBA sinyal çözücüsünün performansı	74
Şekil 23. Uygun bir öznitelik uzayı ve öznitelik ön seçimi yöntemi ile EEG BBA'daki ML sınıflandırma algoritmalarının performansı	88
Şekil 24. 5F deneyimizde üç katılımcımızın elde edilmiş EEG elektrotlarının korelasyon mesafe-bağımlılık eğrileri	91
Şekil 25. 5F deneyimizde üç katılımcımızın elde edilmiş EEG elektrotlarının ortak bilgi mesafe-bağımlılık eğrileri	92
Şekil 26. Yoğunlaştırılan elektrot düzeni kullanan bir senkron Sağ El Beş Parmak 5F deneyimizdeki üç 5 cm mesafe altında olan elektrottaki ortalama olaya ilişkin potansiyeller	92
Şekil 27. Sağ ve sol el hareketlerine cevaben gelişen ve 200Hz örnekleme frekansında C3/C4 EEG elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	94
Şekil 28. Sağ-sol el, sağ-sol ayak ve dil hareketlerine cevaben ve 200Hz örnekleme frekansında C3/C4 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	94
Şekil 29. 5 parmak hareketlerine cevaben 1000Hz örnekleme frekansında C3/C4 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	95
Şekil 30. Sağ ve sol el hareketlerine cevaben gelişen ve O1/T6 EEG elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	95
Şekil 31. Sağ-sol el, sağ-sol ayak ve dil hareketlerine cevaben O1/T6 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	96
Şekil 32. 5 parmak hareketlerine cevaben O1/T6 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller	96

Şekil 33. Sırasıyla tüm elektrotlar için (sol) ve sadece C3/C4 elektrotları için (sağ) DVM eğitim grafikleri	96
Şekil 34. Frekans başına bilgi miktarı ve tüm frekanslarda kanal başına toplam bilgi miktarı	98
Şekil 35. Standart şapka 5 parmak deneyi ERP analiz örnekleri.....	98
Şekil 36. EEG standart şapka 5 parmak deneyi için 5Hz'den düşük ve $5 < f < 10$ Hz frekanslarda kanalların içerdikleri bilgi miktarı.....	99
Şekil 37. EEG standart şapka 5 parmak deneyi için $10 < f < 15$ Hz ve $15 < f < 20$ Hz frekanslarda kanalların içerdikleri bilgi miktarı	99
Şekil 38. EEG standart şapka 5 parmak deneyi için $20 < f < 25$ Hz ve $25 < f < 30$ Hz frekanslarda kanalların içerdikleri bilgi miktarı	99
Şekil 39. EEG standart şapka 5 parmak deneyi için DVM eğitim sonuçlar örnekleri.....	100
Şekil 40. Standart şapka 5 parmak deneyi “birer-kanal-ekle” ve “birer-kanal-çikart” uygulama basamağı sonuçları.....	101
Şekil 41. Tablo 31’de yapılan analiz sonuçlarına göre modellenmiş yoğunlaştırılmış EEG elektrotları haritası	103
Şekil 42. Yoğunlaştırılmış elektrot modeli ile yapılan 5F-yoğunlaştırılmış deneyi sonucu elektrotlar arası korelasyon grafiğı	103
Şekil 43. Yoğunlaştırılmış EEG elektrot modeli ile yapılan 5F-yoğunlaştırılmış deneyi sonucu oluşturulan ERP grafikleri	104
Şekil 44. Yoğunlaştırılmış elektrot modeli ile yapılan 5F-yoğunlaştırılmış deneyi sonucu elde edilen SMV grafiğı	105
Şekil 45. Standart 10/20 elektrot düzeninde direk komşu elektrot arası korelasyonlar	106
Şekil 46. Standart 10/20 elektrot düzeninde 2. komşu elektrot arası korelasyonlar	107
Şekil 47. Yoğunlaştırılmış elektrot modeline göre 5Hz'den küçük frekanslar için kanal başına biriken bilgi miktarı.....	108
Şekil 48. Standart EEG şapkası 5 parmak uygulaması için elektrot-mesafe korelasyon eğrileri	109
Şekil 49. Standart EEG şapkası sağ/sol el-sağ/sol ayak-dil uygulaması için elektrot-mesafe korelasyon eğrileri	109
Şekil 50. Standart EEG şapkası elektrotlar arası ortak bilgi ve korelasyon matrisleri	109

Şekil 51. Yoğunlaştırılmış elektrot modeli uygulaması için elektrot-arası korelasyonları	109
Şekil 52. Doğrusal ve doğrusal olmayan HMM'den elde edilen EEG verileri ile yapay EEG verilerinin karşılaştırılması.	113
Şekil 53. Doğrusal ve doğrusal olmayan HMM'inden 3 makro durumu tahmin etmedeki t-tabanlı hata oranının SNR'ye göre değişimi.....	114
Şekil 54. Doğrusal ve doğrusal olmayan HMM'inden 6 makro durumu tahmin etmedeki t-tabanlı hata oranının SNR'ye göre değişimi.....	115
Şekil 55. Baze katılımcıların EEG verisi ile HMM'den elde edilen EEG verisinin grafiksel karşılaştırılması	118

TABLO LİSTESİ

Tablo 1. Standart EEG frekans bantlarının tanımları.....	25
Tablo 2. Farklı özniteliklerin basit EEG BBA olay sınıflandırılması için tipik performans karşılaştırılma sonuçları.....	29
Tablo 3. Çalışmamızda değerlendirilen öznitelik uzay seçimlerini, öznitelik ön seçim algoritmalarını ve ML sınıflandırma algoritmalarını listesi.....	31
Tablo 4. Rastgele seçilmiş değerlendirme ilişkin BBA performansındaki varyasyon, katılımcı ilişkin performans varyasyonu, ve güne ilişkin performans varyasyonu	34
Tablo 5.SMC yöntemine dayalı ileri geçiş algoritması.....	40
Tablo 6.SMC yöntemine dayalı geri geçiş algoritması	40
Tablo 7.FREEFORM'daki sağ-sol el hareketlerinin EEG verilerden tespiti.....	46
Tablo 8. Deneylede bulunan katılımcıların demografik ve deney bilgileri	52
Tablo 9. Deneysel veri setimizin BBA iletişim modellerine göre bölümü ve bazı istatistikler.	54
Tablo 10. Toplanan verilerde DVM kullanılarak tipik zihinsel durum ayırma kalitesi ve ilgili istatistikler	55
Tablo 11.Toplanan veri setinde kullanılan etiketler ve kısaltmalar	55
Tablo 12. Yazılımımız tarafından toplanan EEG BBA verilerinin formatı.....	56
Tablo 13. Öznitelik ön-seçimin EEG BBA performansına etkisi.....	60
Tablo 14. Hedef zihinsel durum değişkeni ile sınıf içi korelasyon katsayısına (ICC) dayalı 25 en önemli özneliğin istatistiksel özellikleri	63
Tablo 15. Ayır ayrı eğitilen makine öğrenme algoritmalarının kullanılması durumunda dikkat durumlarının tespit doğruluğu	64
Tablo 16. Genel makine öğrenme algoritmasının kullanılması durumunda dikkat durumlarının tespit doğruluğu.....	64
Tablo 17. Katılımcıların 2-durumlu EEG BBA ayırım görevindeki performansları.....	67
Tablo 18. Katılımcıların 3-durumlu EEG BBA ayırım görevindeki performansları.....	68
Tablo 19. Katılımcıların 6-durumlu EEG BBA ayırım görevindeki performansları.....	69
Tablo 20. EEG BBA verilerinin farklı öznitelik gösterimlerinin EEG BBA'daki 2, 3 ve 6 durumlu zihinsel görüntü ayırım görevi üzerindeki performansı	72
Tablo 21. EEG BBA'daki 2, 3 ve 6 durumlu zihinsel görüntü ayırım görevindeki farklı referans mod çıkarma seçimlerinin performansı	73

Tablo 22. Katılımcıların genel performans seviyelerine göre sıralanmış, farklı katılımcıların farklı BBA iletişim görevlerindeki tutarlı performansları	75
Tablo 23. Online BBA kontrol deneylerinde katılımcıların performansı	76
Tablo 24. Veri setimiz üzerindeki LDA+PSD uygulama sonuçlarına dayanan EEG BBA referans performans düzeyleri	81
Tablo 25. Farklı BBA sembol sınıflandırma algoritmalarını karşılaştırmak için kullanılan sıra birleştirme prosedürü için bir tablodan bir alıntı.....	82
Tablo 26. Tüm öznitelik uzayı kullanıldığında ve öznitelik ön seçimi yapılmadığında, EEG BBA'daki farklı ML sınıflandırma algoritmalarının sıralamaları ve karşılık gelen katılımcı-ortalama doğrulukları	83
Tablo 27. Belirli farklı öznitelik uzaylarını kullanan EEG BBA'daki ML sınıflandırma algoritmalarının performansları	83
Tablo 28. Öznitelik uzayları ve öznitelik ön seçim seçeneklerini kullanan Tablo 26 'da verilen EEG BBA'daki en iyi 4 ML sınıflandırma algoritmasının performansları	84
Tablo 29. En iyi öznitelik uzayı ve öznitelik ön seçimi kullanıldığında EEG BBA'daki farklı ML sınıflandırma algoritmalarının sıralamaları ve karşılık gelen katılımcı-ortalama performansları	85
Tablo 30. Uyarlanabilir veri çerçevelerinin BBA sembol sınıflandırmasına etkisi	86
Tablo 31. Frekans, ERP analizleri sinyal ayrımı ve “ekle-bir-kanal” / “çıkart-bir-kanal” program basmakları ile yapılan analiz sonuçları	102
Tablo 32. Doğrusal ve doğrusal olmayan HHM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının iterasyon sayısına göre değişimi	112
Tablo 33. Doğrusal ve doğrusal olmayan HHM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının EEG kaynak sayılarına göre değişimi.....	112
Tablo 34. Doğrusal ve doğrusal olmayan HHM'lerinin katılımcı H1'nin 3 ve 6 zihinsel durumlu EEG verilerini açıklamadaki başarı oranlarının iterasyon sayılarına göre değişimi.....	116
Tablo 35. Doğrusal ve doğrusal olmayan HHM'lerinin katılımcı H1'nin 3 zihinsel durumlu EEG verilerini açıklamadaki başarı oranlarının EEG kaynak sayılarına göre değişimi.....	116
Tablo 36. Doğrusal ve doğrusal olmayan HHM'lerinin katılımcıların 6-zihinsel durumlu EEG verilerini modelleme başarı oranları.....	117

Tablo 37. Katılımcıların EEG verilerindeki farklı zihinsel durumlarının MLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları	119
Tablo 38. Katılımcıların EEG verilerindeki farklı zihinsel durumlarının IMLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları	120
Tablo 39. Bir katılımcının EEG verilerindeki farklı zihinsel durumların MLE ve IMLE yöntemleri kullanılarak çizgisel ve çizgisel olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları	121
Tablo 40. Bir katılımcının EEG verilerindeki farklı zihinsel durumların MLE ve IMLE yöntemleri kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları.....	121

1. GİRİŞ

Travma veya diğer tıbbi durumlardan dolayı felçli kalan hastalar motor ve iletişim fonksiyonlarının büyük ölçüde eksikliğini çekerler. Nöral protezlerdeki son gelişmeler bu tür hastalara belirli motor ve iletişim becerilerini tekrar kontrol edebilmelerini sağlayarak durumlarını iyileştirme potansiyeli sunar (Chaudhary vd., 2016; Kryger vd., 2016; Wolpaw vd., 2002). Hedeflenen kasın tekrardan sinir sistemine bağlanması (Kuiken vd., 2009) ve kalıntı kas aktivitesine bağlı miyoelektrik kontrol (Cipriani vd., 2011, 2014; Resnik vd., 2014) nöral protezler için heyecan verici olanaklar sunar. Bir diğer olanak ise beyindeki sinirsel aktiviteyi harici cihazlar için kontrol sinyaline çevirmeyi amaçlayan Beyin-Bilgisayar arayüzleri (BBA) ile sunulur (Contreras-Vidal vd., 2012; Gharabaghi vd., 2014; Hill vd., 2006; Hong vd., 2015; Lebedev ve Nicolelis, 2006; Pailla vd., 2016). BBA'daki önemli gelişmeler, maymunlar (Kim vd., 2006; Musallam vd., 2004; Serruya vd., 2002; Taylor vd., 2002), insan olmayan primatlar (Carmena vd., 2003a; Clanton vd., 2013; Velliste vd., 2008) ve insanlardaki (Bradberry vd., 2011; Ganguly ve Carmena, 2009; Hochberg vd., 2006; McFarland vd., 2010; Schalk vd., 2008) robotik devindiricilerin sinirsel kontrolünü kapsamaktadır. Son yıllardaki araştırmalar, kafatası içi temelli BBA kullanılmasıyla, tetraplejik bireylerin 3 boyutlu kol hareketlerinde yüksek performans kontrolü sağladığını göstermiştir (Collinger vd., 2012; Hochberg vd., 2012). Bu bağlamda, invaziv BBA, yardımcı robotik cihazların yüksek serbestlik dereceli kontrolü için önemli bir potansiyel sunmaktadır (Collinger vd., 2012; Hochberg vd., 2012; Velliste vd., 2008). Hochberg ve arkadaşları (Hochberg vd., 2006) birincil motor korteks alanına 96 mikroelektrot dizisi nakledilmiş tetraplejik hastası bir insan için sonuçları rapor etmişlerdir. Bu hasta 9 ay süren 57 ardışık oturumlu kurs sonucunda e-postaları okumak, harici cihazları yönetmek ve nesnelere bir robot manipülatörü aracılığıyla taşımak için kullanılabilen bilgisayar ekranındaki 2 boyutlu imleç hareketlerinin BBA kontrolünü başarabilmiştir. Daha yeni sonuçlar tetraplejik bir hasta tarafından 3 boyutlu erişim ve kavrama gibi el hareketlerinin yüksek performanslı kontrolünün sağlanmasında BBA'nın yeteneğini göstermiştir (Hochberg vd., 2012). Collinger ve arkadaşlarının yapmış oldukları çalışmada tetraplejik bir hasta kafatası-içi temelli invaziv BBA'yı kullanarak 7 dof robotik manipülatör kolunu kontrol etmeyi öğrenebilmiştir (Collinger vd., 2012). Bu bağlamda kafatası-içi temelli invaziv BBA robotik protez teknolojisi için önemli bir potansiyel teşkil etmektedir (Collinger vd., 2012; Hochberg vd., 2012; Velliste vd., 2008). Bu etkileyici başarılar ile birlikte, kafatası-içi temelli BBA'nın en önemli sorunu sinirsel aktivite görüntüleme elektrotlarını yerleştirmek için gerekli invaziv beyin ameliyatıdır. Böyle riskli beyin ameliyatını gerektirmeyen BBA araştırmaları da büyük ilgi görmektedir.

Bunlar arasında elektroensefalografik (EEG) BBA, teknolojinin olgunluğu, nispeten düşük maliyeti, kolay kullanımı ve en yeni EEG cihazlarının sağlamlığı ve taşınabilirliği sayesinde önemli bir yön sunmaktadır. EEG BBA ile ilgili önemli ilerlemeler literatürde bildirilmiştir. Wolpaw ve McFarland'ın öncü çalışmaları, sensorimotor ritim modülasyonunun kullanılmasıyla bir bilgisayar ekranındaki imleç hareketlerinin 1D, 2D ve 3D kontrolünü göstermiştir (McFarland vd., 2010; Wolpaw ve McFarland, 2004; Wolpaw vd., 1991). EEG BBA, robotik tekerlekli sandalyelerin gerçek zamanlı kontrolü (Wilkinson, 2009), iyileştirici beyin pili (Pfurtscheller vd., 2003), robot kontrol (Chae vd., 2012), dış iskelet giysileri (exoskeleton suits) (Sankai, 2011) ve birçok heyecan verici digger uygulama için kullanılmıştır (Ang vd., 2014; Bastos vd., 2011; Bell vd., 2008; Kwak vd., 2015; Perrin vd., 2010; Soekadar vd., 2016).

Bu projede amacımız, (Collinger vd., 2012; Hochberg vd., 2012; Velliste vd., 2008) çalışmalarında ele alınanlara benzer bir biçimde, ciddi felçli veya kımıldayamaz duruma gelmiş hastalar için yardımcı robotik bileşenlerin bir parçası olarak ele alınan robotik manipülatörlerin gelecekte yüksek performans kontrolünü mümkün kılma potansiyeline sahip noninvaziv EEG BBA geliştirmektir. Bu proje, beyin aktivitesi görüntüleme, veri kaydetme ve işleme, veri analizi, kontrol sinyalinin üretilmesi ve harici bir cihazı kullanma aşamalarının tümünü içeren bu gibi EEG BBA sistemlerini kendi bünyesinde gerçekleştirme kabiliyetini geliştirmektedir. Makine öğrenmesindeki modern gelişmelere dayanan farklı EEG veri analiz yaklaşımları ele alınmış ve sözü geçen sistemde uygulanmıştır, EEG BBA verilerini analiz etme becerisinde önemli gelişmeler sağlanmıştır. EEG veri toplama kafa takımlarının olası alternatif fiziksel konfigürasyonlarının potansiyelinin araştırılması da dahil olmak üzere, EEG BBA'nın performansını artırmaya yönelik çeşitli alternatif yaklaşımlar göz önüne alınmıştır. Ayrıca EEG BBA sinyalinin modellenmesi için, EEG sinyalini betimleme ve tahmin etme becerimizi arttırmayı ve böylece EEG sinyalinden yararlı bilgileri çıkarmayı amaçlayan saklı Markov modelleri ve bayes tahmini temellerine dayanan gelişmiş istatistiksel yaklaşım geliştirilmiştir.

2. LİTERATÜR ÖZETİ

İlk BMA çalışmaları, geçmiş elli yıldan fazla olan insan-bilgisayar iletişimi için doğrudan nöral aktivite kullanılabilirliğinin gösterildiği çalışmalardır. Fetz ve arkadaşları tarafından yapılan ilk araştırmalar, bireyler tarafından beyindeki belirli nöron aktivitesinin kontrol edilebileceğini göstermiştir (Fetz ve Baker, 1973; Fetz ve Finocchio, 1971, 1972; Fetz, 1969; Schmidt, 1980; Schmidt vd., 1978). Fetz ve arkadaşlarının çalışmaları dışında, BMA alanındaki dönüm noktalarını içeren çalışmalar, beynin içine mikroeletrot dizi yerleştirilmesiyle görüntülenen

motor korteksindeki nöral populasyonların aktivitesinin kullanılmasıyla maymunların robotik kolu kontrol edebileceğinin gösterildiği Donoghue, Schwartz ve Nicolelis laboratuvarlarının çalışmalarıdır (Carmena vd., 2003b; Lebedev vd., 2005; Musallam vd., 2004; Santhanam vd., 2006; Santucci vd., 2005; Serruya ve Donoghue, 2003; Wessberg vd., 2000; Wolpaw ve McFarland, 2004). Bu ilklere imza atan çalışmalarda, maymunun sensorimotor korteksinde olan 16-64 mikroeletrot dizisi kullanılarak bir sanal robot kolu ile “erişme ve tutma” denemeleri gerçekleştirilmiştir (Carmena vd., 2003b). Maymunlar, bir meyve suyu ödülü ile teşvik edilerek ve görsel geri besleme kullanarak sanal elin kontrolünü sağlamıştır. Nöral aktivite ile harici çalıştırıcı kontrolünün yapılabiliğini göstermesi dışında, BBA işlemi esnasında fonksiyonel kortikal organizasyonunun değiştiği keşfedilmiştir. Daha sonraki (Lebedev vd., 2005) çalışmasında, maymunun motor korteksindeki nöronların aktivite görüntüleri kullanılmış ve uzuvların hareketi olmadan gerçek yapay çalıştırıcının hareketlerinin kontrol edilebileceği gösterilmiştir. Kortekste temel sinirsel simgelerin BBA öğrenmesine cevaben hızlı değiştiği de ortaya çıkartılmıştır. (Velliste vd., 2008) çalışmasında, maymun böyle bir BBA sistemi kullanarak robotik kolu kontrol edip kendi kendini besleyebilmiştir. Bu deneyde maymun, motor korteksindeki nöral aktiviteyi kullanarak gerçek manipulatörün üç boyutlu hareketini kontrol etmiştir. Robotik kol ve gerçek nesnel arasındaki fiziksel etkileşimler yüzünden bu yeni görevin daha önceki sanal deneyler ile karşılaştırılmasında büyük zorlukları vardı. Bu çalışmada, nöral aktivite analizi olarak gerçek zamanlı kayıtlı nöral populasyonun atış hızı vektörü ağırlıklandırılıp bireysel nöronların tercih edilen yönleri ile çarpılıp toplanmış ve bu şekilde manipulatörün hızı belirtilmiştir. Son zamanlarda, Pittsburgh Üniversitesindeki araştırmacılar beyin-içi mikroeletrot dizisi kullanarak benzer şekilde tetraplejik bir felçli insanın robot kolu kullanarak kendi kendini besleyebildiğini göstermiştir (Collinger vd., 2012).

Böyle invaziv (iç) teknik ile beraber, son yıllarda noninvaziv (dış) nöral aktivite görüntüleme tekniklerine, özellikle elektroensefalografi, elektromiyografi, ve fonksiyonel manyetik rezonans görüntülemeye dayanan BBA yöntemlerinde önemli ilerlemeler sağlanmıştır. İnvaziv teknikler için önemli olan zorluk, mikroeletrot dizilerinin beyinde yerleştirilmesi için cerrahi müdahale gerekliliğidir. Ayrıca, BBA sinyalini bozabilen mikroeletrotlar etrafındaki dokularda sık sık çizikler görülmüştür. Bu problem, invaziv BBA yöntemlerinde algılayıcının sinyal kalitesinin zamanla düşmesine yol açar. Bu zorluklar nedeniyle, BBA için noninvaziv tekniklerin kullanılabileceği araştırmalar önemli odak noktasıdır.

Noninvaziv teknikler arasında, elektromiyografi (EMG)–iskelet kaslarına ulaşan çevresel sınırlardan elektriksel sinyal kaydetme–en kolay nöral aktivite görüntüleme yöntemidir. EMG, direkt olarak motor nöronlarının aktivitesine dayalı olması sebebiyle yüksek sinyal

çözünürlüğü ve özgünlük sağlar. Örneğin EMG, bir elektromekanik kol kontrolü için kol ve avuç içi hareketlerini kontrol eden sinirlerdeki sinyalleri bu şekilde doğrudan kullanabilir. Ayrıca EMG, nöral aktiviteyi çevresel sinirlerden tenin yüzeyinden de kayıt edebilir (surface EMG veya sEMG). EMG sensorleri çoğu temel EEG sistemlerinden bile önemli oranda çok daha ucuzdur. Bu avantajlar pratik nöroprotezler için sEMG kullanımında önemli ilerlemelere yol açmıştır. Fiziksel hareket veya gerçek konuşmaya ihtiyaç olmaksızın alt vokal ile gırtlak kası kontrol edilerek konuşmanın bozulmasıyla iletişim sağlayan “The Audeo” diye adlandırılan ticari bir ürün piyasaya çıkmıştır. Akademik çalışmalar, bileğin (Jiang vd., 2011) ve dirseğin (Giuffrida ve Crago, 2004, 2005; Giuffrida, 2004) kinematik kontrolünün yani sıra sEMG (Matrone vd., 2012; Tenore vd., 2009) ile parmak hareketlerinin kontrolü için metod araştırıp pratik bir robotik el protezi göstermiştir. Aynı zamanda, EMG BBA’lar, motor nöronlarının çevresel aktivitesine bağlı olduğu için tam anlamıyla doğru BMA değiller, yani EMG BMA’nın kontrolü, motor aktivitesinin bir türü kullanılarak “saf” zihinsel süreçler tarafından sağlanmaz.

Fonksiyonel manyetik rezonans görüntüleme (fMRI), beyinin farklı alanlarında kan akımı değişikliklerine dayanan üç boyutlu beyindeki nöral aktivite görüntüleme tekniğidir. Aktif beyin alanlarında yüksek seviyede aktivite sağlayacak enerji miktarı artar; bu durumda oksijen tüketimi ve dolayısıyla kan akışı da artar (hemodinamik cevabı). Bu yüzden manyetik rezonans kullanarak gözlenen hemodinamik cevap farklı zihinsel prosesler esnasında beyinin uzay-zamansal aktivasyon görüntüsünü sağlar. fMRI’ın başlıca avantajı nispeten iyi uzay çözünürlüğüdür (1mm); buna karşın nispeten kötü zaman çözünürlüğü (hemodinamik cevabının hızı yaklaşık olarak 1-10 sanyedir), maliyeti ve hacmi büyük dezavantajlarıdır. Hala son on yılda fMRI BBA araştırmalarında önemli ilerlemeler sağlanmaktadır. 2007’de Pittsburg beyin aktivite yorumlama yarışında sanal gerçeklik çevrelerinde oynu oynayan deneklerin durumunu takip etmek için fMRI BBA örnekleri sunulmuştur. Yarışta, bu amacı yüksek doğrulukla sağlayan bir kaç fMRI BBA yöntemi ortaya çıkartılmıştır (<http://pbc.lrdc.pitt.edu>). fMRI sinyalini kullanarak denek tarafından izlenen görsel görüntüleri belirleyebilir yöntemler de gösterilmiştir (Miyawaki vd., 2008; Nishimoto vd., 2011).

Yine de, noninvaziv tekniklerinin arasında BBA’da en fazla elektroensefalografi (EEG) görüntüleme tekniği kullanılır. EEG görüntüleme, beyindeki nöronların elektriksel aktivitesi tarafından üretilen elektrik potansiyel değişikliklerinin kafatası yüzeyinden kayıt edilmesidir. EEG’de saptanan elektrik sinyali, kafatası kemiklerinin yani sıra dokulardan elektrotlara geçmek durumundadır. Bu nedenle EEG görüntülerinin uzay çözünürlüğünün kötü olduğu bilinmektedir. Diğer taraftan, EEG’nin zaman çözünürlüğü çok yüksektir (birkaç milisaniye mertebesindedir). EEG’nin diğer avantajları, teknolojinin olgunlaşması, taşınabilirliği ve

nispeten düşük masrafıdır. İlişkili teknikler, kalp-içi EEG veya elektrokortikografi (iEEG veya ECoG) dır. iEEG, nöral doku içerisine nakil olmaksızın, kafatası altında ama beyin yüzeyine yerleştirilen bir mikroelektrot dizisi kullanan nöral aktivite görüntüleme tekniğidir. iEEG daha iyi uzay çözümü veren bir görüntüleme opsiyonudur (Pei vd., 2011; Schalk vd., 2008; Yanagisawa vd., 2011). Ancak, iEEG'in çok büyük dezavantajı iç mikroelektrotların yerleştirilmesi için cerrahi müdahale gerekliliğidir.

EEG BBA'nın gelişmesi, EEG'deki P300 diye adlandırılan olay-ilişki-potansiyelinin (event-related potential, ERP) 1960 yıllarındaki keşfi ile başlamıştır (Chapman ve Bragdon, 1964; Sur ve Sinha, 2009; Sutton vd., 1965, 1967). P300, deneğin bir uyarıcıya dikkatini verdiği zamanda parietal lob elektrotlarında görünen stereotipik bir EEG sinyal desenidir. P300, deneğin uyarıcıya dikkatini vermesinden sonra tipik olarak 300-500ms içinde EEG sinyalindeki pozitif sapmadır. Bu EEG olgusunu kullanarak en temel BBA cihazı, 1980 yıllarında ortaya çıkartılmıştır. P300-dekoder, P300 "evet-hayır" sinyali olarak kullanılarak "locked-in" sendromu gibi ciddi felçli kişilere iletişim fırsatı sunmuştur. P300-dekoder, bireye alfabe harflerini ardaşık gösterip dikkati verilen harfleri belirlemiş ve bu şekilde felçli birey tarafından niyetlenen kelimeler ve cümleler ortaya çıkartılabilmıştır (Donchin vd., 2000; Farwell ve Donchin, 1988; Piccione vd., 2006).

EEG BBA alanında gelişmeler, güçlü bilgisayarlar ve yeni makine öğrenme yaklaşımlarının geliştirilmesi sayesinde, son 10-15 yılda hız kazanmıştır. Bu çalışmaların en önemlilerinin birinde, McFarland ve arkadaşları tarafından gösterilen motor eylem düşünelere bağlı olarak deneğin EEG ritimlerindeki değişikliklerine dayanan bir BBA metodu oluşturulmuştur (Wolpaw ve McFarland, 2004). Bu çalışma, EEG sinyali kullanılarak, deneğin sağ ve sol el hareketi düşünelere bağlı olan bilgisayar ekranı üzerindeki imlecin iki boyutlu hareket kontrolünü göstermiştir. Bu çalışmada, sağ ve sol sensorimotor alanları üzerine yerleştirilen EEG elektrotlarındaki sinyalin, özellikle standart 10/20 sisteminin C3 ve C4 elektrotlarındaki sinyalin, μ (mu, 8-12Hz) ve β (beta, 13-30Hz) ensefalografik ritimlerin genliği kullanılıyordu. Bu şekilde elde edilen EEG sinyali için, sağ ve sol elektrotlar arasında yukarıdaki frekans bantlarında EEG'nin spektral güç farkı ölçülmüştür. Bu ölçüm, imlecin iki boyutlu hareketi lineer model kullanılarak lineer şekilde verilmiş, yani μ ve β frekans bantlarında sağ ve sol sensorimotor alanındaki EEG spektral güç farkına göre imleci sola sağa ve yukarıya aşağıya hareket ettirebilmiştir. Bu şekilde, denekler sağ ve sol el hareketini düşünerek imlecin pozisyonunu kontrol edebilmiştir. Böyle BBA'lar, Sensorimotor Ritim Modülasyon (SMR) olarak nitelendirilir. Bu tip BBA, deneğin beynindeki sensorimotor EEG ritimlerinin modülasyon edilmesi sayesinde harici cihazlara bilgi iletebilmektedir. Bu çalışmada, böyle SMR EEG BBA performansının (Carmena vd., 2003b; Musallam vd., 2004; Serruya ve

Donoghue, 2003)'deki invazif BBA'ların performansı ile karşılaştırılabildiği gösterilmiştir. Müteakip çalışmalarda, McFarland ve arkadaşları EEG ritmi kullanan daha verimli iletişim protokolleri ve üç boyutlu hareketin kontrolünü göstermiştir (Friedrich vd., 2009; McFarland ve Wolpaw, 2008; McFarland ve Wolpaw, 2008, 2010; McFarland vd., 2008, 2010). İlk başta motor eylemler düşünerek imlecin hareketlerini kontrol edebilen deneklerin daha sonra EEG ritimlerini direkt olarak ayarlamayı öğrenebildiği ortaya çıkmıştır. Bu bulguya göre bireyler, beyin ritimlerinin kontrolünü öğrenip herhangi genel araç veya cihaza benzer olarak BBA cihazlarının kullanımı da direkt olarak öğrenebilmektedir (McFarland ve Wolpaw, 2008, 2010; McFarland vd., 2008, 2010).

SMR BBA yöntemlerinin uygulanabilmesindeki ana dezavantaj, bireylerin eğitim sürecinin çok uzun (1 aydan fazla) olmasıdır. Bu sıkıntıdan dolayı yeni EEG BBA çalışmaları, uzun sensörimotor ritim kontrolü eğitimi yerine kısa BBA ölçümlerle oturumu getirmeye başlamıştır.

Sonraki çalışmalarda (Bradberry vd., 2010, 2011), bilgisayar imleç hareketleri için kişinin EEG ritimleri ile ilgili olarak benzer bir yaklaşım kullanıldı fakat (Wolpaw ve McFarland, 2004)'deki eğitilmiş EEG tasarımına karşı doğal EEG tasarımıyla ilgili olarak BBA sistemine ulaşmak amaçlanmıştır. Bu çalışmada, 34 kanallı bir EEG kullanılmış ve imleç hareketleri EEG sinyallerindeki değişime lineer model yoluyla bağlanmıştır. (Wolpaw ve McFarland, 2004)'deki uzun eğitim süreci yerine kısa kalibrasyon oturumu kullanılan EEG BBA, hedef ve tahmin edilmiş imlecin yörüngeleri arasında 0.5-0.7 aralığında olan korelasyon katsayısını sağlayabilmiş ve tahmin edilen hareketlerin doğruluğunun %50-80 aralığında olduğunu göstermiştir. Aynı çalışmada, EEG sinyalindeki imleç hareketlerinin kodlanmasında yer alan bölgeler recentral gyrus, postcentral gyrus, lateral premotor cortex, superior temporal sulcus ve dorsal ve ventral bölgeler olarak belirlenmiştir

Yukarıdaki çalışmalarda imleç hareketini ayarlamak için EEG sinyali ve imleç hareketini sağlayan sürekli bir model kullanılırken diğer birçok EEG BBA çalışmalarında imleç yada robot hareketini ayarlamak için birkaç ayrı zihinsel durum kullanılmıştır. Yani, yukarıdaki EEG BBA çalışmalarında EEG sinyalindeki değişim imleç hareketini sürekli şekilde etkilerken, ikinci tip EEG BBA çalışmalarında denek tarafından uygulanmış motor eylem düşünceleri, imlecin ayrı "sağ/sol dön" ve "ileri/geri hareket et" emirleri olarak kullanılmıştır. Bunlar için genellikle sağ el, sol el ve ayak hareketi düşünceleri kullanılmış ve ham verilerden var olan zihinsel hali belirlemek için bir makine öğrenme sınıflandırma yöntemi kullanılmıştır. Birinci tip EEG BBA'lara EEG sinyal ve imleç hareketini bağlayan regresyon modeli kullanan BBA'lar denirken, ikinci tip olanlara EEG BBA sınıflandırma modeli kullanan BBA'lar denmektedir.

Özellikle, Berlin beyin-bilgisayar arayüzey projesinde (BBBA) büyük bir ekip “modern makine öğrenme metodlarının uygulamalarını ve beyinin nasıl anladığını geliştiren yeni sensor teknolojisi” geliştirerek EEG BBA üzerine çalışmaktadır (<http://www.bbci.de>). BBBA projesinin amaçları arasında, bireyin öğretimini gerektirmeyen, “doğal” nöral EEG sinyali kullanan BBA yaklaşımı geliştirmek yer almaktadır (Blankertz vd., 2007a, 2007b, 2008; Blankertz, Dornhege, Krauledat, Müller, vd., 2006; Krauledat vd., 2008). Bu projede, 128 elektrot yoğun-EEG ve makine öğrenmesinin Linear (Fisher) Discriminant Analysis (LDA) yöntemine bağlı veri işleme yaklaşımı kullanılmış ve zihinsel durumlar olarak bireylerin sağ/sol el ve ayak hareket düşünceleri kullanılmıştır. Bireyin uzun öğretimi yerine daha kısa bir kalibrasyon için pratik bir oturum kullanılmıştır. Bu durumda sözü geçen üç zihinsel durumun %80-%90 doğrulukla belirlenebildiği belirtilmiştir. BBBA projesi tarafından dört EEG BBA yarışı düzenlenmiştir (BCI Competition I-IV, en son olan 2008’de düzenlenmiştir) ve onların sonuçları İnternette açıklanmıştır.

Diğer BBA grupları tarafından farklı veri analiz ve deneysel modeller incelenmiştir. Doğrusal Diskriminant (Linear discriminants (LDA and QDA)) ve destek vektör makinelerinden (support vector machines (SVM)) kompleks nöral ağlara kadar bir çok farklı makine öğrenme teknikleri uygulanmıştır (Lotte vd., 2007). Bunlar genellikle EEG BBA uygulamalarında %80-90 doğruluk göstermiştir. Bunlardan en gelişmiş olan yaklaşım, EEG BBA’da kullanılan zihinsel durumları EEG sinyalinden belirlemek için kullanılan yapay sinir ağları ve “fuzzy hybrid” sinir ağlarıdır. Zihinsel eylemler olarak sağ/sol el parmakları ve ayak hareketi, 3D geometrik şekil sanal dönüşü ve matematiksel hesaplama işleri kullanmıştır (Barbosa vd., 2009; Gupta vd., 2008; Jia vd., 2004; Palaniappan ve Raveendran, 2001). Böyle dört beş zihinsel durumun 70-90% doğrulukla belirlenebildiği belirtilmiştir. Bu çalışmalar bir derleme makalede kapsamlı olarak incelenmiştir (Lotte vd., 2007). Ona göre, BBA uygulamalarında iki ile beş arasındaki zihinsel durumun %80-90 doğrulukla tespit edilebildiği görülmektedir. İletişim için kullanılacak zihinsel eylemler olarak sağ/sol el parmakları ve ayak hareketi, 3 boyutlu geometrik şekil sanal dönüşü ve matematiksel hesaplama işleri belirtilmiştir (Barbosa vd., 2009; Gupta vd., 2008; Jia vd., 2004; Palaniappan ve Raveendran, 2001).

Araştırmalarda ortaya çıkan diğer önemli bir EEG BBA konusu, EEG BBA öğretim süresinde geribildirim (feedback) kullanılmasıdır. (Hwang vd., 2009)’da yazarlar, EEG BBA sistemi öğretilmesinde görsel geribildirim kullanımını tartışmıştır. Deneylerde, 10 denekten yarısına beyin aktivitesi haritasını gösteren 30 dakikalık eğitim oturumu verilmiştir. Kalan beş deneğe görsel geribildirim verilmemiştir. Eğitilmiş tüm deneklerin doğru görüntülenmiş hareketleri kullanmada başarılı olduğu rapor edilmiştir. İki grup öğretim öncesinde BBA kullanarak %60 ve %65, öğretim sonrasında ise %70 ve %65 doğruluklar elde etmişlerdir. Bu sonuçlara

göre, BBA öğretiminde geribildirim önemli olduğu belirtilmiştir. Benzer şekilde, (Iversen vd., 2008)'de sinir bozukluğu hastalığı olan Amyotrophic Lateral Sclerosis (ALS)'den acı çeken iki hastaya bilgisayar imleci taşıyan EEG BBA'yı öğretirken görsel geribildirim verilmiştir. Denekler, deney sırasında %85 ve %83'lük bir ortalama doğruluğa ulaşmıştır.

Daha yeni EEG BBA yöntemi, görsel çağrışımında durağan durum potansiyeli (Steady State Visual Evoked Potentials, SSVEP) kullanan EEG BBA yöntemidir. SSVEP, 3,5-90 Hz frekansla gösterilen görsel uyarıcılara karşılık gelen beynin görsel korteksi üzerinde gelişen aynı frekansta bir EEG tepkisidir. SSVEP'nin önemli tarafı, 30 Hz üstünde olan ve dolayısıyla normalde gözle görünemeyen sinyallerin de SSVEP üzerinde izlenebilmesidir. Örneğin, bireye gösterilen görsel uyarıcı farklı frekanslarda ayarlanarak bireyin görsel korteksindeki tepkisi EEG ile izlenebilmektedir (Chen vd., 2015; Sirvent Blasco vd., 2012; Yin vd., 2015).

Son beş yılda EEG BBA çalışmaları uzaktan robot kontrolü, tekerlekli sandalye kontrolü ve bilgisayar kullanımı gibi pratik durumlarda böyle EEG BBAlarının uygulamaları üzerine yoğunlaşmıştır. (QiBin vd., 2009)'da araba kontrolü için motor korteks üzerinde 5 EEG elektrodunun kullanıldığı EEG BBA sistemi gösterilmiştir. Denekler, sanal arabayı sağ veya sol el hareketi ve ayak hareketi düşünerek kontrol etmişlerdir. Bir "kümülatif artan kontrol" stratejisi kullanılmış, yani durum kademeli olarak güncelleştirilmiş, düşünülen sağ el hareketi kademeli direksiyonu hareket ettirmiş ve bununla beraber düşünülen sol el hareketi kademeli sola hareket ettirmiştir. BBA tarafından belirlenmiş geçerli zihinsel durum kullanıcıya sürekli olarak geribildirim olarak gösterilmiştir. Birkaç eğitim oturumundan sonra %75 üzerinde bir performans ulaşılabildiği sonucuna varılmıştır. 0.5 saniye bir aralıkla elde edilen en iyi doğruluk performansı %70 iken daha dar aralıklarla elde edilen performans daha düşük olmuştur. (Wu vd., 2008) çalışmasında, sensorimotor ritim modülasyonu (SMR) EEG BBA kullanılarak uzaktan hareket edilen oyuncak bir robotun kontrolü için bir yöntem gösterilmiştir. (Chae vd., 2011, 2012) çalışmalarında, benzer robot kontrolü sağlamak için EEG BBA veri işlemede kullanılan iki-aşamalı sınıflandırıcı önerilmiştir. Birinci sınıflandırıcı, sadece pasif ve aktif EEG hallerini ayırt etmiş ve ikinci sınıflandırıcı ise sağ/sol el ve ayak motor düşünceleri gibi birkaç aktif eylemi ayırt etmiştir. İkisi sınıflandırmada sınıflandırma bileşeni olarak LDA yöntemi kullanılmıştır.

Diğer son çalışmalarda kısmen veya tamamen felçli kişilerin kullanabileceği yardımcı aletler için EEG BBA'nın gelişimi sunulmuştur. (Sirvent Blasco vd., 2012)'de internet web tarayıcı, robotik kol ve heceleme tip iletişim cihazı kullanmak için engellilere imkan sağlayan SSVEP'sine bağlı bir EEG BBA sunulmuştur. (Sirvent Blasco vd., 2012)'de farklı frekanslarda birkaç parlak ani uyarıcı kullanılmış ve bireye gösterilmiştir. Dolayısıyla BBA, EEG verilerini kullanıp uyarılan SSVEP'nin frekansını belirleyerek kişinin uyarıcıya dikkatini

vermesi ve ilgili eylemi başlatması tanımlanmıştır. (Cincotti vd., 2008)'de joystick, mouse ve göz takip sistemini birleştiren bir komple yardımcı sistem ile EEG BBA iletişim ve robotik kol kontrol opsiyonları felçli bireyler için tasarlanmıştır. SMR EEG BBA, yukarıdaki taslağı gerçekleştirmek ve sağ/sol el ve ayak motor görüntülemeyi belirlemek için kullanılmıştır. (Mayaud vd., 2013)'da sanal bilgisayar klavye internete göz atmak veya mailleri kontrol etmek gibi temel bilgisayar görevini yapmak için P300 dayalı benzer bir EEG BBA sistemi felçli bireyler için geliştirilmiştir. Protez birey uzuvlarının, medikal, insan uzuvlarının dayanamayacağı ağır yükteki işler ve eğlence sektörlerinde kullanılabilmesi için hibrit asistan uzuvlar geliştirilmiştir (Sankai, 2011). Benzer şekilde gündelik yaşamda sıklıkla ihtiyaç duyulan kupa bardağına erişme ve tutma, bir şeyleri yemek için doğru pozisyonlara erişme ve yaklaştırma gibi hareketler için hibrit BBA geliştirilmiştir (Soekadar vd., 2016). Bu gelişmelerle beraber alt, üst uzuv kontrolünü sağlayan BBA'lar fiziksel rehabilitasyona dahil edilmiştir (Ang ve Guan, 2015; Kwak vd., 2015). Felç sonrası el ve bilek kaslarının motor kontrollerini yenileme üzerine zayıf kasları geliştirmenin el ve bilek fonksiyonlarının tekrar kazanılmasını sağlayabileceği gösterilmiştir (Ang vd., 2014; Zimmermann ve Jackson, 2014).

Son yıllardaki seri çalışmalar, tekerlekli robot sandalyesi kontrol eden EEG BBA'nın gelişimi üzerine yoğunlaşmıştır. (Galán vd., 2008)'de tekerlekli robot sandalyesinin kontrolü için bir EEG BBA önerilmiştir. Bu BBA, SMR modülasyonu kullanarak motor eylem düşünceleri ve kelime-oyun zihinsel aktiviteyi belirlemek için 64 kanallı EEG ve veri işleme için makine öğrenmesinin LDA yaklaşımını kullanmıştır. Bu şekilde uygulanmış BBA için tekerlekli robot sandalyesi kontrolü içinde %60-80 doğruluk rapor edilmiştir. (Ferreira vd., 2010)'de C3/C4 EEG elektrotlarından toplanan SMR EEG sinyali kullanarak %80-90 doğrulukla motor eylem düşüncelerinin belirlenmesi için DVM veri analiz algoritması kullanılmış ve bu EEG BBA sistemi tekerlekli robot sandalyesi kontrolü için uyarlanmıştır. (Benevides vd., 2011b)'de EEG BBA'nın veri işleme algoritmasında kullanılacak EEG elektrotların ve frekansların ön-seçilmesi için Kullback-Leiber uzaklığı ve veri işleme algoritması olarak da LDA yöntemi kullanılmıştır. Tekerlekli robot sandalye kontrolü bağlamında yaklaşımın %80-90 aralığında doğrulukla çalışabileceği belirtilmiştir. (Müller vd., 2010) çalışmasında, tekerlekli robot sandalye için farklı BBA sunulmuştur. Bu BBA, görsel kortekste uyarılan SSVEP'nin frekansını belirleyerek tekerlekli sandalye hareketini başlatmıştır. Kişi, sağ-sol/yukarı-aşağı şekilde gösterilen dört frekansta parlak ani çubukların birinin üzerine odaklandıktan sonra robot sandalyesi ilgili hareketi başlatmıştır. Bu EEG BBA, en yüksek ITR'nin birkaçına (80-100 bit/dakika) ve %85-95'lik doğrulukla BBA durumlarını belirlemeye ulaşabileceğini

göstermiştir. Benzer SSVEP BBA kontrollü tekerlekli robot sandalyesi (Bastos vd., 2011)'de sunulmaktadır.

Bu önemli ilerlemelerle birlikte, birçok önemli problem EEG BBA araştırmalarında çözümlenmeden kalmıştır. Özel olarak zihinsel tek durumun belirlenmesi %100'e yakın bir doğrulukla şimdi uygulanabilir olmasına rağmen, 3 veya 4 zihinsel durum üzerine mevcut BBA performansı %60-80 aralığında kalmakta ve 5 durum halen başarılı bir biçimde elde edilebilir değildir. Dahası, bu bağlamda son 5-10 yılda literatürde küçük ilerlemeler görülmüştür. Bu durumda, en başarılı EEG BBA çalışmalar geleneksel makine öğrenme tekniklerinin uygulanması üzerine yoğunlaşmıştır. Literatüre göre, güncel EEG BBA uygulamalarında şöyle zorluklar vardır (Lotte vd., 2007): (i) EEG veri yapısı konusunda şuanda iyi bilgi olmamakla birlikte, makine öğrenme tabanlı EEG BBA veri analiz yaklaşımlarında yüzlerce ve binlerce öznitelik kullanılabilir. Bu durumda makine öğrenme yaklaşımların verimli kullanılması zor olmakla birlikte önemsiz değildir. (ii) EEG sinyali çokça zamana bağlı ve durağan olmayan sinyaldir; bu sinyal değişkenliği, BBA makine öğrenmesi uygulamalarında gürültü olarak geçer ve çok kötü gürültü oranı (signal-to-noise ratio, SNR) yaratmaktadır. (iii) EEG BBA uygulamalarında makine öğrenmede kullanılabilen eğitim verilerinin boyutu tipik olarak küçük. Yani, deneklerin eğitim için BBA ile harcadıkları zaman kısıtlı ve bu EEG BBA makine öğrenme algoritmalarının eğitilmesini zorlaştırır.

Bu gözlemlere bağlı olarak, pasif (background) EEG sinyalindeki değişimleri açıklayabilen bir EEG sinyalinin dinamik modeli ilerlemelere ümit olabilir. Böyle bir model, EEG sinyalinden "background" değişimini daha iyi çıkartıp EEG BBA sinyalinin gürültüsünü azaltabilecek ve SNR durumunu iyileştirebilecektir. Aynı zamanda, daha küçük dinamik sinyal modelini sunup, makine öğrenmesine az eğitim verilerinin yararlılığını da arttırabilecektir. EEG BBA veri analiz bağlamında bu tür dinamik modeller yüksek potansiyel etkisine rağmen (Lotte vd., 2007), bugüne kadar az dikkat verilmiştir (Makeig ve Onton, 2009; Shenoy ve Rao, 2004; Wu vd., 2011).

Dahası olarak, geçmiş tüm EEG BBA çalışmaları 10/20, 10/10, veya 10/5 sabit elektrot düzenleme sistemlerini kullanmıştır. Böyle sistemler, kafatası derisi etrafında uniform olarak yerleştirilerek elektrotların yerleşim düzeni belirlenmiş (Jurcak vd., 2007), deneylerin tekrar üretilebilirliği amacıyla geliştirilmiştir. Bununla beraber, böyle elektrot yerleşimlerinin BBA uygulamaları için optimal olup olmadığı şu anda bilinmemektedir. Örnek olarak, birçok EEG BBA çalışmasında, ne kadar elektrot olsada EEG verilerini elde etmede her yarıküre motor korteksteki C3 ve C4, tek başına veya birkaç benzer elektrotla birlikte güvenilir olmuştur. Bu seçeneğin özellikle lateralized readiness potansiyeline (Sur ve Sinha, 2009) dayalı olan sağ

ve sol el hareketlerinin ayrımı için yeterli olduğunun kanıtlanabilmesine rağmen, ayak veya dil hareketleri gibi ek hareketler belirlenmediğinde önemli zorluklar ortaya çıkabilmektedir. Vücudun farklı bölgelerinin hareketinden sorumlu olan korteks alanlarının motor kortekste ayrılmış olduğu bilinmesine rağmen (yani, *cortical homunkulus*), yukarıdaki durumda bu alanların çoğundan gelen sinyaller tekli C3 ve C4 elektrodu üzerine düşer ve bu sinyaller arasından ayırım yapmak zor hale gelir. Bu bağlamda en az prensip olarak 10/20 sisteminde olmayan, C3/C4 noktaları veya etrafında elektrotları yoğunlaştıran benzeri elektrotların yerleşimlerinin BBA bağlamında farklı motor görevlerinin belirlenmesinde faydalı olup olmadığı düşünülebilir ve bilinmemektedir.

3. YÖNTEM

3.1 Proje Kapsamı


Yukarıdaki gelişmelerle birlikte BBA araştırmalarındaki önemli açık sorulardan biri BBA cihazlarında sağlanan düşük bilgi aktarma hızıdır. Örneğin, modern noninvaziv BBA'larda genel olarak bilgi hızı 20-60 bit/dakika ve tespit hata oranı %80-90 altındadır. Bu nedenle modern BBA sistemleri ileri görevlerin tamamlanmasında zorluk yaşar ve sadece en ciddi felçlik durumlarda veya temel kontrol senaryolarında faydalıdır. Bu problemin üstesinden gelmek için kafatası-içi EEG gibi invaziv beyin aktivite görüntüleme teknikleri ve aynı zamanda daha ileri beyin aktivite veri işleme yöntemlerinin faydalı olabileceği düşünülmektedir. Projemizde, EEG BBA performansını artırmak amacıyla daha yeni EEG veri analiz yaklaşımları incelenmiştir. EEG BBA için alternatif elektrot yerleşimleri ve EEG verilerinin belirsizliğini azaltmak amacıyla yeni istatistiksel EEG veri modelleme yaklaşımları konusunda da yeni bilgi toplanmıştır.

3.2 Veri Toplama

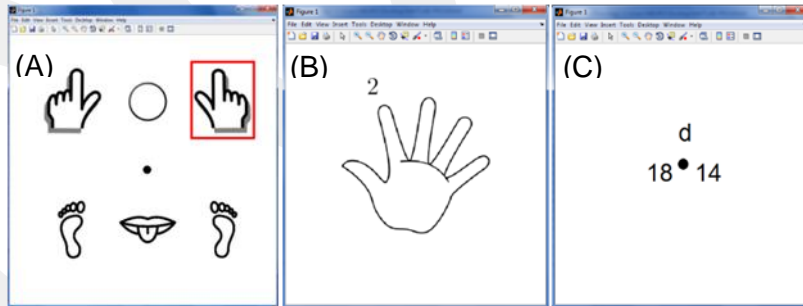
3.2.1 Deneysel Çalışmalar

Bu projedeki tüm deneyler, Türkiye'nin Mersin şehrindeki Toros ve Mersin Üniversitelerinin Etik Kuruları tarafından onaylanmıştır. Deneysel program, Toros ve Mersin Üniversitelerinin mühendislik ve fen programlarındaki sağlıklı ve gönüllü öğrencilerden yaşları 20 ile 35 arasında değişen toplamda 13 bireyi kapsamaktadır. Katılımcıların 8'i (%61.5) erkek ve 5'i (%38.5) ise kadındı. Tüm katılımcılara, psikiyatrik durumlarının, ilaç kullanımlarının ve EEG kontrendikasyonlarının bulunmadığının tespit edildiği tarama anketi uygulanmıştır. Tüm katılımcılar deneylerin amacı ve prosedürleri hakkında bilgilendirilmiş ve verilerin toplanmasına yazılı izin vermişlerdir. Bu çalışmada tüm katılımcıların isimleri anonimleştirilerek sadece "Katılımcı A", "Katılımcı M", YM veya HY gibi takma adları ile tanımlanmışlardır. Deneylerin genel iş akışı **Şekil 1**'de gösterilmiştir.

Katılımcılar bir yaslanan koltuğa oturtularak başlarına EEG şapkası yerleştirildi ve göz seviyelerinin biraz üstünde yaklaşık 200 cm önlerinde bir bilgisayar ekranı (original EEG-1200 EEG sisteminin bilgisayar system parçası) konumlandırıldı. Bilgisayar ekranı, **Şekil 2**'de gösterilen üç (3) grafiksel kullanıcı arayüzünden (eGUI) birini gösterdi. Her eGUI, katılımcılar tarafından gerçekleştirilecek farklı zihinsel imgeleri gösteren ikonlar kümesini ve aynı zamanda pencerenin merkezindeki bakış sabitleme noktasını ve diğer elemanları içeren bir şekil penceresi kullanılarak Matlab'da uygulanmıştır. Katılımcılar deneyler süresinde hareketsiz kaldılar ve aşağıda açıklanan mola veya dinlenme haricinde deneyler süresince sabitleme noktasına baktılar.



Şekil 1. Deneyel veri toplama prosedürlerinin şematik gösterimi. İlk olarak, katılımcılara, bilgisayar ekranında, deneyin grafiksel kullanıcı arayüzü (eGUI) içerisinde gösterilen kırmızı bir dikdörtgen vasıtasıyla gerçekleştirilecek zihinsel imgelerden birini gösteren eylem sinyalleri sunuldu. Daha sonra eylem sinyali ekranda kaldığı süre içinde zihinsel imge katılımcılar tarafından gerçekleştirildi. Zihinsel imgelere karşılık gelen EEG sinyali, EEG-1200 donanımı tarafından yakalandı ve Neurofax EEG kayıt yazılımı tarafından kaydedildi. Deneyden sonra, toplanan EEG verileri Neurofax'ın dahili veritabanına kaydedildi ve ayrıca çevirimdışı analiz için bir ASCII dosyasına aktarıldı.



Şekil 2. BBA etkileşimleri deneylerinde kullanılan deneyin grafiksel kullanıcı arayüzleri (eGUI). (A) Etkileşme paradigmaları CLA ve HaLT (aşağıda) için, eGUI, sol el, sağ el, sol bacak, sağ bacak ve dil motor imgeleri ile birlikte daireyle belirtilen pasif imgesini sembolize eden 6 ikonu göstermektedir. Sabitleme noktası ekranın merkezinde gösterilmektedir. Eylem sinyalleri ilgili imge ikonuna çevresinde kırmızı bir dikdörtgen kullanarak uygulanacak bir imgeyi seçti. (B) Etkileşim paradigması 5F için, eGUI beş parmaklı bir el simgesini gösterdi, ve eylem sinyali motor imgeleri uygulanacak olan parmağın hemen üstünde 1'den 5'e kadar bir sayı olarak gösterildi. (C) Etkileşim paradigması FreeForm için, eGUI ekranın ortasında bir sabitleme noktası ile birlikte sol ve sağ tuşların toplam basım sayısı ve son tuş basım harfini göstermektedir. Katılımcılar sağ ve sol ellerini kullanarak kendi istedikleri gibi tuşlara basarken eGUI basılan tuşları ve tuşa basım zamanlarını takip etmiştir.

Her deney 2 dakikalık dinlenme molaları ile ayrılmış yaklaşık 15 dakikalık süreler içerisinde 3-4 saniyelik BBA etkileşimleri dizisi şeklinde düzenlenmiştir. Her deneyin başlangıcında, katılımcıların rahatlamaları ve ayarlamalar yapabilmeleri için 2.5 dakika başlangıç rahatlama periyodu verilmiştir. Rahatlama periyodundan sonra, 15 dakikalık 3 BBA etkileşim oturumu aşağıda belirtilen paradigmalardan birini kullanarak takip edildi. Bu oturumlarda, katılımcılar her defasında eGUI tarafından verilen talimata göre çağrılan farklı zihinsel imgelerden oluşan 300 trial ile meşgul olmaktadır. Her trial, uygulanacak zihinsel imgeye karşılık gelen bir simgeyi seçmek için kırmızı bir dikdörtgenin kullanılmasıyla oluşturulan uyaran eylem sinyalinin eGUI ekranında gösterilmesiyle başlar. Eylem sinyali ekranda 1 saniye kalmakta ve bu süre boyunca katılımcılar belirtilen zihinsel imgeyi bir kez gerçekleştirmektedirler. EEG verileri (veri kanalı) gösterilen eylem sinyali (işaretçi kanalı) ile ilgili bilgilerle birlikte kayıt yazılımı tarafından yakalanmaktadır. Her trial'den sonra 1.5 saniye ile 2.5 saniye arasında değişen duraklama süresi gelmektedir. Ortalama olarak, 15 dakikalık etkileşim oturumunda her biri 3 saniyelik 300 trial meydana gelmektedir. Her trial'deki zihinsel imgeler, sözde rastgele sayı üretici yazılımına göre eşit olacak biçimde rastgele seçilmişlerdir. Deneyler 50 ve 55 dakika arasında sürdü ve EEG verileri tüm zaman boyunca sürekli olarak kaydedildi.

3.2.2 BBA Etkileşme Modelleri

Aşağıda açıklanan tüm BBA etkileşim paradigmaları senkron paradigmalardır. Diğer bir deyişle, her bir BBA etkileşim trial'i katılımcılara verilen zihinsel imgeyi uygulaması talimatı veren bilgisayar ekranında gösterilen görsel bir eylem sinyaliyle başlamaktadır. Böylece, her trial'in başlangıcı ve katılımcıların zihinsel imgeleri uyguladığı süre bilinebilmektedir. Her bir trial 1 saniyelik zihinsel imgenin uygulanması olmak üzere ortalama olarak 3 saniye almaktadır. Trial'ler 15 dakikalık bir deney oturumunda 300 kez tekrarlanmaktadır. Toplamda 45 dakikalık BBA etkileşim süresi içeren her bir deney 3 etkileşim oturumu içermektedir. Katılımcıların yorgunluğundan dolayı, her bir etkileşim oturumu 15 dakika olarak sınırlandırılarak, oturumlar arasında 2 dakikalık dinlenme süresi verilmektedir. Dinlenme süresi boyunca, katılımcıların ayağa kalkmadan oturdukları sandalyede hareket edebilme ve konuşabilmelerine izin verilmiştir. EEG verileri dinlenme periyotlarında da elde edilmiştir. EEG elektrotlarının elektrik bağlantı kaliteleri, dinlenme sürelerindeki hareketlerin EEG uygulamasının kalitesine gölge düşürmemesini sağlamak için, tüm deneylerin sonunda empedans monitörü kullanılarak kontrol edilmiştir.

Paradigma #1 (CLA)

Motor görüntü (MI) etkileşim paradigması, nöron ayna sistemi aracılığıyla denekler tarafından zihinde canlandırılabilen ve neokorteksteki motor bölgeler üzerine yerleştirilen elektrotlar

aracılığıyla EEG ile izlenebilen gönüllü eylemlere bağımlılığından dolayı son zamanlarda EEG BBA'da popüler hale gelmiştir. Bu amaçla sağ ve sol el , bacak ve dil hareketleri BBA etkileşimleri için bir paradigma olarak geçmişte sıklıkla kullanılmıştır, Bu modelleyici EEG elektrot yerleşim düzeni olan uluslararası standart 10/20 sisteminin C3, C4, T3, T4 ve Cz bölgelerinin hemen altında bulunan sağ ve sol el, bacak gibi uzuvların hareketi için sorumlu kontrolateral kortikal bölgelerde kolaylıkla ayırtedilebilen aktivitelerden dolayı özellikle etkilidir. Bu nedenle C3 ve C4 elektrotları üzerinden gözlenen kontrolateral bölgesel aktiviteye dayanan EEG tabanlı sol ve sağ el MI ayırımı, geçmişte birçok çalışmada başarıyla kullanılan EEG BBA iletişim paradigmalarından biri haline gelmiştir. Bu bağlamda bizim ele aldığımız "Paradigma #1 – CLA (Classical)", katılımcıların hareketsiz kaldığı ve motor imgesi ile meşgul olmadığı bir pasif zihinsel imgenin yanında sol ve sağ el hareket imgeleri ile birlikte toplam 3 zihinsel imgeye dayanan benzer bir EEG–BBA etkileşim modelini içermektedir. Bu deney tasarımında, katılımcılar **Şekil 2A**'da gösterildiği gibi GUI ekranının ortasında bir sabitleme noktası görmektedirler. Her bir trial'in başında bir eylem sinyali, 1 saniyelik süre için ilgili simgenin üzerinde kırmızı bir dikdörtgen vasıtasıyla sol ve sağ el simgelerini ve pasif tepki için de bir daire simgesini göstererek seçmektedir. Eylem sinyalinin gösterildiği 1 saniyelik süre boyunca, katılımcılar seçilen motor görüntüsünü bir kez gerçekleştirmişlerdir. Sol ve sağ motor görüntüleri, ilgili motor görüntüsüne bağlı el için bir kez yumruk kapama ve açma hareketi yapılarak uygulanmıştır. Katılımcı ilgili motor görüntüyü uyguladıktan sonra bir sonraki eylem sinyali sunulana kadar pasif kalmıştır. eGUI'da bir daire ile gösterilen pasif imge için, katılımcılar pasif kaldılar ve bir sonraki trial'in başlangıcına kadar herhangi bir gönüllü zihinsel harekette bulunmadılar. Yine de pasif sinyaller için bile EEG verilerinde "pasif" talimatın işlenmesine ilişkin bir yanıtın gözlenebilir olduğu unutulmamalıdır.

Paradigma #2 (HaLT)

Bu BBA etkileşim paradigması, BBA ile etkileşimde sol, sağ el ve pasif motor hareketlerinin yanında sol, sağ bacak ve dil motor hareket görüntüleri ile birlikte toplamda 6 zihinsel durum olmak üzere CLA paradigmasına göre daha fazla sayıda motor görüntünün kullanıldığı, 3-durumlu CLA paradigmasının genişletilmiş halidir. Bu tasarımında, katılımcılar **Şekil 2A**'da gösterildiği gibi GUI ekranının ortasında bir sabitleme noktası görmektedirler. Her bir trial'in başında bir eylem sinyali, 1 saniyelik süre için sol el, sağ el, sol bacak, sağ bacak, dil ve daire (pasif tepki için) simgelerinden birini göstererek seçmektedir. Eylem sinyalinin gösterildiği 1 saniyelik süre boyunca, katılımcılar seçilen motor görüntüsünü bir kez gerçekleştirmişlerdir. Sol ve sağ el imgeleri, Paradigma #1'deki gibi ilgili motor görüntüsüne bağlı el için bir kez yumruk kapama ve açma hareketi yapılarak uygulanmıştır. Sol ve sağ

bacak motor görüntüleri, ilgili motor görüntüsüne bağlı olarak bacak veya ayağın kısa bir hareketi olarak gerçekleştirilmiştir. Dil imgesi, “el” gibi belirgin harf veya sesin telaffuz edildiğini hayal ederek uygulanmıştır. Pasif imge için, katılımcılar pasif kaldılar ve hiçbir şey yapmadılar. Katılımcılar, her bir eylem sinyali sunulduğunda bir imge gerçekleştirmişler ve bir sonraki eylem sinyalinin sunumuna kadar pasif kalmışlardır.

Paradigma #3 (5F)

Bu BBA paradigması, tek bir elin parmaklarının hareket görüntülerinin EEG sinyalleri yolu ile ayrılma olasılığını incelemek için tasarlanmıştır. Bu deneyler, yüksek frekanslı EEG sinyallerinin sözü edilen ayrılmada kullanılma olasılığını incelemek amacıyla ya 200 Hz ya da 1000 Hz örnekleme hızında yapılmıştır. Burada, katılımcılar **Şekil 2B**'de gösterilen 5F etkileşimli eGUI ekranını görmekteyiz. Katılımcılardan, deney süresince imgenin merkezine odaklanmaları istenmiştir. Her trial'in başlangıcında, hareket görüntüsü uygulanacak parmağın üzerinde 1'den 5'e kadar bir sayı ile temsil edilen bir eylem sinyali belirmektedir. Hareket sinyali, katılımcıların ilgili görüntüleri uyguladıkları 1 saniyelik süre boyunca ekranda görünür kalmaktadır. Görüntüler, katılımcıların tercihi doğrultusunda, karşılık gelen parmakların yukarı veya aşağı doğru bir esnemesi olarak gerçekleştirilmiştir. Bu paradigmada pasif imge yoktu - her hareket sinyali bir yanıt gerektirmekteydi. Her eylem sinyali için tek bir görüntü gerçekleştirilmiştir. Görüntülerin gerçekleştirilmesinden sonra katılımcılar bir sonraki eylem sinyali gösterilinceye kadar pasif kaldılar.

Paradigma #4 (FreeForm)

Bu BBA etkileşim paradigması, gönüllü motor hareketlerinin fiziksel belirtileri öncesinde, EEG sinyalleri aracılığıyla ayırt edilmesini incelemek için tasarlanmıştır. Bu deneylerimizde kullanılan tek eşzamansız BBA etkileşim paradigmasıdır. Araştırmanın bu kısmı kapsamlı bir biçimde incelenmemiştir ve çok az sayıda deney bu paradigma için mevcuttur. Bu deneylerde, katılımcılar **Şekil 2C**'de gösterilen FreeForm etkileşimli eGUI ekranını izlediler. Katılımcılardan elleri bilgisayar klavyesinde sakince dururken bakışlarını sabitleme noktasına odaklamaları istendi. Katılımcılardan sol veya sağ ellerini kullanarak, rastgele zamanlarda klavye üzerindeki 'd' veya 'l' tuşlarına kendi iradeleriyle basmaları istenmiştir. Tuş basımlarının zamanı eGUI tarafından kaydedildi ve EEG tuş basım dalga biçimlerinin analizinde referans noktası belirlemek için kullanıldı. eGUI, ekranda görüntülenen son tuşun ne olduğunun yanı sıra sol ve sağ tuş basımlarının toplam sayısını da takip etti. Katılımcılardan ortalama olarak benzer sayıda sol ve sağ tuşa basmaları istendi. Motor planlaması ve uygulanmasına bağlı sinirsel aktivite değişiklikleri, EEG verilerinde tuş

basımlarından hemen önceki zamanlarda görülebilmektedir. Bu paradigma katılımcı kontrollü bir paradigmadır.

Paradigma #5 (NoMT)

Bu paradigmayla ilgili deneyler, deney programının başlamasından önce, müteakip BBA etkileşim deneyleri için uygunluk kontrolü ve temel belirleme yapmak adına katılımcılarla gerçekleştirilmiştir. Bu deneyler, katılımcılardan eGUI ekranında görülen herhangi bir görsel sinyale tepki vermemelerinin istenmesi haricinde HaLT'a benzemektedir. Bu durumda katılımcılar deney süresince bilgisayar ekranını pasif olarak izlediler. Bu deneylerde, katılımcılar, **Şekil 2A**'da gösterildiği gibi, eGUI ekranının ortasındaki bir sabitleme noktasına baktılar. Her bir trial'in başında bir eylem sinyali, 1 saniyelik süre için sol el, sağ el, sol bacak, sağ bacak, dil ve daire (pasif tepki için) simgelerinden birini göstererek seçmektedir. Diğer zamanlarda olduğu gibi bu süre içerisinde katılımcılar pasif kaldılar ve hiçbir şey yapmayıp pasif bir şekilde ekranı izlediler.


3.2.3 Ham Veri Elde Edilmesi

EEG verileri, EEG-1200 JE-921A EEG sistemi (Nihon Kohden, Japonya) kullanılarak elde edilmiştir. EEG-1200, birçok hastanede kullanılan standart tıbbi bir EEG cihazıdır. Bu cihaz en fazla 100 dB'lik ortak mod bastırma, 1000 Hz'e kadar örnekleme frekansı, 0.01 μ V gerilim çözünürlüğü ve maksimum 38 giriş kanalı ile yüksek hassasiyetli EEG ölçümleri sağlar. Bu çalışmada, standart 10/20 uluslararası elektrot yerleştirme sistemi temel alınarak sadece 19 EEG girişi kullanılmıştır.

EEG-1200, EEG verilerini Neurofax kayıt yazılımında özel formatta kaydeder ve saklar; ayrıca her görüntüleme oturumu bazında kaydedilen veriyi bir ASCII dosyası olarak dışarı aktarmaya izin verir. Dışa aktarılan veriler, kaydedilen, 0.01 μ V gerilim çözünürlüklü, en az 2 mV dinamik aralıklı ve örnekleme hızı 1000 Hz'e kadar olan EEG sinyal değerlerini tablo formatında listeler.

EEG veri edinimi, 10/20 uluslararası konfigürasyonuna göre yerleştirilen 19 köprü elektrotunu içeren 10/20 EEG şapkaları (Electro-Cap International, ABD) yardımıyla gerçekleştirildi. Her deneyden önce katılımcıların kafaları EEG teknisyeni tarafından temizleyici solüsyon yardımıyla kafa derilerinin yüzeyi temizlenerek ve saçları elektrotların konumları çevresinde taranarak hazırlandı. Daha sonra, EEG şapkası katılımcıların kafasına yerleştirildi. Nasion,inion, preoriküler noktalan ve şapkanın Cz elektrodu arasındaki uzaklıklar, EEG şapkasının yaklaşık 0.25 cm'lik hassasiyet ile doğru konumlanmasını sağlamak için bir ölçme bandı kullanılarak ölçülmüştür. EEG şapkası yerleştirildikten sonra, elektrotların empedansı EEG-1200 sisteminin empedans kontrol modu ve Neurofax yazılımı ile izlenirken, köprü elektrotları

iletken elektro jel (Elector-Cap International, ABD) ile doldurulmuştur. Empedans dengesizliği 5 kOhm veya altında olan 10 kOhm veya altında empedanslar elde ettikten sonra, hazırlık sürecinin tamamlandığı kabul edildi. Hazırlıklar deney başına yaklaşık 30 dakika sürdü. Elektrotların empedansı, deneylerin sonunda EEG-1200'ün empedans kontrol modunun kullanılmasıyla, deneylerin tamamı boyunca iyi elektriksel temasın kaldığını garantiye almak için bir kez daha kontrol edildi.



Şekil 3. Bu çalışmada deneylerin çoğunda kullanılan 19+2 elektrotlu standart uluslararası 10/20 elektrot yerleştirme sistemi.

Hazırlıklar yapıldıktan sonra EEG verileri toplandı. Hiçbir elektromanyetik kalkanlama veya yapay kontrol uygulanmamıştır. Bu, EEG BBA'daki veri işleminin dışsal veri kirliliğine karşı baş edebilmesi beklentisi nedeniyle bilinçli olarak yapılmıştır. Veri analizinde elektromanyetik girişim ve yapay hareketlerin üstesinden gelmek, projenin hedeflerinin bir parçasıdır.

EEG verileri, EEG-1200 sistemi ile birlikte Neurofax kayıt yazılımı kullanılarak kaydedildi. Bu yazılımda, verilerle birlikte kullanılmak üzere değiştirilmiş bir 10/20 montajı oluşturulmuştur. Söz konusu montaj, A1 ve A2 etiketli, kulak tomurcuklarına yerleştirilen 2 toprak kablosuna ek olarak 19 standart 10/20 EEG kablosu ve aşağıda belirtildiği gibi veri sekronizasyonu için kullanılan, X3 olarak tanımlanmış bir bipolar kablo olmak üzere toplamda 22 giriş veri kanalından oluşmaktadır. EEG sinyali, deneylerin çoğunluğu için 200 Hz örnekleme hızında ve EEG'de daha yüksek frekans sinyallerinin önemini araştıran deneyler için 1000 Hz örnekleme hızında kaydedildi. Kayıtlar için referans noktası EEG-1200 teknik el kitabında $0.55 \cdot (C3+C4)$ olarak tanımlanan "Sistem 0 Volt" olarak seçildi.

EEG-1200 sistemi ve Neurofax yazılımı, 50 Hz şebeke elektrik girişim çentik önleme filtresi ve 200 Hz veri için 0,53 ila 70 Hz, 1000 Hz örnekleme hızı verileri için 0,53 ila 100 Hz bant geçiren filtreyi varsayılan olarak uygular.

Deneylerdeki zihinsel görüntü programı, Matlab'da yazılmış özel eGUI yazılımı tarafından kontrol edilmiştir. Bu yazılım, deneyin yazılımı tarafından bilgisayar ekranında sunulan eylem

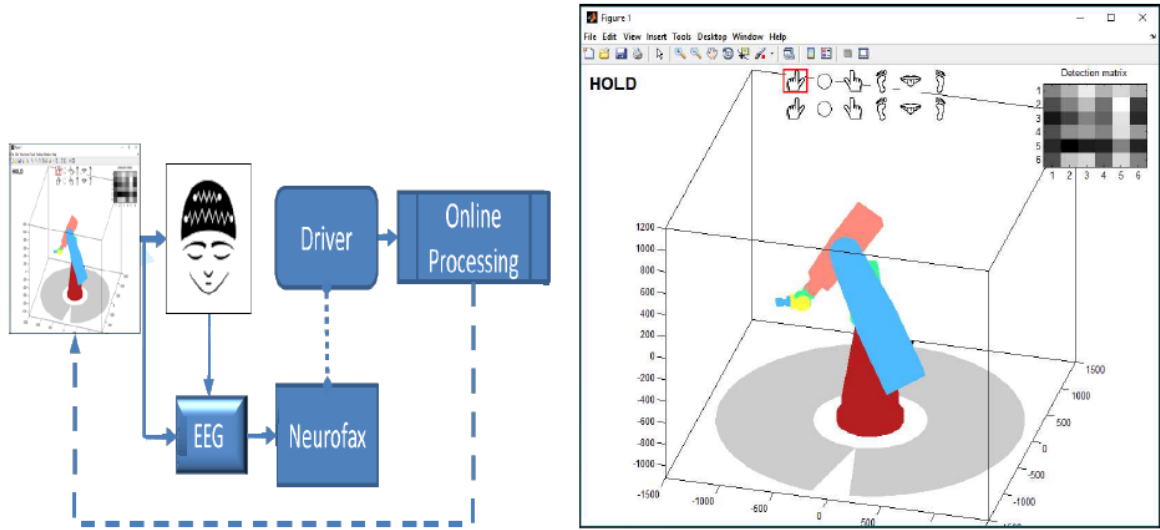
sinyallerinin durumunu kaydetti; böylece olayların sırası daha sonra her bir deney için yeniden oluşturulabildi. EEG-1200'ün sinyal alımında kullanılan saat ile eGUI'yi çalıştıran bilgisayarın kullandığı saat arasında önemli bir farklılık mevcut olduğunu bundan dolayı veri edinme kutusu yoluyla edinilen EEG verileri ile etkileşim programının ek olarak senkronize edilmesi gerekiyordu. Başlangıç zamanı ofsetinde iki saat de farklıydı aynı zamanda şaşırtıcı derecede de hızlıydı. Bu fark, EEG yanıtlarının sırasını bozduğu ve onları kullanılamaz hale getirdiği için önem teşkil etmekteydi.

Bu sorunu çözmek için EEG-1200'ün JE-921A edinim kutusunda X3 bipolar girişine eGUI tarafından kontrol edilen bilgisayarın USB bağlantı noktasından 1 μV senkronizasyon sinyali gönderen ek donanım konuşlandırıldı. eGUI'de her yeni eylem sinyalinin sunumunda, eGUI, USB port ve Arduino Uno mikro denetleyici aracılığıyla EEG-1200'ün X3 bipolar girişine 500 ms'lik 1 μV atım (sinyal) iletti. Bu atım daha sonra 22. giriş veri kanalı olarak Neurofax verilerine kaydedilmiştir. Bu atım, söz konusu kanalın EEG veri kayıtlarında, eGUI'deki her eylem sinyali sunumunun başında ve sonunda 500 ms ile ayrılmış açık/kapalı spike (diken deseni) olarak görülmektedir. Bu sinyal daha sonra ham EEG veri örnekleri ile eGUI olay kaydının hassas sıralamasını yapmak için kullanıldı.

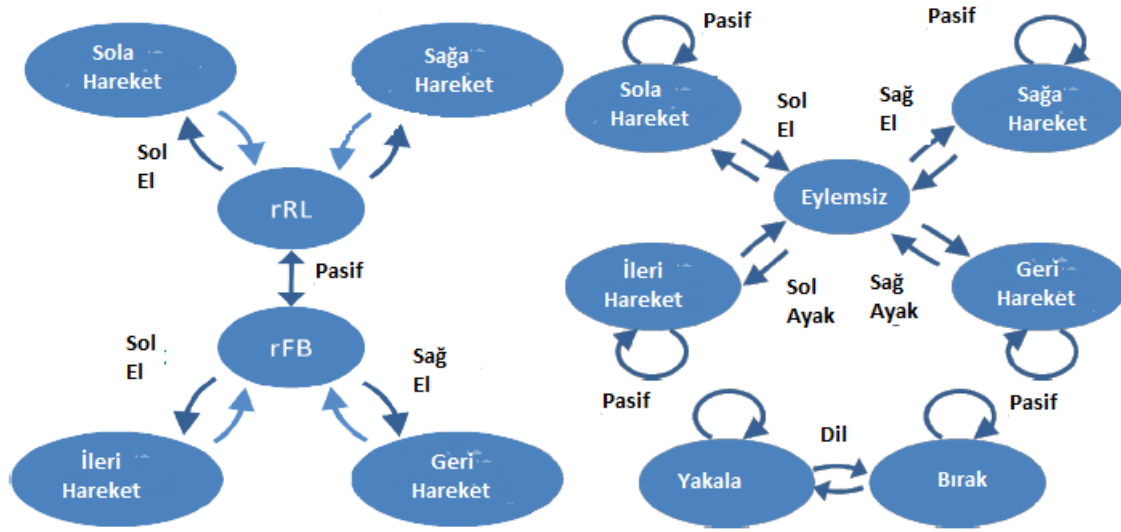
Her bir deneyde elde edilen EEG verileri, deneyin bitiminden sonra Neurofax yazılımının dahili veritabanına saklanır ve ayrıca Neurofax yazılımındaki "ASCII dışı aktarma" seçeneği kullanılarak bir ASCII dosyasına aktarılır. Deneyin etkileşim kaydı sırasıyla eGUI tarafından bir Matlab veri dosyasına kaydedilmiştir. EEG verilerini dışı aktaran bu ASCII, her zaman noktası için Neurofax'ın kayıt montajında, örneklenmiş EEG gerilim değerlerinin metin listesinin bir tablosunu içermektedir. Dışı aktarılan verinin gerilim çözünürlüğü 0.01 μV idi ve örnekleme oranı orijinal EEG kaydının oranıydı. Bu bilgi, dışı aktarılan ASCII dosyasının başlığında da ayrıca belirtilmiştir. Dışı aktarılan ASCII verileri, OpenWetWare.org adresindeki Beauchamp'dan temin edilebilen Timothy Ellmore tarafından oluşturulmuş *convert_nkascii2mat.m*'ye dayanan özel bir scriptimiz yardımıyla Matlab'a aktarılmıştır. Bu script dosyası, orijinal Neurofax'ın ASCII verilerini okuma ve ayrıştırma, eGUI'nin deney etkileşim kaydını alma, ikisini senkronize etme ve tüm deneyin veri kaydının son bir dosyasını yazma işlemlerini gerçekleştirmektedir.



Şekil 4. Online deney programında Sađ/Sol El Sađ/Sol Ayak Dil Hareket modeli için kullanılan ara-yüz ve katılımcı pozisyonu.



Şekil 5. Deneysel programımızda kullanılan deney Anahtar Deđişmeli Sađ/Sol El Hareket modeli için ara-yüz ve sanal robot simülasyon arayüzü



Şekil 6. Online deneylerin çalışma prensibinin şematize edilmiş hali

Sanal robot manipülatör kontrolü için yapılan online kontrol deneylerimizde, önceki dönemlerde geliştirilen Nihon Kohden EEG sistemini kullanan interaktif “online EEG BBA” uygulamamız kullanılmıştır. Bu deneyler 3 bölümden oluşmuştur. 1. bölümde **Şekil 5**'te gösterilen online BBA arayüzü tarafından verilen görsel uyarılara karşın katılımcı motor hareketleri ile ilgili zihinsel durumları uygulamıştır. Bu zihinsel durumları sınıflandırılması için 1. bölümde EEG BBA sinyal çözücü yazılımı otomatik olarak oluşturulmuştur. 2. bölümde katılımcı serbest olarak zihinsel durumları uygulayarak şu çözücü kontrol etmeye çalışmıştır. Bu sürede katılımcı, uyguladığı durumların BBA sinyal çözücü tarafından nasıl sınıflandırıldığını öğrenerek kendini eğitmiştir. 3. bölümde ise katılımcı, daha önceden belirlenen ve laboratuvar asistanı tarafından sözlü olarak verilen komutları BBA'yı ve **Şekil 5**'te gösterilen sanal robot kolu kullanarak online ve interaktif şekilde uygulamaya çalışmıştır. Online analiz prosedürü için önceden offline BBA veri analizlerimizde kullanılan Sağ/Sol El anahtar geçişli veya Sağ/Sol El Sağ/Sol Ayak Dil hareket deney modeli kullanılmıştır, **Şekil 6**. Sağ/Sol El Sağ/Sol Ayak Dil hareket deney modelinde sanal robotik manipülatörün sağa, sola, aşağı, yukarı, tut ve bırak hareketlerini kontrol etmek üzerine uygulamalar yapılmıştır. **Şekil 4, 5** online (canlı) deneylerimizde sanal robot kontrolü için kullanılan görsel arayüzlerimizi göstermektedir. **Şekil 6** ise online deneylerde yer alan ve katılımcı tarafından kullanılan manipülatörün kontrol mekanizmasını şematize etmektedir.

3.3 Veri Analizi

3.3.1 EEG BBA İçin Veri Analiz Yaklaşımları

Literatür özetimiz, EEG BBA uygulamalarında en başarılı yöntemler olarak Lineer (Fisher) Diskriminant Analizi (LDA) ve Destek Vektör Makineleri (DVM) makine öğrenme

yaklaşımlarını belirtir. DVM, bir zihinsel hal durumunda EEG BBA'nın %100 performansını sağlamakta (Ferreira vd., 2010; Kaper vd., 2004; Lotte vd., 2007), ve LDA bugünkü pratik EEG BBA uygulamalarında en çok kullanılan yaklaşım olarak görülmektedir. Dolayısıyla, bu algoritmalar projemizde EEG BBA veri analizi için bir başlangıç noktası olarak kullanılmıştır.

BBA deneylerinde zihinsel halleri tespit etmek için güncel kaynaklarda üç genel yaklaşım kullanılmaktadır. Bunlar olaya-ilişkin-potansiyel (Event Related Potential, ERP), olaya-ilişkin-eşzamanlılık (Event Related Synchronization/Desynchronization, ERS/ERD) ve görsel çağrışımda durağan durum potansiyelleri (Steady State Visually Evoked Potential, SSEVP).

Olaya-ilişkin-potansiyeller, bir operatörün (BBA'yı kullanan birey) belirli zihinsel haline karşılık olarak EEG sinyalinde gelişen stereotipik desenlerdir. ERP'ler belirli olaya bağlı olup, ERP'leri ölçmek için ilgili olayların anlarının tam bilinmesi ve EEG sinyalinin bu anlara göre hizalanıp incelenmesi gereklidir. Örneğin, çok iyi bilinen P300 EEG potansiyeli, birey tarafından beklenen bir görsel veya sesli sinyal geldiğinde yaklaşık olarak 300 milisaniye sonra parietal lobta büyük bir pozitif sapma şeklinde görülmektedir. Beklenen bu sinyalin geldiği ana hizalanmış EEG verilerinde 300-700 milisaniye arasında pozitif sapma görülecektir. Başka bir örnek, birey motor hareketleri uyguladığında veya düşündüğünde motor korteks üzerindeki EEG sinyalinde belirli stereotipik desenler görülmektedir. Bunlara yavaş motor potansiyelleri denir. EEG ERP'lerinin ana avantajı bireyin eğitimi olmadan, yani doğal olarak EEG sinyalinde görülebilmesi ve birey tarafından tipik olarak yüksek seviyede tekrarlanabilmesidir. Dolayısıyla, bu tür olay algılama yaklaşımı kullanacak BBA sistemlerinin uzun eğitim sürecine ihtiyacı yoktur. Eğitim yerine ilgili ERP şekillerini ölçen çok daha kısa BBA ölçümleri kullanılabilir. Aynı zamanda önemli bir nokta olarak, ERP eğrileri aynı bireyin farklı olaylarda stereotipik olmasından dolayı her kişiye özel olmalıdır, yani aynı BBA sistemi yeni bireye uygulandığında söz konusu ERP sinyallerinin yeniden ölçülmesi gereklidir. EEG ERP'lerinin ana dezavantajı ise, genelde çok düşük genliğe sahip olmalarıdır. Örneğin, tipik motor ve P300 potansiyellerinin genliği 1-5 mikro volt civarındadır. Aynı zamanda EEG sinyalinin doğal değişimi (yani deney arayüzünden gelen uyarma sinyallerine bağlı olmayan, beynin aktivitesine dayalı ve kayıt cihazının elektriksel özelliklerine bağlı olmayan EEG sinyalinin değişimi) 5-10 mikro voltur. Bu nedenle ERP sinyallerini gerçekçi bir biçimde algılamak zordur.

ERP araştırmalarında, ERP'ler genellikle ortalama olarak ölçülmektedir. Yani ortalama ERP, birçok aynı olayda görülen ve olayın başlangıç anına hizalanan EEG sinyalinin ortalama desenedir. EEG kayıtları kullanılarak bu tip hesaplama için, zamansal uzun ve sürekli bir EEG kaydında bulunan BBA olay anlarından itibaren belirli süreye kadar (örneğin, olayın ilk anından 1 saniyeye kadar) EEG kayıt parçaları kesilip hazırlanmaktadır. Bu EEG kayıt

parçaları birbirlerinin üzerine yerleştirilerek olaya ilişkin halen ayrı EEG desenlerine ait örneklerin bir yığını oluşturulmaktadır. Bu yığından olay ortalama ERP eğrisi, ilişkin EEG sinyal örneklerinin ortalaması olarak bulunmaktadır. ERP eğrileri, EEG kanallarının hepsi için olayın başlangıç anına göre ilgili kanaldaki ERP desenlerinin ortalaması olarak elde edilmektedir. Bu hesaplamada yeterli sayıda olay kullanılırsa, ortalama ERP eğrilerinin çok kararlı olduğu görülmektedir. Aynı zamanda tek olaylara ait olan ayrı ERP eğrileri, EEG sinyalinin doğal değişiminden dolayı ortalama ERP eğrilerinden çok farklı olabilir ve olaydan olaya yüksek düzeyde değişiklik gösterebilir.


Olaya-ilişkin-eşzamanlılık, frekans uzayında gözlenen bir EEG tepkisidir. ERS/ERD daha çok motor eylemlerle alakalı olan 12-30 Hz (beta) ve 8-12 Hz (alfa) EEG ritimleri ile kullanılır. EEG sinyalinin beyin korteksindeki birçok nöron hücrelerinin ateşlemelerine bağlı sinirsel akış trafiği tarafından üretildiği bilinmektedir. Buna göre beynin bir bölgesinde nöronlar ateşlemeleri senkronize bir şekilde yaparsa, ürettiği EEG sinyalinin genliğinin daha yüksek olması beklenir. Aksi halde, eğer bir bölgede nöronlar ateşlemeleri rastgele yapıyorsa, ritmik EEG sinyallerinin genliğinin düşük olması beklenir. Bu ilkedен yola çıkarak birey tarafından bir hareket yapıldığı zaman, hareket ile ilgili motor korteksindeki nöronlar, ateşlemeleri birbirinden bağımsız olarak yapmaktadır ve ritmik EEG sinyalinin genliği düşmektedir. Bu duruma olaya-ilişkin-eş zamansızlık (ERD) denir. Birey rahatladığı zaman ise, motor korteksindeki nöronlar ateşlemeleri eşzamanlı bir dalga biçiminde yapmaya başlar ve bundan dolayı ritmik EEG sinyali görülür. Bu duruma olaya-ilişkin-eşzamanlılık (ERS) denir. BBA amaçları için kullanılan motor kortekste alfa ve beta ritimleri için, birey hareket ettiği veya hareket etmeyi sadece düşündüğü zaman motor korteksindeki EEG sinyalinin gücü, bahsi geçen frekanslarda anlık olarak değişir. Birey rahat olduğu zaman alfa ve beta ritimleri gözlenmektedir. Birey bir hareketi düşündüğü zaman ise harekete bağlı olan kontralateral motor korteks bölgesinde alfa ve beta ritimlerinde düşme görülmektedir. Bireyin motor korteksinin sağ ve sol tarafındaki alfa ve beta ritimlerini kontrol etmeyi öğrenebilmesi mümkündür. Böylece bireyler, sağ/sol taraftaki alfa ve beta ritimlerini kontrol ederek bilgisayara bilgi gönderebilmektedir.

EEG ERS/ERD'lerinin ana avantajı, ilgili zihinsel olay olduğunda net ve uzun süreli görülmesidir. Örneğin, ERS/ERD BBA modelinde, birey ilk önce rahat olur, sonra bir elin hareketini sürekli yapmaya başlar. Bu durumda elin hareketleri tam yapıldığı zaman kontralateral alfa ve beta ritimlerinin düşmesi görülür. Bu tip sinyalleri BBA tarafından algılamak kolaydır. Ayrıca bireyler, alfa ve beta ritimlerinin genliklerinin dereceli kontrolünü öğrenerek, EEG ERS/ERD modelini bilgisayarda dereceli kontrol uygulamak için kullanabilir. ERS/ERD'lerin ana dezavantajı, ERS/ERD kontrolünün birey tarafından öğrenilmesinin zor

olması ve tüm bireyler tarafından gerçekleştirilememesidir. Örneğin, rahatladıkları zaman bazı bireylerde alfa ritmi görülmekte, diğer bireylerde ise alfa ritmi hiç üretilmemekte ve bu durumun değiştirilemediği bilinmektedir.

Durağan hal görsel çağrışımlı potansiyeller (Steady State Visual Evoked Potentials, SSVEP), 3-90 Hz frekansla gösterilen görsel uyarıcılara karşılık olarak gelişen, aynı frekansta olan ve görsel kortekste bulunan EEG sinyalindeki salınımlardır. BBA için kullanılan bu modelde, BBA arayüzü bireye birkaç kontrol elemanı gösterir ve bu elemanları farklı frekanslarda ışıklarla aydınlatır. Birey, belirli bir kontrol sinyalini BBA'ya göndermek istediği zaman, arayüzün ilgili kontrol elemanına bakar ve görsel kortekste gelişen SSVEP sinyalinin frekansından bireyin dikkatini verdiği eleman belirlenebilir. SSVEP modelinin ana avantajı, çok belirgin olması ve tahminlerinin çok yüksek oranda doğruluk göstermesi, dolayısıyla sağlanan bilgi akışının çok yüksek olabilmesidir.

BBA uygulamalarında, BBA ile etkileşim için seçilen ERP'lerin ham EEG verilerinden algılanması gereklidir. Genellikle ilgili ERP'lerin algılanması, söz konusu olayı kapsayan EEG sinyalinin bir parçası üzerinde gerçekleştirilir. EEG sinyalinin parçalarının seçildiği bölgeye algılama penceresi (detection window) denir. ERP'ler, EEG sinyalinin doğal değişimine göre yetersiz kaldığı için, gereken olay bazından ERP'lerin algılanması EEG sinyalinin birçok kanalından/elektrodundan aynı zamanda veya birkaç ayrı zamansal örneğinden alınan bilgilerin birlikte kullanılmasını gerektirir. Bu bilgilerin en iyi birleştirme yöntemi fark edilmeyebilmektedir. Bu nedenle kaynaklarda bu probleme yaklaşım şekli olarak en çok kullanılan metot, ERP algılama metodunun makine öğrenme yöntemi kullanılarak ortaya çıkarılmasıdır. En iyi sonuç veren makine öğrenme yöntemleri, Lineer Diskriminant Analiz (LDA) veya Destek Vektör Makineleri (DVM) lineer makine öğrenme yöntemleridir.



Şekil 7. DVM yaklaşımında iki tür veri noktaları ayırt etmek için azami-margin düzlem kullanılmaktadır.

LDA ve DVM yöntemleri birçok boyutlu uzayda belirtilen verilerden iki durumu ayırt etmek için kullanılan lineer sınıflandırma yöntemleridir. Lineer sınıflandırma yöntemi, verilerde iki durumu ayırt etmek için çok boyutlu öznitelik uzayında bir düzgün düzlem kullanır. Bu düzlem kullanılarak; belirtilen bir yarı-uzay birinci durum, diğeri ise ikinci durum olarak tanımlanır. Bu durum LDA ve DVM yönteminde ortak olsa da, ayırma düzlemi LDA ve DVM yönteminde farklı şekillerde seçilir. LDA yönteminde (Alpaydin, 2014a), iki sınıftan gelen veri normal dağılım kullanılarak modellenir (1). Yani, iki sınıfın her biri için birer ortalama değer ve varyansının olduğu varsayılır;

$$x_{i,k} = \mu_i + \varepsilon_{i,k}. \quad (1)$$

Burada $x_{i,k}$ i-inci sınıfa atanan k-inci örnek, μ_i ilgili sınıfın ortalama değeri ve $\varepsilon_{i,k}$ normal gürültü olarak modellenen rastgele bir katkıdır. LDA yönteminde birinci ve ikinci sınıfa ait olan $\varepsilon_{i,k}$ değişkenlerinin kovaryans matrislerinin $\Sigma_{ij} = E[(x_{i,k} - \mu_i)(x_{j,k} - \mu_j)]$ aynı olduğu varsayılır ve bu durumda iki sınıfı en iyi ayırt eden düzlemin normal vektörü (2)'dedir.

$$w = \Sigma^{-1}(\mu_2 - \mu_1) \quad (2)$$

Veri noktaları ayırımı (3) 'e göre yapılır.

$$\text{class}(x) = \begin{cases} 1, & \text{eğer } w^T x < c \text{ ise} \\ 2, & \text{eğer } w^T x > c \text{ ise} \end{cases} \quad (3)$$

Burada c sabiti, sınıflandırma hatalarını azaltarak seçilen eşik parametresidir. Aynı prensiple yola çıkan sınıflandırma yönteminde sınıfların kovaryanslarının eşit olduğu varsayılmazsa, elde edilecek sınıflandırma yönergesine karesel diskriminant analizi (Quadratic Discriminant Analysis, QDA) denir (Alpaydin, 2014a).

DVM yönteminde ayrılma düzlemi "en yüksek pay" (maksimum margine) prensibinden hesaplanır (Alpaydin, 2014b). Söz konusu prensip, seçilen ayrılma yönüne göre iki sınıfın en kötü (en yakın) iki örneğine göre en büyük ayrımı sağlamaktadır. Söz konusu prensibin matematiksel ifadesi, (4),(5) problemlerinin çözümüdür.

$$(w, b) = \arg \min_{w,b} \left(\frac{1}{2} |w|^2 + C \sum \xi_i \right) \quad (4)$$

$$y_i(w^T x_i - b) \geq 1 - \xi_i, \xi_i \geq 0. \quad (5)$$

Burada w ayrılma düzleminin normal vektörü ve b bir ofset sabitidir. Veri noktalarının DVM ayrılma yönergesi (6) biçiminde tanımlanır.

$$\text{class}(x) = \begin{cases} 1, & \text{eğer } w^T x - b < 0 \text{ ise} \\ 2, & \text{eğer } w^T x - b > 0 \text{ ise} \end{cases} \quad (6)$$

LDA ve DVM yaklaşımlarının çözümü ve uygulanması basit olmakla beraber, bu yaklaşımları kullanabilmek için kritik bir nokta EEG verilerinin önceden uygun bir biçimde temsil edilmesidir. Yani, farklı zihinsel haller ile ilişkili olacak EEG sinyallerinin bir öznitelik vektörü x olarak belirli bir şekilde belirtilmesi gerekir. Bu çalışmada EEG sinyalini temsil etmek için frekans öznitelik uzayları kullanılır. Kaynaklarda, bu amaçla en çok kullanılan EEG sinyalinin bir algılama penceresi içerisinde hesaplanan EEG bant güçleri ve Spektral Güç Dağılımı (Power Spectrum Distribution, PSD) öznitelikleri bilinmektedir. Eğer bir olayda görülen algılama penceresindeki EEG sinyali $x_k(c; t)$ olarak belirtilirse, algılama penceresindeki EEG sinyalinin ayrık Fourier dönüşümü (7) biçiminde tanımlanabilir.

$$X_k(c; f) = \sum_{t=1}^T x_k(c; t) e^{-j2\pi ft/T} \quad (7)$$

Burada k indeksi belirli BBA olayını belirtir, $t=1, \dots, T$ olayın algılama penceresindeki EEG zamansal ayrık örnekleri ve $f=0, 1, \dots, T-1$ ayrık frekans indeksidir. Yani, $x_k(c; t)$ k . olayın algılama penceresindeki, c . EEG elektrodunun, t . zamansal örneğine karşılık gelir. $X_k(c; f)$ ise, ayrık Fourier dönüşümünün k . Olayının, c . EEG elektrodunun, f . karmaşık genliğine karşılık gelir.

Ayrık Fourier dönüşümü kullanılarak PSD (8)'de verilen biçimde hesaplanır.

$$S_k(c; f) = |X_k(c; f)|^2 \quad (8)$$

Yani, $S_k(c; f)$ ilgili ayrık karmaşık Fourier genliğinin mutlak değerinin karesidir. EEG bant güçleri, sözü geçen PSD niteliğinden (9)'da verilen biçimde hesaplanır.

$$P_k(c; b) = \sum_{f=b_0}^{f=b_1} S_k(c; f) \quad (9)$$

Burada $b = (b_0, b_1)$, EEG bantlarını tanımlayan frekans çiftleridir. EEG bantları olarak kaynaklarda en tipik olarak standart EEG bantları kullanılır. Bunlar **Tablo 1**'de gösterilmiştir.

Tablo 1. Standart EEG frekans bantlarının tanımları.

Bant	b0	b1
Delta	1 Hz	4 Hz
Teta	4 Hz	8 Hz
Alfa (Alt Bant)*	8 Hz	10 Hz
Alfa (Üst Bant)*	10 Hz	12 Hz
Beta (Alt Bant)	12 Hz	18 Hz
Beta (Üst Bant)	18 Hz	30 Hz
Gama (Alt Bant)	30 Hz	40 Hz
Gama (Üst Bant)	40 Hz	50 Hz

* - motor korteks üzerinde görülen alfa ritimlerine mu-ritmi denir

Yukarıdakilere göre, PSD ve EEG bant güçleri algılama pencerelerine bağlı EEG sinyalinin farklı frekanslardaki güçleri ifade eder. ERS/ERD ve SSVEP yöntemlerinde, EEG sinyalinin her bir frekans bandındaki güç değişimleri BBA için doğrudan kontrol sinyalleri üretmek için kullanılır. Örneğin, motor korteksin bir tarafında alfa ritminin kaybolduğu zaman, ilgili bölgenin EEG elektrodununun alfa bandı gücü de düşmektedir. BBA sistemi, bu değişikliği sayısal olarak algılayıp ona bağlı eylem uygulayabilir. Benzer şekilde görsel kortekste belirli frekansta SSVEP sinyali geliştiğinde, görsel korteks üzerindeki EEG elektrodunda ilgili frekansta EEG gücü artmaktadır. ERS/ERD ve SSVEP BBA'ünden farklı olarak, ayrı ERP olayları için olaya özgü ERP parçacıklarına ilişkin farklı frekanslarda geçici EEG sinyal değişimleri görülür. Bu nedenle EEG verilerine karşılık gelen ERP olayları, EEG sinyalinin frekans bileşimindeki geçici değişiklikler benzer şekilde analiz edilerek tespit edilmelidir.

Bu şekilde x öznitelik vektörü genellikle belirli bir BBA olayı için tüm EEG elektrotlarından PSD veya EEG bant güçleri birleştirilerek tanımlanır (10),(11).

$$x = (S(c; f), \text{tüm } c, \text{ tüm } f) \quad (10)$$

veya

$$x = (P(c; b), \text{tüm } c, \text{ tüm } b) \quad (11)$$

Örneğin, eğer analizde n_c sayıda EEG elektrodu ve n_f sayıda PSD frekansı veya EEG bandı kullanılmakta ise, x vektörü $n_c n_f$ sayıda öznitelik oluşturabilir. LDA veya DVM sınıflandırma yöntemi, bu vektörü kullanarak $n_c n_f$ boyutta sınıflandırma parametresi (w) yaratır ve gözlemlenen EEG sinyallerinin ilgili sınıflarına $w^T x$ 'e değerine göre atar.

Bu çalışmada, PSD ve EEG bant gücü özniteliklerine ek olarak zaman uzayında EEG sinyali ve ayrık Fourier dönüşümünün karmaşık genlikleri, ERP algılanması için öznitelik olarak kullanılmıştır.

Kaynaklarda geniş çapta kullanılan PSD ve EEG bant gücü özniteliklerinin önemli bir dezavantajı, sinyalin farklı frekans bileşenlerinin fazları hakkındaki bilginin kaybolmasıdır. Bu faz bilgileri, sinyalin şekilleri için önemlidir. Bu nedenle projemizde, yukarıdaki öznitelik uzaylarına ek olarak olayın ERP tanımlayacak BBA sınıflandırmada tamamen kompleks Fourier dönüşüm genlikleri de kullanılmıştır.

$$x = (x(c; t), \text{tüm } c, t = 1, \dots, T) \quad (12)$$

Yani, sınıflandırmada kullanılacak öznitelik vektörü x , olay uyarıcısının anına göre T zamansal örneği olarak tanımlanır. ERP öznitelikleri olarak ayrık Fourier dönüşümünün karmaşık genlikleri kullanıldığında, sınıflandırmaya giren öznitelik vektörü ise (13)'de verilen biçimde olacaktır.

$$x = (X_{re}(c; f), X_{im}(c; f), \text{tüm } c, f = 0, \dots, T/2) \quad (13)$$

Yani $X_{re}(c; f)$ ve $X_{im}(c; f)$ EEG elektrodunun f . frekansının ayırık Fourier dönüşümü genliğinin gerçel ve sanal bileşenidir. Ancak LDA veya DVM yönteminde kullanılacak öznitelik vektörü x tamamen gerçel olmalıdır. Yukarıdaki formülünde ilk $T/2 + 1$ Fourier genliği kullanılması gerçel sinyal için ayırık Fourier dönüşümü genlikleri birbirlerine (14) bağlı olmasından seçilmiştir:

$$X(c; f) = X^*(c; T - f) \quad (14)$$

Özellikle, bu çalışmada EEG BBA verisinin Makine Öğrenme temelli sınıflandırması frekans öznitelik uzaylarında yapılmıştır. Öznitelik çıkarımı, belirli bir zihinsel imge durumunun mevcut olduğu EEG kayıtlarındaki zaman periyotlarını belirleyerek başladı. Bunun için EEG verileri boyunca eGUI tarafından kaydedilen işaretleyici veri kanalı kullanılmıştır. İşaretleyici kanal, deneyler sırasında her zaman eGUI'nin durumunu tanımlamakta ve bundan dolayı katılımcılara talimat verildiği ve verilen zihinsel görüntülerin uygulandığı zamanı belirlemek için kullanılabilir. Böylece, işaretli eylem sinyallerinin onset zamanları ilkönce işaretleyici kanalındaki verilerin sıfırdan sıfır olmayan bir değere geçiş yaptığı zamanlara bağlı işaret verisinde bulundu. Daha sonra 21 giriş kanalından toplanan EEG verilerinin bir kısmı, eylem sinyal onset konumundan belirli bir başlangıç offset t_1 'den eylem sinyal onset konumundan belirli bir son offset t_2 'ye kadar olan süredeki EEG veillerinin kırılması sonucu çıkartılmıştır. Bu tür her veri çerçevesi bir $x_{c\hat{t}}$ matrisi ile temsil edildi. Burada matrisin satırı EEG veri kanallarını, $c=1, \dots, n_{ch}=21$, ve sütunu ise veri çerçevesindeki zaman örneklerini, $\hat{t}=1, \dots, N$, belirtmektedir. N sayısı, $N = [F_s \cdot (t_2 - t_1)]$ bağıntısıyla verilmektedir. F_s örnekleme frekansıdır. EEG verilerini bu şekilde işleyerek, tüm deneyin veri dosyasında verilen zihinsel görüntü olaylarının farklı oluşumlarını betimleyen veri çerçevelerinin bir kümesi oluşturuldu. Daha sonra, her veri çerçevesi üzerinde $\tilde{x}_{c\hat{t}} = DFT_{\hat{t}}(x_{c\hat{t}})$ biçiminde Ayırık Fourier Dönüşümü (DFT) hesaplanarak frekans özellikleri değerlendirildi. Burada ayırık frekans indeksi $\hat{f} = 0, \dots, [N/2 + 1]$ gerçel frekansları $f = \hat{f} \cdot (t_2 - t_1)^{-1}$ sıralamaktadır. Her veri çerçevesi için üç öznitelik tipi hesaplandı: EEG band gücü (EEGB), güç spektrum yoğunluğu (PSD) ve Fourier dönüşümü genlikleri (FTA).

EEG bant güçleri, klinikte ve EEG BBA literatüründeki EEG sinyallerinin karakterize edilmesinin standart bir yoludur (Guger vd., 2003; Malmivuo ve Plonsey, 1995). EEG bant güçleri, EEG sinyalinin yapısını, tanımlanmış bir dizi frekans bandı, **Tablo 1**, üzerindeki sahip olduğu güç dağılımı yoluyla tanımlar (Malmivuo ve Plonsey, 1995). İlgili frekans bantlarındaki her veri çerçevesi için DFT genliklerinin mutlak kareleri toplanarak EEG bandının güç öznitelikleri hesaplanmaktadır. Her EEG veri kanalı için, veri çerçevesi başına

toplam $n_{eeb} = 147$ öznitelik ($n_{ch}=21$ EEG kanalında verilen 0 Hz-offset ve 6 EEG band için) bulunmuştur.

PSD, EEG BCI literatüründe yaygın olarak kullanılan bir başka özelliktir (Lotte vd., 2007). PSD, DFT amplitüdlerinin mutlak karesi olarak $PSD_{cf} = |\tilde{x}_{cf}|^2$ biçiminde tanımlanır. PSD her girdi kanalı için ayrı ayrı hesaplanarak $n_{PSD} = n_{ch}[N/2 + 1]$ boyutlu bir öznitelik vektörü bulunur. N yukarıda tanımlanmıştır. EEGB ve PSD özellikleri için bu çalışmada ham ((i.e. $|\tilde{x}_{cf}|^2$) ve decibel ($10 \log_{10} |\tilde{x}_{cf}|^2$) gösterimini ayrı olarak incelenmiştir. Bu, doğrusal olmayan dönüşümün basit doğrusal Makine Öğrenmesi (ML) sınıflandırma algoritmalarına üzerindeki potansiyel etkisi nedeniyle yapılabilir.

Not olarak, geçmiş literatürde EEG band gücü ve PSD özellikleri çoğunlukla manuel olarak önceden seçilmiş belirli EEG giriş kanalları veya toplanmış EEG sinyalleri (CSP gibi) kullanılarak hesaplanmıştır. Bu çalışmada, bir Makine Öğrenmesi sınıflandırıcısından önce, böyle bir veri kırılma işlemi yapılmamıştır. Bunun yerine, tüm EEG kanallarından çıkarılan tüm bu öznitelikleri muhafaza ederek, Makine Öğrenme algoritmalarının tutulması gereken özniteliklerin seçimini yapmasına izin verdik. Bu nedenle, çalışmamızda kullanılan EEG band gücü ve PSD öznitelikleri, geçmiş çalışmaların EEG BBA'larında tipik olarak kullanılanlardan daha zengindir.

FTA öznitelikleri EEG sinyallerinin fazına duyarlı özniteliklerdir. Yani, hem EEGB hem de PSD mutlak kare işlemi barındırdıkları için EEG dalga biçiminin frekans bileşenlerinin görece fazına duyarsızdır. FTA, DFT'nin kompleks genlikleri olarak tanımlanır ve kompleks sayıların kartezyen ($Re(\tilde{x}_{cf})$ ve $Im(\tilde{x}_{cf})$) ve/veya kutupsal ($|\tilde{x}_{cf}|$ and $Arg(\tilde{x}_{cf})$) gösterim biçimleri yoluyla ML ile kullanılmak üzere gerçek uzayda tanımlanır. Kartezyen gösterim FTA-C, kutupsal gösterim ise FTA-P ile belirtilmiştir. FTA öznitelik vektörünün boyutu $n_{PSD} = n_{ch}N$ dir. Bu çalışmadaki FTA öznitelikleri boylandırılmış fazlardır (Mishchenko vd., 2017). Bunun nedeni reaksiyon süresindeki trial-trial varyasyonundan kaynaklanan BBA yanıtlarının onset zamanındaki değişimlerinin etkisinin azaltılmasıdır.

Spesifik olarak, FTA öznitelikleri doğrudan kompleks Fourier dönüşüm genlikleri \tilde{x}_{cf} olarak tanımlanır. Fakat olaydan olaya sürekli değişen ERP dalgalarında başlangıç noktasının kontrolsüz şekilde kayma olasılığı olabilir. Böyle ERP dalgalarının başlangıç belirsizliği, ERP dalgalarının Fourier genliklerinde $e^{-i2\pi f \Delta t/n}$ gibi kontrolsüz faz değişiklikleri yaratmaktadır. Bu faz değişiklikleri BMA durumu ile tam olarak ilişkisiz olup belirli BMA durumunun EEG verilerinden algılanabilmesini olumsuz şekilde etkiler. Bu nedenle \tilde{x}_{cf} -genliklerini doğrudan kullanan BMA durum ayırma yöntemine ERP dalgalarının başlangıç noktasının kayması ile

ilgili faz değışiklikleri zarar verir. Bu problemin üstesinden gelmek için çalışmamızda faz-eşleşmiş Fourier genlik öznitelikleri kullanılmıştır. Burada, belirli ERP dalgası için öncelikle karmaşık genliklerinin \tilde{x}_{cf} çarpımını ve fazı buluyoruz;

$$\varphi^k = \text{angle}(\prod_{c=1}^{chmax} \prod_{f=1}^{fmax} \tilde{x}_{cf}) \quad (15)$$

Burada $\text{angle}(z) = \text{Im}(\ln z)$, bir karmaşık değışkenin açısını hesaplayan bir fonksiyondur. Bir olayın ERP dalgasının başlangıç kayması ile ilgili Δt zaman ofseti olursa, φ^k değeri ilgili şekilde $chmax \cdot \sum_{f=1}^{fmax} 2\pi f \Delta t$ ek bir faz yaratılacaktır. Buna göre, faz kaymalarını EEG verilerinden çıkartmak için, hesaplanmış ERP Fourier genlikleri ek bir faz θ ile çarpılır (yani $\tilde{x}_{cf} \rightarrow \tilde{x}_{cf} e^{-i2\pi f \theta}$) öyle ki φ^k sıfır yapılır. Bu şekilde standartlaştırılmış ERP Fourier genliklerine faz-eşleşmiş genlikler denir. Bu genliklerin gerçel ve sanal kısımları öznitelik olarak EEG BMA durumlarının ayrılması için başarılı bir şekilde kullanılabilir.

Tablo 2. Farklı özniteliklerin basit EEG BBA olay sınıflandırılması için tipik performans karşılaştırılma sonuçları.

Öznitelik	Zaman serisi	Güç dağılımı	Faz eşleşmiş genlikler
ERP ayrılma doğruluğu	%55-60	%55-60	%75-85

3.3.2 EEG BBA Imge Sembollerinin Sınıflandırılması

Projemizde geniş çapta, EEG BBA verilerindeki zihinsel görüntülerin sınıflandırılması için modern yüksek varyans ve yüksek bias yaklaşımlarını içeren çok sayıda Makine Öğrenme algoritmaları incelenmiştir. Popüler yüksek bias algoritmalarından DVM, LDA, diyagonal LDA (DLDA) ve Gauss Naïve Bayes (GNB) sınıflandırıcılarını göz önüne alındı. DVM ve LDA iyi biliniyor ve ML'deki en başarılı algoritmalarından bazılarıdır (Hastie vd., 2001). EEG BBA literatüründe de son derece başarılı olmuşlardır ve fiili olarak EEG BBA uygulamaları için en iyi seçim olarak göz önüne alınmışlardır. Bu durum da bu çalışmaya dahil edilmelerini sağlamıştır.

DLDA, LDA sınıflandırma kuralında öznitelik kovaryans matrisinin yalnızca köşegen kısmının kullanıldığı LDA'nın bir varyantıdır ve GNB, $P(X_i|c)$ dağılımlarının, c-bağımlı ortalama ve varyansa sahip Gaussyen ile modellendiği benzer bir algoritmadır. EEG BBA ayarlarında yüksek boyutlu öznitelik uzayı ve az sayıdaki eğitim verileri ile karakterize edilen durumlarda, her ikisinin de başarılı olduğu bilinmektedir (Forman ve Cohen, 2004).

Popüler yüksek varyanslı Makine Öğrenme algoritmalarından QDA, KNN, Radyal Tabanlı Fonksiyon Ağları (RBFN) ve Rasgele Orman (RF) algoritmalarını göz önüne alındı. QDA, ortak (bağılı) dağılım fonksiyonu $P(X|c)$ 'nin c-bağımlı ortalama ve kovaryansa sahip çok

değişkenli bir Gauss dağılımı kullanılarak modellendiği LDA'nın genelleştirilmesidir. QDA, Bayesian çıkarsama açısından daha açık anlamlandırmaya sahip olmakla birlikte genellikle LDA'dan daha kötü performans gösterdiği bilinmektedir. Bu nedenle, bu algoritmanın bizim yaptığımız ayarlama nasıl işlediğini görmek ilgi çekicidir.

KNN, bazı EEG BBA çalışmalarının yanı sıra az sayıda eğitim verisi içeren problemlerde başarılı olduğu bilinen bir yüksek varyans sınıflandırıcısıdır (Schalk vd., 2008).

RBFN, bir hedef fonksiyonun bir dizi "radyal" temel fonksiyonların (RBF) bir lineer süperpozisyonu ile yaklaşıldığı popüler bir evrensel fonksiyon yaklaşıdır.

RF çeşitli oluşumlarda başarılı, sağlam bir evrensel sınıflandırıcı olarak ortaya çıkarak, son zamanlarda popüler bir öğrenme algoritması haline gelmiştir.

Tüm bu algoritmalar İstatistik ve Makine Öğrenme araç kutusu kullanılarak Matlab'da uygulanmıştır. Çok sınıflı DVM için, Matlab İstatistik araç kutusunun ikili "svmtrain"ine dayanan özel 1-vs-1 oylama matris uygulamasını uyguladık. LDA için, İstatistik araç kutusunun sınıflandırması kullanıldı. Matlab'ın sınıflandırma fonksiyonu QR LDA algoritmasını kullanır ancak bizim durumumuzda olduğu gibi öznelik sayısının gözlem sayısını aştığı durumlarda kullanamaz. Bu nedenle, LDA algoritmasında için QR faktörizasyonu gerçekleşmeden önce $\Sigma \rightarrow \Sigma + aI$ düzenlemesine eşdeğer olarak öznelik matrisine $X \rightarrow X + \sqrt{a} \cdot \varepsilon$ biçiminde küçük normal iid gürültüsü ekleyerek sınıflandırma fonksiyonunu modifiye ettik. DLDA, QDA ve GNB, Matlab'ın "classify" fonksiyonu temelinde gerçekleştirildi. Ancak DLDA'da yalnızca Σ 'nin köşegen kısmı kullanılmış ve QDA'da ise LDA karar kuralındaki sınıfa özgü kovaryans $\Sigma_c = cov(X - \mu_c)$ kullanılmıştır. GNB'de sınıfa özel Σ_c 'nin köşegen kısmı kullanıldı.

KNN, RBE ve RF için Matlab Sinir Ağları ve Makine Öğrenme araç kutularındaki mevcut uygulamalar kullanılmıştır. KNN için Makine Öğrenme araç kutusunun KNN sınıflandırıcısı kullanıldı. Bu sınıflandırıcı bir hiper parametreye sahiptir ki bu, $[1, 3\sqrt{n_s}]$ aralığında çapraz doğrulama tabanlı grid araması ile optimize edilen en yakın komşuların sayısı olan K'dır. Burada n_s eğitim örneklerinin sayısıdır (Duda vd., 2001).

RBFN için Sinir Ağı araç kutusunun rbe fonksiyonu kullanıldı (RBE). Bu fonksiyon, n_s 'ye eşit terimlerin sayısının ve tüm eğitim örneklerinin (x_i, y_i) tam olarak eşleştirildiği "tam" bir Gaussyen RBF ağı, $\hat{f}(x) = \sum w_k g(x - \mu_k)$, öğrendi. RBE çıktısını multinomial sınıf etiketine çevirmek için bir indikatör matris yöntemi (Hastie vd., 2001) kullandık. Özellikle n_c sınıfları için n_c RBE, indikatör fonksiyonlarını $I(c(X) = c')$ fit edecek biçimde eğitildi. Sınıflandırma sırasında, en büyük çıktılı RBE'nin etiketi $\hat{c}(X)$ olarak döndürüldü. Bu sınıflandırmadaki tek

serbest parametre $[0.25\rho, 6\rho]$ aralığında grid araması ile optimize edilen Gaussyen RBF'nin genişliğidir. Burada ρ , eğitim örneğindeki ortalama en yakın komşu mesafesidir.

RF için, Makine Öğrenme araç kutusu'nun *TreeBagger*'ı kullanıldı. *TreeBagger* Breiman'ın CART algoritmasını uygulamaktadır (Breiman, 2001). *TreeBagger* fonksiyonunun tüm opsiyonel parametreleri önerilen varsayılanlarda tutulmuştur ve ağaç sayısının zorunlu parametresi (Oshiro vd., 2012) çalışması temel alınarak $n_T=100$ olarak belirlenmiştir. Seçtiğimiz grid aramamızın sonuçları RF doğruluğunun tipik olarak $n_T=100$ 'den sonra artmadığını gösterdi.

Tablo 3. Çalışmamızda değerlendirilen öznitelik uzay seçimlerini, öznitelik ön seçim algoritmalarını ve ML sınıflandırma algoritmalarını içeren listenin tamamı.

Öznitelikler	Öznitelik Filtreler	ML Sınıflandırıcılar
EEG	LOWPASS	DVM
EEG-dB	FRQ	LDA
PSD	MUI	DLDA
PSD-dB	KLD	GNB
FTA-C	COR/ICC	QDA
FTA-P	ALL	KNN
TS		RBE
FULL		RF

3.3.3 EEG BBA Veri Analizi İçin Öznitelik Ön-Seçilmesi

Birçok önceki EEG BBA çalışmalarında başarılı olmak için öznitelik ön-seçiminin önemli olduğu görülmüştür. EEG BBA'de belirleyici öznitelik olarak belirli elektrot veya EEG frekansları kullanılmıştır. Teorik olarak, EEG BBA'da öznitelik ön-seçimi, EEG BBA'daki öznitelik boyutunun yüksek ve eğitim verinin az olmasından dolayı faydalı olabilir.

Önceki birçok EEG BBA çalışmalarında öznitelik ön-seçimi maalesef manuel, yani uzman tarafından verilere bakılarak gerçekleştirilmiştir. Alternatif olarak, EEG BBA öznitelik ön-seçiminde iki farklı yöntemler de literatürde incelenmiştir. Birisi, EEG öznitelikleri çıktı ile korelasyonuna r^2 göre sıralanıp seçilmektedir (Friedrich vd., 2009; McFarland ve Wolpaw, 2008; McFarland vd., 2008, 2010). İkincisi ise, iki durumlu EEG BBA öznitelikleri, hedef olan iki duruma göre ilgili özniteliklerin koşullu değer dağılımlarının Kullback-Leibler uzaklığının ayırımı göre sıralanıp seçilmektedir (Benevides vd., 2011a, 2012).

Bu çalışmada bu iki yaklaşım, sistematik EEG BBA öznitelik ön-seçim yaklaşımı olarak temel başlangıç noktası kabul edilip, alternatif öznitelik ön-seçim ve onların EEG BBA performansına etkisi araştırılmaktadır. Bunlar arasında "leave-one-out" yaklaşımında, tam öznitelik kümesinden bir öznitelik çıkartılır ve öğretim verileri kullanılarak EEG BBA'nın performans azalışı ölçülür. Bu şekilde öznitelikliğin önemi tahmin edilir. Bütün öznitelikler için

bu süreç tamamlandıktan sonra, en az önemli olan öznitelik, öznitelik kümesinden çıkartılır ve süreç tekrarlanır. Görüldüğü gibi, bu yaklaşım “açıklayan varyans” yaklaşımının tam tersidir–en az etkili öznitelikler ilk önce çıkarılır.

Alternatif olarak, karşılıklı bilgi öznitelik değerlendirme ve ön-seçim yöntemi bu çalışmada da kullanılmıştır. Karşılıklı bilgi (MacKay, 2003; Peng vd., 2005; Zaffalon ve Hutter, 2002), bilgi teorisinin iki rastgele değişkeni arasında ortak bilgiyi ölçmek için kullanılan bir yöntemidir. Daha spesifik olarak karşılıklı bilgi, bir rastgele değişken Y 'de diğer rastgele değişken X hakkında içerilen bilgi ölçülür. Karşılıklı bilgi şu şekilde tanımlanır, $I(X, Y) = H(X, Y) - H(X) - H(Y)$, ve bir rastgele değişkenin değerinde ikinci değişkenin değerini dikkate alarak entropiyi yani belirsizlik azalışını ifade eder. Burada $H(X) = E_{P(X)}[\log P(X)]$ standard entropidir. Eğer X ve Y istatistiksel olarak bağımsızlarsa, karşılıklı bilgi $I(X, Y) = 0$ dir. Diğer taraftan eğer değişken Y değişken X 'i tamamen belirlerse, karşılıklı bilgi azami değeri sağlanır $I(X, Y) = H(Y)$. Bu şekilde, karşılıklı bilgi iki değişken arasındaki ilişkiyi ölçer. Karşılıklı bilginin korelasyon gibi diğer niteliklere göre avantajı, iki değişken arasındaki bağımlılığın fonksiyonel şekline bağlı olmamasıdır. Yani korelasyon gerçekten iki değişkenin arasındaki doğrusal ilişkiyi ölçerken, karşılıklı bilginin böyle bir kısıtı yoktur. EEG BBA öznitelikleri ön-seçilmesinde, tüm öznitelikler için birer birer tahmin edilmesi gereken zihinsel durum değişkeni ile karşılıklı bilgiyi hesaplayıp sıralıyoruz ve belirli sayıda en yüksek karşılıklı bilgiye sahip olan öznitelikleri bırakıyoruz.

Bu çalışmada özellikle bilgi temelli, korelasyon tabanlı ve frekans tabanlı öznitelik ön seçim stratejilerini kullanıldı. Bilgi temelli öznitelik seçme stratejileri, karşılıklı bilgi ve Kullback-Leibler ıraksama tabanlı öznitelik filtreleridir. Karşılıklı bilgi, rastgele değişkenlerin ilişkisinin genel bir ölçüsüdür. Karşılıklı bilgi filtresi (MUI), birbirinden ayrı öznitelikler X_i ile hedef zihinsel görüntü sınıf değişkeni c 'nin karşılıklı bilgisi, $MUI = H(X, c) - H(X) - H(c)$ biçiminde hesaplanarak değerlendirilir. Burada H standart entropidir. Histogram yöntemi olasılık yoğunluklarını tahmin etmek için kullanılmıştır. Böylece $H(X, c)$ histogram aracılığıyla tahmin edilen koşullu 1D $P(X|c)$ yoğunlukları ile $H(X, c) = \sum_c P(c) \sum_x P(X|c) \log P(X|c) + H(c)$ olarak hesaplanmaktadır.

İki zihinsel imge için, literatürde EEG BBA öznitelik ön seçimi için $KLD = \sum P(X|c = 1) \ln P(X|c = 1)/P(X|c = -1)$ biçiminde Kullback-Leibler ıraksaması (KLD) kullanılmıştır (Benevides vd., 2011a). KLD, $c=\pm 1$ olmak üzere iki sınıfa göre bir özniteliğin $P(X|c)$ koşullu dağılımındaki ayrımı nicelendirir. Bu ölçüm bizim tarafımızdan uygulanmış ve kullanılmıştır.

Göz önüne alınan korelasyon temelli öznitelik seçimi stratejileri, sınıf içi korelasyon katsayısı (ICC) veya Pearson korelasyon (COR) öznitelik filtreleridir. Sınıf içi korelasyon katsayısı, $X_i|c = \mu_i + \alpha_{ic} + \epsilon_i$ biçimindeki doğrusal bir model cinsinden tanımlanan, bir kategorik ve bir sürekli rastgele değişken arasındaki ilişkililiğin doğrusal bir ölçümüdür, $ICC = var(\alpha) / (var(\alpha) + var(\epsilon))$. Burada, $X_i|c$ sınıf etiketi c üzerinde şartlandırılmış rasgele değişken X_i , μ_i sınıf-bağımsız ortalama ve α_{ic} ise sınıf-bağımlı etkidir. ϵ_i rastgele gürültüdür. $c = \pm 1$ olmak üzere iki sınıf durumunda ICC, Pearson korelasyonun karesine indirgenir $COR = cov(X_i, c) / std(X_i)std(c)$.

Frekansa dayalı öznitelik seçimimiz için, özniteliklerin frekansı, öznitelikleri düşük frekanstan yüksek frekansa (FRQ) sıralamak için kullanılmıştır. Ayrıca, bir 5 Hz alçak-geçiren filtre (LOWPASS) (Mishchenko vd., 2017) çalışmasındaki bulgulardan hareketle denetlenmiştir.

Özniteliklerin ön seçimi için, öznitelikler yukarıdaki ölçütlerden birine göre sıralanmıştır ve ML sınıflandırıcısında kullanım için en üst n_{ft} öznitelikler seçilmiştir. Kullanılan öznitelik sayısı, en üst $n_{ft}=25$ öznitelikten başlanması ve seçilen özniteliklerin sayısının EEG BBA sınıflandırma performansında çapraz doğrulamaya dayalı bir düşüş tespit edilene kadar $\Delta n_{ft}=25$ ile artırılması biçiminde grid araştırması aracılığıyla otomatik olarak seçilmiştir.

3.3.4 Bütünleşik EEG BBA Veri İşleme Tasarımlarının Sistemik İncelenmesi

BBA sembol sınıflandırma algoritması için farklı tasarım seçeneklerinin karşılaştırılması için, sistemik sıra birleştirme (rank aggregation) yöntemi kullanılmıştır. Tüm algoritmalar, zihinsel görüntü tespit doğruluklarına, veri setimizdeki tüm katılımcıların tüm deneyleri üzerinden ortalamalarına ve tüm verilerde her bir katılımcı için en iyi ve en kötü deney doğruluğuna göre sıralanmıştır. Daha sonra farklı seçimlerin genel sıralaması Kendall'in tau sıralama birleştirme kullanılarak üretilmiştir (Lin, 2010). Kendall'in tau sıralama birleştirme, öğelerin sıralanmasının bir dizisi için, uyumsuz çiftlerin yani iki sıralamada ters sırada görünen öğe çiftlerinin toplam sayısını minimize eden bir sıralama bulmak için uğraşır. Kendall'in tau sıra uzaklığı

$$\tau(X, Y) = \sum_{i,j} |w_i^X - w_j^Y| \text{sgn}(X_i - X_j) \text{sgn}(Y_i - Y_j) \quad (16)$$

biçiminde tanımlanır, burada X ve Y iki karşılaştırılan sıralama, w_i^X ağırlıklar; i ve j ise sıralamadaki öğelerdir. Bu çalışmadaki w_i ağırlıkları $w_i^X = p_i^X$ olarak seçilmiştir, burada p_i^X , i öğrenenin kriter X üzerindeki performansdır (bir öğrenenin katılımcıların ortalaması, en iyi veya en kötü deneyleri üzerindeki performansı gibi). Bu, hemen hemen özdeş performansa sahip öğrenenlerin farklı sıralamasının birleştirme sonucu üzerindeki etkisinin azaltılmış olması gerçeğini yansıtmayı amaçlıyordu. Tüm τ için ortaya çıkan kombinasyonel optimizasyon problemi R'deki *RangAggreg* paketi kullanılarak çözülmüştür (Pihur vd., 2009).

Bu değerlendirme prosedürünün seçiminin arkasındaki motivasyon, tüm katılımcılar üzerinden yüksek ortalamalı EEG BBA performansına ulaşan tasarım seçeneklerini ve çoğu katılımcı için en iyi gün ve en kötü gün performansını belirlemek istememizdir.

EEG BBA sınıflandırıcılarının farklı tasarımlarının yani öznelik uzayı, öznelik seçimi ve ML algoritmasının kapsamlı bir şekilde değerlendirilmesi, **Tablo 3**'teki EEG BBA sinyal çözücü tasarım seçeneklerinin her bir kombinasyonunun tüm deneylere göre değerlendirilmesiyle yapılmıştır. Değerlendirilmesi, rasgele dışarıda tutma çapraz doğrulaması (hold-out cross-validation) kullanılarak yapılmıştır: Her bir deney için, mevcut zihinsel görüntü verisinin rastgele %63'ü dekoderi eğitmek için kullanıldı, %27'si herhangi bir hiper parametreyi optimize etmek için kullanılan doğrulama seti olarak seçildi ve %10'u bu tasarımın performansının son tahminleri için test seti olarak seçildi.

EEG BBA çözücü tasarımları belirli rasgele varyasyon faktörlerine bağlıdır. Birincisi, performansı tahmin etmek için kullanılan rastgele test örneğinden dolayı, eğitim, doğruluk ve test zihinsel görüntü veri örneklerinin rastgele seçimi nedeniyle EEG BBA performans tahminlerinde mevcut olan rasgele varyasyondur. Değişkenliğin diğer iki kaynağı, katılımcı ve günle ilişkili EEG BBA performansının varyasyonudur. Farklı katılımcılar EEG BBA'da sürekli olarak farklı performans gösterdi. Örneğin, tüm deneylerde ve tüm analiz yöntemlerinde 13 katılımcıdan 5'i sürekli olarak yüksek BBA performansı gösterirken, 2 denek kötü performans göstermiştir. Benzer şekilde, aynı katılımcılar, farklı günlerde yapılan deneylerde farklı performans sergilediler, ancak yüksek performans gösteren bir katılımcı asla çok düşük performans göstermedi aynı zamanda bunun tam tersi de mümkün olmadı. Bu tür performans değişiklikleri günle ilişkilidir. Bir EEG BBA'daki ayrılmış zihinsel görüntü sembollerinin farklı sayıları ile ilişkili olarak, genel bakış açısından ilginç olan bu performans değişiklik faktörleri üzerine ölçümlerimiz **Table 4.** 'te nicelenmiştir.

Tablo 4. Rastgele seçilmiş değerlendirme ilişkin varyasyon (EVAL), katılımcı ilişkin varyasyon (SUBJ), ve katılımcıların gününe ilişkin varyasyonu (D2D) içeren farklı değişkenlik kaynakları başına EEG BBA sınıflandırma doğruluk varyasyonu.

	EVAL SEM	SUBJ STD	D2D STD
2S	0.011	0.076	0.078
3S	0.010	0.129	0.087
4S	0.010	0.162	0.080
5S	0.010	0.179	0.085
6S	0.009	0.194	0.087

3.4 EEG Veri İçin Saklı Markov Modeli Tabanlı Analizi

Projenin bu bölümünde, Makroskobik ölçekteki elektroensefalografik (EEG) beyin sinyallerini açıklayabilecek (modelleyebilecek) bir matematiksel saklı Markov modelin geliştirilmesi ve bu

modelin parametrelerinin kullanılarak EEG tabanlı BBA zihinsel durumların Bayes yaklaşımlarına dayanılarak tahmin edilmesi amaçlanmıştır.

3.4.1 EEG Beyin Aktivitesinin Saklı Markov Modeli

Makroskobik ölçekteki elektroensefalografik (EEG) beyin sinyallerini açıklamak için kullandığımız saklı Markov modeli (Hidden Markov Model (HMM)), EEG sinyallerini (modelin gözlenen kısmı) ve EEG sinyal kaynaklarını (modelin saklı kısmı) betimleyecek biçimde iki kısımdan oluşturulmuştur:

3.4.2 EEG Sinyal Modeli

EEG sinyali, beyin korteksindeki birer akım kaynağı olan yerleşmiş sinirsel popülasyonların ürettiği elektromanyetik sinyallerin bir karışımı olarak düşünülmektedir. Bu durumda EEG sinyali yerleşmiş sinirsel popülasyonların aktivitelerinin çizgisel üst üste binmesi olarak aşağıdaki biçimde empirik olarak temsil edilebilmektedir:

$$E_{\alpha t} = \sum_{\beta} A_{\alpha\beta} S_{\beta t} + \eta_{\alpha t} \quad (17)$$

Burada $\alpha = 1, \dots, N_e$, $\beta = 1, \dots, N_s$ ve $t = 1, \dots, T$ indisleri sırasıyla elektrot sayısını, kaynak sayısını ve zamanı göstermektedir. $E_{\alpha t}$, her bir t anı için tüm elektrotlardaki EEG aktivitesini temsil eden sütun matrisi, $S_{\beta t}$, her bir t anı için yerleşmiş sinirsel popülasyonlardan oluşan merkezlerin aktivitelerini gösteren sütun matrisi, $A_{\alpha\beta}$ yerleşmiş sinirsel popülasyonlardan oluşan merkezlerin aktivitelerinin karışımını sağlayan matris ve $\eta_{\alpha t}$ ise her bir t anındaki EEG elektrotlarındaki gürültüyü temsil eden sütun matrisidir.

3.4.3 EEG Kaynak Modeli

EEG sinyalinin kaynakları beyindeki nöral merkezleri olarak düşünülerek, birbiri ile etkileşen böyle inhibitör (i) ve eksitatör (e) kaynakları cinsinden ifade edilebilen, EEG sinyal kaynaklarını betimleyebilmek için aşağıdaki nörofizyoloji tabanlı model önerilebilmektedir:

$$\begin{pmatrix} S_{\beta t}^i \\ S_{\beta t}^e \end{pmatrix} = \begin{pmatrix} F(\tilde{I}_{\beta t}^i - \sum_{\beta} w_{\beta\beta;t-t'}^u S_{\beta t'}^i + \sum_{\beta \neq \gamma} w_{\beta\gamma;t-t'}^{ei} S_{\gamma t'}^e + \varepsilon_{\beta t}) \\ F(\tilde{I}_{\beta t}^e + \sum_{\beta} w_{\beta\beta;t-t'}^{ee} S_{\beta t'}^e - \sum_{\beta \neq \gamma} w_{\beta\gamma;t-t'}^{ie} S_{\gamma t'}^i + \varepsilon_{\beta t}) \end{pmatrix} \quad (18)$$

Bu denklem genel olarak kapalı biçimde aşağıdaki vektör denklem ile temsil edilebilmektedir:

$$S_{\beta t} = F(\tilde{I}_{\beta t} + \sum_{\gamma, t' < t} w_{\beta \gamma, t-t'} S_{\gamma t'} + \varepsilon_{\beta t}) \quad (19)$$

burada $t' = t - \tau$ olup τ sinaptik iletimdeki gecikme süresini temsil etmektedir. $\tilde{I}_{\beta t}$, t anındaki yerleşmiş sinirsel popülasyonlardan oluşan merkezlerin sahip olduğu elektriksel aktiviteyi temsil eden sütun matrisi, $\varepsilon_{\beta t}$ ise nöral aktivitedeki ve sinaptik iletimdeki gürültüyü temsil eden sütun matrisidir. F , bir transfer fonksiyonu olup doğrusal ve doğrusal olmayan biçimde seçilebilmektedir. Çalışmalarımızda transfer fonksiyonu hem doğrusal $F(z) = z$ hem de doğrusal olmayan $F(z) = \tanh z$ biçimde ele alınmıştır. $w_{\beta \gamma}$ sinirsel popülasyonlardan oluşan merkezler arasındaki iletim ağırlıklarıdır. $\beta = \gamma$ olması durumu bir merkezin kendisi ile etkileşmesi, $\beta \neq \gamma$ olması durumu ise bir merkezin başka bir merkez ile etkileşmesi anlamına gelmektedir.

Modelin gözlenen kısmını oluşturan Denklem (17) ve Denklem (19), akım ile sinirsel popülasyonlardan oluşan merkezlerin aktiviteleri arasındaki ilişki, $I_{\beta t} = F^{-1}(S_{\beta t})$, kullanılarak akımlar cinsinden aşağıdaki biçimde ifade edilmişlerdir.

$$E_{\alpha t} = \sum_{\beta} A_{\alpha\beta} F(I_{\beta t}) + \eta_{\alpha t} \quad (20a)$$

$$I_{\beta t} = \tilde{I}_{\beta t} + \sum_{\gamma, t' < t} w_{\beta \gamma, t-t'} F(I_{\gamma t'}) + \varepsilon_{\beta t} \quad (20b)$$

Denklem (20a) ve Denklem (20b) veri analizi açısından, makroskobik ölçekteki EEG beyin sinyalleri için çalışmalarımızda kullanılan tam HMM'dir. Şu HMM'nin parametre kümesi $\theta_{k_t} = \{A_{\alpha\beta}, \tilde{I}_{\beta}, w_{\beta\gamma}, \eta_{\alpha}, \varepsilon_{\beta}, P_{kl}\}$ biçiminde tanımlanmaktadır; burada k_t , EEG tabanlı beyin bilgisayar arayüzündeki (Brain-Computer Interface (BCI)) zihinsel durumlara karşılık gelen makro durum değişkeni olarak ifade edilmektedir. Bu, EEG-BCI sinyalindeki farklı zihinsel durumları göstermek için farklı parametre kümelerinin kullanılması anlamına gelmektedir. P_{kl} , makro durumlar için geçiş olasılık matrisidir. HMM'nin değişkenleri ise gözlenen durumlar $E_{\alpha t}$ ve saklı durumlar $\mathbf{X}_t = \{\mathbf{k}_t, \mathbf{I}_t\}$ olarak tanımlanmaktadır.

3.4.4 Empirik EEG Modellerinin Parametre Tahmin Edilmesi

EEG sinyallerini açıklayabilmek için yukarıdaki HMM'in parametrelerinin aslı EEG verilerden tahmin edilmesi gerekmektedir. Bunun için projemizde Beklenti Ençoklama (Expectation-Maximization (EM)) yöntemi kullanılmıştır. Bayes teoremine dayalı EM yönteminde HMM'nin parametre kümesinin tahmin edilebilmesi için aşağıdaki

$$Q(\theta | \hat{\theta}) = E_{P(\mathbf{X}_t | \mathbf{E}_t, \hat{\theta})} \left\{ \ln \left[P(\mathbf{X}_0) P(\mathbf{E}_0 | \mathbf{X}_0, \theta) \prod_{t=1}^T P(\mathbf{E}_t | \mathbf{X}_t, \theta) P(\mathbf{X}_t | \mathbf{X}_{t-1}, \theta) \right] \right\} \quad (21)$$

logaritmik olabilirlik fonksiyonunun maksimize edilmesi gerektiği bulunmuştur. Burada $\hat{\theta}$ tarafımızdan belirlenen başlangıç parametre kümesini ifade etmektedir. Çalışmalarımızda $\eta_{\alpha t}$ ve $\varepsilon_{\beta t}$ gürültülerinin Gausyen dağılıma sahip olduğu varsayılmıştır; $\eta_{\alpha t} \sim N(0, \Sigma_{\eta})$, $\varepsilon_{\beta t} \sim N(0, \Sigma_{\varepsilon})$. Bu durumda HMM'in parametrelerinin tahmin edilmesini sağlayan Denklem (21) aşağıdaki biçimde yazılabilir:

$$Q(\theta | \hat{\theta}) = E_{P(\mathbf{X}_t | \mathbf{E}_t, \hat{\theta})} \left\{ - \sum_t (\mathbf{E}_t - \mathbf{A} F(\mathbf{I}_t))^T \Sigma_{\eta}^{-1} (\mathbf{E}_t - \mathbf{A} F(\mathbf{I}_t)) + \sum_t \ln \mathbf{P}_{\mathbf{k}_t, \mathbf{k}_{t-1}} \right. \\ \left. - \sum_t (\mathbf{I}_t - \tilde{\mathbf{I}}_t - \mathbf{w} F(\mathbf{I}_{t-1}))^T \Sigma_{\varepsilon}^{-1} (\mathbf{I}_t - \tilde{\mathbf{I}}_t - \mathbf{w} F(\mathbf{I}_{t-1})) + sbt \right\} \quad (22)$$

3.4.4.1 Saklı Durum Örneklerinin Üretilmesi

Denklem (22)'nin hesaplanabilmesi için ilk önce gözlenmeyen saklı durum zaman serisi \mathbf{x}_t üretilmelidir. Bunun için ileri-geri algoritmaları (Forward-Backward algorithm) kullanılabilir. $P(\mathbf{X}_t | \mathbf{E}_{1:t})$ olasılık dağılımına göre saklı durum zaman serilerinin üretilmesini sağlayan Bayes teoremine dayalı ileri geçiş algoritması aşağıdaki biçimde yazılır:

$$P(\mathbf{X}_{t+1} | \mathbf{E}_{1:t+1}) = P(\mathbf{E}_{t+1} | \mathbf{X}_{t+1}) \frac{P(\mathbf{X}_{t+1} | \mathbf{X}_t)}{P(\mathbf{E}_{t+1} | \mathbf{E}_{1:t})} P(\mathbf{X}_t | \mathbf{E}_{1:t}) \quad (23)$$

Burada $P(\mathbf{E}_{t+1} | \mathbf{E}_{1:t})$ boylandırma sabitidir ve aşağıdaki biçimde ifade edilir:

$$z = P(\mathbf{E}_{t+1} | \mathbf{E}_{1:t}) = \int P(\mathbf{E}_{t+1} | \mathbf{X}_t) P(\mathbf{X}_t | \mathbf{E}_{1:t}) d\mathbf{X}_t \quad (24)$$

İleri geçiş algoritmasının hesaplanmasında iki sorunla karşılaşmaktadır. Bunlardan birincisi çok katlı integral içeren boylandırma sabitinin analitik olarak hesaplanamaması, ikincisi ise $P(\mathbf{X}_t | \mathbf{E}_{1:t})$ sonsal dağılımına göre doğrudan saklı durum zaman serilerinin üretilmesinin her zaman mümkün olmamasıdır. Bu nedenle ardışık önem örneklemesine (sequential importance sampling (SIS)) dayalı ardışık Monte-Carlo (sequential Monte-Carlo (SMC)) yöntemi kullanılmaktadır. Bu yöntemde, $P(\mathbf{X}_t | \mathbf{E}_{1:t})$ sonsal dağılımına göre parçacık olarak adlandırılan N tane bağımsız ve özdeş dağılmış rastgele örnekler $\{\mathbf{X}_t^i \sim P(\mathbf{X}_t | \mathbf{E}_{1:t}), i = 1, \dots, N, t = 1, \dots, T\}$ üretilmesi amaçlanmaktadır. Ancak $P(\mathbf{X}_t | \mathbf{E}_{1:t})$ sonsal dağılımından doğrudan örnek üretmek mümkün olmadığı için sonsal yoğunluk fonksiyonu $P(\mathbf{X}_t | \mathbf{E}_{1:t})$ yerine öneri yoğunluk fonksiyonu (proposal density function) veya önem fonksiyonu (importance function) $\pi(\mathbf{X}_t | \mathbf{E}_{1:t})$ seçilir. Önem fonksiyonu ile sonsal yoğunluk fonksiyonu arasındaki ilişki aşağıdaki biçimde verilir:

$$\omega_t^i = \frac{P(\mathbf{E}_{1:t} | \mathbf{X}_t^i) P(\mathbf{X}_t^i)}{\pi(\mathbf{X}_t^i | \mathbf{E}_{1:t})} \quad (25)$$

burada ω_t^i boylandırılmamış önem ağırlıklarıdır. Ardışık önem örneklemesi (SIS) göz önüne alındığında önem fonksiyonu

$$\pi(\mathbf{X}_t | \mathbf{E}_{1:t}) = \pi(\mathbf{X}_{t-1} | \mathbf{E}_{1:t-1}) \pi(\mathbf{X}_t | \mathbf{X}_{t-1}, \mathbf{E}_{1:t}) \quad (26)$$

biçiminde yazılır ve boylandırılmamış önem ağırlıkları ise aşağıdaki biçimde elde edilirler:

$$\omega_t^i = \omega_{t-1}^i \frac{P(\mathbf{E}_t | \mathbf{X}_t^i) P(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i)}{\pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})} \quad (27)$$

Ardışık önem örneklemesinde yozlaşma sorunu ortaya çıkmaktadır. t arttıkça biri hariç tüm parçacıkların önem ağırlıkları yaklaşık olarak sıfır olmaktadır. Bundan dolayı algoritma iyi sonuç vermemektedir. Yozlaşmayı ortadan kaldırmak için yeniden örnekleme (resampling) tekniği kullanılmıştır. Yeniden örnekleme tekniğinin amacı küçük önem ağırlıklı parçacıkları kaldırarak büyük önem ağırlıklı parçacıkları çoğaltmaktır. Yozlaşma ölçüsü etkin örnek büyüklüğü ile aşağıdaki biçimde verilir:

$$N_{Etk} = \frac{1}{\sum_{i=1}^N \tilde{\omega}_t^i} \quad (28)$$

burada $\tilde{\omega}_t^i$ boylandırılmış önem ağırlıklarıdır. Yeniden örnekleme adımı sadece $N_{Etk} < N_{Esk}$ olduğunda uygulanır. Burada N_{Esk} belirli bir eşik ifade eder.

Geri geçiş algoritması (backward algorithm) ise Bayes teoreminin kullanılmasıyla aşağıdaki biçimde elde edilir:

$$P(\mathbf{X}_t, \mathbf{X}_{t+1} | \mathbf{E}_T) = P(\mathbf{X}_t | \mathbf{E}_{1:t}) \int \frac{P(\mathbf{X}_{t+1} | \mathbf{X}_t)}{P(\mathbf{X}_{t+1} | \mathbf{E}_{1:t})} P(\mathbf{X}_{t+1} | \mathbf{E}_{1:t}) d\mathbf{X}_{t+1} \quad (29)$$

Bu algoritma SMC yöntemine dayalı aşağıdaki yaklaşımların

$$P(\mathbf{X}_t | \mathbf{E}_{1:t}) = \sum_{i=1}^N \tilde{\omega}_t^i \delta(\mathbf{X}_t - \mathbf{X}_t^i) \quad (30a)$$

$$P(\mathbf{X}_t | \mathbf{E}_{1:T}) = \sum_{i=1}^N \tilde{\omega}_t^i \delta(\mathbf{X}_t - \mathbf{X}_t^i) \quad (30b)$$

kullanılması ile önem ağırlıkları cinsinden aşağıdaki biçimde ifade edilir:

$$\tilde{\omega}_t^i = \sum_{j=1}^N \tilde{\omega}_{t+1}^j \frac{\tilde{\omega}_t^i P(\mathbf{X}_{t+1}^j | \mathbf{X}_t^i)}{\sum_{l=1}^N \tilde{\omega}_t^l P(\mathbf{X}_{t+1}^l | \mathbf{X}_t^l)} \quad (31)$$

burada δ ; Dirac delta fonksiyonunu, $\tilde{\omega}_t^i$; ileri geçiş algoritması, $\tilde{\omega}_t^i$ ise geri geçiş algoritması için boylandırılmış önem ağırlıklarını temsil etmektedir.

Yeniden örnekleme ve SIS'e dayalı SMC yöntemi kullanılan ileri ve geri geçiş algoritmaları, Matlab programı kullanılarak aşağıdaki **Tablo 5** ve **Tablo 6**'da verilen adımlara göre yazılımsal hale getirilmiştir.

Tablo 5.SMC yöntemine dayalı ileri geçiş algoritması

1.Başlangıç adımı:

- $t = 0$ ve $i = 1, \dots, N$ için $\mathbf{X}_0^i \sim P(\mathbf{X}_0)$ örnekleme.

2.Önem örnekleme adımı:

- $i = 1, \dots, N$ için $\mathbf{X}_t^i \sim \pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})$ örnekleme ve $\mathbf{X}_{0:t}^i = \{\mathbf{X}_{0:t}^i, \mathbf{X}_t^i\}$ oluşturulması.
- $i = 1, \dots, N$ için önem ağırlıklarının bulunması ve boylandırılması.

$$\omega_t^i = \omega_{t-1}^i \frac{P(\mathbf{E}_t | \mathbf{X}_t^i) P(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i)}{\pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})} \quad (32)$$

$$\tilde{\omega}_t^i = \frac{\omega_t^i}{\sum_{i=1}^N \omega_t^i} \quad (33)$$

3.Yeniden örnekleme adımı:

- $N_{Etk} < N_{Esk}$ ise önem ağırlıklarına göre $\mathbf{X}_{0:t}^i$ 'den N parçacığın değiştirilmesi ile yeniden örnekleme
- $t \leftarrow t + 1$ ve 2. adıma dönülmesi

Tablo 6.SMC yöntemine dayalı geri geçiş algoritması

1.Başlangıç adımı:

- $t = T$ ve $i = 1, \dots, N$ için $\tilde{\omega}_t^i = \omega_t^i$ olarak ayarlamak.

2.Önem ağırlıklarının hesaplanması adımı:

- $t = T - 1, \dots, 0$ ve $i = 1, \dots, N$ için önem ağırlıklarının bulunması

$$\tilde{\omega}_t^i = \sum_{j=1}^N \tilde{\omega}_{t+1}^j \frac{\tilde{\omega}_t^i P(\mathbf{X}_{t+1}^j | \mathbf{X}_t^i)}{\sum_{l=1}^N \tilde{\omega}_t^l P(\mathbf{X}_{t+1}^l | \mathbf{X}_t^l)} \quad (34)$$

Saklı durum zaman serilerinin üretilmesini sağlayan ileri ve geri geçiş algoritmalarının yazılımsal hale getirilmesinin yanı sıra modelin parametrelerinin tahmin edilmesini sağlayan Denklem (22)'deki olabilirlik fonksiyonun maksimize edilmesi ile ilgili olan optimizasyon adımı da Matlab'da yazılımsal hale getirilmiştir.

Oluşturulan matematiksel HMM'nin ve kullanılan yöntemlerin makroskobik ölçekteki EEG sinyallerini açıklamadaki başarı oranını bulmak için sırasıyla aşağıdaki adımlar izlenmiştir:

- Eğitim verisi olarak belirlenen EEG veri kümesi ile başlangıç parametre kümesi $\hat{\theta}_{k_i}$ EM yönteminde kullanılarak logaritmik olabilirlik fonksiyonu $Q(\theta | \hat{\theta})$ 'yı maksimum yapacak θ_{k_i} parametre kümesi bulunmuştur. EM yönteminin örnekleme kısmı için **Tablo 5** ve **Tablo 6**'da verilen SMC tekniğine dayalı ileri-geri geçiş algoritmaları kullanılmıştır. Bu adımda her bir t anındaki gerçek makro durumlar kullanılmıştır. Bu durumda Denklem (32) ve Denklem (34)'deki ileri ve geri geçiş önem ağırlıkları aşağıdaki gibi yazılır.

$$\omega_t^i = \omega_{t-1}^i \frac{P(\mathbf{E}_t | \mathbf{I}_t^i) P(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i)}{\pi(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i, \mathbf{E}_{1:t})} \quad (35)$$

$$\tilde{\omega}_t^i = \sum_{j=1}^N \tilde{\omega}_{t+1}^j \frac{\tilde{\omega}_t^i P(\mathbf{I}_{t+1}^j | \mathbf{I}_t^i)}{\sum_{l=1}^N \tilde{\omega}_t^l P(\mathbf{I}_{t+1}^l | \mathbf{I}_t^i)} \quad (36)$$

Denklem (35)'deki önem veya öneri fonksiyonu $\pi(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i, \mathbf{E}_{1:t})$ aşağıdaki biçimde seçilmiştir:

$$\pi(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i, \mathbf{E}_{1:t}) = \exp(-d\mathbf{E}^T \Sigma_\eta^{-1} d\mathbf{E} + \mathbf{m}^T \Sigma \mathbf{m}) \exp(-(\mathbf{I}_t^i - \mathbf{I}_{t-1}^i - \mathbf{m})^T \Sigma (\mathbf{I}_t^i - \mathbf{I}_{t-1}^i - \mathbf{m}))$$

buradaki ifadelerin açık biçimleri ise aşağıda verilmektedir:

$$\begin{aligned} \mathbf{I}_t^i &= \tilde{\mathbf{I}} + \mathbf{w} F(\mathbf{I}_{t-1}^i) \\ d\mathbf{E} &= \mathbf{E}_t - \mathbf{A} F(\mathbf{I}_t^i) \\ \Sigma &= F'(0)^T \mathbf{A}^T \Sigma_\eta^{-1} \mathbf{A} F'(0) + \Sigma_\varepsilon^{-1} \\ \mathbf{m} &= \Sigma^{-1} F'(0)^T \mathbf{A}^T \Sigma_\eta^{-1} d\mathbf{E} \end{aligned} \quad (37)$$

Transfer fonksiyonu F 'nin çizgisel fonksiyon olarak seçilmesi durumunda önem fonksiyonu $\pi(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i, \mathbf{E}_{1:t}) = P(\mathbf{E}_t | \mathbf{I}_t^i)P(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i)$ biçiminde olur.

- Bir önceki adımda EM yönteminden bulunan θ_{k_i} parametre kümesi kullanılarak test verisi olarak belirlenen EEG veri kümesi için ileri geçiş algoritması aracılığıyla saklı durumlar $\mathbf{x}_t = \{\tilde{\mathbf{k}}_t, \mathbf{I}_t\}$ üretilir. Bu adımda gerçek makro durumlar yerine önerisel makro durumlar $\hat{\mathbf{k}}_t^i$ kullanılmıştır. Bu durumda Denklem (32)'daki ileri geçiş önem ağırlıkları aşağıdaki biçimde hesaplanmıştır:

$$\omega_t^i = \omega_{t-1}^i \frac{P(\mathbf{E}_t | \mathbf{I}_t^i)P(\mathbf{I}_t^i | \mathbf{I}_{t-1}^i)}{\pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})} \mathbf{P}_{\hat{k}_t^i, \hat{k}_{t-1}^i} \quad (38)$$

- EEG sinyal kaynakları \mathbf{I}_t , üretilen saklı durumlar $\mathbf{x}_t^i = \{\tilde{\mathbf{k}}_t^i, \mathbf{I}_t^i\} \sim \pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})$ ve hesaplanan ileri geçiş önem ağırlıkları kullanılarak aşağıdaki biçimde hesaplanır:

$$\mathbf{I}_t = \sum_{i=1}^N \omega_t^i \mathbf{I}_t^i$$

- Bir önceki adımda hesaplanan EEG sinyal kaynakları \mathbf{I}_t ve EM yönteminden bulunan θ_{k_i} parametre kümesinin Denklem (20a)'da kullanılmasıyla matematiksel HMM'nin EEG verisi $\hat{\mathbf{E}}_t$ elde edilir.
- Matematiksel modelin gerçek EEG verilerini (\mathbf{E}_t) modelleyebilmesindeki başarı yüzdesi aşağıdaki açıklanan varyans R^2 kullanılarak bulunmuştur.

$$R^2 = 100 - \frac{100}{T} \frac{\sum_t (\hat{\mathbf{E}}_t - \mathbf{E}_t)^2}{\text{var}(\mathbf{E}_t)} \quad (39)$$

3.4.5 EEG BBA Zihinsel Durumların Tahmin Edilmesi

EEG-BCI sinyalindeki zihinsel durumların tahmin edilmesinde ise iki yöntem kullanılmıştır. Bunlardan bir tanesi **Tablo 5**'de verilen ileri geçiş algoritmasına göre üretilen saklı durumlar $\mathbf{x}_t^i = \{\tilde{\mathbf{k}}_t^i, \mathbf{I}_t^i\} \sim \pi(\mathbf{X}_t^i | \mathbf{X}_{t-1}^i, \mathbf{E}_{1:t})$ ve hesaplanan ileri geçiş önem ağırlıklarının kullanılması ile her bir t anındaki her bir makro durumun olasılığının

$$P(\tilde{\mathbf{k}}_t | \mathbf{E}_{1:t}) = \sum_{i=1}^N \omega_t^i \tilde{\mathbf{k}}_t^i \quad (40)$$

hesaplandığı ve her bir t anındaki en olası makro durum $\tilde{\mathbf{k}}_t$ 'yi bulmak için maksimum olasılıklı makro durumun seçildiği maksimum olabilirlik tahmin (Maximum Likelihood Estimation, MLE) yöntemidir. İkinci yöntem ise ileri-geri geçiş algoritmalarının kullanıldığı, ardışık zaman noktaları arasındaki zaman aralığının göz önüne alınarak makro durumların logaritmik olasılığı $\log P(\tilde{\mathbf{k}}_t | \mathbf{E}_{t:t+1})$ 'nin ilgili zaman aralığı üzerinden kesikli toplamının

$$\sum_t^{t+1} \log P(\tilde{\mathbf{k}}_t | \mathbf{E}_{t:t+1})$$

hesaplandığı ve her bir t anındaki en olası makro durum $\tilde{\mathbf{k}}_t$ 'yi bulmak için kesikli toplam sonucundaki en büyük logaritmik olasılığın seçildiği tümlemlenebilen maksimum olabilirlik tahmin (Integrated Maximum Likelihood Estimation, (IMLE)) yöntemidir. Bu yöntemde Denklem (38)'de verilen $\mathbf{P}_{\hat{\mathbf{k}}_t, \hat{\mathbf{k}}_{t-1}}$ geçiş olasılık matrisi, gerçek makro durumlardan yararlanılarak, t ve $t+1$ zamanlarındaki makro durumların aynı olması durumunda köşegen matris olarak, diğer durumlarda ise tüm makro durumlar arasında geçişin sağlanabileceği bir matris olarak yapılandırılmıştır.

EEG-BCI sinyalindeki zihinsel durumlara karşılık gelen makro durumların tahmin edilmesindeki hata oranlarını bulmak için MLE ve IMLE yöntemi kullanılarak bulunan makro durumlar $\tilde{\mathbf{k}}_t$ ile gerçek EEG-BCI verisinden bilinen \mathbf{k}_t karşılaştırılmıştır. Makro durumların tahmin edilmesindeki hata oranlarını iki farklı biçimde hesaplanmıştır. Birinci durum: tüm t zamanları için tahmin edilen makro durumlar ile gerçek makro durumların karşılaştırılması sonucunda elde edilen t -tabanlı hata oranları. İkinci durum: zihinsel durumun değiştiği andaki zaman noktaları için tahmin edilen makro durumlar ile gerçek makro durumların karşılaştırılması sonucunda elde edilen trial-tabanlı hata oranları.

4. BULGULAR VE TARTIŞMA

4.1 Yeni EEG BBA Veri Seti

EEG BBA'nın karşılaştığı başlıca engellerden biri, etkili veri işleme ve veri analiz yöntemleridir. Bu yönde bir ilerleme kaydedilmesindeki önemli engel, üniform, geniş, erişilebilir EEG BBA veri tabanları bulunmamasıdır. Farklı araştırmacıların önemli sayıda EEG BBA veri kümesi Internet'te bulunabilirken, bu tür veri setlerinin birçoğu, kısa, az sayıda katılımcıyı kapsayan veya az sayıda BBA sinyaline odaklanan EEG BBA kayıtlarını içermektedir. Örneğin, BBA Competition IV veri seti EEG BBA veri işleme literatüründe en çok kullanılan kaynaklardan biridir. Bu kaynak, ikisi senkron ve diğeri asenkron BBA için olan 3 EEG BBA veri kümesini içermektedir. Katılımcı başına yaklaşık 1 saatlik EEG BBA kayıtları

ve 576 görüntü trial'leri ile birlikte toplamda 9 katılımcı içerilmektedir. Ayrıca ya 2 (sol-sağ motor el görüntüleri (MI)) ya da 4 (değişken MI) durumlu BBA etkileşim paradigmaları kullanılmıştır. www.brainsignals.de veya bnci-horizon2020.eu'da bulunabilecek diğer EEG BBA veri setleri benzer kısıtlamaları paylaşmaktadır. Kapsamlı halka açık EEG BBA veri kümelerinin olmaması, EEG BBA için yeni veri analizi yöntemlerinin geliştirilmesinde önemli bir engeldir. Cho ve arkadaşları (Cho vd., 2017), sadece sol-sağ el MI etkileşim paradigmalı, 52 katılımcılı fakat katılımcı başına 36 dakika (toplam 32 saat) ve 240 EEG görüntü örneği (toplam 12,480) içeren halka açık yayınlanan en büyük EEG BBA veri setini tanıtmışlardır.

Bu çalışmanın deneysel programı sırasında toplanan 60 saatlik EEG BCI kayıtlarını, 13 katılımcı, 75 deney, 4 BBA etkileşim paradigması ve 60.000 bireysel zihinsel görüntü içeren yeni bir EEG BBA veri setini topladık ve halka açık bir biçimde ürettik ve Nature Scientific Data'ya yayınlamaya sunduk. 6'ya kadar zihinsel imge durumlarını içeren BBA etkileşimleri göz önüne alınmıştır. Ortalama olarak, katılımcı başına 4.8 saat EEG kaydı ve 4600 zihinsel görüntü örneği mevcuttur. Bu veri seti şimdiye kadar yayınlanmış en büyük EEG BBA veri setlerinden biridir ve tekdüzelik, boylamsal ve lateral kapsam. ve etkileşimlerin karmaşıklığı açısından mevcut veri kümelerinden önemli bir adım sunar.

Deneyler, 4 farklı iletişim modeline göre tasarlanmıştır: Birincisi - senkron sağ/sol el hareket 3 durumlu iletişim modeli (CLA), ikincisi – genişletilmiş senkron motor hareket 6 durumlu iletişim modeli (HaLT), üçüncüsü – asenkron sağ/sol el hareket 2 durumlu iletişim modeli (FREEFORM), ve dördüncüsü – senkron sağ el parmak hareket 5 durumlu iletişim modeli (5F).

CLA deneylerinde ortalama ERP eğrilerine göre tipik olarak sağ, sol ve pasif olaylar C3 ve C4 elektrotlarının üzerinde iyi ayrılabilirdi. Sol hareket için C3 ve C4 elektrodun asimetri sinyali uyarıcı geldikten sonra yaklaşık olarak 200-500 milisaniyede pozitif olup, sağ hareket için aynı sinyal negatif oluyordu. Asıl asimetri sinyalinin BMA durumuna göre değişimi katılımcıdan katılımcıya 4 mikrovolt'tan 7 mikrovolt'a kadar değişebiliyordu. Bazı katılımcılar için şu asimetri sinyal sadece bir elin hareketi için görülebilmştir, diğer elin hareketinde bir sinyal görülememiştir. Bunun nedeni tam olarak bilinmemektedir. Pasif durum olduğunda C3 ve C4 elektrotları karmaşık bir dalga gösteriyordu, fakat pasif durum Fp1 ve Fp2 gibi diğer elektrotlardan da algılanabilmiştir.

İlgili sağ/sol el hareketinin EEG sinyalinin genlik olarak 4-7 mikrovolt olması ile birlikte, olaydan olaya tipik olarak görülen doğal EEG sinyalinin değişikliği 4-8 mikrovolta gözlemlenmiştir. Buradan "beynin gürültüsü" nedeniyle sağ/sol el hareketinin EEG sinyalinin algılanmasının zor olması anlaşılmaktadır. Genel istatistiksel faktörlerden, bu durumda

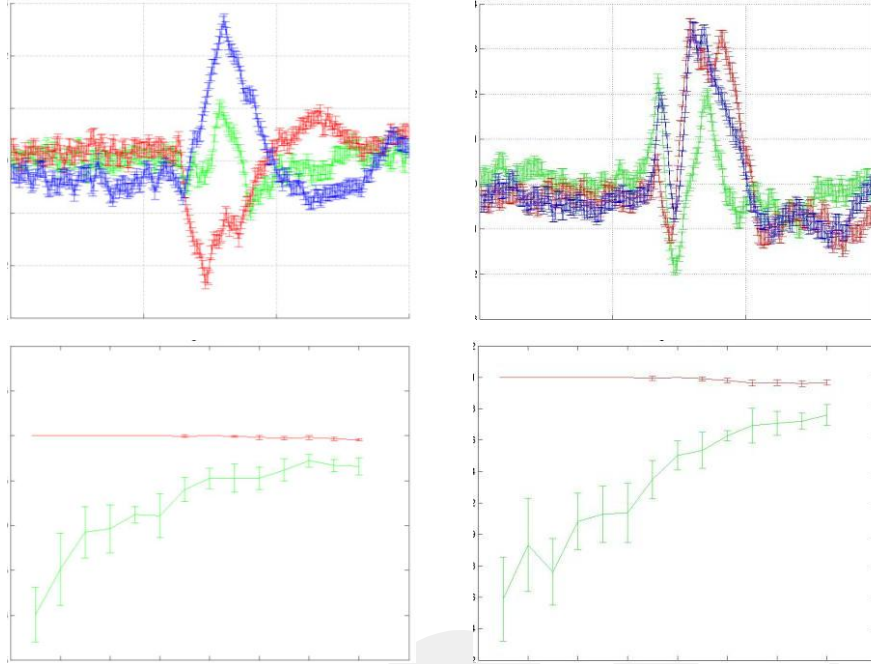
sağ/sol el hareketi ERP'lerinin algılanma doğruluğu %75-85 civarında olması beklenebilmektedir. Deneylerimizde uyguladığımız ve yukarıda tartışılan makine öğrenme yöntemleri kullanıldığında ERP ayrılma doğruluğu ortalama olarak %80-90 aralığında elde edildi ve bazı katılımcılar için %90-%95'e ulaşmıştır (aşağıdaki tablolar).

Asenkron Sağ/Sol El Hareket deneylerimizde (FREEFORM) sadece iki katılımcının katılımıyla 4 tane deney gerçekleştirilmiştir. Bu deneylerde serbest yapılan sağ/sol el hareketi ile ilgili veriler toplanmıştır. Söz konusu deneyler katılımcılara en az 1 sefer yaptırılmıştır. Deney yaklaşık olarak bir saat sürerken 300-400 sağ ve sol el hareketinin ERP örneği toplanmıştır. Bu deneylere katılımcılarımız, üç tane senkron Sağ/Sol El Hareket deneyi yaptıktan sonra katılmıştır.

Gerçekleştirilen deneylerimizde hesaplanan ortalama ERP eğrilerine göre, tipik olarak serbest el hareket olayları yine de C3 ve C4 elektrotlarının üzerinde ayrılmıştır. Bu durumda asimetri sinyal tuşa basmadan 250 milisaniye önce gözlenebilmiştir. Benzer şekilde sağ ve sol el hareketleri negatif ve pozitif olup, C3 ve C4 elektrottaki asimetri sinyalin farkı 2-4 mikrovolta varmıştır. Asenkron Sağ/Sol El Hareket deneylerimizin şu anki sonuçları aşağıdaki tabloda gösterilmiştir.

Bu sonuçlardan görebildiğimiz bir bulgu, sağ ve sol hareketlerle ilgili EEG sinyelindeki değişikliklerin bir tek beynin motor bölgesinde sınırlı olmaması. Hareket öncesinde büyük EEG sinyalleri F4 ve P4 frontal ve parietal bölgelerinde de gözlenebilmekteydi, ayrıca hareketin sonrasında beynin bölgelerindeki EEG sinyalinde aktif tepki görülebilmştir. Bu durum ayrıca aşağıda tartışılacak senkron Sağ El Beş Parmak Hareket Modelinde (5F) de görülebilmektedir.

Senkron sağ el beş parmak deneylerimizde (5F), beyindeki sağ elin ayrı parmaklarının hareketleri için motor ERP verileri toplanmıştır. İlgili deney özellikle yoğunlaştırılmış elektrot düzenleri için tasarlanmıştır. Motor korteksi açısından bir elin tüm parmakları aynı beynin bölgesinden yürütülür. Dolayısıyla sağ-sol asimetri gibi basit beynin elektroensefalografik aktivite ölçümleri parmak hareketlerini ayırmak için kullanılamaz. Aynı zamanda bu deneysel model BMA/BBA için daha çok sinyalleme kanalı sağlar ve katılımcılar tarafından parmak hareketlerini uygulamak daha doğal ve kolaydır.



Şekil 8. Sağ el, sol el ve pasif zihinsel durumların C3-C4 (sol) ve Fp1-Fp2 (sağ) elektrotların üzerindeki ERP ayırımı (üst satır) ve DVM algoritmanın eğitim doğruluk eğrileri (alt satır). Mavi ve kırmızı eğri sağ ve sol el ERP, yeşil ise pasif durum ERP göstermektedir

Tablo 7.FREEFORM'daki sağ-sol el hareketlerinin EEG verilerden tespiti.

Katılımcı	C3/C4 sinyalinin farkı	Diğer EEG elektrotlarındaki farklılıklar
Katılımcı 2	± 1 mikrovolt hareketin 250 milisaniye önce	F4: 1 μV 'a varan farkı 250 ms hareketin öncesi; P3: 0.5 μV 'a varan farkı 250 ms hareketin öncesi, 100 ms ve 300 ms sonrası; P4: 1 μV 'a varan farkı 250 ms hareketin öncesi, 0-500 ms sonrası; O2: 1 μV 'a varan farkı 250 ms hareketin öncesi, 2-3 μV 'a varan farkı 200-400 ms sonrası; T3: 0.5 μV 'a varan farkı 250 ms hareketin öncesi; T4: 1.5 μV 'a varan farkı 200-500 ms hareketin sonrası; T6: 4 μV 'a varan farkı 200-400 ms hareketin sonrası; Cz: 2.5 μV 'a varan farkı 200-300 ms hareketin sonrası; Pz: 1 μV 'a varan farkı 250 ms hareketin öncesi;
Katılımcı 4	± 2 mikrovolt hareketin 250 milisaniye önce	F3: 1 μV 'a varan farkı 250 ms hareketin öncesi; F4: 1 μV 'a varan farkı 250 ms hareketin öncesi; P3: 1 μV 'a varan farkı 100 ms hareketin öncesi, 300 ms sonrası; P4: 1 μV 'a varan farkı 100 ms hareketin öncesi, 200-400 ms sonrası; O2: 3 μV 'a varan farkı 200-300 ms hareketin sonrası; F7: 2 μV 'a varan farkı 200-300 ms hareketin sonrası; T3: 2 μV 'a varan farkı 200-300 ms hareketin öncesi; T4: 2 μV 'a varan farkı 200-500 ms hareketin sonrası; T5: 3 μV 'a varan farkı 200-400 ms hareketin sonrası; Cz: 1 μV 'a varan farkı 200-300 ms hareketin sonrası;

Söz konusu deneysel modelde bir katılımcımız deneylere en az 2 defa katıldı. İlk kez Sağ El Beş Parmak Hareket deneyinde EEG elektrotları standard 10/20 sistemine göre uygulandı. Bu durumda bir elin parmakları için en önemli kafanın bölgeleri ve EEG elektrotları belirlenmiştir. İkinci kez Sağ El Beş Parmak Hareket deneyinde EEG elektrotları ilk deneyde seçilmiş kafanın bölgesi veya bölgelerine 1-2 cm adımlı karesel izgara şeklinde yoğunlaştırılmıştır. Bu şekilde EEG elektrot yoğunlaştıran bir düzen uygulanmıştır. Yerleştirilen elektrotlardan EEG verileri elde edilmiş, ayrıca tüm elektrotların pozisyonları ve elektrotlar arasındaki mesafeler özel olarak ölçülmüştür.

Senkron Sağ El Beş Parmak Hareket deneylerimizin yapısı olarak, bu deneyler yaklaşık olarak üç 15 dakikalık oturum artı iki 2 dakikalık aradan oluşmuş ve toplam 600 olayın gösterilmesine imkan sağlamıştır. Bu 600 olay denetlenecek beş parmağın hareketleri arasında eş şekilde paylaşılmıştır. Bu şekilde bir parmağın hareketi başına yaklaşık olarak 120 tane ERP örneği toplanmıştır.

Gerçekleştirilen senkron Sağ El Beş Parmak Hareket deneylerimizde bir elin parmaklarının hareketlerini ayıran EEG sinyallerinin, genellikle motor bölgelerinden gelmediği gözlenmiştir. Ayrıca bir elin parmaklarının hareketlerini ayıran EEG sinyal bölgelerinin katılımcıdan katılımcıya değiştiği gözlenmiştir. Örneğin bir katılımcı için beş parmak hareketleri hakkında en çok bilgi sağlayan kafa bölgesi, kafanın sol parietal bölgesiydi. Başka katılımcı için en çok bilgi sağlayan bölgeler, kafanın sağ frontal (F4 elektrodun etrafı) ve sağ parietal (P4 elektrodun etrafı) bölgeleri idi. Katılımcı 4 için en çok bilgi sağlayan bölgeler, kafanın sağ frontal (Fp2 ve F4 elektrodun etrafı) ve sol parietal (P3 ve O1 elektrodun etrafı) bölgelerdi.

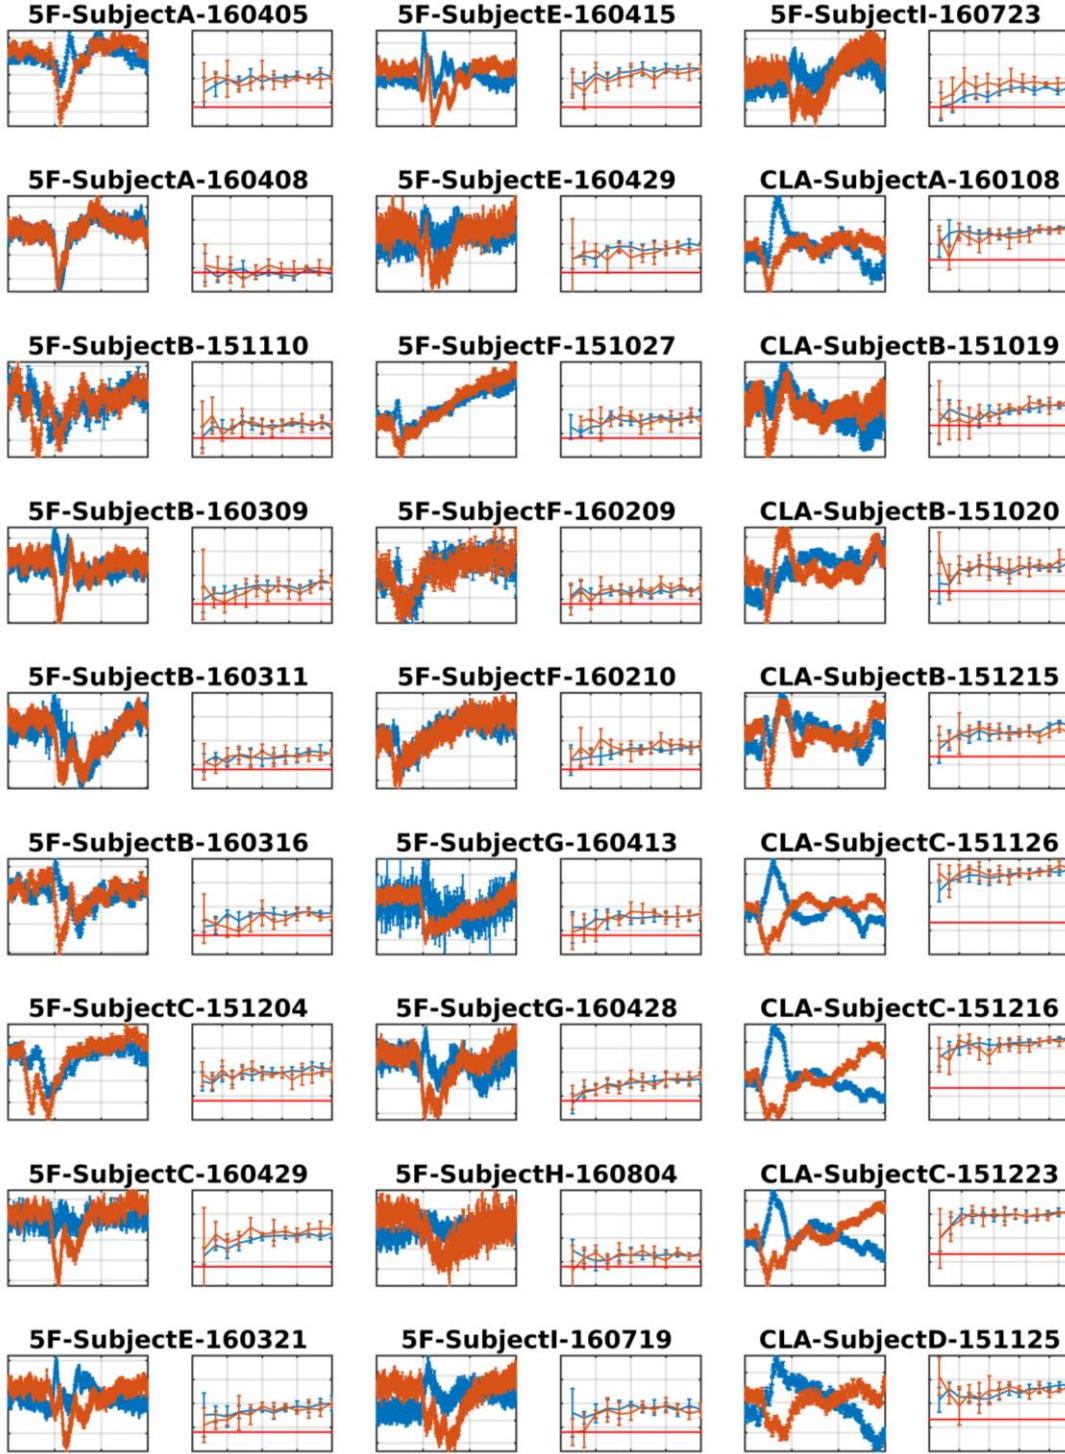
Tüm deneylerimizde, beş parmak hareketleri bu bölgelerdeki ortalama ERP dalgalarından tipik olarak iyi şekilde ayrılabilirdi. Bu şekilde beş parmaktan dört tanesi ayrılabilirken, yüzük ve serçe parmakları ortalama ERP dalgalarından genellikle ayrılamıyordu. Yüzük ve serçe parmakları ile ilgili ERP genellikle birbirine çok benzer şekilde elde ediliyordu.

Son deney türümüz olarak, online sanal robot manipülatör kontrolü deneylerimizde tarafımızdan geliştirilen Nihon Kohden EEG sistemi kullanan interaktif "online EEG BBA" uygulamamız kullanılmıştır. Bunların yapısı bu raporda daha önce açıklanmıştır. Katılımcılar, daha önceden belirlenen ve laboratuvar asistanı tarafından sözlü olarak verilen komutları BBA ve bilgisayar ekranında gösterilen sanal robot kolu kullanarak online interaktif şekilde uygulamaya çalışmışlardır. Online analiz prosedürü için önceden offline BBA veri analizlerimizde kullanılan Sağ/Sol El anahtar geçişli ve Sağ/Sol El Sağ/Sol Ayak Dil hareket kontrol modeli kullanılmıştır. Sağ/Sol El Sağ/Sol Ayak Dil hareket deney modelinde sanal


robotik manipülatörün sağa, sola, aşağı, yukarı, tut ve bırak hareketlerini kontrol etmek üzerine uygulamalar yapılmıştır.

Tüm bu şekilde toplanan veri 75 ayrı deney, 13 katılımcı, 60 saat EEG kaydı ve 225 BBA oturumu içermiştir. Bu veri, EEG BBA literatüründe şimdiye kadar ulaşılabilen en büyük EEG BBA veri setlerinden biridir. Bu veri seti aşağıdaki şekil ve tablolarla biçimde karakterize edilmektedir.

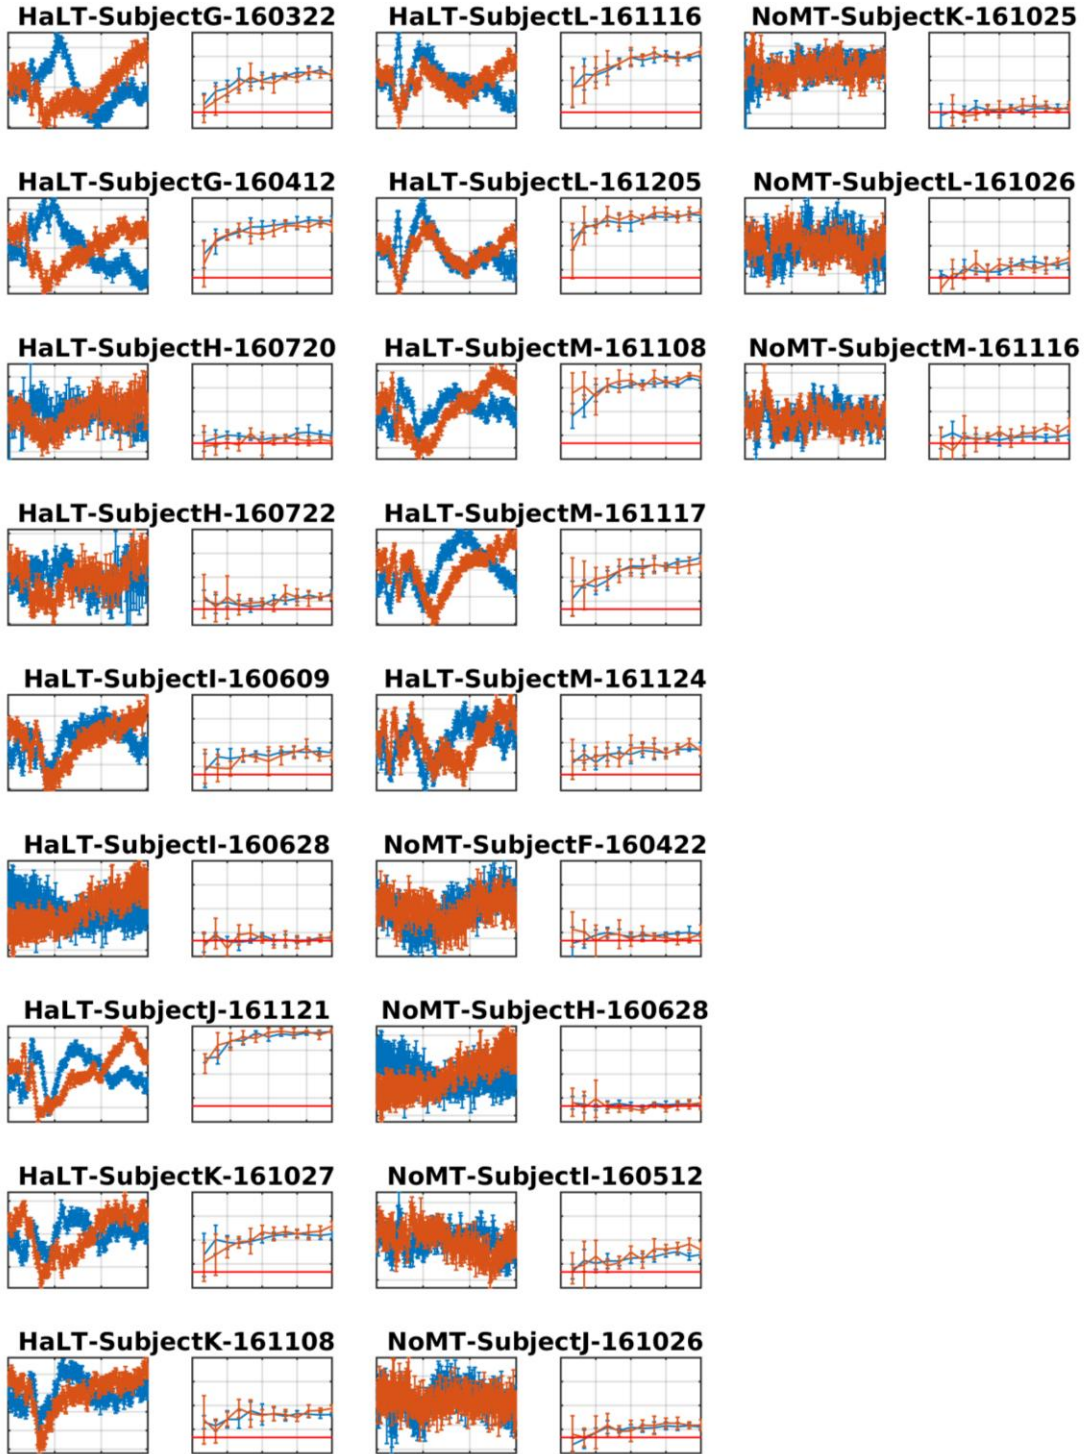
GCPRIS



Şekil 9. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar. 5F-SubjectA-160405 ile CLA-SubjectD-151125 arasındaki veri dosyaları gösterilmektedir.



Şekil 10. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar. CLA-SubjectE-151225 ile HaLT-SubjectG-160301 arasındaki veri dosyaları gösterilmektedir.



Şekil 11. C3 elektrotunda gözlemlenen kaydedilmiş farklı zihinsel imgelere karşılık gelen ERP eğrilerinin örnekleri ve veri setindeki tüm veri dosyaları için DVM tabanlı bir makine öğrenme sınıflandırıcısı tarafından bu tür zihinsel imgelerin sınıflandırılmasına ilişkin sonuçlar. HaLT-SubjectG-160322 ile NoMT-SubjectM-161116 arasındaki veri dosyaları gösterilmektedir.

Tablo 8. Deneylerde bulunan katılımcıların demografik ve deney bilgileri

Katılımcı	Cinsiyet	Yaş	Sağlık	BBA deneyim	BBA performans	Veri Dosyası
A	M	20-25	Healthy	None	Intermediate-High	5F-SubjectA-160405
						5F-SubjectA-160408
						CLA-SubjectA-160108
						HaLT-SubjectA-160223
						HaLT-SubjectA-160308
B	M	20-25	Healthy	None	Intermediate-Low	5F-SubjectB-151110
						5F-SubjectB-160309
						5F-SubjectB-160311
						5F-SubjectB-160316
						CLA-SubjectB-151019
						CLA-SubjectB-151020
						CLA-SubjectB-151215
						FREEFORM-SubjectB-151111
						HaLT-SubjectB-160218
						HaLT-SubjectB-160225
C	M	25-30	Healthy	None	Intermediate-High	5F-SubjectC-151204
						5F-SubjectC-160429
						CLA-SubjectC-151126
						CLA-SubjectC-151216
						CLA-SubjectC-151223
						FREEFORM-SubjectC-151208
						FREEFORM-SubjectC-151210
						HaLT-SubjectC-160224
						HaLT-SubjectC-160302
D	M	25-30	Healthy	None	Intermediate-Low	CLA-SubjectD-151125
E	F	20-25	Healthy	None	Intermediate-Low	5F-SubjectE-160321
						5F-SubjectE-160415
						5F-SubjectE-160429
						CLA-SubjectE-151225
						CLA-SubjectE-160119
						CLA-SubjectE-160122
						HaLT-SubjectE-160219
						HaLT-SubjectE-160226
HaLT-SubjectE-160304						
F	M	30-35	Healthy	None	Intermediate-Low	5F-SubjectF-151027
						5F-SubjectF-160209
						5F-SubjectF-160210
						CLA-SubjectF-150916

						CLA-SubjectF-150917
						CLA-SubjectF-150928
						HaLT-SubjectF-160202
						HaLT-SubjectF-160203
						HaLT-SubjectF-160204
						NoMT-SubjectF-160422
G	M	30-35	Healthy	None	Intermediate-High	5F-SubjectG-160413
						5F-SubjectG-160428
						HaLT-SubjectG-160301
						HaLT-SubjectG-160322
						HaLT-SubjectG-160412
H	M	20-25	Healthy	None	Low	5F-SubjectH-160804
						HaLT-SubjectH-160720
						HaLT-SubjectH-160722
						NoMT-SubjectH-160628
I	F	25-30	Healthy	None	Low	5F-SubjectI-160719
						5F-SubjectI-160723
						HaLT-SubjectI-160609
						HaLT-SubjectI-160628
						NoMT-SubjectI-160512
J	F	20-25	Healthy	None	High	CLA-SubjectJ-170504
						CLA-SubjectJ-170508
						CLA-SubjectJ-170510
						HaLT-SubjectJ-161121
						NoMT-SubjectJ-161026
K	M	20-25	Healthy	None	Intermediate-Low	HaLT-SubjectK-161027
						HaLT-SubjectK-161108
						NoMT-SubjectK-161025
L	F	20-25	Healthy	None	High	HaLT-SubjectL-161116
						HaLT-SubjectL-161205
						NoMT-SubjectL-161026
M	F	20-25	Healthy	None	Intermediate-High	HaLT-SubjectM-161108
						HaLT-SubjectM-161117
						HaLT-SubjectM-161124
						NoMT-SubjectM-161116

Tablo 9. Deneysel veri setimizin BBA iletişim modellerine göre bölümü ve bazı istatistikler

Model	Veri	Orta	Std	Model	Veri	Orta	Std
5F	5F-SubjectA-160405	43%	10%	FREEFORM	FREEFORM-SubjectB-151111	57%	20%
	5F-SubjectA-160408				FREEFORM-SubjectC-151208		
	5F-SubjectB-151110				FREEFORM-SubjectC-151210		
	5F-SubjectB-160309			HaLT	HaLT-SubjectA-160223		
	5F-SubjectB-160311				HaLT-SubjectA-160308		
	5F-SubjectB-160316				HaLT-SubjectA-160310		
	5F-SubjectC-151204				HaLT-SubjectB-160218		
	5F-SubjectC-160429				HaLT-SubjectB-160225		
	5F-SubjectE-160321				HaLT-SubjectB-160229		
	5F-SubjectE-160415				HaLT-SubjectC-160224		
	5F-SubjectE-160429				HaLT-SubjectC-160302		
	5F-SubjectF-151027				HaLT-SubjectE-160219		
	5F-SubjectF-160209				HaLT-SubjectE-160226		
	5F-SubjectF-160210				HaLT-SubjectE-160304		
	5F-SubjectG-160413				HaLT-SubjectF-160202		
	5F-SubjectG-160428				HaLT-SubjectF-160203		
	5F-SubjectH-160804				HaLT-SubjectF-160204		
	5F-SubjectI-160719				HaLT-SubjectG-160301		
	5F-SubjectI-160723				HaLT-SubjectG-160322		
	CLA				CLA-SubjectA-160108		
CLA-SubjectB-151019		HaLT-SubjectH-160720					
CLA-SubjectB-151020		HaLT-SubjectH-160722					
CLA-SubjectB-151215		HaLT-SubjectI-160609					
CLA-SubjectC-151126		HaLT-SubjectI-160628					
CLA-SubjectC-151216		HaLT-SubjectJ-161121					
CLA-SubjectC-151223		HaLT-SubjectK-161027					
CLA-SubjectD-151125		HaLT-SubjectK-161108					
CLA-SubjectE-151225		HaLT-SubjectL-161116					
CLA-SubjectE-160119		HaLT-SubjectL-161205					
CLA-SubjectE-160122		HaLT-SubjectM-161108					
CLA-SubjectF-150916		HaLT-SubjectM-161117					
CLA-SubjectF-150917		HaLT-SubjectM-161124					

CLA-SubjectF-150928	CLA-SubjectJ-170504	CLA-SubjectJ-170508	CLA-SubjectJ-170510	NoMT	NoMT-SubjectF-160422		
					NoMT-SubjectH-160628		
					NoMT-SubjectI-160512		
					NoMT-SubjectJ-161026		
NoMT-SubjectK-161025							
NoMT-SubjectL-161026							
NoMT-SubjectM-161116							

Tablo 10. Toplanan verilerde DVM kullanılarak tipik zihinsel durum ayırma kalitesi ve ilgili istatistikler

Model	Katılımcılar üzerinde ortalama doğruluk	Katılımcıya bağlı STD	Katılımcı sayısı	Deney sayısı
5F	43%	10%	8	19
CLA	75%	10%	7	17
HaLT	57%	20%	12	29

Tablo 11. Toplanan veri setinde kullanılan etiketler ve kısaltmalar

Kısaltmalar	Anlamları	Açıklama
CLA	Classical left/right hand MI (klasik sol/sağ el MI)	Paradigma#1
HaLT	Hand/Leg/Tongue MI (El/Bacak/Dil MI)	Paradigma#2
FREEFORM	Free style left/right hand MI (Serbest stil sol/sağ el MI)	Paradigma#3
5F	Five fingers MI (Beş parmak MI)	Paradigma#4
NoMT	No imagery, visual stimuli only (İmge yok, sadece görsel uyarılar)	Paradigma#5
SGLHand	Single Hand (Tek EL)	Parmakların motor görüntüleri için tek elle gerçekleştirilen 5F paradigma deneyleri
HFreq	High Frequency (Yüksek Frekans)	Deneyler, 200 Hz örnekleme hızında kaydedilen deneylerin aksine EEG 1200'de 1000 Hz örnekleme hızı ayarında kaydedilmiştir.
Tong	Tongue (Dil)	Dil MI'yi içeren deneyleri tanımlar
St	State (Durum)	Deneyde mevcut zihinsel görüntülerin toplam sayısını belirtir
Inter	Interface (Arayüz)	Daha düşük bir sinyal çözünürlüğü (0.133 μ V vs. 0.01 μ V) ve (121 μ V vs. 2mV) dinamik aralığına sahip diğer deneylerden farklı olarak İnteraktif Kullanıcı Arayüzü kullanılarak gerçekleştirilen deneyleri belirtir.
LRHand	Left/Right Hand (Sol/Sağ El)	Sol ve sağ el MI hareketleri için deneyleri belirtir
LRHandLeg Tongue	Left/Right Hand, Leg and Tongue (Sol/Sağ El, Bacak ve Dil)	Sol ve sağ el, sol ve sağ bacak ve dil MI hareketleri için odaklanan deneyleri gösterir

4.2 EEG BBA Sinyal ve Veri İşleme Yazılım Altyapısı

Projemizin içerisinde EEG BBA uygulamalarımızdaki EEG veri analiz ve BBA veri işleme için özel ve orijinal Matlab yazılım paketi geliştirilmiştir.

Söz konusu yazılım paketi kapsamında aşağıdaki temel problemler çözülmüştür: Nihon Kohden EEG sisteminin verilerinin Matlab'a yüklenmesi ve Matlab'ta bir standard formata kaydedilmesi; elde edilen Nihon Kohden EEG sisteminin EEG verilerinin temel analizi ve olaya ilişkin potansiyellerinin (Event Related Potential, ERP) hesaplanması, analizi ve gösterimi; EEG BMA/BBA uygulamalarında kullanılacak ERP olaylarının özniteliklerinin hesaplanması; EEG BMA/BBA uygulamalarında kullanılacak makine öğrenme yöntemlerinin uygulanması; EEG BMA/BBA uygulamalarında kullanılabilir ERP özniteliklerinin ön-değerlendirme, ranklama ve seçimi yöntemlerinin uygulanması.

Yukarıdaki kapsamda ilk olarak, Nihon Kohden EEG cihazından veri elde etme işlemindeki senkronize sorununu çözerek, Nihon Kohden EEG cihazından veri elde edilmesi sağlanmıştır. Bunu yapabilmek için ilk olarak Nihon Kohden cihazının EEG verileri, Nihon Kohden cihazında özel olarak çalışan "Neurofax" yazılımından kendi formatında export edildi. Daha sonra bu formatı Matlab'a indirmek için, yazılım paketimizde "nimport.m" biçiminde bir program uyguladık. İlgili program, Neurofax'ın EEG verilerini ve deney protokolü ile ilgili arayüzümüzün kayıtlarını okuyup belirttiğimiz bir Matlab formatına kaydetmiştir. Kendi veri formatımızda, EEG BMA/BBA deneylerinin verileri bir Matlab nesnesi olarak kaydedilmiştir. Bu nesneye deneyin bir özel alfasayısal kodu, açıklayıcı metin, Nihon Kohden cihazından ham EEG verileri, deney arayüzümüzün tarihçe verileri ve EEG veri örnekleme frekansı, örnek sayısı, kanallarının isimleri, voltaj birimi gibi destekleyici bilgiler dahildir.


Tablo 12. Yazılımımız tarafından toplanan EEG BBA verilerinin Matlab'taki formatı

Veri Kayıt Değişkenleri	
id	Kaydın özel bir alfasayısal tanımlayıcısı
nS	Kayıttaki EEG veri örneklerinin sayısı
sampFreq	Kayıttaki EEG verilerinin örnekleme frekansı
marker	Deneyin etkileşim kaydı
data	Deneyin ham EEG verileri

Online BBA deneylerimiz için ayrı olarak, Neurofax yazılımla iletişime geçip gerçek zamanlı veri ortaya çıkartan bir C# driver yazılımı ve onunla haberleşen Matlab arayüzü tarafımızdan geliştirildi. Söz konusu yazılım, gerçek zamanlı sanal robot kolun kontrolünü online BBA kullanılarak sağlayan uygulamamızın bir entegre parçası olmuştur.

İkinci olarak, toplanan verilerde ERP ile ilgili temel analiz işlemleri uygulanmıştır. Yazılım paketimizde, "analysis" kısmında ham EEG verilerinden olaya ilişkin potansiyellerinin

oluşturulması, ortalama ERP eğrilerinin hesaplanması, gösterilmesi ve kaydedilmesi, ERP'lerinin olaydan olaya değişiminin değerlendirilmesi ve grafiksel gösterimi ile ilgili işlemleri yapan Matlab programları geliştirilmiştir. Ayrıca, EEG sinyalinin spektrogram gösterimlerini hesaplamak için ayrı analiz programları uygulanmıştır. Deneylerimizde bu şekilde elde edilen bazı ölçümlerin örnekleri aşağıdaki **Şekil 12**'de gösterilmiştir.




Şekil 12. Geliştirdiğimiz yazılım yardımıyla elde edilen ortalama ERP eğrilerin ve ERP eğrilerin dağılım hesaplamalarının bazı örnekleri. ERP eğrileri sağ-sol el-pasif durumları için C3-C4 EEG elektrotlarında (sol) ve Cz EEG elektrotunda (merkez) gösterilmektedir. Eylem uyarma sinyali 500 milisaniye noktasında bulunmaktadır. Sağda, sağ el hareketlerine cevaben gelişen C3 elektrotundan izlenen olaya ilişkin potansiyellerinin dağılım haritası. Burada X eksenini zaman, Y eksenini EEG voltajıdır. Eylem uyarıcısı $t=500$ milisaniyede yer almaktadır. Olaydan olaya değişen ERP'nin tipik sapmasının büyük olması görülebilir.

Üçüncü olarak, EEG ham verileri kullanılarak genel BMA/BBA durumlarının ayrılmasında kullanılabilecek öznelik hesaplama yazılım geliştirilmiştir. İlgili program, EEG ham verileri için hem literatürde kullanılan EEG sinyalinin bant güçlerini ve güç dağılımını (Power Spectrum Distribution, PSD), hem de geliştirdiğimiz faz-eşleşmiş EEG sinyalinin karmaşık Fourier genlik özneliklerini (FTA) hesapladı.

Dördüncü olarak, EEG BMA'lerinde durum ayrılması için makine öğrenme yöntemlerine dayalı yazılım paketimizin "learning" kısmında kendi kendine öğrenen sinyal çözücü için öğrenme ve uygulama yazılımları geliştirildi. Söz konusu programları, ilgili Makine öğrenme sınıflandırıcıları oluşturmak için, yazılımın öznelik hesaplama kısmında hesaplanan EEG sinyalinin özneliklerinin bir alt kümesini seçer ve bu öznelikleri kullanarak EEG verilerinde belirli BMA durumunu bir makine öğrenme yaklaşımı kullanılarak ortaya çıkartır. Eğitilmiş sınıflandırıcıların performansı, çarpaz doğrulama yöntemi kullanılarak değerlendirildi. Bunun için ilgili programımız, genel EEG BMA makine öğrenme yöntemi için bir deney kümesinin EEG veri kümesi kullanılarak "eğitim eğrileri" (Learning Curves) oluşturdu. Eğitim eğrileri, eğitimde kullanılan örnek sayısına göre sınıflandırıcının performansını gösterir ve bu şekilde eğitiminin başarılı olup olmadığı, daha çok örneklere ihtiyaç olup olmadığı ve sonuçta

beklenebilir performansını tahmin etmek için kullanılabilir. Deneylerimizde bu şekilde elde edilen baze sonuçları aşağıdaki **Şekil 13**'de gösterilmiştir.



Şekil 13. Geliştirdiğimiz yazılım yardımıyla elde edilen EEG BBA dekodere eğitim eğrileri örnekleri gösterilmiştir. Burada x ekseninde eğitimde kullanılan zihinsel durum örnek sayısı, y ekseninde ise test veri setinde görülen zihinsel durum tespit doğruluğudur (yeşil eğri). Kırmızı eğri eğitim kümesinde görülen doğruluk. Eğitim kümesinde sağlanan doğruluk tahmini test kümesindeki doğruluktan her zaman yüksek ve çok sık 1'e yakındır. İdeal durumda, eğitim ve test kümesindeki doğruluklar birbirine yakın olup eğitimin yakınsamasını gösterir.


Beşinci olarak, EEG BMA uygulamasında kullanılacak öznitelik ön-değerlendirme, ranklama ve ön-seçimi yöntemleri uygulandı incelendi. Genel EEG BMA deneylerinde öznitelik sayısı tipik olarak deney sayısının çok fazlasıdır. Örneğin, birçoğu deneylerimizde tipik Fourier genlik özniteliklerinin sayısı 4,000'e varabilmektedir. Aynı zamanda tipik BMA/BBA durum örnek sayısı 300-500 civarındadır. Bu durumda tüm öznitelikler kullanılarak genel makine öğrenme sınıflandırıcıları verimli bir şekilde eğitilemez; örneğin bu şekilde eğitilmiş sınıflandırıcılar iki BMA durumu için durum algılama performansını %50'e yakın doğruluk oranı ile gösterirler. Genel makine öğrenme sınıflandırıcılarını verimli şekilde eğitebilmek için, eğitime girecek öznitelik sayısının en azından olay sayısının civarında olması gerekmektedir.

Bu problemin üstesinden gelmek için ve tüm öznitelik kümesinden en etkili öznitelikleri seçebilmek için, yazılım paketimizde birkaç öznitelik ön-değerlendirme, ranklama ve filtreleme yöntemi uygulandı. Uygulanmış yöntemler arasında, literatürde kullanılan r^2 (hedef-öznitelik korelasyon) ranklanması, Kullback-Leibler (KL) uzaklığı ranklanması, bu çalışmada yeni incelenmiş olan ortak bilgi (mutual information) ranklanması ve EEG kanallarının devamlı artırılıp azaltılması yöntemleri bulunmaktadır. Ayrıca, frekans filtreleme gibi bazı temel öznitelik seçme yöntemleri de uygulanıp denetlenmiştir. İlgili yöntemlerinin teorisi bu raporun daha önceki bölümlerde tartışılmıştır.

Yukarıdaki ranklama yöntemlerine ek olarak, ekle-bir-kanal ve çıkart-bir-kanal iki EEG kanal seçme yöntemleri uygulanmıştır. Bu yöntemlerin varsayışı, bazı EEG kanallarının BMA/BBA durumunun sınıflandırılması için daha çok önemli olmasıdır. Buna göre bu algoritmalar, ayrı öznitelikleri değil BMA/BBA için önemli olan EEG kanallarını seçmeye çalışıyor. Bu yöntemler, başka bir öznitelik ranklama yöntemi ile birlikte kullanılabilir.

Ekle-bir yönteminde, EEG kanalları öznitelik kümesine birer birer eklenir. Algoritmanın her adımında, daha önce eklenmiş kanallara göre her bir yeni kanal için sınıflandırıcı doğrudan eğitilmiş olarak denetleniyor. Bu şekilde her adımda, en yüksek performans artışını sağlayacak EEG kanalı öznitelik kümesine ekleniyor. Böylece EEG kanalları, ERP sınıflandırıcısının performans önemine göre sıralanmış oluyor, aynı zamanda kanal sayısına göre sınıflandırıcısının performans eğrisi elde ediliyor. Belirli performansı sağlayacak asgari EEG kanal sayısı bu eğriden sonra da seçilebiliyor.

Çıkart-bir yönteminde benzer şekilde, tüm EEG kanalları ile başlayıp EEG kanalları öznitelik kümesinden birer birer çıkartılıyor. Sınıflandırıcısının performansını doğrudan hesaplayarak, bu performansı en az etkileyecek EEG kanalını her adımda kaldırıyoruz. Bu şekilde EEG kanallarının ranklanması ve performans eğrisi de elde ediliyor.



Şekil 14. Geliştirdiğimiz yazılım yardımıyla elde edilen öznitelik önem ölçüm örnekleri. Soldan sağa gösterilenler korelasyon katsayısının karesi, Kullback-Leibler uzaklığı, ve ortak bilgidir. Farklı ölçümlerin genel olarak benzer olmasıyla birlikte farklı öznitelik önem ölçümleri biraz farklı öznitelikler seçer.


Yukarıdaki tüm geliştirilmiş öznitelik ön-değerlendirme ve ranklama yöntemleri, EEG verilerimizden sağ/sol el hareketlerinin ayrılma işleminde denetlenmiştir. Özet olarak, r^2 , KL uzaklık ve Ortak Bilgi ranklama yöntemlerinin performansları bu veri kümesinde benzer olarak tahmin edilmiştir. Tüm bu yöntemlere göre 3,000-4,000 orijinal öznitelikten 50-100 en önemli öznitelik bırakılıyordu ve bu durum için en yüksek genel makine öğrenme BMA/BBA durum ayrılma performansı gösterilmiştir. Düşük frekans filtrelemesi, bezner performansı göstermiş olup tipik olarak öznitelik sayısı 2-3 kat daha büyüktü. Bununla beraber, bu deneylerimizde sağ/sol el hareketleri için BMA/BBA veri kümesinde en yüksek durum algılama performansı, kanal ekle-bir yöntemi ve düşük frekans filtreleme ile birlikte sağlanmıştır. Öznitelik ön-seçme ve ranklama için farklı yöntemlerde gördüğümüz BBA/BMA durum algılama performansları aşağıdaki tabloda gösterilmiştir.

Tablo 13. Öznitelik ön-seçimin EEG BBA performansına etkisi.


Öznitelik ön-seçme yöntemi	Hiç	r^2 , KL uzaklığı ve ortak bilgi ranklama	5Hz düşük frekans filtreleme	5Hz düşük frekans filtreleme ve kanal ekle-bir
Tipik ERP ayrılma doğruluğu	%55-60	%85-90	%85-90	%90-95
Tipik öznitelik sayısı	4000	50-100	200-250	100-150

4.3 EEG BBA Kullanılarak Kullanıcı Dikkat Durumu Tespit Etme Sistemi

Projemizin başka bir kısmında makine kullanıcılarının dalgınlık durumlarının, noninvaziv EEG BBA kullanılarak tespit edilebilmesi incelenmiştir. Gelişen teknoloji ile birlikte makine kullanıcıları üzerindeki kontrol yükünün azalması süreç içinde kullanıcıda dalgınlık problemleri oluşturur. Bu çalışmada, laboratuvarımızda mevcut olan edilmiş portatif Emotiv EPOC cihazı ve tarafımızda uygulandığı DVM veri analiz yöntemi kullanılmıştır (**Şekil 15**).



Şekil 15. EEG ve DVM tabanlı "operatör durum tespiti" BBA sisteminin çalışma diyagramı.



Şekil 16. Operatör durum tespiti BBA için elde edilen verilerin örneği. İki farklı EEG kanalı için (Fz ve Pz), katılımcı treni sürürken EEG sinyalinin spektrogramı gösterilmektedir. Spektrogramlarda, 0-10 dakikalarında aktiflik durumu, 10-20 dakikalarında dalgınlık durumu ve 20-35 dakikalarında uyumlu durumuna bağlı EEG sinyalindeki değişiklik açıkça gözlemlenebilmektedir.

Sürekli kontrol görevine katılan 5 katılımcının 25 saatlik EEG kayıtlarından oluşan orijinal bir veri kümesi toplanmış ve <http://yumishch.me/bci/attention-monitoring> yoluyla halka açık olarak yayınlanmıştır.

Bu veri seti, bir sanal trenin kontrolü için bilgisayar simülasyonunda görev alan makine kullanıcısının EEG durumunu gözlemlenmeyi içermektedir. Yani, her deney, bir kullanıcının treni özelliği olmayan bir rotada 35 ile 55 dakika boyunca kontrol etmesinden oluşmaktadır.

Kullanıcı, odaklanmış ancak pasif şekilde dikkatli, odaklanmamış veya ilişkisiz durum ve uyuşuk veya uykulu olmak üzere 3 zihinsel durumunu simüle etmiştir.

Birinci "odaklanmış" durum, görev üzerindeki yoğunlaşmanın sürekli olarak sürdürülüp trenin pasif olarak yönetilmesine karşılık gelmektedir. Görevlerin çoğu tren operasyonlarına aktif müdahale gerektirmiyordu. Yine de, kullanıcının sürekli olarak yoğunlaşması ve odaklanması gerekiyordu.

İkinci durum, katılımcının serbest, tren görevi ile ilişkisiz ancak uyanık olduğu durumdur. Katılımcılar uyutulmadılar ancak ekrandaki gelişmelere dikkat etmeyi bıraktılar ve dikkatli olmaktan vazgeçtiler. Bu riskli bir durum olarak yorumlanabilir. Riskli olabilir çünkü böyle durumlar, kontrol gözetleme veya video gözetleme aracılığıyla elde edilen harici gözlemlenebilir ipuçlarında doğrudan ortaya çıkmayabilir.

Üçüncü durum uykulu halin olduğu durumdur. İkinci durum önceleri literatürde dikkate alınmadan bırakılırken, uykulu durumun özellikleri literatürde daha önce yapılmış çalışmaların bir konusu olmuştur. Bu çalışmalarda, makine operatörlerinin yanı sıra bireylerin uykulu durumu, artmış alfa bandı EEG aktivitesiyle ilişkiliydi, Uykulu durumun EEG verilerinden algılanması, araba sürücülerinde veya yorgunluk izleme sistemlerinde uyuşukluk ya da yorgunluğun başlama anının belirlenmesi için bir yöntem olarak literatürde tartışılmıştır. İzleme sistemleri bağlamında uyuşukluk, bir videodaki göz kapaklarını izlemek veya EKG'de kalp atış hızını izlemek gibi EEG olmadan da tespit edilebilir.

Deneylerimizde, katılımcılar deneylerin başında yönetici tarafından kendilerine verilen talimatları takip ederek 3 zihinsel durumu simüle ettiler. Her bir tren sürme deneyinin ilk 10 dakikasında katılımcılar, simülatörün kontrollerine ve ekrandaki tüm gelişmelere dikkat ederek, odaklanmış kontrol durumuyla meşgul oldular. İkinci 10 dakika boyunca, katılımcılar simülatörü yakından takip etmeyi durdular ve onlardan odaklanmamaları talimatına uymaları istendi. Bu aşamada, katılımcılar kontrol girdileri sağlamadı ve bilgisayar ekranına dikkat etmeyi bıraktı; ancak, gözlerini kapatmalarına ve uyumalarına izin verilmedi. Deneyin üçüncü 10 dakikasında katılımcıların serbest bir biçimde rahatlamalarına, gözlerini kapatmalarına ve uykuya dalmalarına izin verildi. Tren kontrol simülasyon deneylerinin spesifik ayarları, trial'ler için seçilen "Acela Express" modern lokomotifli bir PC'deki "Microsoft Train" simulator programının kullanılmasını kapsamaktaydı. Yukarıda bahsedilen simülatörde düz ve özelliksiz olmasından dolayı 40 dakikalık "Amtrak-Philadelphia" rotası kullanılmıştır. Böylece katılımcıların daha yüksek iştiraklerine ihtiyaç duyulan rotanın ilk ve son 5 dakikalık bölümleri haricinde, simülasyonlara çok az girdi sağlama gerekiyordu. Kontroller, gaz ayarı (sürüş hızının kontrolü) ve fren uygulaması (çabuk bir yavaşlama üretmek için) içeriyordu.

Kontroller, standart bir bilgisayar klavyesindeki tuşlarla gerçekleştirildi. Katılımcılar, simülasyonda, yaklaşık 40 mph hızında sabit kaldılar; bu, deney ayarları ve artmış zihinsel yorgunluk faktörü için nispeten yavaştı.

Her katılımcı günde en fazla bir deney olmak üzere 7 deneyde yer aldı. İlk 2 deney katılımcılara alıştırmaya olması için son 5 deney ise veri toplamak için kullanıldı. Bütün deneyler, zihinsel yorgunluk faktörünü arttırmak için akşam 7 ve 9 saatleri arasında gerçekleştirildi. Katılımcılar, bir yönetici tarafından izlendi ve deneyler sırasındaki tüm zamanlarda bir videoya kaydedildi. Böylece deneyin yukarıda belirtilen yapıyı izlediğini ve deney sırasında katılımcıların hareket etmesi veya konuşması gibi önemli aksamaların oluşmadığından emin olunmuştur.

EEG verileri modifiye edilmiş Epc EEG kulaklık seti (Emotiv, San Francisco) kullanılarak toplanmıştır. Epc kulaklık, bir kablosuz Bluetooth bağlantısı üzerinden veri toplama bilgisayarına bağlanan, 128 Hz örnekleme hızında, 0.51 μ V gerilim çözünürlüğünde ve 0.2-43Hz bant genişliğinde 12 kanal gerçek zamanlı EEG verisi sağlayan portatif bir EEG toplama cihazıdır. Bu kulaklık, kafatası yüzeyinin frontal ve parietal lobları üzerindeki elektrotları değiştirmek için tarafımızdan modifiye edildi. Orijinal Epc aygıtı yalnızca frontal lob ve oksipital alanları kaplıyordu. Kullanılan elektrotların pozisyonları, standart 10-20 sisteminde F3-Fz-F4-C3-Cz-C4-T3-T4-T5-T6-Pz biçimindedir. Bunlardan T3, T4, T5 ve T6 konumlarıyla tanımlanan 4 kablo, Epc'daki akım ve referans elektrotlardı ve bu nedenle veriler için kullanılmadı. Böylece, F3, F4, Fz, C3, C4, Cz ve Pz ile tanımlanan 7 veri kanalı elde edildi. Ham EEG verileri, Epc yazılımının Araştırma Lisansı'ndaki Epc cihazının veri toplama API'si ile birlikte örnek program *eeglogger.m* temel alınarak geliştirilen özel bir Matlab komut dosyası kullanarak Epc cihazından doğrudan elde edildi.

Bu şekilde toplanan verilerin bireysel dikkat durumlarındaki değişiklikler, bazı frekanslarda ve EEG kanallarında değişiklikler olarak görülen EEG sinyalinin spektral güç dağılımındaki değişikliklerle ilişkiliydi, **Şekil 16**. Odaklı ve odaklanmamış durumların, frontal lobun F3, F4 ve Fz EEG elektrotlarındaki 1-10 Hz frekans bantlarında bulunan artmış ve baskılanmış EEG aktiviteleri ile ilişkili olduğu görülmüştür. Uykulu durum, C3, C4, Cz ve Pz EEG kanallarındaki 10-15 Hz alfa band frekansında bulunan kesintisiz veya kesintili güç çıkışları ile ilişkilendirilebilir. Yukarıda bahsedilenler, çeşitli EEG kanallarında gözlenen EEG verilerinin lokalize zamana bağlı spektrumuna bağlı olarak, odaklanmış, odaklanmamış ve uykulu durumların ayırt edilmelerine olanak sağladı.

EEG verilerinden yukarıda bahsedilen üç durumu otomatik olarak saptamak için bir yöntem oluşturduk. Kısacası, bu algoritma, gelen tüm veri kanallarından toplanan EEG verilerinin

zaman lokalize PSD gösterimine DVM sınıflandırıcısının uygulanmasını içeriyordu. **Tablo 14**, bu tür PSD özniteliklerinin bazılarını ve hedef durumlar ile bu tür özniteliklerin sınıf içi korelasyon katsayısına (ICC) göre organize edilen istatistiksel özelliklerini listeler. Küme içi korelasyon, yalın Pearson korelasyonu ile ilişkili, bir kesikli bağımlı değişken ile sürekli bir tahmin değişkeninin ilişkisinin istatistiksel bir ölçümüdür ve

$$ICC = \frac{\text{grup ortalamasının varyansı}}{\text{tüm varyans}}$$

ile tanımlanır. Farklı özniteliklerin çeşitli özelliklerini ve EEG sinyalinin karakterize eden kanal PSD özniteliklerini gösteren **Tablo 14** incelendiğinde, dikkat durumundaki değişikliklerle açıkça ilişkili olan, EEG sinyalindeki farklılıkların şu iki tipini ortaya koyar: özellikle parietal lob (C3, C4, Cz ve Pz elektrotları) üzerinden 8-13 Hz frekanslarındaki alfa band gücünde bir artış ve özellikle frontal lob (F3, F4 ve Fz elektrotları) üzerinden 1-4 Hz düşük delta ve teta band frekanslarında bir azalma.

Tablo 14. Hedef zihinsel durum değişkeni ile sınıf içi korelasyon katsayısına (ICC) dayalı 25 en önemli öznitelğin istatistiksel özellikleri.

Rank	Kanal	Frekans Hz	Ortalama düzey	STD	Odaklanmış ortalama	Dalgın ortalama	Uykulu ortalama	ICC
1	C3	12	7.3701	6.6015	3.0069	2.8568	15.258	0.77489
2	F3	12	7.3351	7.1219	2.6434	2.4826	15.817	0.76973
3	C4	12	7.0274	6.9183	2.5108	2.2899	15.251	0.76694
4	Cz	12	7.1504	6.9895	2.5024	2.4753	15.436	0.76248
5	F4	12	7.7564	6.9367	3.2259	3.0626	15.954	0.75787
6	C3	11.5	7.2411	6.4331	2.6736	3.2756	14.824	0.75544
7	C4	11.5	6.8756	6.5842	2.2998	2.7417	14.616	0.75063
8	F3	11.5	7.1857	6.7928	2.3314	3.0661	15.161	0.74986
9	Pz	12	5.6787	5.9377	2.0338	1.5049	12.627	0.74438
10	Fz	12	6.24	7.2337	1.4592	1.4907	14.709	0.7438
11	F4	11.5	7.5599	6.7017	2.8145	3.5413	15.348	0.73483
12	Cz	11.5	7.0045	6.7105	2.3403	2.8885	14.807	0.73479
13	Fz	11.5	6.1487	7.0016	1.181	2.1192	14.144	0.71065
14	Pz	11.5	5.866	6.0477	1.9401	2.0206	12.772	0.70766
15	C4	12.5	5.9152	6.233	1.9	1.9717	12.988	0.6987
16	F3	12.5	6.3208	6.3337	2.2655	2.2949	13.502	0.69763
17	C3	12.5	6.2436	5.8986	2.4349	2.5351	12.924	0.69603
...								
43	F4	3	10.72	3.4544	14.252	9.0921	9.0286	0.50204
44	F4	3.5	9.5554	3.2217	12.813	8.2334	7.8354	0.49144
45	F4	2.5	11.889	3.4799	15.402	10.138	10.323	0.49129
46	F4	4	8.86	3.049	11.921	7.5095	7.3397	0.48387
47	F4	4	8.1726	2.8992	11.054	6.8883	6.7534	0.47408
48	F4	2.5	11.351	3.2627	14.548	9.691	9.9839	0.46457
...								

Tablo 15, otomatik dikkat durum saptamasının doğruluğunu göstermektedir. Tüm katılımcılar için, gelişmiş yöntem, kullanıcıların dikkat durumlarını, şans seviyesi %33.3±2.5 iken %90-%95 doğruluk ile ayırabilmeyi başarmıştır. Zihinsel durum tespitini hem katılımcıya özel hem de ortak-katılımcı paradigmaları olarak test ettik, burada zihinsel durum algılama algoritması

her katılımcı için ya ayrı ayrı eğitildi ya da tüm katılımcıların tüm verilerini kullanarak tek bir "Genel" EEG dikkat durum detektörü oluşturuldu. **Tablo 16** bu araştırmanın sonuçlarını göstermektedir. Ayrı ayrı eğitilmiş dedektörlerin kullanılması durumunda belirgin bir şekilde daha yüksek algılama doğruluğuna ulaşılabileceğini görüyoruz. "Genel" dedektör için, dikkat durumlarını sadece %70-75 doğrulukla yani **Tablo 15**'teki değerlerin önemli ölçüde altında tespit ettik.

Tablo 15. Ayrı ayrı eğitilen makine öğrenme algoritmalarının kullanılması durumunda dikkat durumlarının tespit doğruluğu.

Katılımcı	Den.1	Den.2	Den.3	Den.4	Den.5	Ortalama
S1	98%	99%	93%	95%	97%	96.7%
S2	90%	87%	91%	90%	88%	89.7%
S3	88%	88%	88%	86%	91%	88.6%
S4	91%	95%	92%	96%	92%	93.5%
S5	90%	81%	93%	91%	93%	90.1%

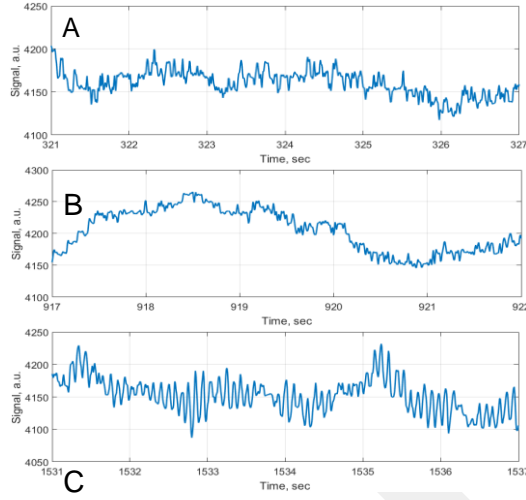
Tablo 16. "Genel" makine öğrenme algoritmasının kullanılması durumunda dikkat durumlarının tespit doğruluğu.

Katılımcı	Den.1	Den.2	Den.3	Den.4	Den.5	Ortalama
S1	75%	70%	71%	75%	68%	71.8%
S2	81%	72%	72%	74%	76%	75.0%
S3	82%	68%	76%	77%	72%	75.0%
S4	79%	80%	78%	79%	78%	78.8%
S5	76%	69%	74%	72%	73%	72.2%

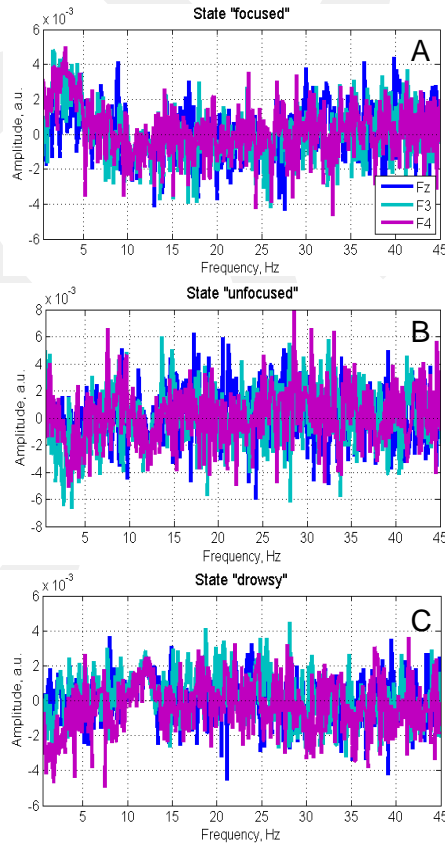
Ayrıca farklı kullanıcı dikkat durumlarının ayırt edilmesine katkıda bulunan EEG verilerinin öznitelikleri ile de ilgilendik. Bu özniteliklerin özelliklerinin anlaşılması, her bir dikkat durumu için elde edilen DVM sınıflandırıcısını karakterize eden ağırlık katsayıları vektörünün ağırlıkları tarafından sağlanmıştır. EEG özniteliklerinin frekansının bir fonksiyonu olarak DVM sınıflandırıcısının w ağırlık vektörlerinin tipik bir örneğini gösteren çizim, **Şekil 18**'de gösterilmiştir. Burada görülebileceği gibi, 1-5 Hz frekans aralıklarındaki yüksek EEG gücü "odaklanmış" dikkat durumunun artmış olasılığı ile ilişkili iken, 10-15 Hz frekans aralığındaki yüksek güç "uykulu" durumla ilişkilidir. "Odaksız" veya görev ile ilişkisi olmayan (serbest) zihinsel durumun belirteci, hem 1-5 Hz hem de 10-15 Hz frekanslarında EEG gücündeki azalma veya serbest zihinsel durumlar süresince tüm EEG spektrumun belirginliği idi. Bu gözlemler literatürde bulunan genel bulgulardır.

Son olarak, farklı zihinsel dikkat durumlarının ayrılmasına en çok hangi EEG kanallarının katkıda bulunduğu incelenmiştir. Bunun için, tüm elektrotlar eleninceye kadar tüm katılımcı ortalama dikkat durum tespit doğruluğu üzerindeki en az etkiye sahip elektrodun bir seferde veriden elendiği geriye doğru adım-adım eleme yöntemini (backward step-wise elimination) kullandık. Bu deneyin sonucu, elektrotların, dikkat durumların belirlenmesinde azalan önemleri bakımından sırasının F3-Fz-Cz-F4-Pz-C4-C3 olduğudur. F3, F4, Fz ve Cz olmak


üzere bu dört elektrot, dikkat durum ayırımı %85-%90 doğrulukla elde etmek için yeterlidir çünkü tüm elektrotlarla elde edilen sonuçlara yakındır, **Şekil 19**.



Şekil 17. Farklı zihinsel dikkat durumlarıyla ilişkili elektroensefalografik kayıtların örnekleri. A)'odaklanmış' durum için bir elektroensefalografik sinyal örneği. B) 'odaklanmamış' durum için bir elektroensefalografik sinyal örneği. C) "Uykulu" durum için bir elektroensefalografik sinyal örneği. Tüm elektroensefalogramlar bir katılımcı (S1) ve elektrot Pz içindir.



Şekil 18. EEG verilerinde farklı dikkat durumlarının tanımlanması için DVM tarafından oluşturulan ağırlık vektörleri w 'ye bir örnek. Odaklanmış (A), odaklanmamış (B) ve uyuşuk (C) dikkat durumlarına karşılık gelen katılımcı S1 ve en seçkin üç EEG kanalının F3, F4 ve Fz için ağırlık vektörleri gösterilmektedir.



Şekil 19. EEG veri setinde kullanılan EEG elektrotlarının sayısının bir fonksiyonu olarak zihinsel dikkat durumu saptamasının doğruluğu. Şekilde dikkat durumundaki değişiklikleri saptamaya yönelik önemleri ile ilişkili olarak elektrotların sırası, önem azalma sırasına göre F3-Fz-Cz-F4-Pz-C4-C3'tür. Dört elektrot F3, F4, Fz ve Cz, dikkat durumu hakkında en fazla bilgiyi sağlar ve birlikte %90'dan fazla maksimum tespit doğruluğu yakalayabilirler.

4.4 Motor Niyet Tabanlı Genel EEG BBA Uygulaması

Bu bölümde, proje kapsamında motor niyet tabanlı EEG BBA'nın geliştirilmesine yönelik çabayı ele alıyoruz. Bu çalışmaya, BBA ile iletişime girmek üzere farklı hareketlerin zihinsel görüntülerini (motor görüntüleri) kullanan 13 gönüllü katılmıştır. Bunlardan 1 katılımcı sadece 1 deneye katıldı ve aşağıdaki tartıştırmada dikkate alınmamıştır.

Zihinsel motor görüntü durumları çevrimdışı toplanan EEG verilerinde yazılımımız tarafından iyi bir doğrulukla ve şans seviyesini önemli ölçüde aşarak tespit edilmiştir. İletişim için kullanılan, sol ve sağ el hareketlerden oluşan iki motor görüntü durumunda, 12 katılımcının 6'sı (%50) EEG sinyalinden sol ve sağ hareket görüntülerinin ayrımını %95 üstünde doğrulukla gösterirken, 12 katılımcının 8'i (%67), iki hayali görüntünün ayrımını 90% seviyesinde veya üzerinde doğrulukla göstermiştir. 2 motor görüntü durum belirleme şans seviyesi, %50'nin biraz üzerinde olmaktadır. Sağlandığı performans tüm deneylerde sabit olmakla birlikte en iyi 6 birey sürekli olarak tüm deneylerde %90'dan daha iyi ayırım doğrulukları göstermekteydi. Aynı zamanda, 12 bireyden 2'si (% 17), bu iki motor görüntü üzerinde en iyi %70-80 doğruluk gösterdiğinden, bu iki birey için BBA'dan tatmin edici bir performans elde edilemedi. Projemizin bu aşamasında DVM ve LDA tabanlı makine öğrenme sinyal çözücülerini kullanılmıştır. Hem DVM hem de LDA tabanlı kod çözücüler benzer sonuçlar verdi, ancak DVM ortalama olarak LDA'dan %3-5 daha iyi performans sergiledi. Bu bulgular aşağıda **Tablo 17**'de özetlenmiştir. İki zihinsel imge durumlarının ayrımı, BCI ile ikili evet/hayır iletişimde ve benzer kararlarda kullanılabilir.

Tablo 17. Katılımcıların 2-durumlu EEG BBA ayırım görevindeki performansları.

Katılımcı	Performans DVM			Performans LDA			Deneysel sayı
	Ortalama	En kötü	En iyi	Ortalama	En kötü	En iyi	
BA	0.77	0.75	0.79	0.73	0.69	0.77	2
EM	0.96	0.93	1.00	0.95	0.92	0.97	3
ER	0.95	0.89	0.99	0.94	0.88	0.97	3
HI	0.98	0.96	0.99	0.94	0.88	0.98	5
ME	0.75	0.66	0.84	0.70	0.62	0.77	2
MR	0.88	0.74	0.92	0.79	0.73	0.86	5
SE	0.95	0.89	1.00	0.92	0.82	0.98	5
YU	0.91	0.78	0.93	0.84	0.72	0.92	5
EK	0.84	0.76	0.93	0.85	0.79	0.90	2
ES	0.99	0.98	0.99	0.98	0.97	0.99	2
UL	0.81	0.76	0.87	0.79	0.74	0.84	2
YL	0.98	0.98	0.98	0.97	0.96	0.97	2
Toplam	0.90	0.66	1.00	0.87	0.62	0.99	38

İkili EEG BBA, deneylerimizde yüksek verimlilikle uygulanabilirken, ikili iletişim paradigması, anlamlı kompleksliğe sahip robotik sistemlerin kontrolü için çok sınırlıdır. Bu nedenle, EEG BBA'da üçüncü zihinsel durumu ele alındı. 3. durum, sol-sağ ve ileri-geri hareketleri gibi bir robot manipülatör sisteminin farklı çalışma düzenleri arasında değişim yapmak için kullanılabilirken, orijinal iki zihinsel görüntü, manipülatörü mesela bu rejimlerin herbirinde iki yönde hareket ettirmek için de kullanılabilir. 'Pasif' zihinsel görüntü durumunu, 3. BBA iletişim durumu için bir aday olarak seçtik. Pasif durum, bu rol için doğal bir tercihtir, kullanıcı, çalışma düzenlerini değiştirip BBA ile iletişim kurmak için pasif kalmalı- yani hiçbir şey yapmamalıdır. Bu seçim diğer seçeneklere göre net olarak avantajlıdır, oysa BBA modları basitçe değiştirip hiçbir net eylem üretilmemiş olsaydı bile, kullanıcı, BBA'yı kullanmak için sürekli olarak aktif kalmaya zorlanacaktı.

EEG BBA'daki 3 zihinsel durum ayırımına ilişkin olarak, zihinsel görüntü ayırımını yüksek doğrulukla başardık. 12 katılımcının 5'i (%42) için 3 zihinsel durumun ayırımını %85'ten daha iyi doğrulukta elde ettik. En iyi 5 kişiden oluşan ikinci grup (%42) 70-80% oranında biraz daha kötü performans göstermektedir. 12 katılımcının 2'si (%16) ise bu durumları 40-60% doğrulukla tespit ederek tatmin edici bir performans elde edememiştir, **Tablo 18**.

Tablo 18. Katılımcıların 3-durumlu EEG BBA ayırım görevindeki performansları.

Katılımcı	Performans DVM			Performans LDA		
	Ortalama	En kötü	En iyi	Ortalama	En kötü	En iyi
BA	0.54	0.49	0.58	0.55	0.47	0.62
EM	0.85	0.80	0.89	0.82	0.81	0.83
ER	0.89	0.83	0.93	0.84	0.74	0.89
HI	0.89	0.86	0.95	0.90	0.85	0.95
ME	0.52	0.42	0.62	0.52	0.41	0.63
MR	0.70	0.59	0.82	0.67	0.55	0.77
SE	0.82	0.63	0.90	0.78	0.60	0.88
YU	0.76	0.71	0.83	0.74	0.68	0.79
EK	0.71	0.61	0.81	0.70	0.58	0.81
ES	0.98	0.96	0.99	0.97	0.95	0.97
UL	0.69	0.58	0.80	0.66	0.57	0.75
YL	0.90	0.89	0.91	0.88	0.87	0.88
Toplam	0.77	0.49	0.99	0.75	0.41	0.97

Ayrıca, EEG BBA kontrolü için 6'ya kadar farklı durumların kullanılması da projemizde değerlendirilmiştir. 6 durumlu bir BBA kullanıcılara açıkça daha zengin dinamikler sunar. Bu anlamda, her zihinsel imgenin, sol-sağ dönüşü, ileri-geri hareketi ve nesnelere yakalamak ve bırakmaktan oluşan 3 dof manipülatörün farklı bir hareketine eşlendiği BBA için bir kontrol modeli tasarlanabilir. Burada 6 durumlu BBA iletişim modeli için kullanılan durumlar, sol ve sağ el hareket görüntüleri, sol ve sağ bacak hareket görüntüleri, dil hareketi görüntüsü ve bir pasif görüntüdür.


Bu durumda da tüm deneylerimizde şansın üzerinde bir yüksek performans gözlemliyoruz. Bununla birlikte, hata oranları daha önemli hale geldi. Özellikle, yalnızca %17'lik taban çizgisi veya "şans" performansı ile karşılaştırıldığında 12 katılımcının en iyi 5 tanesi, bu BBA görevinde %75-90 doğruluk sergileyebildi, **Tablo 19**. Bu bireylerin performansı şansın çok üstündedir ve daha ileri araştırmalar için ilginç olabilirler. Aynı zamanda, diğer bireylerin performansı %50-60 doğruluk seviyelerine kadar önemli ölçüde düşmüştür. Hala şans seviyesinden önemli ölçüde yüksek olsa da, bu gibi hatalar EEG BBA iletişim paradigmasının pratik amaçlar için kullanılmasında ciddi engel teşkil etmektedir: 6 zihinsel durumun ayırımı bizim BBA'da hala yüksek doğrulukla yapılabilsede, **Tablo 17**, böyle bir BBA'nın neredeyse %50 hata oranı göz önünde bulundurulduğunda, hemen uygulanabilir olup olmayacağı açık değildir, ki bu da pratik kullanımlarda kullanıcıları sınırlendirir ve performansları bozar.

Tablo 19. Katılımcıların 6-durumlu EEG BBA ayırım görevindeki performansları.

Katılımcı	Performans DVM			Performans LDA		
	Ortalama	En kötü	En iyi	Ortalama	En kötü	En iyi
BA	0.33	0.29	0.37	0.33	0.29	0.38
EM	0.74	0.69	0.80	0.78	0.73	0.83
ER	0.79	0.70	0.86	0.84	0.76	0.89
HI	0.84	0.80	0.87	0.88	0.82	0.93
ME	0.35	0.22	0.47	0.37	0.24	0.50
MR	0.49	0.37	0.61	0.56	0.38	0.74
SE	0.60	0.50	0.66	0.67	0.55	0.75
YU	0.62	0.55	0.70	0.72	0.66	0.80
EK	0.63	0.52	0.74	0.73	0.64	0.82
ES	0.93	0.89	0.97	0.95	0.91	0.97
UL	0.56	0.47	0.64	0.65	0.55	0.75
YL	0.87	0.84	0.89	0.90	0.88	0.92
Toplam	0.64	0.29	0.97	0.70	0.29	0.99

4.4.1 EEG BBA Sinyal Çözücünün Optimizasyonu

EEG verilerinde hedef zihinsel durumların ayırımının üstün doğruluğunu elde etmeyi amaçlayan yukarıdaki BBA sinyal çözücüsünün birkaç optimizasyonunu ele aldık. İlk önce, sinyal çözücünün veri çerçeve seçiminin optimizasyonunu ele aldık. EEG BBA verilerinde farklı zihinsel görüntü durumlarını saptamak için, trial başlama sinyaline ilişkin $[t_0, t_1]$ zaman penceresinde tüm elektrotlardan elde edilen EEG verilerinin bir bölümünü içeren trial onset kilitli veri çerçeveleri $[t_0, t_1]$ sinyal çözme için kullanılmaktadır, **Şekil 20**. Bu tarz sinyal çözme veri çerçevesi parametrelerinin seçiminin EEG BBA'nın kapasitesini optimize etmede önemli olduğu gözlemlendi. Örneğin, sinyal çözme çerçevesini çok büyük yapmak, yararlı EEG BBA sinyalinin hemen öncesi ve hemen sonrasında bilgi vermeyen EEG sinyal kısımlarından kaynaklanan ilgisiz gürültünün birikmesinden dolayı ilgili öznelikleri gizler. Aynı şekilde, çok küçük olan veri çerçevesinin seçilmesi, bu tür ilgili sinyalleri toplu olarak gözden kaçırılabilir.




Şekil 20. EEG BBA verilerinde zihinsel görüntü durumlarını çözmek için kullanılan trial onset kilitli veri çerçevesinin gösterimi.

Veri çerçevesi parametrelerini, başlangıç ve son ofsetlerin olası tüm seçimlerini kapsamlı bir şekilde tarayarak tarafımızdan optimize edildi. İlk ofset, t_0 , 0.1 sn'lik adımlarla trial başlangıcı

sinyaline göre -0.5 saniyeden +1.0 saniye kadar olan aralıkta ayrıntılı olarak incelendi. Son ofset, 0.1 sn adımlarla 0.2 ile 2.0 saniye aralığındaki tüm değerler için $dt=t_1-t_0$ veri çerçevesi uzunluğu aracılığıyla incelendi. Her deneyde sinyal çözücüyü optimize etmek için, her bir katılımcı ve deney için bu tür tam grid araştırması yapıldı. **Şekil 21**, bir yüksek performans gösteren birey (HI), bir orta performans gösteren birey (YU) ve bir az performans birey (BA) için 2-durumlu BBA ayırım doğruluklarının örneklerini göstermektedir. Bu şekilde birkaç öznelik belirtilebilir. İlk olarak, diyagramların sol üst köşesinde şans performansı sadece %50 civarında olan bir bölge gözlemlenir. Daha yakından incelendiğinde, bu bölge tamamen trial başlangıcından önceye uzanan veri çerçevelerine karşılık gelir. Zihinsel görüntülerle ilgili bilgi, tamamen trial başlangıç sinyalinden önce uzanan sinyal çözme çerçevelerinde muhtemelen bulunmadığından, diyagramın bu bölümündeki sinyal çözücü performansı basitçe şans seviyesindedir.

Sinyal çözücünün performansı, şifre çözme çerçevesi trial başlangıç zamanını geçen bölge ile çakışmaya başladıktan sonra yaklaşık 300-500 milisaniyede keskin bir şekilde yükselir. Nitekim, en yüksek doğruluk, -0.5-0.3 saniye aralığındaki çerçeve başlangıç ofseti t_0 ve 0.2-0.9 saniye aralığındaki çerçeve uzunluğu ile tanımlanan diyagramın üçgen bölgesinde, sürekli olarak gözlemlenir. t_0 , 0.5 sn sınırını aştığında performansda hızlı bir düşüş gözlenir. Bu, zihinsel görüntü durumunun belirlenmesiyle ilgili bilgilerin, trial başlangıç sinyalini yaklaşık 500 milisaniye geçtikten sonraki EEG sinyalinde mevcut olmadığını gösterir. Son olarak, her bir katılımcı için **Şekil 20**'deki t_0 - dt diyagramlarının benzer yapısını gözlemlerken, sadece daha düşük performans gösteren bireyler yukarıda belirtilen en iyi tespit üçgeninde sinyal çözücünün doğruluğunda daha düşük bir artış sergilemektedir, diğer durumlarda diyagramın yapısı aynı kalmaktadır.

Tüm katılımcılar, $t_0=0-0.2$ saniye ve $dt=0.6-0.9$ saniye sinyal çözme çerçeve parametrelerinin seçimine yakın optimum performans sergilerler. Bu nedenle, sinyal çözme çerçevesinin konumunun ince ayarlanması BBA sinyal çözücünün performansının bireysel deney temelinde makul düzeyde artmasına sebep olurken, çoğu katılımcı için genellikle uygun olan sinyal çözme çerçeve parametrelerinin $[t_0, t_1]=[0, 0.85]$ saniyelik bir seçimini kabul etmek mümkün görünmektedir.



Şekil 21. İki durumlu BBA ayırımının, bir yüksek performans gösteren birey (HI), bir orta performans gösteren birey (YU) ve bir düşük performans gösteren birey (BA) için sinyal çözücünün veri çerçevesi seçiminin parametrelerine göre doğruluğunu gösteren diyagramlar.

İkinci olarak, EEG sinyalinin öznitelik gösterimini seçme konusu ele alındı. BBA sinyal çözücü için EEG sinyalinin öznitelik gösteriminin seçimi BBA'nın performansını önemli ölçüde etkiler. Burada, EEG bant güç öznitelikleri, güç spektrum yoğunluğu (PSD) öznitelikleri ve aynı zamanda yeni Fourier dönüşüm genlik (FTA) öznitelikleri kullanılarak oluşturulan BBA sinyal çözücülerin performansını inceleyerek bu etkiyi araştırdık. EEG bant güçleri ve PSD gibi tüm sinyal güç temelli öznitelikler için sıra güçlerini ve bu gibi özniteliklerin log₁₀ (yani Desibel) temsilini inceledik. Sıralı zaman serisi (TS) öznitelikleri de bu bölümde ayrıca ele alınmıştır: Zaman serisi öznitelikleri geçmişteki bazı çalışmalarda EEG BBA için kullanılmıştır ancak EEG BBA literatüründe yaygın olarak kullanıldığı saptanmamıştır.

Yukarıda açıklanan tüm öznitelik setlerini kullanarak LDA ve DVM tabanlı BBA sinyal çözücülerinin performansı test edildi, **Tablo 20**. EEG sinyal gösteriminin yukarıda bahsedilen tüm seçimleri için performansın şans seviyesinin çok üzerinde olduğunu gözlemlerken, FTA-Kartezyen öznitelikleri EEG bant gücü, PSD ve FTA-kutup dahil tüm diğer özniteliklerden önemli ölçüde daha iyi performans gösterir. Bu seçimler, 2-durumlu BBA ayırım görevinde tüm katılımcılar üzerinden ortalama %80'e varan oranda performans sergilerken, FTA-Kartezyen öznitelikler ortalama %90'a yakın performans sağlar. 3 durumlu BBA için, güç temelli öznitelikler kullanılarak elde edilen performans %55-60 iken, FTA-Kartezyen için elde edilen ise %75 BBA durum ayırım doğruluğuna yakındır. 6 zihinsel görüntü durumu içeren BBA görevinde, EEG bant gücü, PSD ve kutupsal FTA öznitelikleri ile elde edilen ortalama performans %40 iken , FTA-Kartezyen için %65'dir. Güç temelli öznitelikler ve bunların desibel gösterimlerinde, sinyal çözücünün performansında önemli bir farklılık gözlenmemektedir. Bu nedenle, FTA-Kartezyen özniteliklerinin, literatürde yaygın olarak

kullanılan EEG band gücü veya PSD gibi sinyal gücü temelli EEG özniteliklerin seçiminden çok daha üstün olduğu burada görülmektedir.

Tablo 20. EEG BBA verilerinin farklı öznitelik gösterimlerinin EEG BBA'daki 2, 3 ve 6 durumlu zihinsel görüntü ayırım görevi üzerindeki performansı.

	EEG bant	log-EEG bant	PSD	log-PSD	FTA Kütüp.	FTA Kartesian	Zaman seri
DVM-2	0.770	0.769	0.780	0.766	0.812	0.910	0.897
DVM-3	0.579	0.594	0.580	0.560	0.624	0.744	0.757
DVM-6	0.439	0.427	0.422	0.384	0.432	0.594	0.597
LDA-2	0.698	0.710	0.740	0.717	0.769	0.860	0.858
LDA-3	0.578	0.612	0.586	0.563	0.622	0.754	0.734
LDA-6	0.443	0.439	0.453	0.415	0.493	0.646	0.605

FTA-Kartezyen özellikleri EEG zaman serilerinin basit bir doğrusal dönüşümü olduğundan, DVM ve LDA gibi doğrusal makine öğrenme sınıflandırıcılarının bu öznitelik kümeleri üzerinde benzer performans göstereceği beklenebilir. Gerçekten de deneylerimize göre, hem FTA-Kartezyen hem de TS öznitelikleri, 6'ya kadar zihinsel görüntü durumunun ayrımının yapılmasında benzer bir performans sağladı. Ancak, aşağıda göreceğimiz gibi, FTA öznitelikleri frekans ayrışımına göre EEG sinyalinin daha kısa bir sunumunun ek avantajına sahiptir; bu da, FTA özniteliklerinin çok daha küçük bir alt kümesinin, EEG BBA sinyal çözücüsünde performansdan ödün vermeden kullanılmasına olanak tanır. Bu nedenle, EEG BBA için FTA-Kartezyen özniteliklerin daha iyi bir seçim olduğuna karar verildi.

Son olarak, EEG verileri için referans modu çıkarma optimizasyonunu ele alındı. EEG verileri bir EEG edinme cihazı tarafından alındığında, belirli bir voltaj referansına göre kaydedilir (Teplan, 2002). Zamanla değişen bir ortak mod bileşenini ekleyerek veya çıkararak farklı bir voltaj referansı seçmek, EEG sinyalinin nihai gösterimini etkiler. Bu tür ortak referans modunun farklı seçimlerinin DVM ve LDA EEG BBA sinyal çözücülerinin performansı üzerindeki etkisini inceledik. Özellikle, sistemin 0 Volt referansını (Nihon Kohden EEG-1200 sisteminde), A1-A2 ortalama referansını (A1 ve A2 elektrotlarındaki voltajların ortalaması olarak tanımlandı), ortak referansını (tüm EEG elektrotlarının ortalama potansiyeli) ve Laplace referansını (her elektrot için 4 komşu elektrodun ortalaması olarak tanımlanır) içeren seçimleri araştırdık. Bu analizin sonuçları **Tablo 21**'de sunulmaktadır. Genel olarak, referans voltajın seçilmesinin, EEG bant güçleri ve PSD özellikleri için EEG BBA performansı üzerinde belirgin bir etkiye sahip olabileceği gözlemlenebilir. Bir BBA durum algılama doğruluğu, bu referansların kullanılması durumunda sistem 0 Volt'a göre %5'e varan oranda sürekli artar. FTA-Kartezyen ve TS öznitelikleri söz konusu olduğunda, voltaj referansının

değişimine atfedilen bu farklar daha az belirgindir, Laplace referansı marjinal olarak daha iyi sonuçlar vermektedir.

Tablo 21. EEG BBA'daki 2, 3 ve 6 durumlu zihinsel görüntü ayırım görevindeki farklı referans mod çıkarma seçimlerinin performansı.

	System 0V	Ground	Common	Laplace
EEG bant	0.727	0.770	0.760	0.748
log-EEG bant	0.713	0.748	0.769	0.762
PSD	0.719	0.768	0.779	0.761
log-PSD	0.697	0.748	0.766	0.752
FTA kütüp. FTA	0.782	0.803	0.800	0.812
Kartesian	0.884	0.907	0.905	0.910
Zaman seri	0.874	0.897	0.892	0.893


4.4.2 Frekans Aralığı İle İlgili EEG Sinyalinin Bilgi İçeriği

EEG sinyalinin alçak geçiren filtreler kullanılarak önışlenmesi, EEG BBA'da yaygın bir uygulamadır (Bigdely-Shamlo vd., 2015; Blankertz vd., 2002; Lin vd., 2010; Lotte, 2014; Sitaram vd., 2007; Teplan, 2002; Tomioka ve Müller, 2010; Vidaurre vd., 2009; Wang vd., 2004). Bu çalışmada, EEG sinyallerine alçak geçiren filtrenin uygulanmasının BBA sinyal çözücüsünün performansını artırabileceğini de gözlemledik. PSD veya FTA gibi frekans uzayı öznitelikleri söz konusu olduğunda, böyle bir filtreleme, yalnızca $[0, F_c]$ geçiş aralığı girmeyen öznitelikleri eleyerek gerçekleştirilebilir. TS öznitelikleri söz konusu olduğunda, alçak geçiren filtre uygulamak için 8.dereceden Butterworth alçak geçiren filtre kullanıldı. Her iki durumda da EEG sinyalinden yüksek frekansların atılması EEG BBA performansı için avantajlıdır. Aslında denemelerimiz, yalnızca $[0, 5-10]$ Hz'lik en düşük frekans aralıklarının tutulmasının EEG BBA'nın genel en iyi performansına neden olabileceğini önermektedir.

Yukarıdaki deneme, EEG sinyalindeki kullanışlı BBA bilgilerinin çoğunun çok düşük frekanslarda olduğunu önermektedir. Bunu detaylı araştırmak için, 0-80 Hz frekans aralığında seçilen ve yalnızca 5 Hz genişliğinde bir banttan gelen EEG verilerini kullanmaya sınırlandırılan BBA sinyal çözücüsünün olduğu bir dizi sayısal deney gerçekleştirdik.

Bir başka deyişle, ilk önce 0-5 Hz frekans aralığına filtre edilen EEG verilerini kullanarak BBA sinyal çözücüsü incelendi. İkincisi, 5-10 Hz frekans bandında filtrelenmiş EEG verilerini kullanarak BBA sinyal çözücüsü incelendi ve bu şekilde devam ettik. EEG BBA sinyal çözücülerini 2, 3 ve 6 zihinsel durum ayırımı için değerlendirdik. Tüm durumlarda, EEG BBA sinyal çözücülerinin, zihinsel görüntüleri ayırt etme kabiliyetinin, daha yüksek frekans bantları seçilmesi durumunda önemli ölçüde bozulduğunu ve yaklaşık 20 Hz eşliğinden sonra şans

seviyesine düştüğünü gözlemledik, **Şekil 22**. Bir EEG BBA'da farklı motor görüntülerini ayırt etme görevi ile ilgili bilginin 0-15 Hz'lik düşük frekans aralığında bulunduğu ve bu tür bilgilerin çoğunun 0-10 Hz aralığında yer aldığı sonucu elde edilmiştir.



Şekil 22. 0-80 Hz aralığında dar 5 Hz frekans bantları kullanmaya kısıtlanmış EEG BBA sinyal çözücüsünün performansı. Düz çizgiler – 0-5 Hz'den 75-80 Hz'e kadar 5 Hz frekans bantlarına göre sıralanmış FTA-Kartezyen öznitelikler. Kesikli çizgiler – 5 Hz frekans bantlarına göre sıralanmış TS öznitelikleri. Üçgenler 2-durumlu BBA sınıflandırmasını, kareler 3 durumlu BBA sınıflandırmasını, ve elmaslar 6-durumlu BBA sınıflandırmasını göstermektedir. Kırmızı kesikli çizgiler, 2, 3 ve 6 durum sınıflandırma görevi için şans seviyesini göstermektedir. Tüm durumlarda, yaklaşık 20 Hz'yi aşan frekans bantlarında, sınıflandırma performansının şans seviyelerine düştüğü görülmektedir.

4.4.3 Katılımcıların EEG BBA Performanslarının Tutarlılığı ve “BBA Okur-Yazarlık”

Bazı katılımcıların tüm deneylerde ve BBA görevlerinin her çeşidi için daha iyi performans gösterme eğiliminde olduklarını, bazı katılımcıların ise her deneyde her zaman daha kötü performans gösterme eğiliminde olduğunu gözlemledik. **Tablo 22**, bu incelemeyi farklı katılımcıların performans verilerini, incelenen tüm BBA görevleri ve tüm deneyleri bir araya getirerek göstermektedir. **Tablo 22**'de görüldüğü gibi, en üst performans gösteren bireyler tüm BBA görevlerinde ve tüm deneylerde daha iyi performans gösterirler. Benzer şekilde, orta performans gösteren bireyler tüm görevlerde orta düzeyde performans sergilerken, düşük performans gösteren bireyler her zaman düşük performans seviyeleri gösterdiler. Bu bulgumuz, literatürde yer olan “BBA okur-yazarlık” veya “BCI literacy” diye adlandırılan son bulgular ve tartışmalarla eşleşmektedir (Aghaei vd., 2016; Ahn vd., 2013; Sannelli vd., 2008).

Tablo 22. Katılımcıların genel performans seviyelerine göre sıralanmış, farklı katılımcıların farklı BBA iletişim görevlerindeki tutarlı performansları.

Rank	Katılımcı	Ortalama performans		
		2-durum	3-durum	6-durum
1	ES	0.99	0.98	0.93
2	YL	0.98	0.90	0.87
3	HI	0.98	0.89	0.84
4	ER	0.95	0.89	0.79
5	EM	0.96	0.85	0.74
6	SE	0.95	0.82	0.60
7	YU	0.91	0.76	0.62
8	EK	0.84	0.71	0.63
9	MR	0.88	0.70	0.49
10	UL	0.81	0.69	0.56
11	ME	0.75	0.52	0.35
12	BA	0.77	0.54	0.33

4.4.4 EEG BBA Kullanılarak Sanal Robotun Online Kontrolü

Daha önce geliştirilen donanım ve yazılıma dayanan interaktif online EEG BBA sistemimiz bu bölümde tartışılır. Söz konusu sistem, bilgisayar ekranında 3D olarak simüle edilen ve yanal hareket, boylamsal hareket ve tutma ve açma hareketi yapabilen sanal bir 3 dof robot manipülatördür. Bu manipülatör, EEG BBA vasıtasıyla kullanıcılar tarafından interaktif olarak kontrol edildi, **Şekil 4**.

Bunun için, en iyi performans gösteren üç katılımcımız interaktif BBA deneylerine katılmaya davet edildi. Her deney, bu çalışmanın başka bölümlerinde açıklandığı üzere 15 dakikalık üç oturumdan oluşuyordu: bir BBA sinyal çözücü eğitim oturumu, bir alıştırma oturumu ve bir test oturumu. Eğitim oturumu sırasında kullanıcılar, BBA'nın GUI'leri ile kendilerine gösterilen bir dizi zihinsel görüntüyü uygulayarak BBA sinyal çözücüyü denetlenen şekilde eğittiler. Robot manipülatörü bu süre boyunca hareket etmedi ve BBA, yalnızca BBA sinyal çözücüsünü eğitmek için kullanılacak verileri topladı ve kullanıcıya cevap vermedi. Eğitim bittikten sonra, katılımcılar, eğitilmiş sinyal çözücü ve 3-durumlu BBA kontrol modelini (bkz. Yöntemler) kullanarak, manipülatörü etkileşimli olarak, serbest tarzda kontrol etmeye davet edildi. Son olarak, test oturumunda, katılımcılara manipülatörü farklı pozisyonlara taşımak için bir dizi sözlü görev verildi ve onları tamamlamak için çalıştılar. Görevler, manipülatörü iki (sol-sağ veya ileri-geri) veya dört yöne (sol-sağ ve ileri-geri) olmak üzere en fazla dört adıma kadar hareket ettirmeyi içermekteydi. Katılımcılar 15 dakikalık test oturumu süresince toplamda 7-8 test görevi tamamlamışlardır.

Katılımcıların performansı, başarıyla tamamlanan görevlerin yüzdesi, bir görevi tamamlamak için geçen ortalama süre ve manipülatörün kontrolünün ortalama doğruluğu olarak değerlendirildi. Kontrol doğruluğu, doğru yöndeki manipülatör hareketlerinin yüzdesi olarak

nicelendirildi. Buradaki doğru yön manipülatörün hedefe doğru hareket ettiği yöndür. En iyi katılımcı (HI) interaktif denemelerde %84.6 ortalama kontrol doğruluğu ve ikinci en iyi katılımcı (ER) etkileşimli denemelerde %77.8 kontrol doğruluğu göstermiştir; bu katılımcılar için bu bölümünde elde edilen sonuçlarla çalışmanın çevrimdışı analiz yapılan kesiminde elde edilen sonuçlar birbiriyle uyumludur. Üçüncü katılımcımız (ES), BBA'yi denetleme konusunda daha fazla zorluk yaşadı; BBA'yi çevrimdışı deneylerde gösterdiği performans seviyelerinin çok altında sadece ortalama %49.6 bir doğrulukla kontrol edebilmiştir. Bu, katılımcının stresinden kaynaklandığı tespit edilir. Başarılı katılımcılar, bir manipülatör hareketini ortalama olarak uygulamak için 7-10 saniyeye ihtiyaç duymuştur. Her manipülatörün hareketini uygulamak için katılımcı HI 6.5 saniyeye ve katılımcı ER 9.3 saniyeye ihtiyaç duyuyordu. Buradaki BBA kontrol modeli nedeniyle, BBA, BBA'daki her bir "açık" sinyalin sunumu başına verilen süreye eşit her 3 saniyelik bir süre boyunca bir komut alabildi. En iyi senaryoya göre bu süre, BBA hareket rejimini değiştirmek için gereken süre ile birlikte, manipülatör hareketi başına ortalama 4.1 saniye demektir. Bu nedenle, en iyi katılımcı, manipülatörü %50 zaman kazancı ve %15 hata oranı ile kontrol edebildi; ikinci en iyi katılımcı, ideal zaman süresinin yaklaşık iki katına ihtiyaç duydu ve BBA'yı kontrol etmede yaklaşık %25 hata yaptı. BBA'yı kontrol etmede yaşadığı zorluk nedeniyle, üçüncü katılımcı, başarılı trial'lerde hareket başına 13 ile 40 saniye arasında zaman harcadı ve verilen görevlerin sadece %40'ını tamamlayabildi. Diğer iki katılımcı kendilerine verilen görevlerin %100'ünü tamamlayabildi. Etkileşimli BBA uygulamasının sonuçları **Tablo 23**'de özetlenmiştir.

Tablo 23. Online BBA kontrol deneylerinde katılımcıların performansı.

Katılımcı	HI	ER	ES
Görev Tamam	100%	100%	40%
Doğruluk	84.6%	77.6%	49.6%
Min adıma zaman	4.1 sec	4.1 sec	4.1 sec
Adıma zaman	6.5 sec	9.3 sec	26.7 sec

EEG BBA deneylerimizde 6 kadar zihinsel görüntü durumunu şans seviyesinin oldukça üzerinde ayırt ettik. Burada elde edilen ayrılmış zihinsel görüntü durumlarının gözlemlenen doğruluğu, tüm katılımcılar üzerinden ortalaması alınmış olarak, 2 zihinsel görüntü (sağ ve sol el motor görüntüleri) için %90, 3 zihinsel görüntü için %77 ve 6 görüntü için %64'tür (tüm konular üzerinde ortalama). Çevrimdışı deneyler için elde ettiğimiz sonuçlar, literatürde bulunan sonuçlarla tutarlıdır (Abdalsalam vd., 2017; Forney vd., 2015; Gysels ve Celka, 2004; Jeunet vd., 2015; Liu vd., 2005; Müller-Gerking vd., 1999; Obermaier vd., 2001). Müller ve arkadaşlarının yapmış oldukları çalışmada iki zihinsel görev ayırımının doğrulukları üç katılımcı için sırasıyla %94, %90 ve %84 olarak bulunmuştur. (Müller-Gerking vd., 1999).

Obermaier'in yapmış olduğu çalışmada EEG sinyal bandı güç öznitelikleri ve Elektroensefalografik desen sınıflandırması için bir saklı Markov modeli kullanılarak, üç katılımcının iki zihinsel görev için %86, %96 ve %90 ve beş zihinsel göreve kadar %46, %67 ve %45 sınıflandırma doğrulukları elde ettikleri raporlanmıştır (Obermaier vd., 2001). Gysels ve arkadaşlarının yapmış oldukları çalışmada 3 farklı zihinsel görevi gerçekleştiren 3 katılımcı için deneysel EEG kayıtları elde edilmiş ve %62'ye kadar BBA ayırım doğrulukları elde edildiği gösterilmiştir (Gysels ve Celka, 2004). Liu ve arkadaşlarının yapmış oldukları çalışmada 2 zihinsel görüntü (sağ ve sol el parmak motor görüntüleri) kullanılarak altı katılımcının sınıflandırma doğruluklarının ortalamasının %75.6'ya kadar ulaştığı bildirilmiştir (Liu vd., 2005). Literatürde yer alan başka daha yeni bir çalışmada 3 zihinsel görüntü görevini kullanarak EEG BBA'nın kontrolünü öğrenmeyi amaçlayan deneylere katılan 18 katılımcının ortalama %53'lük grup performansı gösterdiği rapor edilmiştir (Jeunet vd., 2015) ki bu bizim sonuçlarımızla uyumludur. Zihinsel görev tabanlı beyin-bilgisayar arayüzünde EEG sinyallerinin sınıflandırılması için Echo State Networks'ün kullanıldığı başka bir çalışmada iki zihinsel görev için en yüksek %95, dört zihinsel görev için ise % 65'e varan sınıflandırma doğrulukları bildirilmiştir (Forney vd., 2015). iki görev sınıflandırması için 9 katılımcının grup başarı ortalaması 81% ve dört görev sınıflandırması için %54 olarak bildirilmiştir (Forney vd., 2015). Abdalsalam ve arkadaşlarının yapmış oldukları çalışmada 5 katılımcıdan oluşan bir grup için, dört zihinsel görüntünün (sol ve sağ elin açılması ve kapanması, iki el ve iki ayak hareketi) sınıflandırma doğrulukları 86.6% olarak rapor edilmiştir (Abdalsalam vd., 2017). Böyle bizim offline analizlerimiz sonucu elde edilen, iki görev için %90, üç görev için %77 ve altı görev için %64'lük grup ortalama performansları, literatürde bulunan benzer sonuçlar ile tutarlıdır veya onlardan üstündü.

Sonuç olarak, EEG öznitelik seçimi, tespit çerçeve seçimi, voltaj referans seçimi ve diğer seçimler de dahil olmak üzere EEG BBA sinyal çözücüsünün tasarımındaki farklı seçimler BBA performansı üzerine etki sağladı. FTA özniteliklerinin, geçmişteki EEG BBA literatüründe ağırlıklı olarak kullanılan ve EEG sinyalinin güç spektrumunun hesaplanmasına dayanan diğer özniteliklere kıyasla %30'a varan oranlarda üstün performans gösterdiğini projemizde gözlemlendi. EEG sinyal güç özniteliklerinin kullanılması durumunda, 2 durumlu BBA ayırım görevi için, tüm katılımcıların ayırım doğruluklarının ortalaması yaklaşık %78 iken, FTA özniteliklerinin kullanılması durumunda ayırım doğruluklarının ortalamasının % 90'dan fazla bulunduğu gösterilmiştir. 6 zihinsel görüntü durum ayırımı için, EEG sinyal güç öznitelikleri, bazı kişiler için %85-90'a kadar, tüm katılımcılar üzerinden ortalama alınması durumunda ise FTA özniteliklerinin % 65 doğruluk oranı karşısında yalnızca yaklaşık %45

ayrım doğruluğuna izin vermiştir. Bu nedenle, bizim projemizde FTA özneliklerinin kullanımı, EEG BBA performansında önemli iyileştirmeler gerçekleştirmek için önemlidir.

EEG sinyalinin işlenmesinden önce EEG sinyalinin alçak geçiren biçimde filtrelenmesi EEG BBA literatüründe yaygın bir uygulamadır. Alçak geçiren filtrelemenin, EEG BBA verilerini çözme performansını iyileştirmeye yardımcı olabileceğini gözlemledik. 5 Hz yüksek frekans kesiminde alçak geçiren filtreleme yapılmasının EEG BBA performans bağlamında en iyi sonuçları verdiğini gözlemledik. Bu şaşırtıcıydı ve kullanılan motor zihinsel görüntüler hakkında en kullanışlı bilginin EEG sinyalinin çok düşük frekanslarında olduğunu göstermektedir. Üst ekstremite hareket niyetlerinin özellikleri (Agashe ve Contreras-Vidal, 2011, 2013; Bradberry vd., 2010; Paek vd., 2014), alan potansiyeli (Bansal vd., 2011; Hall vd., 2014; Mollazadeh vd., 2011; Zhuang vd., 2010), ECoG (Acharya vd., 2010; Kubánek vd., 2009; Pistohl vd., 2012), ve implantlanmış intra-kortikal elektrotlu kapalı döngü çalışmaları (Perge vd., 2014) ile ilgili literatürde benzer sonuçlar mevcuttur. Aynı zamanda, geleneksel motor-görüntü EEG BBA, mu (8-13 Hz) ve beta (20-30 Hz) ritimleri gibi EEG sinyalinin daha yüksek frekans bantlarındaki güç modülasyonunu kullanmaktadır.

Bu durumu açıklığa kavuşturmak için, zihinsel motor görüntülerinin 0-5 Hz'den başlayarak 75-80 Hz'e kadar belirli bir 5 Hz bandına filtrelenmiş EEG verilerinden ayırdedilebilirliğini test ettik. EEG bant frekansının 15-20 Hz'yi aşması durumunda EEG verilerindeki motor görüntü durumlarını ayırt etme kabiliyetinin hızla düştüğünü gözlemledik. Sadece 0-5 Hz, 5-10 Hz ve 10-15 Hz frekans bantları, EEG BCI performansının şans seviyesinden önemli derecede farklı kalmasına izin verdi ve sadece 0-5 Hz ve 5-10 Hz frekans aralıkları, anlamlı bir farkla şans seviyesinden daha iyi performans gösterdi. Özellikle, sol ve sağ el hareketlerin motor görüntülerinin sınıflandırılmasında, tüm katılımcıların gözlemlenen ortalama ayırt etme doğruluğu, 0-5 Hz bandında filtrelenmiş EEG sinyali için %80-90, 5-10 Hz bandında filtrelenmiş EEG sinyali için %65-75 ve 10-15 Hz bandında filtrelenmiş EEG sinyali için %50 olan şans seviyesinin biraz üzerinde %55-60'dır. 15 Hz'nin ötesinde, bu BBA görevi için ayırım doğruluğu şans seviyesinden farklı değildi. Aynı zamanda, 6 zihinsel görüntü durumunu ayırt etmek için, tüm katılımcıların ortalama doğruluğu 0-5 Hz frekans bandı kullanıldığında %50-60, 5-10 Hz bandı kullanıldığında %30-35 ve 10-15 Hz bandı kullanıldığında ise %20-23 olarak bulunurken yine daha yüksek bantlarda %16'lık şans seviyesinden farklı sonuç göstermemektedir, **Şekil 22**. Dolayısıyla, 0-15 Hz'lik düşük frekansların, EEG BBA'da kullanılan farklı motor görüntüleriyle ilgili en önemli bilgiyi taşıdığına ve bu bilgilerin çoğunun sadece 0-10 Hz frekans bandından geldiği sonucuna vardık.

Deneylelerimizdeki katılımcılar, günden güne olduğu gibi farklı etkileşim paradigmalarına göre de her zaman tutarlı performans sergilediler. Bu bulgular, "BCI literacy" olgusuyla ilgili literatürdeki son tartışmalarla paralellik göstermektedir. Yüksek performanslı, orta derecede performans gösteren ve düşük performans gösteren gruplar oluşturulduğunda, 12 katılımcının 5'i 2 durumlu BBA görevi için %95-100, 3 durumlu BBA görevi için %85-90 ve 6 durumlu BBA görevi için ise %80-90 offline sinyal çözme doğruluğu elde ederek yüksek seviyede performans göstermiştir. Bu bireyler, tüm BBA görevlerinde ve tüm deneylerde yüksek performans sergilemiştir. Bu katılımcılar online BBA denemelerinde, simüle edilmiş bir 3D robotik manipülatör kolu ve BBA'yı dakikada 6-9 hareket oranında %80 doğrulukla kullanarak hareketleri gerçekleştirebilmişler ve böylece interaktif ortamlarda da BBA'yı kontrol etme konusunda iyi bir yetenek göstermişlerdir. Bu kişilerin BBA'yı kontrol etme kabiliyeti, daha fazla pratik uygulamaya fırsat vermektedir. 12 katılımcının 5'i 2 durumlu BBA görevi için %80-90, 3 durumlu BBA görevi için %70-80 ve 6 durumlu BBA görevi için ise %50-70 sınıflandırma doğruluğu elde ederek orta düzeyde performans göstermiştir. 12 katılımcının 2'si tatmin edici bir BBA kontrol yeteneği elde edemedi. Söz konusu iki birey BBA kullanımında hala şans seviyesinin üzerinde oldukça yüksek performans sergilemelerine rağmen, 2 durumlu senaryoda sadece %75, 3 durumlu senaryoda %50 ve 6 durumlu senaryoda %35 BBA kontrol doğruluğu elde edebildiler.

Online deneylerimizde, BBA sinyal çözücünün eğitilmesi için tek bir 15 dakikalık oturum kullanıldı. Bunun yapılmasının nedeni, deneylerimiz sırasında göz önüne alınan tasarım seçimleri için, katılımcıların alıştırmaya ve test oturumları sırasındaki niyetlerinin tam olarak bilinemeyeceğinin düşünülmesidir. İlkesel olarak, bu tasarım uygun değilmiş gibi görünse de literatürde alıştırmaya ve test oturumlarını da içeren sinyal çözücünün eğitilmesi için öneriler yapılmıştır (DiGiovanna vd., 2009; Orsborn vd., 2012). Bunun için ortak bir yaklaşım, test ve alıştırmaya oturumunda kullanıcılar tarafından yürütülen hedefler ile uyumlu olan BBA hareketlerini doğru olarak ele almak olabilir. Öte yandan, diğer çalışmalar BBA'nın öğrenilmesinin, başka bir aracın kullanımının öğrenilmesine benzer bir süreç olarak görülebileceğini önermektedir (Bradberry vd., 2011). Bu nedenle, BBA uygulama süreci, önce kullanıcılara bir dereceye kadar başarılı bir BBA sinyal çözücü sunulacak şekilde ve ardından bu BBA'nın kontrolünü daha iyi yapabilmeleri için kullanıcıların sinyal çözücüye adapte olabilecekleri şekilde yapılandırılabilir; ki bu adaptasyon kullanıcıların beynindeki sinirsel desenlerin değişmesiyle gerçekleşir. Bu senaryoda, kullanıcının bu adaptasyon sürecine yardımcı olması için BBA sinyal çözücünün sabit kalması gerekmektedir (Carmena vd., 2003a). Bu iki olasılığı birbirinden ayırmak gelecekteki çalışmalar için muhtemel yönlerden biridir.

EEG BBA'da, EEG sinyallerinin oturumdan oturuma yüksek değişkenliği ve beraberinde BBA'yı yeniden eğitime gerekliliği iyi bilinmektedir (Cinar ve Sahin, 2013; Faller vd., 2014; Hammon ve De Sa, 2007; Lopez-Larraz vd., 2010). Bu değişkenliğin nedenleri iyi anlaşılmamış olsa da, bu nedenler elektrot yerleşimindeki oturumdan oturuma değişkenlik, nem, sıcaklık, kanal hareketi, ter ve duygusal, hormonal ve farmakolojik değişiklikler nedeniyle elektrot empedansındaki ve kafa derisindeki değişkenlikleri içerebilirler. Benzer şekilde, deneylerimizde, BBA sinyal çözücüsünün her deneyde yeniden eğitimden geçirilmesi veya yeniden kalibre edilmesi ihtiyacını gözlemliyoruz. BBA'nın her yeni uygulaması için sinyal çözücüyü eğitmenin gerekliliği mevcut EEG BBA teknolojisinin bir dezavantajdır. Ancak, çalışmamızda eğitim süresi yalnızca 15 dakika sürdü ve sonrasında aynı sinyal çözücü deneyin sonuna kadar kullanıldı. Bu eğitim süresi diğer BBA çalışmalarında açıklanan süreden çok daha kısadır (Blankertz, Dornhege, Krauledat, Muller, vd., 2006; Buch vd., 2008; Guger vd., 2000; Thulasidas vd., 2006).

4.5 EEG BBA İçin Makine Öğrenme Tabanlı Sinyal Çözücülerinin İyileştirilmesi

4.5.1 Genel Giriş

Toplanan EEG BBA veri kümesini, EEG BBA sinyal çözücülerini iyileştirmek için kullandık. Bu alt-proje kapsamında, 2S-6S ile gösterilen 2'den 6'ya kadar değişen aynı anda ayırt edilen zihinsel görüntü oluşumlarında, sol ve sağ el, sol ve sağ bacak ve dil hareket motor görüntüleri ile bir pasif durum görüntüsü gibi EEG BBA zihinsel sembolleri için farklı sinyal çözücü tasarımları kapsamlı şekilde incelendi. Böyle gerçekleştirilen 384 offline EEG BBA tasarımı 48 deneydeki performanslarına ve 2S-6S olmak üzere 5 ayırma paradigmasına göre toplam 92,160 çözücü tasarımı sayısal olarak değerlendirildi, **Tablo 3**.

4.5.2 EEG BBA Performans İçin Referans Düzeyi

EEG BBA'nın tespit doğruluklarındaki performanslarının, 2 motor görüntü için %60-%95, 3 motor görüntü için %60-%95, 4 motor görüntü için %40-%85 ve 5 görüntü için %50-%65 arasında değiştiğinin rapor edildiği çok sayıdaki EEG BBA çalışması literatürden bulunabilmektedir (Abdalsalam vd., 2017; Blankertz vd., 2011; Forney vd., 2015; Jeunet vd., 2015; Lemm vd., 2011; Li ve Pan, 2011; Lotte vd., 2007; Tangermann vd., 2012). Ancak, rapor edilen sonuçların ve kullanılan yaklaşımların geniş değişkenliğinden dolayı, bu sonuçlardan ortak bir performans referansı oluşturmak zordur. Bir problem şudur ki; birçok çalışmada 3-5 katılımcıdan daha az katılımcı kullanılmıştır. Bireylerin EEG BBA performansında gözlemlenen büyük içsel değişkenlik (örneğin (Ahn ve Jun, 2015; Sannelli vd., 2008) ve ayrıca **Tablo 4**) ile ilgili bu tür deneylerde bildirilen büyük farklılıklar katılımcı gruplarındaki rassal değişimden kaynaklanmaktadır. Bu durum, farklı çalışmalarda kullanılan

veri işleme yaklaşımlarındaki ve deneysel ve veri edinim prosedürlerindeki değişkenlik nedeniyle ağırlaşmaktadır.

Birkaç daha büyük EEG BBA çalışması, 50 ile 180 katılımcıdan oluşan daha büyük gruplarda 2 motor görüntünün ayırımına odaklanmıştır. Bu çalışmalar, böyle bir 2S görev için katılımcı-ortalama doğruluklarını (ortalama \pm ortalama hata kare) $\%66 \pm 1.4$ (N = 50) (Ahn vd., 2013), $\%73 \pm 0.7$ (N=180) (Guger vd., 2003) ve $\%74 \pm 1.9$ (N=80) (Blankertz vd., 2010) olarak bildirmektedir. Guger (Guger vd., 2003) ve Blankertz'in (Blankertz vd., 2010) sonuçları oldukça uyumluyken, Ahn'nın (Ahn vd., 2013) sonuçları bu sonuçlardan farklıdır. Bu fark, onların basit veri ön-işleme yaklaşımlarının kullanımıyla ilişkilendirilebilir. Guger (Guger vd., 2003) ve Blankertz (Blankertz vd., 2010) bulgusal öznitelik seçimini kullanırken Ahn (Ahn vd., 2013) bunu yapmamıştır. Bunlar EEG BBA çözücü iyileştirilmesi için daha iyi bir temel referans noktası sağlar, ancak yalnızca 2S görevi kapsar. Dolayısıyla, kendi deneysel veri tabanımız üzerinde tüm çalışmalarda (Ahn vd., 2013; Blankertz vd., 2010; Guger vd., 2003) kullanılan LDA+PSD veri analiz yaklaşımının performans incelemesini baz alarak kendi referans performans düzeyimizi ürettik. Bu performans düzeyleri **Tablo 24**'de belirtilmiştir. 2S için elde ettiğimiz performans düzeyleri (Ahn vd., 2013; Blankertz vd., 2010; Guger vd., 2003) referanslarındakiler ile uyumludur. Ayrıca, 3S - 6S EEG BBA sınıflandırma görevleri için yeni, daha fazla performans düzeyleri sunuyoruz.

Tablo 24. Veri setimiz üzerindeki LDA+PSD uygulama sonuçlarına dayanan EEG BBA performans düzeyleri. Base-1, öznitelik ön seçimi olmaksızın LDA + PSD (ya ham ya da desibel biçimde, hangisi daha yüksekse) ve Base-2 LDA+PSD+en iyi öznitelik ön seçimi. 2S-6S görevlerindeki katılımcı-ortalama sınıflandırma doğrulukları gösterilmektedir. STD, bu doğruluklardaki katılımcı ilişkili standart sapma tahminidir.

Görev	2S	3S	4S	5S	6S
Base-1	0.65	0.52	0.43	0.36	0.36
Base-2	0.75	0.62	0.56	0.49	0.47
STD	0.07	0.08	0.10	0.15	0.15

4.5.3 EEG BBA Uygulamalarında En İyi Makine Öğrenme Algoritması

Projemizin bu bölümünde hangi sinyal çözme yaklaşımı EEG BBA'da en iyi zihinsel görüntü sınıflandırmasını sunduklarını belirlemek istiyoruz. Bu soruyu çözenin bir yolu, farklı sınıflandırma algoritmalarının bir veri kümesindeki ortalama doğruluklarına bakmak olabilir (Kaya vd., 2017). Ancak, bu yaklaşımda baze sorun vardır. İlk olarak, katılımcı bireylerin performanslarının EEG BBA'da (literatürde BBA öğrenme olarak adlandırılan bir olgu (Sannelli vd., 2008)) önemli ölçüde değişebileceğini gözlemledik. Örneğin, 2S görevinde, farklı katılımcılar için BBA sembol sınıflandırma doğruluklarının $\%55$ 'den $\%95$ 'e kadar değişebildiğini gözlemledik, bu durum tüm deneyler için tutarlı bir şekilde sağlandı. Ayrıca, farklı deneyler üzerinden katılımcıların EEG BBA performanslarında daha az değişkenlik

mevcuttur. Bu nedenle, basit bir ortalama temelli seçilen bir BBA sinyal çözme algoritması, bireylerin hepsi veya çoğu için iyi bir seçim olmayabilir ve bu bireylerin farklı deneylerinde bile en iyi sonucu vermeyebilir.

Bu çalışmada benimsediğimiz yaklaşım, EEG BBA için en iyi makine öğrenme sınıflandırıcılarının belirlenmesini bir sıra birleştirme (rank aggregation) problemi olarak formüle edildi. Yani, bireylerin hem farklı deney günlerindeki en iyi ve en kötü performansları hem de ortalama performanslarına göre çoğu birey için tercih edilebilecek bir seçim olan sınıflandırıcıları belirlemek istendi. Bunun için öncelikle, yukarıdaki 3 kategoriye ayrı ayrı tüm farklı katılımcılar için sınıflandırıcıları sıraladık ve sonra sınıflandırıcıların tüm veri kümesi üzerindeki performanslarını temsil eden en iyi genel sınıflandırma sıralamasını oluşturduk. Böyle bir sıralama tablosundan bir alıntı **Tablo 25**'te gösterilmiştir ve tüm öznitelik uzayında (yani herhangi bir öznitelik ön seçimi olmaksızın **Tablo 3**'deki tüm öznitelikleri birleştirerek) EEG BBA sembol sınıflandırmasına uygulanan farklı ML algoritmaları için sıra birleştirme sonuçları **Tablo 26**'da gösterilmektedir.

Bu tabloda yukarıdaki ayarlarda DVM'nin en iyi performansı gösterdiğini gözlemliyoruz. Daha önceki çalışmalarla (Lotte vd., 2007) tutarlı olarak, 2S için %69-%93 ve 3S görevler için %53-%87 arasında değişen bireysel performanslar gözlemlenmiştir. DVM, katılımcı-ortalama doğruluk cinsinden, 2S görevlerde %82 ve 3S görevlerde %71 doğruluk göstermektedir. İkinci en iyi algoritma RBE olarak karşımıza çıkmaktadır. RBE'nin performansı, DVM'nin 2S-4S görevlerdeki performansını çok yakından takip eder, ancak daha büyük sembol sayıları için belirgin olarak geride kalır. Naïve Bayes ve QDA bu ayarlarda iyi performans göstermez.

Tablo 25. Farklı BBA sembol sınıflandırma algoritmalarını karşılaştırmak için kullanılan sıra birleştirme prosedürü için bir tablodan bir alıntı. Tüm algoritmalar her katılımcı için en iyi gün, en kötü gün ve ortalama performanslarına dayalı olarak ayrı ayrı düzenlenmiştir. Ardından, algoritmaların genel sıralanması, sıra birleştirme yoluyla üretilmiştir.

	S1 ave	S1 max	S1 min	S2 ave	S2 max	S2 min	S3 ave	S3 max
2S								
kNN	0.88	0.93	0.88	0.88	0.92	0.87	0.73	0.70
LDA	0.89	0.95	0.89	0.89	0.93	0.89	0.69	0.67
DLDA	0.88	0.93	0.86	0.87	0.92	0.86	0.69	0.64
NB	0.77	0.88	0.74	0.82	0.90	0.80	0.59	0.56
QDA	0.61	0.65	0.58	0.62	0.68	0.59	0.56	0.54 ...
RBE	0.89	0.95	0.87	0.91	0.94	0.91	0.70	0.68
RF	0.88	0.94	0.87	0.88	0.91	0.86	0.67	0.64
DVM	0.92	0.97	0.90	0.92	0.94	0.91	0.69	0.66
...								
5S								
kNN	0.55	0.60	0.54	0.63	0.70	0.62	0.34	0.32
LDA	0.59	0.67	0.58	0.74	0.76	0.72	0.35	0.35

DLDA	0.55	0.62	0.54	0.69	0.72	0.65	0.31	0.31
NB	0.43	0.54	0.42	0.62	0.67	0.62	0.26	0.26
QDA	0.26	0.27	0.25	0.29	0.29	0.28	0.24	0.24
RBE	0.56	0.64	0.55	0.75	0.76	0.73	0.35	0.32
RF	0.55	0.60	0.53	0.66	0.71	0.65	0.32	0.31
DVM	0.63	0.70	0.63	0.75	0.79	0.74	0.35	0.34

...

Tablo 26. Tüm öznitelik uzayı kullanıldığında ve öznitelik ön seçimi yapılmadığında, EEG BBA'daki farklı ML sınıflandırma algoritmalarının sıralamaları (sol) ve karşılık gelen katılımcı-ortalama doğrulukları (sağ).

	TÜM	2S	3S	4S	5S	6S	2S	3S	4S	5S	6S
DVM	0	0	0	0	0	0	0.82	0.71	0.64	0.59	0.58
RBE	1	1	1	1	1	1	0.81	0.71	0.63	0.57	0.55
LDA	2	2	2	2	2	2	0.80	0.67	0.59	0.55	0.54
RF	3	3	3	3	3	3	0.79	0.66	0.58	0.52	0.51
KNN	4	4	4	4	4	5	0.79	0.62	0.54	0.48	0.43
DLDA	5	5	5	5	5	4	0.78	0.62	0.55	0.50	0.47
NB	6	6	6	6	6	6	0.71	0.55	0.47	0.42	0.41
QDA	7	7	7	7	7	7	0.60	0.42	0.32	0.26	0.23

4.5.4 EEG BBA Uygulamalarında En İyi Öznitelik Uzayı

Farklı sınıflandırıcıların, **Tablo 3**'te listelenen belirli öznitelik uzaylarına uygulanmasının sonuçları **Tablo 27**'de gösterilmektedir. Burada gösterilen sonuçlar DVM içindir; ancak şu açıklamalar diğer tüm yöntemler için benzerdir. Genel olarak, PSD ve EEG bant gücü gibi güç temelli öznitelikler en kötü performansı gösterirken, EEG verisinin ham zaman serisi (TS) gösteriminin kullanılması durumunda en iyi sonuçlar gözlemlenir.

Burada TS özelliklerinin başarısı şaşırtıcı olabilir. Literatürde PSD ve EEG bant gücü gibi popüler EEG sinyalinin frekans gösterimi kullanılarak üretilen öznitelikler deneylerimizde önemli ölçüde daha kötü sonuç vermiştir. Örneğin, 2S görevi için TS öznitelik uzayı kullanıldığında, DVM %84 oranında doğruluğa ulaşırken, PSD özniteliklerinin kullanılması durumunda doğruluk %68'e düşmüştür.

Tablo 27. Belirli farklı öznitelik uzaylarını kullanan EEG BBA'daki ML sınıflandırma algoritmalarının performansları (tipik bir örnek)

alg.	S	psd-db	psd	eegb-db	eegb	fta-p	fta-c	ts	tüm
DVM	2S	0.68	0.68	0.70	0.71	0.75	0.76	0.84	0.82
	3S	0.54	0.55	0.56	0.58	0.59	0.59	0.72	0.71
	4S	0.45	0.47	0.47	0.50	0.51	0.50	0.65	0.64
	5S	0.40	0.40	0.41	0.44	0.46	0.44	0.61	0.59
	6S	0.40	0.39	0.40	0.42	0.44	0.41	0.60	0.58

4.5.5 EEG BBA Uygulamalarında En İyi Öznitelik Ön-Seçim Yaklaşımı

Öznitelik ön seçiminin BBA sembol sınıflandırması üzerindeki etkisini inceledik. Öznitelik ön seçiminin bazı biçimleri, bugün, ML algoritmaları uygulamalarında gerekli bir adım olarak ele alınır. **Tablo 26**'da verilen ilk 4 sınıflandırıcı için **Tablo 3**'te listelenen en iyi öznitelik seçim stratejilerinin performansı **Tablo 28**'de gösterilmektedir.

Tüm sınıflandırıcıların performanslarının uygun öznitelik ön seçimiyle birlikte önemli ölçüde arttığını gözlemledik. Burada özel olarak RBE sınıflandırıcısı, korelasyon tabanlı öznitelik ön seçimi ve FTA-P öznitelik uzayı ile kullanıldığında doğruluk performansını **Tablo 26**'da verilen %72'den **Tablo 28**'de verilen %90'a artırarak 2S sınıflandırması için en iyi seçenek haline gelmiştir. FTA-C öznitelik uzayında frekans tabanlı öznitelik filtrelemeyle birlikte DVM, RBE sınıflandırıcısına çok yakın bir performans göstermektedir.

*Tablo 28. Öznitelik uzayları ve öznitelik ön seçim seçeneklerini kullanan **Tablo 26**'da verilen EEG BBA'daki en iyi 4 ML sınıflandırma algoritmasının performansları*

alg.	S	tüm	ts	fta-p	fta-c	psd-db	psd	eegb-db	eegb	En iyi öznitelik ön-seçim						
DVM	2S	0.82	0.86	0.79	0.88	0.73	0.75	0.73	0.75	6	1	2	2	2	4	2
	3S	0.71	0.72	0.63	0.76	0.57	0.60	0.62	0.61	6	1	2	2	2	4	3
	4S	0.64	0.65	0.57	0.70	0.50	0.54	0.56	0.55	6	1	2	2	2	4	4
	5S	0.59	0.61	0.53	0.66	0.45	0.49	0.50	0.49	6	6	2	2	2	3	2
	6S	0.58	0.60	0.49	0.64	0.43	0.46	0.50	0.48	6	2	2	2	3	2	3
RBE	2S	0.88	0.85	0.90	0.89	0.83	0.75	0.73	0.71	5	1	5	5	5	5	5
	3S	0.73	0.72	0.68	0.74	0.61	0.57	0.59	0.55	3	1	3	2	3	3	6
	4S	0.67	0.67	0.60	0.68	0.54	0.48	0.54	0.48	3	1	3	2	3	3	6
	5S	0.62	0.62	0.53	0.63	0.47	0.41	0.48	0.42	3	1	3	2	3	2	3
	6S	0.60	0.61	0.51	0.61	0.44	0.38	0.46	0.39	3	1	3	2	3	2	3
LDA	2S	0.84	0.84	0.82	0.87	0.75	0.75	0.76	0.74	3	6	5	2	3	3	2
	3S	0.69	0.72	0.66	0.75	0.62	0.60	0.63	0.62	3	6	3	2	3	3	4
	4S	0.63	0.66	0.60	0.71	0.56	0.54	0.58	0.56	3	6	3	2	3	2	4
	5S	0.58	0.62	0.55	0.68	0.49	0.49	0.52	0.51	3	2	3	2	3	2	4
	6S	0.56	0.61	0.52	0.67	0.46	0.47	0.52	0.49	3	2	3	2	3	2	4
RF	2S	0.86	0.84	0.85	0.86	0.77	0.74	0.74	0.72	4	3	3	3	3	4	4
	3S	0.73	0.70	0.71	0.72	0.63	0.59	0.62	0.59	3	3	3	3	3	3	3
	4S	0.67	0.64	0.63	0.64	0.57	0.52	0.56	0.53	3	3	3	3	3	3	2
	5S	0.62	0.58	0.57	0.59	0.50	0.45	0.50	0.46	3	3	3	3	3	2	3
	6S	0.58	0.55	0.53	0.56	0.47	0.43	0.48	0.45	3	1	3	3	3	2	6

Daha yüksek sembol sayıları için, frekans temelli filtreleme ve FTA-C öznitelikli LDA, en iyi performansı göstermektedir; örneğin 6S görevleri için performansı %40'dan (**Tablo 26**) %67'ye (**Tablo 28**) kadar artırarak, 4S-6S sınıflandırması için en iyi seçenek haline gelmiştir. Daha yüksek sembol miktarları için de, frekans tabanlı öznitelik filtresi ve FTA-C öznitelik

uzayını kullanan DVM, LDA'ya çok yakın sonuçlar verir ve bu da DVM sınıflandırıcısının tüm farklı sınıflandırma görevlerine göre en iyi genel seçim olabileceğini gösterir.

TS ve FTA-C öznitelikleri, dikkate alınan tüm durumlarda PSD ve EEG band gücü gibi sinyal güç temelli özniteliklere göre üstün performans göstermiştir. Bu, güç temelli özelliklerdeki faz bilgi kaybı nedeniyle olabilir. Bu etki, "faz duyarlı" olan TS, FTA-P ve FTA-C öznitelikleri ile "faz-duyarlı olmayan" PSD-DB, PSD, EEG-DB ve EEG öznitelikleri arasındaki performans ayrımının net olduğu RF sınıflandırıcısında açıkça görülmektedir. (**Tablo 28**'deki RF kesimi).

4.5.6 Optimize Edilmiş EEG BBA Sinyal Çözme Yaklaşımı

EEG BBA sinyal çözücü tasarımı için genel en iyi performansı belirlemek için yukarıdaki sonuçları birleştirdik. Bunlar **Tablo 29**'da gösterilmektedir. Burada, DVM tüm sınıflandırma görevlerinde tutarlı bir şekilde en iyi veya en iyiye yakın performans göstererek, genel en iyi seçim olarak karşımıza çıkmaktadır. Ancak, 2S ve 6S görevleri için, en iyi sınıflandırıcı sırasıyla RBE ve LDA olarak ortaya çıkmaktadır. LDA'nın DVM ile çok benzer bir şekilde performans gösterdiğini ve böylece uygulamalı EEG BBA'daki kullanımını haklı gösterdiğini belirtmek gerekir. Ayrıca, RBE, KNN ve RF gibi yüksek varyanslı sınıflandırıcıların, daha düşük sembol miktarları üzerinde neredeyse DVM ve LDA kadar başarılı olabileceğini buluyoruz. Ancak, daha yüksek sembol miktarları 5S ve 6S için DVM ve LDA'ya göre performansları önemli ölçüde düşmektedir.

Tablo 29. En iyi öznitelik uzayı ve öznitelik ön seçimi kullanıldığında EEG BBA'daki farklı ML sınıflandırma algoritmalarının sıralamaları (sol) ve karşılık gelen katılımcı-ortalama performansları (sağ)

	HEPSİ	2S	3S	4S	5S	6S	2S	3S	4S	5S	6S
DVM	0	2	0	0	0	1	0.88	0.76	0.70	0.66	0.64
LDA	1	3	1	1	1	0	0.87	0.75	0.71	0.68	0.67
RBE	2	0	2	3	3	2	0.90	0.74	0.68	0.63	0.61
KNN	3	1	3	4	4	4	0.88	0.73	0.66	0.61	0.57
RF	4	4	4	2	2	3	0.86	0.73	0.68	0.62	0.58
DLDA	5	5	5	6	6	5	0.86	0.70	0.64	0.58	0.54
NB	6	6	6	5	5	6	0.85	0.69	0.63	0.58	0.54
QDA	7	7	7	7	7	7	0.80	0.64	0.56	0.47	0.45

4.5.7 Uyarlanabilir Veri-Çerçevesinin Etkisi

EEG BBA'da önemli bir nokta, öznitelik çıkarımı için veri çerçevesinin seçilmesidir. Örneğin, Blankertz çalışmasında her katılımcı için manuel olarak ayarlanmış uyarlanabilir bir veri çerçevesi kullanılır (Blankertz vd., 2010). Öte yandan, (Ahn vd., 2013) çalışmasında sabit bir veri çerçevesi kullanılır ve önemli ölçüde daha kötü sonuçlar rapor edilir. Her bir katılımcı ya da deney için veri çerçevesini uyarlanabilir bir şekilde seçmek, EEG BBA için çekici bir

seçenek olarak görülebilir. Ancak, bu optimizasyon aynı zamanda EEG BBA tasarımlarına önemli miktarda karmaşıklık ve hesaplama maliyeti getirmektedir.

Tablo 30'da uyarlanabilir veri çerçevelerinin yararını araştırdık. Orada görülebileceği gibi, uyarlanabilir veri çerçevelerinin kullanılması, EEG BBA sinyal çözücülerinin performansında sabit veri çerçevesine göre az fakat %3-4'lük kadar (genel olarak optimal olarak seçilmiş) farkedilir bir kazanç sağlar. Performans artışı yüksek eğilim (DVM, LDA) için daha yüksektir ve yüksek varyanslı sınıflandırıcılar (RF, RBE) için çok azdır. Katılımcı-özel adaptasyona göre belirli deneyler için veri çerçevesinin uygulanması verilerimize önemsiz faydalar sağlandı.

Tablo 30. Uyarlanabilir veri çerçevelerinin BBA sembol sınıflandırmasına etkisi.

	Deney	Katılımcı	Sabit		Deney	Katılımcı	Sabit
DVM				LDA			
2S	0.88	0.86	0.84	2S	0.87	0.85	0.84
3S	0.76	0.74	0.72	3S	0.76	0.74	0.72
4S	0.70	0.69	0.67	4S	0.71	0.70	0.67
5S	0.66	0.65	0.63	5S	0.68	0.67	0.65
6S	0.65	0.64	0.62	6S	0.67	0.66	0.64
RBE				RF			
2S	0.90	0.88	0.87	2S	0.86	0.85	0.84
3S	0.74	0.73	0.71	3S	0.73	0.72	0.71
4S	0.68	0.67	0.65	4S	0.68	0.66	0.65
5S	0.63	0.62	0.60	5S	0.62	0.61	0.60
6S	0.61	0.60	0.59	6S	0.58	0.57	0.57

4.5.8 Özet

Özet olarak, bu proje boyunca topladığımız büyük tekdüze EEG BBA veri kümesini kullanarak, modern makine öğrenme yöntemlerine dayanan çok sayıda EEG BBA sinyal çözücü tasarımlarının performanslarını değerlendirdik. Modern makine öğrenme tekniklerinin EEG BBA'da şaşırtıcı bir şekilde başarılı olabileceği bu şekilde gösterildi. Mevcut makine öğrenme algoritmaları, literatürde bulunan özel olarak tasarlanmış ve yaygın olarak manuel optimize edilen EEG BBA veri işleme yaklaşımlarıyla karşılaştırılabilir yakın performans elde etti. Bu tür algoritmaların öznitelik çıkarma ve öznitelik seçim aşamalarını optimize etme, günümüzde standart uygulamalar olduğu gibi, EEG BBA'daki mevcut gelişme seviyesini önemli ölçüde daha iyi yapmak için onların performanslarını arttırabilir.

Hem modern yüksek eğilim (DVM ve LDA) hem de yüksek varyans (RBE, KNN ve RF) algoritmalarının EEG BBA'da çok iyi performans gösterdiği bulunmuştur. EEG BBA'da bulunan az sayıdaki eğitim örnekleri göz önüne alındığında, bu ikincisi şaşırtıcı olabilir (bu çalışmada, tipik olarak, buradaki algoritmaların bir uygulama birimi içeren her bir deney için her zihinsel görüntü türünden kümülatif olarak 600'den az eğitim örneği vardır). Buna


rağmen, yüksek eğilimli ve yüksek varyanslı sınıflandırıcıların performanslarının, yüksek eğilimlilerin yüksek varyanslıları %5-%10 gibi çok önemli bir farkla geçtiği 5S ve 6S yüksek miktarlı sembol görevleri haricinde yakın oldukları gözlenmiştir. Bu, genel makine öğrenme algoritmalarındaki önemli yeni gelişmelerin yanı sıra burada uygulanan öznelik ön seçiminin verimliliğine atfedilebilir.

2S sınıflandırması için, tüm en iyi sınıflandırıcılar, istatistiksel hata sınırları içinde son derece yakın performans sergilediler. Böylece, DVM, RBE, LDA, RF, KNN, DLDA ve NB sınıflandırıcılarının 2S motor görüntü sınıflandırma görevine ilişkin en iyi katılımcı-ortalama performansı araştırmamızda %90 iken en kötü %86'dır. Daha büyük miktardaki BBA sembolleri için, en iyi (LDA -%67) ve en kötü performans gösteren algoritmalar (NB -%54) arasındaki fark önemli ölçüde olup %13'tür.

Öznelik uzayının seçilmesinin EEG BBA sınıflandırıcılarının performansını önemli ölçüde etkiledi. Literatürde popüler olan PSD ve EEG bant gücü gibi güç temelli özellikler, muhtemelen faz bilgi kaybı nedeniyle tüm deneylerimizde önemli ölçüde daha kötü performansa neden oldu. EEG sinyalinin frekans modülasyonlu olmadığı ve EEG BBA performansındaki önemli artışların (bazı durumlarda %20 gibi), FTA gibi faz-duyarlı öznelik setleri kullanılarak elde edilebilir olduğu görülmektedir. RF'nin faz duyarlılığının avantajlarından kolayca yararlanabildiğini fark ettik, ancak bu tüm algoritmalar için doğru olmayabilir. Böylece, DVM ve LDA, açıkça eşdeğer olsa da, FTA-C'ye kıyasla FTA-P öznelik uzayı ile kullanıldıklarında önemli ölçüde daha kötü performans göstermektedirler. Bunun nedeni, farklı BBA sembollerinin FTA-C'de lineer olarak daha iyi ayrılabilir olması fakat doğrusal olmayan FTA-P uzayında ayrılabilir olmasıdır.

RF diğer yüksek varyanslı sınıflandırıcılar ile birlikte, öznelik uzayının seçimine anlamlı sağlamlık gösterdi. Özellikle, RBE, KNN ve RF, **Tablo 3**'deki tüm öznelikleri tek bir öznelik vektörüne birleştiren ayırt edilmemiş "tüm" öznelik uzayında en iyiye yakın performans gösterdi. 2S ve 3S gibi sınıflandırmalarda RF+MUI performansındaki %3-4'lük kayıp, öznelik uzayının olası seçimindeki hassasiyetsizlik göz önüne alındığında bazı BBA uygulamaları için makul kabul edilebilir. Bu tür sınıflandırıcıların ayrıntılı ön öznelik mühendislik aşamasına gerek kalmaksızın BBA'da başarılı olabilmeleri çekici bir özellik olabilir. Buna göre, potansiyel olarak kullanışlı tüm öznelikler bir araya getirilebilir ve RF+MUI, EEG BBA'da çok düşük bir performans kaybıyla kullanılabilir. Genel olarak, EEG BBA sınıflandırıcılarındaki öznelik uzayını ve öznelik filtre seçimini optimize ederek, zihinsel görüntü sınıflamasında katılımcı-ortalama doğruluklarındaki önemli artışları, 2S sınıflandırma görevlerinde %75'den %90'a ve 6S sınıflandırma görevlerinde ise %47'den %67'ye olarak raporlayabilmekteyiz.

Genel olarak, bu projede EEG BBA sinyal çözücülerinin performansında belirgin artış elde edildi. Daha önceden yaygın olarak kullanılan EEG sinyal gücü özniteliklerine karşı faz duyarlı özniteliklerden ve optimal öznitelik filtrelerinden yararlanılarak, geçmişte literatürde sıklıkla kullanılan bulgusal frekans seçimi ve giriş kanal seçimi de dahil olmak üzere, manuel ayarlama gerektirilmeksizin yüksek bir zihinsel görüntü sınıflandırma doğruluğu elde edilir. 2S sınıflandırma görevi için FTA-P öznitelikli ve korelasyon tabanlı öznitelik filtreli (RBE+FTA-P+COR) RBE sınıflandırıcısı kullanarak en iyi zihinsel görüntü ayırım doğruluğunun 89.9 ± 1.6 (katılımcı-ortalama \pm katılımcıyla ilişkili MSE) olduğunu gösterdik ki bu değer, geçmiş çalışmalarda bulunan, 66.4 ± 1.4 (Ahn vd., 2013) veya 73.8 ± 1.3 (Blankertz vd., 2010; Guger vd., 2003) performans düzeylerinden yüksektir. 3S sınıflandırma görevi için, en düşük $52-62$ olmak üzere en yüksek 75.8 ± 4.7 (DVM + FTA-C + FRQ) ve 6S sınıflandırma görevi için en düşük $36-47$ olmak üzere en yüksek 66.9 ± 5.1 (LDA+FTA-C+FRQ) performans düzeyleri elde ettik.



Şekil 23. Uygun bir öznitelik uzayı ve öznitelik ön seçimi yöntemi, EEG BBA'daki ML sınıflandırma algoritmalarının performansını önemli ölçüde artırabilir. Farklı ML algoritmalarının, optimal öznitelik uzay ve öznitelik filtre seçiminin yapıldığı durumdaki performansları (sağ) ve yapılmadığı durumdaki performansları (sol) gösterilmektedir

4.6 EEG BBA Sinyalinin Temel Özellikler Konusunda Veri Toplamı

4.6.1 Elektrotlar Arasındaki Mesafenin Fonksiyonu Olarak EEG Montajındaki EEG Elektrotlar Arasındaki Bağımlılık

Projenin bu kısmında, BMA/BBA uygulamaları için muhtemel alternatif EEG elektrot yerleşimleri, özellikle daha yoğun elektrot yerleşimlerinin araştırılması planlanmıştır. Var olan EEG BMA/BBA sistemlerinin örneklerinin birçoğunda, EEG verilerini toplamak için standart 10/20 veya genişletilmiş standart 10/20 elektrot düzeni kullanılmıştır. Bu sistemler kafayı düzgün şekilde kapsarken EEG sinyalinin özelliklerini ve EEG sinyalinin BMA/BBA uygulamaları ile ilişkilerini dikkate almadan tanımlanmıştır. Bu nedenle, bu standart EEG düzenlerinin BMA/BBA uygulamaları için optimal olup olmadığı şu anda bilinmemektedir. Özellikle, hassas motor veya zihinsel durumların ayrılması için kafanın belirli bölgesine

elektrotların yoğunlaştırılmasının faydalı olabileceği düşünülebilir. Aynı zamanda yoğunlaştırılmış EEG elektrotlarının BMA/BBA uygulamaları için ne faydası ne de yoğunlaşma limitleri bilinmemektedir. Bu soruları cevaplamak için, EEG sinyalinin uzaysal özellikleri ve EEG elektrot-arası mesafelerine göre elektrotların istatistiksel bağımlılığı hakkında bilgi toplanmıştır.

BMA/BBA uygulamaları için EEG elektrotları yoğunlaştırarak EEG sinyalinden daha çok bilgi elde edilebileceği düşünülebilir. Fakat bu bilginin (i) BMA/BBA uygulamasında kullanılan motor veya zihinsel durumlar için faydalı olması ve (ii) diğer elektrotlardan türetilmemesi gerekmektedir. Eğer bir EEG elektrodunun sinyali BMA/BBA uygulamasında kullanılan zihinsel durumla alakasız olursa, böyle elektrodun BMA/BBA sisteminde kullanılması fayda sağlamaz. Benzer şekilde, eğer bir EEG elektrodunun sinyali diğer yakın elektrotların sinyaline çok benziyor ise, böyle elektrodun kullanılmasından da BMA/BBA için az fayda sağlanır.

Çalışmalarımız ikinci soruya daha çok odaklanmış olup, elektrot arası mesafesine göre farklı elektrotların sinyalleri arası istatistiksel bağımlılık fonksiyonu ölçülmüştür;

$$F(d) = EEG_elektrot_bağımlılık(elektrot_arası_mesafesi)$$

Söz konusu fonksiyonel bağımlılık ölçümleri için senkron Sağ El Beş Parmak Hareket (5F) deneyler kullanılmıştır. Yukarıda tartışıldığı gibi, bir elin parmaklarının hareketleri EEG sinyali anlamında daha hassas bir durum belirtmektedir. Bu durumda yoğunlaştırılmış elektrot düzenlerinin daha çok faydalı olabileceği beklenebilmektedir. Bu deneylerimiz, standart 10/20 düzeni kullanılarak ve kafanın, beş parmağın hareketlerine en çok tepki gösteren bölgelerine yoğunlaştırılan EEG elektrot düzenleri kullanılarak gerçekleştirilmiştir. Tüm deneylerde, EEG elektrotlarının pozisyonları ve kafa üzerindeki elektrot arası mesafeleri ölçülüp kayıt edildi.

EEG elektrotlarının istatistiksel bağımlılıklarını ölçmek için, korelasyon ve ortak bilgi (Mutual Information) ölçekleri kullanılmıştır. Sözü geçen ölçekler bu raporda daha önce tartışılmıştır. Burada, bu ölçekler EEG ham sinyali için hesaplanmıştır. Daha spesifik olarak, iki EEG elektrot için korelasyon ölçüğü ham sinyallerin kullanılması ile şu şekilde hesaplanmıştır;

$$r_{ij}^2 = corr(e_i, e_j) = \frac{1}{T\sigma_i\sigma_j} \sum_{t=1}^T (e_i(t) - \bar{e}_i)(e_j(t) - \bar{e}_j)$$

Burada $e_i(t)$ i -inci EEG elektrodunun zamana bağlı ham sinyali, \bar{e}_i i -inci EEG elektrodunun ham sinyalinin ortalama değeri, T toplam zaman örneklerinin sayısı, σ_i i -inci EEG elektrodunun ham sinyalinin standart sapmasıdır. Korelasyon katsayısı sıfırdan bire kadar değişiyor olup, sıfıra yakın olursa iki EEG elektrodunun ham sinyalleri başlıca bağımsız, bire yakın olursa EEG elektrodunun sinyalleri birbirine tam bağımlıdır.

Ortak bilgi, bir EEG elektrodunun sinyalini bir rastgele deęişken olarak varsayar ve řu řekilde tanımlanır;

$$MUI(e_i, e_j) = H(e_i, e_j) - H(e_i) - H(e_j) = H(e_i, e_j) - H(e_i|e_j) = H(e_i, e_j) - H(e_j|e_i)$$

Burada $H(e_i)$, i -inci EEG elektrodunun sinyalinin entropisi veya belirsizlięidir,

$$H(e_i) = - \sum_{e_i} P(e_i) \ln P(e_i)$$

$H(e_i, e_j)$ i -inci ve j -inci EEG elektrot sinyallerinin ortak entropisi veya belirsizlięi,

$$H(e_i, e_j) = - \sum_{e_i, e_j} P(e_i, e_j) \ln P(e_i, e_j)$$

Ortak bilgi, bir elektrodun ham sinyalinin bir deęerinin belli olması durumunda dięer elektrodun ham sinyalinin belirsizlięinin azalıřını ifade eder. Eęer iki EEG elektrodu baęımsız ise, $H(e_i, e_j) = H(e_i) + H(e_j)$ ve $MUI(e_i, e_j) = 0$; eęer iki EEG elektrodunun ham sinyalleri bir birine tamamen baęlı ise, $H(e_i, e_j) = H(e_i) = H(e_j)$ ve $MUI(e_i, e_j) = H(e_i, e_j) = H(e_i) = H(e_j)$ azamidir.

Korelasyona gore ortak bilgi oleęinin faydası řudur; r^2 oleęinde iki deęişken arasında bir lineer iliřki varsayılır, yani $e_i = ae_j + b + \epsilon$. Burada a ve b iki sayısal katsayı ve ϵ bir rastgele gurultu deęişkenidir. Herhangi a ve b deęerleri iin, korelasyon katsayısı fonksiyonel baęlantının $e_i = ae_j + b$ ve gurultunun ϵ goreli onemleri olur. Orneęinin, $\epsilon = 0$ durumunda korelasyon katsayısı $r^2 = 1$ dir; $a \approx 0$ veya ϵ ok buyuk durumunda $r^2 \approx 0$ dir. Buna raęmen iki deęişken arasında lineer olmayan bir baęlantı varsa, korelasyon katsayısı yanlış sonular verebilir; lineer olmayan fonksiyon ile baęlı olan iki deęişkenin korelasyon katsayısı birden kuuk ve hatta sıfıra yakın olabilir.

Ortak bilgi oleęinin boy­le dezavantajı yok ve ortak bilgi lineer olmayan iliřkiler iin kullanılabilir. İki deęişken herhangi lineer olmayan fakat monoton fonksiyon ile baęlı olursa, $e_i = f(e_j)$, her zaman $H(e_i) = H(e_j)$ ve $MUI(e_i, e_j) = H(e_i)$ yani azami olduęu gosterilebilir. Bununla beraber, eęer iki EEG elektrodunun sinyalleri Normal daęılmış rastgele deęişkenler olarak duřunulebilir ise ve onların ortak daęılımı da korelasyon katsayısı r ile Normal daęılım olursa, korelasyon ve ortak bilgi oleekleri arasında belirli fonksiyonel iliřki mevcut olur;

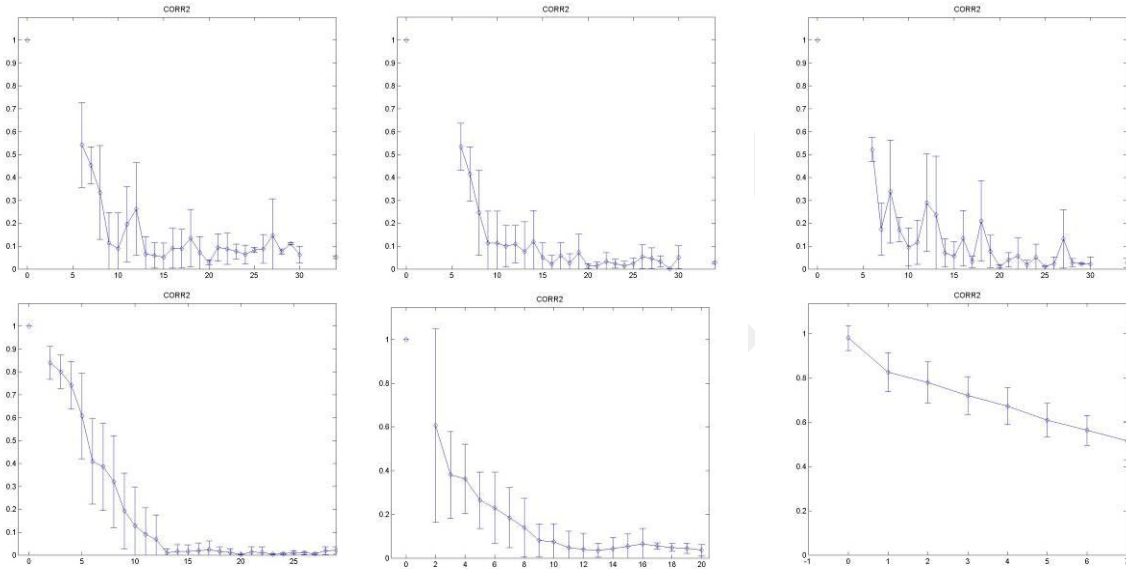
$$MUI(e_i, e_j) \approx -\frac{1}{2} \ln(1 - r_{ij}^2)$$

Standart 10/20 duzeni kullanılan deneylerimizde boy­le baęımlılık-mesafe eęrileri elde edilmiřtir. Bu durumda asgari elektrot-elektrot uzaklıęı 6 cm dir. 10 cm den kuuk uzaklıklarda olan elektrotlar iin hem ortak bilgi hemde korelasyon baęımlılık oleeklerinin


artmaya başladığı görülebilir ve 6 cm elektrot arası uzaklığında ortak bilgi olarak yaklaşık olarak 0.5 nat, korelasyon olarak $r^2 \approx 0.5$ değerine kadar istatistiksel bağımlılığı görülebilir

EEG elektrotlarını yoğunlaştıran düzenlerde elektrot-elektrot uzaklığı 1 cm'e kadar azaltılabilmektedir. Bu elektrot-arası mesafesi, yaklaşık olarak 720 elektrot içeren elektrot düzenlerinin yoğunluğuna denk gelir. 1 cm'e devam eden mesafe-bağımlılık eğrileri, standart 10/20 düzeni kullanılarak elde edilen mesafe-bağımlılık eğrilerimiz ile uyumlu şekilde olup, 6 cm'den küçük uzaklıklarda artışa devam ediyor ve 1-2 cm elektrot-elektrot mesafelerinde ham EEG verilerinin istatistiksel bağımlılığının ortak bilgi olarak 1 nat, korelasyon r^2 olarak 0.8-0.9'a vardığını gösterir.


Bu ara bulgulara göre, EEG elektrotlarının 10 cm den daha büyük uzaklıkta olan elektrotlar oldukça bağımsızdır. Bununla beraber, 10 cm den daha düşük uzaklıklarda olan elektrot-arası bağımlılık artmaya başlar. 5 cm'den daha çok yoğunlaştırılan elektrotların ham sinyali yüksek derecede korelasyon ve ortak bilgi göstermektedir, **Şekil 24-26**.



Şekil 24. 5F deneyimizde üç katılımcımızın elde edilmiş EEG elektrotlarının korelasyon mesafe-bağımlılık eğrileri. Üst satır, standard 10/20 yerleşim sistemi ve 6 cm uzaklığa devam eden, alt satır ise kafanın bir bölgesine yoğunlaştırılan elektrot düzenleri ve 1 cm uzaklığa devam eden mesafe-bağımlılık eğrilerini gösterir. Elde edilmiş mesafe-bağımlılık eğrileri EEG ham sinyalinin 5 cm elektrot-arası uzaklığın altında sinyallerinin birbirinden istatistiksel olarak bağılı olduğunu gösterir. X ekseninin birimi cm, Y ekseninin ise korelasyon katsayısının karesidir



Şekil 25. 5F deneyimizde üç katılımcımızın elde edilmiş EEG elektrotlarının ortak bilgi mesafe-bağımlılık eğrileri. Üst satır, standart 10/20 yerleşim düzenini, alt satır kafanın bir bölgesine yoğunlaştırılan elektrot düzenleri için mesafe-bağımlılık eğrilerini gösterir. Bu şekilde ölçülen mesafe-bağımlılık eğrileri EEG ham sinyallerinin 5 cm uzaklığın altında birbirine bağlı olduğunu gösterir. X ekseninin birimi cm, Y ekseninin birimi nat tır.



Şekil 26. Yoğunlaştırılan elektrot düzeni kullanan bir senkron Sağ El Beş Parmak 5F deneyimizdeki üç 5 cm mesafe altında olan elektrottaki ortalama olaya ilişkin potansiyeller. Farklı 5 parmağın hareket ERP potansiyelleri farklı 5 renkle gösterilmiştir. Yüzük ve serçe parmakları hariç, farklı parmak hareketleri gösterilen ERP'lerden iyi şekilde ayrılabilir. Aynı zamanda, yoğunlaştırılan EEG elektrotlarında gözlenen ERP'ler birbirine büyük ölçüde benzerlik göstermektedir. Böyle çok yakında olan elektrottaki sinyallerin oldukça yakın olması gözlemlenebilir.

4.6.2 Geleneksel EEG Düzeni Dışında Elektrotların Aralarındaki Mesafe Daha Kısa Olacak Şekilde Yerleştirilmesi EEG Kayıtlanmasına Fayda Sağlar mı?

Geçmişte yapılan EEG BBA çalışmalarında 10/20, 10/10 ya da 10/5 gibi standart elektrot yerleşim sistemleri kullanılmıştır. Bu sistemlerde, elektrotların yerleşim yerleri kafa etrafına uniform olarak yerleştirilerek belirlenmiş ve deneylerin tekrar uygulanabilir olması amacıyla geliştirilmiştir. Bu sistem çoğu BBA çalışmaları açısından en iyi verimi sağlamayabilir. Bu sistemler her yarıküre motor korteksteki C3 ve C4 elektrotlarından veri almak için güvenilirdir. Özellikle “lateralized readiness potansiyeline” dayalı olan sağ ve sol el hareketlerinin ayrımı

için yeterli olduğu kanıtlanmıştır. Ancak ayak ya da dil hareketleri gibi hareketlerin olduğu çalışmalarda, bu sistemlerle alınan ölçümlerde zorluklar ortaya çıkmaktadır..

Projenin bu kısmında, “EEG BBA için yeni deneysel tasarımlar araştırılacaktır” ibaresi gereğince, standart 10/20 ve 10/10 EEG yerleşim sistemini kullanmayan yeni EEG BBA tasarımlarını araştırmak, özellikle motor korteks alanında elektrotların yoğunlaştığı yeni yerleşim stratejilerini incelemek ve onların EEG BBA performansına etkisini belirlemek için deneyler tasarlandı. Bu deneyler şu sorulara cevap bulmak için tasarlanmıştır.

1. BBA uygulamasında EEG ölçümünde hangi elektrotlar bilgi sağlar mı?
2. BBA uygulamasındaki elde edilmek istenilen sinyaller EEG ölçümünde hangi frekanslarda kapsanmaktadır?
3. BBA uygulamasında belli elektrotlar daha fazla bilgi sağlar mı?
4. Elektrotlar arası mesafenin standart 10/20 sistemindeki elektrotlar arası mesafeden daha az mesafede yerleştirilmesinin genel EEG kaydı ve EEG uygulaması açısından bir faydası var mı?
5. Sık elektrot yerleştirilmiş modelde farklı frekanslarda EEG verilerinin özellikleri değişmekte midir?


EEG elektrot yoğunlaştırılmış 5F 5 parmak deneyleri dışındaki tüm deneylerimiz 10/20 sistemine yerleştirilmiştir. Tüm deneylerde elektrotlar arasındaki mesafelere göre korelasyon analizi yapılmış ve tüm veriler frekans aralıklarının bilgi yoğunluğu açısından analiz edilmiştir. Bu uygulama için; $>5\text{Hz}$ (Low-pass filter), $5 < f < 10\text{ Hz}$, $10 < f < 15\text{Hz}$, $15 < f < 20\text{Hz}$, $20 < f < 25\text{Hz}$ ve $25 < f < 30\text{Hz}$ band-pass filtreleri kullanılarak hangi frekans aralığına BBA durumu hakkında ne kadar bilgi düştüğünün analizi yapılmıştır.

Farklı alanlardaki farklı hareketler açısından düşünüldüğünde, korteks alanlarının spesifik olarak bölgelere ayrılmış (cortical homunculus) olduğu bilinmektedir. Bu farklı hareketler için farklı alanlardan gelen sinyaller de C3 ve C4 üzerine düşmektedir. Bu da bu sinyallerin ayrımı açısından güçlük yaratmaktadır. Klasik 10/20 düzeninde olmayan, belirli elektrotlar etrafında yoğunlaşarak elektrot yerleşimi yapılması farklı motor hareketlerin EEG ölçümü ile ayırt edilmesinde daha iyi bir uzaysal çözüm sağlayabilir. “Standart EEG elektrot düzeni 5 parmak” deneyleri için yapılan bu analizler sonucunda en çok veri elde edilen elektrotlar ve frekanslar belirlenmiş, bu elektrotlar etrafında yoğunlaşacak şekilde yeni elektrot yerleşim modelleri EEG elektrot yoğunlaştırılmış deneyleri için belirlenmiştir. Bu modeller kullanılarak “EEG elektrot yoğunlaştırılmış 5 parmak” deneylerinin sonuçları da analiz edilmiştir.


Aşağıda yapılan bu uygulamalar ve analiz sonuçları maddeler halinde yer almaktadır. Uygulamalar tüm deneklere yapılmış olup birer tanesi her maddede örnek olarak verilmiştir.

4.6.3 BBA Uygulamasında EEG Ölçümünde Hangi Elektrotlar Bilgi İçermektedir?


Bu soruya cevap bulabilmek için sağ/sol el, sağ/el-ayak-dil ve 5 parmak deneyleri standart EEG şapkası ile uygulanmıştır. Elde edilen kayıtlardan her kanal için ortalama olay-ilişkili-potansiyeller olan (Event-related potential) ERP'lerin analizi yapılmıştır. Aşağıda deneylerden alınmış ERP analizlerine örnekler verilmiştir.



Şekil 27. Sağ ve sol el hareketlerine cevaben gelişen ve 200Hz örnekleme frekansında C3/C4 EEG elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller (ERP). Mavi eğri sol el, kırmızı eğri sağ el, yeşil eğri ise pasif durumu temsil etmektedir. Yatay ölçek zamanı (ms), dikey ölçek potansiyeli (mV) temsil eder. Hareketin yaklaşık 850ms civarında başladığı gözlemlenmektedir




Şekil 28. Sağ-sol el, sağ-sol ayak ve dil hareketlerine cevaben ve 200Hz örnekleme frekansında C3/C4 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyelleri gösterir. Mavi eğri sol el, kırmızı eğri sağ el, yeşil eğri pasif durumu, magenta eğri sol ayak hareketini, siyah eğri sağ ayak hareketini ve siyah eğri dil hareketini temsil etmektedir. Yatay ölçek zamanı (ms), dikey ölçek potansiyeli (mV) temsil eder. Hareketin yaklaşık 850ms civarında başladığı gözlemlenmekte ancak ayırım yapılamamaktadır.




Şekil 29. 5 parmak hareketlerine cevaben 1000Hz örnekleme frekansında C3/C4 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyelleri gösterir. Mavi eğri 1, kırmızı eğri 2, yeşil eğri 3, magenta eğri 4 ve siyam eğri 5 numaralı parmağın hareketini göstermektedir


Şekil 27-29'da verilen örnek grafiklerden de görüldüğü gibi iki hareket (sağ/sol el ve pasif) durumları için C3/C4 elektrotları motor korteks üzerinde buldukları yer itibariyle hareket ayrımı için oldukça iyi sonuçlar vermektedir. Ancak ikiden fazla hareket için, motor korteksin ilgili alanlarından ve tüm hareketlerin sinyallerinin C3/C4 üzerine düşmesinden dolayı iyi bir ayırım söz konusu olamamaktadır. Aşağıda başka elektrotların aynı uygulamalar için ERP analizlerine örnekler verilmiştir.



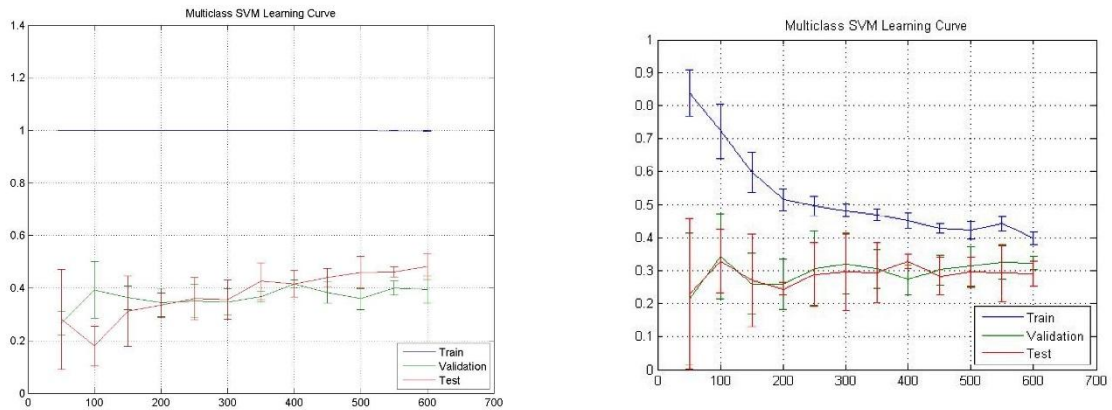
Şekil 30. Sağ ve sol el hareketlerine cevaben gelişen ve O1/T6 EEG elektrotlarından izlenen yavaş motor olaya ilişkin potansiyeller (ERP). Mavi eğri sol el, kırmızı eğri sağ el, yeşil eğri ise pasif durumu temsil etmektedir. Yatay ölçek zamanı (ms), dikey ölçek potansiyeli (mV) temsil eder. Hareketin yaklaşık 850ms civarında başladığı gözlemlenmektedir.



Şekil 31. Sağ-sol el, sağ-sol ayak ve dil hareketlerine cevaben O1/T6 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyelleri gösterir(ERP). Mavi eğri sol el, kırmızı eğri sağ el, yeşil eğri i pasif durumu, magenta eğri sol ayak hareketini, siyam eğri sağ ayak hareketini ve siyah eğri dil hareketini temsil etmektedir. Yatay ölçek zamanı (ms), dikey ölçek potansiyeli (mV) temsil eder. Hareketin yaklaşık 850ms civarında başladığı gözlemlenmekte



Şekil 32. 5 parmak hareketlerine cevaben O1/T6 elektrotlarından izlenen yavaş motor olaya ilişkin potansiyelleri gösterir. (ERP). Mavi eğri 1, kırmızı eğri 2, yeşil eğri 3, magenta eğri 4 ve siyam eğri 5 numaralı parmağın hareketini göstermekte



Şekil 33. Sırasıyla tüm elektrotlar için (sol) ve sadece C3/C4 elektrotları için (sağ) DVM eğitim grafiklerin örnekleri


Şekil 30-32'de verilen örnek grafiklerden de anlaşılacağı üzere C3/C4 elektrotları buldukları yer itibariyle bilgi içermektedir. Ancak diğer elektrotların analizi ve **Şekil 33**'de verilen DVM eğitim grafikleri farkı göz önüne alındığında diğer elektrotlardan faydalanmak BBA uygulaması açısından daha başarılı olacaktır.

4.6.4 BBA Uygulamasındaki Elde Edilmek İstenilen Sinyaller EEG Ölçümünde Hangi Frekanslarda Kapsanmaktadır?


EEG ölçümlerinde elde edilen bilgiler, geçmiş çalışmalardan ve literatüre artık standart olarak geçmiş bazı dalgalardan oluşmaktadır. Bunlar alfa, beta, teta, gama dalgaları ve olaya ilişkin potansiyellerdir. Bu dalgalar 0,5-70Hz ve 5-400 μ V aralığında değerlere sahip olan dalgalardır. Bizim çalışmamızda uygulamakta olduğumuz deneylerin kapsadığı EEG sinyalinin değişimleri olaya ilişkin potansiyellere girmektedir ve BBA uygulamasında bu değişimler belli bir frekans aralığında analiz edilmektedir. Bu sebeple yapılan deneylerden elde edilen veriler 0-30 Hz aralığında, 5'er Hertz'lik aralıklarda olmak üzere band geçiren filtre kullanarak içerdikleri veri miktarları açısından analiz edildi. Her frekans aralığı için, o frekans aralığında elektrot başına ne kadar bilgi toplandığını analiz eden Naive-bilgi-toplamı analizi yapıldı. Bu analizler tüm hareketler için, band geçiren filtre ile ve tüm frekanslar için ayrı ayrı yapılarak değerlendirilmiştir.

5 parmak hareketleri motor korteksin belli bir bölgesinden (tüm hareketler için birbirine çok yakın bölgeler) kaynaklanmaktadır. Bu sebeple yukarıda ERP sonuçları verilen 5 parmak hareketleri için frekans analizleri üzerinde durulmuştur. **Şekil 35**'de bu analizlere ait grafikler ve değerlendirilmeleri verilmiştir. Grafiklerde yatay eksen kanalları, dikey eksen ise bilgi miktarını göstermektedir.

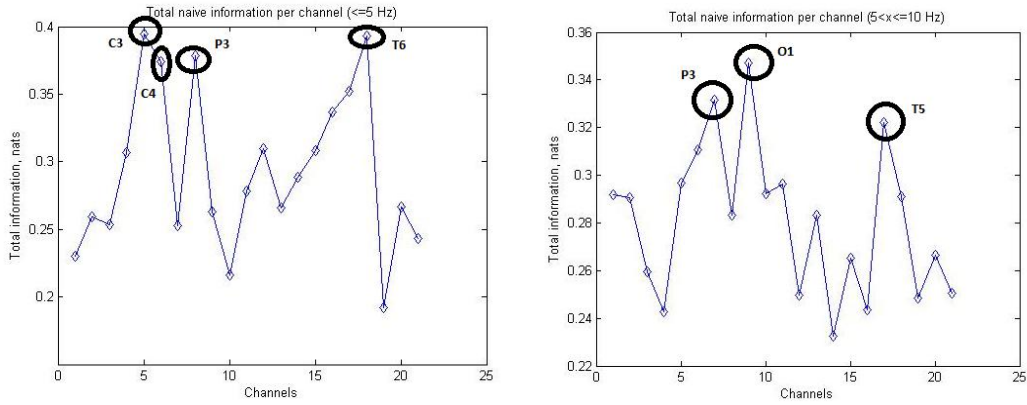
5 parmak hareketleri motor korteksin belli bir bölgesinden(tüm hareketler için birbirine çok yakın bölgeler) kaynaklanmaktadır. Bu sebeple **Şekil 35**'deki ERP sonuçları verilen 5 parmak hareketleri için frekans analizleri üzerinde durulmuştur. **Şekil 34**'de bu analizlere ait grafikler ve değerlendirilmeleri verilmiştir. Grafiklerde yatay eksen kanalları, dikey eksen ise bilgi miktarını göstermektedir. Ancak **Şekil 34**'de verilen grafiklerdeki dikey ölçekte belirtilen bilgi miktarları tüm frekanslardaki verilerin geçerli elektrotlar üzerindeki toplam bilgi miktarları oldukları için güvenilmezler.



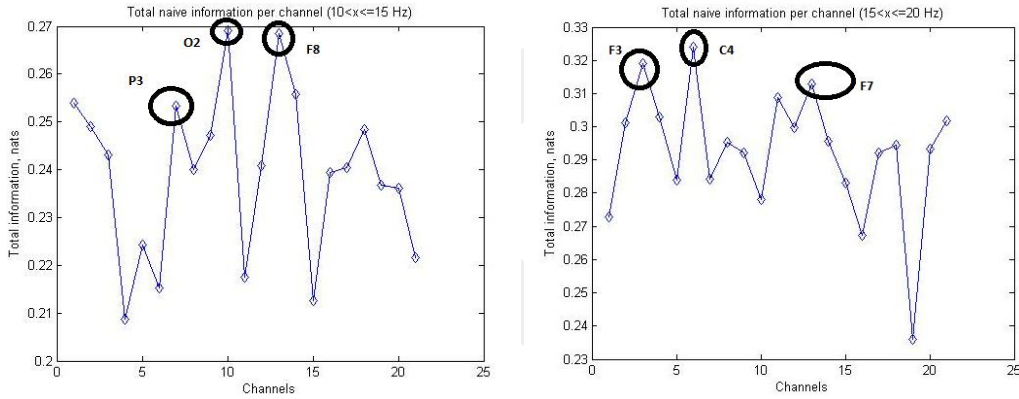
Şekil 34. Sırasıyla (soldan sağa) frekans başına bilgi miktarı ve tüm frekanslarda kanal başına toplam bilgi miktarı



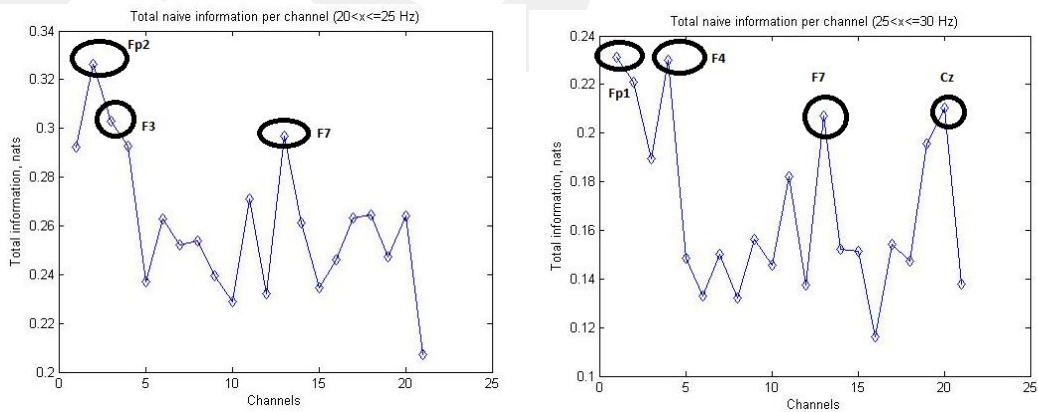
Şekil 35. Standart şapka 5 parmak deneyi ERP analiz örnekleri




Şekil 36. Sırasıyla EEG standart şapka 5 parmak deneyi için 5Hz'den düşük ve $5 < f < 10$ Hz frekanslarda kanalların içerdikleri bilgi miktarını gösterir. Soldaki grafikte ($f < 5\text{ Hz}$) C3 0,39nats, C4 0,37nats, P3 0,38nats ve T6 0,39nats bilgi içermektedirler. Sağdaki grafikte ($5 < f < 10\text{ Hz}$) P3 0,33nats, O1 0,35nats ve T5 0,32 nats bilgi içermektedirler



Şekil 37. Sırasıyla EEG standart şapka 5 parmak deneyi için $10 < f < 15\text{ Hz}$ ve $15 < f < 20\text{ Hz}$ frekanslarda kanalların içerdikleri bilgi miktarını gösterir. Soldaki grafikte ($10 < f < 15\text{ Hz}$) P3 0,25nats, O2 0,27nats ve F8 0,26 nats bilgi içermektedirler. Sağdaki grafikte ($15 < f < 20\text{ Hz}$) F3 0,33nats, C4 0,32nats ve F7 0,31nats bilgi içermektedirler.



Şekil 38. Sırasıyla EEG standart şapka 5 parmak deneyi için $20 < f < 25\text{ Hz}$ ve $25 < f < 30\text{ Hz}$ frekanslarda kanalların içerdikleri bilgi miktarını gösterir. Soldaki grafikte ($20 < f < 25\text{ Hz}$) Fp2 0,33 nats, F3 0,31nats ve F7 0,30 nats bilgi içermektedirler. Sağdaki grafikte ($25 < f < 30\text{ Hz}$) Fp1 0,23nats, F4 0,23 nats, F7 0,21nats ve Cz 0,21 nats bilgi içermektedirler.



Şekil 39. EEG standart şapka 5 parmak deneyi için DVM eğitim sonuçları örnekleri. Burada öğrenme %30'dan %50'ye yükselmiştir

Analizden de anlaşılacağı üzere farklı frekanslarda aynı kanalların içerdiği bilgiler açısından farklı sonuçlar elde edilmiştir. Bu da göstermektedir ki ölçülmek istenilen sinyale göre frekans aralığı belirlenip ölçüm yapılarak istenilen bilgiye daha rahat ulaşılabilir.

Şekil 34, 36-38'de verilen verilere göre 5 parmak hareketlerinin yoğunlaştığı frekans aralığı 0-5Hz'dir. Ayrıca belli elektrotlarda yüksek bilgi ölçümü gözlemlenmiştir. 5 parmak ile yapılacak olan BCI uygulamasında 0-5Hz aralığını ölçecek şekilde EEG cihazında "Low-pass filtre" kullanılarak daha verimli uygulamalar yapılabilir.

4.6.5 BBA Uygulamasında Belli Elektrotlardan Daha Fazla Bilgi Elde Edilebilir mi?

Standart EEG şapkasında iki hareket (sağ/sol el) ile yapılan uygulamalarda C3/C4 elektrotlarından yeterli bilgiler alınabildiği, daha farklı hareketlerde ise bu iki elektrotun yeterli olmadığı yukarıda belirtilmişti. Bu sebeple tüm elektrotlarda analizler yapmak gerekmektedir. O halde hangi elektrotların bu analize dahil edilmesi gerekmektedir?

Analiz için, yukarıda tartışılmış olan harekete dair sinyallerin birbirine yakın bölgelerden kaynaklanması sebebiyle yine standart şapka 5 parmak uygulaması üzerinde durulmuştur. Yukarıda frekans analizinde de yapıldığı gibi motor korteksin dar bir bölgesinden elde edilecek sinyaller arasında ayırım yapabilecek bilgileri analiz ederek belli elektrotlarda bilgi yoğunluğu olup olmadığı belirlenebilir. Bu araştırmaya için Şekil 40'da verilen "birer-kanal-ekle" ve "birer-kanal-çıkart" programımızın basamakları kullanılmıştır. Bu basamaklar yardımıyla elektrotlar BBA sınıflandırıcısının performansını etkileyecek şekilde sıralamaya konulmaktadır. Aşağıda örnek bir analiz sonucu verilmiştir.

ftr_out1ch :

Columns 1 through 8

18.0000	9.0000	21.0000	13.0000	3.0000	4.0000	20.0000	10.0000
0.3444	0.3769	0.3989	0.4226	0.4372	0.4767	0.4870	0.4734
0.3333	0.4545	0.3485	0.5152	0.5152	0.4697	0.4697	0.5455

Columns 9 through 16

19.0000	14.0000	11.0000	7.0000	6.0000	12.0000	2.0000	5.0000
0.4794	0.4751	0.5281	0.5220	0.4724	0.4911	0.4918	0.5140
0.4848	0.5000	0.5303	0.4242	0.5758	0.5000	0.5152	0.5152

Columns 17 through 21

1.0000	8.0000	15.0000	16.0000	17.0000
0.5160	0.4606	0.5000	0.5000	0.4162
0.4848	0.4697	0.5152	0.4545	0.3788

ftr_in1ch :

Columns 1 through 8

8.0000	9.0000	15.0000	6.0000	1.0000	18.0000	4.0000	13.0000
0.3387	0.4094	0.4955	0.4500	0.4762	0.5426	0.5000	0.5464
0.2436	0.3462	0.3974	0.4615	0.4487	0.4872	0.4487	0.5000

Columns 9 through 16

7.0000	16.0000	17.0000	20.0000	21.0000	19.0000	3.0000	12.0000
0.5137	0.5275	0.5057	0.5521	0.5155	0.5114	0.5254	0.4444
0.4487	0.4487	0.4359	0.5000	0.4103	0.4872	0.4487	0.4103

Columns 17 through 21

2.0000	5.0000	10.0000	14.0000	11.0000
0.4811	0.4689	0.5200	0.4746	0.4171
0.3974	0.4359	0.4487	0.5385	0.5256

Şekil 40. Standart şapka 5 parmak deneyi “birer-kanal-ekle” ve “birer-kanal-çıkart” uygulama basamağı sonuçları.

“Birer-kanal-ekle” BBA uygulamasının performansını etkileme açısından en yüksekten en aza doğru sıralayan ve “birer-kanal-çıkart” BBA uygulamasının performansını etkileme açısından en azdan en yükseğe doğru analiz ederek sondan başa doğru sıralayan program basamaklarıdır. Program basamakları uygulaması sonucunda ilk üç elektrot olarak sırasıyla uygulama başına en yüksekten en aza doğru sonuçlar P4, O1,T3 ve T6,O1, Pz elektrotları çıkmıştır,(**Şekil 40**). Bu analiz bir deneğin standart şapka parmak deneyi sonucu elde edilmiştir. Diğer deneklerde de buna benzer sonuçlar elde edilmiştir.

Bu sonuçlar dahilinde O1 elektrotunda kesin olarak en yüksek veri olduğu söylenebilir. Ancak ikinci bir elektrot için P4 ve T6 elektrotları aynı sırada çıkmıştır. Bu sebeple 3. maddede yapmış olduğumuz frekansa göre kanal başına veri analizinden ve ERP grafiklerinden yararlanılabilir.

Tablo 31'de hem frekans açısından hem ERP analizlerindeki ayrımlardan hem de “birer-kanal-ekle” ve “birer-kanal-çıkart” program basamakları açısından veri birikimi en yüksek olan elektrotlar verilmiştir. Bu tabloda ilk sütunda ERP analizlerinde hareket eğrilerinin sinyallerinin en iyi pik yaptığı ve birbirinden en iyi şekilde ayrıldığı kanallar, ikinci sütunda frekans aralıkları, üçüncü sütunda ikinci sütundaki frekans aralıklarına göre en fazla bilgi içeren elektrotlar içerdikleri bilgi miktarlarıyla birlikte ve dördüncü sütunda “birer-kanal-ekle” ve “birer-kanal-çıkart” program basamakları ile yapılan analiz sonucunda BBA uygulaması için en verimli olacak elektrotlar sırayla verilmiştir.

Tablo 31. Frekans, ERP analizleri sinyal ayrımı ve “ftr_in1ch” / “ftr_out1ch” program basmakları ile yapılan analiz sonuçları


ERP	Frekans aralıklarına göre bilgi miktarları		“birer-kanal-ekle” ve “birer-kanal-çıkart” uygulama sonuçları
6,9,13,17,18,21	<5	C3 0,39nats, C4 0,37nats, P3 0,38nats ve T6 0,39nats	ftr_in1ch 8,9,15
	5<f<10	P3 0,33nats, O1 0,35nats ve T5 0,32 nats	
	10<f<15	P3 0,25nats, O2 0,27nats ve F8 0,26)	
	15<f<20	F3 0,33nats, C4 0,32nats ve F7 0,31nats)	ftr_out1ch 18,9,21
	20<f<25	Fp1 0,23nats, F4 0,23 nats, F7 0,21nats ve Cz 0,21nats	
	25<f<30	Fp1 0,23nats, F4 0,23 nats, F7 0,21nats ve Cz 0,21nats	

Bu sonuçlardan yola çıkılarak 5 parmak deneyleri için O1 ve T6 nolu elektrotlarda en fazla veri olduğu söylenebilir. Bu elektrotlardan siyinal analizinde faydalanılabilir.


4.6.6 Elektrotlar Arası Mesafenin Standart 10/20 Sistemindeki Elektrotlar Arası Mesafeden Daha Az Mesafede Yerleştirilmesinin EEG Kaydı Açısından Bir Faydası Var mı?

Standart 10/20 sisteminde elektrotlar belli aralıklarla ve belli bölgelerin üzerine gelecek şekilde yerleştirilir. Bu yerleşim beyin fonksiyonlarının neredeyse tamamının ürettiği sinyallerin ölçülebilmesi için tasarlanmıştır. BCI uygulamalarında ise bu ölçümlerin hepsine ihtiyaç duyulmamaktadır. 5 parmak uygulaması kullanılan BCI çalışması düşünülürse, motor korteks üzerindeki elektrotlar ve eğer ki varsa bilgi yoğunluğu olan elektrotlardan veriler elde edilebilir.



Yukarda yapılan analiz (Tablo 31) düşünülürse O1 ve T6 üzerine yerleştirilecek olan elektrotlar C3 ve C4 elektrotlarından elde edilen verileri destekleyerek BBA uygulamasında kullanılabilir. Geri kalan elektrotlar da veri yoğunluğu tespit edilen O1 ve T6 elektrotları etrafında yoğunlaştırılabilir. Aşağıda O1 ve T6 etrafında yoğunlaştırılarak oluşturulan elektrot dizilim modeli yer almaktadır (Şekil 41). Referans, toprak elektrotlarına ve C3/C4 elektrotlarına dokunulmamıştır. O1 ve T6 simetriğinde bulunan O2 ve T5 elektrotları da sabit kalmıştır. Geri kalan 10 elektrot O1 ve T6 etrafında aşağıdaki modeldeki gibi yoğunlaştırılmıştır.




Şekil 41. Tablo 31'de yapılan analiz sonuçlarına göre modellenmiş yoğunlaştırılmış EEG elektrotları haritası



Şekil 42. Yoğunlaştırılmış elektrot modeli ile yapılan 5F-yoğunlaştırılmış deneyi sonucu elektrotlar arası korelasyon grafiği. Elektrotlar yatay ölçekte önce sol hemisfer sonra sağ hemisfer elektrotları (soldan sağa), dikey ölçekte önce sol hemisfer sonra sağ hemisfer elektrotları (yuvarıdan aşağıya) sıralanmış



Şekil 43. Yoğunlaştırılmış EEG elektrot modeli ile yapılan “5F-yoğunlaştırılmış” deneyi sonucu oluşturulan ERP grafikleri.




Şekil 44. Yoğunlaştırılmış elektrot modeli ile yapılan 5fingerext deneyi sonucu elde edilen SMV grafiği; öğrenme %20'den %50'ye yükselmiştir

Yukarıdaki grafiklerden de anlaşılabilceği (Şekil 42-44) gibi, motor korteks üzerinde bulunan ve standart 10/20 sistemine göre yerini değiştirmedığımız C3/C4 elektrotlarında sinyal görülmektedir. Ancak ayırt edilmesi oldukça zordur. Gene sabit bırakılan O1/2 ve T5/T6 elektrotlarında ayırımın standart modelle neredeyse aynı olduğu gözlenmektedir. Yeni model olarak O1 ve T6 etrafında yoğunlaştırdığımız 1-2-3-4-7-8-13-14-15-16 numaralı elektrotlarda da hareketlerin ayırımı net bir şekilde gözlenmemektedir. Ancak bu elektrotlardaki sinyaller neredeyse birbirinin aynısıdır. DVM eğitim grafikleri (Şekil 39) karşılaştırılınca da öğrenmede elektrot yoğun diziliminin bir farkı olmadığı anlaşılmaktadır. Ayrıca korelasyon grafiğinde de (Şekil 42) yoğun yerleştirilmiş elektrotların birbiri ile korelasyonlarının yüksek olduğu görülmektedir. Buradan yola çıkarak birbirine yakın olarak yerleştirilen elektrotlardan farklı bilgiler elde edilemeyeceği sonucuna varılabilir. Yani burada yoğunlaştırılan elektrotlar yerine tek bir elektrot kullanımı da aynı başarıyı getirebilmektedir.


Standart 10/20 elektrot düzeninde yapılan deneylerde, direk komşu ve bir sonraki komşu elektrotlar arası korelasyonlar ayrıca tarafımızdan hesaplanmıştır (Şekil 45 ve 46). Elektrotlardan alınan BBA ile ilgili bilgi (information) miktarları karşılıklı bilgi yöntemi kullanılarak (Şekil 51) belirlenmiştir. En çok bilgi veren elektrotların bulunduğu bölgelere elektrotlar yoğunlaştırıldıktan sonra yoğunlaştırılmış elektrotlardan beklenen deneyler tekrar edilmiştir. Yoğunlaştırılmış elektrot düzeninde yapılan deneylerin sonuçlarında, 6cm uzaklıktaki elektrotlardan alınan verilerin 5Hz bandında değerlendirilmesinin hala en verimli neticeyi verdiği saptanmıştır.

Buna ek olarak, Şekil 45 ve 46'da gösterilen yeni yapılan korelasyon analizleri kafatasının ortadaki parietal bölgesine yerleştirilen elektrotların birbiriyle daha düşük korelasyona sahip

olması ve öndeki frontal ile arkadaki osipital bölgedeki elektrotların birbiriyle daha yüksek korelasyona sahip olmasına bağlı olarak, EEG BBA elektrot düzenlerinin parietal bölgede daha çok yoğunlaşan, frontal ve osipital bölgede ise daha az yoğunlaşan şekilde oluşturulmasının faydalı olabileceğini ortaya çıkarmıştır. Aynı analizlere göre ve bir önceki ilerleme raporunda elde edilen uzaysal EEG elektrot korelasyon eğrisi ile uyumlu bir şekilde, 2. en yakın elektrotlarla EEG düzenlerde büyük korelasyonlar gözlemlenmektedir yani bu 7-10 cm uzaklıktaki elektrot çiftleri tüm kafatasında korelasyon içinde bulunmaması yeni gösterilmiştir.




Şekil 45. Standart 10/20 elektrot düzeninde direk komşu elektrot arası korelasyonlar (yazarların okunabilmesi için bu resim büyük boyutta biçimlendirilmiştir)



Şekil 46. Standart 10/20 elektrot düzeninde 2. komşu elektrot arası korelasyonlar (yazarların okunabilmesi için bu resim büyük boyutta biçimlendirilmiştir)

4.6.7 Sık Elektrot Yerleştirilmiş Modelde Farklı Frekanslarda EEG Verileri Değişmekte midir?

Yukarıdaki tüm analizler ham EEG sinyali için yapılmış olup, BBA uygulaması eğer belirli bir frekansta odaklanırsa farklı bir sonuç elde etme ihtimali vardır. Bu sebeple frekans analizi aynı şekilde “5F-yoğunlaştırılmış” deneyi için yeni oluşturulmuş EEG yerleşim modeli için de yapılmıştır. Daha önceki analizlerin de gösterdiği üzere en yüksek veri 5Hz'den küçük frekanslarda elde edilmektedir. Aşağıda frekans analizine dair grafik verilmiştir (Şekil 47).




Şekil 47. Yoğunlaştırılmış elektrot modeline göre 5Hz'den küçük frekanslar için kanal başına biriken bilgi miktarını gösterir

Standart 10/20 sistemindeki C3/C4 elektrotlarında 0,38 nats, O1 elektrotunda 0,33nats, O2 elektrotunda 0,39nats, T5 elektrotunda 0,35nats, T6 elektrotunda 0,35 nats veri elde edilmiştir. Yeni modelleme ile yerleştirilmiş ve O1-T6 etrafındaki elektrotlarda gözlenen veri miktarı, 2,3 nolu elektrotlarda 0,4nats, 4,5,6,8,10,13,16,17 nolu elektrotlarda 0,38 nats, 1 nolu elektrotta 0,36 nats, 15 nolu elektrotta ise 0,35 nats, 14 nolu elektrotta 0,31 nats, 7 nolu elektrotta ise 0,27 nats veri elde edilmiştir (**Şekil 47**).


Yeni modellemede en düşük veriler 7 ve 14 numaralı elektrotlardan alınmıştır. Ancak 0,31 ve 0,27 nats olan bu veriler bile yüksek veri içermektedir. Buradan, “5F-yoğunlaştırılmış” deneyi ile gerçekleştirilecek olan BBA uygulaması yoğunlaştırılmış elektrot modeli ile daha başarılı sonuçlar elde edilebilecek gibi gözükmemektedir. Ancak yoğunlaştırılmış olan bölgedeki elektrotlardan alınan veri miktarının ve ERP sinyallerinin neredeyse aynı olduğu gözönüne alınırsa bir bölgede çok elektrot kullanmakla tek elektrot kullanmak arasında anlamlı bir fark oluşmadığı sonucuna varılır.

4.6.8 Elektrotlar Arası Uzaklığın BBA Uygulaması İçin Önemi Nedir?


Uzaklıklara bağlı korelasyon analizimizin baze örneklerimiz aşağıda gösterilmektedir.




Şekil 48. Standart EEG şapkası 5 parmak uygulaması için elektrot-mesafe korelasyon eğrileri



Şekil 49. Standart EEG şapkası sağ/sol el-sağ/sol ayak-dil uygulaması için elektrot-mesafe korelasyon eğrileri



Şekil 50. Standart EEG şapkası elektrotlar arası ortak bilgi (mutual information, sol) ve korelasyon (sağ) matrisleri



Şekil 51. Yoğunlaştırılmış elektrot modeli uygulaması için elektrot-arası korelasyonları (x-eksendeki değerler doğru mesafe değildir)

Yukarıda sırasıyla $\langle r(0,w)r(dx,w) \rangle_T$ formülüne bağlı korelasyon grafiği (**Şekil 48,49,51**), normalize edilmiş korelasyon grafiği (**Şekil 48,49,51**) ve korelasyonların karesi ile elde edilen korelasyon grafiği (**Şekil 48,49,51**) verilmiştir. Tüm korelasyon grafiklerinde renkler frekansı (kırmızı en düşük frekans), yatay eksen ise elektrotlar arası uzaklığı vermektedir. En soldaki $\langle r(0,w)r(dx,w) \rangle_T$ formülüne bağlı korelasyon grafiğinde dikey ölçek mikrovolt cinsinden genli standart sapma, ortadaki normalize edilmiş korelasyon grafiğinde dikey ölçek korelasyon, en sağdaki korelasyon kareleri grafiğinde de dikey ölçek korelasyonların karesini göstermektedir. Bütün grafiklerdeki sinyaller uzaklık ve frekansa bağlıdır.

Grafiklerimizden de anlaşılacağı üzere yapmış olduğumuz analizler sonucunda elektrotlar arası mesafenin 6 cm uzaklıkta en ideal olduğu gözlemlenmektedir. Ayrıca elektrotlar arası korelasyon değerleri de dikkat çekicidir. Frontal lob üzerindeki komşu elektrotlar arası korelasyon ortalama 0,6 değerinde, frontal-parietal loblardaki komşu elektrotlar arası korelasyon ortalama 0,34 değerinde, parietal lob üzerindeki komşu elektrotlar arası korelasyon değeri ortalama 0,40 değerinde, temporal-frontal loblar üzerindeki komşu elektrotlar arası korelasyon değeri ortalama 0,21 değerinde, temporal bölge üzerindeki komşu elektrotlar arası korelasyon değeri ortalama 0,44 değerinde, temporal-central bölge komşu elektrotlar arası korelasyon değeri ortalama 0,25 değerinde, temporal-parietal bölge komşu elektrotlar arası korelasyon değeri 0,54 değerinde, parietal bölge komşu elektrotları arası korelasyon değeri ortalama 0,46 değerinde, central bölge komşu elektrotlar arası korelasyon değeri ortalama 0,20 değerinde, temporal-occipital bölge komşu elektrotları arası korelasyon değeri ortalama 0,54 değerinde, occipital bölge komşu elektrotlar arası korelasyon değeri 0,56 değerinde ve occipital-parietal bölge komşu elektrotları arası korelasyon değeri ortalama 0,51 değerinde hesaplanmıştır, **Şekil 45**.

Elektrotlar arası ilişkiyi açıklayan yukarıdaki değerlere göre en yüksek korelasyon değeri frontal bölge üzerindeki elektrotlar arasındadır. Bunu occipital bölge ve occipital-parietal bölge komşu elektrotları takip etmektedir. Yani bu bölgelerden alınacak olan veriler birbirine yakın veriler olacaktır.

4.6.9 Özet

Özet olarak, yapılan deneyler ve analizler bize göstermektedir ki, 6cm aralığındaki elektrotlarda, 5Hz ve altı frekanslarda alınacak olan veriler ayırt edilebilme ve farklı veriler sağlama açısından BBA uygulaması için en verimli model olacaktır. Bu kapsamda projenin ilerleyen aşamalarında elde ettiğimiz veriler ışığında EEG sinyalinin daha kapsamlı analiz edilebilmesi, zamansal, uzaysal ve zamansal-uzaysal özelliklerin ortaya çıkarılabilmesi için çalışmalar yürütülmüştür.

Senkron Beş Parmak deney modelimiz ile bazı veriler alındı ve analizler devam edilmiştir. Standart 10/20 elektrot düzeninde yapılan deneylerde, direk komşu ve bir sonraki komşu elektrotlar arası korelasyonlar hesaplanmış, ayrıca elektrotlardan alınan BBA ile ilgili bilgi (information) miktarları karşılıklı bilgi yöntemi kullanılarak belirlenmiştir. En çok bilgi veren elektrotların bulunduğu bölgelere elektrotlar yoğunlaştırıldıktan sonra yoğunlaştırılmış elektrotlardan beklenen deneyler tekrar edilmiştir. Yoğunlaştırılmış elektrot düzeninde yapılan deneylerin sonuçlarında 6cm uzaklıktaki elektrotlardan alınan verilerin 5Hz bandında değerlendirilmesinin hala en verimli neticeyi verdiği saptanmıştır.

Buna ek olarak, korelasyon analizleri kafatasının ortadaki parietal bölgesine yerleştirilen elektrotların birbiriyle daha düşük korelasyona sahip olması ve öndeki frontal ile arkadaki osipital bölgedeki elektrotların birbiriyle daha yüksek korelasyona sahip olmasına bağlı olarak, EEG BBA elektrot düzenlerinin parietal bölgede daha çok yoğunlaşan, frontal ve osipital bölgede ise daha az yoğunlaşan şekilde oluşturulmasının faydalı olabileceğini ortaya çıkarmıştır. Aynı analizlere göre ve bir önceki ilerleme raporunda elde edilen uzaysal EEG elektrot korelasyon eğrisi ile uyumlu bir şekilde, 2. en yakın elektrotlarla EEG düzenlerde büyük korelasyonlar gözlemlenmektedir yani bu 7-10 cm uzaklıktaki elektrot çiftleri tüm kafatasında korelasyon içinde bulunmaması gösterilmiştir.

4.7 EEG Sinyali İçin Saklı Markov Model Tabanlı İstatistiksel Modellenme ve Analiz Yaklaşımının Geliştirilmesi

Geliştirilen doğrusal (transfer fonksiyonunun doğrusal olması durumu) ve doğrusal olmayan (transfer fonksiyonunun doğrusal olmaması durumu) HMM'lerin ve kullanılan yöntemlerin EEG sinyallerini açıklamadaki ve EEG sinyallerindeki zihinsel durumları (makro durumlar) tahmin etmedeki başarıları hem yapay EEG verileri için hem de laboratuvarda katılımcılardan elde edilen gerçek EEG verileri için incelenmiştir.

4.7.1 Yapay EEG Verileri Modellenmesi

Denklem (20a) ve Denklem (20b)'de EEG sinyal kaynaklarının sayısı $N_s = 300$ ve elektrot sayısı $N_e = 19$ seçilerek Matlab programı aracılığıyla her bir sezonu 10000 zaman noktasından oluşan 2 sezonlu, 3 ve 6 makro durumlu yapay EEG verileri üretilmiştir. Doğrusal ve doğrusal olmayan HMM'lerin üretilen yapay EEG verilerini açıklamadaki başarı oranlarının, EM yönteminin optimizasyon kısmındaki iterasyon sayısına ve EEG sinyal kaynakları sayısına (N_s) bağlı olarak nasıl değiştiği incelenmiştir. Ayrıca sinyal-gürültü oranının (signal to ratio (SNR)) makro durumların tahmin edilmesindeki hata oranlarını nasıl etkilediği araştırılmıştır.

Doğrusal ve doğrusal olmayan HMM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının iterasyon sayısına göre değişimi **Tablo 32'**de verilmiştir.

Tablo 32. Doğrusal ve doğrusal olmayan HMM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının iterasyon sayısına göre değişimi

İterasyon sayısı	Doğrusal HMM'in başarı performansı (%)	Doğrusal olmayan HMM'in başarı performansı (%)
1	72.54	82.98
11	94.72	95.93
21	96.46	97.18
31	97.26	97.71
41	97.65	98.02
51	97.86	98.25
61	97.97	98.40

İterasyon sayısının artmasıyla birlikte hem doğrusal hem de doğrusal olmayan HMM'lerinin 3 durumlu yapay EEG verisini açıklayabilmesindeki başarı oranlarının arttığı ancak 30 iterasyondan sonra yaklaşık olarak %97 olan başarı oranlarının çok da fazla değişmediği **Tablo 32'**den gözlemlenmektedir. Bunun yanında 60 iterasyon olması durumunda modelin parametrelerinin hesaplanması için gerekli sürenin, 30 iterasyon olması durumunda gerekli olan süreden 2 kat fazla olduğu tespit edilmiştir. Bu nedenle yapay EEG verilerini ve EEG verilerindeki makro durumları açıklamada iterasyon sayısının 30 olarak seçilmesinin yeterli olduğu bulunmuştur.

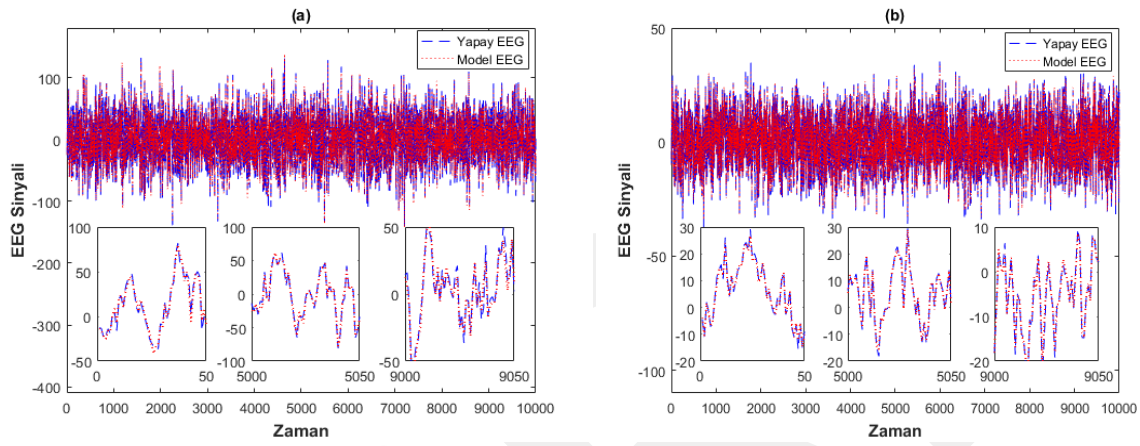
Doğrusal ve doğrusal olmayan HMM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının EEG kaynak sayılarına (N_s) bağlı olarak değişimi **Tablo 33'**de verilmiştir.

Tablo 33. Doğrusal ve doğrusal olmayan HMM'lerinin 3 makro durumlu yapay EEG verilerini açıklamadaki başarı oranlarının EEG kaynak sayılarına (N_s) göre değişimi.(iterasyon sayısı=30).

N_s	Doğrusal HMM'in başarı performansı (%)	Doğrusal olmayan HMM'in başarı performansı (%)
1	73.83	72.64
5	88.88	89.25
10	91.94	93.90
15	95.17	96.47
19	96.61	97.67

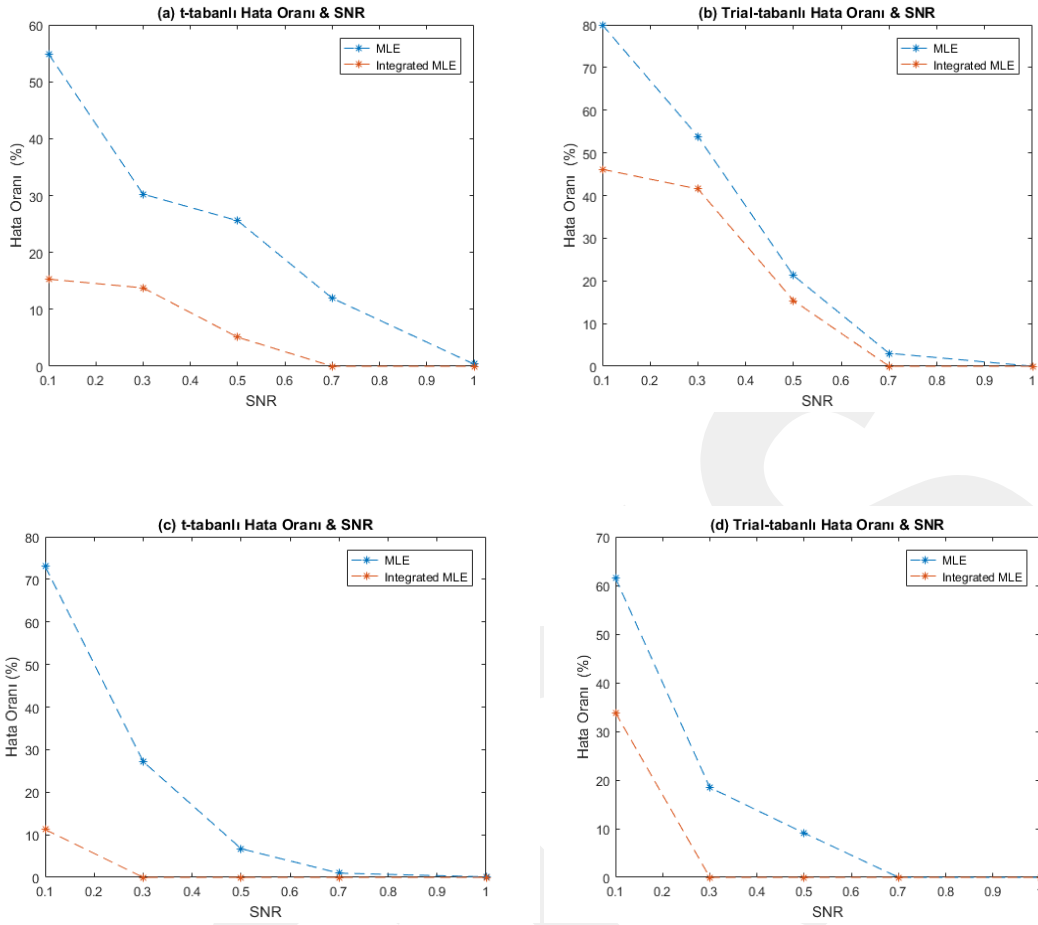
Tablo 33'deki verilere göre kaynak sayısı N_s 'nin artması durumunda doğrusal ve doğrusal olmayan HMM'lerinin 3 makro durumlu yapay EEG verilerini modelleyebilme performansının arttığı görülmektedir. Kaynak sayısı genellikle en fazla elektrot sayısına eşit olarak alınmaktadır bu nedenle burada en fazla 19 olarak seçilmiştir. Bu inceleme sonucunda

doğrusal/doğrusal olmayan HMM'lerinin yapay EEG verilerini iyi açıklayabilmesi için, EEG kaynak sayısının en az $N_s \geq 15$ olması gerektiği bulunmuştur. **Tablo 33'**e ek olarak doğrusal ve doğrusal olmayan HMM'lerin yapay EEG verilerini başarılı bir biçimde modelleyebildiğini ortaya kaymanın bir başka yolu da modelden elde edilen EEG verileri ile yapay EEG verilerinin grafiksel karşılaştırmasını yapmaktır. $N_s = 19$ ve iterasyon sayısı=30 seçiminde modelden elde edilen EEG verileri ile yapay EEG verilerinin grafiksel karşılaştırılması yapılmış ve **Şekil 52'**de gösterilmiştir.

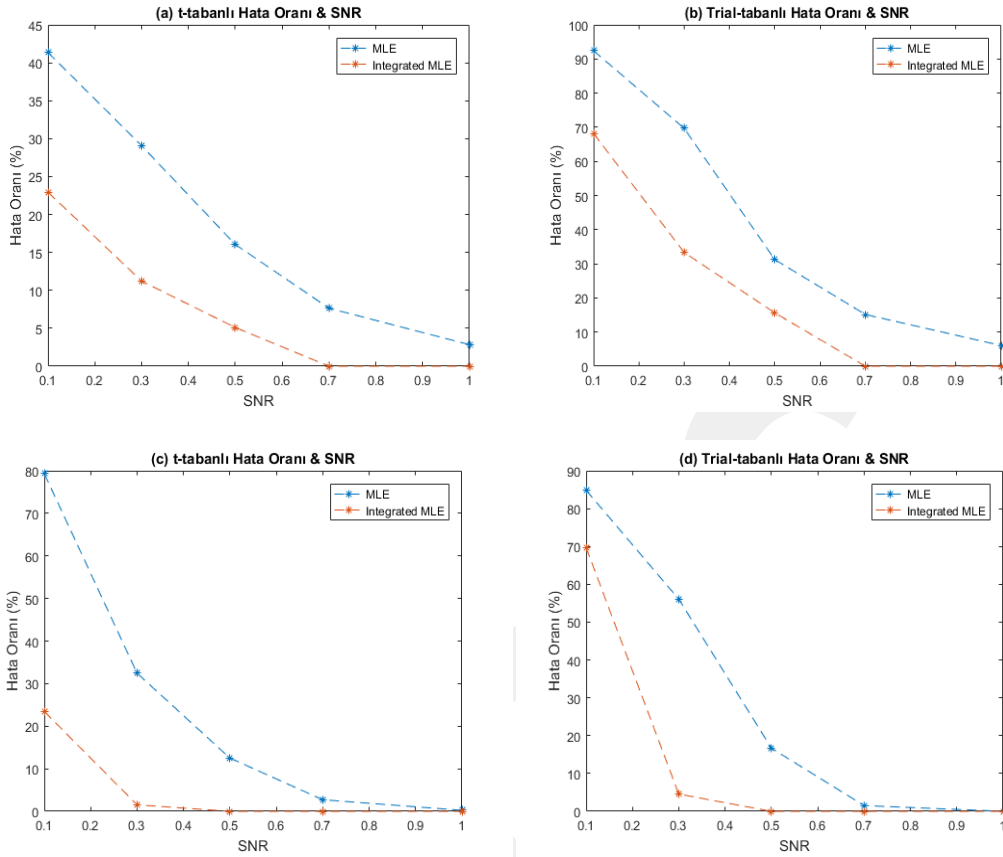


Şekil 52. (a) Doğrusal HMM'den elde edilen EEG verileri ile yapay EEG verilerinin karşılaştırılması. (b) Doğrusal olmayan HMM'den elde edilen EEG verileri ile yapay EEG verilerinin karşılaştırılması.

$N_s = 300$ ve $0.1 \leq SNR \leq 1$ aralığındaki farklı gürültü seviyeleri için doğrusal ve doğrusal olmayan HMM'leri kullanarak üretilen yapay EEG verilerindeki makro durumların tahminindeki t-tabanlı (t-based) ve trial-tabanlı (trial based) hata oranları $N_s = 19$ seçimi ile MLE ve IMLE yöntemleri kullanılarak elde edilmiştir. MLE ve IMLE yöntemlerini kullanarak doğrusal ve doğrusal olmayan HMM'lerinden 3 makro durumu tahmin etmedeki t-tabanlı ve trial-tabanlı hata oranlarının SNR'ye bağlı olarak değişimi **Şekil 53'**de, 6 makro durumun tahminindeki t-tabanlı ve trial-tabanlı hata oranlarının SNR'ye bağlı olarak değişimi ise **Şekil 54'**de gösterilmiştir.



Şekil 53. (a) Doğrusal olmayan HMM'inden 3 makro durumu tahmin etmedeki t -tabanlı hata oranının SNR'ye göre değişimi. (b) Doğrusal olmayan HMM'inden 3 makro durumu tahmin etmedeki trial-tabanlı hata oranının SNR'ye göre değişimi. (c) Doğrusal HMM'inden 3 makro durumu tahmin etmedeki t -tabanlı hata oranının SNR'ye göre değişimi. (d) Doğrusal HMM'inden 3 makro durumu tahmin etmedeki trial-tabanlı hata oranının SNR'ye göre değişimi.



Şekil 54. (a) Doğrusal olmayan HMM'inden 6 makro durumu tahmin etmedeki t-tabanlı hata oranının SNR'ye göre değişimi. (b) Doğrusal olmayan HMM'inden 6 makro durumu tahmin etmedeki trial-tabanlı hata oranının SNR'ye göre değişimi. (c) Doğrusal HMM'inden 6 makro durumu tahmin etmedeki t-tabanlı hata oranının SNR'ye göre değişimi. (d) Doğrusal HMM'inden 6 makro durumu tahmin etmedeki trial-tabanlı hata oranının SNR'ye göre değişimi.

Şekil 53 ve Şekil 54, EEG sinyalindeki yüksek gürültünün ($SNR < 0.3$) makro durumların tahmin edilmesine olumsuz yönde etki ettiğini göstermektedir. Ayrıca bu şekiller, makro durumları tahmin etmede IMLE yönteminin MLE yönteminden daha iyi olduğunu ve doğrusal HMM'inden makro durumları tahmin etme başarısının doğrusal olmayan HMM'ye göre daha fazla olduğunu ortaya koymaktadır. $0.3 \leq SNR \leq 1$ aralığı için yapay EEG verilerindeki hem 3 hem de 6 makro durumu doğrusal HMM'inden IMLE yöntemini kullanarak tahmin etmedeki başarı oranı oldukça yüksektir (%100'e yakın).

4.7.2 Gerçek EEG Verilerinin Modellenmesi ve Analizi

Yapay EEG verileri için yapılan benzer analizler, gerçek EEG verileri için de yapılmıştır. IMLE ve MLE yöntemi kullanılarak doğrusal/doğrusal olmayan HMM'inden zihinsel durumların (modelin makro durumların) tahmin edilip edilemediğini incelemek için 10-20 elektrot yerleşim sisteminde 19 elektrot yardımıyla 12 sağlıklı katılımcıdan toplanan EEG verileri kullanılmıştır. Ancak gerçek EEG verilerini açıklayabilmek için iterasyon sayısının ve EEG

sinyal kaynakları sayısının (N_s) ne olması gerektiğini belirlemek için sadece bir sağlıklı katılımcının EEG verileri kullanılmıştır.

Tablo 34, doğrusal ve doğrusal olmayan HMM'lerinin katılımcı HI'nın 3 (sağ el, sol el ve pasif) ve 6 (sağ ve sol el, sağ ve sol ayak, dil ve pasif) zihinsel durumlu EEG verilerini modelleyebilmekteki başarı oranlarının iterasyon sayılarına göre değişimini göstermektedir. Bu tabloya göre iterasyon sayısının artmasıyla birlikte hem doğrusal hem de doğrusal olmayan HMM'lerinin katılımcı HI'nın 3 ve 6 zihinsel durumlu EEG verisini açıklayabilmesindeki başarı oranlarının arttığı ancak 20 iterasyondan sonra oldukça yavaşlayarak arttığı saptanmıştır. İterasyon sayısının 20 olması durumunda doğrusal ve doğrusal olmayan HMM'lerin katılımcı HI'nın 3 zihinsel durumlu EEG verisini modellemedeki başarı oranı yaklaşık olarak 80-82%, 6 zihinsel durumlu EEG verisini modellemedeki başarı oranları ise yaklaşık olarak 90-92%'dir. İterasyon sayısının 30 olması durumunda doğrusal ve doğrusal olmayan HMM'lerin katılımcı HI'nın 3 zihinsel durumlu EEG verisini modellemedeki başarı oranı yaklaşık olarak 82-86%, 6 zihinsel durumlu EEG verisini modellemedeki başarı oranları ise yaklaşık olarak 92%'dir. Bunun yanında Matlab programının 20 iterasyonlu EM algoritmasını çalıştırıp saklı durum zaman serilerini üretme, parametreleri bulma ve EEG verilerindeki zihinsel durumları tahmin etme süreci yaklaşık olarak 9 saat iken, 30 iterasyon olması durumunda yaklaşık olarak 13 saattir. Söz konusu zaman farkı ve 20 iterasyondan sonraki başarı oranlarındaki yavaş artış dikkate alınarak, gerçek EEG verilerinin modellenmesinde kullanılan iterasyon sayısı 20 olarak belirlenmiştir. Ayrıca doğrusal/doğrusal olmayan HMM'lerin 6 zihinsel durumlu EEG verilerini modelleme başarısının 3 zihinsel durumlu EEG verilerinin modelleme başarısından daha yüksek olduğu **Tablo 34**'den görülmektedir.

Tablo 34. Doğrusal ve doğrusal olmayan HMM'lerinin katılımcı HI'nın 3 ve 6 zihinsel durumlu EEG verilerini açıklamadaki başarı oranlarının iterasyon sayılarına göre değişimi. ($N_s = 19$)

İterasyon Sayısı	Doğrusal HMM		Doğrusal olmayan HMM	
	3 zihinsel durum için başarı performansı (%)	6 zihinsel durum için başarı performansı (%)	3 zihinsel durum için başarı performansı (%)	6 zihinsel durum için başarı performansı (%)
1	34.79	66.61	38.45	73.21
10	75.14	86.60	71.43	91.77
20	81.85	90.00	79.06	92.65
30	86.08	92.78	81.06	92.11

Katılımcı HI'nın 3 zihinsel durumlu EEG verilerini kullanarak doğrusal ve doğrusal olmayan HMM'lerinin bu EEG verilerini modellemedeki başarı oranlarının EEG kaynak sayılarına (N_s) göre değişimi incelenmiş ve sonuçlar **Tablo 35**'de verilmiştir.

Tablo 35. Doğrusal ve doğrusal olmayan HMM'lerinin katılımcı HI'nın 3 zihinsel durumlu EEG verilerini

açıklamadaki başarı oranlarının EEG kaynak sayılarına (N_s) göre değişimi. (iterasyon sayısı=20).

N_s	Doğrusal HMM'in başarı performansı (%)	Doğrusal olmayan HMM'in başarı performansı (%)
1	15.55	03.42
5	54.73	44.91
10	71.70	65.95
15	77.10	73.78
19	81.85	79.06

Tablo 35, doğrusal/doğrusal olmayan HMM'lerinin 3 zihinsel durumlu gerçek EEG verilerini modellemedeki başarı oranlarının EEG kaynak sayısının (N_s) artması durumunda arttığını göstermektedir. Ancak gerçek EEG verilerini modellemedeki başarı oranının 80% ve üzeri olabilmesi için EEG kaynak sayısının $N_s = 19$ olması gerekmektedir.

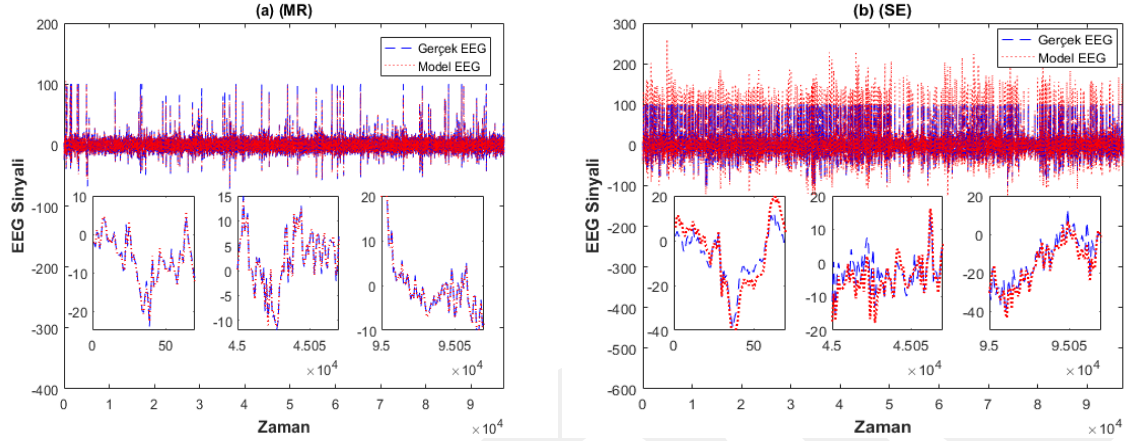
Gerçek EEG verilerini modellemek için iterasyon sayısının 20 ve EEG kaynak sayısının 19 olarak belirlenmesinden sonra, doğrusal ve doğrusal olmayan HMM'lerinin 12 katılımcının 6-zihinsel durumlu EEG verilerini modelleme başarı oranları bulunmuş ve **Tablo 36**'da verilmiştir. Ayrıca MLE ile IMLE yöntemlerinin kullanılmasıyla 6 zihinsel durumun doğrusal/doğrusal olmayan HMM'lerden tahmin edilmesindeki t-tabanlı ve trial-tabanlı hata oranları incelenmiştir.

Tablo 36. Doğrusal ve doğrusal olmayan HMM'lerinin katılımcıların 6-zihinsel durumlu EEG verilerini modelleme başarı oranları

Katılımcı	Doğrusal HMM'nin başarı oranı (%)	Doğrusal olmayan HMM'nin başarı oranı (%)
MR	97.90	98.75
EM	96.57	97.56
ER	94.90	95.80
BA	94.48	95.43
UN	92.57	94.88
YL	91.72	95.59
ES	91.21	95.29
HI	90.00	92.65
ML	89.00	92.79
EK	87.69	93.08
YR	86.72	94.59
SE	85.74	93.69

Tablo 36'daki veriler doğrusal ve doğrusal olmayan HMM'lerinin farklı katılımcıların gerçek EEG verilerini başarılı bir biçimde modelleyebildiğini ortaya koymaktadır. On iki (12) katılımcı için doğrusal HMM'inin gerçek EEG verilerini modelleme başarısı ortalama %91.54 iken, doğrusal olmayan HMM'in gerçek EEG verilerini modelleme başarısı ortalama %95.00'dir. Bu oranlar, doğrusal olmayan HMM'in doğrusal HMM'ine göre gerçek EEG verilerini

modellemede daha başarılı olduğunu göstermektedir. HMM'nin **Tablo 36**'daki en iyi performans ile en kötü performansı destekleyecek grafiksel gösterim **Şekil 55**'de verilmiştir. Bu şekilden **Tablo 36**'daki başarı oranlarını yansıtabilecek biçimde MR katılımcısının EEG verisinin modelden elde edilen EEG verisi ile çok iyi eşleştiği, SE katılımcısının EEG verisinin ise modelden elde edilen EEG verisi ile çok iyi eşleşmediği görülmektedir.



Şekil 55. (a) MR katılımcısının EEG verisi ile HMM'den elde edilen EEG verisinin grafiksel karşılaştırılması. (b) SE katılımcısının EEG verisi ile HMM'den elde edilen EEG verisinin grafiksel karşılaştırılması

Katılımcıların EEG-BCI sinyalindeki farklı zihinsel durumların MLE ve IMLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t-tabanlı ve trial-tabanlı hata oranları hesaplanmış ve sonuçlar MLE için **Tablo 37**'de IMLE için ise **Tablo 38**'de verilmiştir. Bu sonuçlar incelendiğinde MLE yönteminin gerçek EEG-BCI sinyallerindeki zihinsel durumları tahmin etmede başarısız olduğu, IMLE yönteminin ise katılımcılardan sadece YL ve ES'nin EEG-BCI sinyallerindeki zihinsel durumların tahmin edilmesinde başarılı olduğu görülmektedir. Bu iki katılımcı için IMLE yöntemi kullanılarak 3 zihinsel durumu (sağ-sol ayak ve dil) doğrusal HMM'den tahmin etmedeki hem t-tabanlı hem de trial-tabanlı başarı oranı ortalama olarak yaklaşık %85,00 iken doğrusal olmayan HMM'den tahmin etmedeki t-tabanlı ve trial-tabanlı başarı oranı ise ortalama olarak yaklaşık %82,00'dir. Ayrıca 6 zihinsel durumu (sağ-sol el, sağ-sol ayak, pasif ve dil) doğrusal HMM'den tahmin etmedeki t ve trial tabanlı başarı oranı ortalama olarak yaklaşık %70,00 iken doğrusal olmayan HMM'den tahmin etmedeki t ve trial tabanlı başarı oranı ise ortalama olarak yaklaşık %56,00'dir. Katılımcı YL ve ES'nin EEG verilerindeki her bir zihinsel durumun tahmin edilmesindeki hata oranları **Tablo 39** ve **Tablo 40**'da sırasıyla verilmiştir.

Tablo 37. Katılımcıların EEG verilerindeki farklı zihinsel durumlarının MLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları.

Katılımcı	Zihinsel durum Sayısı	Doğrusal HMM		Doğrusal olmayan HMM	
		t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)	t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)
YL	3(sağ-sol el/pasif)	0,8157	0,7927	0,8675	0,8537
	3(sağ-sol ayak/dil)	0,7579	0,6688	0,7005	0,5455
	6	0,7295	0,7327	0,6966	0,7044
ES	3(sağ-sol el/pasif)	0,8441	0,8049	0,8747	0,8171
	3(sağ-sol ayak/dil)	0,7080	0,5417	0,7026	0,4583
	6	0,8197	0,6818	0,7165	0,6494
HI	3(sağ-sol el/pasif)	0,9332	0,9329	0,8856	0,8841
	3(sağ-sol ayak/dil)	0,7513	0,7484	0,8516	0,8581
	6	0,8283	0,8433	0,8171	0,8715
ER	3(sağ-sol el/pasif)	0,9603	0,9571	0,9935	0,9877
	3(sağ-sol ayak/dil)	0,7683	0,7613	0,9248	0,9355
	6	0,7842	0,8616	0,5321	0,9623
EK	3(sağ-sol el/pasif)	0,9191	1,0000	0,9947	0,9167
	3(sağ-sol ayak/dil)	0,8664	0,9286	0,8567	0,8571
	6	0,6114	0,9615	0,4192	0,8846
UN	3(sağ-sol el/pasif)	0,9303	0,9207	0,9363	0,9207
	3(sağ-sol ayak/dil)	0,7326	0,6776	0,7744	0,6382
	6	0,8371	0,8038	0,7849	0,7848
YR	3(sağ-sol el/pasif)	0,9218	0,9207	0,8377	0,8354
	3(sağ-sol ayak/dil)	0,7258	0,7290	0,9441	0,9419
	6	0,8953	0,8276	0,9012	0,8871
ML	3(sağ-sol el/pasif)	0,8418	0,8395	0,7282	0,7284
	3(sağ-sol ayak/dil)	0,9211	0,9211	0,9673	0,9671
	6	0,8646	0,8790	0,9386	0,8439
SE	3(sağ-sol el/pasif)	0,7619	0,7805	0,9191	0,9207
	3(sağ-sol ayak/dil)	0,8934	0,8701	0,9355	0,9416
	6	0,8651	0,8239	0,6716	0,9308
EM	3(sağ-sol el/pasif)	0,8796	0,4918	0,7879	0,7866
	3(sağ-sol ayak/dil)	0,8398	0,1960	0,9455	0,9548
	6	0,8140	0,5192	0,8565	0,8683
MR	3(sağ-sol el/pasif)	0,8899	0,8841	0,9613	0,9634
	3(sağ-sol ayak/dil)	0,8473	0,8065	0,7813	0,7806
	6	0,8691	0,8464	0,8736	0,8764
BA	3(sağ-sol el/pasif)	0,7719	0,7682	0,8217	0,8278
	3(sağ-sol ayak/dil)	0,9172	0,9167	0,9424	0,9524
	6	0,8540	0,8464	0,6112	0,8934

Tablo 38. Katılımcıların EEG verilerindeki farklı zihinsel durumlarının IMLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları.

Katılımcı	Zihinsel durum Sayısı	Doğrusal HMM		Doğrusal olmayan HMM	
		t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)	t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)
YL	3(sağ-sol el/pasif)	0,4815	0,4817	0,5790	0,5793
	3(sağ-sol ayak/dil)	0,1033	0,1039	0,2129	0,2143
	6	0,2976	0,2987	0,4010	0,4025
ES	3(sağ-sol el/pasif)	0,4081	0,4085	0,7375	0,7378
	3(sağ-sol ayak/dil)	0,1793	0,1806	0,1450	0,1458
	6	0,3008	0,3019	0,4596	0,4610
HI	3(sağ-sol el/pasif)	0,8902	0,8902	0,9025	0,9024
	3(sağ-sol ayak/dil)	0,7438	0,7419	0,7245	0,7290
	6	0,8188	0,8182	0,8157	0,8182
ER	3(sağ-sol el/pasif)	0,7850	0,7853	0,7668	0,7669
	3(sağ-sol ayak/dil)	0,7821	0,7806	0,7628	0,7613
	6	0,7836	0,7830	0,7648	0,7642
EK	3(sağ-sol el/pasif)	0,9112	0,9167	0,9938	0,9167
	3(sağ-sol ayak/dil)	0,7119	0,7143	0,6963	0,7143
	6	0,8034	0,8077	0,8329	0,8077
UN	3(sağ-sol el/pasif)	0,6888	0,6890	0,6403	0,6402
	3(sağ-sol ayak/dil)	0,4377	0,4342	0,4182	0,4211
	6	0,5676	0,5665	0,5331	0,5348
YR	3(sağ-sol el/pasif)	0,6892	0,6890	0,7197	0,7195
	3(sağ-sol ayak/dil)	0,8974	0,8968	0,8720	0,8710
	6	0,7907	0,7900	0,7939	0,7931
ML	3(sağ-sol el/pasif)	0,7900	0,7901	0,8702	0,8704
	3(sağ-sol ayak/dil)	0,9022	0,9013	0,7910	0,7961
	6	0,8445	0,8439	0,8317	0,8344
SE	3(sağ-sol el/pasif)	0,7806	0,7805	0,7438	0,7439
	3(sağ-sol ayak/dil)	0,8193	0,8182	0,9741	0,9740
	6	0,7994	0,7987	0,8557	0,8553
EM	3(sağ-sol el/pasif)	0,8050	0,8049	0,6890	0,6890
	3(sağ-sol ayak/dil)	0,7372	0,7419	0,8781	0,8839
	6	0,7719	0,7743	0,7812	0,7837
MR	3(sağ-sol el/pasif)	0,7435	0,7439	0,9512	0,9512
	3(sağ-sol ayak/dil)	0,9615	0,9613	0,6861	0,6839
	6	0,8498	0,8495	0,8219	0,8213
BA	3(sağ-sol el/pasif)	0,8744	0,8742	0,8346	0,8344
	3(sağ-sol ayak/dil)	0,7754	0,7798	0,7872	0,7917
	6	0,8221	0,8245	0,8096	0,8119

Tablo 39. Katılımcı YL'nin EEG verilerindeki farklı zihinsel durumların MLE ve IMLE yöntemleri kullanılarak çizgisel ve çizgisel olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları.

Yöntem	Zihinsel durum	Doğrusal HMM		Doğrusal olmayan HMM	
		t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)	t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)
MLE	Sol El	0,8154	0,8196	0,8517	0,8524
	Sağ El	0,7616	0,7058	0,8093	0,7843
	Pasif	0,8688	0,8461	0,9426	0,9230
	Sol ayak	0,8804	0,8666	0,8326	0,8222
	Sağ ayak	0,9083	0,8431	0,7626	0,6470
	Dil	0,5343	0,3620	0,5459	0,2413
IMLE	Sol El	0,4751	0,4754	0,7543	0,7540
	Sağ El	0,5094	0,5098	0,5092	0,5098
	Pasif	0,4615	0,4615	0,4418	0,4423
	Sol ayak	0,2891	0,2888	0,6887	0,6888
	Sağ ayak	0,0587	0,0588	0,0196	0,0196
	Dil	0,0000	0,0000	0,0169	0,0172

Tablo 40. Katılımcı ES'nin EEG verilerindeki farklı zihinsel durumların MLE ve IMLE yöntemleri kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesindeki t tabanlı ve trial tabanlı hata oranları.

Yöntem	Zihinsel durum	Doğrusal HMM		Doğrusal olmayan HMM	
		t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)	t-tabanlı hata oranı (%)	Trial-tabanlı hata oranı (%)
MLE	Sol El	0,9121	0,8852	0,8460	0,8032
	Sağ El	0,8722	0,8431	0,8995	0,9019
	Pasif	0,7367	0,6730	0,8840	0,7500
	Sol ayak	0,8515	0,8444	0,7410	0,6888
	Sağ ayak	0,7996	0,8000	0,8072	0,7250
	Dil	0,5388	0,1355	0,6039	0,1016
IMLE	Sol El	0,4919	0,4918	0,7704	0,7704
	Sağ El	0,1954	0,1960	0,9022	0,9019
	Pasif	0,5181	0,5192	0,5375	0,5384
	Sol ayak	0,2659	0,2666	0,2441	0,2444
	Sağ ayak	0,2249	0,2250	0,1251	0,1250
	Dil	0,0837	0,0847	0,0837	0,0847

4.7.3 Özet

Özet olarka, makroskobik ölçekteki EEG beyin sinyallerini açıklayabilecek (modelleyebilecek) doğrusal ve doğrusal olmayan HMM'leri geliştirilmiş ve bu modellerin parametrelerini tahmin edebilmek için kullanılan algoritmalar Matlab programı yardımıyla yazılımsal hale getirilmiştir. Ayrıca modelin parametrelerinin kullanılarak EEG-BCI'deki zihinsel durumların MLE ve IMLE

yöntemlerine dayanılarak tahmin edilmesini sağlayacak algoritmalar yazılımsal biçime dönüştürülmüştür. Oluşturulan matematiksel model, algoritma ve yazılımların doğru çalışıp çalışmadığını görebilmek için ilk olarak yapay EEG verileri üzerinde analizler yapılmıştır. Bu Yapay EEG verileri üzerinde yapılan analizler sonucunda doğrusal ve doğrusal olmayan HMM'lerin yapay EEG verilerini yaklaşık olarak 95-100% başarı oranı ile modelleyebildiği gösterilmiştir. Ayrıca yapay EEG verilerindeki makro durumların (zihinsel durum) doğrusal ve doğrusal olmayan HMM'lerden IMLE yöntemi ile tahmin edilmesindeki başarı oranı $0.3 \leq SNR \leq 1$ aralığı için 100% yakın olarak bulunmuştur. Model algoritma ve yazılımların yapay EEG verileri üzerindeki başarısı gösterildikten sonra 12 sağlıklı katılımcıdan elde edilen gerçek EEG verileri üzerinde analizler yapılmıştır. On iki (12) katılımcı için doğrusal HMM'nin gerçek EEG verilerini modelleme başarısı ortalama %91.54 iken, doğrusal olmayan HMM'in gerçek EEG verilerini modelleme başarısının ortalama olarak %95.00 olduğu bulunmuş ve doğrusal olmayan HMM'nin doğrusal HMM'ye göre gerçek EEG verilerini modellemede daha başarılı olduğu gösterilmiştir. Doğrusal/doğrusal olmayan HMM'ler tüm katılımcıların EEG verilerini modellemede yüksek başarı oranları göstermişlerdir. Ancak katılımcıların EEG-BCI sinyalindeki farklı zihinsel durumların MLE ve IMLE yöntemi kullanılarak doğrusal ve doğrusal olmayan HMM'den tahmin edilmesinde MLE yöntemi başarısız olurken, IMLE yöntemi ise sadece YL ve ES katılımcılarının EEG-BCI sinyallerindeki zihinsel durumların tahmin edilmesinde başarılı olmuştur. Bu iki katılımcı için IMLE yöntemi kullanılarak 3 zihinsel durumu (sağ-sol ayak ve dil) doğrusal HMM'den tahmin etmedeki başarı oranı ortalama olarak %85,00, doğrusal olmayan HMM'den tahmin etmedeki başarı oranı ortalama olarak %82,00, 6 zihinsel durumu (sağ-sol el, sağ-sol ayak, pasif ve dil) doğrusal HMM'den tahmin etmedeki başarı oranı ortalama olarak %70,00 ve doğrusal olmayan HMM'den tahmin etmedeki başarı oranı ise ortalama olarak %56,00 bulunmuş ve bu iki katılımcı için doğrusal HMM'nin zihinsel durumların tahmin edilmesinde doğrusal olmayan HMM'ye göre daha başarılı olduğu gösterilmiştir.

5. SONUÇ

Bu çalışmada, elektroensefalografik beyin-makine arayüzleri (EEG BMA) için sistemler ve yöntemler geliştirilmiştir. Deneysel veri toplama, verileri işleme, analiz etme ve sanal robot manipülatör kontrolünde kullanılan etkileşimli online sistem olmak üzere tam bir EEG BMA'ya ait tüm sistem ve süreçler geliştirilmiştir. EEG BMA verisinin analizi ve gerçek zamanlı işlenmesi için, birçok modern Makine Öğrenme tekniklerini destekleyen orijinal yazılım paketi oluşturulmuştur.

Bu gelişme, EEG BBA verilerindeki 6 zihinsel durumun eş zamanlı olarak belirlenmesinde mevcut gelişmişliği kayda değer bir oranla aşarak, offline EEG BBA verilerinin sınıflandırılmasında var olanlardan üstün sonuçlar elde etmemize olanak sağladı. Ayrıca Eşsiz EEG BBA veri kümesi toplanmış ve halka açık bir şekilde yayınlanmıştır.

EEG BBA performansını artırmak için potansiyel konumlar üzerindeki ilgili veriler toplanmıştır. EEG toplama kulaklıklarının fiziksel tasarımı, boyutu ve yoğunluğu için önemli sonuçlar içeren EEG BBA sinyalindeki uzaysal korelasyonlarla ilgili veriler ilk kez toplanmıştır. Saklı kaynakların nörofizyolojik temelli modeline dayanarak EEG sinyalinin zamansal değişkenliğini açıklamak için bir model geliştirilmiştir ve EEG sinyalinin değişkenliğinin önemli bir bölümünü açıklayabildiği gösterilmiştir.

Projenin sonuçları doğrultusunda ulusal ve uluslararası konferanslarda 6 sunum gerçekleştirilmiş ve ulusal ve uluslararası dergilerde 5 adet yayın yapılmış veya yayınlanmak üzere gönderilmiştir. Projenin sonuçlarına dayanan bir yüksek lisans ve bir doktora tezi şu anda yazım aşamasındadır.

6. KAYNAKLAR

- Abdalsalam, E, Yusoff, M Z, Kamel, N, Malik, A S, ve Mahmoud, D. 2017. "Classification of Four Class Motor Imagery for Brain Computer Interface", 9th International Conference on Robotic, Vision, Signal Processing and Power Applications. 297–305.
- Acharya, S, Fifer, M S, Benz, H L, Crone, N E, ve Thakor, N V. 2010. "Electrocorticographic amplitude predicts finger positions during slow grasping motions of the hand", Journal of Neural Engineering, 7(4), 46002.
- Agashe, H A ve Contreras-Vidal, J L. 2013. "Decoding the evolving grasping gesture from electroencephalographic (EEG) activity", 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 5590–5593.
- Agashe, H A ve Contreras-Vidal, J L. 2011. "Reconstructing hand kinematics during reach to grasp movements from electroencephalographic signals", 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 5444–5447.
- Aghaei, A S, Mahanta, M S, ve Plataniotis, K N. 2016. "Separable common spatio-spectral patterns for motor imagery BCI systems", IEEE Transactions on Biomedical Engineering, 63(1), 15–29.
- Ahn, M, Cho, H, Ahn, S, ve Jun, S C. 2013. "High theta and low alpha powers may be indicative of BCI-illiteracy in motor imagery", PLoS ONE, 8(11), 0080886.
- Ahn, M ve Jun, S C. 2015. "Performance variation in motor imagery brain-computer interface: A brief review", Journal of Neuroscience Methods, 243, 103–110.

- Alpaydin, E. 2014a. *Introduction to Machine Learning*.
- Alpaydin, E. 2014b. *Introduction to machine learning*.
- Ang, K K ve Guan, C. 2015. "Brain-Computer Interface for Neurorehabilitation of Upper Limb After Stroke", *Proceedings of the IEEE*, 103(6).
- Ang, K K, Guan, C, Phua, K S, Wang, C, Zhou, L, Tang, K Y, Ephraim Joseph, G J, Kuah, C W K, ve Chua, K S G. 2014. "Brain-computer interface-based robotic end effector system for wrist and hand rehabilitation: results of a three-armed randomized controlled trial for chronic stroke.", *Frontiers in neuroengineering*, 7(July), 30.
- Bansal, A K, Vargas-Irwin, C E, Truccolo, W, ve Donoghue, J P. 2011. "Relationships among low-frequency local field potentials, spiking activity, and three-dimensional reach and grasp kinematics in primary motor and ventral premotor cortices", *Journal of Neurophysiology*, 105(4), 1603–1619.
- Barbosa, A O G, Diaz, D R A, Vellasco, M M B R, Meggiolaro, M A, ve Tanscheit, R. 2009. "Mental Tasks Classification for a Noninvasive BCI Application", *Lecture Notes in Computer Science*, 5769, 495–504.
- Bastos, T F, Muller, S M T, Benevides, A B, ve Sarcinelli-Filho, M. 2011. "Robotic wheelchair commanded by SSVEP, motor imagery and word generation.", *Conference proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*. 4753–4756.
- Bell, C J, Shenoy, P, Chalodhorn, R, ve Rao, R P N. 2008. "Control of a humanoid robot by a noninvasive brain-computer interface in humans.", *Journal of neural engineering*, 5(2), 214–20.
- Benevides, A B, Bastos, T F, ve Sarcinelli-Filho, M. 2011a. "A pseudo-online Brain-Computer Interface with automatic choice for EEG channel and frequency", *2011 IEEE International Symposium on Circuits and Systems*. 81–84.
- Benevides, A B, Bastos, T F, ve Sarcinelli-Filho, M. 2011b. "Proposal of Brain-Computer Interface architecture to command a robotic wheelchair", *2011 IEEE International Symposium on Industrial Electronics*. 2249–2254.
- Benevides, A B, Filho, T F B, ve Sarcinelli-Filho, M. 2012. "Pseudo-Online Classification of Mental Tasks Using Kullback-Leibler Symmetric Divergence", *Journal of Medical and Biological Engineering*, 32(6), 411–416.
- Bigdely-Shamlo, N, Mullen, T, Kothe, C, Su, K-M, ve Robbins, K A. 2015. "The PREP pipeline: standardized preprocessing for large-scale EEG analysis", *Frontiers in Neuroinformatics*, 9(June), 16.

- Blankertz, B, Curio, G, ve Müller, K. 2002. "Classifying Single Trial EEG: Towards Brain Computer Interfacing", *Advances in neural information processing systems*, 1, 157–164.
- Blankertz, B, Dornhege, G, Krauledat, M, Müller, K, ve Curio, G. 2007a. "The non-invasive Berlin Brain – Computer Interface: Fast acquisition of effective performance in untrained subjects", *Neuroimage*, 37, 539–550.
- Blankertz, B, Dornhege, G, Krauledat, M, Müller, K, Kunzmann, V, Losch, F, ve Curio, G. 2006. "The Berlin Brain-Computer Interface: EEG-based communication without subject training", *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, 14(2), 147–152.
- Blankertz, B, Dornhege, G, Krauledat, M, Müller, K-R, ve Curio, G. 2007b. "The Berlin Brain-Computer Interface: Machine learning based detection of user specific brain states", *NeuroImage*, 37(2), 539–550.
- Blankertz, B, Dornhege, G, Krauledat, M, Müller, K-R, Kunzmann, V, Losch, F, ve Curio, G. 2006. "The Berlin Brain–Computer Interface: EEG-Based Communication Without Subject Training", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2), 147–152.
- Blankertz, B, Lemm, S, Treder, M, Haufe, S, ve Müller, K-R. 2011. "Single-trial analysis and classification of ERP components--a tutorial.", *NeuroImage*, 56(2), 814–25.
- Blankertz, B, Losch, F, Krauledat, M, Dornhege, G, Curio, G, ve Müller, K-R. 2008. "The Berlin Brain-Computer Interface: Accurate Performance From First-Session Naive Subjects", *IEEE Trans. on Biomedical Engineering*, 55(10), 2452–2462.
- Blankertz, B, Sannelli, C, Halder, S, Hammer, E M, Kübler, A, Müller, K R, Curio, G, ve Dickhaus, T. 2010. "Neurophysiological predictor of SMR-based BCI performance", *NeuroImage*, 51(4), 1303–1309.
- Bradberry, T J, Gentili, R J, ve Contreras-Vidal, J L. 2011. "Fast attainment of computer cursor control with noninvasively acquired brain signals.", *Journal of neural engineering*, 8(3), 036010.
- Bradberry, T J, Gentili, R J, ve Contreras-Vidal, J L. 2010. "Reconstructing Three-Dimensional Hand Movements from Noninvasive Electroencephalographic Signals", *The Journal of Neuroscience*, 30(9), 3432–3437.
- Breiman, L. 2001. "Random Forests", *Machine Learning*, 45(1), 5–32.
- 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. 2008. "Think to move: A neuromagnetic brain-computer interface (BCI) system for chronic stroke", *Stroke*, 39(3), 910–917.
- Carmena, J M, Lebedev, M A, Crist, R E, O'Doherty, J E, Santucci, D M, Dimitrov, D F, Patil,

- P G, Henriquez, C S, ve Nicoletis, M A L. 2003a. "Learning to control a brain-machine interface for reaching and grasping by primates", *PLoS Biology*, 1(2), 193–208.
- Carmena, J M, Lebedev, M A, Crist, R E, O'Doherty, J E, Santucci, D M, Dimitrov, D F, Patil, P G, Henriquez, C S, ve Nicoletis, M A L. 2003b. "Learning to Control a Brain–Machine Interface for Reaching and Grasping by Primates", *PLoS Biology*, 1(2), e42.
- Chae, Y, Jeong, J, ve Jo, S. 2012. "Toward Brain-Actuated Humanoid Robots: Asynchronous Direct Control Using an EEG-Based BCI", *IEEE Transactions on Robotics*, 28(5), 1131–1144.
- Chae, Y, Jo, S, ve Jeong, J. 2011. "Brain-Actuated Humanoid Robot Navigation Control Using Asynchronous Brain-Computer Interface", *Proceedings of the 5th Int. IEEE EMBS Conf. on Neural Engineering*. 519–524.
- Chapman, R M ve Bragdon, H R. 1964. "Evoked responses to numerical and non-numerical visual stimuli while problem solving", *Nature*, 203, 1155–7.
- Chaudhary, U, Birbaumer, N, ve Ramos-murguialday, A. 2016. "Brain–computer interfaces for communication and rehabilitation", *Nature Reviews Neurology*, (August).
- Chen, X, Wang, Y, Nakanishi, M, Gao, X, Jung, T-P, ve Gao, S. 2015. "High-speed spelling with a noninvasive brain–computer interface", *Proceedings of the National Academy of Sciences*, 112(44), 1–10.
- Cho, H, Ahn, M, Ahn, S, Kwon, M, ve Jun, S. 2017. "EEG datasets for motor imagery brain computer interface.", *Gigascience*.
- Cinar, E ve Sahin, F. 2013. "New classification techniques for electroencephalogram (EEG) signals and a real-time EEG control of a robot", *Neural Computing and Applications*, 22(1), 29–39.
- Cincotti, F, Mattia, D, Aloise, F, Bufalari, S, Schalk, G, Oriolo, G, Cherubini, A, Marciani, M G, ve Babiloni, F. 2008. "Non-invasive brain-computer interface system: towards its application as assistive technology.", *Brain research bulletin*, 75(6), 796–803.
- Cipriani, C, Antfolk, C, Controzzi, M, Lundborg, G, Rosen, B, Carrozza, M C, ve Sebelius, F. 2011. "Online myoelectric control of a dexterous hand prosthesis by transradial amputees", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(3), 260–270.
- Cipriani, C, Segil, J L, Birdwell, J A, ve Weir, R F. 2014. "Dexterous control of a prosthetic hand using fine-wire intramuscular electrodes in targeted extrinsic muscles", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 828–836.
- Clanton, S T, McMorland, A J C, Zohny, Z, Jeffries, S M, Rasmussen, R G, Flesher, S N, Velliste, M, McMorland A JC, Zohny, Z, Jeffries, S M, Rasmussen, R G, Flesher, S N,

- ve Velliste, M. 2013. "Seven Degree of Freedom Cortical Control of a Robotic Arm", *Brain-Computer Research*. 73–81.
- Collinger, J L, Wodlinger, B, Downey, J E, Wang, W, Tyler-Kabara, E C, Weber, D J, McMorland, A J C, Velliste, M, Boninger, M L, ve Schwartz, A B. 2012. "High-performance neuroprosthetic control by an individual with tetraplegia", *The Lancet*, 381(9866), 557–564.
- Contreras-Vidal, J, Presacco, A, Agashe, H, ve Paek, A. 2012. "Restoration of Whole Body Movement", *IEEE Pulse*, (February), 34–37.
- DiGiovanna, J, Mahmoudi, B, Fortes, J, Principe, J C, ve Sanchez, J C. 2009. "Coadaptive Brain - Machine Interface via Reinforcement Learning", *IEEE Transactions on Biomedical Engineering*, 56(1), 54–64.
- Donchin, E, Spencer, K M, ve Wijesinghe, R. 2000. "The mental prosthesis: assessing the speed of a P300-based brain-computer interface", *IEEE TRansactions on Rehabilitation Engineering*, 8(2), 174–9.
- Duda, R O, Hart, P E, ve Stork, D G. 2001. *Pattern Classification*.
- Faller, J, Scherer, R, Costa, U, Opisso, E, Medina, J, ve Müller-Putz, G R. 2014. "A co-adaptive brain-computer interface for end users with severe motor impairment", *PLoS ONE*, 9(7), 1–10.
- Farwell, L A ve Donchin, E. 1988. "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials.", *Electroencephalography and clinical neurophysiology*, 70(6), 510–23.
- Ferreira, A, Bastos-Filho, T F, Sarcinelli-Filho, M, Sánchez, J L M, García, J C G, ve Quintas, M M. 2010. "Improvements of a Brain-Computer Interface Applied to a Robotic Wheelchair", *Communications in Computer and Information Science*, 52, 64–73.
- Fetz, E E. 1969. "Operant conditioning of cortical unit activity", *Science*, 163(3870), 955–8.
- Fetz, E E ve Baker, M A. 1973. "Operantly conditioned patterns on precentral unit activity and correlated responses in adjacent cells and contralateral muscles", *Journal of Neurophysiology*, 36, 179–204.
- Fetz, E E ve Finocchio, D B. 1971. "Operant conditioning of specific patterns of neural and muscular activity", *Science*, 174, 431–5.
- Fetz, E E ve Finocchio, D V. 1972. "Operant conditioning of isolated activity in specific muscles and precentral cells", *Brain Research*, 40, 19–23.
- Forman, G ve Cohen, I. 2004. "Learning from Little: Comparison of Classifiers Given Little Training", *Knowledge Discovery in Databases: PKDD 2004*. 161–172.
- Forney, E M, Anderson, C W, Gavin, W J, Davies, P L, Roll, M C, ve Taylor, B K. 2015.

“Echo State Networks for Modeling and Classification of EEG Signals in Mental-Task Brain-Computer Interfaces”.

- Friedrich, E V C, Mcfarland, D J, Neuper, C, Vaughan, T M, Brunner, P, ve Wolpaw, J R. 2009. “A scanning protocol for sensorimotor rhythm-based brain computer interface”, *Biological Psychology*, 80(2), 169–175.
- Galán, F, Nuttin, M, Lew, E, Ferrez, P W, Vanacker, G, Philips, J, ve Millán, J D R. 2008. “A brain-actuated wheelchair: asynchronous and non-invasive Brain-computer interfaces for continuous control of robots.”, *Clinical neurophysiology*, 119(9), 2159–69.
- Ganguly, K ve Carmena, J M. 2009. “Emergence of a stable cortical map for neuroprosthetic control”, *PLoS Biology*, 7(7).
- Gharabaghi, A, Naros, G, Walter, A, Grimm, F, Schuermeyer, M, Roth, A, Bogdan, M, Rosenstiel, W, ve Birbaumer, N. 2014. “From assistance towards restoration with epidural brain-computer interfacing”, *Restorative Neurology and Neuroscience*, 32(4), 517–525.
- Giuffrida, J P. 2004. *Synergistic neural network control of FES elbow extension after spinal cord injury using EMG*. Case Western Reserve University.
- Giuffrida, J P ve Crago, P E. 2005. “Functional restoration of elbow extension after spinal-cord injury using a neural network-based synergistic FES controller”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 13(2), 147–52.
- Giuffrida, J P ve Crago, P E. 2004. “Utilizing remaining voluntary muscle synergies to control FES elbow extension after spinal cord injury”, *Engineering in Medicine and Biology Society, 2004. IEMBS '04. 26th Annual International Conference of the IEEE*. 4118–21.
- Guger, C, Edlinger, G, Harkam, W, Niedermayer, I, ve Pfurtscheller, G. 2003. “How many people are able to operate an EEG-based brain-computer interface (BCI)?”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 145–147.
- Guger, C, Ramoser, H, ve Pfurtscheller, G. 2000. “Real-time EEG analysis with subject-specific spatial patterns for a brain-computer interface (BCI)”, *IEEE Transactions on Rehabilitation Engineering*, 8(4), 447–456.
- Gupta, N, Gupta, S, Khare, V, Jain, C K, ve Akhter, S. 2008. “An Efficient Model to Decipher the Electroencephalogram Signals Using Machine Learning Approach”, *IFMBE Proceedings*, 21, 782–785.
- Gysels, E ve Celka, P. 2004. “Phase synchronization for the recognition of mental tasks in a brain-computer interface”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 12(4), 406–415.
- Hall, T M, deCarvalho, F, ve Jackson, A. 2014. “A Common Structure Underlies Low-

- Frequency Cortical Dynamics in Movement, Sleep, and Sedation”, *Neuron*, 83(5), 1185–1199.
- Hammon, P S ve De Sa, V R. 2007. “Preprocessing and meta-classification for brain-computer interfaces”, *IEEE Transactions on Biomedical Engineering*, 54(3), 518–525.
- Hastie, T, Tibshirani, R, ve Friedman, J. 2001. *The Elements of Statistical Learning*. Springer.
- Hill, N J, Lal, T N, Schröder, M, Hinterberger, T, Wilhelm, B, Nijboer, F, Mochty, U, Widman, G, Elger, C, Schölkopf, B, Kübler, A, ve Birbaumer, N. 2006. “Training for Fast BCI Implementation : Comparison of”, 14(2), 183–186.
- Hochberg, L R, Bacher, D, Jarosiewicz, B, Masse, N Y, Simeral, J D, Vogel, J, Haddadin, S, Liu, J, Cash, S S, van der Smagt, P, ve Donoghue, J P. 2012. “Reach and grasp by people with tetraplegia using a neurally controlled robotic arm”, *Nature*, 485(7398), 372–375.
- Hochberg, L, Serruya, M, Friehs, G, Mukand, J, Saleh, M, Caplan, A, Branner, A, Chen, D, Penn, R, ve and Donoghue, J. 2006. “Neuronal ensemble control of prosthetic devices by a human with tetraplegia”, *Nature*, 442, 164–171.
- Hong, K S, Naseer, N, ve Kim, Y H. 2015. “Classification of prefrontal and motor cortex signals for three-class fNIRS-BCI”, *Neuroscience Letters*, 587, 87–92.
- Hwang, H, Kwon, K, ve Im, C. 2009. “Neurofeedback-based motor imagery training for brain-computer interface (BCI)”, *Journal of Neuroscience Methods*, 179(1), 150–6.
- Iversen, I H, Ghanayim, N, Kuebler, A, Neumann, N, Birbaumer, N, ve Kaiser, J. 2008. “A brain-computer interface tool to assess cognitive function in completely paralyzed patients with amyotrophic lateral sclerosis”, *Clinical Neurophysiology*, 119(10), 2214–23.
- Jeunet, C, Nkaoua, B, Subramanian, S, Hachet, M, ve Lotte, F. 2015. “Predicting Mental Imagery-Based BCI Performance from Personality, Cognitive Profile and Neurophysiological Patterns”, *PLoS ONE*, 10(12), 1–21.
- Jia, W, Zhao, X, Liu, H, Gao, X, Gao, S, ve Yang, F. 2004. “Classification of single trial EEG during motor imagery based on ERD”, *IEMBS '04. 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 5–8.
- Jiang, N, Vest-Nielsen, J, Muceli, S, ve Farina, D. 2011. “EMG-based Simultaneous and Proportional Estimation of Wrist Kinematics and its Application in Intuitive Myoelectric Control for Unilateral transradial Amputees”, *Front. Comput. Neurosci. Conference Abstract: BC11: Computational Neuroscience & Neurotechnology Bernstein Conference & Neurex Annual Meeting 2011*. doi: 10.3389/conf.fncom.2011.53.00081.
- Jurcak, V, Tsuzuki, D, ve Dan, I. 2007. “10/20, 10/10, and 10/5 Systems Revisited: Their

- Validity As Relative Head-Surface-Based Positioning Systems.”, *NeuroImage*, 34(4), 1600–11.
- Kaper, M, Meinicke, P, Grossekhoefer, U, Lingner, T, ve Ritter, H. 2004. “BCI competition 2003-data set iib: support vector machines for the p300 speller paradigm”, *IEEE Trans. on Biomedical Engineering*, 51, 1073–1076.
- Kaya, M, Binli, M K, Ozbay, E, Yanar, H, ve Mishchenko, Y. 2017. “A large motor imagery dataset for data analysis in EEG-based brain computer interfaces”, Preprint.
- Kim, S-P, Sanchez, J C, Rao, Y N, Erdogmus, D, Carmena, J M, Lebedev, M a, Nicoletis, M a L, ve Principe, J C. 2006. “A comparison of optimal MIMO linear and nonlinear models for brain-machine interfaces.”, *Journal of neural engineering*, 3(2), 145–161.
- Krauledat, M, Tangermann, M, Blankertz, B, ve Muller, K. 2008. “Towards Zero Training for Brain-Computer Interfacing”, *PloS one*, 3(8), e2967.
- Kryger, M, Wester, B, Pohlmeier, E A, Rich, M, John, B, Beaty, J, McLoughlin, M, Boninger, M, ve Tyler-Kabara, E C. 2016. “Flight simulation using a Brain-Computer Interface: A pilot, pilot study.”, *Experimental neurology*, 287, 473–478.
- Kubánek, J, Miller, K J, Ojemann, J G, Wolpaw, J R, ve Schalk, G. 2009. “Decoding flexion of individual fingers using electrocorticographic signals in humans.”, *Journal of neural engineering*, 6(6), 66001.
- Kuiken, T A, Li, G, Lock, B A, Lipschutz, R D, Miller, L A, Stubblefield, K A, ve Englehart, K B. 2009. “Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms”, *Jama*, 301(6), 619–628.
- Kwak, N-S, Müller, K-R, ve Lee, S-W. 2015. “A lower limb exoskeleton control system based on steady state visual evoked potentials”, *Journal of Neural Engineering*, 12(5), 56009.
- Lebedev, M A, Carmena, J M, O’Doherty, J E, Zacksenhouse, M, Henriquez, C S, Principe, J C, ve Nicoletis, M A L. 2005. “Cortical Ensemble Adaptation to Represent Velocity of an Artificial Actuator Controlled by a Brain-Machine Interface”, *Journal of Neuroscience*, 25(19), 4681–4693.
- Lebedev, M a ve Nicoletis, M a L. 2006. “Brain-machine interfaces: past, present and future.”, *Trends in Neurosciences*, 29(9), 536–46.
- Lemm, S, Blankertz, B, Dickhaus, T, ve Müller, K R. 2011. “Introduction to machine learning for brain imaging”, *NeuroImage*, 56(2), 387–399.
- Li, M ve Pan, J. 2011. “An Effective Classification Approach for EEG-based BCI System”, 2011 Sixth International Conference on Image and Graphics. 897–901.
- Lin, C T, Chang, C J, Lin, B S, Hung, S H, Chao, C F, ve Wang, I J. 2010. “A real-time wireless brain-computer interface system for drowsiness detection”, *IEEE Transactions*

- on Biomedical Circuits and Systems, 4(4), 214–222.
- Lin, S. 2010. “Rank aggregation methods”, Wiley Interdisciplinary Reviews: Computational Statistics, 2(5), 555–570.
- Liu, B, Wang, M, ve Liu, Z. 2005. “Identification and classification of finger movement based on EEG”, IEEE-EMBS 2005. 27th Annual International Conference of the Engineering in Medicine and Biology Society. 5408–5411.
- Lopez-Larraz, E, Iturrate, I, Montesano, L, ve Minguez, J. 2010. “Real-time recognition of feedback error-related potentials during a time-estimation task”, 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. 2670–2673.
- Lotte, F. 2014. “A Tutorial on EEG Signal-processing Techniques for Mental-state Recognition in Brain–Computer Interfaces”, Guide to Brain-Computer Music Interfacing, 133–161.
- Lotte, F, Congedo, M, Lecuyer, A, Lamarche, F, Arnaldi, B, L{e}cuyer, A, Lamarche, F, ve Arnaldi, B. 2007. “A review of classification algorithms for EEG-based brain–computer interfaces”, Journal of Neural Engineering, 4(2), R1–R13.
- MacKay, D. 2003. *Information Theory, Inference and Learning Algorithms*. Cambridge University Press.
- Makeig, S ve Onton, J. 2009. “ERP features and EEG dynamics: an ICA perspective”, Oxford Handbook of Event-Related Potential Components. New York, NY.
- Malmivuo, J ve Plonsey, R. 1995. “Electroencephalography”, Bioelectromagnetism.
- Matrone, G C, Cipriani, C, Carrozza, M C, ve Magenes, G. 2012. “Real-time myoelectric control of a multi-fingered hand prosthesis using Principal Components Analysis”, Journal of neuroengineering and rehabilitation, 9, 40.
- Mayaud, L, Filipe, S, Pétégnief, L, Rochecouste, O, ve Congedo, M. 2013. “Robust Brain-computer Interface for virtual Keyboard (RoBIK): Project results”, IRBM, 34(2), 131–138.
- McFarland, D J, Krusienski, D J, Sarnacki, W a, ve Wolpaw, J R. 2008. “Emulation of computer mouse control with a noninvasive brain-computer interface.”, Journal of neural engineering, 5(2), 101–110.
- McFarland, D J, Sarnacki, W a, ve Wolpaw, J R. 2010. “Electroencephalographic (EEG) control of three-dimensional movement”, Journal of Neural Engineering, 7(3), 036007.
- McFarland, D J ve Wolpaw, J R. 2008. “Brain-Computer Interface Operation of Robotic and Prosthetic Devices”, Computer, 41(10), 52–56.
- McFarland, D J ve Wolpaw, J R. 2010. “Brain–Computer Interfaces for the Operation of Robotic and Prosthetic Devices”, Advances in computers, 79(10), 169–187.
- Mcfarland, D J ve Wolpaw, J R. 2008. “Sensorimotor rhythm-based brain-computer interface

- (BCI): model order selection for autoregressive spectral analysis”, *Journal of Neural Engineering*, 5(2), 155–162.
- Mishchenko, Y, Kaya, M, Ozbay, E, ve Yanar, H. 2017. “Developing a 3- to 6-state EEG-based brain-computer interface for a robotic manipulator control”, *BioRxiv* 171025.
- Miyawaki, Y, Uchida, H, Yamashita, O, Sato, M, Morito, Y, Tanabe, H C, Sadato, N, ve Kamitani, Y. 2008. “Visual Image Reconstruction from Human Brain Activity using a Combination of Multiscale Local Image Decoders”, *Neuron*, 60(5), 915–929.
- Mollazadeh, M, Aggarwal, V, Davidson, a. G, Law, a. J, Thakor, N V, ve Schieber, M H. 2011. “Spatiotemporal Variation of Multiple Neurophysiological Signals in the Primary Motor Cortex during Dexterous Reach-to-Grasp Movements”, *Journal of Neuroscience*, 31(43), 15531–15543.
- Müller, S M T, Celeste, W C, Bastos-filho, T F, ve Sarcinelli-Filho, M. 2010. “Brain-computer Interface Based on Visual Evoked Potentials to Command Autonomous Robotic Wheelchair”, *Journal of Medical and Biological Engineering*, 30(6), 407–416.
- Müller-Gerking, J, Pfurtscheller, G, ve Flyvbjerg, H. 1999. “Designing optimal spatial filters for single-trial EEG classification in a movement task”, *Clinical Neurophysiology*, 110(5), 787–798.
- Musallam, S, Corneil, B D, Greger, B, Scherberger, H, ve Andersen, R A. 2004. “Cognitive Control Signals for Neural Prosthetics”, *Science*, 305, 258–263.
- Nishimoto, S, Vu, A T, Naselaris, T, Benjamini, Y, Yu, B, ve Gallant, J L. 2011. “Reconstructing Visual Experiences from Brain Activity Evoked by Natural Movies”, *Current Biology*, 21(19), 1641–6.
- Obermaier, B, Neuper, C, Guger, C, ve Pfurtscheller, G. 2001. “Information transfer rate in a five-classes brain-computer interface”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(3), 283–288.
- Orsborn, A L, Dang, S, Moorman, H G, ve Carmena, J M. 2012. “Closed-Loop Decoder Adaptation on Intermediate Time-Scales Facilitates Rapid BMI Performance Improvements Independent of Decoder Initialization Conditions”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(4), 468–477.
- Oshiro, T M, Perez, P S, ve Baranauskas, J A. 2012. “How Many Trees in a Random Forest?”, *MLDM*. 154–168.
- Paek, A Y, Agashe, H a, ve Contreras-Vidal, J L. 2014. “Decoding repetitive finger movements with brain activity acquired via non-invasive electroencephalography.”, *Frontiers in neuroengineering*, 7(March), 3.
- Pailla, T, Jiang, W, Dichter, B, Chang, E F, ve Gilja, V. 2016. “ECoG Data Analyses to Inform

- Closed-loop BCI Experiments for Speech-based Prosthetic Applications .”, 5713–5716.
- Palaniappan, R ve Raveendran, P. 2001. “Cognitive task prediction using parametric spectral analysis of eeg signals”, *Malaysian Journal of Computer Science*, 14(1), 58–67.
- Pei, X, Barbour, D L, Leuthardt, E C, ve Schalk, G. 2011. “Decoding vowels and consonants in spoken and imagined words using electrocorticographic signals in humans.”, *Journal of Neural Engineering*, 8(4), 046028.
- Peng, H, Long, F, ve Ding, C. 2005. “Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy.”, *IEEE transactions on pattern analysis and machine intelligence*, 27(8), 1226–1238.
- Perge, J A, Zhang, S, Malik, W Q, Homer, M L, Cash, S, Friehs, G, Eskandar, E N, Donoghue, J P, ve Hochberg, L R. 2014. “Reliability of directional information in unsorted spikes and local field potentials recorded in human motor cortex”, *Journal of Neural Engineering*, 11(4), 46007.
- Perrin, X, Chavarriaga, R, Colas, F, Siegwart, R, ve Millán, J D R. 2010. “Brain-coupled interaction for semi-autonomous navigation of an assistive robot”, *Robotics and Autonomous Systems*, 58(12), 1246–1255.
- Pfurtscheller, G, Müller, G R, Pfurtscheller, J, Gerner, H J, ve Rupp, R. 2003. “‘Thought’ - Control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia”, *Neuroscience Letters*, 351(1), 33–36.
- Piccione, F, Giorgi, F, Tonin, P, Priftis, K, Giove, S, Silvoni, S, Palmas, G, ve Beverina, F. 2006. “P300-based brain computer interface: reliability and performance in healthy and paralysed participants”, *Clinical Neurophysiology*, 117(3), 531–7.
- Pihur, V, Datta, S, ve Datta, S. 2009. “RankAggreg, an R package for weighted rank aggregation”, *BMC Bioinformatics*, 10(1), 62.
- Pistohl, T, Schulze-Bonhage, A, Aertsen, A, Mehring, C, ve Ball, T. 2012. “Decoding natural grasp types from human ECoG”, *NeuroImage*, 59(1), 248–260.
- QiBin, Z, LiQing, Z, ve Cichocki, A. 2009. “EEG-based asynchronous BCI control of a car in 3D virtual reality environments”, *Chinese Science Bulletin*, 54(1), 78–87.
- Resnik, L, Latief, G, Sasson, N, Smurr-Walters, L, ve Borgia, M. 2014. “Self-reported and performance-based outcomes using DEKA Arm”, *JRRD Volume 51, Number 3, 2014*, 51(3), 351–362.
- Sankai, Y. 2011. “HAL: Hybrid Assistive Limb Based on Cybernetics”, *Robotics Research: The 13th International Symposium ISRR*, 25–34.
- Sannelli, C, Tangermann, M, ve Muller, K. 2008. “Estimating noise and dimensionality in BCI data sets: Towards BCI illiteracy comprehension”, *4th International Brain-Computer*

Interface Workshop and Training Course. 18–20.

- Santhanam, G, Ryu, S I, Yu, B M, Afshar, A, ve Shenoy, K V. 2006. “A high-performance brain-computer interface.”, *Nature*, 442(7099), 195–8.
- Santucci, D M, Kralik, J D, Lebedev, M A, ve Nicolelis, M A L. 2005. “Frontal and parietal cortical ensembles predict single-trial muscle activity during reaching movements in primates”, *European Journal of Neuroscience*, 22(6), 1529–40.
- Schalk, G, Miller, K J, Anderson, N R, Wilson, J A, Smyth, M D, Ojemann, J G, Moran, D W, Wolpaw, J R, ve Leuthardt, E C. 2008. “Two-dimensional movement control using electrocorticographic signals in humans”, *Journal of Neural Engineering*, 5, 75–84.
- Schmidt, E M. 1980. “Single neuron recording from motor cortex as a possible source of signals for control of external devices”, *Annals of Biomedical Engineering*, 8, 339–49.
- Schmidt, E M, McIntosh, J S, Durelli, L, ve Bak, M J. 1978. “Fine control of operantly conditioned firing patterns of cortical neurons”, *Experimental Neurology*, 61(2), 349–69.
- Serruya, M D ve Donoghue, J P. 2003. “Chapter 3: Design Principles of a Neuromotor Prosthetic Device”, *Neuroprosthetics: Theory and Practice*. 1158–96.
- Serruya, M, Hatsopoulos, N, Paninski, L, Fellows, M, ve Donoghue, J. 2002. “Instant neural control of a movement signal”, *Nature*, 416, 141–142.
- Shenoy, P ve Rao, R P N. 2004. “Dynamic Bayesian Networks for Brain-Computer Interfaces”, *Advances in Neural Information Processing Systems*. 1265–1272.
- Sirvent Blasco, J L, Iáñez, E, Úbeda, A, ve Azorín, J M. 2012. “Visual evoked potential-based brain-machine interface applications to assist disabled people”, *Expert Systems with Applications*, 39(9), 7908–7918.
- Sitaram, R, Zhang, H, Guan, C, Thulasidas, M, Hoshi, Y, Ishikawa, A, Shimizu, K, ve Birbaumer, N. 2007. “Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain-computer interface.”, *NeuroImage*, 34(4), 1416–27.
- Soekadar, S R, Witkowski, M, Gómez, C, Opisso, E, Medina, J, Cortese, M, Cempini, M, Carrozza, M C, Cohen, L G, Birbaumer, N, ve Vitiello, N. 2016. “Hybrid EEG/EOG-based brain/neural hand exoskeleton restores fully independent daily living activities after quadriplegia”, *Science Robotics*, 1(1), eaag3296.
- Sur, S ve Sinha, V K. 2009. “Event-related potential: an overview”, *Industrial Psychiatry Journal*, 18(1), 70–73.
- Sutton, S, Braren, M, Zubin, J, ve John, E R. 1965. “Evoked-potential correlates of stimulus uncertainty”, *Science*, 150, 1187–8.
- Sutton, S, Tueting, P, Zubin, J, ve John, E R. 1967. “Information delivery and the sensory

- evoked potential”, *Science*, 155, 1436–9.
- Tangermann, M, Müller, K-R, Aertsen, A, Birbaumer, N, Braun, C, Brunner, C, Leeb, R, Mehring, C, Miller, K, Mueller-Putz, G, Nolte, G, Pfurtscheller, G, Preissl, H, Schalk, G, Schlögl, A, Vidaurre, C, Waldert, S, ve Blankertz, B. 2012. “Review of the BCI Competition IV”, *Frontiers in Neuroscience*, 6, 55.
- Taylor, D M, Tillery, S I H, ve Schwartz, A B. 2002. “Direct cortical control of 3D neuroprosthetic devices”, *Science*, 296(5574), 1829–1832.
- Tenore, F V G, Ramos, A, Fahmy, A, Acharya, S, Etienne-Cummings, R, ve Thakor, N V. 2009. “Decoding of Individuated Finger Movements Using Surface Electromyography”, *IEEE Transactions on Biomedical Engineering*, 56(5), 1427–34.
- Teplan, M. 2002. “Fundamentals of EEG measurement”, *Measurement Science Review*, 2, 1–11.
- Thulasidas, M, Guan, C, ve Wu, J. 2006. “Robust classification of EEG signal for brain-computer interface”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(1), 24–29.
- Tomioka, R ve Müller, K R. 2010. “A regularized discriminative framework for EEG analysis with application to brain-computer interface”, *NeuroImage*, 49(1), 415–432.
- Velliste, M, Perel, S, Spalding, M C, Whitford, A S, ve Schwartz, A B. 2008. “Cortical control of a prosthetic arm for self-feeding.”, *Nature*, 453(7198), 1098–101.
- Vidaurre, C, Krämer, N, Blankertz, B, ve Schlögl, A. 2009. “Time Domain Parameters as a feature for EEG-based Brain-Computer Interfaces”, *Neural Networks*, 22(9), 1313–1319.
- Wang, Y, Zhang, Z, Li, Y, Gao, X, Gao, S, ve Yang, F. 2004. “BCI Competition 2003 - Data set IV: An algorithm based on CSSD and FDA for classifying single-trial EEG”, *IEEE Transactions on Biomedical Engineering*, 51(6), 1081–1086.
- Wessberg, J, Stambaugh, C R, Kralik, J D, Beck, P D, Laubach, M, Chapin, J K, Kim, J, Biggs, S J, Srinivasan, M A, ve Nicolelis, M A L. 2000. “Real-time prediction of hand trajectory by ensembles of cortical neurons in primates.”, *Nature*, 408, 361–5.
- Wilkinson, J. 2009. “Real-time control of wheelchairs with brain waves”, RIKEN BSI-TOYOTA Collaboration Center.
- Wolpaw, J R, Birbaumer, N, McFarland, D J, Pfurtscheller, G, ve Vaughan, T M. 2002. “Brain Computer Interfaces for communication and control”, *Frontiers in Neuroscience*, 4(113), 767–791.
- Wolpaw, J R ve McFarland, D J. 2004. “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans.”, *Proceedings of the National Academy of Sciences of the United States of America*, 101(51), 17849–54.

- Wolpaw, J R, McFarland, D J, Neat, G W, ve Forneris, C A. 1991. "An EEG-based brain-computer interface for cursor control", *Electroencephalography and Clinical Neurophysiology*, 78(3), 252–259.
- Wu, L-W, Liao, H-C, Hu, J-S, ve Lo, P-C. 2008. "Brain-controlled robot agent: an EEG-based eRobot agent", *Industrial Robot: An International Journal*, 35(6), 507–519.
- Wu, W, Chen, Z, Gao, S, ve Brown, E. 2011. "A hierarchical Bayesian approach for learning sparse spatio-temporal decompositions of multichannel EEG", *Neuroimage*, 56(4), 1929–1945.
- Yanagisawa, T, Hirata, M, Saitoh, Y, Kishima, H, Matsushita, K, Goto, T, Fukuma, R, Yokoi, H, Kamitani, Y, ve Yoshimine, T. 2011. "Electrocorticographic control of prosthetic arm in paralyzed patients", *Annals of Neurology*, 71, 353–61.
- Yin, E, Zeyl, T, Saab, R, Chau, T, Hu, D, ve Zhou, Z. 2015. "A Hybrid Brain–Computer Interface Based on the Fusion of P300 and SSVEP Scores", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(4), 693–701.
- Zaffalon, M ve Hutter, M. 2002. "Robust feature selection by mutual information distributions.", *Proceedings of the Eighteenth Conference on Uncertainty in Artificial Intelligence*. 577–584.
- Zhuang, J, Truccolo, W, Vargas-Irwin, C, ve Donoghue, J P. 2010. "Decoding 3-D Reach and Grasp Kinematics From High-Frequency Local Field Potentials in Primate Primary Motor Cortex", *IEEE Transactions on Biomedical Engineering*, 57(7), 1774–1784.
- Zimmermann, J B ve Jackson, A. 2014. "Closed-loop control of spinal cord stimulation to restore hand function after paralysis.", *Frontiers in neuroscience*, 8(May), 87.

**TÜBİTAK
PROJE ÖZET BİLGİ FORMU**

Proje Yürütücüsü:	Yrd. Doç. Dr. YURİY MİSHCHENKO
Proje No:	113E611
Proje Başlığı:	Daha Verimli Noninvaziv Beyin-Makine Arayüzlerinin Geliştirilmesi
Proje Türü:	1001 - Araştırma
Proje Süresi:	36
Araştırmacılar:	ZEHRA YILDIZ
Danışmanlar:	AYNUR ÖZGE
Projenin Yürütüldüğü Kuruluş ve Adresi:	İZMİR EKONOMİ Ü.
Projenin Başlangıç ve Bitiş Tarihleri:	01/07/2014 - 01/01/2018
Onaylanan Bütçe:	313811.0
Harcanan Bütçe:	210256.0
Öz:	<p>Son yıllarda nöral aktivite görüntüleme ve analiz tekniklerinin hızlı gelişimi, beyinde bilginin nasıl işlendiğinin temellerini anlamamıza yardımcı olmuştur. Aynı zamanda, beyinde bilgi işleyişi hakkında bilgi elde eden yeni yaklaşımlar ve bunlara bağlı gelişmeler birçok tıbbi nörolojik durumların yeni tedavisine yol açmıştır. Beyin-Makine veya Beyin-Bilgisayar Arayüzleri (BMA/BBA) böyle gelişmelerden bir tanedir. BMA, nörobilim, istatistik ve sayısal yöntemler ile birlikte ortaya çıkan araştırma alanı olup, insanlarla iletişim ve kontrol için beyindeki nöral aktiviteyi doğrudan kullanmaya hedeflenmektedir. BMA, son 15 yılda hızlı ilerleyip, sanal ve gerçek durumda robotik manipatörün kontrolü gibi imkanları felçli insanlara sağlamaktadır. Noninvaziv BMA da görüntüleme için kafatası-dışı beyin aktivite görüntüleme teknikleri, başlıca elektroensefalografi (EEG), kullanır ve son yıllarda çok hızlı gelişmiştir. Bu projede, EEG beyin görüntüleme tekniği kullanılarak orijinal bir BMA sistemi geliştirilmekte ve bu sistem kapsamında yeni EEG veri analiz ve modelleme teknikleri araştırılmaktadır. Proje süresince, tam bir EEG BMA sistemi geliştirilmekte, EEG veri analizi için yeni yöntemler araştırılmakta, EEG veri konusunda EEG BMA ile ilgili temel yeni bilgiler toplanmakta ve EEG verileri için yeni istatistiksel veri modelleme yöntemi incelenmektedir.</p>
Anahtar Kelimeler:	Beyin bilgisayar arayüzleri, elektroensefalografi, sinyal işleme, makine öğrenme
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır
Projeden Yapılan Yayınlar:	<p>1- Characterization of the keyproperties of electroencephalographic signal for noninvasive brain machine/computer interface applications (Bildiri - Uluslararası Bildiri - Poster Sunum), 2- Variability in cellular gene expression profiles and homeostatic regulation (Makale - Diğer Hakemli Makale), 3- Gelişmiş EEG tabanlı beyin bilgisayar arayüzleri için elektroensefalogra?k beyin aktivitesinin saklı Markov modeli (Bildiri - Ulusal Bildiri - Poster Sunum), 4- EEG tabanlı Beyin Makine Arayüzü kullanılarak devamlı dikkat gerektiren görevde operatorün dikkat durumunun tespiti (Bildiri - Ulusal Bildiri - Poster Sunum), 5- Operatör dikkat durumu tespiti sistemi (Bildiri - Ulusal Bildiri - Poster Sunum), 6- EEG tabanlı bir beyin bilgisayar arayüzü için yazılımsal altyapı geliştirme (Bildiri - Ulusal Bildiri - Sözlü Sunum), 7- 1. Sinyal İşleme ve Uygulamaları Yarışması, 23. IEEE SİU2015 Sinyal İşleme ve İletişim Uygulamaları Kurultayı (Ödül - Ulusal Ödül - Diğer), 8- Beyin bilgisayar arayüzü için DVM makine öğrenme yöntemi kullanılarak EEG verilerinden sağ ve sol el hareket düşüncelerinin tespiti. (Makale - Diğer Hakemli Makale), 9- Control of a virtual robotic hand manipulator using a non-invasive EEG-based brain-machine interface (Bildiri - Uluslararası Bildiri - Sözlü Sunum), 10- Developing a 3 to 6 state slow cortical potentials brain computer interface for high performance control of a 3D robotic manipulator (Bildiri - Uluslararası Bildiri - Sözlü Sunum),</p>