

SPEKTRAL VE FAZ TABANLI ÖZNİTELİKLERLE ÇOK SINIFLI MOTOR HAYALİ EEG
SİNYALLERİNİN SINIFLANDIRILMASI

Osman ÇETİN

Kütahya Dumlupınar Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliği Uyarınca
Lisansüstü Eğitim Enstitüsü İleri Teknolojiler Anabilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır.

Danışman: Dr. Öğr. Üyesi Mustafa TOSUN

Ocak – 2021

KABUL VE ONAY SAYFASI

Osman ÇETİN tarafından hazırlanan “SPEKTRAL VE FAZ TABANLI ÖZNİTELİKLERLE ÇOK SINIFLI MOTOR HAYALİ EEG SİNYALLERİNİN SINIFLANDIRILMASI” adlı tez çalışması, aşağıda belirtilen jüri tarafından Kütahya Dumlupınar Üniversitesi Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek OY BİRLİĞİ ile Kütahya Dumlupınar Üniversitesi Lisansüstü Eğitim Enstitüsü İleri Teknolojiler Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

19/01/2021

Prof. Dr. Şahmurat ARIK
Enstitü Müdürü, Lisansüstü Eğitim Enstitüsü

Prof. Dr. Muammer GAVAS
Anabilim Dalı Başkanı, İleri Teknolojiler Anabilim Dalı

Dr. Öğr. Üyesi Mustafa TOSUN
Danışman, İleri Teknolojiler Anabilim Dalı

Sınav Komitesi Üyeleri

Dr. Öğr. Üyesi Mustafa TOSUN
Elektrik-Elektronik Mühendisliği Bölümü, Kütahya Dumlupınar Üniversitesi

Prof. Dr. Hamdi Melih SARAOĞLU
Elektrik-Elektronik Mühendisliği Bölümü, Kütahya Dumlupınar Üniversitesi

Prof. Dr. Ayhan İSTANBULLU
Bilgisayar Mühendisliği Bölümü, Balıkesir Üniversitesi

ETİK İLKE VE KURALLARA UYGUNLUK BEYANI

Bu tezin hazırlanmasında Akademik kurallara riayet ettiğimizi, özgün bir çalışma olduğunu ve yapılan tez çalışmasının bilimsel etik ilke ve kurallara uygun olduğunu, çalışma kapsamında teze ait olmayan veriler için kaynak gösterildiğini ve kaynaklar dizininde belirtildiğini, Yüksek Öğretim Kurulu tarafından kullanılmak üzere önerilen ve Kütahya Dumlupınar Üniversitesi tarafından kullanılan İntihal Programı ile tarandığını ve benzerlik oranının %5 çıktığını beyan ederiz. Aykırı bir durum ortaya çıktığı takdirde tüm hukuki sonuçlara razı olduğumuzu taahhüt ederiz.

Dr. Öğr. Üyesi Mustafa TOSUN

Osman ÇETİN

SPEKTRAL VE FAZ TABANLI ÖZNİTELİKLERLE ÇOK SINIFLI MOTOR HAYALİ EEG SİNYALLERİNİN SINIFLANDIRILMASI

Osman ÇETİN

İleri Teknolojiler, Yüksek Lisans Tezi, 2021
Tez Danışmanı: Dr. Öğr. Üyesi Mustafa TOSUN

ÖZET

Beyin-Bilgisayar Ara Yüzleri (BBA), insanların herhangi bir kas gücü gerektirmeden tamamen zihinsel olarak elektronik cihazlarla iletişim kurmalarına olanak sağlayan bir teknolojidir. Günümüzde kullanılan BBA sistemlerinde, sinyal elde etmenin kolaylığı nedeniyle çoğunlukla EEG (Elektroensefalogram) sinyalleri tercih edilmektedir. EEG tabanlı BBA uygulamalarında, kişilerin ilgili uzuv hareketlerini hayal etmesiyle elde edilen motor hayali (MI) sinyallerinden özellik çıkarmak ve bunları sınıflandırmak oldukça önemli bir konudur. MI-EEG sinyalleriyle ilgili yapılan çalışmalarda, birçok farklı özellik çıkarma yöntemleri ve sınıflandırma algoritmaları kullanılmıştır. Fakat MI-EEG sinyallerinde sınıf sayısı arttıkça elde edilen sınıflandırma başarıları arasında belirgin farklar gözlemlenmiştir.

Bu tez çalışmasında, sinyallerin PSD ve faz bilgilerini içeren özellik çıkarma yöntemleri incelenmiştir. PSD tabanlı özellikleri elde etmek için Ayırık Dalgacık Dönüşümüyle birlikte Welch yöntemi ve Ampirik Mod Ayırıştırmasıyla birlikte Welch yöntemi kullanılmıştır. Faz tabanlı özellikleri elde etmek için ise Hilbert dönüşümü ve Hilbert-Huang dönüşümü yöntemleri kullanılmıştır. PSD veya faz bilgileri içeren öznitelik vektörleriyle LSTM derin ağı ve SVM algoritması eğitilmiştir. İki farklı PSD tabanlı yöntemin, sınıflandırma başarılarına olan etkileri kişiler, kanallar ve kullanılan sınıflandırıcı alt başlıkları altında detaylıca incelenmiştir. Ayrıca iki farklı faz tabanlı yöntemin sınıflandırma başarılarına olan etkileri ise kişiler, belirli zaman aralıkları ve kullanılan sınıflandırıcı bazında detaylı olarak incelenmiştir. Tez çalışmasının son kısımlarında, PSD ve faz tabanlı yöntemlerin başarılarının karşılaştırılması yapılmıştır. Ek olarak, makalelerde aynı veri setini kullanarak yapılan 4' lü motor hayali sinyallerinin sınıflandırılmasıyla ilgili bazı çalışmalar ile önerilen yöntemin başarıları karşılaştırılmıştır.

Anahtar Kelimeler: Ampirik Mod Ayırıştırması (EMD), Ayırık Dalgacık Dönüşümü (DWT), Beyin-Bilgisayar Arayüzü (BBA), Destek Vektör Makinesi (SVM), EEG Sinyal İşleme, Hilbert Dönüşümü (HT), Hilbert-Huang Dönüşümü (HHT), Motor Hayali (MI), Güç Spektral Yoğunluğu (PSD), Uzun-Kısa Dönem Hafıza (LSTM), Welch Yöntemi.

CLASSIFICATION OF MULTI-CLASS MOTOR IMAGERY EEG SIGNALS WITH SPECTRAL AND PHASE BASED FEATURES

Osman ÇETİN

Advanced Technologies, M. Sc. Thesis, 2021

Thesis supervisor: Assist Prof. Dr. Mustafa TOSUN

SUMMARY

Brain-Computer Interfaces (BCI) is a technology that allows people to mentally communicate with electronic devices without requiring any muscle power. EEG (Electroencephalogram) signals are mostly preferred in the BCI systems used today due to the ease of signal acquisition. In EEG-based BCI applications, extracting features from Motor Imagery (MI) signals obtained by imagining related limb movements and classifying them is a very important issue. Many different feature extraction methods and classification algorithms have been used in studies on MI-EEG signals. However, as the number of classes in MI-EEG signals increased, significant differences were observed between the obtained classification accuracies.

In this thesis, feature extraction methods including PSD and phase information of signals were examined. Welch method with Discrete Wavelet Transform and Welch method with Empirical Mode Decomposition were used to obtain PSD based properties. Hilbert transform and Hilbert-Huang transform methods are used to obtain phase based properties. LSTM deep network and SVM algorithm were trained with feature vectors containing PSD or phase information. The effects of two different PSD-based methods on the classification accuracy were examined in detail under the subheadings of persons, channels and classifier used. Also, the effects of two different phase-based methods on the classification accuracy were examined in detail on the based of individuals, specific time intervals and the classifier used. In the last parts of the thesis, the accuracy of PSD and phase-based methods has been compared. In addition, some studies on the classification of 4-motor imagery signals using the same data set in the articles with a comparison of the accuracies obtained with proposed method were made.

Keywords: Brain Computer Interface (BCI), Discrete Wavelet Transform (DWT), EEG Signal Processing, Empirical Mode Decomposition (EMD), Hilbert Transform (HT), Hilbert-Huang Transform (HHT), Long-Short Term Memory (LSTM), Motor Imagery (MI), Power Spectral Density (PSD), Support Vector Machine (SVM), Welch Method.

TEŞEKKÜR

Bu çalışmada bana yardımcı olan başta sayın danışman hocam Dr. Öğr. Üyesi Mustafa Tosun' a, bilgi ve tecrübelerini esirgemeyen sayın hocam Dr. Öğr. Üyesi Ömer Kasım' a ve hayatım boyunca maddi, manevi desteği ile hep yanımda olan; aldığım kararlarda beni sürekli destekleyen canım anneme, babama ve biricik kardeşime teşekkürlerimi borç bilirim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xv
1. GİRİŞ	1
2. LİTERATÜR ÇALIŞMALARI.....	3
3. GENEL KISIMLAR	10
3.1. EEG’ nin Tarihsel Gelişimi	10
3.2. EEG Sinyalleri	11
3.3. EEG Sinyallerinin Oluşumu.....	14
3.4. EEG Sinyallerindeki Artifaktlar	15
3.4.1. İç artifaktlar.....	15
3.4.2. Dış artifaktlar	15
3.5. Beyin Aktivitelerinin Ölçülmesi	16
3.5.1. EEG, ECoG ve LFP/MUR.....	16
3.5.2. Manyetoensefalogram (MEG)	19
3.5.3. Fonksiyonel manyetik rezonans görüntüleme (fMRI)	20
3.5.4. Pozitron emisyon tomografisi (PET)	20
3.5.5. Fonksiyonel yakın infrared spektroskopisi (fNIRS)	21
3.6. Beyin Bilgisayar Arayüzü (BBA)	22
3.6.1. BBA’ nın genel tanımı.....	22
3.6.2. BBA sistemlerinde kullanılan EEG sinyalleri.....	24
4. MATERYAL VE METOD	33
4.1. EEG Veri Kaydı.....	33
4.2. EEG Sinyal İşleme Yöntemleri	34
4.2.1. Dalgacık dönüşümü (WT).....	34
4.2.2. Hilbert-Huang dönüşümü (HHT).....	45
4.2.3. Welch yöntemi	51
4.3. Sınıflandırma Yöntemleri.....	55

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
4.3.1. Uzun-kısa dönem hafıza (LSTM)	55
4.3.2. Destek vektör makinesi (SVM)	58
5. DENEYSEL ÇALIŞMALAR VE BULGULAR	63
5.1. 4 Sınıfa Ait Ham EEG Sinyalleri	63
5.2. DWT Yöntemiyle Katsayı Sinyallerinin Elde Edilmesi.....	64
5.3. Welch Yöntemiyle Katsayı Sinyallerinin PSD Değerlerinin Hesaplanması	66
5.4. DWT+Welch Yöntemiyle Özniteliklerin Oluşturulması.....	71
5.5. EMD Yöntemiyle İMF' lerin Elde Edilmesi	72
5.6. Welch Yöntemiyle İMF Sinyallerinin PSD Değerlerinin Hesaplanması	75
5.7. EMD+Welch Yöntemiyle Özniteliklerin Oluşturulması	79
5.8. DWT ve EMD Yöntemlerinin Karşılaştırılması.....	81
5.9. PSD Tabanlı Sınıflandırma İşlemleri	86
5.9.1. Kullanılan veri setinin dağılımı	86
5.9.2. LSTM ağında kullanılan parametreler	87
5.9.3. PSD özelliklerini kullanarak LSTM ağının eğitilmesi.....	88
5.9.4. PSD tabanlı sınıflandırma sonuçları	89
5.10. Hilbert Dönüşümüyle Anlık Fazların Hesaplanması.....	95
5.11. Hilbert-Huang Dönüşümüyle Anlık Fazların Hesaplanması.....	97
5.12. Faz Tabanlı Sınıflandırma İşlemleri	99
5.12.1. Kullanılan veri setinin dağılımı	99
5.12.2. LSTM ağında kullanılan parametreler	100
5.12.3. Faz özelliklerini kullanarak LSTM ağının eğitilmesi	100
5.12.4. Faz tabanlı sınıflandırma sonuçları	102
5.13. PSD ve Faz Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması	116
5.14. Önerilen Yöntem ve Literatürdeki Bazı Yöntemlerin Sınıflandırma Sonuçları	118
6. SONUÇ VE ÖNERİLER	120
KAYNAKLAR DİZİNİ.....	121
ÖZGEÇMİŞ	

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
3.1. Delta dalgası.....	11
3.2. Teta dalgası.....	12
3.3. Alfa dalgası.	12
3.4. Beta dalgası.	13
3.5. Gamma dalgası.....	13
3.6. Sinir hücresinin yapısı.....	14
3.7. Sinir hücresinde elektriksel aktivitenin oluşumu ve EEG ile ölçümü.	15
3.8. EEG kaydı esnasında farklı sebeplerden oluşan artifaktlar.	16
3.9. EEG ile beyin sinyallerinin elde edilmesi.	17
3.10. Uluslararası 10-20 elektrot sistemi.....	18
3.11. EEG, ECoG ve LFP elektrotlarının kafa bölgesindeki konumları.	19
3.12. BBA sisteminin blok diyagramı	23
3.13. BBA türlerinde kullanılan farklı tipteki EEG sinyalleri.	25
3.14. ERP' lerin elde edilmesi ve oluşan farklı tipteki ERP' ler.....	26
3.15. a) P300 heceleme sisteminin arayüzü b) P300 sinyali.	27
3.16. Bir kişiye ait farklı frekans değerlerine sahip görsel uyarının uygulanması sonucunda elde edilen frekans spektrumu.	28
3.17. SSVEP tabanlı BBA' daki bazı görsel uyarılar ve PSD değerleri.....	29
3.18. a) Gözler kapalı ve açık olduğu esnadaki alfa ritimleri b) Kolun dinlenimde ve hareket halinde olduğu mu ritimleri.	30
3.19. Hayal esnasında oluşan mu ve beta bandlarındaki ERD/ERS etkinlikleri.....	30
3.20. Alt ve üst hedeflere ait μ ve β ritimlerini içeren frekans spektrumu.	31
3.21. Sol ve sağ motor hareketi hayali esnasında oluşan ERD etkinliği.	32
3.22. EEG sinyalindeki negatif ve pozitif yönlü SCP' ler.	32
4.1. EEG kaydının zamanlama şeması.	33
4.2. Uluslararası 10-20 sistemine karşılık gelen elektrot montajı.	33
4.3. STFT' nin zaman-frekans çözünürlüğünün karşılaştırılması; a) dar pencere b) geniş pencere c) orta pencere.....	34
4.4. Giriş sinyaline FFT ve STFT uygulanması.	36
4.5. Dalgacık dönüşümünün ölçek-zaman grafiği.....	37
4.6. Fourier ve Dalgacık Dönüşümleriyle elde edilen yapıtaş fonksiyonları.	38
4.7. Farklı ölçek değerlerine sahip fonksiyonlar.	39
4.8. Farklı öteleme değerlerine sahip fonksiyonlar.	39

ŞEKİLLER DİZİNİ (devam)

<u>Sekil</u>	<u>Sayfa</u>
4.9. Dalgacık dönüşümünde kullanılan bazı ana dalgacık fonksiyonları.	40
4.10. cA ve cD katsayıları elde edilirken yapılan filtreleme ve alt örnekleme işlemi.	43
4.11. 5. Seviye DWT uygulaması.	44
4.12. Bir sinyalden İMF elde etmenin ilk aşaması.	46
4.13. h1 sinyalinin elde edilmesi.	47
4.14. Eleme işlemindeki ikinci aşama.	47
4.15. Eleme işlemindeki üçüncü aşama.	48
4.16. İlk İMF bileşeni.	49
4.17. Analitik sinyal (Feldman, 2011) (a) Sinyalin 3D görüntüsü (b) Sinyalin fazör diyagramı	50
4.18. Pencerelemler arasındaki overlap mesafesi.	53
4.19. Giriş sinyalinin herhangi bir dilimi için FFT alma işlemi.	54
4.20. Welch yönteminin uygulanma aşamaları.	54
4.21. LSTM hücresinin yapısı.	55
4.22. Unutma kapısı.	56
4.23. Giriş kapısı.	56
4.24. Güncellenmiş hücre durumu.	57
4.25. Çıkış kapısı.	57
4.26. Birbiri ardına bağlı LSTM hücreleri.	58
4.27. Farklı sınıflara ait verileri birbirinden ayıran hiper-düzlemler.	59
4.28. İki sınıfı birbirinden ayıran optimum hiper-düzlem ve sınır düzlemleri.	60
4.29. İki boyutta gösterilen verilerin kernel fonksiyonuyla üç boyutta gösterilmesi.	61
5.1. 4 sınıfa ait ham EEG işaretlerinin dalga formları.	63
5.2. DWT kullanılarak hesaplanan sol el sınıfına ait katsayı sinyalleri.	64
5.3. DWT kullanılarak hesaplanan sağ el sınıfına ait katsayı sinyalleri.	65
5.4. DWT kullanılarak hesaplanan ayak sınıfına ait katsayı sinyalleri.	65
5.5. DWT kullanılarak hesaplanan dil sınıfına ait katsayı sinyalleri.	66
5.6. Sol el sınıfına ait bandların PSD grafikleri.	67
5.7. Sol el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	67
5.8. Sağ el sınıfına ait bandların PSD grafikleri.	68
5.9. Sağ el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	68
5.10. Ayak sınıfına ait bandların PSD grafikleri.	69
5.11. Ayak sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	69

ŞEKİLLER DİZİNİ (devam)

<u>Sekil</u>	<u>Sayfa</u>
5.12. Dil sınıfına ait bandların PSD grafikleri.	70
5.13. Dil sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	70
5.14. Sol el sınıfına ait birleştirilmiş band güçleri.	71
5.15. Sağ el sınıfına ait birleştirilmiş band güçleri.....	71
5.16. Ayak sınıfına ait birleştirilmiş band güçleri, ...	72
5.17. Dil sınıfına ait birleştirilmiş band güçleri.	72
5.18. EMD kullanılarak hesaplanan sol el sınıfına ait İMF sinyalleri.....	73
5.19. EMD kullanılarak hesaplanan sağ el sınıfına ait İMF sinyalleri.	73
5.20. EMD kullanılarak hesaplanan ayak sınıfına ait İMF sinyalleri.....	74
5.21. EMD kullanılarak hesaplanan dil sınıfına ait İMF sinyalleri.	74
5.22. Sol el sınıfına ait bandların PSD grafikleri.	75
5.23. Sol el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	76
5.24. Sağ el sınıfına ait bandların PSD grafikleri.....	76
5.25. Sağ el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	77
5.26. Ayak sınıfına ait bandların PSD grafikleri.	77
5.27. Ayak sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.....	78
5.28. Dil sınıfına ait bandların PSD grafikleri.	78
5.29. Dil sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.	79
5.30. Sol el sınıfına ait birleştirilmiş band güçleri.	79
5.31. Sağ el sınıfına ait birleştirilmiş band güçleri.....	80
5.32. Ayak sınıfına ait birleştirilmiş band güçleri.	80
5.33. Dil sınıfına ait birleştirilmiş band güçleri.	81
5.34. DWT ve EMD ile hesaplanan sol el sınıfına ait band sinyalleri.	82
5.35. DWT ve EMD ile hesaplanan sağ el sınıfına ait band sinyalleri.....	83
5.36. DWT ve EMD ile hesaplanan ayak sınıfına ait band sinyalleri.	84
5.37. DWT ve EMD ile hesaplanan dil sınıfına ait band sinyalleri.....	85
5.38. DWT+Welch kullanarak LSTM ağının eğitim ve validation başarıları.	88
5.39. EMD+Welch kullanarak LSTM ağının eğitim ve validation başarıları.	88
5.40. LSTM ve SVM' nin DWT+Welch kullanarak elde edilen ortalama başarıları.	93
5.41. LSTM ve SVM' nin EMD+Welch kullanarak elde edilen ortalama başarıları.	93
5.42. LSTM ağının DWT+Welch ve EMD+Welch kullanarak elde edilen ortalama başarıları..	94

ŞEKİLLER DİZİNİ (devam)

<u>Sekil</u>	<u>Sayfa</u>
5.43. SVM modeli' nin DWT+Welch ve EMD+Welch kullanarak elde edilen ortalama başarıları.	95
5.44. Anlık fazların özdeğerleriyle öznitelik vektörü oluşturulması.	96
5.45. Ham EEG sinyalleri ve anlık fazların özdeğerleri.	97
5.46. 22 kanalın İMF-4 sinyalleri ve anlık fazların özdeğerleri.	98
5.47. 4-5 sn aralığında Hilbert dönüşümü kullanarak LSTM ağının eğitilmesi.	100
5.48. 3-6 sn aralığında Hilbert dönüşümü kullanarak LSTM ağının eğitilmesi.	101
5.49. 4-5 sn aralığında Hilbert-Huang dönüşümü kullanarak LSTM ağının eğitilmesi.	101
5.50. 3-6 sn aralığında Hilbert-Huang dönüşümü kullanarak LSTM ağının eğitilmesi.	102
5.51. EMD' siz 3-4 sn aralığındaki ortalama test başarıları.	102
5.52. EMD' siz 4-5 sn aralığındaki ortalama test başarıları.	103
5.53. EMD' siz 5-6 sn aralığındaki ortalama test başarıları.	103
5.54. EMD' siz 3-6 sn aralığındaki ortalama test başarıları.	104
5.55. EMD' li 3-4 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.	104
5.56. EMD' li 3-4 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.	105
5.57. EMD' li 3-4 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.	106
5.58. EMD' li 3-4 sn aralığında ve İMF-4' ten elde edilen ortalama test başarıları.	106
5.59. EMD' li 4-5 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.	107
5.60. EMD' li 4-5 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.	107
5.61. EMD' li 4-5 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.	108
5.62. EMD' li 4-5 sn aralığında ve İMF-4' ten elde edilen ortalama test başarıları.	109
5.63. EMD' li 5-6 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.	109
5.64. EMD' li 5-6 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.	110
5.65. EMD' li 5-6 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.	110
5.66. EMD' li 5-6 sn aralığında ve İMF-4' ten elde edilen ortalama test başarıları.	111
5.67. EMD' li 3-6 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.	112
5.68. EMD' li 3-6 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.	112
5.69. EMD' li 3-6 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.	113
5.70. EMD' li 3-6 sn aralığında ve İMF-4' den elde edilen ortalama test başarıları.	113

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
3.1. Beyin aktivitelerinin ölçülmesinde kullanılan yöntemlerin karşılaştırılması.....	21
4.1. Ana dalgacık fonksiyonlarının isimleri.....	40
4.2. 5. Seviye DWT Ayırıştırması ve EEG’ deki karşılıkları.....	45
4.3. Kernel fonksiyonlarının matematiksel ifadeleri.....	62
5.1. Sol el sınıfına ait korelasyon katsayıları	82
5.2. Sağ el sınıfına ait korelasyon katsayıları.....	83
5.3. Ayak sınıfına ait korelasyon katsayıları	84
5.4. Dil sınıfına ait korelasyon katsayıları.....	85
5.5. Sınıflandırmada kullanılan veri seti’ nin dağılımı	86
5.6. LSTM derin ağında kullanılan eğitim parametreleri.....	87
5.7. LSTM derin ağının DWT+Welch yöntemiyle elde edilen test başarıları.....	89
5.8. SVM algoritmasının DWT+Welch yöntemiyle elde edilen test başarıları.....	90
5.9. LSTM derin ağının EMD+Welch yöntemiyle elde edilen test başarıları.....	91
5.10. SVM algoritmasının EMD+Welch yöntemiyle elde edilen test başarıları	92
5.11. LSTM ve SVM’ de kullanılan veri setinin miktarları	99
5.12. LSTM derin ağında kullanılan eğitim parametreleri.....	100
5.13. EMD’ siz farklı zaman aralıkları için hesaplanan LSTM ve SVM test başarıları.....	114
5.14. EMD’ li birim zaman aralıkları için hesaplanan LSTM test başarıları	115
5.15. EMD’ li birim zaman aralıkları için hesaplanan SVM test başarıları	115
5.16. EMD’ li 3-6 sn aralığı için hesaplanan LSTM ve SVM test başarıları	116
5.17. SVM’ nin PSD ve faz tabanlı özellikler ile elde edilen sınıflandırma başarıları.....	117
5.18. LSTM ağının PSD ve faz tabanlı özellikler ile elde edilen sınıflandırma başarıları.....	117
5.19. Önerilen yöntem ve literatürdeki bazı yöntemlerin sınıflandırma başarıları	118

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

Hz

Açıklama

Hertz

Kısaltmalar

AAR

Uyarlanabilir Otoregresif Model

AR

Otoregresif Model

ANN

Yapay Sinir Ağı

BBA

Beyin Bilgisayar Arayüzü

CNN

Evrişimli Sinir Ağı

CSP

Ortak Uzamsal Örüntü

CWT

Sürekli Dalgacık Dönüşümü

DBM

Derin Boltzmann Makinesi

DBN

Derin İnanç Ağı

DFT

Ayrık Fourier Dönüşümü

DWT

Ayrık Dalgacık Dönüşümü

ECoG

Elektrokortigram

EEG

Elektroensofalogram

EMD

Ampirik Mod Ayırıştırması

ERD/ERS

Olay İlişkili Desenkronizasyon/Senkronizasyon

ERP

Olay İlişkili Potansiyel

FBCSP

Filtre Bankası Ortak Uzamsal Örüntü

FDM

Bulanık Ayırt Edilebilirlik Matrisi

FFT

Hızlı Fourier Dönüşümü

FSVM

Bulanık Destek Vektör Makinesi

FIR

Sonlu Dürtü Yanıtı

fMRI

Fonksiyonel Manyetik Rezonans Görüntüleme

fNIRS

Fonksiyonel Yakın İnfrared Spektroskopisi

HHT

Hilbert-Huang Dönüşümü

HT

Hilbert Dönüşümü

İMF

İçsel Mod Fonksiyonu

k-NN

En Yakın Komşuluk İlişkisi

LDA

Doğrusal Diskriminant Analizi

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
LFP/MUR	Yerel Alan Potansiyelleri/Çok Üniteli Kayıt
LR	Lojistik Regresyon
LSP	Lomb-Scargle Periodogram
LS-SVM	En Küçük Kareler Destek Vektör Makinesi
LSTM	Uzun-Kısa Dönem Hafıza Ağı
MEG	Manyetoensefalogram
MI	Motor Hayali
MIBIF	Karşılıklı Bilgiye Dayalı En İyi Bireysel Özellik
MLP	Çok Katmanlı Perceptron
MRC	Çoklu Riemann Kovaryansı
MSPCA	Çok Ölçekli Temel Bileşen Analizi
NIRS	Yakın İnfrared Spektroskopisi
NRSC	Kaba Küme Komşuluk Sınıflandırıcısı
PCA	Temel Bileşen Analizi
PLV	Faz Kilit Değeri
PET	Pozitron Emisyon Tomografisi
PSD	Güç Spektral Yoğunluğu
PSO	Parçacık Sürüsü Optimizasyonu
RF	Rastgele Orman
RNN	Tekrarlanan Sinir Ağı
RST	Kaba Küme Teorisi
SCP	Yavaş Kortikal Potansiyeli
FFFS	Sıralı İleri Kayan Seçim
SSVEP	Kararlı Durum Görsel Uyarılmış Potansiyeli
STFT	Kısa Süreli Fourier Dönüşümü
SVD	Tekil Değer Ayrışımı
SVM	Destek Vektör Makinesi
WDPSD	Güç Spektral Yoğunluğunun Ağırlıklı Farkı
WPT	Paket Dalgacık Dönüşümü
WT	Dalgacık Dönüşümü

1. GİRİŞ

Beyin-Bilgisayar Arayüzleri (BBA), kişilerin herhangi bir kas gücü gerektirmeden, beyinden alınan biyoelektriksel sinyaller ile harici elektronik cihazlar arasında iletişim kurmalarını sağlayan sistemlerdir. Bu sistemler; biyomedikal uygulamalarda, motor fonksiyonlarını yerine getiremeyen felçli hastaların tekerlekli sandalye ve robot kol gibi cihazları kontrol etmelerinde, araba kullanma, drone kontrolü gibi çeşitli uygulamalar için kullanılır (Amin vd., 2019b; Lu vd., 2016). Beyin aktivitelerinin ölçülmesinde, EEG (Elektroensefalogram), Elektrokortigografi (ECoG), Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), Magnetoensefalografi (MEG), Fonksiyonel Yakın İnfrared Spektroskopisi (fNIRS) gibi çeşitli yöntemler mevcuttur (Wang vd., 2013). Bu yöntemler arasında düşük maliyeti, taşınabilirliği ve sinyal elde etmenin kolaylığı nedeniyle çoğunlukla EEG (Elektroensefalogram) sinyalleri tercih edilir (Ventakachalam vd., 2020).

BBA ile ilgi yapılan çalışmalarda, motor Hayali (MI), kararlı durum görsel uyarılmış potansiyelleri (SSVEP) ve P300 gibi çeşitli EEG sinyalleri kullanılmıştır. Bu sinyaller arasında motor hayali sinyalleri, kişide herhangi bir dürtüye gerek olmadan kendiliğinden üretilebildiği için en yaygın kullanılmakta olan sinyallerdir (Li vd., 2020). Motor hayali, bir kişi el veya bacak gibi uzuvlarının hareketini hayal ettiğinde ve hayalini bitirdiğinde, elektrotlardan kaydedilen beynin elektriksel aktivitesidir (Wang vd., 2004).

EEG tabanlı BBA sistemlerinde kontrol komutları, kafa derisi üzerine yüzeysel olarak yerleştirilmiş elektrotlardan alınan sinyallerin farklı şekillerde işlenmesiyle gerçekleştirilir (Gaur vd., 2018). İlk olarak, elektrotlardan alınan düşük genlikli biyoelektriksel sinyaller yükselteç aracılığıyla yükseltilir. Yükseltilmiş sinyal üzerinde hangi frekansa ait bileşenlerin ne tür anlamlar içerdiğini incelemek için spektral veya zaman-frekans analizi yöntemleri uygulanarak gerekli öznelikler elde edilir. Çıkarılan öznelikler ile yapay zeka algoritması ile eğitilerek, yapılması istenen motor fonksiyon gerçekleştirilir.

BBA uygulamalarında gerekli özneliklerin çıkarılması ve bunların sınıflandırılması oldukça önemli bir konudur. Çünkü, EEG sinyalleri beyindeki milyarlarca nöronun etkileşimi sonucunda elde edilen aperiodyk ve non-lineer sinyallerdir (Kam vd., 2013). EEG sinyallerinden özellik çıkarmada; Ortak Uzamsal Örüntüler (CSP), Filtre Bankası CSP (FBCSP), Ayrık Dalgacık Dönüşümü (DWT), Hızlı Fourier Dönüşümü (FFT), Kısa Süreli Fourier Dönüşümü (STFT), Hilbert-Huang Dönüşümü (HHT) ve Auto-Regresyon parametreleri (AR) gibi birçok farklı yöntem kullanılmıştır (Dai vd., 2019; Hu vd., 2011; Ting vd., 2008).

Öznitelikleri sınıflandırmada; Destek Vektör Makineleri (SVM), Doğrusal Diskriminant Analizi (LDA), En yakın komşuluk ilişkisi (k-NN), Lojistik Regresyon (LR), Random Forest (RF) gibi çeşitli yöntemler kullanılmıştır (Lu vd., 2016; Bentlemsan vd., 2014). Fakat, makine öğrenmesi tekniklerini kullanarak beyin sinyallerinin modellenmesi oldukça zordur (Kumar vd., 2016). Geleneksel makine öğrenmesi yöntemleriyle sınıflandırmada yüksek doğruluklar elde edilememiştir (Amin vd., 2019a).

Son yıllarda, araştırmacılar tarafından derin öğrenme yöntemlerine ilgi artmıştır. Derin öğrenme yöntemleri, konuşma ve görüntü tanıma gibi alanlarda yaygın olarak başarıyla kullanılmıştır (Amin vd., 2019a). Bu ağlardan Evrişimli Sinir Ağları (CNN), görüntülerden ayırt edici özellikler çıkarma ve sınıflandırma yeteneğine sahiptir. Tekrarlanan Sinir Ağları (RNN), konuşma sınıflandırmadaki zamansal özellikleri diğer modellerden daha iyi çıkarmaktadır (Wang vd., 2018). Bununla birlikte, MI-EEG uygulamalarında derin öğrenme yöntemlerinin kullanımı, konuşma ve görüntü tanıma gibi alanlara göre kısıtlıdır ve daha fazla araştırmaya ihtiyaç vardır (Jirayucharoensak vd., 2014).

Sınıflandırıcıyla elde edilen başarı, eğitim verilerinin miktarına bağlıdır. Özellikle, küçük veri kümeleriyle derin öğrenme modelleri eğitilemez. Derin öğrenme algoritmalarının öğrenme stratejilerinde çok büyük eğitim verileri gereklidir (Zhang vd., 2019). Bu nedenle, çalışmada kullanılan mevcut veri setinin tamamı, sınıflandırıcılara uygulanmadan önce 0.9 ve 1.1 ile çarpılarak arttırılmıştır.

Bu tez çalışmasında; Ayrık Dalgacık Dönüşümü (DWT)+Welch yöntemi, Ampirik Mod Ayrıştırması (EMD)+Welch yöntemi, Hilbert Dönüşümü ve Hilbert-Huang Dönüşümü (HHT) ile elde edilen özniteliklerin, Uzun-Kısa Dönem Hafıza (LSTM) derin öğrenme modeli ve makine öğrenmesi algoritması olan SVM ile sınıflandırılması yapılmıştır. Eğitim sonucunda elde edilen sınıflandırma başarıları, Çizelgeler ve sütun grafikleri halinde detaylı olarak incelenmiştir.

2. LİTERATÜR ÇALIŞMALARI

Literatürde, sınıf sayısı 2 ve 2' den fazla olan motor hayali sinyallerinin sınıflandırılmasıyla ilgili farklı özellik çıkarma, özellik seçme ve sınıflandırma algoritmaları kullanılarak çeşitli çalışmalar yapılmıştır.

Wang vd. (2012), hareket hayali esnasında motor kortekste alfa (8-13 Hz) ve beta (13-30 Hz) band aralıklarındaki sinyallerin gücündeki anlık değişim tepkisi olarak bilinen ERD/ERS bilgisini baz alarak, 22 kanallı EEG verilerinden optimum kanalları seçmişlerdir. Seçilen kanalların alfa ve beta frekans aralıklarındaki güç değerlerini öznitelik olarak kullanmışlardır. PCA ile veri boyutunu azaltarak, SVM modeliyle sınıflandırdıklarında 9 kişiye ait, 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %71.83 başarı elde etmişlerdir.

Sakhavi vd. (2018), tüm kanallara ait verileri, 4 Hz' lik band genişliğine sahip ve 4 Hz' den başlamak üzere (4-8 Hz, 8-12 Hz, ... 36-40 Hz) aralıklarında band geçiren bir filtre bankası kullanarak filtrelemişlerdir. Kullandıkları filtreler Chebyshev tipinde olup, filtre sabiti 2 ' dir. CSP kullanarak, her bir band aralığındaki çıktı için uzamsal filtreleri hesaplamışlardır. Uzamsal olarak filtrelenen kanalların enerji değerlerini hesaplayarak, bu değerleri kanalların toplam enerjisine göre normalize etmişlerdir. Her filtre bandından gelen enerji değerlerini birleştirerek, karşılıklı bilgi tabanlı özellik seçimi gerçekleştirmişlerdir. CNN derin öğrenme modeliyle sınıflandırarak 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %74.46 başarı elde etmişlerdir.

Selim vd. (2018), CSP özelliklerini sabit bir zaman aralığı için 9 farklı frekans bandından (4-8 Hz, 8-12 Hz, ... 36-40 Hz) çıkarmışlardır. Bu özellikleri, bir öznitelik vektörü elde etmek için birleştirmişlerdir. Sınıflandırıcı olarak yeni bir yaklaşım olarak AM-BA-SVM modelini önermişlerdir. En iyi CSP özelliklerini AM algoritmasıyla seçerek, BA algoritmasıyla SVM sınıflandırıcısının parametrelerini optimize etmişlerdir. Sınıflandırma sonucunda 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %78.55 başarı elde etmişlerdir.

Yu ve Song (2017), EEG verilerinde boyut azaltmak için SVD yöntemini uygulamışlardır. Gerekli öznitelikleri çıkarmak ve bunları sınıflandırmak için DBM modelini kullanmışlardır. Sınıflandırma sonucunda 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %80.38 başarı elde etmişlerdir.

Rahman vd. (2020), 5. seviye WPT kullanarak sinyallerin enerji, varyans, standart sapma ve dalga formu gibi özelliklerini hesaplamışlardır. Tüm bu özellikleri birleştirerek öznitelik vektörü elde etmişlerdir. Özellik seçimi için Rényi' nin min-entropi tabanlı algoritmasını

önermişlerdir. Seçtikleri özellikleri SVM, RF, k-NN, MLP-ANN ve LR gibi farklı algoritmalarla sınıflandırdıklarında 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için en yüksek başarıyı RF ile birlikte ortalama %80.55 olarak elde etmişlerdir.

Kumar ve Inbarani (2017), 5. seviye DWT kullanarak, D1 (64-128 Hz), D2 (32-64 Hz), D3 (16-32 Hz), D4 (8-16 Hz), D5 (4-8 Hz) ve A5 (0-4 Hz) frekans bandlarından özellik çıkarmışlardır. PSO tabanlı RST algoritması kullanarak özellik seçimi yapmışlardır. Seçtikleri özellikleri NRSC yöntemiyle sınıflandırarak 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %80.99 başarı elde etmişlerdir.

Razi vd. (2019), 22 kanallı EEG verilerinin her bir kanalına, band genişliği 4 Hz olmak üzere 9 adet band geçiren filtre (4-8, 8-12, ...36-40 Hz) içeren bir filtre bankası uygulayarak her kanala ait sinyali 9 farklı sinyale ayırmışlardır. Özellik çıkarmak için, filtrelenmiş her bir sinyale CSP algoritması uygulamışlardır. Her sinyalden 4 adet, toplamından 36 adet özellik elde etmişlerdir. En anlamlı özellikleri seçmek için MIBIF yöntemini kullanmışlardır. Seçilen özellikleri LDA makine öğrenmesi algoritmasıyla sınıflandırarak, 9 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama %82.13 başarı elde etmişlerdir.

Xu vd. (2018), C3, Cz ve C4 kanallarına WT uygulayarak kanalların 2 boyutlu skalogram (zaman-frekans-enerji) görüntülerini elde etmişlerdir. Özellik olarak kullandıkları görüntüleri 2D-CNN derin öğrenme modeliyle eğitmişlerdir. Eğitim sonucunda 9 kişiye ait 4 farklı sınıf için ortalama %85.59 başarı elde etmişlerdir.

Ge vd. (2014), tek kanala ait EEG verileriyle motor görevlerini sınıflandırmak için STFT yöntemini kullanmışlardır. Fp1, Fpz, Fp2, C3 Cz ve C4 kanallarına ayrı ayrı STFT uygulayarak, zaman alanındaki tek boyutlu özelliği, zaman-frekans alanında 2 boyutlu özelliğe genişletmişlerdir. Öznitelikleri, STFT matrislerine CSP algoritması uygulayarak elde etmişlerdir. SVM ile sınıflandırdıklarında 3 kişiye ait 4 farklı sınıf (sağ el, sol el, ayak ve dil) için ortalama en yüksek başarıyı Fp2 ve C4 kanallarında, sırasıyla %75.63 ve %76.87 olarak elde etmişlerdir.

Chu vd. (2018), özellik çıkarımı için FFT, Welch ve LSP olmak üzere 3 farklı PSD yöntemini kullanmışlardır. Her bir kanala ait verileri 8-13 Hz, 13-18 Hz, 18-23 Hz ve 23-28 Hz olmak üzere dört alt banda ayırmışlardır. Tüm kanallar için, her bir alt banda ait PSD değerlerinin ortalamasını almışlardır. Elde ettikleri PSD değerlerini alt alta ekleyerek öznitelik vektörü elde etmişlerdir. DBN ve SVM olmak üzere 2 farklı algoritma ile sınıflandırmışlardır. 9 kişiye ait, 3 farklı sınıf (sağ el, sol el ve ayak) için ortalama en yüksek başarıyı LSP+DBN kullanarak %70.72 olarak elde etmişlerdir.

Rodríguez vd. (2012), 2 sınıfa ait (sol el ve sağ el) verilerinden özellik çıkarmak için güç spektral yoğunluğu, hjort parametreleri ve AAR tekniklerini uygulamışlardır. FFT kullanarak C3, C4 ve Cz kanallarındaki sinyallerin PSD değerlerini, alfa (8-13 Hz) ve beta (13-30 Hz) bandlarının ortalama gücünden elde etmişlerdir. Sinyallerin aktivite, hareketlilik ve karmaşıklık değerlerini hjort parametreleri başlığı altında hesaplamışlardır. 3 yöntem ile elde ettikleri değerleri birleştirerek bir öznitelik vektörü elde etmişlerdir. LOO-Press kritine göre, en uygun özellikleri seçtikten sonra LDA ve SVM ile sınıflandırarak 9 kişi için sırasıyla %69.70 ve %70.50 ortalama başarı elde etmişlerdir.

Kevric ve Subasi (2017), EMD, DWT ve WPT gibi 3 farklı sinyal ayrıştırma yöntemini kullanmışlardır. İlk olarak MSPCA olarak adlandırılan doğrusal olmayan filtreleme yöntemiyle EEG verilerindeki gürültüyü ortadan kaldırmışlardır. DWT ve WPT ile farklı dalgacık katsayılarını elde etmişlerdir. EMD kullanarak giriş sinyallerini, aynı veri uzunluğunda fakat farklı frekans seviyelerindeki İMF' lere ayırmışlardır. İMF sinyallerinin ortalaması, ortalama gücü, standart sapması, mutlak değerlerinin toplamının birbirlerine olan oranları, çarpıklık ve basıklık parametrelerini hesaplamışlardır. Kaiser kriterine göre özellik seçimi yaparak, k-NN ile sınıflandırmışlardır. Sınıflandırma sonucunda en yüksek başarıyı MSPCA+WPD+Çarpıklık ve basıklık özelliklerini kullanarak, 5 kişiye ait 2 farklı sınıf için (sol el ve sağ el) ortalama %92.80 başarı elde etmişlerdir.

Zhou vd. (2018), EEG sinyallerindeki genlik ve frekans modülasyonlu bilgiyi baz alarak DWT ve HT yöntemini birleştirmişlerdir. İlk olarak EEG sinyallerine DWT uygulayarak, farklı frekans aralıklarındaki alt bantlara (D1, D2, D3, D4, D5, A5) ayırmışlardır. Her bir alt bandın zarfını elde etmek için HT yöntemini uygulamışlardır. Elde ettikleri zarf spektrumunun, zaman-frekans dağılımını karakterize etmek için ortalama, enerji, standart sapma, maksimum değer gibi istatistiksel özellikleri her bir band için hesaplamışlardır. Bu değerleri birleştirerek bir öznitelik vektörü elde etmişlerdir. Sınıflandırıcı olarak LSTM derin öğrenme modelini kullanmışlardır. Elde ettikleri sınıflandırma başarısı 2 sınıf için (sol el ve sağ el) %91.43' tür.

Astolfi vd. (2009), omurilik yaralanması olan 15 kişi üzerinde sol el, sağ el ve ayak motor görevlerinin sınıflandırılmasıyla ilgili çalışma yapmışlardır. EEG kayıtları 3 farklı elektrottan (C3, Cz ve C4) 256 hz örnekleme frekansı ile alınmıştır. İlk olarak, ham verilerden EOG ve EMG artifaktlarını filtrelemişlerdir. CSP yöntemini uygulayarak, herhangi 2' li sınıf arasında varyansları bakımından optimum ayırma yapan uzamsal özellikleri elde etmişlerdir. Çıkarılan özellikleri LDA kullanarak sınıflandırmışlardır. Elde ettikleri ortalama sınıflandırma başarıları sırasıyla: sol ve sağ el için %65.03, sol el ve ayak için %68.18, sağ el ve ayak için %65.05' tir.

Kim vd. (2018), 9 kişiye ait 2 sınıflı (sol ve sağkol) olmak üzere çok kanallı EEG verilerinden elde edilen PSD değerlerinden en uygun kanal çiftini seçmek için WDPSD yöntemini önermişlerdir. Bütün kanallardaki EEG verilerinin alfa (8-13 Hz) ve beta (13-30 Hz) band aralıklarındaki PSD değerlerini elde etmek için STFT, CWT ve HHT gibi 3 farklı yöntemi uygulamışlardır. Elde ettikleri PSD matrisinden en uygun kanal çiftini seçmek için Davies-Bouldin indeksini kullanmışlardır. Seçilen kanal çiftinden en uygun özellikleri seçmek için k-ortalama kümeleme algoritmasını kullanmışlardır. Öznitelikleri SVM ile sınıflandırmışlardır. Farklı kanal çiftleri için değişik başarılar elde etmişlerdir.

Yuyi vd. (2017), sol ve sağ motor görevlerine ait verilerin anlık frekans bilgisini analiz edilerek, marjinal spektrumlarının (zaman-frekans-enerji) hesaplanabilmesi için Hilbert-Huang dönüşümü uygulamışlardır. IMF'lerine ayrılan verilerin, alfa ve beta bandlarını içeren (8-30) Hz aralığı için Shannon entropi (SE) değerini hesaplanmıştır. Farklı zaman aralıkları için hesaplanan SE değerlerini birleştirerek bir öznitelik vektörü elde etmişlerdir. Hilbert-Huang tabanlı entropi değerlerini, SVM modeliyle sınıflandırmışlardır. Elde ettikleri eğitim başarıları %85.57 olup, test başarıları ise %85'tir.

Wang vd. (2011), 28 kanallı EEG verilerinden zaman-frekans-enerji özelliklerini çıkarmak için Hilbert-Huang dönüşümünü kullanmıştır. Her bir kanal için 6-30 Hz band aralığını içeren aralıktan 36 özellik elde etmişlerdir. Toplamda 28 kanaldan gelen özellikleri birleştirerek 1008 elemanlı bir özellik vektörü elde etmişlerdir. En uygun özellikleri seçmek için, Genetik Algoritma yöntemini kullanmışlardır. LDA ile sınıflandırdıklarında 3 kişiye ait 3 sınıf için (sol el, sağ el ve ayak) ortalama %79.24 başarı elde etmişlerdir.

Li vd. (2016), 2 sınıf (sol el ve sağ el) motor hayali sinyallerinin sınıflandırılması için DWT+LSTM yöntemini önermişlerdir. 6.seviye DWT kullanarak her kanala ait zaman-frekans özelliklerini içeren dalgacık katsayılarını hesaplamışlardır. 3 kanaldan (C3, Cz ve C4) elde edilen A6 katsayılarını birleştirerek bir özellik vektörü elde etmiştir. LSTM ağıyla sınıflandırarak %93.30' luk başarı elde etmişlerdir.

Xu vd. (2019), motor görevlerinin sınıflandırılmasında, hesaplama açısından basit bir yöntem olan faz tabanlı bir yöntem önermişlerdir. Yöntem, iki sinyal arasındaki senkronizasyonu ölçmeye dayalıdır. EEG kanallarına band geçiren bir FIR filtre uygulayarak alfa (8-12 Hz) ve beta (12-30 Hz) ritimlerini elde etmişlerdir. Filtrelenmiş kanalların her birisine Hilbert dönüşümü uygulayarak, sinyallerin anlık faz değerlerini elde etmişlerdir. Anlık faz değerlerini kullanarak, belirledikleri 2'li kanal çiftleri için PLV değerlerini hesaplamışlardır. Bu değerleri birleştirip bir öznitelik vektörü elde etmişlerdir. LDA kullanarak, 3 sınıfa (el, ön kol ve arka kol) ait verilerin

sınıflandırmasını yapmışlardır. Sınıfların 2' li ve 3' lü kombinasyonları sonucunda değişik başarı oranları elde etmişlerdir.

Djema vd. (2016), özellik çıkarımı olarak FFT ve AR yöntemlerini birlikte kullanmışlardır. İlk olarak Laplace filtresi kullanarak, verileri ön işlemeden geçirmişlerdir. Her kanala FFT uygulayarak, sinyalde bulunan her bir trigonometrik bileşenin genlik ve faz bilgisini elde etmişlerdir. Zaman bölgesindeki EEG sinyallerinin farklı bir temsili elde etmede kullanılan AR katsayılarını hesaplamışlardır. Tüm bu değerleri bir öznitelik vektöründe toplayarak, SFFS algoritmasıyla özellik seçimi yapmışlardır. LDA, SVM ve k-NN algoritmalarıyla 9 kişiye ait 3 farklı sınıfın (sol el, sağ el ve ayak) sınıflandırmasını yapmışlardır. En yüksek başarıyı LDA ile birlikte ortalama %86.06 olarak elde etmişlerdir.

Taran vd. (2018), farklı motor görevlerinin sınıflandırılmasında analitik iç mod fonksiyonlarından (AİMF) elde edilen özellikleri önermişlerdir. EEG verilerine ampirik mod ayrıştırması uygulayarak farklı frekans değerlerindeki 6 farklı İMF' ye ayırmışlardır. Her bir İMF' nin PSD değerlerini Welch yöntemi kullanarak elde etmişlerdir. Farklı İMF' lerden gelen özellikleri normalize ettikten sonra LS-SVM algoritmasıyla sınıflandırmışlardır. En yüksek sınıflandırma başarısını İMF1 sinyaline ait PSD değerleriyle 2 sınıf için (sağ el ve sağ ayak) ortalama %97.56 olarak elde etmişlerdir.

Duan vd. (2015), EEG verilerinden özellik çıkarmak ve aynı zamanda boyut azaltmak için PCA yöntemini önermişlerdir. Genellikle sınıflandırma için kullanılan karar ağacı yöntemiyle ise özellik seçimi yapmışlardır. İlk olarak, belirlemiş oldukları EEG kanallarına PCA uygulayarak elde ettikleri özelliklerden en uygun olanlarını karar ağacı yöntemiyle seçmişlerdir. Daha sonra bu özellikleri bir öznitelik vektöründe birleştirmişlerdir. SVM ile sınıflandırarak 2 sınıf için ortalama %88.23 başarı elde etmişlerdir.

Chatterjee vd. (2019), çalışmalarında sol ve sağ el motor görevlerinin sınıflandırılması için 2 farklı veri seti kullanmışlardır. Her iki veri seti C3, Cz ve C4 kanallarından alınan EEG verilerinden oluşmaktadır. Özellik çıkarımı için AAR yönteminin, RLS (Yinelemeli En Küçük Kareler) modelini önermişlerdir. İlk olarak, ham EEG verilerine 0.5-50 Hz arası band geçiren bir filtre uygulamışlardır. Filtrelenmiş sinyallerin, C3 ve C4 kanallarındaki AAR katsayılarını hesaplamışlardır. Bu değerleri öznitelik vektöründe birleştirmişlerdir. FDM yöntemiyle en uygun özellikleri seçip, SVM ile sınıflandırmışlardır. 2 farklı veri seti için %80 ve %78.57 başarı değerleri elde etmişlerdir.

Duan vd. (2017), farklı motor görevlerinden özellik çıkarmada PCA ile birlikte LDA yöntemini önermişlerdir. Bu sayede, düşük veri boyutuyla birlikte yüksek sınıf ayırt ediciliği elde etmişlerdir. Seçmiş oldukları A1 ve A2 elektrotlarındaki verileri 9 ayrı dilime ayırmışlardır ve her bir dilim 128 veriden oluşmaktadır. PCA uygulayarak her bir dilimdeki veri sayısını 16 değere düşürmüşlerdir. LDA ile 16 boyutlu özellikleri, 1 boyutlu özelliklere indirgemişlerdir. Böylece 1 kanaldan 9 değer ve 2 kanaldan toplamda 18 adet öznitelik elde etmişlerdir. KHELM algoritmasıyla sınıflandırarak 2 sınıf için %94.54 başarı elde etmişlerdir.

Tang vd. (2020), EEG sinyallerinden gürültünün giderilmesi için deneysel ampirik mod ayrıştırması (CEMD) kullanmışlardır. Yöntem, EMD algoritmasıyla elde edilen İMF'lerden en uygun olanlarını seçmek için 2 koşuldan oluşmaktadır. Bu koşullar sırasıyla orijinal EEG sinyali ile İMF'ler arasındaki korelasyon katsayısı ve göreceli enerji oranlarıdır. Buna göre korelasyon katsayısı ne kadar büyükse, İMF o kadar etkili bilgi içermektedir. Benzer şekilde daha büyük göreceli enerji oranı, İMF'nin daha etkili bilgileri kapsadığı anlamına gelmektedir. Bu şartlara göre en uygun İMF'ler birleştirilerek EEG sinyali tekrardan oluşturulur. Daha sonra, kanallar arasında ERD/ERS bilgilerini çözmek için EEG sinyallerini farklı bir tarzda birleştirmişlerdir. Kafadan karşılıklı olarak sol taraftaki elektrotlardan alınan sinyaller ile, sağ taraftan alınan sinyallerin farkını alarak, yeni sinyaller elde etmişlerdir. Elde ettikleri sinyalleri, Tek Boyutlu Çok Ölçekli Evrişimli Sinir Ağı (1DMSCNN) kullanarak sınıflandırmışlardır. Sınıflandırma sonucunda 2 sınıf için ortalama %82.61 başarı elde etmişlerdir.

Zhang vd. (2018), ilki sağ el ve ayak, ikincisi sağ el ve sol elden oluşmak üzere 2 farklı veri setine ait motor görevlerinin sınıflandırması üzerine çalışma yapmışlardır. 4-40 Hz band aralığında filtrelenmiş EEG verilerine, CSP yöntemi uygulamışlardır. Böylece bir sınıfa ait EEG verilerinin varyans değerleri minimuma indiği, diğer sınıfın ise varyans değerlerinin maksimuma çıktığı düşük boyutlu öznitelik vektörlerini elde etmişlerdir. Çıkarılan öznitelik vektörlerini, Multi-kernel ELM ağının girişine uygulamışlardır. Sınıflandırma sonucunda 5 kişiye ait el ve ayak motor görevleri için ortalama %87.5, 9 kişiye ait sağ el ve sol el motor görevleri için ortalama %78.9 başarı elde etmişlerdir.

Yang vd. (2020), 4 farklı sınıfı (sol el, sağ el, ayak ve dil) içeren motor hayali sinyallerinin sınıflandırmasını yapmışlardır. Band geçiren bir filtre kullanarak EEG verilerini farklı frekanslardaki dilimlere ayırmışlardır. Çoklu Riemann Kovaryansı (MRC) tabanlı öznitelik çıkarma yöntemini kullanmışlardır. Yöntem, her bir alt frekans bandı için kanallar arasındaki kovaryans matrisini hesaplamaya dayanmaktadır. Her bir alt banttaki gelen özellikleri bir öznitelik

vektöründe birleştirerek Çok Katmanlı Perceptron (MLP) ile sınıflandırmışlardır. Elde ettikleri sınıflandırma başarısı 9 kişi için ortalama %76.05' tir.

Alvarez-Meza vd. (2015), 2 sınıf (sol ve sağ el) MI sinyallerinden özellik çıkarmada hem zamansal hemde frekans bazlı yöntemleri kullanmışlardır. Ön işlemeden geçirilen EEG verilerinin alfa (8-13 Hz) ve beta (13-30 Hz) ' lik band aralıklarından özellikleri çıkarmışlardır. Bu kapsamda, her bir kanalın PSD değerlerini, CWT ve DWT' yi ayrı ayrı kullanarak hesapladıkları dalgacık katsayılarını ve hjort parametreleri başlığı altında aktivite, hareketlilik ve karmaşıklık gibi özelliklerini elde etmişlerdir. Öznitelik vektöründe birleştirdikleri değerleri 2 farklı veri setinde uygulamışlardır. SVM ile sınıflandırdıklarında 7 kişiye ait veri seti için ortalama %92.86, 9 kişiye ait veri seti için ortalama %72.30 sınıflandırma başarısı elde etmişlerdir.

Shajil vd. (2020), 4 sınıf (sol el, sağ el, ayak ve dil) motor görevlerine ait EEG verilerinden özellik çıkarmada CSP algoritmasını kullanmışlardır. Uzamsal olarak filtrelenmiş sinyallere Hamming penceresiyle birlikte Kısa-Süreli Fourier Dönüşümü uygulanmıştır. Sonuç olarak sinyallerin 2 boyutlu spektogramlarını (zaman-frekans-enerji) görüntülerini elde etmişlerdir. Bu spektogramları augmente ederek eğitim verilerinin boyutunu arttırmışlardır. 4 sınıf için elde ettikleri spektogram görüntülerini CNN derin öğrenme modelinin girişine uygulamışlardır. Sınıflandırma sonucunda 12 kişi için ortalama %87.37 başarı elde etmişlerdir.

3. GENEL KISIMLAR

3.1. EEG' nin Tarihsel Gelişimi

EEG sinyallerinin tarihsel gelişimi, 1875 yılında, İngiliz bir doktor olan Richard Caton' un hayvanların beynindeki elektriksel akımları keşfetmesiyle başlamıştır. Caton, tavşanlar ve maymunlar üzerinde yapmış olduğu deneyler sonucunda hayvanların beyinlerinde bir takım elektriksel aktivitelerin olduğunu fark etmiştir. Deneylerinde, hayvanların gözlerine ışık uyarıtımı uygulamış ve galvanometre aracılığıyla beyinlerindeki elektriksel potansiyellerde negatif yönde sapmalar olduğunu göstermiştir. 1890 yılında, Polonyalı bir fizyolog olan Adolf Beck, felçli köpek ve tavşanlar üzerinde yapmış olduğu deneylerde beyin korteksinin elektriksel ve duyuşal uyarımlara cevap veren kısımlarını araştırmıştır. Beck, uyarılma sonucunda beyindeki elektriksel potansiyellerin değişimini fark etmiştir ve bu dalgalanmaların kalp ve solunum ritimleriyle alakalı olmadığını göstermiştir. 1913 yılında, Ukraynalı bir fizyolog olan Vladimir Pravdich-Neminsky tarafından bir köpeğe ait kaydedilmiş ilk hayvan EEG' si yayınlanmıştır (Coenen ve Zayachkivska, 2013).


İnsan beyninin ilk kez elektriksel aktivitesinin ölçülmesi, Alman nöropsikiyatristi olan Hans Berger tarafından 1924 yılında gerçekleştirilmiştir. Richard Caton ve diğerlerinin hayvanlar üzerinde yürüttüğü çalışmaları genişleten Berger, klinik nöroloji tarihindeki en önemli bir buluş olarak adlandırılan elektroensefalogram' ı keşfetmiştir. Berger, kafa derisi üzerine yerleştirilen elektrotlar ve bu elektrotlara bağlı hassas bir galvanometre aracılığıyla elektriksel potansiyellerin varlığını göstermiştir. Ayrıca, bu potansiyellerin kafatasını açmadan kaydedilebileceğini ve bir kâğıt üzerinde grafiksel olarak temsil edilebileceğini kanıtlamıştır. Çalışmalarında daha çok uyku EEG' si, anestezi ve epileptik deşarjlar gibi alanlara yoğunlaşmış ve bu durumlar altında beyin farklı elektriksel aktiviteler gösterdiğini savunmuştur. 1929 yılında, yayınlamış olduğu bir makalede beyin sinyallerinin göz açma ve kapama esnasında değiştiğinden bahsetmiştir ve bu dalgaları sırasıyla beta ve alfa ritimleri olarak isimlendirmiştir. 1934 yılında, Adrian ve Matthews, alfa ve beta ritimlerini doğrulayan bir makale yayınlamışlardır ve bu konu onlar tarafından geliştirilmiştir. 1957 yılında, İngiliz nörofizyolog olan William Grey Walter, EEG topografyası adı verilen ve elektriksel aktivelerin beyin yüzeyi boyunca 2 boyutlu olarak haritalanmasını sağlayan bir cihaz geliştirmiştir. 1988 yılında, Stevo Bozinovski, Mihail Sestakov ve Liljana Bozinovska tarafından, EEG sinyallerini kullanarak bir robotun kontrol edilmesi sağlanmıştır. Günümüzde, EEG sinyallerini kullanarak nörolojik hastalıkların teşhisi gibi birçok klinik uygulama ve robot, drone gibi elektronik cihazların kontrolü yapılmaktadır (Mantri vd., 2013; Aghayousefi ve Delrobaei).

3.2. EEG Sinyalleri

Beyindeki sinir hücrelerinin birbirleriyle etkileşimi sonucunda elde edilen elektriksel potansiyellerin kâğıt üzerine kaydedilmesi yöntemine EEG (Elektroansefalogram) denir. EEG sinyalleri, belirli aralıklarla kafa derisi üzerine yerleştirilmiş elektrotlar aracılığıyla elde edilir. Bu sinyaller ile beynin elektriksel aktivitesi değerlendirilerek, çeşitli hastalıkların teşhis edilmesi sağlanır. EEG sinyalleri daha çok uyku bozuklukları, alzheimer hastalığı, dikkat eksikliği, beyin tümörleri, migren, travmatik sinir bozuklukları, bunama ve epilepsi gibi hastalıkların tanısında kullanılır (Olejniczak, 2006; Siuly vd., 2016).


EEG sinyalleri, durağan olmayan ve aperiodyk formdaki sinyallerdir. Bu sinyallerin genlik, frekans ve faz gibi bileşenleri zaman içerisinde beyin aktivitesine bağlı olarak sürekli değişmektedir (Von Bünau vd., 2010). Genlikleri çok düşük değerlerde olmakla birlikte, tepeden tepeye 0,5 ile 100 μ V arasında değişmektedir. EEG sinyallerinin genlikleri, EKG sinyallerinden 100 kat daha küçüktür. EEG sinyallerinin frekans bandı aralığı ise 0.5 ile 100 hz arasındadır (Teplan, 2002). Beyin aktivitesi arttığı zaman, nöronlar arasındaki senkronizasyon bozulur. Bu durumda EEG sinyallerinin frekansı artar ve genliği düşer. Sakin bir halde veya uyku durumundayken, nöronlar arasındaki senkronizasyon artar. Bu durumda ise frekans azalır ve genlik artar (Duman vd., 2005). EEG sinyallerinin işlenmesinde frekans analizi önemli bir işlem olduğundan, bu sinyaller 5 farklı frekans bandına bölünmüştür:

- **Delta (δ) Dalgaları:** 0.5 ile 4 hz arasında görülen beyin dalgalarıdır. Bu dalgaların salınımı oldukça yavaştır ve genlikleri ise yüksektir. Genellikle bebeklerde ve yetişkinlerin derin uyku evrelerinde oluşmaktadır (Mantri vd. 2013; Siuly vd. 2016). Şekil 3.1' de Delta dalgası gösterilmiştir.




Şekil 3.1. Delta dalgası.

- **Teta (θ) Dalgaları:** 4 ile 8 hz arasında görülen dalga tipidir. Hayal kurma ve derin rahatlama esnalarında oluşurlar. Yoğun olarak, vücudun alın ve şakak bölgelerinde ortaya çıkarlar (Mantri vd. 2013; Siuly vd. 2016). Şekil 3.2' de Teta dalgası gösterilmiştir.




Şekil 3.2. Teta dalgası.

- **Alfa (α) Dalgaları:** 8 ile 13 hz arasında görülen beyin dalgalarıdır. Gözlerin kapalı olduğu ve kişinin kendisini sakin hissettiği durumlarda oluşurlar. Genlikleri, delta ve teta dalgalarına göre daha düşüktür. Uyku aşamasına gelindiğinde veya gözler açıldığında yok olurlar (Mantri vd. 2013; Siuly vd. 2016). Şekil 3.3' te Alfa dalgası gösterilmiştir.




Şekil 3.3. Alfa dalgası.

- **Beta (β) Dalgaları:** 13 ile 30 hz arasında görülen dalga tipidir. Kişilerde, aktif olarak düşünme ve bir işe konsantrasyon olma gibi durumlarda oluşmaktadır. Bu dalgalar, motor korteks üzerinde baskın olarak görülmektedir (Mantri vd. 2013; Siuly vd. 2016). Şekil 3.4' te Beta dalgası gösterilmiştir.



Şekil 3.4. Beta dalgası.


- **Gamma (γ) Dalgaları:** 30 hz ve üzerindeki beyin dalgalarıdır. Sportif faaliyetler, matematiksel becerilerin geliştirilmesi, stress ve hatta depresyon gibi bedensel ve ruhsal bakımdan yüksek enerji harcanan durumlarda ortaya çıkarlar. Genlikleri diğer dalgalara kıyasla en küçük dalga tipidir (Mantri vd. 2013; Siuly vd. 2016). Şekil 3.5' te Gamma dalgası gösterilmiştir.



Şekil 3.5. Gamma dalgası.

3.3. EEG Sinyallerinin Oluşumu

Beyindeki elektriksel yük akışı, nöron adı verilen sinir hücrelerinden oluşmaktadır. Yetişkin bir insan beyinde yaklaşık 100 milyar nöron bulunmaktadır. Nöronlar, sahip oldukları elektrokimyasal yapıları sayesinde elektriksel sinyallerin iletimini sağlarlar. Bir sinir hücresi; hücre gövdesi (soma), akson, dendritler ve terminal dalları olmak üzere 4 temel kısma ayrılır (Siuly vd., 2016). Şekil 3.6’ da bir sinir hücresinin yapısı gösterilmiştir.




Şekil 3.6. Sinir hücresinin yapısı (Siuly vd., 2016).

Hücre gövdesinde, hücrenin yaşamsal faaliyetlerini sağlayan hücre çekirdeği bulunmaktadır. Dendritler, hücre gövdesinden çıkan ve çok sayıda resöptörü bulunan dallanmış yapıdaki uzantılardır. Görevleri, diğer nöronlardan gelen uyarıları hücre gövdesine iletmektir. Dendritlerin çok sayıda olması, aynı anda daha fazla nörondan sinyal alınması anlamına gelmektedir. Akson, kendi nöronunun çekirdeğini, diğer nöronunun dendritine bağlayan uzun ve ince kısımdır. Aksonun görevi, hücre gövdesinden alınan bilgileri diğer nöronlara iletmektir. Terminal dalları, aksonun ucunda bulunan yapılardır ve diğer nöronlara bilgi iletimini sağlarlar. Aksonun etrafını saran kılıfa miyelin kılıfı denir. Miyelin kılıfı, aksonun elektriksel izolasyonunu sağlayarak bilgi iletimini hızlandırır (Siuly vd., 2016).

Nöronlar kendi aralarında akson-dendrit bağı kullanarak iletişim kurarlar. Bu iletişim, aksiyon potansiyeli sayesinde gerçekleşmektedir. Aksiyon potansiyeli, bir aksonun iyonik yapısını hızla değiştiren ve aksondan dendrite doğru bilginin iletilmesine olanak sağlayan kısa süreli elektrik etkisi olarak tanımlanabilir. İyonik yükteki hızlı değişme sonucunda, nöronlarda bir voltaj üretilir. Nöronlarda üretilen bu elektriksel aktivite, korteks bölgesinde toplanır ve kafa derisi yüzeyine doğru uzanır. Bu aktiviteler, kafa derisi üzerine yerleştirilmiş elektrotlar aracılığıyla kayıt edilirler (Siuly vd., 2016). Ayrıca, sadece kalabalık nöron gruplarının etkileşimi

kafa derisi üzerinde kaydedilebilir bir elektriksel aktivite oluşturur. Tek bir nöronun ürettiği voltaj, günümüz teknolojisiyle ölçülemeyecek kadar küçüktür. Şekil 3.7’ de sinir hücresinde oluşan elektriksel aktivite ve eeg elektrotu yardımıyla elde edilmesi gösterilmiştir.



Şekil 3.7. Sinir hücresinde elektriksel aktivitenin oluşumu ve EEG ile ölçümü (Siuly vd., 2016).

3.4. EEG Sinyallerindeki Artifaktlar

EEG sinyallerinde, korteks kökenli olmayan bozucu etkiye sahip sinyallere artifakt denir. EEG sinyallerinin aksine, artifaktlar genellikle daha yüksek genliklere sahiptir. EEG kaydındaki artifaktlar, iç (biyolojik) ve dış (teknik) artifaktlar olmak üzere 2’ ye ayrılır:


3.4.1. İç artifaktlar

EEG kaydı esnasında; göz hareketlerinin (EOG), kalp aktivitesinin (EKG), çene, bacak, kol, yutkunma gibi kas hareketlerinin (EMG) ve hatta terlemenin neden olduğu istenmeyen biyolojik kökenli sinyallerdir. EKG’ den kaynaklanan artifaktlar sabit olmakla birlikte diğerleri geçici etkiye sahiptir (Paszkiel, 2020; Peng, 2019).

3.4.2. Dış artifaktlar

Genellikle EEG ölçüm cihazından kaynaklanan bozucu sinyallerdir. Çok fazla elektrot jeli kullanımı, deri yüzeyi ile elektrotlar arasındaki temassızlık, kablo hareketleri, düşük pil kullanımı gibi nedenler dış artifakt oluşumuna sebep olur. Ayrıca, kayıt ortamında bulunan cep

telefonu ve elektronik cihazlarla birlikte 50 hz şebeke sinyali, EEG sinyallerinde bozucu etkilere sahiptir (Paszkiel, 2020; Peng, 2019).



Şekil 3.8. EEG kaydı esnasında farklı sebeplerden oluşan artifaktlar (Siuly vd., 2016).

Şekil 3.8’ de, EEG kaydı esnasında en çok karşılaşılan 4 farklı artifakt tipi gösterilmiştir. 1 no’ lu kısımda göz kırpmadan kaynaklanan aşağı yönlü ve büyük bir genliğe sahip artifakt türü gösterilmiştir. 2 no’ lu kısımda elektrot başlığı ile cilt temasının kötü olması sonucunda büyük empedanstan kaynaklanan artifakt türü gösterilmiştir. 3 no’ lu kısımda yutkunma esnasında kasların kasılmasından kaynaklanan artifakt türü gösterilmiştir. 4 no’ lu kısımda referans elektrot ile kafa derisi yüzeyi arasındaki kötü temas veya temassızlıktan kaynaklanan artifakt türü gösterilmiştir (Siuly vd., 2016). Araştırmacılar tarafından, EEG sinyallerinden bu tip artifaktların giderilmesinde çoğunlukla Bağımsız Bileşen Analizi (ICA) ve Ortak Uzaysal Filtre (CSP) algoritmaları kullanılmaktadır (Lakshmi vd. 2014).


3.5. Beyin Aktivitelerinin Ölçülmesi

3.5.1. EEG, ECoG ve LFP/MUR

EEG, beyindeki nöronların aktivitesi sonucunda oluşan elektriksel potansiyelleri kafa derisi üzerine yerleştirilen elektrotlar aracılığıyla elde etmeye yarayan invazif olmayan bir yöntemdir. Yüksek zaman çözünürlüğü, taşınabilirliği, kullanım açısından pratikliği ve düşük maliyete sahip olması gibi nedenlerle sıklıkla tercih edilmektedir. EEG yöntemi; uyku bozuklukları, beyin tümörleri, baş ağrıları, baş dönmesi, hafıza kaybı ve epilepsi gibi birçok

nörolojik hastalıklarının tanısında ve beyin fonksiyonlarını incelenmesinde nörologlar ve araştırmacılar tarafından kullanılmaktadır (Xia ve Hu, 2019).


EEG kaydı esnasında elektrot adı verilen iletken malzemeler, kafa derisi yüzeyinde farklı konumlara yerleştirilir. Elektrotlar aracılığıyla nöronlar arasındaki düşük genlikli biyoelektriksel potansiyeller elde edilir. Bu potansiyeller amplifikatörler aracılığıyla yükseltilir ve bilgisayar ortamında kaydedilir. EEG kayıtları, 1 ile 256 arasında değişen sayılardaki elektrotlara sahip olabilir. Şekil 3.9’ da EEG yöntemiyle beyin sinyallerinin elde edilmesi gösterilmiştir.



Şekil 3.9. EEG ile beyin sinyallerinin elde edilmesi (Siuly vd., 2016).

Serebral korteks içerisinde farklı tipteki loblar olduğundan, EEG elektrotlarının kafa derisi üzerine yerleştirilmesi önemli bir konudur. Çünkü farklı türdeki aktivitelerin işlenmesinden farklı serebral korteks lobları sorumludur. Elektrotların kafa derisi üzerine yerleştirilmesinde standart yöntem uluslararası 10-20 elektrot sistemidir. Bu sisteme göre, elektrotlar arasındaki mesafe, kafa yüzeyinin ön ile arka veya sağ ile sol tarafları arasındaki toplam mesafenin, %10’ u veya %20’ si kadardır.

Şekil 3.10' da uluslararası 10-20 elektrot sisteminin kafa derisi üzerindeki yerleşimi gösterilmiştir (Siuly vd., 2016).




Şekil 3.10. Uluslararası 10-20 elektrot sistemi (Siuly vd., 2016).

Her elektrotta, bulunduğu lob bölgesini tanımlamak için bir harf ve kafa üzerindeki konumunu temsil etmek için bir sayı bulunur. F, T, C, P ve O harfleri sırasıyla Frontal, Temporal, Central, Parietal ve Occipital' i temsil eder. "Z" harfi, orta kısma yerleştirilmiş elektrotları temsil eder. Çift sayılar sağ yarım küredeki elektrot konumlarına karşılık gelirken, tek sayılar sol yarım küredekilere karşılık gelir (Siuly vd., 2016).

Kortex yüzeyindeki aktiviteleri kaydetmek için ameliyat esnasında beyine intracortical adı verilen iğne elektrotlar yerleştirilir. Bu şekilde elde edilen elektriksel aktiviteye ECoG (Elektrokortigram) denir. ECoG yöntemi, kişide cerrahi operasyon gerektiren yani invazif olan bir yöntemdir. Yüzey elektrotları ile elde edilen EEG sinyalinin genliği, normal bir yetişkinde tipik olarak yaklaşık 1 ile 100 μ V arasındayken, iğne elektrotları kullanarak ölçüldüğünde ise yaklaşık olarak 10-20 mV' dir (Siuly vd., 2016). ECoG ile elektriksel potansiyeller doğrudan korteksin yüzeyinden kaydedilir. Böylece bu sinyallerin kafatası ve diğer ara dokular aracılığıyla bozulması engellenir. Korteks bölgesindeki elektriksel aktiviteleri kaydeden EEG ve ECoG' nin aksine, LFP/MUR (Yerel Alan Potansiyelleri, Çok Üniteli Kayıt) yöntemi temel olarak daha derin katmanlardaki elektriksel aktivitelerle ilgilendir. LFP' de, beyin içerisine cam veya silyondan yapılmış hassas mikroeletrotlar yerleştirilerek nöronların aktivitesi kaydedilir. LFP yöntemi aşırı invazif bir yöntemdir (Xia ve Hu, 2019).

Şekil 3.11’ de EEG, ECoG ve LFP yöntemlerinin kafa bölgesindeki elektrot konumları gösterilmiştir.



Şekil 3.11. EEG, ECoG ve LFP elektrotlarının kafa bölgesindeki konumları (Xia ve Hu, 2019).

Kaliteli bir EEG sinyali elde etmek için temel koşul, elektrot direncinin 10k değerinden düşük olmasıdır. Ayrıca kullanılan elektrotların, kafa derisi yüzeyiyle temasının iyi olması ve iletken bir sıvı kullanarak iletkenliğinin artırılması gerekir. Ek olarak, beyindeki nöronlar arasındaki etkileşimin senkronize olması durumunda EEG sinyalini ölçmek kolaylaşır (Paszkiel, 2020).

3.5.2. Manyetoensefalogram (MEG)

Beyindeki nöronların birbirleriyle etkileşimleri sonucunda elektriksel akımlar oluşur. Bu elektriksel akımlar, nöronların çevrelerinde manyetik alanlar oluşturur. Oluşturulan manyetik alanları çok hassas manyetometreler kullanarak kayıt eden ve beyin aktivitesini haritalamayı sağlayan fonksiyonel görüntüleme tekniğine Manyetoensefalogram (MEG) denir. MEG tekniği, kısaca beyin tarafından üretilen manyetik alanın kaydı ile ilgilenir. Fakat, nöronların faaliyetleri sonucunda üretilen nöromanyetik alanlar oldukça zayıf olduğundan ölçülmeleri çok zordur. MEG yöntemi, Süper İletken Quantum Cihazlarının (SQUIDS) geliştirilmesiyle uygulanabilir bir hale gelmiştir. SQUIDS’ ler beyindeki manyetik alanları tespit eden hassas yapıdaki manyetometrelerdir. Günümüzde MEG cihazlarında kullanılan SQUID sensörleri, çok düşük empedansa sahiptirler. MEG tekniği, EEG’ ye göre oldukça pahalı olan ve invazif olmayan bir yöntemdir (Paszkiel, 2020; Lakshmi vd., 2014).

3.5.3. Fonksiyonel manyetik rezonans görüntüleme (fMRI)

Fonksiyonel manyetik rezonans görüntüleme (fMRI), beyin aktivasyonunu kandaki oksijen seviyesine bağlı olarak gösteren fonksiyonel bir görüntüleme tekniğidir. Bu yöntem, sinir hücresi aktivitesi sırasında oksijen ihtiyacının artması ve karbondioksit üretiminin yoğunlaşması prensibine dayanmaktadır. fMRI yöntemi dinlenme ve zihinsel faaliyetler gibi farklı işlevler sırasında beyindeki bölgelerde oluşan nöral aktivite farklılıklarını tespit ederek bu olaylara ilişkin bilgilerin elde edilmesini sağlar. Nöral aktivite tarafından tetiklenen yerel kan akımındaki artış, kandaki oksijen seviyesini yükseltir. Belirli bir bölge aktivitesindeki artış, manyetik rezonans sinyal yoğunluğunun kandaki oksijen seviyesine bağımlılığını tanımlayan BOLD (Blood Oxygenation Level Dependent) sinyali ile ölçülür. BOLD sinyali, kandaki oksijenlenme seviyesini gösterir ve nöral aktivite hakkında doğrudan fikir vermez. Kandaki oksijen artışı peşi sıra ölçülen fonksiyonel MR görüntüleri aracılığıyla tespit edilerek nöral aktivitenin ölçümü yapılır. Yani, nöral aktivite vasküler sistemdeki değişiklikleri temel alınarak hesaplanır. Diğer bir deyişle, fMRI tekniğinde nöral aktiviteler dolaylı yoldan ölçülür. fMRI, kişilerde herhangi bir operasyon gerektirmedikten invazif olmayan bir yöntemdir. Beyin tümörleri gibi çeşitli nörolojik hastalıkların tanısında nörologlar tarafından sıkça kullanılmaktadır (Paszkiel, 2020; Lakshmi vd., 2014).

3.5.4. Pozitron emisyon tomografisi (PET)

Pozitron emisyon tomografisi (PET), organlar ve dokuların fonksiyonlarındaki değişiklikleri anatomik detaylarla birlikte gösteren medikal bir görüntüleme tekniğidir. PET sistemleri ile beyindeki nörolojik hastalıkların neden olduğu yapısal ve işlevsel değişiklikler eş zamanlı olarak incelenebilir. Bu yöntemde; pozitron tipi ışıma yapan radyoaktif madde hastaya damar yolundan uygulanır. Radyoaktif bozunma nedeniyle oluşan pozitronlar, birkaç milimetrelik mesafeyi kat ettikten sonra dokudaki elektronlarla çarpışarak yok olurlar. Elektron-pozitron çiftinin yok olmasından dolayı zıt yönlerde hareket eden fotonlar oluşur. Belli bir süre boyunca verilen radyoaktif maddeden kaynaklanan fotonların tüm vücuda yayılması ve ilgili dokularda tutulması için beklenir. Kamera altına alınan hastanın, kısa bir süre içerisinde ilgili dokuya ait bilgisayarlı tomografi ve pozitron emisyon tomografi (PET) görüntüleri üç boyutlu olarak elde edilir. Organ ve dokulardaki normal ve normal dışı metabolik fonksiyon gösteren patolojik bölgelerin üç boyutlu görüntülenmesi sağlanır. Başta epilepsi, alzheimer ve beyin tümörleri olmak üzere birçok nörolojik hastalığın tanısında PET yöntemi uygulanmaktadır. Fakat, radyoaktif malzeme enjeksiyonu ve sınırlı zamansal çözünürlüğüne sahip olması bazı dezavantajlarıdır (Paszkiel, 2020; Ray ve Slobounov, 2006).

3.5.5. Fonksiyonel yakın infrared spektroskopisi (fNIRS)

Fonksiyonel yakın kızılötesi spektroskopisi (fNIRS), kızıl ötesi dalgalar ile insan beyni korteksindeki hemodinamik aktiviteleri ölçen invazif olmayan bir beyin görüntüleme tekniğidir. fNIRS yöntemi, beyindeki kan oksijenlenmesinden faydalanarak dolaylı yoldan beyin aktivitelerinin ölçülmesini sağlar. fNIRS cihazı, üzerinde çalışılan dokuya kızılötesi ışınları gönderir. Kızılötesi ışınları kafa derisinden 3 cm' ye kadar derinliğe iner. Bu derinlik, pratik olarak beynin korteksini içermektedir. Işınlar doku içinde yay çizererek tekrar yüzeye yönelir, kısmen geri yansır. Yetişkinlerde yansıyan ışık, gönderilen ışığın yüz milyonda, hatta milyarda biri kadar düşük bir seviyeye düşer. Bu ışık, ışık toplayıcılar ile toplanır. Cihazdan gönderilen ve dedektörden toplanan ışık incelenir. Emilme miktarı üzerinden o bölgedeki oksijen-hemoglobin ve deoksi-hemoglobin değişiklikleri ile toplam kan hacmi değişiklikleri ölçülür. Bu veriler beyin üzerinde hareketli ve renkli görüntülere dönüştürülerek beyin aktivitelerinin ölçümü yapılır. Hafif ve tanımlanabilir olması sebebiyle çeşitli nörolojik hastalıkların tanısında ve motor görevleri sırasında beyin aktivitelerini incelemek için kullanılmaktadır (Paszkiel, 2020; Lakshmi vd., 2014).

Çizelge 3.1. Beyin aktivitelerinin ölçülmesinde kullanılan yöntemlerin karşılaştırılması (Lakshmi vd., 2014; Tiwari vd., 2018).

Method	Tip	Ölçüm Şekli	Avantajları	Dezavantajları
EEG	Elektrofizyolojik	Elektriksel potansiyeller	Güvenli ve kolay teknik, düşük maliyet	EOG, EKG gibi gürültü sinyallerine duyarlı
ECoG	Elektrofizyolojik	Elektriksel potansiyeller	Detaylı bilgi, düşük hata oranı	İnvazif teknik
LFP	Elektrofizyolojik	Elektriksel potansiyeller	Daha detaylı bilgi	Aşırı invazif teknik
MEG	Elektrofizyolojik	Manyetik alanlar	İyi zamansal çözünürlük	Çok yüksek maliyet
fMRI	Metabolik bazlı	Metabolik faaliyetler	İyi zamansal ve uzaysal çözünürlük	Veri alma süresi fazla
PET	Metabolik bazlı	Metabolik faaliyetler	İşlevsel ve biyolojik bilgi	Radyoaktif malzeme enjeksiyonu,
fNIRS	Metabolik bazlı	BOLD yanıtını kullanan metabolik	Yüksek uzaysal çözünürlük,	Düşük zamansal çözünürlük, kısıtlı

Çizelge 3.1' de, beynin elektriksel aktivitelerini ölçmede kullanılan elektrofizyolojik ve metabolik bazlı yöntemlerin karşılaştırılması gösterilmiştir. EEG, ECoG ve LFP gibi elektrofizyolojik yöntemler, kafa derisi yüzeyi veya kortekstelektrotlardan alınan elektriksel sinyalleri kullanarak çalışır. MEG yöntemi, elektriksel akımların sonucunda oluşan manyetik alanları tespit eden sensörleri kullanarak çalışır. Elektrofizyolojik yöntemlerden EEG; güvenilirliği, düşük maliyeti ve kullanım pratikliği açısından en yaygın olarak kullanılan tekniktir. Metabolik bazlı yöntemler, kişilerde herhangi bir cerrahi işlem gerektirmediğinden invazif değildir. Bu yöntemler ile nöral aktivitelerin incelenmesinde vücuttaki metabolik faaliyetlerden yararlanır ve dolaylı bir yoldan nöral aktivite değerlendirilmesi gerçekleştirilir. Metabolik bazlı teknikler arasında fMRI, nöral haritalama konusunda oldukça başarılıdır.


3.6. Beyin Bilgisayar Arayüzü (BBA)

3.6.1. BBA' nın genel tanımı

BBA sistemleri, insan beyni ile harici elektronik cihazlar arasında iletişim kurulmasına olanak sağlayan teknolojilerdir. BBA sistemleri, hayatımızın bir parçası olan akıllı cihaz kontrollerinde ve bedensel engelli insanların hayatlarını kolaylaştıracak biyomedikal uygulamalar gibi geniş bir alanda araştırmacılar tarafından kullanılmaktadır. Bu sistemler, biyoelektrik beyin aktivitesini analiz ederek zihinsel kararları kontrol komutlarına dönüştürürler. BBA uygulamalarında, sinyal elde edilmesinin kolaylığı ve yüksek zaman çözünürlüğüne sahip olması nedeniyle çoğunlukla EEG tekniği tercih edilir (Tosun vd., 2018). Yapılan BBA çalışmalarında, farklı motor hareketlerinin hayali esnasında elde edilen μ ve β ritimlerine ait ERD/ERS potansiyelleri, kararlı durum görsel uyarılmış potansiyelleri (SSVEP), yavaş kortikal potansiyelleri (SCP) ve P300 gibi çeşitli EEG sinyalleri kullanılmıştır (Amiri vd., 2013).

EEG tabanlı BBA sistemlerinde, sinyallerin elde edilebilmesi için kişilerin kafasına bir elektrot başlığı yerleştirilir. Kişiler; ilgili uzuvlarının hareketlerine ait görevleri belirli bir zaman aralığında hayal ederler. Farklı sınıflara ait görevler, elde edilen sinyallerin karakteristik yapısını etkilerler. Bu sinyallerin bilgisayarlar aracılığıyla farklı yöntemler kullanılarak özellik çıkarma ve sınıflandırma işlemleri yapılır. Yapılan sınıflandırma sonucunda kişilerin robot kolu, tekerlekli sandalye veya bir bilgisayarın imleç hareketlerini kontrol etme gibi değişik uygulamalar yapılabilir. BBA sistemleri, kişilerde kas gücü gerektirmediğinden bedensel engelli kişilerin motor faaliyetlerini yürütmelerinde kolaylık sağlarlar (Ochoa, 2002).

Şekil 3.12’ de, BBA sisteminin blok diyagramı gösterilmiştir.



Şekil 3.12. BBA sisteminin blok diyagramı (Siuly vd., 2016).

Sinyal alımı: Beyin aktivitelerinin elde edilmesinde; EEG, MEG, fMRI, PET ve fNIRS gibi çeşitli invazif olmayan yöntemler kullanılır. BBA sistemlerinde ise, düşük maliyeti ve kullanım pratikliği bakımından EEG tekniği tercih edilir. Kişilerin kafasına yerleştirilen elektrot başlığı sayesinde farklı sınıflara ait hareket hayallerini temsil eden sinyaller elde edilir (Tiwari vd., 2018).

Ön işleme: Ham EEG sinyalleri; göz hareketleri, göz kırpma, çene hareketi, diş sıkma, herhangi bir kas hareketi veya dış etkenlerden kaynaklanan bozucu sinyallerden etkilenir. Sinyalde herhangi bir bilgi kaybı oluşturmada kaliteli bir sinyal elde edilmesi gerekir. Artifakt adı verilen bozucu sinyal etkilerini ortadan kaldırmak için çoğunlukla Bağımsız Bileşen Analizi (ICA) ve Ortak Uzaysal Filtre (CSP) algoritmaları kullanılır. Aynı zamanda şebeke gürültüsü olan 50 Hz’lik sinyalin etkisi notch filtre yardımıyla giderilebilir (Siuly vd., 2016; Lakshmi vd., 2014).

Özellik çıkarma: BBA sistemleri için oldukça önemli bir konudur. Özellik çıkarma, elde edilen sinyallerin arka planlarında var olan etkinliklerini ayırt etmede önemli bir rol oynar. Kabalık verilerin oluşturduğu ham EEG sinyalleri, özellik çıkarma ile ayırt edici ve çok az sayıda değişken ile temsil edilirler (Siuly vd., 2016). Bu işlem için birçok farklı spektral veya zaman-frekans analizi yöntemleri uygulanmaktadır. Bu yöntemlerin ortak noktaları, zaman bölgesinde tanımlı EEG sinyallerinin frekans bölgesinde sinyallerin güç değerleriyle temsil edilmesidir.

Sınıflandırma: Sınıflandırma işlemi, sinyallerden özellik çıkarma ile elde edilen öznitelik vektörlerini kullanarak bu sinyallerin temsil ettiği sınıflara atamalarını gerçekleştirir. Bu sınıflar, tanımlanan zihinsel durumların türüne karşılık gelmektedir. Her bir sınıfa ait öznitelikler, birbirlerinden ne kadar ayırt edici özelliklere sahipse sınıflandırma başarısı o kadar yüksek olur. Sınıflandırma işlemi için birçok farklı yapay sinir ağları, makine ve derin öğrenme algoritmaları kullanılmaktadır (Siuly vd., 2016).


Komutlara dönüştürme: Yapılan sınıflandırma sonucuna göre ilgili zihinsel faaliyet tespit edilir. Bu zihinsel faaliyet ile bilgisayar, robot veya tekerlekli sandalye gibi belirli bir cismi kontrol etmek için bir komut ilişkilendirilir (Siuly vd., 2016).

Geri bildirim: Son olarak, kullanıcıya tespit edilen zihinsel faaliyet hakkında geri bildirim sağlanır. Bu işlemin amacı, kullanıcının beyin aktivitelerini kontrol etmesine yardımcı olmaktır ve böylece kullanıcı zihinsel performansını arttırmaktadır (Siuly vd., 2016).

3.6.2. BBA sistemlerinde kullanılan EEG sinyalleri

BBA sistemleri kendi içinde bağımlı ve bağımsız BBA olmak üzere 2' ye ayrılırlar. Bağımlı BBA sistemlerini kullanacak olan kişilerin çok fazla hasar görmemiş bir sinir sistemi ve normal fonksiyonlarını yerine getirebilen bir beyine sahip olmaları gerekmektedir. Bağımsız BBA sistemleri, herhangi bir sinir aktivesine ihtiyaç duymadan sadece düşünme yardımıyla çalışan sistemlerdir. Bağımlı ve bağımsız BBA sistemleri de kendi içlerinde uyaranlı ve uyaranlı olmak üzere 2' ye ayrılırlar. SSVEP tabanlı BBA sistemleri, kişilerde göz kasları hasar görmemiş bir sinir sistemi gerektirdiğinden bağımlı bir BBA türü olup, aynı zamanda sistemin çalışabilmesi için görsel uyaranlar gerektirdiğinden uyaranlı bir BBA' dır. P300 tabanlı BBA sistemleri, kişilerin sadece düşüncelerini kullanarak çalıştığından bağımsız bir BBA türü olup, aynı zamanda sistemin çalışabilmesi için görsel veya işitsel uyaranlar gerektirdiğinden uyaranlı bir BBA sistemidir. Sensorimotor ritimleri (μ ve β ritimleri) ve Yavaş kortikal potansiyelleri (Slow Cortical Potential, SCP) ise sadece düşünce yoluyla elde edildiklerinden bağımsız BBA sistemleri olup, sistemin çalışması için herhangi bir uyarana gerek duyulmamaktadır (Olgun ve Türkoğlu, 2017).

Şekil 3.13’ te BBA türlerinde kullanılan farklı tipteki EEG sinyallerinin gruplandırılması gösterilmiştir:




Şekil 3.13. BBA türlerinde kullanılan farklı tipteki EEG sinyalleri.

Olay ilişkili potansiyeller (ERP)

EEG sinyallerinde, görsel ve işitsel gibi çeşitli uyaranlar sonucunda meydana gelen küçük genlik değişimlerine Olay İlişkili Potansiyeller (Event Related Potentials, ERP) denir. Kişilere, titreşimli bir ışık gibi harici bir görsel uyaran sunulduğunda, EEG aktivitesinde çok kısa bir süre içinde potansiyel değişimler oluşur. Bu değişimler, EEG aktivesinde uyarımın uygulandığı zaman değeri baz alınarak zaman bölgesinde analiz edilir. ERP sinyallerinin genlik değerleri, normal beyin aktivitesinin 1/10’ u kadar olduğundan fark edilmeleri oldukça zordur ve belirli bir süre daha uyarım uygulanması gereklidir. Tekrarlanan uyarımlar neticesinde elde edilen EEG sinyallerin ortalaması alınarak, uyarılmış potansiyeller açıkça görünür hale gelmektedir. Gözlemlenen ERP’ lerin genlikleri 10 μV ’ dan daha az ve süreleri yaklaşık 0,5 sn’ dir. (Olgun ve Türkoğlu, 2017; Martišius ve Damaševičius, 2016).

ERP sinyalleri pozitif veya negatif genlik değerlerine sahiptir. Bu sinyaller, pozitif veya negatifliklerine göre bir kısaltma adı ve oluşma süresi ile ifade edilirler. Örnek olarak, EEG aktivitesinde uyarımdan 100 ms oluşan negatif genlikteki ERP sinyaline N100 potansiyeli, yaklaşık olarak 300 ms sonra oluşan pozitif genlikteki ERP sinyaline ise P300 potansiyeli denmektedir. Günümüzde farklı tipteki ERP sinyallerini kullanan BBA sistemleri geliştirilmiştir. Bunlar başlıca olarak P300 uyarılmış potansiyelleri, kararlı durum görsel uyarılmış potansiyelleri (SSVEP), yavaş kortikal potansiyelleri (SCP), mu ve beta ritimlerini içeren ERD/ERS potansiyelleridir (Olgun ve Türkoğlu, 2017; Martišius ve Damaševičius, 2016).

Şekil 3.14’ te ERP sinyallerinin oluşum aşamaları ve elde edilen ERP’ ler gösterilmiştir. ERP grafiğinde aşağı yön pozitif olarak kabul edilmiştir.




Şekil 3.14. ERP’ lerin elde edilmesi ve oluşan farklı tipteki ERP’ ler (San Martin ve Huettel, 2013).

P300 potansiyelleri

Kişilere görsel veya işitsel yoldan harici bir uyarı sunulduğunda, beyin yaklaşık 300 ms sonra verdiği tepkiye P300 potansiyelleri denir. Uyarımın başlamasından itibaren pozitif yönde en büyük sapmalar P300 potansiyellerinde görülmektedir. P300 potansiyelleri, BBA sistemlerinde sıkça kullanılan ERP çeşitidir. İlk P300 tabanlı BBA sistemi, 1988 yılında karakter yazmak amacıyla Donchin ve Coles tarafından icat edilmiştir. Bu sistemde, P300 sinyallerinin elde edilebilmesi için kişilere ilgilenilen uyarının dışında çok fazla alakasız görsel uyarı gösterilir. Kişiler alakasız görsel uyarıların içinden ilgilenilen görsel uyarı ile karşılaştığında, beyin aktivitesinde yaklaşık 300 ms sonra pozitif yönde bir ERP sinyali oluşur. Bu yöntemi kullanarak P300 sinyallerinin elde edilmesi işlemine şaşırtmalı uyarı dizisi adı verilir. Beynin parietal bölgesine yerleştirilmiş P7, P3, P4 ve P8 elektrotlarında P300 sinyallerine yoğun bir şekilde rastlanmaktadır (Olgun ve Türkoğlu, 2017; Fazel-Rezai vd. 2012).

Şekil 3.15' te, P300 heceleme sisteminin arayüzü ve Pz kanalından elde edilen P300 sinyali gösterilmiştir. Şekil 3.15 (b)' de aşağı yön pozitif kabul edilmiştir.




Şekil 3.15. a) P300 heceleme sisteminin arayüzü (Wolpaw vd., 2002) b) P300 sinyali (Olgun ve Türkoğlu, 2017).

P300 heceleme sisteminin arayüzü, harflardan ve rakamlardan oluşan 6x6 boyutundaki matrissel bir formdadır. Bu sistemde, matriste bulunan satırlar ve sütunlar rastgele olarak parlatılır ve ardından söndürülür. Kişilerin aklından geçirdiği karakterin bulunduğu satır veya sütun parlatıldığı zaman, kişiler ilgili karaktere odaklanır ve içinden kısa bir süre sayar. Bu esnada diğer karakterleri görmezden gelir. Bu işlem birkaç defa tekrarlandıktan sonra elde edilen EEG sinyallerinin ortalaması alınır. İşlem sonucunda odaklanılan karaktere ait EEG sinyallerinde, diğer karakterlere ait EEG sinyallerinden farklı olarak yaklaşık 300 ms sonra ve pozitif yönlü bir P300 sinyali gözlemlenir. Kişiler, bu sistemi kullanarak herhangi bir isteklerini harflerle ekrana yazdırıp diğer insanlarla iletişim kurabilirler. Ayrıca arayüz matrisindeki rakamlar ve harflerin yerine belirli komutlar veya görseller eklenebilir. Böylece herhangi bir BBA sisteminin uygulaması yapılabilir (Olgun ve Türkoğlu, 2017).

Kararlı durum görsel uyarılmış potansiyelleri (SSVEP)

Kişilere gösterilen değişken frekansa sahip görsel uyaranlar sonucunda, beyin tarafından üretilen biyoelektriksel potansiyellerde birtakım genlik değişimleri oluşur. Bu genlik değişimleri, frekans spektrumunda görsel uyaranın frekansına karşılık gelmektedir. EEG sinyallerinin frekans spektrumlarında görsel uyaranlardan kaynaklanan bu potansiyellere SSVEP adı verilir ve Fourier Dönüşümü kullanılarak kolayca gözlemlenebilir. İlk olarak, EEG kaydı esnasında kişilere belirli bir frekans değerine sahip ışık gibi bir görsel uyaran gösterilir. Kişilerin ışığa odaklanması sonucunda, oksipital bölgeden elde edilen EEG sinyallerinin frekans spektrumlarında belirgin


genlik deęişimleri meydana gelir. Frekans spektrumundaki bu genlik deęerleri, ışık uyarının frekanslarına karşılık gelmektedir. Işık uyarının frekansının 15 hz' den başlayarak ve 15' in katları şeklinde arttırıldığı düşünülürse, frekans spektrumundaki en yüksek genlik deęeri 15 hz' de görünecektir (Amiri vd., 2013; Martišius ve Damaševičius, 2016). Şekil 3.16' da, bir kişiye 15 hz ve katlarındaki frekans deęerlerine sahip görsel bir uyarın uygulanması sonucunda elde edilen frekans spektrumu grafięi gösterilmiştir.



Şekil 3.16. Bir kişiye ait farklı frekans deęerlerine sahip görsel uyarının uygulanması sonucunda elde edilen frekans spektrumu (Zhu vd., 2010).

Şekil 3.16' daki frekans spektrumundan, görsel uyarının 15, 30 ve 45 hz frekans deęerlerine karşılık gelen belirgin güç deęerleri görülmektedir. Aynı zamanda, uyarının frekansı arttıkça buna karşılık güç deęerinde azalma meydana gelmektedir. SSVEP tabanlı BBA uygulamalarında, kullanıcıya her biri farklı frekanslara sahip 1' den fazla görsel uyarın gösterilir. Bu uyarınlar, farklı motor görevlerine karşılık gelmektedir. Kullanıcıya bu uyarınlardan birisine odaklanması talimatı verilir. Beynin oksipital bölgesinden alınan sinyallerde, uyarınların frekansına ve harmoniklerine ait güç sinyalleri elde edilir. Bu güç sinyallerinin sınıflandırılması yapılarak, istenilen motor görevi gerçekleştirilir (Olgun ve Türkoęlu, 2017). SSVEP tabanlı BBA uygulamalarındaki temel sorun, görsel uyarıcının kişilerde yorgunluk oluşturmasıdır. Bu uyarınların frekanslarının arttırılması duyulan rahatsızlığı azaltır. Fakat, bu durumda ilgili motor görevine ait SSVEP' i tespit etmek zorlaşır. Bilgi aktarım hızının yüksek olması ve önemli bir eğitim gereksinimi olmaması bu sistemlerin en önemli avantajlarıdır (Amiri vd., 2013).

Şekil 3.17’ de SSVEP tabanlı BBA sisteminin çalışma prensibi gösterilmiştir.




Şekil 3.17. SSVEP tabanlı BBA’ daki bazı görsel uyarılar ve PSD değerleri (Olgun ve Türkoğlu, 2017).

Sensorimotor ritimler (μ ve β ritimleri)


Yapılan çalışmalarda kişilerin el, ayak ve dil gibi herhangi bir uzvunun hareketini hayal etmesi veya bunu gerçekleştirmesi sonucunda elde edilen beyin sinyallerinin mu (8-13 Hz) ve beta (13-30 Hz) bandlarındaki ritimlerinde önemli değişimler meydana geldiği görülmüştür. Motor aktivitelerle ilişkili ve motor korteks üzerinden kaydedilen alfa aktivelerine mu ritimleri denmektedir ve alfa bandıyla aynı frekans aralığındadır. Hareket veya hareket hayali esnasında mu ve beta ritimlerinde azalma görülür. Örnek olarak, bir kişi elini hareket ettirdiğinde veya elinin herhangi bir yöne hareketini hayal ettiğinde elde edilen sinyallerin mu ve beta bandlarındaki ritimlerin genlikleri düşer. Hareket veya hareket hayali esnasında mu ve beta bandındaki ritimlerin genliklerinin düşmesine olay ilişkin desenkronizasyon (event related desynchronization, ERD) adı verilir. Gerçekleştirilen hareket veya hareket hayali bittiğinde mu ve beta bandlarındaki ritimlerin genliklerinde tekrardan bir artış olur. Hareket veya hareket hayali bittiğinde mu ve beta bandlarındaki ritimlerin genliklerinin tekrardan yükselmesi, olay ilişkin senkronizasyon (event related synchronization, ERS) olarak adlandırılır (Olgun ve Türkoğlu, 2017).

Şekil 3.18’ te alfa ve mu ritimlerinin oluşmasındaki durumlar gösterilmiştir.




Şekil 3.18. a) Gözler kapalı ve açık olduğu esnadaki alfa ritimleri b) Kolun dinlenimde ve hareket halinde olduğu mu ritimleri (Olgun ve Türkoğlu, 2017).

Alfa ritimleriyle, mu ritimleri aynı frekans bandı aralığındadır. Aralarındaki temel fark, alfa ritimleri (görsel) kortekste, mu ritimleri ise motor kortekste oluşur. Gözler kapalı ve sakin bir haldeyken oluşan alfa ritimlerinin, gözler açıldığında genlikleri azalır. Motor hareketleriyle doğrudan ilişkili mu ritimleri, herhangi bir hareket veya hareket niyeti olmadığında genlikleri yüksektir. Hareket veya niyeti esnasında ise genlikleri düşer. Şekil 3.19’ da motor hareketi hayali esnasında mu ve beta bandlarında oluşan ERD/ERS etkinlikleri gösterilmiştir.



Şekil 3.19. Hayal esnasında oluşan mu ve beta bandlarındaki ERD/ERS etkinlikleri (Jeon vd., 2011).


Şekil 3.19’ daki, MOn olarak işaretlenen kısımlar motor hayalinin başlama anı, MOff olarak işaretlenen yerler ise bitiş anıdır. Hem mu hem de beta bandlarındaki sinyallerin, hayal başladığı andan itibaren azalan karakteristikte olduğu (ERD), hayal bittiği anda ise yükselen karakteristikte olduğu (ERS) görülmektedir. Şekil 3.20’ de, fare imlecini bilgisayar ekranının altındaki ve üstündeki bir hedefe hareket ettirme hayali esnasında elde edilen mu ve beta ritimlerini içeren frekans spektrumu gösterilmiştir.



Şekil 3.20. Alt ve üst hedeflere ait μ ve β ritimlerini içeren frekans spektrumu (Wolpaw vd., 2002).

Kişiler, mu ve beta ritimlerinin genliklerini kontrol etmeyi öğrenerek herhangi bir beyin bilgisayar arayüzü sistemi geliştirilebilir. ERD/ERS bilgilerinin farklı uzuvlara ait motor hareket hayalleri için farklı uzamsal dağılımlara sahip oldukları bilinmektedir. Örnek olarak, bir kişi sağ elini hareket ettirmeyi hayal ettiğinde motor korteksin sol tarafında, sol elini hareket ettirmeyi hayal ettiğinde ise motor korteksin sağ tarafında yoğun bir şekilde ERD/ERS etkinliği meydana gelir (Duman, 2016).


Şekil 3.21’ de sol ve sağ motor hareketi hayalleri esnasında kortekste oluşan ERD etkinliği gösterilmiştir.



Şekil 3.21. Sol ve sağ motor hareketi hayali esnasında oluşan ERD etkinliği (Pfurtscheller vd., 2000).

Yavaş kortikal potansiyeller (SCP)

Yavaş kortikal potansiyeller (SCP), EEG sinyallerinde 0.5 ile 10 sn aralığında görülen pozitif veya negatif yönlü küçük çaptaki olay ilişkili potansiyel kaymalardır. SCP’ lerin oluşturdukları kaymaların genlikleri genellikle 10 ile 100 μV arasındadır. Kortikal faaliyetlerin azaldığı zamanlarda EEG sinyallerinde pozitif yönde sapmalar görülmektedir. Bilişsel faaliyetlere odaklanma anında ise negatif yönde sapmalar görülmektedir. Yavaş kortikal potansiyelleri kullanarak herhangi bir cihazın kontrolü, ekrana yazı yazdırma ve fare imlecinin kontrolü gibi değişik uygulamalar yapılmaktadır. Herhangi bir harici uyaran olmadan elde edilen bu potansiyelleri kullanarak, ALS gibi motor faaliyetlerini yerine getiremeyen hastaların temel bazı ihtiyaçları karşılanabilmektedir (Olgun ve Türkoğlu, 2017; Wolpaw vd., 2002). Şekil 3.22’ de alt ve üst hedef sınıflarına ait EEG sinyallerindeki pozitif ve negatif yönlü sapmalar gösterilmiştir.




Şekil 3.22. EEG sinyalindeki negatif ve pozitif yönlü SCP’ ler (Wolpaw vd., 2002).

4. MATERİYAL VE METOD


4.1. EEG Veri Kaydı

Bu çalışmada BCI Competition IV-2a veri seti kullanılmıştır (Brunner vd., 2008). Çalışılan veri seti, 9 farklı kişiden alınan sol el, sağ el, ayak ve dil olmak üzere 4 farklı sınıfa ait motor hayali görevlerinden oluşmaktadır. Denekler bilgisayar ekranının önüne oturtularak, her deneme $t = 0$ sn' de uyarım sesiyle birlikte başlamıştır ve siyah ekranda çarpı işareti belirmiştir. İki saniye sonra ($t = 2$ sn' de) sola, sağa, aşağıya ve yukarıya dönük, dört sınıftan birine karşılık gelen bir ok işareti belirmiştir. Daha sonra, deneklere ok işaretine karşılık gelen sınıfın hayali hareketini 3. saniye ile 6. saniye arasında yapmaları istenmiştir. Zamanlama şeması Şekil 4.1' de gösterilmiştir.



Şekil 4.1. EEG kaydının zamanlama şeması.

Elektrotlar, uluslararası 10-20 sistemine göre kafa derisi üzerine yerleştirilmiştir. Şekil 4.2' de uluslararası 10-20 sisteminin kafa derisi üzerindeki konumu gösterilmiştir.




Şekil 4.2. Uluslararası 10-20 sistemine karşılık gelen elektrot montajı.

Veriler, 22 kanallı EEG cihazı kullanılarak 250 Hz örnekleme frekansında örneklenmiştir. EEG sinyalleri mikrovolt seviyelerinde sinyaller olduğu için kayıt esnasında ortam gürültüleri bu sinyalleri etkilemektedir. Bu nedenle, kaydedilen raw EEG sinyallerine 0,5 Hz ile 100 Hz arasında bant geçiren filtre uygulanmıştır. Aynı zamanda şebeke gürültülerini bastırmak için 50 Hz' lik notch filtre uygulanmıştır.

4.2. EEG Sinyal İşleme Yöntemleri

4.2.1. Dalgacık dönüşümü (WT)

Bu yöntemin daha anlaşılır olabilmesi için Kısa-Süreli Fourier Dönüşümü (STFT)' nin bilinmesi gerekir. STFT, bir zaman-frekans analizi yöntemi olup, klasik fourier dönüşümünün pencerelemiş halidir. Fourier dönüşümlerinde, sinyallerin frekans spektrumları elde edilir. Fakat bu yöntemlerde, zaman bölgesinden frekans bölgesine geçildiğinde incelenen sinyalin zaman bilgisi kaybolur. Başka bir deyişle, frekans değerlerinin hangi zaman dilimlerine karşılık geldiği bilinemez. Doğadaki sinyallerin büyük bir çoğunluğu durağan olmayan sinyaller olduğundan bu sinyallerin analizlerinde tek başına frekans bilgisi yeterli olmayabilir. Dolayısıyla hem zaman hem de frekans bilgisinin eş zamanlı olarak incelenebilmesi için 1946 yılında Denis Gabor tarafından STFT yöntemi geliştirilmiştir. STFT yönteminde giriş sinyali, zaman ve frekansın 2 boyutlu fonksiyonu olarak elde edilir. İlk olarak, giriş sinyali eşit uzunluktaki dilimlere bölünür ve sinyallerin bu aralıklarda durağan olduğu kabul edilir. Her bir dilimin belirli bir pencere fonksiyonuyla çarpılmasından sonra çarpım ifadesinin Fourier dönüşümü alınır. Sonuç olarak, zaman ve frekansa bağımlı 2 boyutlu bir fonksiyon elde edilir. Bu fonksiyonu kullanarak zaman-frekans-güç grafikleri çizdirilebilir (Polikar, 1999). Şekil 4.3' te STFT' de kullanılan farklı genişliklerdeki pencere fonksiyonlarıyla elde edilen zaman-frekans çözünürlükleri gösterilmiştir.




Şekil 4.3. STFT' nin zaman-frekans çözünürlüğünün karşılaştırılması; a) dar pencere b) geniş pencere c) orta pencere.

Şekil 4.3 (a)'daki her bir kutucuk, dar yapıdaki pencere fonksiyonlarını temsil etmekte olup, bu fonksiyonların hepsi birbirine eşittir. Dar bir pencere fonksiyonu, zaman ekseninde daha kısa aralıklarla hareket edeceğinden bunun sonucunda ardışık zaman değerleri arasındaki mesafe birbirine yakın olur. Yani, spesifik zaman değerleri daha belirgin olur. Buna karşılık, frekans ekseninde ardışık frekans değerleri arasındaki mesafe fazla olur. Dolayısıyla, STFT' de dar bir pencere fonksiyonu kullanımı zaman çözünürlüğünü artırır, frekans çözünürlüğünü ise azaltır. Şekil 4.3 (b)'deki her bir kutucuk geniş yapıdaki pencere fonksiyonlarını temsil etmekte olup, bu fonksiyonlar birbirlerine eşittir. Geniş bir pencere fonksiyonu, zaman ekseninde daha uzun aralıklarla hareket edeceğinden ardışık zaman değerleri arasındaki mesafe birbirine uzak olur. Buna karşılık, frekans ekseninde spesifik frekans değerleri daha da belirginleşir. Dolayısıyla, STFT' de geniş bir pencere fonksiyonu kullanımı zaman çözünürlüğünü azaltır, frekans çözünürlüğünü ise artırır. Şekil 4.3 (c)'de hem zaman hem de frekans çözünürlüğünün eşit olduğu görülmektedir. Böyle bir pencere fonksiyonu ne çok geniş ne de çok dar bir yapıdadır. Fakat, bir fonksiyonda bazen zaman bazen de frekansın daha önemli olduğu anlar olabilir. Böyle bir durumda ilgili çözünürlüğün azaltılması veya artırılması gerekmektedir (Nisar vd., 2016).

STFT yönteminin dezavantajı olarak, bu yöntemde kullanılan pencere fonksiyonlarının genişliği sabittir ve değişmez. Seçilen pencere genişliği ise hem zaman hem de frekans çözünürlüğünü etkiler. Pencere fonksiyonunun genişliğinin artırılması, zaman bölgesinde geniş bir alan kaplayacağından düşük bir zaman çözünürlüğü sağlar ve spesifik bir zaman dilimi belirgin olmaz. Buna karşılık artan pencere genişliği yüksek frekans çözünürlüğü sağlar. Pencere fonksiyonunun genişliğinin azaltılması ise zamanda daha dar bir alan kaplayacağından spesifik zaman dilimleri belirgin olur. Dolayısıyla zaman çözünürlüğü artar, buna karşılık frekans çözünürlüğü azalır. Sonuç olarak, STFT' de kullanılan pencere fonksiyonlarının genişliği sabit olduğu için sabit bir zaman-frekans çözünürlüğünden söz edilir. Bu olumsuz durum, Dalgacık Dönüşümünün en önemli çıkış nedenlerinden birisidir. Diğer bir sebep ise Fourier Dönüşümlerinde kullanılan sinüs ve kosinüs fonksiyonlarının parabolik yapıları nedeniyle, orijinal giriş sinyalindeki sivri noktaları tam olarak düzgün temsil edememeleridir. Dalgacık dönüşümünde, orijinal giriş sinyalinin yapıtaşları olarak belirli tipteki dalgacıklar kullanılır. Bu dalgacıklar, sahip oldukları ölçek faktörü sayesinde genişleyip, daralabilirler. Geniş yapıdaki (büyük ölçekli) dalgacık fonksiyonlarının frekansı düşüktür. Dar yapıdaki (küçük ölçekli) dalgacık fonksiyonlarının frekansları ise yüksektir. Dolayısıyla, zaman bilgisinin önemli olduğu yerlerde dar yapıdaki dalgacık fonksiyonları, frekans bilgisinin önemli olduğu yerlerde ise geniş yapıdaki dalgacık fonksiyonları kullanılır.


Sonuç olarak, Dalgacık dönüşümünde STFT' ye kıyasla değişken bir zaman-frekans çözünürlüğünden söz edilir (Polikar, 1999; Ocak, 2009). Şekil 4.4' te, zaman-frekans çözünürlüğünün anlaşılması için temsili bir örnek gösterilmiştir.



Şekil 4.4. Giriş sinyali FFT ve STFT uygulanması (Wang vd. 2013).

Şekil 4.4 (a)' da üst kısımdaki giriş sinyali, 3 farklı fonksiyonun birleşiminden meydana gelmektedir. 25 Hz' lik sabit bir sinüs dalgasından, $t=0$ anında 125 Hz ile başlayıp $t=1$ sn' de 10 Hz ile biten quadratic chirp sinyalinden ve $t=0.2$ sn' den itibaren başlayan bir darbe sinyalinden meydana gelmektedir. Bu sinyalin FFT' si alındığında, hemen altındaki PSD grafiği elde edilmektedir. PSD grafiğinde, yaklaşık olarak 25 Hz' lere karşılık gelen sinüs fonksiyonuna ait güç değeri görülmektedir. Ayrıca, giriş sinyalindeki maksimum frekans değeri 125 Hz olduğundan, PSD grafiğinde 125 Hz' den sonraki frekanslarda güç değeri görülmemektedir. FFT yöntemi, frekans tabanlı bir yöntem olduğundan zaman bölgesindeki bir sinyal frekans bölgesinde analiz edilir ve bu sinyale ait zaman bilgisi kaybolur. Dolayısıyla, FFT grafiğinde 25 Hz' lik bir sinüs dalgasının etkisi görülür ama bu dalga kaçınıcı saniyede başladığı bilinemez. Şekil 4.4 (b)' de giriş sinyali, dar pencereli STFT uygulandığında elde edilen 2 boyutlu spektrogram

(zaman-frekans-enerji) grafiği gösterilmiştir. Spektogramlardaki beyaz renkli çizgiler enerji veya güç değerlerini temsil etmektedir. Dar bir pencere kullanmak, zaman çözünürlüğünü arttıracığı için, buradan $t=0.2$ sn' de (200ms) başlayan darbe sinyalinin etkisi görülebilir. Buna karşılık frekans çözünürlüğü azalacağı için 25 Hz' lik sinüs dalgasıyla $t=0$ ' da 125 Hz ile başlayıp $t=1$ ' de 10 Hz ile biten quadratic chirp fonksiyonlarına karşılık gelen frekans değerleri hafif belli olmakla birlikte net değildir. Şekil 4.4 (c)' de, giriş sinyaline geniş pencere STFT uygulandığında elde edilen spektrogram gösterilmiştir. Geniş bir pencere kullanmak, frekans çözünürlüğünü arttıracığı için sabit 25 Hz' lik sinüs dalgasının etkisiyle birlikte, 125 Hz ile başlayıp 10 Hz ile biten quadratic chirp sinyalinin etkileri (diğer bir deyişle frekans eksenindeki frekans değerleri) rahatlıkla görülebilir. Fakat buna karşılık, zaman çözünürlüğü azalacağı için darbe sinyalinin başlama anı olan 0.2 sn değeri belirgin olmaz. Şekil 4.4 (d)' de giriş sinyaline orta genişlikteki bir pencere kullanarak STFT uygulandığında elde edilen spektrogram gösterilmiştir. Burada hem zaman hem de frekans için optimum bir çözünürlükten söz edilebilir. Hem darbe sinyalinin başlama anı olan $t=0.2$ sn değeri, hem sinüs dalgasının sabit 25 Hz' lik frekansı, hem de quadratic chirp sinyaline ait olan frekans değerleri görülebilir. Dalgacık Dönüşümünde ise durum biraz daha farklıdır. Şekil 4.5' te, Dalgacık dönüşümünde kullanılan zaman-ölçek grafiği gösterilmiştir.




Şekil 4.5. Dalgacık dönüşümünün ölçek-zaman grafiği.

Dalgacık dönüşümünde, herhangi bir giriş sinyali zaman-ölçek alanında analiz edilir. Bu dönüşümde, STFT' de kullanılan pencere fonksiyonlarının işlevini dalgacık fonksiyonları gerçekleştirir. Dalgacıklar, “ana dalgacık” olarak isimlendirilen farklı tipteki sinyallerden ölçek ve öteleme parametreleriyle türetilirler. Yavaş değişimlerin olduğu alçak frekans noktalarında geniş pencere, hızlı değişimlerin olduğu yüksek frekans noktalarında ise dar yapıdaki dalgacık fonksiyonları kullanılır (Öner vd., 2017). Şekil 4.5, Dalgacık dönüşümünde kullanılan hem büyük hem de küçük ölçekli dalgacıkların zaman içerisindeki konumu göstermektedir. Büyük ölçekli


(genişlemiş) dalgacıklar geniş kutucuklarla, küçük ölçekli (dar) dalgacıklar uzun ince kutularla temsil edilir. Genişlemiş dalgacıkların frekansı düşük, dar dalgacıkların ise frekansı yüksektir. Dikkat edilirse, zaman eksenindeki ardışık zaman dilimleri arasındaki mesafe kısadır. Yani, spesifik zaman dilimleri daha belirgindir. O halde, zaman analizi ana dalgacıktan türetilen küçük ölçekli (dar) dalgacıklarla yapılır. Bunun tam tersi olarak, frekans analizi ana dalgacıktan türetilen büyük ölçekli (geniş) dalgacıklarla yapılır.

Dalgacık dönüşümünde giriş sinyali, “ana dalgacık” olarak isimlendirilen sinyallerin farklı ölçek ve farklı öteleme değerleriyle oluşturulan dalgacık versiyonlarına ayrıştırılır. Fourier Dönüşümünde giriş sinyali; farklı frekans, genlik ve faz açılarına sahip sinüsoidal yapıdaki alt sinyallere ayrıştırılır (Sifuzzaman vd., 2009). Şekil 4.6’ da, orijinal bir giriş sinyaline Fourier dönüşümü ve Dalgacık dönüşümü uygulanarak farklı tipteki sinyallere ayrıştırılması gösterilmiştir.




Şekil 4.6. Fourier ve Dalgacık Dönüşümleriyle elde edilen yapıtaş fonksiyonları.

Şekil 4.7' de farklı ölçek değerlerine sahip fonksiyonlar gösterilmiştir.



Şekil 4.7. Farklı ölçek değerlerine sahip fonksiyonlar.

$Y = f(m \cdot x)$ şeklinde verilen bir fonksiyonun ölçek değeri, $1/m$ şeklinde elde edilir. Buradaki m değerleri büyüdükçe ölçek değeri küçülür. Bu da, fonksiyonun dar bir yapıda olması anlamına gelir. Şekil 4.7' den ölçek değerleri küçüldükçe, fonksiyonun daraldığı görülmektedir. İlk fonksiyonun ana dalgacık olduğunu düşünürsek, diğer fonksiyonlar bu ana dalgacıktan öteleme parametresiyle türetilen dalgacıklardır. Şekil 4.8' de farklı öteleme değerlerine sahip dalgacıklar gösterilmiştir.



Şekil 4.8. Farklı öteleme değerlerine sahip fonksiyonlar.


Öteleme değeri, fonksiyonun zaman bölgesindeki konumuyla ilgilidir. Ortadaki fonksiyonu baz alırsak, pozitif bir öteleme değeri bu fonksiyonu zaman bölgesinde sola, negatif bir öteleme değeri ise bu fonksiyonu sağa kaydırır.

Dalgacık dönüşümünde kullanılan toplamda 75 adet “ana dalgacık” fonksiyonu bulunmaktadır. Bu fonksiyonların isimleri Çizelge 4.1’ de gösterilmiştir.

Çizelge 4.1. Ana dalgacık fonksiyonlarının isimleri.

Ait olunan dalgacık sınıfı	Ana dalgacığın ismi
Daubachies	db1, db2, db3, db4,db5, ... db20
Symlets	symlets 1, symlets 2, symlets 3, symlets4,symlest5, ... symlets20
Coiflets	coiflets 1, coiflets2, coiflets3, coiflets4, coifles5
Biorthogonal	bio 1.1, bio 1.3, bio 1.5, bio 2.2, bio 2.4, bio 2.6, bio 2.8, bio 3,1, bio 3.3, bio 3.5, bio 3.7, bio 3.9, bio 4.4, bio 5.5, bio 6.8
Reverse Biorthogonal	rbio 1.1, rbio 1.3, rbio 1.5, rbio 2.2, rbio 2.4, rbio 2.6, rbio 2.8, rbio 3,1, rbio 3.3, rbio 3.5, rbio 3.7, rbio 3.9, rbio 4.4, rbio 5.5, rbio 6.8

Dalgacık dönüşümünde orijinal giriş sinyalinin yapıtaşları, “ana dalgacık” olarak isimlendirilen farklı isimlerdeki fonksiyonlardan türetilir. Kullanılan ana dalgacık fonksiyonlarının bazıları Şekil 4.9’ da gösterilmiştir.



Şekil 4.9. Dalgacık dönüşümünde kullanılan bazı ana dalgacık fonksiyonları.

Dalgacık dönüşümü; Sürekli dalgacık dönüşümü ve Ayrık dalgacık dönüşümü olmak üzere 2' ye ayrılır:

Sürekli dalgacık dönüşümü (CWT)

Dalgacık dönüşümündeki temel mantık, Fourier dönüşümündekine benzerdir. Fourier dönüşümünde, herhangi bir giriş sinyali farklı tipteki trigonometrik dalgaların toplamı şeklinde ifade edilir. Sürekli dalgacık dönüşümünde, herhangi bir giriş sinyali belirli bir ölçek ve belirli bir öteleme değerleri olan “dalgacık” adı verilen farklı tipteki fonksiyonların zaman boyunca toplamı şeklinde ifade edilir. Dalgacıklar, hem zaman hem de frekans alanlarında lokalize olan fonksiyonlardır. Dalgacık dönüşümünde, “ana dalgacık” olarak isimlendirilen ve $\Psi(t)$ ile gösterilen farklı tipteki fonksiyonlar mevcuttur. Bu fonksiyonlar, gerçek veya sanal değerlere sahip olabilirler. Ana dalgacıkların en önemli özellikleri ise ortalama değerlerinin 0 olmaları ve sonlu bir enerjiye sahip olmalarıdır. Diğer bir deyişle, sönümlü bir yapıdadırlar. Sürekli dalgacık dönüşümünde herhangi bir giriş sinyali, ana dalgacık olarak isimlendirilen bu fonksiyonların ölçeklenmiş ve kaydırılmış versiyonlarına ayrıştırılır. Belirli bir ölçek ve öteleme değeri olan ayrıştırılmış dalgacık fonksiyonunun ifadesi eşitlik (4.1)' de gösterilmiştir (Ocak, 2009; Öner vd., 2017).

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) \quad (4.1)$$

Eşitlik (4.1)' deki a katsayısı ölçek değeri, b ise öteleme değeridir. Ölçek değeri, dalgacığın genişleyip daralmasıyla ilgilidir. Ölçek değeri büyüdükçe dalgacık daralır, küçüldükçe genişler. Öteleme değeri ise dalgacığın zaman bölgesindeki konumunu gösterir. $(t - b)$ ifadesindeki b değerinin, 0' dan küçük olduğu durumlarda sola doğru, 0' dan büyük olduğu durumlarda sağa doğru bir kayma gerçekleşir. $1/\sqrt{|a|}$ ifadesi, değişen ölçek değerleri için hesaplanan normalizasyon faktörüdür. Sürekli dalgacık dönüşümü, dönüşümü yapılacak sürekli giriş sinyaliyle, dalgacık fonksiyonunun çarpılarak zaman bölgesi boyunca toplanmasıyla ifade edilir ve eşitlik (4.2)' deki gibi gösterilir (Öner vd., 2017).

$$CWT(a, b) = \int_{-\infty}^{\infty} x(t) \Psi_{a,b}^*(t) dt \quad (4.2)$$

Eşitlik (4.1)' deki ifade, eşitlik (4.2)' de yerine konulduğunda eşitlik (4.3)' teki nihai CWT formülü elde edilir. Eşitlik (4.3)' teki formül yardımıyla, değişen a ve b değerlerine bağlı olarak ilgili “dalgacık katsayıları” hesaplanır (Öner vd., 2017; Chetkovic vd., 2008).

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \Psi_{a,b}^* \left(\frac{t-b}{a} \right) dt \quad (4.3)$$

Ayrık dalgacık dönüşümü (DWT)

Sürekli dalgacık dönüşümünde, ölçek ve öteleme parametreleri olan a ve b değerleri devamlı olarak değişir. Dalgacık katsayılarının her olası ölçek değeri için hesaplanması uzun ve zahmetli bir iştir. Bunun yerine, Sürekli dalgacık dönüşümünde kullanılan ölçek ve öteleme değerleri, 2^r nin kuvveti olacak şekilde seçilir. Bu şekilde gerçekleştirilen dönüşüme Ayrık dalgacık dönüşümü denir. DWT ile dalgacık katsayılarının hesaplanması, özellikle veri sayısının çok olduğu durumlarda oldukça verimli ve hızlıdır. Ölçek ve öteleme değerleri sırasıyla $a = 2^r$ ve $b = k2^r$ olmak üzere, bu ifadeler eşitlik (4.1)' de yerlerine yazıldığında eşitlik (4.4)' teki ifade elde edilir (Ocak, 2007; Chen vd., 2017).

$$\Psi_{r,k}(t) = 2^{-r/2} \Psi(2^{-r}t - k) \quad (4.4)$$

Eşitlik (4.4)' teki ifade tekrar düzenlenip yazıldığında eşitlik (4.5)' teki ifade elde edilir (Chen vd., 2017).


$$\Psi_{r,k}(t) = \frac{1}{\sqrt{|2^r|}} \Psi \left(\frac{t-k2^r}{2^r} \right) \quad (4.5)$$

Eşitlik (4.5)' teki ifade, eşitlik (4.3)' te yerine yazıldığında, elde edilen Ayrık dalgacık dönüşümü ifadesi eşitlik (4.6)' daki gibi gösterilir (Ocak, 2007; Chen vd., 2017).

$$DWT_{r,k} = \frac{1}{\sqrt{|2^r|}} \int_{-\infty}^{\infty} x(t) \Psi \left(\frac{t-k2^r}{2^r} \right) dt \quad (4.6)$$

Eşitlik (4.6)' daki $DWT_{r,k}$ ifadesi, r . seviyedeki ve k . konumdaki dalgacık katsayılarını temsil etmektedir. 1989 yılında, Mallat tarafından ayrık dalgacık katsayılarının hesaplanmasında alçak ve yüksek geçiren filtreleri kullanarak etkili bir yöntem geliştirilmiştir. İlk olarak, ayrık yapıdaki giriş sinyali eş zamanlı olarak alçak ve yüksek geçiren filtrelerden geçirilir. Buradaki önemli nokta, ayrıştırma işlemine örnekleme frekansının yarısı olan Nyquist değerinden başlanır. Birinci seviye ayrıştırmadan sonra alçak geçiren filtrenin çıktısı olan cA1 (yaklaşım) katsayıları, yüksek geçiren filtrenin çıktısı olan cD1 (detay) katsayıları elde edilir. İkinci seviye ayrıştırmada aynı işlemler cA1 katsayıları üzerinden devam eder. Her aşamada frekans bandı aralığı filtreleme yoluyla 2^r ye bölünür. Frekans bandının 2^r ye bölünmesi, daha spesifik frekansları belirgin kılacağından frekans çözünürlüğünün 2 katına çıkması anlamına gelir. Zaman çözünürlüğü ise alt örnekleme yoluyla yarıya indirilir. İkinci seviye ayrıştırmadan cA2 ve cD2 katsayıları elde edilir.


Benzer mantıkla, aynı işlemler $cA3$ üzerinden sonuncu seviyeye kadar devam eder (Ocak, 2007). Hesaplanan katsayılar, yeniden yapılandırıldığında ilgili seviyelerdeki $A1, D1, A2, D2, A3, D3 \dots$ sinyalleri elde edilir. Yeniden yapılandırılmış bu sinyaller, orijinal giriş sinyaliyle aynı uzunluğa sahip ve farklı frekans bandlarına sahiptir. Şekil 4.10' da, cA (yaklaşık) ve cD (detay) dalgacık katsayıları elde edilirken öncesinde yapılan filtreleme ve alt örnekleme işlemleri gösterilmiştir.



Şekil 4.10. cA ve cD katsayıları elde edilirken yapılan filtreleme ve alt örnekleme işlemi.

Eş zamanlı olarak, yüksek geçiren ve alçak geçiren filtrelerden geçirilen giriş sinyaline DWT uygulanır ve ilgili dalgacık katsayıları hesaplanır. Ardından, her iki durum için hesaplanan dalgacık katsayılarının sayısı, alt örnekleme yoluyla yarıya indirilir. Sonuç olarak, cA ve cD dalgacık katsayı vektörleri elde edilir. Elde edilen bu katsayı vektörlerinin eleman sayısı, ayrık giriş sinyalinin eleman sayısının yarısı kadardır. Yaklaşım katsayıları, giriş sinyalinin alçak frekanslı bileşenlerini, detay katsayıları ise giriş sinyalinin yüksek frekanslı bileşenlerini temsil eder.

Şekil 4.11’ de, belirli bir örnekleme frekansına sahip ayrık yapıdaki bir EEG sinyaline 5. Seviye DWT uygulaması gösterilmiştir.



Şekil 4.11. 5. Seviye DWT uygulaması (Raghu vd. 2019).

Herhangi bir giriş sinyalinin en geniş band aralığı Nyquist frekansına kadardır. EEG sinyalinin 256 Hz örnekleme frekansına sahip olduğunu düşünürsek bu durumda Nyquist frekansı, örnekleme frekansının yarısı kadar olup, 128 Hz’ dir. Bu değer, EEG sinyalinin band aralığındaki üst sınır değeridir. O halde, giriş sinyaline DWT uygulanırken 128 Hz değerinden bölünmeye başlanır ve 2’ nin katları şeklinde bölünme gerçekleştirilir. 5. Seviyeye gelindiğinde bölünme işlemi biter. Sonuç olarak elde edilen cA1, cD1, cA2, cD2, cA3, cD3, cA4, cD4, cA5, cD5 katsayı vektörleri, orijinal sinyalin ilgili band aralıklarındaki frekans içeriklerini temsil eder. Yaklaşım katsayıları, alçak frekans içeriklerini temsil ettiğinden büyük ölçekli, detay katsayıları ise yüksek frekans içeriklerini temsil ettiğinden küçük ölçekli dalgacıklardan oluşur (Raghu vd. 2019).

Elde edilen katsayı vektörlerinin, ilgili seviyelerindeki yeniden yapılandırılmış halleri ve bu sinyallerin EEG’ deki karşılıkları ise Çizelge 4.2.’ de gösterilmiştir.

Çizelge 4.2. 5. Seviye DWT Ayırıştırması ve EEG’ deki karşılıkları.

Ayırıştırma Seviyesi	Band Aralığı	Ayırıştırılmış Sinyal	EEG’ deki karşılığı
1	64-128	D1	Gürültü
2	32-64	D2	Gama Bandı
3	16-32	D3	Beta Bandı
4	8-16	D4	Alfa Bandı
5	4-8	D5	Teta Bandı
5	0-4	A5	Delta Bandı

4.2.2. Hilbert-Huang dönüşümü (HHT)

1996 yılında, Huang ve arkadaşları tarafından bulunan Ampirik Mod Ayırıştırması (EMD) yönteminin, Hilbert spektral analiziyle birleştirilmesiyle oluşan dönüşüme Hilbert-Huang dönüşümü adı verilmiştir. EEG gibi hem durağan olmayan hem de doğrusal olmayan sinyallerin analizlerinde Hilbert-Huang dönüşümünün başarılı sonuçlar verdiği bilinmektedir. Hilbert-Huang Dönüşümünde, verilere öncesinde Ampirik Mod Ayırıştırması (EMD) ardından Hilbert spektral analizi uygulanır. İlk olarak, orijinal ve gerçel değerli bir giriş sinyali, EMD uygulanarak içsel mod fonksiyonları adı verilen İMF’ lerine ayrılır. İMF’ ler, giriş sinyali ile aynı veri uzunluğunda fakat her birisi farklı frekans seviyelerindedir. Ayrılan İMF sinyallerine Hilbert dönüşümü uygulanarak, her bir İMF için 3 boyutlu zaman-frekans-enerji temsilleri elde edilir (Peng vd., 2020; Huang, 2014)

Ampirik mod ayırıştırması (EMD)

Bu yöntem, HHT’ nin ilk adımını oluşturmaktadır. Ampirik mod ayırıştırması, doğrusal olmayan ve durağan olmayan zaman serilerinin daha doğru bir şekilde analiz edilebilmesi için gereklidir. EMD yöntemi, herhangi bir gerçek değerli giriş sinyalinin, farklı salınımlar yapan basit alt sinyallerin toplamından oluştuğu prensibine dayanmaktadır. Bu alt sinyallerin her birisi içsel mod fonksiyonları (İMF) olarak isimlendirilir. Sonlu ve gerçek değerli herhangi bir sinyaline ait birçok İMF bileşeni bulunabilir (Huang, 2014).

Bir sinyalden İMF çıkarma işlemi “eleme” olarak adlandırılır. İlk olarak, giriş sinyalindeki tüm yerel ekstremum noktaları (minimumlar ve maksimumlar) belirlenir. Daha sonra tüm yerel maksimum noktaları üst zarf, tüm yerel minimum noktaları ise alt zarf olacak şekilde

birleştirilir. Üst ve alt zarfların ortalaması m_1 olarak adlandırılır. Giriş sinyali $x(t)$ ve m_1 sinyalinin farkı h_1 olarak adlandırılır ve (4.7) no' lu bağıntıyla gösterilir (Pigorini vd., 2011).

$$h_1 = x(t) - m_1 \quad (4.7)$$


Eleme işlemi, üst ve alt zarflar simetrik yapıda oluncaya kadar devam eder. Bir sonraki aşamada h_1 sinyali proto-İMF olarak kabul edilir ve yeni giriş verisi olarak ele alınır. Diğer İMF, bu sinyalden elde edilir. Üst ve alt zarfların ortalaması m_{11} olarak adlandırılır. Yeni giriş verisi h_1 ve m_{11} arasındaki fark h_{11} olarak adlandırılır ve (4.8) no' lu bağıntıyla gösterilir (Pigorini vd., 2011).

$$h_{11} = h_1 - m_{11} \quad (4.8)$$

k kez tekrarlanan eleme işleminden sonra, yerel zarfların simetri koşulu karşılanır. İlk İMF bileşeni c_{1k} olarak adlandırılır ve (4.9) no' lu bağıntıyla gösterilir (Pigorini vd., 2011).

$$c_{1k} = h_{1(k-1)} - m_{1k} \quad (4.9)$$


Şekil 4.12' de herhangi gerçek değerli bir giriş sinyalini, İMF' lerine ayrıştırma aşamasının ilk etabı gösterilmiştir.



Şekil 4.12. Bir sinyalden İMF elde etmenin ilk aşaması (Huang, 2014).


Şekil 4.12' deki mavi renkli sinyal orijinal giriş sinyalidir. Bu sinyalin üst tepe noktalarının birleştirilmesiyle elde edilen yeşil sinyal üst zarf, alt tepe noktalarının birleştirilmesiyle elde edilen diğer yeşil sinyal ise alt zarf olarak adlandırılır. Kırmızı renkli sinyal,

üst ve alt zarfların ortalamasından elde edilen sinyaldir (Huang, 2014). Şekil 4.13' te orijinal giriş sinyalinden, alt ve üst zarfların ortalaması olan $m1$ sinyalinin farkı alınarak elde edilen koyu renkli $h1$ sinyali gösterilmiştir.



Şekil 4.13. $h1$ sinyalinin elde edilmesi (Huang, 2014).


Böylece eleme işleminin ilk etabı tamamlanmış olur. Normalde $h1$ sinyalinin, ilk İMF bileşenine karşılık gelmesi gerekir. Fakat yerel zarflar simetrik yapıda olmadığından eleme işlemine devam edilir. İlk İMF bileşeninin elde edilebilmesi için üst ve alt zarfların simetri şartı sağlanmalıdır ve dolayısıyla eleme işlemine devam edilir (Huang, 2014).



Şekil 4.14. Eleme işlemindeki ikinci aşama (Huang, 2014).

Şekil 4.14' te eleme işleminin ikinci aşaması gösterilmiştir. İkinci aşamada, yeni giriş verisi olarak bir önceki aşamadan elde edilen $h1$ sinyali ele alınır. Bu sinyale kısaca proto-İMF denilir. $h1$ sinyalinin üst tepe noktalarından geçen sinyal üst zarf, alt tepe noktalarından geçen


sinyal alt zarf olarak adlandırılır. Şekil 4.14’ te, üst ve alt zarfların ortalaması m2 sinyaliyle ifade edilmiştir. Giriş sinyali h1 ile m2 sinyalinin farkı alınarak h2 sinyali elde edilir. Yerel zarfların simetri koşulu tam olarak sağlanamadığından eleme işleminde 3. aşamaya geçilir. Bu işlem, Hilbert dönüşümünün anlamlı (negatif olmayan) anlık frekans değerleri vermesi için gereklidir (Huang, 2014).



Şekil 4.15. Eleme işlemindeki üçüncü aşama (Huang, 2014).

Şekil 4.15’ te eleme işleminin üçüncü aşaması gösterilmiştir. Buradaki h2 sinyali yeni giriş sinyali konumundadır. Bu sinyalin üst ve alt tepe noktaları ayrı ayrı birleştirilerek sırasıyla üst ve alt zarf sinyalleri elde edilir. Zarf sinyallerinin ortalaması m3 ile gösterilmiştir. Giriş sinyali h2 ile m3 sinyalinin farkı alınarak, yeni giriş sinyali elde edilir. Şekil 4.15’ te gösterildiği gibi, üst ve alt zarflar birbirleriyle hağlen simetrik yapıda olmadıklarından eleme işlemine devam edilir. 12 kez tekrarlanan eleme işleminden sonra yerel zarfların simetri koşulu sağlanır (Huang, 2014).

Bu aşamada, o ondaki giriş sinyalinden üst ve alt zarfların ortalaması alınarak elde edilen sinyalin farkı alınır ve ilk İMF bileşeni elde edilir. Şekil 4.16’ da ilk İMF bileşeni gösterilmiştir.



Şekil 4.16. İlk İMF bileşeni (Huang, 2014).

Benzer mantıkla, orijinal ilk giriş sinyalinin eğer varsa diğer İMF’ leri, bu İMF’ den elde edilir. Yani bir sonraki İMF sinyali, bir önceki İMF’ den elde edilir. Eleme aşamalarında yapılan işlemler aynen buradada geçerlidir. İMF bulma işlemi, dc seviyesi (residual sinyal) elde edilene kadar devam eder. Orijinal giriş sinyaline ait tüm İMF’ ler elde edildikten sonra her bir İMF’ ye Hilbert dönüşümü uygulanır. Böylece her bir İMF’ nin anlık frekans, anlık enerji gibi değerleri elde edilir (Peng vd., 2005). EMD yöntemiyle EEG gibi karmaşık yapıdaki sinyaller, daha sade ve düzgün yapılarıdaki farklı İMF’ lere ayrıştırılır. Ardından, belirlenen İMF’ ler üzerinden ilgili öznitelikler çıkartılır.

Hilbert dönüşümü (HT)

Herhangi gerçekteğerli bir sinyalin, anlık frekans ve zarf gibi özellikleri analitik sinyal aracılığıyla elde edilebilir. Hilbert dönüşümü, temel olarak gerçekteğerli bir $x(t)$ sinyalini analitik sinyal olarak ifade etmeye yarar. Herhangi bir gerçekteğerli $x(t)$ sinyalinin Hilbert dönüşümü (4.10) nolu bağıntıyla ifade edilir (Feldman, 2011; Loboda vd., 2014)

$$H\{x(t)\} = \tilde{x}(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{(t-\tau)} d\tau \quad (4.10)$$

Daha sonra analitik sinyal aşağıdaki (4.11) nolu bağıntıyla ifade edilir (Feldman, 2011).

$$z(t) = x(t) + j\tilde{x}(t) = a(t)e^{j\theta(t)} \quad (4.11)$$


Buradaki analitik sinyalin gerçek kısmı orijinal sinyal olup, sanal kısmı ise orijinal sinyalin Hilbert dönüşümünden elde edilen değerdir. Analitik sinyal; anlık genlik ve anlık faz olmak üzere 2 bileşene ayrılır. Buradaki $a(t)$ ifadesi, analitik sinyalin anlık genliği olup, orijinal giriş sinyalinin ise zarfını oluşturur. $\theta(t)$ ise analitik sinyalin anlık fazıdır. Analitik sinyalin anlık fazı aşağıdaki (4.12) nolu bağıntıyla elde edilir (Feldman, 2011; Oweis vd., 2011).

$$\theta(t) = \tan^{-1} \left(\frac{\tilde{x}(t)}{x(t)} \right) \quad (4.12)$$

Giriş sinyalinin anlık frekansı olan $f(t)$, anlık fazın zamana göre türevi olup, aşağıdaki (4.13) nolu bağıntıyla ifade edilir (Feldman, 2011; Oweis vd., 2011).

$$f(t) = \frac{1}{2\pi} \frac{d\theta(t)}{dt} \quad (4.13)$$

EMD ile elde edilen farklı frekans seviyelerindeki İMF bileşenlerine Hilbert dönüşümü uygulanarak, her bir İMF bileşeninin analitik sinyalleri elde edilir. Analitik sinyaller, içerisinde negatif frekans değeri barındırmayan sinyallerdir. (Feldman, 2011; Oweis vd., 2011). Şekil 4.17' de analitik sinyal ve bu sinyale ait fazör diyagramı gösterilmiştir.



Şekil 4.17. Analitik sinyal (Feldman, 2011) (a) Sinyalin 3D görüntüsü (b) Sinyalin fazör diyagramı

Şekil 4.17 (a)' da, mavi renkli ve zaman bölgesinde tanımlı gerçel değerli bir sinyal verilmiştir. Yeşil renkli sinyal ise gerçel değerli sinyalin hilbert dönüşümünden elde edilen

sinyaldır ve sanal değerlidir. Dikkat edilecek olursa Hilbert dönüşümü bölge değişikliğine sebep olmamıştır. Siyah renkli sinyal, mavi ve yeşil renkli sinyallerin birleşiminden elde edilen analitik sinyaldir. Bu sinyal, hem gerçel hem de sanal kısımdan oluşmaktadır. Pembe renkli sinyal ise, analitik sinyalin gerçel ve sanal eksenlerdeki görüntüsüdür. Şekil 4.17 (b)' de analitik sinyalin fazör diyagramı verilmiştir. Bu diyagrama göre, her bir işaretli noktadaki anlık faz değerleri, orijinal sinyalin hilbert dönüşümünden elde edilen sanal kısımların, gerçel sinyalin o andaki değerlerine bölünüp ters tanjantının alınmasıyla elde edilir.

4.2.3. Welch yöntemi

Bu yöntemin daha anlaşılabilir olabilmesi için Ayırık Fourier Dönüşümü (DFT) 'nin bilinmesi gerekir. DFT, adından da anlaşılacağı üzere ayırık (kesikli) değerleri olan sinyallerin frekans bölgesi analizlerinde kullanılır. DFT yöntemi; sonlu uzunluğa sahip, periyodik ve gerçel değerli ayırık bir giriş sinyalinin basit trigonometrik dalgaların toplamı şeklinde ifade edilmesi prensibine dayanır. Bu trigonometrik dalgalar, sinüs ve cosinüs fonksiyonları olup, tabiri caizse orijinal sinyalin birer yapı taşlarıdır. Giriş sinyaliyle, bu trigonometrik yapı taşlarının toplam şeklinde oluşturduğu dalga formu birbirlerine oldukça benzer sinyallerdir.

Giriş sinyaline DFT uygulandıktan sonra farklı frekans, farklı genlik ve farklı faz açılarına sahip kalabalık bir toplam halinde sinüs ve cosinüs fonksiyonları elde edilir. Buradaki sinüs ve kosinüs fonksiyonlarının ne kadar olduğu, orijinal giriş sinyalindeki ayırık veri sayısına bağlıdır. Bu fonksiyonların frekans değerlerinin küçükten büyüğe doğru sıralanmış hali, frekans bölgesindeki nyquist frekansına kadar olan frekans değerlerini oluşturmaktadır. Bu sinyallerin sahip olduğu katsayılarının (genliklerinin) karesi ise orijinal giriş sinyalinin güç değerlerini temsil etmektedir. Trigonometrik fonksiyonların, sahip oldukları frekansa karşılık gelen güç değerlerinin birleştirilmesiyle elde edilen grafiğe güç-frekans eğrisi denir. Böylece zaman bölgesindeki bir sinyalin spektral analizi yapılmış olur. Diğer bir deyişle, frekans bölgesindeki temsili elde edilir.

DFT yönteminde, giriş sinyalinin veri sayısı arttıkça çok kalabalık bir işlem yoğunluğu olduğundan hesaplanması çok zaman alır. Buna çözüm olarak, DFT' nin daha verimli ve hızlı hesaplanabilmesi için FFT algoritmaları geliştirilmiştir. Aslında, FFT yeni bir dönüşüm değildir. Sadece DFT' nin hızlandırılmış halidir.

Bir sinyalin, güç spektral yoğunluğunun tahmin edilmesi yöntemine periodogram denir. Periodogram, FFT tabanlı bir yöntemdir. Welch yöntemi ise, yumuşatılmış periodogramların ortalaması prensibine dayanır. Doğal olarak, Welch yöntemide FFT tabanlı bir yöntemdir. Welch

yönteminde, sonlu uzunluktaki ve gerçek değerli bir giriş sinyali belirli uzunluktaki dilimlere bölünür. Bölünen bu dilimlere ait sinyallerin uç noktaları süreksizlik belirttiğinden, bu noktalar frekans spektrumu grafiklerinde çok yüksek güç değerlerine sebep olur. Buradaki temel mantık, her bir dilimdeki sinyal bu aralıkta durağan kabul edilir ve bir pencere fonksiyonuyla çarpılarak mevcut sinyallerin uç noktaları yumuşatılır. Böylece, sinyallerin sağ ve solundaki uç noktaları sıfıra yakın değerler alarak sönümlü bir hale gelir ve spektral sızıntı engellenmiş olur. Ardından, bu sinyallerin FFT' leri alınarak PSD değerleri elde edilir. Yani periodogramları hesaplanır. Her bir sinyale ait periodogramların ortalaması alınarak giriş sinyalinin nihai PSD değerleri hesaplanır. Diğer bir deyişle, orijinal giriş sinyalinin Welch yöntemini kullanarak nihai periodogramı elde edilmiş olur (Polat ve Güneş, 2007; Alkan ve Kiymik, 2006; So vd., 1999).

N adet elemana sahip, $x[n]$ şeklinde verilen kesikli bir giriş sinyalinin güç spektral yoğunluğunun tahmini periodogram ile ifade edilir ve eşitlik (4.14)' deki gibi gösterilir (Polat ve Güneş, 2007).

$$\hat{P}_{per}(f) = \frac{1}{N} \left[\sum_{n=0}^{N-1} x[n] e^{-j2\pi f n} \right]^2 \quad (4.14)$$

Welch yönteminde ise, kesikli giriş sinyali belirli uzunluktaki dilimlere bölünür. Her bir dilimin, isteğe bağlı olarak seçilmiş bir pencere fonksiyonuyla çarpıldıktan sonra yumuşatılmış periodogramları hesaplanır. Ardından, i. yumuşatılmış periodogram ifadesi eşitlik (4.15)' deki gibi gösterilir (Polat ve Güneş, 2007; Alkan ve Kiymik, 2006).

$$\hat{P}_i(f) = \frac{1}{M} \frac{1}{H} \left[\sum_{n=0}^{M-1} w[n] x_i[n] e^{-j2\pi f n} \right]^2 \quad (4.15)$$


Eşitlik (4.15)' deki $w[n]$ ifadesi, isteğe bağlı olarak seçilen herhangi bir pencere fonksiyodur. Genellikle “hamming” penceresi tercih edilir. M ifadesi, dilim uzunluğudur ve her bir dilim için eşittir. H ifadesi pencere fonksiyonunun normalize edilmiş halidir ve eşitlik (4.16)' da gösterilmiştir (Polat ve Güneş, 2007; Alkan ve Kiymik, 2006).

$$H = \frac{1}{M} \sum_{n=0}^{M-1} w[n]^2 \quad (4.16)$$

Son olarak, Welch' in güç spektral tahmini, yumuşatılmış periodogramların ortalaması alınarak elde edilir ve eşitlik (4.17)' deki gibi gösterilir (Polat ve Güneş, 2007; Alkan ve Kiymik, 2006).

$$\hat{P}_{welch}(f) = \frac{1}{S} \sum_{i=1}^S \hat{P}_i(f) \quad (4.17)$$

Eşitlik (4.17)' deki S ifadesi, dilim sayısı olup toplam veri uzunluğunun (N), dilim uzunluğuna (M) bölümüdür ($S = N/M$). Overlap uzunluğu ise ardışık 2 dilimin üst üste bindiği noktadaki veri sayısıdır. Diğer bir ifadeyle, dilimlerin kesişim noktasının uzunluğudur. Genellikle dilim uzunluğunun $1/2$ ' si kadar seçilir. Bu durumda, $S = (2N/M) - 1$ ile ifade edilir (Alkan ve Kiymik, 2006; Naderi ve Mahdavi-Nasab, 2010). Dilim uzunluğu ise veri uzunluğunun boyutuna göre keyfi bir değerde seçilebilir. Şekil 4.18' de pencerelenmiş dilimler arasında overlap yokken ve pencere genişliğinin $1/2$ ' si kadar overlap olduğu durumlar gösterilmiştir.



Şekil 4.18. Pencereler arasındaki overlap mesafesi.


Overlap, matematikteki kümeler mantığından ardışık iki pencerenin kesişim bölgesi olarak düşünülebilir. Bu bölgede kalan veri sayısı, overlap uzunluğu anlamına gelir. Welch yönteminde genel olarak pencere genişliğinin %50' si kadar overlap mesafesi seçilir.

Şekil 4.19’ da giriş sinyalinin herhangi bir dilimi için yapılan pencereleme işlemi ve ardından FFT ile güç spektral yoğunluğunun hesaplanması gösterilmiştir.



Şekil 4.19. Giriş sinyalinin herhangi bir dilimi için FFT alma işlemi.

Şekil 4.20’ de Welch yönteminin uygulanması sırasındaki aşamalar gösterilmiştir.



Şekil 4.20. Welch yönteminin uygulanma aşamaları.


Öncelikle giriş sinyali belirli ve eşit uzunluktaki dilimlere ayrılır. Ardından, bu dilimlere ait sinyallerin pencere fonksiyonuyla çarpılarak FFT’leri alınır ve yumuşatılmış periodogramları elde edilir. Yumuşatılmış periodogramların ortalamaları alınarak orijinal giriş sinyalinin nihai güç spektral yoğunluğu elde edilir. Böylece Welch yöntemi uygulanmış olur.

4.3. Sınıflandırma Yöntemleri

4.3.1. Uzun-kısa dönem hafıza (LSTM)

Uzun-kısa dönem hafıza ağları, Yinelenen sinir ağlarının (RNN) özel bir türüdür. RNN ağları eğitim sürecinde gradyan kaybolması sahip olduğundan daha önceki öğrendiği bilgileri kullanamaz. Kaybolan gradyan problemi, RNN ağındaki ağırlıkların güncellenmesi için uygulanan geri besleme algoritması esnasında hata sinyalinin 0' a yakın değerler almasıyla ortaya çıkar. Bunun sonucunda yeni ağırlık değerleri gittikçe küçülür ve belli bir aşamadan sonra güncellenemez. Bu probleme çözüm olarak, 1997 yılında Hochreiter ve Schmidhuber, RNN ağlarına yeni bellekler ekleyerek, uzun süreli bilgi depolayabilen LSTM ağlarını tanıtmıştır. LSTM ağları, kapılar aracılığıyla hücre durumlarına bilgi ekleme veya kaldırma yeteneğine sahiptir.

Kapı yapıları, sigmoid sinir ağı katmanı ve noktasal çarpma işlemlerini içerir. LSTM derin öğrenme ünitesi 3 kapıdan oluşmaktadır. Bu kapılar sırasıyla unutma kapısı, giriş kapısı ve çıkış kapısıdır (Michielli vd., 2019). Şekil 4.21' de, LSTM hücresinin yapısı gösterilmiştir.




Şekil 4.21. LSTM hücresinin yapısı.

Unutma kapısı sigmoid katmandan oluşur ve hücre durumundan (C_t) hangi bilgilerin atılacağına karar verir. Mevcut giriş x_t ve önceki hücre çıkışı h_{t-1} , unutma kapısının girişine uygulanır. Kapının çıkışından 0 veya 1 değeri elde edilir. Çıktı 0 ise bilgiler unutulur, 1 ise bilgi hücre durumunda tutulur (Alhagry vd., 2017).

Unutma kapısının çıkışı f_t , eşitlik (4.18)' de verilmiştir. Şekil 4.22' de, unutma kapısının LSTM hücresi içindeki yeri gösterilmiştir.

$$f_t = \sigma (w_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.18)$$




Şekil 4.22. Unutma kapısı

Giriş kapısı, sigmoid ve hiperbolik tanjant katmanlarından oluşmaktadır. Sigmoid katmanı, hangi bilgilerin güncelleneceğine karar verir. Tanjant katmanı güncellenmiş yeni değerlerin vektörü $\tilde{C}_t$ ' yi oluşturur.

Sigmoid katmanın çıkışı olan i_t ifadesi eşitlik (4.19)' da, tanjant katmanın çıkışı olan $\tilde{C}_t$ ifadesi eşitlik (4.20)' de verilmiştir (Wang vd. 2018). Şekil 4.23' te, giriş kapısının LSTM hücresi içindeki yeri gösterilmiştir.

$$i_t = \sigma (w_i \cdot [h_{t-1}, x_t] + b_i) \quad (4.19)$$


$$\tilde{C}_t = \tanh (w_c \cdot [h_{t-1}, x_t] + b_c) \quad (4.20)$$



Şekil 4.23. Giriş kapısı.

Eşitlik (4.19) ve (4.20) kullanılarak hücre durumunun güncellenmiş hali eşitlik (4.21)' de verilmiştir. (Wang vd. 2018). Şekil 4.24' te güncellenmiş hücre durumu gösterilmiştir.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4.21)$$




Şekil 4.24. Güncellenmiş hücre durumu.

Çıkış kapısında, güncellenmiş hücre durumu bilgileri tanjant katmanından geçirilir. Mevcut giriş bilgileri ile bir önceki hücrenin çıkışı sigmoid katmanından geçirilerek o_t elde edilir. Daha sonra her iki katmandan gelen bilgiler çarpılarak hücre çıkışı olan h_t ifadesi elde edilir. İfadeler eşitlik (4.22) ve (4.23)' te gösterilmiştir (Rashid vd., 2020). Şekil 4.25' te çıkış kapısının LSTM hücresi içindeki yeri gösterilmiştir.


$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (4.22)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (4.23)$$



Şekil 4.25. Çıkış kapısı

Yukarıda geçen eşitliklerde; σ ifadesi, değer aralığı $[0,1]$ olan sigmoid aktivasyon fonksiyonu, $\tanh$ ifadesi, değer aralığı $[-1,1]$ olan hiperbolik tanjant aktivasyon fonksiyonudur. w_f, w_i, w_c, w_o ağırlık matrisleri, x_t girdi vektörü ve h_{t-1} bir önceki gizli durumu gösterir. b_f, b_i, b_c, b_o ise bias vektörleridir (Alhagry vd., 2017). Şekil 4.26’ da birbiri ardına bağlı (kaskat) LSTM hücreleri gösterilmiştir.



Şekil 4.26. Birbiri ardına bağlı LSTM hücreleri.

4.3.2. Destek vektör makinesi (SVM)

Destek vektör makinesi (SVM), istatistiksel öğrenme teorisine dayalı bir sınıflandırma algoritmasıdır (Wang vd. 2013). SVM’ ler, sınıflandırma haricinde regresyon analizleri için de kullanılmaktadır. SVM algoritmaları, ilk başta 2 sınıflı doğrusal verilerin sınıflandırılması için tasarlanmıştır. Ardından bu algoritmalar geliştirilerek, çok sınıflı ve doğrusal olmayan veriler için de sınıflandırma imkânı doğmuştur. SVM algoritmaları, herhangi iki sınıfı birbirinden en iyi şekilde ayırabilen bir hiper-düzlemin oluşturulması esasına dayanmaktadır. Düzlem ifadesi, 2 boyutta bir “doğru”, 3 boyutta ise bir “yüzey” belirtir. 2 boyutlu grafiksel yaklaşımlarda, hiper-düzlem yerine “karar doğrusu” da denmektedir. SVM algoritmaları, verilerin doğrusal ayrılabilir ve doğrusal ayrılamama gibi durumları için 2’ ye ayrılır (Kavzoğlu ve Çölkesen, 2010).

Doğrusal destek vektör makineleri

İlk olarak herhangi iki sınıfa ait örnekler, -1 ve +1 değerleriyle ayrı ayrı etiketlenirler. Ardından eğitim verisiyle elde edilen karar fonksiyonunu kullanarak bu örnekler birbirinden bir doğru çizilerek ayrılırlar. Buradaki amaç, eğitim verilerini en iyi şekilde ayırabilecek bir hiper-düzlem bulmaktır. Diğer bir ifadeyle, sınıflara ait destek vektörleri arasındaki uzaklığı maksimize etmektir. Doğrusal SVM’ lerin eğitimi için kullanılan örnekler x_i ile bu örneklerin ait olduğu sınıf ise y_i olarak temsil edilsin. Buradaki y_i ifadesi -1 ve +1 değerlerini almaktadır. $\{x_i, y_i\}$ şeklinde ifade edilen eğitim verilerinin n adet olduğunu düşünelim ($i=1, 2, 3 \dots n$). Bu durumda en ideal

hiper-düzlem ifadesi eşitlik (4.24) ve eşitlik (4.25)' deki gibi ifade edilir (Wang vd., 2013; Kavzoğlu ve Çölkesen, 2010).


$$w \cdot x_i + b \geq +1, \text{ her } y = +1 \text{ için} \quad (4.24)$$

$$w \cdot x_i + b \leq -1, \text{ her } y = -1 \text{ için} \quad (4.25)$$

Buradaki w ifadesi ağırlık vektörü, b ise eğilim değeri olarak adlandırılır. En uygun hiper-düzlemin oluşturulabilmesi için bu düzleme biri solunda diğeri sağında ve paralel olacak şekilde iki adet hiper-düzlemin daha oluşturulması gerekir. Bu yeni hiper-düzlemleri oluşturan noktalara destek vektörleri denir. Oluşturulan düzlemlerin matematiksel ifadesi eşitlik (4.26)' da gösterilmiştir (Kavzoğlu ve Çölkesen, 2010).

$$w \cdot x_i + b = \pm 1 \quad (4.26)$$


Herhangi iki sınıfa ait verileri birbirinden ayıran farklı şekillerde birçok hiper-düzlem çizilebilir. Bu durum şekil 4.27' de gösterilmiştir.



Şekil 4.27. Farklı sınıflara ait verileri birbirinden ayıran hiper-düzlemler (Kavzoğlu ve Çölkesen, 2010).

Şekil 4.27' deki hiper-düzlemlerin, herhangi bir sınıfa çok yakın olmaları durumunda sınıflandırma başarısı düşer. En iyi sınıflandırma başarısı, sınıflara eşit uzaklıkta çizilen hiper düzlem veya “karar doğrusuyla” elde edilir.

Herhangi iki sınıfa ait verileri birbirinden ayıran optimum hiper düzlem ile bu düzleme paralel olan sınır düzlemleri şekil 4.28’ de gösterilmiştir.



Şekil 4.28. İki sınıfı birbirinden ayıran optimum hiper-düzlem ve sınır düzlemleri (Ayhan ve Erdoğan, 2014).

Kırmızı ve mavi kutucuklar, sırasıyla -1 ve +1 sınıflarına karşılık gelmektedir. Sınır düzlemi üzerlerindeki yeşil yuvarlaklar destek vektörleridir ve ait oldukları sınıfın sınırlarını belirtirler. Optimum bir hiper düzlemde, paralel sınır düzlemlerinin optimum düzleme olan uzaklıkları birbirine eşittir. Sınır düzlemleri arasındaki uzaklık “margin” veya türkçe tabirle “sınır” olarak adlandırılır. Sınır değeri arttığında, farklı sınıflara ait örnekler birbirlerinden daha iyi bir şekilde ayrılacağı için sınıflandırma başarısı artar. Dolayısıyla SVM’ nin çalışma prensibi, farklı sınıflara ait destek vektörleri arasındaki uzaklığın maksimum olduğu bir hiper düzlem oluşturmaktır. Bu hiper düzlem, karar fonksiyonu aracılığıyla oluşturulur.


Doğrusal olarak ayrılabilen veriler için optimum karar fonksiyonu ifadesi eşitlik (4.27)’ de gösterilmiştir (Ayhan ve Erdoğan, 2014).

$$h(x) = \sum_{i=1}^n \alpha_i y_i (x \cdot x_i) + b \quad (4.27)$$

Eşitlik (4.27)’ deki, n değişkeni eğitim setindeki örnek sayısına, b değişkeni eğilim değerine, y_i değeri -1 veya +1 değerine, x_i değişkeni giriş verisine, α_i ifadesi x_i ’ nin lagrange çarpanına karşılık gelir. Sınıflandırma çıktısı, karar fonksiyonunun işaretinin alınmasıyla, $f(x) = \text{sign}(h(x))$ ile elde edilir (Wang vd., 2013).

Doğrusal olmayan destek vektör makineleri

Bazı problemlerde, farklı sınıflara ait verilerin karar doğrusu kullanılarak doğrusal bir şekilde ayrılması mümkün olmaz. Bu sorun, kernel fonksiyonları aracılığıyla çözülebilir. Kernel fonksiyonlarıyla, girdi uzayında (iki boyutta) doğrusal olarak ayıramayan farklı sınıflara ait verilerin, özellik uzayında (üç boyutta) doğrusal olarak ayrılmaları sağlanır (Kavzoğlu ve Çölkesen, 2010). Bu durum şekil 4.29’ da gösterilmiştir.



Şekil 4.29. İki boyutta gösterilen verilerin kernel fonksiyonuyla üç boyutta gösterilmesi (Kavzoğlu ve Çölkesen, 2010).

Şekil 4.29’ da gösterildiği gibi, girdi uzayındaki iki farklı sınıfa ait olan veriler doğrusal olarak ayıramamaktadır. Bu durumda, girdi uzayındaki veriler kernel fonksiyonları aracılığıyla 3 boyutlu olan özellik uzayında görüntülenir. Böylece, özellik uzayında görüntülenen verilerin doğrusal ayrımı yapılarak sınıfları birbirinden ayıran bir hiper-düzlem çizilebilir. İki sınıflı ve doğrusal olarak ayıramayan problemlerdeki optimum karar fonksiyonu ifadesi, eşitlik (4.28)’ de gösterilmiştir (Wang vd., 2013).

$$h(x) = \sum_{i=1}^n \alpha_i y_i k(x, x_i) + b \quad (4.28)$$

Eşitlik (4.28)’ deki, n değişkeni eğitim setindeki örnek sayısına, b değişkeni eğilim değerine, y_i değeri-1 veya+1 değerine, $k(x, x_i)$ ifadesi ilgili kernel fonksiyonuna, α_i ifadesi x_i ’nin lagrange çarpanına karşılık gelir. Sonuç olarak, sınıflandırma çıktısı karar fonksiyonunun işaretinin alınmasıyla, $f(x) = \text{sign}(h(x))$ ile elde edilir (Wang vd., 2013). Doğrusal olmayan verilerin sınıflandırılmasında, ilgili kernel fonksiyonu ve bu fonksiyona ait bazı parametrelerin seçilmesi önemlidir. SVM ile yapılan doğrusal olmayan verilerin sınıflandırma işlemlerinde farklı kernel fonksiyonları kullanılmıştır. Bunlardan yaygın olarak kullanılanları; polinom, radyal tabanlı fonksiyon (RBF), Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom

kernelleridir (Kavzoğlu ve Çölkesen, 2010). Çizelge 4.3' te bu kernel fonksiyonlarının eşitlikleri gösterilmiştir.

Çizelge 4.3. Kernel fonksiyonlarının matematiksel ifadeleri (Kavzoğlu ve Çölkesen, 2010).


Kernel Fonksiyonu	Matematiksel İfadesi	Parametre
Polinom Kerneli	$K(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi (d)
Normalleştirilmiş Polinom Kerneli	$K(x, y) = \frac{((x \cdot y) + 1)^d}{\sqrt{((x \cdot x) + 1)^d ((y \cdot y) + 1)^d}}$	Polinom derecesi (d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	Kernel boyutu (γ)
Pearson VII (PUK) Kerneli	$\frac{1}{1 + \left(\frac{2 \cdot \sqrt{\ x - y\ ^2} \sqrt{2^{(1/\omega)} - 1}}{\sigma} \right)^2}^\omega$	Pearson genişliği parametreleri (σ, ω)

Çizelge 4.3' te adı geçen kernel fonksiyonlarının karşılaştırılması yapılacak olursa, polinom kernelinin derecesinin artırılması doğru orantılı olarak sınıflandırma işleminin de süresini arttırır. Derece parametresi çok fazla arttırıldığında ise sınıflandırma doğruluğu ciddi bir şekilde düşer. Normalleştirilmiş polinom kerneli, eğitimde kullanılan veri setinde normalleştirme yapmak yerine, polinom kernelinin normalleştirilmesiyle elde edilen kernel fonksiyonudur. RBF kerneline ait, kernel boyutu parametresinin değişen değerlerine bağlı olarak sınıflandırıcı performansının çok fazla etkilenmediği görülmüştür. PUK kernelinde ise, diğerlerine göre girilen 2 farklı parametre değeri bulunmaktadır. Bu ikili parametrenin seçilen değerleri sınıflandırıcı performansını önemli ölçüde etkiler ve hangi ikili değer en iyi sonuç vereceği önceden kestirilemez (Kavzoğlu ve Çölkesen, 2010).

5. DENEYSEL ÇALIŞMALAR VE BULGULAR

Bu tez çalışmasında; sol el, sağ el, ayak ve dil olmak üzere 4 farklı sınıfa ait motor hayali sinyallerinden özellik elde etmek için güç ve faz bilgisini içeren yöntemler sunulmuştur. PSD tabanlı özellikleri elde etmek için 2 farklı yöntem önerilmiştir. İlk yöntemde DWT ile birlikte Welch, ikinci yöntemde EMD ile birlikte Welch metodu kullanılmıştır. Sonlu uzunluktaki ve gerçek değerli bir giriş sinyalini, farklı frekans bandlarına sahip alt sinyallere ayırtmak için kullanılan DWT ve EMD yöntemlerinin sınıflandırıcı başarılarına olan etkileri kişiler ve kanallar bazında incelenmiştir. Faz tabanlı özellikleri elde etmek için 2 farklı yöntem sunulmuştur. İlk yöntemde ham EEG sinyallerine doğrudan Hilbert Dönüşümü uygulayarak analitik sinyallerin anlık faz değerleri elde edilmiştir. İkinci yöntemde ise EMD ile birlikte Hilbert Dönüşümü uygulanarak analitik sinyallerin anlık faz değerleri elde edilmiştir. Bu yöntemlerin sınıflandırıcı başarılarına olan etkileri kişiler ve belirli zaman aralıklarında incelenmiştir. Ayrıca, son zamanlarda sinyal sınıflandırmada yaygın olarak kullanılan LSTM derin ağı ile birlikte makine öğrenmesi olan SVM modelinin, sınıflandırma başarılarına olan etkileri detaylı olarak incelenmiştir.

5.1. 4 Sınıfa Ait Ham EEG Sinyalleri




Şekil 5.1. 4 sınıfa ait ham EEG işaretlerinin dalga formları.

Şekil 5,1' de, Cz kanalından alınan ve 4 farklı motor görevine ait EEG sinyallerinin dalga formları gösterilmiştir. Veriler, 22 kanallı ve 250 hz örnekleme frekansına sahip EEG cihazı kullanılarak örneklenmiştir. Ham EEG verileri toplamda 3' er saniyelik olup, 750 değerden oluşmaktadır. Sol el, sağ el, ayak ve dil sınıflarına ait motor hayali sinyallerinin farklı karakteristik yapılar da olduğu görülmektedir.


5.2. DWT Yöntemiyle Katsayı Sinyallerinin Elde Edilmesi

250 hz örnekleme frekansı ile örneklenen EEG sinyallerine, 'db8' dalgacık fonksiyonunu kullanarak 5. seviye DWT uygulanmıştır. Elde edilen A5 (Delta, 0-4 hz), D5 (Teta, 4-8 hz), D4 (Alfa, 8-16 hz) ve D3 (Beta, 16-32 hz) sinyalleri özellik çıkarmada kullanılmıştır. Şekil 5.2' de, sol el sınıfına ait EEG verilerine DWT yöntemi uygulanarak elde edilen katsayı sinyallerinin dalga formları gösterilmiştir.




Şekil 5.2. DWT kullanılarak hesaplanan sol el sınıfına ait katsayı sinyalleri.

Şekil 5.3' te, sağ el sınıfına ait EEG verilerine DWT yöntemi uygulanarak elde edilen katsayı sinyallerinin dalga formları gösterilmiştir.




Şekil 5.3. DWT kullanılarak hesaplanan sağ el sınıfına ait katsayı sinyalleri.

Şekil 5.4' te, ayak sınıfına ait EEG verilerine DWT yöntemi uygulanarak elde edilen katsayı sinyallerinin dalga formları gösterilmiştir.



Şekil 5.4. DWT kullanılarak hesaplanan ayak sınıfına ait katsayı sinyalleri.

Şekil 5.5’ te, dil sınıfına ait EEG verilerine DWT yöntemi uygulanarak elde edilen katsayı sinyallerinin dalga formları gösterilmiştir.




Şekil 5.5. DWT kullanılarak hesaplanan dil sınıfına ait katsayı sinyalleri.

5.3. Welch Yöntemiyle Katsayı Sinyallerinin PSD Değerlerinin Hesaplanması


Bandlara ait PSD değerleri, Welch yöntemi kullanılarak hesaplanmıştır. Welch yönteminde, pencere uzunluğu parametresi veri boyutunun $1/3$ ' ü kadar, noverlap parametresi ise pencere uzunluğunun $1/2$ ' si kadar seçilmiştir. Pencere fonksiyonu olarak Hamming window kullanılmıştır. Nyquist frekansı 125 hz olduğundan elde edilen grafiklerdeki frekans değerleri 125 hz' ye kadardır. Yani, her bir band sinyali için 0' dan 125 hz' ye kadar PSD değeri mevcuttur. Fakat, bu PSD değerleri ilgili band aralıklarının dışında çok küçük değerlere sahiptir. Bu yüzden sol el, sağ el, ayak ve dil sınıfları için 4 farklı banda ait PSD değerlerinin, sadece ilgili frekans bandı aralıklarındaki kısımları bir öznitelik vektöründe birleştirilmek üzere kullanılmıştır.

Şekil 5.6’ da, sol el sınıfına ait ve her bir band aralığı için elde edilen güç-frekans grafikleri gösterilmiştir.




Şekil 5.6. Sol el sınıfına ait bandların PSD grafikleri.

Şekil 5.7’ de sol el sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.7. Sol el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.8’ de, sağ el sınıfına ait ve her bir band aralığı için elde edilen güç-frekans grafikleri gösterilmiştir.




Şekil 5.8. Sağ el sınıfına ait bandların PSD grafikleri.

Şekil 5.9’ da sağ el sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.9. Sağ el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.10’ da, ayak sınıfına ait ve her bir band aralığı için elde edilen güç-frekans grafikleri gösterilmiştir.




Şekil 5.10. Ayak sınıfına ait bandların PSD grafikleri.

Şekil 5.11’ de ayak sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.11. Ayak sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.12’ de, dil sınıfı ait ve her bir band aralığı için elde edilen güç-frekans grafikleri gösterilmiştir.



Şekil 5.12. Dil sınıfına ait bandların PSD grafikleri.

Şekil 5.13’ de dil sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.13. Dil sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

5.4. DWT+Welch Yöntemiyle Özniteliklerin Oluşturulması

Delta (0-4 Hz), Teta (4-8 Hz), Alfa (8-16 Hz) ve Beta (16-32) bandlarından elde edilen PSD değerlerinin alt alta eklenmesiyle öznitelik vektörleri oluşturulmuştur. Öznitelik vektörü; delta bandından 12, teta bandından 12, alfa bandından 24 ve beta bandından 48 adet olmak üzere toplamda 96 adet PSD değerinden oluşmaktadır. Sonuç olarak, kanal bazında 750 elemandan oluşan EEG verileri, 96 elemanlı PSD değerleriyle temsil edilmiştir.

Şekil 5.14' te sol el sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.14. Sol el sınıfına ait birleştirilmiş band güçleri.

Şekil 5.15' te sağ el sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.15. Sağ el sınıfına ait birleştirilmiş band güçleri.

Şekil 5.16' da ayak sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.



Şekil 5.16. Ayak sınıfına ait birleştirilmiş band güçleri,

Şekil 5.17' de dil sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.17. Dil sınıfına ait birleştirilmiş band güçleri.

5.5. EMD Yöntemiyle İMF' lerin Elde Edilmesi


250 hz örnekleme frekansı ile örneklenen EEG sinyalleri, farklı frekanslardaki 4 adet İMF' ye ayrıştırılmıştır. İMF' lerin anlık frekans bilgisinden yola çıkarak elde edilen İMF-5, İMF-4, İMF-3 ve İMF-2 sinyallerinin sırasıyla delta, teta, alfa ve beta bandlarına yaklaşık olarak karşılık geldiği söylenebilir.

Şekil 5.18’ de, sol el sınıfına ait EEG verilerine EMD yöntemi uygulanarak elde edilen İMF sinyallerinin dalga formları gösterilmiştir.




Şekil 5.18. EMD kullanılarak hesaplanan sol el sınıfına ait İMF sinyalleri.

Şekil 5.19’ da, sağ el sınıfına ait EEG verilerine EMD yöntemi uygulanarak elde edilen İMF sinyallerinin dalga formları gösterilmiştir.




Şekil 5.19. EMD kullanılarak hesaplanan sağ el sınıfına ait İMF sinyalleri.

Şekil 5.20’ de, ayak sınıfına ait EEG verilerine EMD yöntemi uygulanarak elde edilen İMF sinyallerinin dalga formları gösterilmiştir.



Şekil 5.20. EMD kullanılarak hesaplanan ayak sınıfına ait İMF sinyalleri.


Şekil 5.21’ de, dil sınıfına ait EEG verilerine EMD yöntemi uygulanarak elde edilen İMF sinyallerinin dalga formları gösterilmiştir.



Şekil 5.21. EMD kullanılarak hesaplanan dil sınıfına ait İMF sinyalleri.


5.6. Welch Yöntemiyle İMF Sinyallerinin PSD Değerlerinin Hesaplanması

Bandlara ait PSD değerleri, Welch yöntemi kullanılarak hesaplanmıştır. Welch yönteminde, pencere uzunluğu parametresi veri boyutunun $1/3$ ' ü kadar, noverlap parametresi ise pencere uzunluğunun $1/2$ ' si kadar seçilmiştir. Ayrıca pencere fonksiyonu olarak Hamming window kullanılmıştır. Nyquist frekansı, 125 hz olduğundan elde edilen grafikler frekans değerleri 125 hz' ye kadardır. Yani, her bir band sinyali için 0' dan 125 hz' ye kadar PSD değeri mevcuttur. Fakat, bu PSD değerleri ilgili band aralıklarının dışında çok küçük değerlere sahiptir. Bu yüzden sol el, sağ el, ayak ve dil sınıfı için 4 banda ait PSD değerlerinin, sadece ilgili frekans bandı aralıklarındaki kısımları bir öznitelik vektöründe birleştirilmek üzere kullanılmıştır. Şekil 5.22' de, sol el sınıfına ait ve EMD yöntemiyle elde edilen her bir band aralığının güç-frekans grafikleri gösterilmiştir.




Şekil 5.22. Sol el sınıfına ait bandların PSD grafikleri.

Şekil 5.23’ te sol el sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.23. Sol el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.24’ te, sağ el sınıfına ait ve EMD yöntemiyle elde edilen her bir band aralığının güç-frekans grafikleri gösterilmiştir.




Şekil 5.24. Sağ el sınıfına ait bandların PSD grafikleri.

Şekil 5.25’ te sağ el sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.25. Sağ el sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.26’ da, ayak sınıfına ait ve EMD yöntemiyle elde edilen her bir band aralığının güç-frekans grafikleri gösterilmiştir.




Şekil 5.26. Ayak sınıfına ait bandların PSD grafikleri.

Şekil 5.27’ de ayak sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.




Şekil 5.27. Ayak sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.

Şekil 5.28’ de, dil sınıfına ait ve EMD yöntemiyle elde edilen her bir band aralığının güç-frekans grafikleri gösterilmiştir.



Şekil 5.28. Dil sınıfına ait bandların PSD grafikleri.

Şekil 5.29’ da dil sınıfına ait, Welch yöntemiyle hesaplanan PSD’ lerin belirli frekans aralıklarındaki değerleri gösterilmiştir.



Şekil 5.29. Dil sınıfına ait bandların ilgili frekans aralıklarındaki PSD grafikleri.


5.7. EMD+Welch Yöntemiyle Özniteliklerin Oluşturulması

Delta (0-4 Hz), Teta (4-8 Hz), Alfa (8-16 Hz) ve Beta (16-32) bandlarından elde edilen PSD değerlerinin alt alta eklenmesiyle öznitelik vektörleri oluşturulmuştur. Öznitelik vektörü; delta bandından 12, teta bandından 12, alfa bandından 24 ve beta bandından 48 adet olmak üzere toplamda 96 adet PSD değerinden oluşmaktadır. Sonuç olarak, kanal bazında 750 elemandan oluşan EEG verileri, 96 elemanlı PSD değerleriyle temsil edilmiştir. Şekil 5.30’ da sol el sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.30. Sol el sınıfına ait birleştirilmiş band güçleri.

Şekil 5.31’ de sağ el sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.31. Sağ el sınıfına ait birleştirilmiş band güçleri.

Şekil 5.32’ de ayak sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.



Şekil 5.32. Ayak sınıfına ait birleştirilmiş band güçleri.

Şekil 5.33' te dil sınıfına ait 4 farklı band gücünün birleştirilmesiyle elde edilen güç sinyali gösterilmiştir.




Şekil 5.33. Dil sınıfına ait birleştirilmiş band güçleri.

5.8. DWT ve EMD Yöntemlerinin Karşılaştırılması

Bu tez çalışmasında, DWT ve EMD yöntemleri kullanılarak elde edilen ve yaklaşık olarak aynı frekans bandlarına ait eşdeğer sayılabilecek sinyaller arasında karşılaştırma yapılmıştır. Karşılaştırma sonucu, grafiksel yaklaşımla birlikte sinyaller arasındaki korelasyon katsayılarıyla verilmiştir. Ham EEG verilerine DWT uygulanarak A5, D5, D4 ve D3 sinyalleri, EMD uygulanarak İMF-5, İMF-4, İMF-3 ve İMF-2 sinyalleri elde edilmiştir. Bu sinyaller sırasıyla delta (0-4 Hz), teta (4-8 Hz), alfa (8-16 Hz) ve beta (16-32 Hz) bandlarına karşılık gelmektedir.

Şekil 5.34’ te, sol el sınıfına ait DWT ve EMD yöntemleri ile elde edilen band sinyalleri gösterilmiştir.



Şekil 5.34. DWT ve EMD ile hesaplanan sol el sınıfına ait band sinyalleri.


Şekil 5.34’ teki sinyaller arasındaki benzerlik oranları, Çizelge 5.1’ de korelasyon katsayıları hesaplanarak verilmiştir.

Çizelge 5.1. Sol el sınıfına ait korelasyon katsayıları.

Sınıf	DWT	EMD	Korelasyon Katsayısı
Sol El	A5	İMF-5	0.72
	D5	İMF-4	0.63
	D4	İMF-3	0.57
	D3	İMF-2	0.61

Çizelge 5.1’ de, 2 farklı yöntemle elde edilen ve yaklaşık olarak aynı frekans bandlarına karşılık gelen sinyaller arasındaki korelasyon katsayıları verilmiştir. Çizelge’ ye göre en yüksek benzerliğin, A5 ile İMF-5 sinyalleri arasında olduğu görülmektedir. En düşük benzerlik ise D4 ile İMF-3 sinyalleri arasındadır.

Şekil 5.35’ te, sağ el sınıfına ait DWT ve EMD yöntemleri ile elde edilen band sinyalleri gösterilmiştir.



Şekil 5.35. DWT ve EMD ile hesaplanan sağ el sınıfına ait band sinyalleri.


Şekil 5.35’ teki sinyaller arasındaki benzerlik oranları Çizelge 5.2’ de korelasyon katsayıları hesaplanarak verilmiştir.

Çizelge 5.2. Sağ el sınıfına ait korelasyon katsayıları.

Sınıf	DWT	EMD	Korelasyon Katsayısı
Sağ El	A5	İMF-5	0.56
	D5	İMF-4	0.59
	D4	İMF-3	0.69
	D3	İMF-2	0.62

Çizelge 5.2’ de 2 farklı yöntemle elde edilen ve yaklaşık olarak aynı frekans bandlarına karşılık gelen sinyaller arasındaki korelasyon katsayıları verilmiştir. Çizelge’ ye göre en yüksek benzerliğin, D4 ile İMF-3 sinyalleri arasında olduğu görülmektedir. En düşük benzerlik ise A5 ile İMF-5 sinyalleri arasındadır.

Şekil 5.36’ da, ayak sınıfına ait DWT ve EMD yöntemleri ile elde edilen band sinyalleri gösterilmiştir.



Şekil 5.36. DWT ve EMD ile hesaplanan ayak sınıfına ait band sinyalleri.


Şekil 5.36’ daki sinyaller arasındaki benzerlik oranları Çizelge 5.3’ te korelasyon katsayıları hesaplanarak verilmiştir.

Çizelge 5.3. Ayak sınıfına ait korelasyon katsayıları.

Sınıf	DWT	EMD	Korelasyon Katsayısı
Ayak	A5	İMF-5	0.76
	D5	İMF-4	0.42
	D4	İMF-3	0.61
	D3	İMF-2	0.63

Çizelge 5.3’ te 2 farklı yöntemle elde edilen ve yaklaşık olarak aynı frekans bandlarına karşılık gelen sinyaller arasındaki korelasyon katsayıları verilmiştir. Çizelge’ ye göre en yüksek benzerliğin, A5 ile İMF-5 sinyalleri arasında olduğu görülmektedir. En düşük benzerlik ise D5 ile İMF-4 sinyalleri arasındadır.

Şekil 5.37’ de, dil sınıfına ait DWT ve EMD yöntemleri ile elde edilen band sinyalleri gösterilmiştir.



Şekil 5.37. DWT ve EMD ile hesaplanan dil sınıfına ait band sinyalleri.

Şekil 5.37’ deki sinyaller arasındaki benzerlik oranları Çizelge 5.4’ te korelasyon katsayıları hesaplanarak verilmiştir.

Çizelge 5.4. Dil sınıfına ait korelasyon katsayıları.

Sınıf	DWT	EMD	Korelasyon Katsayısı
Dil	A5	İMF-5	0.85
	D5	İMF-4	0.70
	D4	İMF-3	0.61
	D3	İMF-2	0.59

Çizelge 5.4’ te, 2 farklı yöntemle elde edilen ve yaklaşık olarak aynı frekans bandlarına karşılık gelen sinyaller arasındaki korelasyon katsayıları verilmiştir. Çizelge’ ye göre en yüksek benzerliğin, A5 ile İMF-5 sinyalleri arasında olduğu görülmektedir. En düşük benzerlik ise D3 ile İMF-2 sinyalleri arasındadır.

Sonuç olarak, 2 farklı sinyal ayrıştırma yöntemi olan DWT ve EMD yöntemleriyle elde edilen aynı tür band aralıklarındaki sinyallerin benzerlikleri bulunmaktadır. Genel olarak, en yüksek korelasyon katsayısının en düşük frekanslı sinyallere karşılık gelen A5 ile İMF-5 sinyalleri arasında olduğu gözlemlenmiştir.

5.9. PSD Tabanlı Sınıflandırma İşlemleri

5.9.1. Kullanılan veri setinin dağılımı

Çizelge 5.5’ te DWT+WELCH ve EMD+WELCH yöntemlerinde kullanılan veri seti, kişiler ve sınıflar bazında olmak üzere detaylı olarak verilmiştir.

Çizelge 5.5. Sınıflandırmada kullanılan veri seti’ nin dağılımı.

Kişi	Sınıf				Sınıflandırıcı				
	Sol El	Sağ El	Ayak	Dil	LSTM			SVM	
					Eğitim	Val.	Test	Eğitim	Test
S1	411	411	411	411	1148	244	244	1148	488
S2	411	411	411	411	1148	244	244	1148	488
S3	411	411	411	411	1148	244	244	1148	488
S4	411	411	411	411	1148	244	244	1148	488
S5	411	411	411	411	1148	244	244	1148	488
S6	411	411	411	411	1148	244	244	1148	488
S7	411	411	411	411	1148	244	244	1148	488
S8	411	411	411	411	1148	244	244	1148	488
S9	411	411	411	411	1148	244	244	1148	488

Derin öğrenme algoritmalarının öğrenme stratejilerinde, eğitimleri için çok sayıda örnek gerektiğinden, elde edilen öznitelik vektörleri %90 ve %10 faktörleriyle çarpılmıştır. Böylece, öznitelik vektörlerinin sayıları üç kat artırılmıştır (Lashgari vd., 2020; Sakai vd., 2017). Kullanılan yöntemlerde kanal bazında çalışıldığından, toplamda 22 kanalın her biri için aynı sayıda veri seti mevcuttur. Her bir kişi için tüm sınıflara ait veriler, 411 adet öznitelik vektöründen oluşmaktadır. Her bir öznitelik vektörü 96 adet PSD değeri içermektedir. Bir kişiye ait sol el, sağ el, ayak ve dil sınıfları için toplamda 1644 adet öznitelik vektörü mevcuttur. LSTM derin ağında, bu öznitelik vektörlerinin %70’ lik kısmı eğitim, %15’ lik kısmı validation ve diğer %15’ lik kısmı test için kullanılmıştır. SVM’ de ise, veri setinin %70’ i eğitim ve %30’ ı test için ayrılmıştır. 2 sınıflandırıcının doğru bir şekilde kıyaslanabilmesi için, LSTM ve SVM

sınıflandırıcılarında aynı eğitim seti kullanılmıştır. Ayrıca, LSTM ağının %15' lik test ve %15' lik validation veri setleri birleştirilerek SVM sınıflandırıcısının test seti olarak kullanılmıştır.

5.9.2. LSTM ağında kullanılan parametreler


Çizelge 5.6' da LSTM derin ağında kullanılan ve önemli sayılabilecek parametreler verilmiştir.

Çizelge 5.6. LSTM derin ağında kullanılan eğitim parametreleri.

LSTM Parametreleri		Sayı
Layers	Fully Connected Layer	4
	Softmax Layer	1
	Hidden Layer	100
Options	Max Epoch	200
	Mini Batch Size	64
	Learning Rate	0.005
	Validation Freq.	50


Epochs sayısı 200 olarak girildiğinden LSTM derin ağı eğitim boyunca 3600 iterasyon yapmıştır. MiniBatchSize parametresi olarak 64 girilmiştir ve her epochta veri setinden alınan 64 adet öznitelik vektörüyle eğitim yapılmıştır. Öğrenme oranı olarak 0.005 değeri seçilmiştir. Validation frequency olarak 50 değeri girilmiştir. Böylece eğitim boyunca her 50 iterasyonda bir LSTM ağının kendi içerisinde öğrendiklerini test etmesi sağlanmıştır.

5.9.3. PSD özelliklerini kullanarak LSTM ağının eğitilmesi



Şekil 5.38. DWT+Welch kullanarak LSTM ağının eğitim ve validation başarıları.

Şekil 5.38’ de, 9.kişinin FCz kanalına DWT+Welch yöntemi uygulanarak oluşturulan özniteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde edilen eğitim ve validation başarı grafikleri verilmiştir. LSTM ağının validation başarıları %89,92’ dir.



Şekil 5.39. EMD+Welch kullanarak LSTM ağının eğitim ve validation başarıları.

Şekil 5.39’ da, 9.kişinin FCz kanalına EMD+Welch yöntemi uygulanarak oluşturulan özniteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde edilen eğitim ve validation başarı grafikleri verilmiştir. LSTM ağının validation başarıları ise %90,73’ tür.

5.9.4. PSD tabanlı sınıflandırma sonuçları

Çizelge 5.7’ de DWT+Welch yöntemiyle oluşturulan özniteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde edilen test başarıları verilmiştir.

Çizelge 5.7. LSTM derin ağının DWT+Welch yöntemiyle elde edilen test başarıları.

Kanal	Kişiler									Ort.
	S1	S2	S3	S4	S5	S6	S7	S8	S9	
Fz	83,20	86,89	89,34	84,43	89,92	82,26	87,50	81,05	92,34	86,33
FC3	87,30	86,48	93,85	86,48	89,11	79,03	89,92	87,08	82,26	86,83
FC1	92,62	80,74	92,62	84,84	90,73	88,31	77,02	75,81	81,85	84,95
FCz	87,70	86,07	89,34	79,51	87,90	84,68	80,65	89,07	86,69	85,73
FC2	84,43	86,89	89,75	87,30	87,11	83,06	89,11	87,10	84,68	86,60
FC4	80,33	89,75	88,11	86,89	82,66	83,47	86,69	83,87	92,34	86,01
C5	84,02	85,25	87,70	88,93	89,11	87,50	85,08	86,29	87,50	86,82
C3	83,20	84,84	86,89	84,43	80,65	84,27	86,69	89,52	87,40	85,32
C1	86,07	86,48	87,70	83,61	90,32	87,50	88,31	91,94	86,55	87,61
Cz	88,93	91,39	88,11	86,07	82,66	83,87	91,13	92,34	87,90	88,04
C2	75,41	86,07	90,16	87,30	81,05	78,23	83,47	87,02	84,27	83,66
C4	89,75	92,21	90,57	87,20	72,98	77,82	83,06	87,10	85,89	85,18
C6	93,03	90,57	73,77	79,51	89,11	74,60	86,69	77,82	89,11	83,80
CP3	86,48	89,34	88,11	88,11	80,65	84,27	81,85	81,45	87,90	85,35
CP1	81,56	89,34	85,25	86,07	74,60	87,46	86,29	91,94	81,45	84,88
CPz	86,89	84,84	82,38	76,64	73,39	70,97	88,31	85,89	89,04	82,04
CP2	89,75	88,11	80,33	89,75	87,10	75,81	83,87	89,11	85,79	85,51
CP4	86,89	74,18	88,11	87,70	84,68	88,31	72,18	90,73	85,08	84,21
P1	77,87	73,36	89,34	90,57	90,73	86,29	75,00	84,68	79,03	83,00
Pz	84,84	85,25	82,79	90,45	83,06	88,71	86,69	87,00	83,47	85,81
P2	82,38	80,74	87,30	90,30	87,90	87,10	88,71	78,63	84,27	85,26
POz	86,07	90,98	90,58	88,93	79,84	87,40	88,65	89,11	88,31	87,76
Ort.	85,40	85,90	87,37	86,14	84,33	83,22	84,86	86,12	86,05	---

Çizelge 7’ de, 9 kişiye ait 22 kanalın başarıları detaylı olarak gösterilmiştir. Kişiler bazında en yüksek başarı, 22 kanalın başarılarının ortalaması alınarak hesaplanmıştır ve 3. kişide %87,37 olarak elde edilmiştir. Bu kişiye en yakın başarı ise %86,14’ lük başarıyla 4. kişi olmuştur. Kişiler bazında en düşük başarı ise 6. kişide %83,22 olarak elde edilmiştir. Kanallar bazında en yüksek başarı, 9 kişiye ait başarıların ortalaması alınarak hesaplanmıştır ve Cz kanalında %88,04 olarak elde edilmiştir. Bu kanala en yakın başarı ise %87,76’ lık başarıyla POz kanalı olmuştur. Kanallar bazında en düşük başarı ise CPz kanalında %82,04 olarak elde edilmiştir.

Çizelge 5.8’ de DWT+Welch yöntemiyle oluşturulan özniteliklerin, SVM algoritmasıyla sınıflandırılması sonucunda elde edilen test başarıları verilmiştir.

Çizelge 5.8. SVM algoritmasının DWT+Welch yöntemiyle elde edilen test başarıları.

Kanal	Kişiler									Ort.
	S1	S2	S3	S4	S5	S6	S7	S8	S9	
Fz	74,59	73,98	78,89	73,57	69,76	70,56	72,98	77,22	78,63	74,46
FC3	78,07	67,01	84,63	74,80	71,37	72,58	77,22	77,15	78,02	75,65
FC1	80,33	66,19	81,15	79,51	70,16	70,77	73,59	79,23	75,81	75,19
FCz	80,30	71,72	78,89	77,25	67,74	71,57	77,42	81,05	77,82	75,97
FC2	78,48	69,67	81,15	77,05	68,35	75,00	75,81	79,84	77,42	75,86
FC4	76,43	69,06	80,74	73,36	66,13	74,00	75,00	76,41	74,40	73,95
C5	81,15	63,93	85,25	73,16	66,94	76,21	75,03	76,45	81,45	75,51
C3	77,66	64,75	87,09	75,00	74,00	76,01	77,62	78,63	81,25	76,89
C1	78,07	67,62	80,74	77,87	68,35	77,22	74,80	78,23	78,23	75,68
Cz	82,38	70,90	81,97	74,80	69,56	72,58	77,22	80,04	80,44	76,65
C2	80,12	67,83	83,40	72,95	69,76	75,20	79,44	80,24	79,84	76,53
C4	80,94	68,44	82,58	77,85	69,35	70,97	77,22	77,42	79,80	76,06
C6	73,16	71,93	80,33	77,80	70,97	71,98	77,18	76,81	79,75	75,55
CP3	83,81	65,98	84,63	79,92	73,59	74,40	75,40	78,23	81,65	77,51
CP1	79,51	70,90	82,79	80,94	68,75	71,37	77,42	82,66	82,86	77,47
CPz	76,02	69,26	80,33	75,61	69,15	72,58	78,02	83,67	81,05	76,19
CP2	77,87	69,06	79,92	77,85	67,74	75,40	76,01	81,85	78,23	76,00
CP4	80,74	70,08	83,81	76,84	69,15	77,02	77,82	78,63	82,26	77,37
P1	79,30	69,88	78,48	80,53	68,75	72,38	76,41	79,84	83,87	76,60
Pz	77,66	68,85	77,25	79,92	68,95	70,77	78,63	82,46	77,62	75,79
P2	78,69	71,52	78,89	77,66	65,73	75,00	79,03	81,25	77,02	76,09
POz	75,82	69,67	76,84	82,38	70,97	74,40	76,05	81,85	75,60	75,95
Ort.	78,69	69,01	81,35	77,12	69,33	73,54	76,61	79,51	79,23	---

Çizelge 5.8’ de, 9 kişiye ait 22 kanalın başarısı detaylı olarak gösterilmiştir. Kişiler bazında en yüksek başarı, 22 kanalın başarılarının ortalaması alınarak hesaplanmıştır ve 3. Kişide %81,35 olarak elde edilmiştir. Bu kişiye en yakın başarı ise %79,51’ lik başarıyla 8. Kişi olmuştur. Kişiler bazında en düşük başarı ise 2. Kişide %69,01 olarak elde edilmiştir. Kanallar bazında en yüksek başarı, 9 kişiye ait başarıların ortalaması alınarak hesaplanmıştır ve CP3 kanalında %77,51 olarak elde edilmiştir. Bu kanala en yakın başarı ise %77,47’ lik başarıyla CP1 kanalı olmuştur. Kanallar bazında en düşük başarı ise FC4 kanalında %73,95 olarak elde edilmiştir. SVM ve LSTM ile yapılan sınıflandırma sonuçlarına göre, derin öğrenme algoritması olan LSTM ağının, makine öğrenmesi algoritması olan SVM’ ye göre üstünlüğü görülmektedir.

Çizelge 5.9’ da EMD+Welch yöntemiyle oluşturulan özneteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde edilen test başarıları verilmiştir.

Çizelge 5.9. LSTM derin ağının EMD+Welch yöntemiyle elde edilen test başarıları.

Kanal	Kişiler									Ort.
	S1	S2	S3	S4	S5	S6	S7	S8	S9	
Fz	92,21	90,98	88,93	76,64	89,92	87,90	90,32	87,50	85,08	87,72
FC3	85,66	81,97	84,84	73,77	90,32	88,71	87,90	91,13	86,69	85,67
FC1	90,57	90,92	89,34	84,02	77,42	76,61	81,45	86,69	86,65	84,55
FCz	88,52	90,16	87,70	88,52	87,50	89,52	89,52	90,73	91,94	89,35
FC2	84,84	75,41	87,65	77,05	87,45	88,31	90,32	83,06	87,50	84,62
FC4	86,89	84,84	88,52	89,75	84,68	85,86	90,73	80,65	88,71	86,74
C5	74,18	84,43	87,68	79,92	89,11	87,50	73,39	84,68	72,98	81,54
C3	94,26	86,07	88,11	76,23	80,65	77,82	73,79	92,34	90,32	84,40
C1	89,75	86,48	91,39	91,80	86,69	88,31	80,65	79,44	89,92	87,16
Cz	85,25	91,80	91,32	81,56	91,53	89,11	89,92	88,71	89,52	88,75
C2	93,03	89,34	90,16	86,07	84,27	91,53	85,08	87,90	89,88	88,58
C4	90,16	77,05	84,81	76,64	85,89	89,92	84,27	83,87	83,87	84,05
C6	76,64	88,11	77,46	78,28	82,66	79,03	80,65	87,10	83,47	81,49
CP3	88,52	89,75	86,48	82,38	78,23	74,60	83,06	91,94	87,90	84,76
CP1	77,46	86,48	82,79	84,80	91,13	83,06	89,92	88,71	89,52	85,99
CPz	86,07	90,16	84,02	84,02	90,32	84,27	85,08	89,52	81,85	86,15
CP2	90,57	77,87	77,42	81,56	89,52	91,13	89,52	87,50	86,29	85,71
CP4	90,53	92,21	88,07	82,38	79,03	77,42	85,05	74,19	89,11	84,22
P1	81,56	73,36	90,16	88,52	88,71	83,06	78,23	90,32	91,13	85,01
Pz	73,36	91,80	82,75	86,07	89,52	80,65	81,45	89,92	80,24	83,97
P2	84,84	77,82	91,80	87,70	91,50	86,69	80,24	77,42	84,27	87,70
POz	90,50	82,79	89,34	79,92	76,61	82,66	82,26	87,10	85,48	84,07
Ort.	86,15	85,45	86,85	82,62	86,03	84,71	84,22	86,38	86,47	---


Çizelge 5.9’ da, 9 kişiye ait 22 kanalın başarısı detaylı olarak gösterilmiştir. Kişiler bazında en yüksek başarı, 22 kanalın başarılarının ortalaması alınarak hesaplanmıştır ve 3. kişide %86,85 olarak elde edilmiştir. Bu kişiye en yakın başarı ise %86,47’ lik başarıyla 9. kişi olmuştur. Kişiler bazında en düşük başarı ise 4. kişide %82,62 olarak elde edilmiştir. Kanallar bazında en yüksek başarı, 9 kişiye ait başarıların ortalaması alınarak hesaplanmıştır ve FCz kanalında %89,35 olarak elde edilmiştir. Bu kanala en yakın başarı ise %88,75’ lik başarıyla Cz kanalı olmuştur. Kanallar bazında en düşük başarı ise C6 kanalında %81,49 olarak elde edilmiştir.

Çizelge 5.10’ da, EMD+Welch ile oluşturulan özniteliklerin, SVM algoritmasıyla sınıflandırılması sonucunda elde edilen test başarıları verilmiştir.

Çizelge 5.10. SVM algoritmasının EMD+Welch yöntemiyle elde edilen test başarıları.


Kanal	Kişiler									Ort.
	S1	S2	S3	S4	S5	S6	S7	S8	S9	
Fz	76,84	72,13	77,87	75,00	70,16	78,23	73,19	74,60	78,02	75,12
FC3	78,69	69,26	83,81	77,46	69,15	74,19	74,19	72,78	80,04	75,51
FC1	76,23	67,01	81,76	70,70	69,35	76,61	77,42	74,40	76,61	74,45
FCz	76,84	70,70	78,48	71,52	70,97	77,82	75,20	76,81	75,60	74,88
FC2	76,02	73,57	79,10	72,54	67,74	76,41	72,78	74,55	76,41	74,35
FC4	75,00	68,65	76,43	76,84	70,56	73,00	73,79	78,02	75,00	74,14
C5	78,48	63,93	87,30	73,36	69,15	75,60	74,60	72,98	81,25	75,18
C3	78,07	67,62	85,04	74,18	67,94	77,22	79,44	75,60	81,65	76,31
C1	80,53	69,47	81,76	77,46	67,54	79,03	76,01	73,79	79,84	76,16
Cz	77,25	72,54	77,66	76,64	67,34	73,59	73,79	77,62	76,61	74,78
C2	81,35	68,85	80,33	75,41	68,15	75,20	77,02	77,59	79,03	75,88
C4	80,12	74,59	80,74	75,61	72,38	71,77	79,23	76,01	80,04	76,72
C6	78,28	68,65	81,15	70,90	72,98	78,23	76,61	75,81	77,62	75,58
CP3	86,07	73,57	80,94	76,43	65,52	78,02	75,20	77,22	78,23	76,80
CP1	79,71	70,08	82,17	78,07	66,94	76,21	75,40	75,60	78,20	75,82
CPz	78,07	75,00	79,51	80,53	72,78	73,19	78,23	79,23	77,42	77,11
CP2	75,20	70,49	83,61	80,12	69,96	78,63	78,20	79,03	77,82	77,01
CP4	80,53	70,08	83,81	75,61	68,55	78,83	79,44	76,01	78,63	76,83
P1	78,28	70,70	81,15	77,05	71,77	73,19	74,40	79,03	77,79	75,93
Pz	78,07	68,03	80,94	80,53	69,56	72,18	75,00	76,61	72,78	74,86
P2	77,25	67,00	79,10	80,74	70,56	77,82	75,60	81,65	75,60	76,15
POz	74,80	70,49	78,07	79,51	71,37	70,97	70,90	78,02	74,40	74,28
Ort.	78,26	70,11	80,94	76,19	69,56	75,72	75,71	76,50	77,66	---

Çizelge 5.10 ‘da, 9 kişiye ait 22 kanalın başarıları detaylı olarak gösterilmiştir. Kişiler bazında en yüksek başarı, 22 kanalın başarılarının ortalaması alınarak hesaplanmıştır ve 3. kişide %80,94 olarak elde edilmiştir. Bu kişiye en yakın başarı ise %78,26’ lık başarıyla 1. kişi olmuştur. Kişiler bazında en düşük başarı ise 5. kişide %69,56 olarak elde edilmiştir. Kanallar bazında en yüksek başarı, 9 kişiye ait başarıların ortalaması alınarak hesaplanmıştır ve CPz kanalında %77,11 olarak elde edilmiştir. Bu kanala en yakın başarı ise %77,01’ lik başarıyla CP2 kanalı olmuştur. Kanallar bazında en düşük başarı ise FC4 kanalında %74,14 olarak elde edilmiştir. SVM ve LSTM ile yapılan sınıflandırma sonuçlarına göre, derin öğrenme algoritması olan LSTM ağının, makine öğrenmesi algoritması olan SVM’ ye göre üstünlüğü görülmektedir.




Şekil 5.40. LSTM ve SVM’ nin DWT+Welch kullanarak elde edilen ortalama başarıları.

Şekil 5.40’ ta DWT+Welch yöntemiyle oluşturulan öz niteliklerin, LSTM ve SVM ile yapılan sınıflandırma sonucunda elde edilen ortalama test başarılarının karşılaştırılması gösterilmiştir. Toplamda 9 kişi için, LSTM ağı SVM’ ye göre daha başarılı sonuçlar vermiştir. Sınıflandırıcılar arasında başarı farkının en az olduğu kişi %6.02’ lik farkla 3.kişi, en fazla olduğu kişi ise %16.89 farkla 2.kişi olmuştur.




Şekil 5.41. LSTM ve SVM’ nin EMD+Welch kullanarak elde edilen ortalama başarıları.

Şekil 5.41’ de EMD+Welch yöntemiyle oluşturulan özniteliklerin, LSTM ve SVM ile yapılan sınıflandırma sonucunda elde edilen ortalama test başarılarının karşılaştırılması gösterilmiştir. Toplamda 9 kişi için, LSTM ağı SVM’ ye göre daha başarılı sonuçlar vermiştir. Sınıflandırıcılar arasında başarı farkının en az olduğu kişi %5.91’ lik farkla 3.kişi, en fazla olduğu kişi ise %16.47’ lik farkla 5.kişi olmuştur.



Şekil 5.42. LSTM ağının DWT+Welch ve EMD+Welch kullanarak elde edilen ortalama başarıları.

Şekil 5.42’ de DWT+Welch ve EMD+Welch yöntemiyle oluşturulan özniteliklerin, LSTM derin ağı ile yapılan sınıflandırma sonucunda elde edilen ortalama test başarılarının karşılaştırılması gösterilmiştir. S2, S3, S4 ve S7 kişlerinde DWT+Welch yöntemi daha başarılı sonuçlar vermiştir. S1, S5, S6, S8 ve S9 kişlerinde ise EMD+Welch yöntemi daha başarılı sonuçlar vermiştir. Her iki yöntem için 9 kişiye ait başarıların tekrardan ortalaması alındığında, DWT+Welch yönteminin nihai ortalama başarıları %85,50 olarak, EMD+Welch yönteminin ise %85,34 olarak elde edilmiştir.




Şekil 5.43. SVM modeli' nin DWT+Welch ve EMD+Welch kullanarak elde edilen ortalama başarıları.

Şekil 5.43' te DWT+Welch ve EMD+Welch yöntemiyle oluşturulan özneliklerin, SVM algoritması ile yapılan sınıflandırma sonucunda elde edilen ortalama test başarılarının karşılaştırılması gösterilmiştir. S1, S3, S4, S7, S8 ve S9 kişilerinde DWT+Welch yöntemi daha başarılı sonuçlar vermiştir. S2, S5 ve S6 kişilerinde ise EMD+Welch yöntemi daha başarılı sonuçlar vermiştir. Her iki yöntem için 9 kişiye ait başarıların tekrardan ortalaması alındığında, DWT+Welch yönteminin nihai ortalama başarıları %76,04 olarak, EMD+Welch yönteminin ise %75,63 olarak elde edilmiştir.

5.10. Hilbert Dönüşümüyle Anlık Fazların Hesaplanması


Bu tez çalışmasında, analitik sinyallerin anlık faz bilgisini kullanarak yeni bir öznelik çıkarma yöntemi sunulmuştur. Yöntemde, 3-6 sn aralığında tanımlı motor hayali sinyalleri 3-4, 4-5 ve 5-6 saniye aralıklarındaki alt dilimlere ayrılmıştır. Bu dilimlere Hilbert dönüşümü uygulanarak analitik sinyaller elde edilmiştir. Analik sinyaller aracılığıyla verilerin anlık faz değerleri hesaplanmıştır. Anlık faz matrisi üzerinde 22x22 boyutunda kare pencere gezdirilerek her pencereye ait özdeğerler hesaplanmıştır. Anlık fazlardan elde edilen özdeğerler ile bir öznelik vektörü oluşturulmuştur. Bu öznelik vektörleri, LSTM ve SVM sınıflandırıcıları ile eğitilmiştir.

Şekil 5.44’ te 3-4 saniye aralığı için özellik vektörünün elde edilmesinde yapılan işlem aşamaları gösterilmiştir.



Şekil 5.44. Anlık fazların özdeğerleriyle öznitelik vektörü oluşturulması.

EEG verilerinin örnekleme frekansı 250 hz olduğundan 3-4, 4-5 ve 5-6 saniye aralıklarında 250 adet veri bulunmaktadır. 22x250 boyutundaki ham EEG verilerine Hilbert dönüşümü uygulanarak her bir kanalın analitik sinyalleri elde edilmiştir. Analitik sinyal aracılığıyla kanalların anlık faz değerleri hesaplanmıştır ve 22x250 boyutunda anlık faz matrisi elde edilmiştir. Anlık faz matrisi üzerinde kare matris olacak şekilde 22x22 boyutlarında aşağı yönlü bir pencere gezdirilmiştir. Gezdirilen pencerenin noverlap parametresi 0’ dır. Her 22x22 boyutundaki kare matristen 22 adet özdeğer hesaplanmıştır. Elde edilen özdeğerlerin alt alta eklenmesiyle 242 elemanlı bir öznitelik vektörü oluşturulmuştur. Sonuç olarak, 22x250 boyutundaki ham EEG verileri, faz bilgisi tabanlı 242 elemanlı öznitelik vektörleriyle temsil edilmiştir. Ek olarak, 3-6 saniye aralığında benzer mantıkla aynı işlemler yapılmıştır. Toplamda 3 saniyelik dilim için 750 adet veri bulunmaktadır. 22x750 boyutundaki EEG verileri, faz bilgisi tabanlı 748 elemanlı öznitelik vektörleriyle temsil edilmiştir.



Şekil 5.45. Ham EEG sinyalleri ve anlık fazların özdeğerleri.

Şekil 5.45’ te 3-6 saniye aralığında tanımlı sol el, sağ el, ayak ve dil sınıfları için 22 kanallı ham EEG verileriyle birlikte, anlık fazlardan elde edilen özdeğerlerinin grafikleri verilmiştir. 22x750 boyutundaki EEG verileri, tek boyutlu 748 özdeğer ile temsil edilmiştir.

5.11. Hilbert-Huang Dönüşümüyle Anlık Fazların Hesaplanması

Bu yöntem ile önceki yöntem arasındaki tek fark, Huang ve arkadaşlarının bulduğu EMD algoritmasının uygulanmasıdır. Yöntemde, orijinal EEG verileri 3-4, 4-5 ve 5-6 saniyelik alt dilimlere ayrılmıştır. Her bir dilime ait ham EEG verilerine öncelikle EMD algoritması uygulanmıştır. Böylece 22 kanalın her birisi için IMF-1, IMF-2, IMF-3 ve IMF-4 sinyalleri elde

edilmiştir. 22 kanala ait aynı tipteki İMF' ler yan yana birleştirilerek orijinal EEG verileriyle aynı boyutta veriler elde edilmiştir. Yani 3-4, 4-5 ve 5-6 saniyelik dilimler için 22x250 boyutunda ve 3-6 saniye aralığı için 22x750 boyutunda aynı tipteki İMF' lerden oluşan sinyaller elde edilmiştir. Daha sonra bu verilere Hilbert dönüşümü uygulayarak her bir kanala ait analitik sinyaller elde edilmiştir. Analitik sinyaller aracılığıyla hesaplanan anlık faz matrisi üzerinde 22x22 boyutlarında kare pencere gezdirilmiştir. Her pencereden hesaplanan 22 adet özdeğerin alt alta eklenmesiyle öznitelik vektörleri oluşturulmuştur. Öznitelik vektörleri, birim zaman aralıklarında 248 ve 3-6 saniye aralığında ise 748 adet özdeğerden oluşmaktadır.



Şekil 5.46. 22 kanalın İMF-4 sinyalleri ve anlık fazların özdeğerleri.

Şekil 5.46' da 3-6 saniye aralığında tanımlı sol el, sağ el, ayak ve dil sınıflarına ait 22 kanallı ham EEG verilerine EMD algoritması uygulanarak elde edilen İMF-4 sinyalleriyle birlikte anlık fazlardan elde edilen özdeğerlerinin grafikleri verilmiştir. 22x750 boyutundaki EEG verileri, tek boyutlu 748 özdeğer ile temsil edilmiştir.

5.12. Faz Tabanlı Sınıflandırma İşlemleri

5.12.1. Kullanılan veri setinin dağılımı

Çizelge 5.11’ de Hilbert ve Hilbert-Huang dönüşümlerinde kullanılan veri seti, kişiler ve sınıflar bazında olmak üzere detaylı olarak verilmiştir.

Çizelge 5.11. LSTM ve SVM’ de kullanılan veri setinin miktarları.

Kişiler	Sınıf				Sınıflandırıcı				
	Sol El	Sağ El	Ayak	Dil	LSTM			SVM	
					Eğitim	Val.	Test	Eğitim	Test
S1	411	411	411	411	984	328	328	984	656
S2	411	411	411	411	984	328	328	984	656
S3	411	411	411	411	984	328	328	984	656
S4	411	411	411	411	984	328	328	984	656
S5	411	411	411	411	984	328	328	984	656
S6	411	411	411	411	984	328	328	984	656
S7	411	411	411	411	984	328	328	984	656
S8	411	411	411	411	984	328	328	984	656
S9	411	411	411	411	984	328	328	984	656

Derin öğrenme algoritmalarının öğrenme stratejilerinde, eğitimleri için çok sayıda örnek gerektiğinden, elde edilen öznitelik vektörleri %90 ve %10 faktörleriyle çarpılmıştır. Böylece, öznitelik vektörlerinin sayıları üç kat artırılmıştır (Lashgari vd., 2020; Sakai vd., 2017). Bu yöntemlerde, mevcut 22 kanalın etkisi aynı anda ele alınmıştır. Tüm sınıflara ait veriler, 411 adet öznitelik vektöründen oluşmaktadır. Bu öznitelik vektörleri, anlık fazlardan pencere yöntemiyle elde edilen özdeğerlerden oluşmaktadır. Her bir öznitelik vektörü 3-4, 4-5 ve 5-6 saniyelik dilimler için 242 elemanlı olup, 3-6 saniye aralığı için 748 elemanlıdır. Bir kişiye ait sol el, sağ el, ayak ve dil sınıfları için toplamda 1644 adet öznitelik vektörü mevcuttur. LSTM derin ağında, bu öznitelik vektörlerinin %60’ lık kısmı eğitim, %20’ lik kısmı validation ve diğer %20’ lik kısmı test için kullanılmıştır. SVM modelinde ise, veri setinin %60’ ı eğitim ve %40’ ı test için ayrılmıştır. 2 sınıflandırıcının doğru bir şekilde kıyaslanabilmesi için, LSTM ve SVM sınıflandırıcılarında aynı eğitim seti kullanılmıştır. Ayrıca, LSTM ağının %20’ lik test ve %20’ lik validation veri setleri birleştirilerek SVM sınıflandırıcısının test seti için kullanılmıştır.

5.12.2. LSTM ağında kullanılan parametreler


Çizelge 5.12’ de LSTM derin ağında kullanılan ve önemli sayılabilecek parametreler verilmiştir.

Çizelge 5.12. LSTM derin ağında kullanılan eğitim parametreleri.

LSTM Parametreleri		Sayı
Layers	Fully Connected Layer	4
	Softmax Layer	1
	Hidden Layer	100
Options	Max Epochs	100
	Mini Batch Size	64
	Learning Rate	0.005
	Validation Freq.	50

Epochs sayısı olarak 100 seçilmiştir ve LSTM derin ağı eğitim boyunca 1500 iterasyon yapmıştır. MiniBatchSize parametresi olarak 64 girilmiştir ve her epoch’ ta veri setinden alınan 64 adet öznitelik vektörüyle eğitim yapılmıştır. Öğrenme oranı 0.005 girilmiştir. Validation frequency olarak 50 değeri seçilmiştir. Böylece eğitim boyunca her 50 iterasyon’ da bir LSTM ağının kendi içerisinde öğrendiklerini test etmesi sağlanmıştır.


5.12.3. Faz özelliklerini kullanarak LSTM ağının eğitilmesi



Şekil 5.47. 4-5 sn aralığında Hilbert dönüşümü kullanarak LSTM ağının eğitilmesi.


Şekil 5.47’ de, 4-5 saniye aralığındaki EEG verilerine Hilbert dönüşümü uygulanarak oluşturulan faz bilgisi tabanlı özniteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde

edilen eğitim ve validation başarılarının grafikleri verilmiştir. Eğitim sonucunda LSTM ağının validation başarıları %88,11' dir.




Şekil 5.48. 3-6 sn aralığında Hilbert dönüşümü kullanarak LSTM ağının eğitilmesi.

Şekil 5.48' de, 3-6 saniye aralığındaki EEG verilerine Hilbert dönüşümü uygulanarak oluşturulan faz bilgisi tabanlı özniteliklerin, LSTM derin ağıyla sınıflandırılması sonucunda elde edilen eğitim ve validation başarılarının grafikleri verilmiştir. Eğitim sonucunda LSTM ağının validation başarıları %85,67' dir.



Şekil 5.49. 4-5 sn aralığında Hilbert-Huang dönüşümü kullanarak LSTM ağının eğitilmesi.


Şekil 5.49' da, 4-5 sn aralığındaki EEG verilerine Hilbert-Huang dönüşümü uygulanarak elde edilen öznitelikler ile eğitilen LSTM ağının eğitim ve validation grafikleri verilmiştir. Şekildeki eğitimde, İMF-4 sinyallerinin anlık fazlarından elde edilen özdeğerlerin oluşturduğu öznitelik vektörleri kullanılmıştır. Eğitim sonucunda LSTM ağının validation başarıları %88,72' dir.



Şekil 5.50. 3-6 sn aralığında Hilbert-Huang dönüşümü kullanarak LSTM ağının eğitilmesi.


Şekil 5.50’ de, 3-6 sn aralığındaki EEG verilerine Hilbert-Huang dönüşümü uygulanarak elde edilen öznitelikler ile eğitilen LSTM ağının eğitim ve validation grafikleri verilmiştir. Şekildeki eğitimde, İMF-4 sinyallerinin anlık fazlarından elde edilen özdeğerlerin oluşturduğu öznitelik vektörleri kullanılmıştır. Eğitim sonucunda LSTM ağının validation başarısı %87,5’ tir. Hilbert-Huang dönüşümüyle elde edilen bu grafikler, Hilbert dönüşümüyle elde edilen grafiklerle karşılaştırıldığında, verileri öncesinde İMF’ lerine ayırıp ardından özellik çıkararak yapılan sınıflandırmanın daha başarılı olduğu görülmüştür.

5.12.4. Faz tabanlı sınıflandırma sonuçları




Şekil 5.51. EMD’ siz 3-4 sn aralığındaki ortalama test başarıları.

Şekil 5.51’ de, kişiler bazında ve 3-4 sn aralığındaki ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanmadan elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 6. kişide %91,77 olarak, SVM algoritmasının en yüksek başarısı ise 8. kişide %87,5 olarak elde edilmiştir.




Şekil 5.52. EMD’ siz 4-5 sn aralığındaki ortalama test başarıları.

Şekil 5.52’ de, kişiler bazında ve 4-5 sn aralığındaki ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanmadan elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 4. kişide %92,38 olarak, SVM algoritmasının en yüksek başarısı ise 1. kişide %84,76 olarak elde edilmiştir.




Şekil 5.53. EMD’ siz 5-6 sn aralığındaki ortalama test başarıları.

Şekil 5.53’ te, kişiler bazında ve 5-6 sn aralığındaki ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanmadan elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 9. kişide %90,55 olarak, SVM algoritmasının en yüksek başarısı ise 6. kişide %85,52 olarak elde edilmiştir.




Şekil 5.54. EMD’ siz 3-6 sn aralığındaki ortalama test başarıları.

Şekil 5.54’ te, kişiler bazında ve 3-6 sn aralığındaki ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanmadan elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 2. kişide %91,16 olarak, SVM algoritmasının en yüksek başarısı ise 8. kişide %89,18 olarak elde edilmiştir.




Şekil 5.55. EMD’ li 3-4 sn aralığında ve İMF-1’ den elde edilen ortalama test başarıları.

Şekil 5.55’ te, kişiler bazında, 3-4 sn aralığında ve İMF-1’ den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 9. kişide %91,77 olarak, SVM algoritmasının en yüksek başarısı ise yine 9. kişide %86,55 olarak elde edilmiştir.




Şekil 5.56. EMD’ li 3-4 sn aralığında ve İMF-2’ den elde edilen ortalama test başarıları.

Şekil 5.56’ da, kişiler bazında, 3-4 sn aralığında ve İMF-2’ den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 8. kişide %91,46 olarak, SVM algoritmasının en yüksek başarısı ise 6. kişide %84,91 olarak elde edilmiştir.



Şekil 5.57. EMD' li 3-4 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.


Şekil 5.57' de, kişiler bazında, 3-4 sn aralığında ve İMF-3' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 2. kişide %91,46 olarak, SVM algoritmasının en yüksek başarısı ise yine 2. kişide %86,43 olarak elde edilmiştir.



Şekil 5.58. EMD' li 3-4 sn aralığında ve İMF-4' ten elde edilen ortalama test başarıları.


Şekil 5.58' de, kişiler bazında, 3-4 sn aralığında ve İMF-4' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak

elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 6. kişide %90,85 olarak, SVM algoritmasının en yüksek başarısı ise 2. kişide %86,43 olarak elde edilmiştir.




Şekil 5.59. EMD' li 4-5 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.

Şekil 5.59' da, kişiler bazında, 4-5 sn aralığında ve İMF-1' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 8. kişide %89,02 olarak, SVM algoritmasının en yüksek başarısı ise 3. kişide %85,52 olarak elde edilmiştir.




Şekil 5.60. EMD' li 4-5 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.

Şekil 5.60' ta, kişiler bazında, 4-5 sn aralığında ve İMF-2' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 5. kişide %89,63 olarak, SVM algoritmasının en yüksek başarısı ise 6. kişide %85,82 olarak elde edilmiştir.




Şekil 5.61. EMD' li 4-5 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.

Şekil 5.61' de, kişiler bazında, 4-5 sn aralığında ve İMF-3' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 1. kişide %90,85 olarak, SVM algoritmasının en yüksek başarısı ise yine 1. kişide %87,20 olarak elde edilmiştir.



Şekil 5.62. EMD' li 4-5 sn aralığında ve İMF-4' ten elde edilen ortalama test başarıları.


Şekil 5.62' de, kişiler bazında, 4-5 sn aralığında ve İMF-4' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 2. kişide %92,38 olarak, SVM algoritmasının en yüksek başarısı ise yine 2. kişide %84,76 olarak elde edilmiştir.



Şekil 5.63. EMD' li 5-6 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.


Şekil 5.63' te, kişiler bazında, 5-6 sn aralığında ve İMF-1' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM

ağının en yüksek başarısı 4. kişide %90,55 olarak, SVM algoritmasının en yüksek başarısı ise 1. kişide %86,43 olarak elde edilmiştir.




Şekil 5.64. EMD' li 5-6 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.

Şekil 5.64' te, kişiler bazında, 5-6 sn aralığında ve İMF-2' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 2. kişide %90,85 olarak, SVM algoritmasının en yüksek başarısı ise 9. kişide %86,13 olarak elde edilmiştir.




Şekil 5.65. EMD' li 5-6 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.

Şekil 5.65’ te, kişiler bazında, 5-6 sn aralığında ve İMF-3’ ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 4. kişide %90,24 olarak, SVM algoritmasının en yüksek başarısı ise yine 4. kişide %85,98 olarak elde edilmiştir.




Şekil 5.66. EMD’ li 5-6 sn aralığında ve İMF-4’ ten elde edilen ortalama test başarıları.

Şekil 5.66’ da, kişiler bazında, 5-6 sn aralığında ve İMF-4’ ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM’ ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 9. kişide %91,16 olarak, SVM algoritmasının en yüksek başarısı ise 4. kişide %85,82 olarak elde edilmiştir.



Şekil 5.67. EMD' li 3-6 sn aralığında ve İMF-1' den elde edilen ortalama test başarıları.


Şekil 5.67' de, kişiler bazında, 3-6 sn aralığında ve İMF-1' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 4. kişide %91,46 olarak, SVM algoritmasının en yüksek başarısı ise 3. kişide %89,79 olarak elde edilmiştir.



Şekil 5.68. EMD' li 3-6 sn aralığında ve İMF-2' den elde edilen ortalama test başarıları.


Şekil 5.68' de, kişiler bazında, 3-6 sn aralığında ve İMF-2' den hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM

ağının en yüksek başarısı 1. kişide %92,68 olarak, SVM algoritmasının en yüksek başarısı ise yine 1. kişide %88,96 olarak elde edilmiştir.



Şekil 5.69. EMD' li 3-6 sn aralığında ve İMF-3' ten elde edilen ortalama test başarıları.

Şekil 5.69' da, kişiler bazında, 3-6 sn aralığında ve İMF-3' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 8. kişide %91,46 olarak, SVM algoritmasının en yüksek başarısı ise yine 8. kişide %89,63 olarak elde edilmiştir.



Şekil 5.70. EMD' li 3-6 sn aralığında ve İMF-4' den elde edilen ortalama test başarıları.

Şekil 5.70' te, kişiler bazında, 3-6 sn aralığında ve İMF-4' ten hesaplanan anlık fazların özdeğerlerini kullanarak elde edilen ortalama sınıflandırıcı başarıları verilmiştir. EMD kullanarak elde edilen bu sonuçlara göre LSTM derin ağının SVM' ye göre üstünlüğü görülmektedir. LSTM ağının en yüksek başarısı 2. kişide %91,16 olarak, SVM algoritmasının en yüksek başarısı ise 3. kişide %88,67 olarak elde edilmiştir.

22 kanala ait ham EEG verilerine direkt olarak Hilbert dönüşümü uygulandığındaki durum Çizelge 5.13' te verilmiştir.

Çizelge 5.13. EMD' siz farklı zaman aralıkları için hesaplanan LSTM ve SVM test başarıları.

Kişiler	EMD Kullanmadan LSTM ve SVM Sınıflandırıcılarının Test Başarıları							
	3-4 sn		4-5 sn		5-6 sn		3-6 sn	
	LSTM	SVM	LSTM	SVM	LSTM	SVM	LSTM	SVM
S1	90,24	82,32	91,46	84,76	88,72	84,15	87,80	85,98
S2	90,18	81,55	88,11	78,20	88,41	77,44	91,16	81,25
S3	90,85	87,35	88,72	83,38	87,50	84,00	89,94	87,50
S4	89,94	82,47	92,38	84,15	90,24	83,69	87,20	87,50
S5	86,89	80,95	86,89	80,49	85,06	81,71	88,41	86,89
S6	91,77	83,23	91,16	82,47	89,02	85,52	88,11	84,15
S7	89,02	85,37	88,05	80,79	89,33	82,62	89,33	88,57
S8	89,85	87,50	89,33	81,10	89,25	83,95	90,55	89,18
S9	90,76	85,21	90,55	81,55	90,55	83,54	86,89	89,02
Ort.	89,94	83,99	89,63	81,88	88,68	82,96	88,82	86,67

Çizelge 5.13' te, LSTM derin ağının SVM algoritmasına göre her bir zaman aralığındaki başarı üstünlüğü görülmektedir. En yüksek ortalama sınıflandırma başarısı 3-4 saniye diliminde LSTM' e ait ve %89,94 olarak elde edilmiştir. En düşük ortalama başarı değeri ise ait 4-5 saniye diliminde SVM' ye ait ve %81,88 olarak elde edilmiştir. Ayrıca birim zaman aralıklarında LSTM ve SVM başarıları arasındaki fark fazla olup, tüm motor hayali verilerini kapsayan 3-6 saniye aralığında ise fark daha azdır. Kişiler bazında en yüksek başarı S4 kişinin 4-5 sn.lık EEG diliminden ve LSTM ile %92.38 olarak elde edilmiştir. En düşük başarı S2 kişinin 5-6 sn.lık EEG diliminden ve SVM sınıflandırıcı ile %77.44 olarak elde edilmiştir.

22 kanala ait birim zaman aralıklarındaki ham EEG verilerine öncesinde EMD, daha sonra Hilbert dönüşümü uygulanarak LSTM ile sınıflandırılmıştır. Elde edilen sınıflandırma başarıları her bir zaman aralığı ve her bir İMF için Çizelge 5.14' te verilmiştir.

Çizelge 5.14. EMD' li birim zaman aralıkları için hesaplanan LSTM test başarıları.

Kişiler	EMD Kullanarak LSTM ve SVM Sınıflandırıcılarının Test Başarıları											
	3-4 sn				4-5 sn				5-6 sn			
	İMF1	İMF2	İMF3	İMF4	İMF1	İMF2	İMF3	İMF4	İMF1	İMF2	İMF3	İMF4
S1	85,98	85,98	86,89	89,63	85,37	85,06	90,85	92,07	89,63	90,55	88,41	89,94
S2	88,41	88,41	91,46	90,55	88,41	86,89	90,55	92,38	88,41	90,85	86,59	87,80
S3	89,63	86,89	87,80	86,89	87,80	84,45	88,41	87,80	87,80	88,72	88,35	88,41
S4	89,02	90,24	88,72	88,72	84,15	86,85	89,63	88,72	90,55	90,80	90,24	88,35
S5	81,10	87,80	87,76	86,59	86,28	89,63	86,60	84,76	85,67	87,80	85,37	84,45
S6	85,67	79,88	89,63	90,85	83,23	85,98	88,72	90,24	81,71	84,15	86,28	88,11
S7	86,59	91,16	87,70	88,11	81,10	86,28	87,50	90,20	87,20	89,33	88,38	86,59
S8	90,24	91,46	85,98	89,33	89,02	87,80	86,55	89,63	85,98	84,45	87,80	89,94
S9	91,77	85,06	88,41	87,80	88,41	86,59	87,50	89,02	86,28	88,11	87,75	91,16
Ort.	87,60	87,43	88,26	88,72	85,97	86,61	88,48	89,42	87,03	88,31	87,69	88,31

Çizelge 5.14' te, LSTM ağının en yüksek sınıflandırma başarıları İMF-4' e ait ve 4-5 saniye diliminde %89,42 olarak elde edilmiştir. En düşük başarı değeri ise İMF-1' e ait ve 4-5 saniye diliminde %85,97 olarak elde edilmiştir. 22 kanala ait birim zaman aralıklarındaki ham EEG verilerine öncesinde EMD, daha sonra Hilbert dönüşümü uygulanarak SVM ile sınıflandırılmıştır. Elde edilen sınıflandırma başarıları her bir zaman aralığı ve her bir İMF için Çizelge 5.15' te verilmiştir.

Çizelge 5.15. EMD' li birim zaman aralıkları için hesaplanan SVM test başarıları.

Kişiler	EMD Kullanarak SVM Test Başarıları											
	3-4 sn				4-5 sn				5-6 sn			
	İMF1	İMF2	İMF3	İMF4	İMF1	İMF2	İMF3	İMF4	İMF1	İMF2	İMF3	İMF4
S1	82,16	84,30	80,34	83,69	79,88	84,76	87,20	81,55	86,43	84,60	80,18	82,93
S2	82,93	81,25	86,43	86,43	78,96	80,95	82,47	84,76	81,25	82,62	84,15	82,62
S3	85,98	83,38	80,49	83,69	85,52	82,77	82,40	84,60	81,66	84,12	83,54	84,15
S4	82,62	82,62	84,15	83,65	81,25	81,71	81,25	82,32	82,32	84,55	85,98	85,82
S5	82,16	83,84	86,13	82,32	82,77	82,47	80,64	84,60	81,69	84,58	82,32	80,49
S6	80,64	84,91	84,60	83,60	82,47	85,82	79,73	80,95	80,49	83,84	83,69	82,32
S7	81,08	81,86	80,34	85,52	83,23	81,55	80,03	82,32	84,30	83,69	82,47	84,00
S8	83,38	84,60	83,54	82,16	83,38	84,30	83,08	82,27	83,84	82,93	83,50	83,69
S9	86,55	82,62	82,47	78,66	83,30	85,52	84,91	83,69	84,76	86,13	84,00	82,01
Ort.	83,06	83,26	83,17	83,30	82,31	83,32	82,41	83,01	82,97	84,12	83,31	83,11

Çizelge 5.15’ te, SVM modelinin en yüksek sınıflandırma başarısı İMF-2’ e ait ve 5-6 saniye diliminde %84,12 olarak elde edilmiştir. En düşük başarı değeri ise İMF-1’ e ait ve 4-5 saniye diliminde %82,31 olarak elde edilmiştir.

22 kanala ait 3-6 saniye aralığındaki ham EEG verilerine öncesinde EMD, daha sonra Hilbert dönüşümü uygulanarak LSTM ve SVM ile sınıflandırılmıştır. Elde edilen sınıflandırma her bir İMF için Çizelge 5.16’ da verilmiştir.

Çizelge 5.16. EMD’ li 3-6 sn aralığı için hesaplanan LSTM ve SVM test başarıları.

EMD Kullanarak 3-6 sn Aralığındaki LSTM ve SVM Test Başarıları								
Kişiler	LSTM				SVM			
	İMF1	İMF2	İMF3	İMF4	İMF1	İMF2	İMF3	İMF4
S1	90,24	92,68	90,55	89,63	84,76	88,96	87,65	86,59
S2	89,02	91,46	90,50	91,16	86,74	85,37	83,23	86,55
S3	88,72	89,02	90,24	90,55	89,79	87,50	86,13	88,67
S4	91,46	88,11	90,85	90,85	85,37	86,89	85,52	87,35
S5	91,36	87,20	88,41	88,11	87,04	86,28	87,96	85,06
S6	88,95	89,00	87,50	88,72	84,60	87,50	84,60	87,20
S7	82,01	80,18	90,80	87,50	87,65	86,59	85,98	85,52
S8	89,63	88,04	91,46	88,65	85,67	86,20	89,63	87,96
S9	88,41	88,41	88,72	88,70	89,63	86,13	87,65	86,13
Ort.	88,87	88,23	89,89	89,32	86,81	86,82	86,48	86,78

Verilen Çizelgede, LSTM derin ağının en yüksek sınıflandırma başarısı İMF-3 ile birlikte %89,89 olarak elde edilmiştir. SVM modelinin en yüksek sınıflandırma başarısı ise İMF-2 ile birlikte %86,82 olarak elde edilmiştir.

5.13. PSD ve Faz Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması

3-6 sn aralığını kapsayan motor hayali verilerine PSD ve faz bilgilerini içeren özellik çıkarma yöntemleri uygulanmış ve SVM modeliyle sınıflandırılmıştır. Elde edilen sınıflandırma başarıları Çizelge 5.17’ de verilmiştir.

Çizelge 5.17. SVM’ nin PSD ve faz tabanlı özellikler ile elde edilen sınıflandırma başarıları.

Kişiler	Yöntem			
	PSD Tabanlı		Faz Tabanlı	
	DWT+Welch	EMD+Welch+S	HT+SVM	HHT+SVM
S1	78,69	78,26	85,98	88,96
S2	69,01	70,11	81,25	85,37
S3	81,35	80,94	87,5	87,50
S4	77,12	76,19	87,5	86,89
S5	69,33	69,56	86,89	86,28
S6	73,54	75,72	84,15	87,50
S7	76,61	75,71	88,57	86,59
S8	79,51	76,5	89,18	86,20
S9	79,23	77,66	89,02	86,13
Ort.	76,04	75,63	86,67	86,82

Çizelge 5.17’ deki sonuçlara göre, analitik sinyallerin anlık fazlarından pencereleme yöntemiyle elde edilen özdeğerleri kullanarak yapılan sınıflandırmanın, PSD tabanlı öznelilikler ile yapılan sınıflandırmaya göre daha başarılı olduğu görülmüştür. 3-6 sn aralığını kapsayan motor hayali verilerine PSD ve faz bilgilerini içeren özellik çıkarma yöntemleri uygulanmış ve LSTM derin ağıyla sınıflandırılmıştır. Elde edilen sınıflandırma başarıları Çizelge 5.18’ de verilmiştir.

Çizelge 5.18. LSTM ağıının PSD ve faz tabanlı özellikler ile elde edilen sınıflandırma başarıları.

Kişiler	Yöntem			
	PSD Tabanlı		Faz Tabanlı	
	DWT+Welch +LSTM	EMD+Welch +LSTM	HT+LSTM	HHT+LSTM
S1	85,40	86,15	87,80	90,55
S2	85,90	85,45	91,16	90,50
S3	87,37	86,85	89,94	90,24
S4	86,14	82,62	87,2	90,85
S5	84,33	86,03	88,41	88,41
S6	83,22	84,71	88,11	87,50
S7	84,86	84,22	89,33	90,80
S8	86,12	86,38	90,55	91,46
S9	86,05	86,47	86,89	88,72
Ort.	85,50	85,34	88,82	89,89

Çizelge 5.18’ deki sonuçlara göre, analitik sinyallerin anlık fazlarından pencereleme yöntemiyle elde edilen özdeğerleri kullanarak yapılan sınıflandırmanın, PSD tabanlı öznelilikler ile yapılan sınıflandırmaya göre daha başarılı olduğu görülmüştür. Ek olarak, LSTM derin ağı, her iki durumda da SVM algoritmasına göre daha yüksek başarı sonuçları vermiştir.

5.14. Önerilen Yöntem ve Literatürdeki Bazı Yöntemlerin Sınıflandırma Sonuçları

Literatürdeki bazı çalışmalarda, BCI-Competition Dataset IV-2a veri setine farklı özellik çıkarma yöntemleri uygulanmış ve elde edilen bu özellikler, farklı sınıflandırma yöntemleriyle sınıflandırılmıştır. Elde edilen sınıflandırma başarıları Çizelge 5.19’ da gösterilmiştir.

Çizelge 5.19. Önerilen yöntem ve literatürdeki bazı yöntemlerin sınıflandırma başarıları.

Özellik Çıkarma	Sınıflandırma	Doğruluk (%)									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	Ort.
PCA (Wang vd. 2012)	SVM	71.43	67.50	64.29	57.50	87.86	58.93	85.71	79.29	73.93	71.83
FBCSP+HT (Sakhavi vd. 2018)	CNN	87.50	65.28	90.28	66.67	62.50	45.49	89.58	83.33	79.51	74.46
CSP (Selim vd. 2018)	AM-BA-SVM	90.56	66.32	91.99	70.28	68.53	55.75	90.63	87.80	85.07	78.55
SVD (Yu ve Song 2017)	DBM	90.80	79.50	81.40	80.50	84.60	72.20	81.50	69.10	83.80	80.38
WT+RME (Rahman vd. 2020)	RF	82.00	86.00	84.00	78.00	79.00	86.00	75.00	80.00	75.00	80.55
DWT (Kumar ve Inbarani, 2017)	NRSC	90.04	73.30	92.50	82.72	71.68	64.98	85.01	86.74	81.90	80.99
FBCSP+MIBIF (Razi vd. 2019)	LDA	83.33	69.09	88.89	89.17	75.00	68.06	85.42	89.24	90.97	82.13
WT (Xu vd. 2018)	CNN	85.71	78.57	92.15	95.67	89.20	85.12	79.23	81.28	80.67	85.59
HHT (önerilen yöntem)	LSTM	90,55	90,50	90,24	90,85	88,41	87,50	90,80	91,46	88,72	89,89

Wang D. vd., PCA yöntemini EEG sinyallerinden özellik çıkarmak için kullanmışlardır. Çıkardıkları özellikleri SVM algoritması kullanarak sınıflandırmışlardır. Sonuç olarak, ortalama %71.83 başarı elde etmişlerdir. Sakhavi S. vd., FBCSP kullanarak band güçlerinden elde ettikleri değerleri, CNN derin öğrenme modeliyle sınıflandırarak ortalama %74.46 başarı elde etmişlerdir. Selim S. vd., özellik çıkarma yöntemi olarak CSP kullanıp, AM-BA-SVM modeliyle sınıflandırarak ortalama %78.55 başarıya ulaşmışlardır. Yu Z. vd., SVD ile birlikte DBM kullanarak ortalama %80.38 başarı elde edilmiştir. Rahman M. vd., WPT+RME kullanarak çıkardıkları özellikleri, RF sınıflandırma algoritmasına uygulamışlar ve ortalama %80.56 başarı elde etmişlerdir. Kumar S. vd., DWT ve NRSC kullanarak ortalama %80.99 başarı elde

etmişlerdir. Razi S. vd., FBCSP+MIBIF kullanarak elde ettiği öznitelikleri LDA ile sınıflandırarak ortalama %82.13 başarı elde etmişlerdir.

Xu B. vd., WT kullanarak elde ettikleri scalogram görüntülerini 2D-CNN ile sınıflandırarak ortalama %85.59 başarı elde etmişlerdir. Önerilen yöntemde, HHT ile elde edilen faz tabanlı özniteliklerin LSTM derin ağı ile sınıflandırılması yapılmıştır. Sınıflandırma sonucunda 9 kişi için ortalama %89,89 başarıya ulaşılmıştır. Önerilen yönteme en yakın çalışma, Dalgacık dönüşümü ile özniteliklerin çıkarılarak CNN derin öğrenme algoritması ile sınıflandırıldığında %85.59 olarak elde edilmiştir.



6. SONUÇ VE ÖNERİLER

Son yıllarda, sinyal sınıflandırma alanında derin öğrenme algoritmalarına ilgi artmıştır. EEG gibi periyodik olmayan sinyallerin sınıflandırılmasında 1D-CNN, 2D-CNN ve LSTM gibi popüler derin öğrenme algoritmaları kullanılmıştır. Literatürdeki motor hayali sinyallerinin sınıflandırılmasıyla ilgili yapılan çalışmalarda, derin öğrenme algoritmalarının klasik makine öğrenmesi yöntemlerinden daha başarılı oldukları görülmüştür. Ayrıca çok fazla eğitim verisinin olduğu durumlarda, klasik makine öğrenmesi yöntemleriyle yapılan eğitimin süresi oldukça uzundur ve hesaplama verimliliği düşüktür. Derin öğrenme algoritmalarının öğrenme stratejilerinde ise çok fazla eğitim verisi bulunması gerekir. Derin öğrenme algoritmaları, eğitimleri boyunca ne kadar çok fazla veriyle eğitilirse elde edilen sınıflandırma başarıları da o derece yüksek olur.

Bir BBA sisteminin anlık tepkilere net cevaplar verebilmesi çok fazla veriyle yapılan iyi bir eğitim sürecine bağlıdır. Bu sebeple, herhangi bir BBA sisteminde uygulanabilirlik açısından derin öğrenme algoritmaları kullanmak daha doğrudur. Ayrıca, yapılan çalışmalarda 4' lü motor hayali sinyallerinden özellik çıkarmada kullanılan yöntemlerin, sinyallerin band aralıklarındaki gücü veya enerjisiyle ilgili olduğu görülmektedir. Motor hayali sinyallerinin sınıflandırılmasında, sinyallerin faz bilgisiyle ilgili öznitelikler üzerinde yapılan çalışmalar sınırlı sayılardadır. Bu tez çalışmasında kullanılan faz tabanlı öznitelikler ile elde edilen ortalama başarı, önerilen yöntemin diğer yöntemlerden üstünlüğünü göstermektedir.

KAYNAKLAR DİZİNİ

- Aghayousefi, R., Delrobaei, M. Artifact Rejection from EEG Signals–A Tutorial.
- Alhagry, S., Fahmy, A. A., El-Khoribi, R. A. (2017). Emotion recognition based on EEG using LSTM recurrent neural network. *Emotion*, 8 (10), 355-358.
- Alkan, A., Kiymik, M. K. (2006). Comparison of AR and Welch methods in epileptic seizure detection. *Journal of Medical Systems*, 30 (6), 413-419.
- Álvarez-Meza, A. M., Velásquez-Martínez, L. F., Castellanos-Dominguez, G. (2015). Time-series discrimination using feature relevance analysis in motor imagery classification. *Neurocomputing*, 151, 122-129.
- Amin, S. U., Alsulaiman, M., Muhammad, G., Bencherif, M. A., Hossain, M. S. (2019a). Multilevel weighted feature fusion using convolutional neural networks for EEG motor imagery classification. *IEEE Access*, 7, 18940-18950.
- Amin, S. U., Alsulaiman, M., Muhammad, G., Mekhtiche, M. A., Hossain, M. S. (2019b). Deep Learning for EEG motor imagery classification based on multi-layer CNNs feature fusion. *Future Generation computer systems*, 101, 542-554.
- Amiri, S., Fazel-Rezai, R., Asadpour, V. (2013). A review of hybrid brain-computer interface systems. *Advances in Human-Computer Interaction*, 2013.
- Astolfi, L., Cichocki, A., Babiloni, F. (2009). NeuroMath: advanced methods for the estimation of human brain activity and connectivity.
- Ayhan, S., Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9 (1), 175-201.
- Bentlemsan, M., Zemouri, E. T., Bouchaffra, D., Yahya-Zoubir, B., Ferroudji, K. (2014, January). Random forest and filter bank common spatial patterns for EEG-based motor imagery classification. In *2014 5th International conference on intelligent systems, modelling and simulation* (s. 235-238). IEEE.
- Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., Pfurtscheller, G. (2008). BCI Competition 2008–Graz data set A. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology*, 16.
- Chen, D., Wan, S., Xiang, J., Bao, F. S. (2017). A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. *PloS one*, 12 (3), e0173138.
- Chu, Y., Zhao, X., Zou, Y., Xu, W., Han, J., Zhao, Y. (2018). A decoding scheme for incomplete motor imagery EEG with deep belief network. *Frontiers in neuroscience*, 12, 680.
- Coenen, A., Zayachkivska, O. (2013). Adolf Beck: A pioneer in electroencephalography in between Richard Caton and Hans Berger. *Advances in cognitive psychology*, 9 (4), 216.

KAYNAKLAR DİZİNİ (devam)

- Dai, M., Zheng, D., Na, R., Wang, S., Zhang, S. (2019). EEG classification of motor imagery using a novel deep learning framework. *Sensors*, 19 (3), 551.
- Djemal, R., Bazyed, A. G., Belwafi, K., Gannouni, S., Kaaniche, W. (2016). Three-class EEG-based motor imagery classification using phase-space reconstruction technique. *Brain sciences*, 6 (3), 36.
- Duan, L., Bao, M., Cui, S., Qiao, Y., Miao, J. (2017). Motor imagery EEG classification based on kernel hierarchical extreme learning machine. *Cognitive Computation*, 9 (6), 758-765.
- Duan, L., Ge, H., Ma, W., Miao, J. (2015). EEG feature selection method based on decision tree. *Bio-medical materials and engineering*, 26 (s1), S1019-S1025.
- Duman, F. Y., Telatar, Z. T. D., Eroğul, O. T. D. (2005). *EEG sinyallerinin analizi ile uyku durumunun belirlenmesi* (Doctoral dissertation, Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı).
- Duman, M. E. (2016). *Sınıf İçi ve Sınıflar Arası Saçılmaya Duyarlı Ortak Uzamsal Örüntüler İle Motor Hareket Hayalinin Tanınması* (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Fazel-Rezai, R., Allison, B. Z., Guger, C., Sellers, E. W., Kleih, S. C., Kübler, A. (2012). P300 brain computer interface: current challenges and emerging trends. *Frontiers in neuroengineering*, 5, 14.
- Feldman, M. (2011). Hilbert transform in vibration analysis. *Mechanical systems and signal processing*, 25 (3), 735-802.
- Gaur, P., Pachori, R. B., Wang, H., Prasad, G. (2018). A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry. *Expert Systems with Applications*, 95, 201-211.
- Ge, S., Wang, R., Yu, D. (2014). Classification of four-class motor imagery employing single-channel electroencephalography. *PloS one*, 9 (6), e98019.
- Hu, D., Li, W., Chen, X. (2011, May). Feature extraction of motor imagery EEG signals based on wavelet packet decomposition. In *The 2011 IEEE/ICME International Conference on Complex Medical Engineering* (s. 694-697). IEEE.
- Huang, N. E. (2014). Introduction to the Hilbert–Huang transform and its related mathematical problems. In *Hilbert–Huang transform and its applications* (s. 1-26).
- Jeon, Y., Nam, C. S., Kim, Y. J., Whang, M. C. (2011). Event-related (De) synchronization (ERD/ERS) during motor imagery tasks: Implications for brain–computer interfaces. *International Journal of Industrial Ergonomics*, 41 (5), 428-436.

KAYNAKLAR DİZİNİ (devam)

- Jirayucharoensak, S., S. Pan-Ngum ve P. Israsena, (2014). "EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation," *The Scientific World Journal*, C. s. 10.
- Kam, T. E., Suk, H. I., Lee, S. W. (2013). Non-homogeneous spatial filter optimization for Electroencephalogram (EEG)-based motor imagery classification. *Neurocomputing*, 108, 58-68.
- Kavzoğlu, T., Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144 (7), 73-82.
- Kevric, J., Subasi, A. (2017). Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. *Biomedical Signal Processing and Control*, 31, 398-406.
- Kim, C., Sun, J., Liu, D., Wang, Q., Paek, S. (2018). An effective feature extraction method by power spectral density of EEG signal for 2-class motor imagery-based BCI. *Medical biological engineering computing*, 56 (9), 1645-1658.
- Kumar, S. U., Inbarani, H. H. (2017). PSO-based feature selection and neighborhood rough set-based classification for BCI multiclass motor imagery task. *Neural Computing and Applications*, 28 (11), 3239-3258.
- Kumar, S., Sharma, A., Mamun, K., Tsunoda, T. (2016, December). A deep learning approach for motor imagery EEG signal classification. In *2016 3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)* (s. 34-39). IEEE.
- Lakshmi, M. R., Prasad, T. V., Prakash, D. V. C. (2014). Survey on EEG signal processing methods. *International Journal of Advanced Research in Computer Science and Software Engineering*, 4 (1).
- Lashgari, E., Liang, D., Maoz, U. (2020). Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 108885.
- Le Van Quyen, M., Foucher, J., Lachaux, J. P., Rodriguez, E., Lutz, A., Martinerie, J., Varela, F. J. (2001). Comparison of Hilbert transform and wavelet methods for the analysis of neuronal synchrony. *Journal of neuroscience methods*, 111 (2), 83-98.
- Li, F., He, F., Wang, F., Zhang, D., Xia, Y., Li, X. (2020). A Novel Simplified Convolutional Neural Network Classification Algorithm of Motor Imagery EEG Signals Based on Deep Learning. *Applied Sciences*, 10 (5), 1605.
- Li, M., Zhang, M., Luo, X., Yang, J. (2016, August). Combined long short-term memory based network employing wavelet coefficients for MI-EEG recognition. In *2016 IEEE International Conference on Mechatronics and Automation* (s. 1971-1976). IEEE.

KAYNAKLAR DİZİNİ (devam)

Loboda, A., Margineanu, A., Rotariu, G., Lazar, A. M. (2014). Discrimination of EEG-based motor imagery tasks by means of a simple phase information method. *International Journal of Advanced Research in Artificial Intelligence*, 3 (10).

Lu, N., Li, T., Ren, X., Miao, H. (2016). A deep learning scheme for motor imagery classification based on restricted boltzmann machines. *IEEE transactions on neural systems and rehabilitation engineering*, 25 (6), 566-576.

Lu, N., Li, T., Ren, X., Miao, H. (2016). A deep learning scheme for motor imagery classification based on restricted boltzmann machines. *IEEE transactions on neural systems and rehabilitation engineering*, 25 (6), 566-576.

Mantri, S., Dukare, V., Yeole, S., Patil, D., Wadhai, V. M. (2013). A survey: Fundamental of EEG. *International Journal of Advance Research in Computer Science and Management Studies*, 1 (4).

Martišius, I., Damaševičius, R. (2016). A prototype SSVEP based real time BCI gaming system. *Computational intelligence and neuroscience*, 2016.

Michielli, N., Acharya, U. R., Molinari, F. (2019). Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. *Computers in biology and medicine*, 106, 71-81.

Naderi, M. A., Mahdavi-Nasab, H. (2010, November). Analysis and classification of EEG signals using spectral analysis and recurrent neural networks. In *2010 17th Iranian Conference of Biomedical Engineering (ICBME)* (s. 1-4). IEEE.

Nisar, S., Khan, O. U., Tariq, M. (2016). An efficient adaptive window size selection method for improving spectrogram visualization. *Computational intelligence and neuroscience*, 2016.

Ocak, H. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 36 (2), 2027-2036.

Ochoa, J. B. (2002). EEG signal classification for brain computer interface applications. *Ecole Polytechnique Federale de Lausanne*, 7, 1-72.

Olejniczak, P. (2006). Neurophysiologic basis of EEG. *Journal of clinical neurophysiology*, 23 (3), 186-189.

Olgun, N., Türkoğlu, İ. (2017). Brain-Computer Interface Systems. In *At 8th International Advanced Technologies Symposium, Elazığ, Turkey* (C. 1, s. 2318-2327).

Oweis, R. J., Abdulhay, E. W. (2011). Seizure classification in EEG signals utilizing Hilbert-Huang transform. *Biomedical engineering online*, 10 (1), 38.

Öner, İ. V., Yeşilyurt, M. K., Yılmaz, E. Ç. (2017). Wavelet Analiz Tekniği ve Uygulama Alanları. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 7 (1), 42-56.

KAYNAKLAR DİZİNİ (devam)

- Paszkiet, S. (2020). Data Acquisition Methods for Human Brain Activity. In *Analysis and Classification of EEG Signals for Brain–Computer Interfaces* (s. 3-9). Springer, Cham.
- Peng, C. J., Chen, Y. C., Chen, C. C., Chen, S. J., Cagneau, B., Chassagne, L. (2020). An EEG-Based Attentiveness Recognition System Using Hilbert–Huang Transform and Support Vector Machine. *Journal of Medical and Biological Engineering*, 40 (2), 230-238.
- Peng, W. (2019). EEG Preprocessing and Denoising. In *EEG Signal Processing and Feature Extraction* (s. 71-87). Springer, Singapore.
- Peng, Z. K., Peter, W. T., Chu, F. L. (2005). An improved Hilbert–Huang transform and its application in vibration signal analysis. *Journal of sound and vibration*, 286 (1-2), 187-205.
- Pfurtscheller, G., Neuper, C., Guger, C., Harkam, W. A. H. W., Ramoser, H., Schlogl, A., Pregenzer, M. A. P. M. (2000). Current trends in Graz brain-computer interface (BCI) research. *IEEE transactions on rehabilitation engineering*, 8 (2), 216-219.
- Pigorini, A., Casali, A. G., Casarotto, S., Ferrarelli, F., Baselli, G., Mariotti, M., Rosanova, M. (2011). Time–frequency spectral analysis of TMS-evoked EEG oscillations by means of Hilbert–Huang transform. *Journal of neuroscience methods*, 198 (2), 236-245.
- Polat, K., Güneş, S. (2007). Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*, 187 (2), 1017-1026.
- Polikar, R. (1999). The story of wavelets. *Physics and modern topics in mechanical and electrical engineering*, 192-197.
- Raghu, S., Sriraam, N., Temel, Y., Rao, S. V., Hegde, A. S., Kubben, P. L. (2019). Performance evaluation of DWT based sigmoid entropy in time and frequency domains for automated detection of epileptic seizures using SVM classifier. *Computers in biology and medicine*, 110, 127-143.
- Rahman, M. A., Khanam, F., Ahmad, M., Uddin, M. S. (2020). Multiclass EEG signal classification utilizing Rényi min-entropy-based feature selection from wavelet packet transformation. *Brain informatics*, 7 (1), 1-11.
- Rashid, M., Islam, M., Sulaiman, N., Bari, B. S., Saha, R. K., Hasan, M. J. (2020). Electroencephalography based motor imagery movements classification using long short-term memory (LSTM) based on deep learning approach. *SN Applied Sciences*, 2 (2), 211.
- Ray, W. J., Slobounov, S. (2006). Fundamentals of EEG methodology in concussion research. In *Foundations of Sport-Related Brain Injuries* (s. 221-240). Springer, Boston, MA.
- Razi, S., Mollaei, M. R. K., Ghasemi, J. (2019). A novel method for classification of BCI multi-class motor imagery task based on Dempster–Shafer theory. *Information Sciences*, 484, 14-26.

KAYNAKLAR DİZİNİ (devam)

Rodríguez-Bermúdez, G., García-Laencina, P. J. (2012). Automatic and adaptive classification of electroencephalographic signals for brain computer interfaces. *Journal of medical systems*, 36 (1), 51-63.

Sakai, A., Minoda, Y., Morikawa, K. Data augmentation methods for machine-learning-based classification of bio-signals. In 2017 10th Biomedical Engineering International Conference (BMEiCON) (s. 1-4). IEEE.

Sakhavi, S., Guan, C., Yan, S. (2018). Learning temporal information for brain-computer interface using convolutional neural networks. *IEEE transactions on neural networks and learning systems*, 29 (11), 5619-5629.

San Martin, R., Huettel, S. A. (2013). Cognitive functions as revealed by imaging of the human brain. *Neuroscience in the 21st century*, 2213-2238.

Selim, S., Tantawi, M. M., Shedeed, H. A., Badr, A. (2018). A CSP\AM-BA-SVM Approach for Motor Imagery BCI System. *IEEE Access*, 6, 49192-49208.

Shajil, N., Mohan, S., Srinivasan, P., Arivudaiyanambi, J., Murrugesan, A. A. (2020). Multiclass Classification of Spatially Filtered Motor Imagery EEG Signals Using Convolutional Neural Network for BCI Based Applications. *Journal of Medical and Biological Engineering*, 40 (5), 663-672.

Sifuzzaman, M., Islam, M. R., Ali, M. Z. (2009). Application of wavelet transform and its advantages compared to Fourier transform.

Siuly, S., Li, Y., Zhang, Y. (2016). Electroencephalogram (EEG) and Its Background. In *EEG Signal Analysis and Classification* (s. 3-21). Springer, Cham.

Siuly, S., Li, Y., Zhang, Y. (2016). Significance of eeg signals in medical and health research. In *EEG Signal Analysis and Classification* (s. 23-41). Springer, Cham.

So, H. C., Chan, Y. T., Ma, Q., Ching, K. P. (1999). Comparison of various periodograms for sinusoid detection and frequency estimation. *IEEE Transactions on Aerospace and Electronic Systems*, 35 (3), 945-952.

Tang, X., Li, W., Li, X., Ma, W., Dang, X. (2020). Motor imagery EEG recognition based on conditional optimization empirical mode decomposition and multi-scale convolutional neural network. *Expert Systems with Applications*, 149, 113285.

Taran, S., Bajaj, V., Sharma, D., Siuly, S., Sengur, A. (2018). Features based on analytic IMF for classifying motor imagery EEG signals in BCI applications. *Measurement*, 116, 68-76.

Teplan, M. (2002). Fundamentals of EEG measurement. *Measurement science review*, 2 (2), 1-11.

KAYNAKLAR DİZİNİ (devam)

- Ting, W., Guo-Zheng, Y., Bang-Hua, Y., Hong, S. (2008). EEG feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement*, 41 (6), 618-625.
- Tiwari, N., Edla, D. R., Dodia, S., Bablani, A. (2018). Brain computer interface: A comprehensive survey. *Biologically inspired cognitive architectures*, 26, 118-129.
- Tosun, M., Erginli, M., Kasım, Ö. (2018). EEG Verileri Kullanılarak Fiziksel El Hareketleri ve Bu Hareketlerin Hayalinin Yapay Sinir Ağları İle Sınıflandırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(2), 1-9.
- Venkatachalam, K., Devipriya, A., Maniraj, J., Sivaram, M., Ambikapathy, A., Iraj, S. A. (2020). A novel method of motor imagery classification using eeg signal. *Artificial Intelligence in Medicine*, 103, 101787.
- Von Büna, P., Meinecke, F. C., Scholler, S., Müller, K. R. (2010, August). Finding stationary brain sources in EEG data. In *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology* (s. 2810-2813). IEEE.
- Wang, D., Miao, D., Blohm, G. (2012). Multi-class motor imagery EEG decoding for brain-computer interfaces. *Frontiers in neuroscience*, 6, 151.
- Wang, L., Xu, G., Wang, J., Yang, S., Yan, W. (2011, May). Motor Imagery BCI Research Based on Hilbert-Huang Transform and Genetic Algorithm. In *2011 5th International Conference on Bioinformatics and Biomedical Engineering* (s. 1-4). IEEE.
- Wang, L., Zhang, X., Zhong, X., Zhang, Y. (2013). Analysis and classification of speech imagery EEG for BCI. *Biomedical signal processing and control*, 8 (6), 901-908. *Congress on Computer Science and Engineering (APWC on CSE)* (s. 34-39). IEEE.
- Wang, P., Jiang, A., Liu, X., Shang, J., Zhang, L. (2018). LSTM-based EEG classification in motor imagery tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26 (11), 2086-2095.
- Wang, R., Kwong, S., Chen, D., Cao, J. (2013). A vector-valued support vector machine model for multiclass problem. *Information Sciences*, 235, 174-194.
- Wang, T., Deng, J., He, B. (2004). Classifying EEG-based motor imagery tasks by means of time-frequency synthesized spatial patterns. *Clinical Neurophysiology*, 115 (12), 2744-2753.
- Wang, Z., Cao, L., Zhang, Z., Gong, X., Sun, Y., Wang, H. (2018). Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition. *Concurrency and Computation: Practice and Experience*, 30 (23), e4413.
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical neurop.*, 113 (6), 767-791.

KAYNAKLAR DİZİNİ (devam)

Xia, X., Hu, L. (2019). EEG: Neural Basis and Measurement. In *EEG Signal Processing and Feature Extraction* (s. 7-21). Springer, Singapore.

Xu, B., Wei, Z., Song, A., Wu, C., Zhang, D., Li, W., Zeng, H. (2019). Phase synchronization information for classifying motor imagery EEG from the same limb. *IEEE Access*, 7, 153842-153852.

Xu, B., Zhang, L., Song, A., Wu, C., Li, W., Zhang, D., Zeng, H. (2018). Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification. *IEEE Access*, 7, 6084-6093.

Yang, P., Wang, J., Zhao, H., Li, R. (2020). MLP With Riemannian Covariance for Motor Imagery Based EEG Analysis. *IEEE Access*, 8, 139974-139982.

Yu, Z., Song, J. (2017, October). Multi-class motor imagery classification by singular value decomposition and deep boltzmann machine. In *2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference (ITOEC)* (s. 376-379). IEEE.

Yuyi, Z., Surui, L., Lijuan, S., Zhenxin, L., Bingchao, D. (2017). Motor imagery eeg discrimination using hilbert-huang entropy.

Zhang, Y., Wang, Y., Zhou, G., Jin, J., Wang, B., Wang, X., Cichocki, A. (2018). Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces. *Expert Systems with Applications*, 96, 302-310.

Zhang, Z., Duan, F., Sole-Casals, J., Dinares-Ferran, J., Cichocki, A., Yang, Z., Sun, Z. (2019). A novel deep learning approach with data augmentation to classify motor imagery signals. *IEEE Access*, 7, 15945-15954.

Zhou, J., Meng, M., Gao, Y., Ma, Y., Zhang, Q. (2018, June). Classification of motor imagery EEG using wavelet envelope analysis and LSTM networks. In *2018 Chinese Control And Decision Conference (CCDC)* (s. 5600-5605). IEEE.

Zhu, D., Bieger, J., Garcia Molina, G., Aarts, R. M. (2010). A survey of stimulation methods used in SSVEP-based BCIs. *Computational intelligence and neuroscience*, 2010.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ÇETİN, Osman
Doğum tarihi ve yeri :
e-mail :

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	---	---
Yüksek Lisans	Dumlupınar Üniversitesi/E.E.M	2021
Lisans	Dumlupınar Üniversitesi/E.E.M.	2018
Lise	Ertuğrul Gazi Anadolu Lisesi	2013

Yabancı Dil İngilizce: Çok iyi