

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ ALGORİTMALARI
KULLANILARAK GLOSSOKİNETİK POTANSİYEL
TABANLI DİL-MAKİNE ARAYÜZÜ TASARIMI**

DOKTORA TEZİ

Kutlucan GÖRÜR

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**
Enstitü Bilim Dalı : ELEKTRONİK
Tez Danışmanı : Doç. Dr. Mehmet Recep BOZKURT
Ortak Danışman : Prof. Dr. Feyzullah TEMURTAŞ

ŞUBAT 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

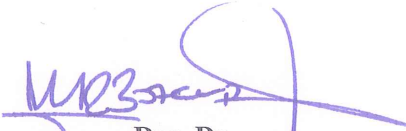
MAKİNE ÖĞRENMESİ ALGORİTMALARI
KULLANILARAK GLOSSOKİNETİK POTANSİYEL
TABANLI DİL-MAKİNE ARAYÜZÜ TASARIMI

DOKTORA TEZİ

Kutlucan GÖRÜR

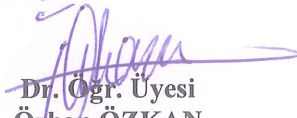
Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ

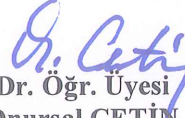
Bu tez 01 / 02 / 2019 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.


Doç. Dr.
Mehmet Recep BOZKURT
Jüri Başkanı


Doç. Dr.
Akif AKGÜL
Üye


Dr. Öğr. Üyesi
Gökçen ÇETİNEL
Üye


Dr. Öğr. Üyesi
Özhan ÖZKAN
Üye


Dr. Öğr. Üyesi
Onursal ÇETİN
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.


Kutlucan GÖRÜR

01.02.2019

TEŞEKKÜR

Doktora eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli ortak danışman hocam Prof. Dr. Feyzullah TEMURTAŞ'a ve danışman hocam Doç. Dr. Mehmet Recep BOZKURT'a teşekkürlerimi sunarım.

Teknik olanakları konusunda anlayış ve yardımlarını esirgemeyen Bozok Üniversitesi Elektrik-Elektronik Müh. Bölümü'ne ve özellikle bilgi ve deneyimlerinden yararlandığım arkadaşım Dr. Öğr. Üyesi. M. Serdar BAŞÇIL'a teşekkür ederim.

Ayrıca doktora tez çalışması içerisinde kullandığım verileri toplamama yardımcı olan ve çalışmalara gönüllü olarak katılan Bozok Üniversitesi Elektrik-Elektronik Müh. Bölümü öğrencilerine teşekkür ederim.

Yalnız bu çalışmada değil, her zaman her türlü alanda manevi desteğiyle yanımda olan aileme, akrabalarım ve arkadaşlarıma minnet ve şükranlarımı sunuyorum. Hepsinden önce bütün ömrü boyunca arkamda duran yetişmemde ve bu günlere gelmemde sayısız emeği olan rahmetli babam Ömer GÖRÜR'ü rahmet, şükran ve minnetle anarım.

Bu çalışma Sakarya Üniversitesi Etik Kurulu'nun 61923333/044 sayılı nolu etik kurulu izin belgesi alınarak yapılmıştır. Toplanan veriler insan sağlığına ait etik standartlara uygun olarak toplanmıştır.

İÇİNDEKİLER

| | |
|---------------------------------------|------|
| TEŞEKKÜR | i |
| İÇİNDEKİLER | ii |
| SİMGELER VE KISALTMALAR LİSTESİ | v |
| ŞEKİLLER LİSTESİ | ix |
| TABLolar LİSTESİ | xvii |
| ÖZET | xxi |
| SUMMARY | xxii |

BÖLÜM 1.

| | |
|-------------|---|
| GİRİŞ | 1 |
|-------------|---|

BÖLÜM 2.

| | |
|----------------------------------------------------------------------------------------------------------------------------|----|
| İSTEMLİ DİL HAREKETİ VE GLOSSOKİNETİK POTANSİYEL SİNYALLERİ..... | 25 |
| 2.1. Glossokinetik Potansiyel Sinyal Oluşumu..... | 25 |
| 2.2. Glossokinetik Potansiyel Sinyalleri ve EEG İlişkisi..... | 27 |
| 2.2.1. İstemi motor dil hareketine bağlı beyin aktivasyonu ile EEG ve GKP frekans bantları..... | 29 |
| 2.3. Dil-Makine Arayüzü ve Beyin-Bilgisayar Arayüzü Çalışmalarındaki Geleneksel Problemler..... | 32 |
| 2.4. Glossokinetik Potansiyel ve Dilin, Dil-Makine Arayüzü, Beyin-Bilgisayar Arayüzü Üzerine Katkıları ve Avantajları..... | 35 |
| 2.5. EEG Ölçüm Düzeni, Elektrot Yerleşimi ve Elektrot Çeşitleri..... | 37 |
| 2.5.1. Tez çalışması için gerçekleştirilen EEG üzerinden glossokinetik potansiyel sinyali ölçüm düzeni..... | 39 |
| 2.6. Deneysel Düzen ve Glossokinetik Potansiyel Veri Toplama Adımları... | 42 |

BÖLÜM 3.

SİNYAL İŞLEME METOTLARI VE MAKİNE ÖĞRENMESİ

| | |
|-----------------------------------------------------------------------------------------|----|
| ALGORİTMALARI..... | 45 |
| 3.1. Sinyal Ön İşleme Adımları, Filtreleme ve Normalizasyon..... | 45 |
| 3.1.1. Ayrık dalgacık dönüşümü..... | 47 |
| 3.2. Özellik Çıkarma ve Sinyalden Görüntüye Çevirme İşlemi..... | 49 |
| 3.2.1. Zaman alanında özellik çıkarma yöntemleri..... | 50 |
| 3.2.2. Frekans alanında özellik çıkarma yöntemi..... | 50 |
| 3.2.3. Sinyalden görüntüye çevirme işlemi..... | 52 |
| 3.2.4. Tez çalışması için elde edilen 1-D veri seti ve 2-D görüntü seti oluşumu..... | 53 |
| 3.3. Boyut Azaltma ve Özellik Seçme Yöntemleri..... | 54 |
| 3.3.1. Temel bileşen analizi yöntemi..... | 54 |
| 3.3.2. Bağımsız bileşen analizi yöntemi..... | 55 |
| 3.4. Makine Öğrenmesi Algoritmaları..... | 56 |
| 3.4.1. Performans değerlendirme kriterleri..... | 57 |
| 3.4.2. Çok katmanlı sinir ağları..... | 59 |
| 3.4.3. Olasılıksal sinir ağları..... | 61 |
| 3.4.4. Destek vektör makinesi..... | 63 |
| 3.4.5. Doğrusal ayırım analizi..... | 64 |
| 3.4.6. En yakın k komşuluğu..... | 65 |
| 3.4.7. Karar ağaçları..... | 67 |
| 3.4.8. Konvolüsyonel sinir ağları..... | 68 |

BÖLÜM 4.

| | |
|------------------------------------------------------------------|-----|
| ÇALIŞMANIN BULGULARI..... | 70 |
| 4.1. Geleneksel Sınıflandırıcılar İçin Performans Değerleri..... | 70 |
| 4.1.1. Ortalama karesel kök sonuçları..... | 71 |
| 4.1.2. Standart sapma sonuçları..... | 83 |
| 4.1.3. Varyans sonuçları..... | 92 |
| 4.1.4. Ortalama değer sonuçları..... | 101 |
| 4.1.5. Ortalama mutlak değer sonuçları..... | 108 |

| | |
|--------------------------------------------------------------------------------|-----|
| 4.1.6. Maksimum tepe değeri sonuçları..... | 118 |
| 4.1.7. Şekil faktörü sonuçları..... | 126 |
| 4.1.8. Güç spektral yoğunluğu sonuçları..... | 131 |
| 4.1.9. Geleneksel sınıflandırıcılar için birleştirilmiş veri seti sonuçları.. | 142 |
| 4.2. Konvolüsyonel Sinir Ağı İçin Sınıflandırma Performans Değerleri..... | 145 |
| 4.3. Geleneksel Sınıflandırıcılar İçin Hesaplama Süreleri ve Saçılım Grafiği.. | 147 |

BÖLÜM 5.

| | |
|------------------------|-----|
| SONUÇ VE ÖNERİLER..... | 150 |
|------------------------|-----|

| | |
|----------------|-----|
| KAYNAKLAR..... | 157 |
|----------------|-----|

| | |
|---------------|-----|
| ÖZGEÇMİŞ..... | 171 |
|---------------|-----|

SİMGELER VE KISALTMALAR LİSTESİ

| | |
|-------|-------------------------------------------------------------------------------------|
| ACC | : Doğruluk (Accuracy) |
| AFE | : Analog Ön Uç (Analog Front-End) |
| ALS | : Amiyotrofik Lateral Skleroz (Amyotrophic Lateral Sclerosis) |
| ANN | : Yapay Sinir Ağı (Artificial Neural Network) |
| AT | : Yardımcı Teknolojiler (Assistive Technologies) |
| BC | : Bayes Sınıflandırıcısı (Bayesian Classifier) |
| BCI | : Beyin-Bilgisayar Arayüzü (Brain-Computer Interface) |
| BSS | : Kör Kaynak Ayırma (Blind Source Separation) |
| CNN | : Konvolüsyonel Sinir Ağı (Convolutional Neural Network) |
| CSP | : Yaygın Mekansal Modeller (Common Spatial Pattern) |
| CSSSP | : Ortak Seyrek Spektral Mekansal Modeller (Common Sparse Spectral Spatial Patterns) |
| CWT | : Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform) |
| DC | : Doğru Akım (Direct Current) |
| DCT | : Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform) |
| DL | : Derin Öğrenme (Deep Learning) |
| DoF | : Serbestlik Derecesi (Degrees of Freedom) |
| DT | : Karar Ağaçları (Decision Trees) |
| dTDS | : Çift Modlu Dil-Sürücü Sistemi (Dual-Mode Tongue-Drive System) |
| DWT | : Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform) |
| ECG | : Elektrokardiyogram (Electrocardiogram) |
| ECoG | : Elektrokortikografik (Electrocorticographic) |
| EEG | : Elektroensefalogram (Electroencephalogram) |
| EMG | : Elektromiyogram (Electromyogram) |
| EOG | : Elektrookülogram (Electrooculogram) |

| | |
|------|--------------------------------------------------------------------------------------------------------|
| ERD | : Olay İle İlgili Uyumsuzluk (Event Related Desynchronization) |
| ERP | : Olaya İlişkin Potansiyel (Event-Related Potential) |
| ERS | : Olayla İlişkili Senkronizasyon (Event Related Synchronization) |
| eTDS | : Harici Dil Sürücü Sistemi (External Tongue-Drive System) |
| FN | : Yanlış Negatif (False Negative) |
| FP | : Yanlış Pozitif (False Positive) |
| FPGA | : Alan Programlanabilir Kapı Dizisi (Field Programmable Gate Array) |
| GKP | : Glossokinetik Potansiyel (Glossokinetic Potential) |
| HCN | : Hipoglossal Kranial Sinirler (Hypoglossal Cranial Nerve) |
| HMI | : İnsan Makine Arayüzü (Human-Machine Interface) |
| HMM | : Saklı Markov Modelleri (Hidden Markov Models) |
| ICA | : Bağımsız Bileşen Analizi (Independent Component Analysis) |
| IFCN | : Uluslararası Klinik Nörofizyoloji Federasyonu (International Federation of Clinical Neurophysiology) |
| IIR | : Sonsuz Dürtü Tepkisi Yanıtı (Infinite Impulse Response) |
| ITCI | : İndüklenen Dil-Bilgisayar Arayüzü (Inductive Tongue-Computer Interface) |
| ITCS | : İndüklenen Dil-Kontrol Sistemi (Inductive Tongue-Control System) |
| ITR | : Bilgi Transfer Oranı (Information Transfer Rate) |
| iTDS | : Dahili Dil-Sürücü Sistemi (Internal Tongue-Drive System) |
| kNN | : En Yakın k Komşuluğu (k-Nearest Neighbor) |
| LDA | : Doğrusal Ayırım Analizi (Linear Discriminant Analysis) |
| LFP | : Yerel Alan Potansiyeli (Local Field Potential) |
| LM | : Levenberg Marquardt |
| LoC | : Kontrol Kaybı (Loss of Control) |
| LSPC | : En Küçük Kareler Olasılıklı Sınıflandırma (Least-Squares Probabilistic Classification) |
| MAV | : Ortalama Mutlak Değer (Mean-Absolute Value) |
| MI | : Motor Düşüncesi (Motor Imagery) |
| ML | : Makine Öğrenmesi (Machine Learning) |

| | |
|------|-----------------------------------------------------------------------------|
| MLNN | : Çok Katmanlı Sinir Ağı (Multilayer Neural Network) |
| MPV | : Maksimum Tepe Değeri (Maximum Peak Value) |
| MS | : Multipl Skleroz (Multiple Sclerosis) |
| MSE | : Ortalama Karesel Hata (Mean-Square Error) |
| mTDS | : Çok Modlu Dil-Sürücü Sistemi (Multi-Mode Tongue-Drive System) |
| MV | : Ortalama Değer (Mean Value) |
| OTI | : Ağız Dokunma Ara Yüzü (Oral Tactile Interface) |
| PC | : Temel Bileşenler (Principal Components) |
| PCA | : Temel Bileşen Analizi (Principal Component Analysis) |
| PCT | : Temel Bileşen Dönüşümü (Principal Component Transformation) |
| PNN | : Olasılıksal Sinir Ağı (Probabilistic Neural Network) |
| PSD | : Güç Spektral Yoğunluğu (Power Spectral Density) |
| ROC | : Alıcı İşletim Karakteristiği (Receiver Operating Characteristic) |
| ReLU | : Düzeltilmiş Doğrusal Aktivasyon Birimi (Rectified Linear Activation Unit) |
| RMS | : Karesel Ortalama Kök (Root Mean Square) |
| SB | : Katılımcı (Subject) |
| SC | : Sığ Sınıflandırıcılar (Shallow Classifiers) |
| SCI | : Omurilik Yaralanmaları (Spinal Cord Injuries) |
| SCP | : Yavaş Kortikal Potansiyel (Slow Cortical Potential) |
| SENS | : Duyarlılık (Sensitivity) |
| SF | : Şekil Faktörü (Shape Factor) |
| SoC | : Tek Bir Entegre Sistemi (System-on-Chip) |
| SSI | : Basit Kare İntegral (Simple Square Integral) |
| STD | : Standart Sapma (Standart Deviation) |
| STFT | : Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform) |
| SPEC | : Özgüllük (Specificity) |
| SVM | : Destek Vektör Makinesi (Support Vector Machine) |
| TBI | : Travmatik Beyin Yaralanmaları (Traumatic Brain Injury) |
| TCI | : Dil Bilgisayar Arayüzü (Tongue Computer Interface) |

| | |
|------|-------------------------------------------------------------|
| TDS | : Dil Sürücü Sistemi (Tongue Drive System) |
| TMI | : Dil Makine Arayüzü (Tongue Machine Interface) |
| TMEP | : Dil Hareketi Kulak Basıncı (Tongue-Movement Ear Pressure) |
| TN | : Doğru Negatif (True Negative) |
| ToT | : Dil Ucu (Tip of the Tongue) |
| TP | : Doğru Pozitif (True Positive) |
| TS | : Test Seti (Test Set) |
| VAR | : Değişim (Variance) |
| WA | : Willison Genliği (Willison Amplitude) |
| WL | : Dalga Biçimi Uzunluğu (Waveform Length) |
| WPT | : Dalgacık Paket Dönüşümü (Wavelet Packet Transform) |
| 1-D | : 1-Boyutlu (1-Dimensional) |
| 2-D | : 2-Boyutlu (2-Dimensional) |

ŞEKİLLER LİSTESİ

| | | |
|-------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1. | Glossokinetik potansiyel tabanlı dil-makine arayüzü çalışması genel blok diyagramı gösterimi..... | 4 |
| Şekil 2.1. | Ağız içinde dil yapısının şematik gösterimi..... | 25 |
| Şekil 2.2. | Dil hareketine bağlı dil ucunun dokunması esnasında yüz ve kafa derisi üzerindeki potansiyel değişimin topografik gösterimi | 26 |
| Şekil 2.3. | Doğrusal GKP sinyali elde etmek için gerçekleştirilen elektrot yerleşimi, dil hareketi ve doğrusal sinyal gösterimi. $z(t)$ her iki elektrottaki $(x_1(t), x_2(t))$ sinyalin farkı alınarak elde edilmiştir..... | 27 |
| Şekil 2.4. | Dilin izole edilmesiyle GKP sinyalinin yüz ve kafa derisi üzerinde oluşmasının önlenmesine ait bir gösterim..... | 29 |
| Şekil 2.5. | Beyin lobları gösterimi..... | 30 |
| Şekil 2.6. | Delta ve teta frekans bantlarını içeren EEG sinyalleri..... | 31 |
| Şekil 2.7. | Tez çalışması için yanak duvarına istemli ve ardışık hareketlerle dokunan dilin oluşturduğu GKP sinyallerinin, 6 sn boyunca kafa derisi üzerinden kaydedilen görüntüsü (Genlik: $\pm 80 \mu V$ civarında)..... | 32 |
| Şekil 2.8. | a) iTDS sistemine ait bir gösterim b) eTDS sistemine ait bir gösterim c) TMEP sistemine ait bir gösterim d) TDS sistemine ait başka bir gösterim..... | 33 |
| Şekil 2.9. | a) OTI sistemine ait bir gösterim b) ITCI sistemine ait bir gösterim..... | 33 |
| Şekil 2.10. | BCI ve robotik kol kullanımına ait örnek bir gösterim..... | 34 |
| Şekil 2.11. | Yanak duvarına değdirilen 1-boyutlu dil hareketiyle oluşan GKP potansiyel farkı ile elektrikli sandalye kullanımına ait örnek gösterim..... | 37 |

| | | |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 2.12. | 10-20 EEG düzeni ve kafa derisi üzerine elektrot yerleşimi..... | 38 |
| Şekil 2.13. | a) Altın elektrot gösterimi b) Gümüş elektrot gösterimi..... | 38 |
| Şekil 2.14. | EEG kepi ve jel enjeksiyonu gösterimi..... | 39 |
| Şekil 2.15. | Tez çalışması içinde kullanılan EEG ölçüm cihazı gösterimi.... | 40 |
| Şekil 2.16. | EEG ölçüm sistemi içerisinde empedans ayarlama arayüzü gösterimi..... | 41 |
| Şekil 2.17. | EEG ölçüm sistemi içerisinde System Plus Evaluation arayüzü gösterimi..... | 41 |
| Şekil 2.18. | Deneysel düzen gösterimi a) 1.deneysel düzen b) 2. deneysel düzen c) 3.deneysel düzen..... | 44 |
| Şekil 3.1. | Dil hareketine bağlı olarak üretilen Fp2 kanalına ait 6 sn'lik GKP ham veri sinyali ve filtre uygulanmış sinyal örnek gösterimi (Mavi Sinyal: Ham GKP sinyali, Kırmızı Sinyal: Filtrelenmiş GKP sinyali)..... | 46 |
| Şekil 3.2. | Ayrık dalgacık dönüşümü ve filtre yapısı (S: Sinyal (Signal), A: Düşük frekanslı sinyal (Approximation), D: Yüksek frekanslı sinyal (Detail))..... | 47 |
| Şekil 3.3. | Wavelet analizi ve zaman-ölçek alanı..... | 48 |
| Şekil 3.4. | Sürekli dalgacık dönüşümü ve zaman-frekans analizine ait örnek gösterim..... | 48 |
| Şekil 3.5. | GKP ham veri sinyaline ait bölütler ve $M \times M$ boyutunda görüntüler..... | 52 |
| Şekil 3.6. | Çok katmanlı sinir ağı yapısının gösterimi..... | 60 |
| Şekil 3.7. | Olasılıksal sinir ağına ait örnek gösterim..... | 62 |
| Şekil 3.8. | Destek vektör makinesi ve sınıflandırma örneği..... | 64 |
| Şekil 3.9. | LDA projeksiyon tekniği ile sınıflandırma için örnek bir gösterim..... | 65 |
| Şekil 3.10. | İki sınıflı en yakın k komşuluğu algoritmasına ait örnek bir gösterim..... | 66 |
| Şekil 3.11. | Veri seti ve ilgili karar ağacı ile sınıflandırma örnek gösterimi..... | 67 |
| Şekil 3.12. | Tez çalışması içinde kullanılan CNN mimarisi örnek gösterimi.. | 69 |

| | | |
|------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 4.1. | Ortalama karesel kök ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri..... | 73 |
| Şekil 4.2. | En başarılı katılımcıya (katılımcı-2) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 79 |
| Şekil 4.3. | En başarısız katılımcıya (katılımcı-1) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 80 |
| Şekil 4.4. | En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 81 |
| Şekil 4.5. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 81 |
| Şekil 4.6. | En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 82 |
| Şekil 4.7. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 82 |
| Şekil 4.8. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram | |

| | | |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| | grafığı (sağ)..... | 83 |
| Şekil 4.9. | Standart sapma ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri | 85 |
| Şekil 4.10. | En başarılı katılımcıya (katılımcı-10) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin gösterimi..... | 88 |
| Şekil 4.11. | En başarısız katılımcıya (katılımcı-7) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin gösterimi..... | 89 |
| Şekil 4.12. | En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 90 |
| Şekil 4.13. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 91 |
| Şekil 4.14. | En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 91 |
| Şekil 4.15. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 92 |
| Şekil 4.16. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiğı (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram | |

| | | |
|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| | grafığı (sağ)..... | 92 |
| Şekil 4.17. | Varyans ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri..... | 94 |
| Şekil 4.18. | En başarılı katılımcıya (katılımcı-6) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 97 |
| Şekil 4.19. | En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 98 |
| Şekil 4.20. | En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 100 |
| Şekil 4.21. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafığı (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafığı (sağ)..... | 100 |
| Şekil 4.22. | Ortalama değer ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri | 102 |
| Şekil 4.23. | En başarısız katılımcıya (katılımcı-5) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 105 |
| Şekil 4.24. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 106 |

| | | |
|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Şekil 4.25. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 107 |
| Şekil 4.26. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)..... | 108 |
| Şekil 4.27. | Ortalama mutlak değer ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri..... | 110 |
| Şekil 4.28. | En başarısız katılımcıya (katılımcı-3) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 116 |
| Şekil 4.29. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 117 |
| Şekil 4.30. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 117 |
| Şekil 4.31. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)..... | 118 |
| Şekil 4.32. | Maksimum tepe değeri ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri..... | 120 |
| Şekil 4.33. | En başarısız katılımcıya (katılımcı-4) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile | |

| | | |
|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| | dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 123 |
| Şekil 4.34. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 124 |
| Şekil 4.35. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 125 |
| Şekil 4.36. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)..... | 125 |
| Şekil 4.37. | Güç spektral yoğunluğu ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri..... | 132 |
| Şekil 4.38. | En başarısız katılımcıya (katılımcı-8) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi..... | 139 |
| Şekil 4.39. | En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim..... | 140 |
| Şekil 4.40. | En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)..... | 141 |
| Şekil 4.41. | En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan | |

| | |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| GKP sinyali periodogram grafiđi (sol),en başarısız katılımcıya ait sađ dil hareketi esnasında oluřan GKP sinyali periodogram grafiđi (sađ)..... | 141 |
| řekil 4.42. Katılımcı-2'ye ait MAV için ham veri seti üzerinden saçılım grafiđi (sol), katılımcı-2'ye ait MPV için ham veri seti üzerinden saçılım grafiđi (sađ) (Mavi: Sađ sınıfı, Turuncu: Sol sınıfı göstermektedir)..... | 148 |

TABLolar LİSTESİ

| | | |
|-------------|------------------------------------------------------------------------------|----|
| Tablo 2.1. | Tez çalışması içinde kullanılan EEG kanal isimleri ve numaraları..... | 42 |
| Tablo 2.2. | Tez çalışması için gönüllü olan katılımcılara ait demografik bilgiler..... | 43 |
| Tablo 3.1. | Zaman alanı özellik çıkarma yöntemleri ve matematiksel ifadeleri..... | 50 |
| Tablo 4.1. | RMS ham veri seti sonuçları (400×19)..... | 71 |
| Tablo 4.2. | RMS ve temel bileşen analizi veri seti sonuçları (400×12)..... | 73 |
| Tablo 4.3. | RMS ve temel bileşen analizi veri seti sonuçları (400×10)..... | 74 |
| Tablo 4.4. | RMS ve bağımsız bileşen analizi veri seti sonuçları (400×12).. | 75 |
| Tablo 4.5. | RMS ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 75 |
| Tablo 4.6. | RMS ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 77 |
| Tablo 4.7. | RMS ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 78 |
| Tablo 4.8. | STD ham veri seti sonuçları (400×19)..... | 84 |
| Tablo 4.9. | STD ve temel bileşen analizi veri seti sonuçları (400×12)..... | 85 |
| Tablo 4.10. | STD ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 86 |
| Tablo 4.11. | STD ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 86 |
| Tablo 4.12. | STD ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 87 |
| Tablo 4.13. | VAR ham veri seti sonuçları (400×19)..... | 93 |
| Tablo 4.14. | VAR ve temel bileşen analizi veri seti sonuçları (400×12)..... | 94 |
| Tablo 4.15. | VAR ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 95 |
| Tablo 4.16. | VAR ve 11 kanal-frontal ve temporal bölge veri seti sonuçları | |

| | | |
|-------------|-----------------------------------------------------------------------------------------------------------------|-----|
| | (400×11)..... | 96 |
| Tablo 4.17. | VAR ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 96 |
| Tablo 4.18. | MV ham veri seti sonuçları (400×19)..... | 101 |
| Tablo 4.19. | MV ve temel bileşen analizi veri seti sonuçları (400×12)..... | 102 |
| Tablo 4.20. | MV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 104 |
| Tablo 4.21. | MV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 104 |
| Tablo 4.22. | MV ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 105 |
| Tablo 4.23. | MAV ham veri seti sonuçları (400×19)..... | 109 |
| Tablo 4.24. | MAV ve temel bileşen analizi veri seti sonuçları (400×12)..... | 110 |
| Tablo 4.25. | MAV ve ayrık dalgacık dönüşümü uygulanmış, temel bileşen analizi veri seti sonuçları (400×12)..... | 111 |
| Tablo 4.26. | MAV ve bağımsız bileşen analizi veri seti sonuçları (400×12).. | 112 |
| Tablo 4.27. | MAV ve ayrık dalgacık dönüşümü uygulanmış, bağımsız bileşen analizi veri seti sonuçları (400×12)..... | 112 |
| Tablo 4.28. | MAV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 113 |
| Tablo 4.29. | MAV ve ayrık dalgacık dönüşümü uygulanmış, 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 113 |
| Tablo 4.30. | MAV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 114 |
| Tablo 4.31. | MAV ve ayrık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 114 |
| Tablo 4.32. | MAV ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 115 |
| Tablo 4.33. | MPV ham veri seti sonuçları (400×19)..... | 119 |
| Tablo 4.34. | MPV ve temel bileşen analizi veri seti sonuçları (400×12)..... | 120 |
| Tablo 4.35. | MPV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 121 |
| Tablo 4.36. | MPV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 122 |
| Tablo 4.37. | MPV ve ayrık dalgacık dönüşümü uygulanmış, 11 kanal- | |

| | | |
|-------------|------------------------------------------------------------------------------------------------------------------|-----|
| | frontal ve temporal bölge veri seti sonuçları (400×11)..... | 122 |
| Tablo 4.38. | MPV ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 123 |
| Tablo 4.39. | SF ham veri seti sonuçları (400×19)..... | 126 |
| Tablo 4.40. | SF ve temel bileşen analizi veri seti sonuçları (400×12)..... | 127 |
| Tablo 4.41. | SF ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 128 |
| Tablo 4.42. | SF ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 129 |
| Tablo 4.43. | SF ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 129 |
| Tablo 4.44. | SF ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 130 |
| Tablo 4.45. | PSD ham veri seti sonuçları (400×19)..... | 131 |
| Tablo 4.46. | PSD ve temel bileşen analizi veri seti sonuçları (400×12)..... | 132 |
| Tablo 4.47. | PSD ve temel bileşen analizi veri seti sonuçları (400×10)..... | 133 |
| Tablo 4.48. | PSD ve ayırık dalgacık dönüşümü uygulanmış, temel bileşen analizi veri seti sonuçları (400×12)..... | 134 |
| Tablo 4.49. | PSD ve bağımsız bileşen analizi veri seti sonuçları (400×12)... | 134 |
| Tablo 4.50. | PSD ve ayırık dalgacık dönüşümü uygulanmış, bağımsız bileşen analizi veri seti sonuçları (400×12) | 135 |
| Tablo 4.51. | PSD ve 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 136 |
| Tablo 4.52. | PSD ve ayırık dalgacık dönüşümü uygulanmış, 7 kanal-frontal bölge veri seti sonuçları (400×7)..... | 136 |
| Tablo 4.53. | PSD ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 137 |
| Tablo 4.54. | PSD ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)..... | 137 |
| Tablo 4.55. | PSD ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)..... | 138 |
| Tablo 4.56. | RMS+STD+VAR+MV ham veri seti sonuçları (400×76)..... | 142 |
| Tablo 4.57. | RMS+STD+VAR+MV ve temel bileşen analizi veri seti sonuçları (400×20)..... | 143 |

| | | |
|-------------|----------------------------------------------------------------------------------------|-----|
| Tablo 4.58. | RMS+STD+VAR+MV ve 7 kanal-frontal bölge veri seti sonuçları (400×28)..... | 144 |
| Tablo 4.59. | RMS+STD+VAR+MV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×44)..... | 144 |
| Tablo 4.60. | CNN için ham görüntü seti ve DWT uygulanmış görüntü seti sonuçları (456×2)..... | 145 |
| Tablo 4.61. | CNN için 11 kanal-frontal ve temporal bölge görüntü seti sonuçları (264×2)..... | 147 |
| Tablo 4.62. | Geleneksel sınıflandırıcılar için hesaplama süreleri (sn)..... | 148 |

ÖZET

Anahtar kelimeler: Glossokinetik Potansiyel Sinyalleri, Dil-Makine Arayüzü, Yardımcı Teknolojiler, Beyin-Bilgisayar Arayüzü, Felçli Bireyler

Yardımcı teknolojiler, ağır engelli bireylerin diğer aygıtlara veya bireylere niyetlerini iletmelerini sağlayabilir. Bu teknolojiler, bireylerin sürekli yardım alma ihtiyacını kolaylaştırarak, aile üyelerinin yükünü ve sağlık maliyetlerini azaltacaktır. Omurilik yaralanmalarında veya amiyotrofik lateral sklerozda, engelli insanlar dış dünyayla sınırlı derecede iletişim kurabilirler. Bu tez çalışmasında, makine öğrenmesi algoritmalarını uygulayarak 1-boyutlu hareketler içeren yardımcı teknolojileri kontrol etmek için glossokinetik potansiyel (GKP) tabanlı dil-makine arayüzü geliştirilmiştir. GKP sinyalleri, dil hareket bilgilerini içeren elektrik sinyalleridir. Tez çalışmasında GKP sinyalleri, deneysel düzenler içinde dil ucunun yanak duvarlarıyla teması sırasında kafa derisine yerleştirilen elektrotlarla ölçülmüştür.

İnsan vücudunun en esnek organlarından biri olan dil, yardımcı teknolojiler alanında çalışan araştırmacılar tarafından ileri motor kontrol görevlerine aday olarak kabul edilmiştir. Dil, omurilik yaralanmaları ve çoğu sinir-kas bozukluklarında bile genellikle ağır hasarlardan kaçabilir ve beyne hipoglosal kranial sinir yoluyla bağlanır. Bu nedenle, yüksek düzeyde omurilik yaralanması olan felçli kişiler bile, dil kontrol yeteneklerini korurlar. Bununla beraber dil, çok fazla çaba gerektirmeden ağız boşluğu içinde hızlı ve doğru bir şekilde hareket edebilir. Dahası, bu yetenekli organ, ağız boşluğu içinde olmasından dolayı engelli bireyler için mahremiyet sağlayabilir.

Dil-makine arayüzlerini kullanan araştırma çalışmalarının çoğu, ağız boşluğu içinde ve baş çevresinde rahatsızlık veren, hijyenik olmayan ekipmanlara sahiptir. Ancak, bu tez çalışması, engelli insanlara yardımcı teknolojileri doğal, rahatsızlık vermeyen, hızlı ve güvenilir bir şekilde kontrol etmesine hizmet edebilir. Çalışmada geleneksel makine öğrenmesi algoritmaları ve konvolüsyonel sinir ağı kullanılmış ve sırasıyla %99 ve %100 sınıflandırma doğruluğu sağlanmıştır. Daha sonra algoritmaların karşılaştırmalı analizi yapılmıştır. Zaman alanı ve frekans alanı özellik çıkarma metotlarının yanı sıra ayırık dalgacık dönüşümü, temel bileşen analizi ve bağımsız bileşen analizi sinyal işleme teknikleri de kullanılmıştır. Ayrıca, glossokinetik potansiyel tabanlı dil-makine arayüzü, elektroensefalografi (EEG) sinyallerinden kaynaklanan önemli yetersizlikleri içeren geleneksel EEG tabanlı beyin-bilgisayar arayüzleri için alternatif veya yardımcı kontrol ve iletişim kanalı olabileceği beklenmektedir.

GLOSSOKINETIC POTENTIAL BASED TONGUE-MACHINE INTERFACE DESIGN USING MACHINE LEARNING ALGORITHMS

SUMMARY

Keywords: Glossokinetic Potential Signals, Tongue-Machine Interface, Assistive Technologies, Brain-Computer Interface, Paralyzed Individuals

Assistive technologies (ATs) can enable severely disabled individuals to communicate their intentions to other devices or individuals. These technologies will ease the burden on family members and health costs by facilitating the need for continuous help for individuals. In spinal cord injuries (SCIs) or amyotrophic lateral sclerosis (ALS), disabled people can communicate with the external world to a limited degree. In this thesis study, we have developed glossokinetic potential (GKP) based tongue-machine interface (TMI) to control assistive technologies for 1-D movements via implementing machine learning algorithms. GKP signals are electrical signals that consist of information on tongue movements. In the thesis study, GKP signals were measured by electrodes placed on the scalp during contact of the tongue tip and buccal walls in the experimental setups.

Tongue, one of the most flexible organs of the human body, has been accepted as a candidate for advanced motor control tasks by researchers in the field of assistive technologies. The tongue is connected to the brain via the hypoglossal cranial nerve and can generally escape severe damages in SCIs and most neuromuscular disorders. Hence, high-level SCIs still maintain intact tongue control capabilities. Then the tongue is able to move quickly and accurately without so much effort. Moreover, this gifted organ may provide privacy for paralytics because in the oral cavity.

Most of the research using TMIs have obtrusive, unhygienic pieces of equipment in the oral cavity and around the headset. However, this dissertation may serve disabled people to control assistive technologies in natural, unobtrusive, speedy and reliable manner. In the study, traditional machine learning algorithms and convolutional neural network were used and classification accuracies of %99 and %100 were achieved respectively. And then comparative analysis of the algorithms was performed. In addition to time domain and frequency domain feature extraction methods, discrete wavelet transform, principal component analysis and independent component analysis signal processing techniques were also used. Moreover, it is expected that GKP-based TMI could be alternative or partner control and communication channel for traditional electroencephalography (EEG)-based brain-computer interfaces (BCIs) which involve significant inadequacies arisen from the EEG signals.

BÖLÜM 1. GİRİŞ

Yardımcı teknolojiler (AT), engelli bireylerin işlevsel kabiliyetlerini arttırmak, sürdürmek veya iyileştirmek için kullanılan, ticari olarak satın alınmış, değiştirilmiş veya özelleştirilmiş olan herhangi bir parça, ekipman veya ürün sistemidir. Ağır engelli bireyler yardımcı teknolojiler vasıtasıyla kendi ortamlarındaki cihazları kontrol edebilir ve diğer bireylerle iletişim kurabilirler [1]. Bu sistemler, kullanıcıların motorlu sandalye, akıllı telefon veya bilgisayar gibi harici bir cihaza komut göndermesine izin verir [2]. Omurilik yaralanmaları (SCI), travmatik beyin yaralanmaları (TBI) ve amiyotrofik lateral skleroz (ALS) gibi felçli ve ciddi fiziksel engelli bireyler dört uzuvun da felç olduğu durumları içerebilir ve yaşam kalitelerini arttırmak, daha üretken ve bağımsız olarak yaşamak için AT'lere ihtiyaç duyarlar [1]–[4].

Ciddi kısıtlamaları olan engelli bireylerin etraflarındaki ortamla etkileşime girebilmeleri için, elektroensefalogram (EEG), elektrookülogram (EOG) ve elektromiyogram (EMG) gibi farklı sinyalleri kullanan yardımcı teknolojiler geliştirilmiştir [2], [4]. Bu sinyaller sırasıyla beyin aktivitesi, göz hareketleri, kafa ve yüz kas grubu hareketleri sonucunda oluşurlar. Bu sinyaller ve buna bağlı olarak yardımcı cihazları kullanmak için oluşturulan en yaygın ve en bilinen sistemler EEG tabanlı beyin-bilgisayar arayüz (BCI) modelleridir [5]–[7]. Çok kanallı EEG sinyalleri, genelde kafa derisi üzerine invazif olmayan elektrot yerleşimini kullanarak beyindeki elektriksel aktiviteleri görmek ve yardımcı teknolojilere anlamlı komutlar göndermek için ölçülür. Nispeten iyi zamansal çözünürlük sağlamakla beraber kişiler arası ve oturumlar arası değişkenliklerden oldukça etkilenirler [7], [8]. EEG sinyallerinin doğasından kaynaklanan, yetersiz sinyal-gürültü oranı ve içsel zihinsel aktivitelere veya bazı dış faktörlere bağlı olarak değişen durağan olmayan yapısı nedeniyle geleneksel EEG tabanlı BCI'lar birçok dezavantaja sahiptir [3], [9]. Bütün bu olumsuz durumlar senkron BCI'larda kontrol kaybı (LoC) ve serbestlik derecesi

(DoF) problemlerini getirmektedir [10], [11]. Yüksek bilişsel iş yükü ve uzun eğitim süreleri de EEG tabanlı BCI'lardaki önemli sorunlar olarak görülmektedir [10].

İnsan vücudunun en esnek ve yetenekli parçalarından biri olan dil, AT alanındaki çeşitli araştırmacılar tarafından gelişmiş motor kontrol görevleri için uygun bir aday olarak görülmektedir [1], [12]. Dil, hipoglossal kranial sinirler (HCN) yoluyla beyne doğrudan bağlanır ve bu sebeple genellikle omurilik yaralanmaları ve sinir-kas hastalıklarının çoğundan kaçabilir. Böylece, yüksek seviyeli omurilik yaralanmaları olan hastalar bile dil kontrol yeteneklerini koruyabilirler [12], [13]. Dil, ağız içinde beyin ile geniş bant iletişimi içinde olan, hızlı ve doğru bir şekilde hareket edebilen bir organdır. Hareketleri sezgiseldir ve EEG tabanlı BCI'dan farklı olarak yüksek oranda düşünme veya yüksek konsantrasyon gerektirmez [1], [14]. Dil kasları az efor sarf eder ve kolayca yorulmaz. Bu nedenle, bir dil tabanlı arayüz sistemi, dilin ağız boşluğu içinde serbestçe hareket etmesine izin verdiği sürece birkaç saat boyunca sürekli olarak kullanılabilir. Dil kaslarını kontrol eden motor nöronlar, vücut pozisyonundaki değişikliklerle dilin vücut pozisyonunun refleksi olarak ayarlanmasına izin vererek zengin bir vestibüler girdi alırlar. Bu nedenle, dil ile çalışan arayüz sistemleri, tekerlekli sandalyede oturmak veya yatakta uzanmak gibi herhangi bir yerde ve herhangi bir pozisyonda rahatlıkla kullanılabilir [1]. Dilin arayüz sistemleri içinde kullanılmasının bir başka avantajı da ağız içindeki dilin konumudur. Engelli kişiler sosyal hayat içinde sağlıklı bireylerden farklı görülmemek istemezler. Böylece dil engelli hastalara önemli ölçüde mahremiyet ve kozmetik bir görüntü sağlayabilmektedir [1], [3].

Literatürde dilin zengin yeteneklerinden yararlanarak geliştirilen dil-sürücü sistemi (TDS), dil-makine arayüzü (TMI) veya dil-bilgisayar arayüzü (TCI) isimlerinde birçok fiziksel ve giyilebilir sistemler geliştirilmiştir [1]–[3], [15], [16]. Bu arayüz sistemleri, istemli serbest dil hareketleri ile ciddi fiziksel engelli bireylerin ortamlarını kontrol edebilmelerine, bilgisayarlara erişmelerine ve tekerlekli sandalyelerini sürebilmelerine imkan tanımaktadır. Fakat, birçoğu ağız içine, dil üzerine ve baş üzerine yerleştirilmiş sensör, manyetik izleyici ve ağız içi elektronik dokunma kitleri gibi donanımlardan oluşan rahatsız edici sistemlerdir [1], [16], [17],

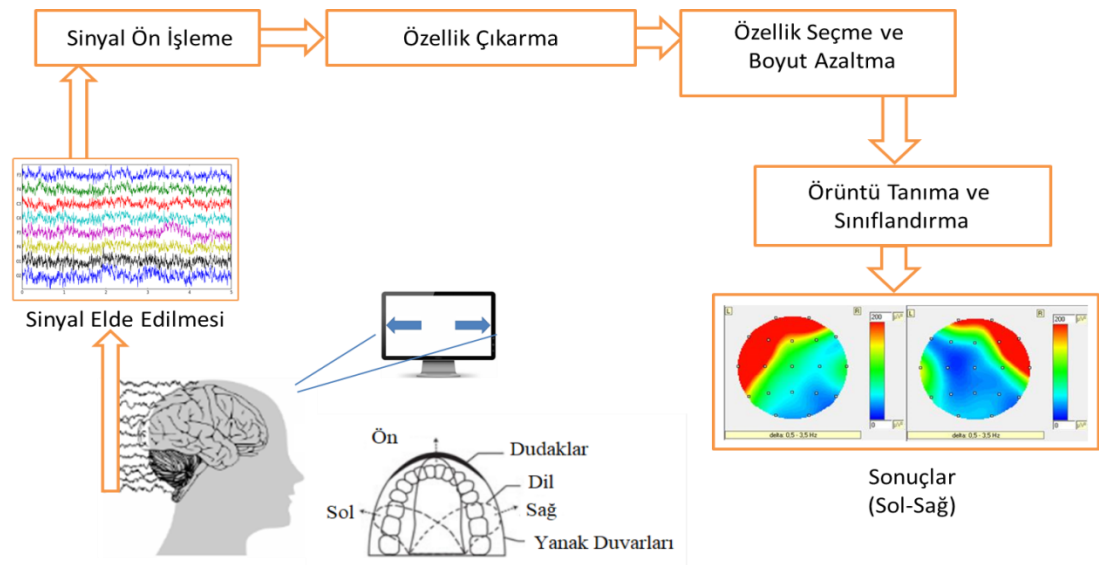
[18]. Bu nedenle, bu yaklaşımlar engelli bireyler için rahatsızlık veren, estetik açıdan güzel olmayan ve hijyenik sorunlar çıkarabilen donanımsal tabanlı sistemlerden oluşmaktadır.

Bu tez çalışmasında yardımcı teknolojileri kontrol etmek ve iletişim kurmak için tek boyutlu (1-D) hareketler içeren doğal ve güvenilir bir dil-makine arayüzü sistemi geliştirmek glossokinetik potansiyel (GKP) sinyallerini kullanarak ve makine öğrenmesi (ML) algoritmalarının başarısının araştırılması yoluyla amaçlanmıştır. Glossokinetik potansiyel yanıtları, dil ucuyla yanak duvarlarına veya diş ve damak gibi ağız içi dokularına dokunmak suretiyle üretilen elektriksel sinyallerdir [14]. Dilin ucu, dil köküne göre negatif elektrik yüküne sahiptir, bu nedenle ağız içindeki dokulara dokunduğunda, temas noktasındaki yük potansiyel seviyesini azaltır [13], [14]. Bu sebepten dolayı dile yüklü organ denilmektedir. Genel olarak, GKP sinyalleri, EEG sinyallerini bozan bir sinyal olarak kabul edilmiştir [14]. Bununla birlikte, literatürdeki az sayıdaki birkaç çalışmada, dil hareketlerini izlemek için yeni bir araç olarak kullanılmaya başlanmıştır [13], [14], [19]. Örneğin negatif yüklü dil, sol tarafa doğru hareket eder ve sol yanak duvarına dokunursa, sol yarımküredeki elektrotların potansiyelleri yavaş yavaş azalacak ve sağ yarımküredeki potansiyeller orantısız olarak artacaktır. Kafa derisi ve yüz bölgesindeki bu doğrusal yük değişimini kullanarak oluşturulan literatürdeki dil-makine arayüzü çalışmalarında uzamsal sinyallerin sınıflandırılması istatistiksel yaklaşımlarla ortaya konulmuştur [13], [19]. Fakat doğrudan makine öğrenmesi algoritmalarını kullanarak, başarılarının araştırılması suretiyle mukayese edilmesi, 1 boyutlu GKP tabanlı dil-makine arayüzü çalışmalarında ilk olarak ilgili bu tez çalışmasında gerçekleştirilmiştir [3], [9].

Makine öğrenmesi algoritmaları yıllardır çeşitli araştırmacılar tarafından beyin bilgisayar arayüz ve dil-makine arayüz çalışmalarının başarısı açısından vazgeçilmez ve en önemli odak noktası olarak görülmektedir [5]-[9]. BCI ve TMI sistemlerinde hangi makine öğrenmesi algoritması ve sinyal işleme yönteminin en iyi olduğunu saptamak zordur. Bu tez çalışmasında kullanılan en başarılı makine öğrenmesi algoritması ve en başarılı sinyal işleme yönteminin GKP tabanlı TMI

üzerinde daha iyi sonuç ürettiği ortaya konulmuştur. Bu konuda genellikle çalışmalarda kullanılan geleneksel algoritmalarından bazıları şunlardır; destek vektör makine'si (SVM), doğrusal ayırım analizi (LDA), çok katmanlı sinir ağı (MLNN), olasılıksal sinir ağları (PNN), en yakın k komşuluğu (kNN), karar ağaçları (DT), bayes sınıflandırıcıları (BC), saklı markov modelleri (HMM) [4]. İlgili tez çalışmasında geleneksel veya literatürdeki yeni ismiyle sığ sınıflandırıcılardan (SC); SVM, LDA, MLNN, PNN, kNN ve DT algoritmaları kullanılmıştır. Bununla beraber yine bu tez çalışmasında, görüntü ve sinyal işleme, uzamsal örüntü tanıma çalışmalarında son yıllarda ortaya koyduğu performans ile literatürde ön plana çıkan derin öğrenme (Deep Learning) metotlarından birisi olan konvolüsyonel sinir ağı (CNN) da kullanılmıştır [20].

Bu tez çalışmasında Şekil 1.1.'de gösterildiği gibi kafa derisi üzerinden ölçülen glossokinetik potansiyel yanıtları dil ucunun sağ ve sol yanak duvarlarına değdirilmesi suretiyle oluşur. Oluşan GKP sinyalleri üzerinden sinyal işleme ve makine öğrenmesi algoritmaları kullanarak engelli insanlar için doğal, güvenilir ve kullanımı kolay bir dil-makine arayüzü geliştirilmiştir. Gerçekleştirilen bu sistem, GKP sinyallerinin elde edilmesi, sinyal filtreleme gibi ön işleme adımları, özellik çıkarma, özellik seçme-boyut azaltma ve sınıflandırma adımlarından oluşmaktadır.



Şekil 1.1. Glossokinetik potansiyel tabanlı dil-makine arayüzü çalışması genel blok diyagramı gösterimi

Tez kitabı şu şekilde düzenlenmiştir: Bölüm 1’de engelli ve felçli bireylerin kullandığı yardımcı teknolojiler ile bunları kontrol etmek için gerekli olan dil-makine arayüzü çalışmalarından bahsedilmiştir. Ayrıca beyin-bilgisayar arayüz sistemleri ile beraber sahip olduğu sınırları ve dezavantajları kısaca anlatılmıştır. Aynı bölümün devamında glossokinetik potansiyel sinyallerinin nasıl oluştuğu ve makine öğrenmesi algoritmaları ile bu sinyallerin dil-makine arayüzünde nasıl kullanıldığı üzerinde durulmuştur. Son olarak tez çalışmasının sunduğu katkı ve özgün nitelikten kısaca bahsedilmiş ve ilgili literatür çalışması verilmiştir.

Bölüm 2’de glossokinetik potansiyel sinyallerinin oluşumundan ve EEG ile ilişkisinden bahsedilmiştir. Daha sonra GKP ve EEG sinyallerinin bulunduğu frekans bantları ve motor bir fonksiyon olan dilin, beyin lobları açısından ilişkisine değinilmiştir. Aynı bölümde, dil-makine arayüzü ve beyin-bilgisayar arayüzü çalışmalarına ait görseller sunularak örnekler verilmiştir. Yine aynı bölümde, tez çalışması içerisinde kullanılan EEG veri ölçme cihazı ve 10-20 uluslararası elektrot yerleşimi anlatılmıştır. Bununla beraber katılımcıların istatistiksel bilgilerinden ve oluşturulan deneysel düzenlerden bahsedilmiştir.

Bölüm 3’de sinyal işleme adımları ve metotları üzerinde durulmuştur. Sinyal işleme adımlarından sinyal ön işleme, özellik çıkarma, özellik seçme-boyut azaltma metotları ve örüntü tanıma-sınıflandırma algoritmaları anlatılmıştır. Bununla beraber konvolüsyonel sinir ağı için 1-D zaman serisi sinyallerinden 2-D zaman serisi sinyallerine ait griölçek görüntü (Grayscale Images) dönüştürme işlemi de anlatılmıştır. Sinyal işlemede kullanılan, katılımcılara ait 1-D zaman serisi sinyallerine ait veri setleri ile 2-D zaman serisi sinyallerine ait görüntü setleri oluşumu da yine ilgili bölümde anlatılan konulardandır. Ayrıca yine aynı bölümde ilgili makine öğrenmesi algoritmaları ve sinyal işleme metotlarının başarılarının gösterilmesi için değerlendirme kriterlerinden söz edilmiştir.

Bölüm 4’te glossokinetik potansiyel sinyallerine bağlı olarak oluşturulan dil-makine arayüzünde kullanılan sinyal işleme metotları ve sınıflandırma sonuçları tablolar içinde verilmiştir. Bununla beraber beyin haritalama sonuçları, zaman-frekans skalası

ve frekans spektrumu sonuçları, saçılım grafikleri, güç-frekans (periodogram) dağılımı ve ortalama sinyal gücü-kanal değişimi bulguları da ilgili bölümde gösterilmektedir.

Bölüm 5'te sonuçlar tartışmaları ile yorumlanmış ve biyomedikal alanı ile ilgili literatüre olduğu kadar gerçek zamanlı gelecek çalışmalar için katkısı da vurgulanmıştır. Bununla beraber var olan dil-makine arayüzü ve beyin-bilgisayar arayüzü çalışmaları ile kıyas edilmiş ve avantajlarından bahsedilmiştir.

Literatürde var olan bu konu ile ilgili çalışmalardan bazıları şunlardır:

Klass, D. ve ark. 1960 yılında yaptıkları klinik çalışmada EEG sinyalleri üzerinde glossokinetik potansiyel sinyallerinin görüldüğünden bahsetmişlerdir [21]. Jaffe, R. ve ark. 1983 yılında yaptıkları klinik çalışmada dil hareketinin EEG sinyali üzerinde bozulmalara sebep olduğundan bahsetmişlerdir [22]. 2003 senesi içinde yapılan diğer bir klinik çalışmada, dil hareketine bağlı olarak yavaş EEG potansiyel değişiminin topografik yapısını ve mekanizmasını karakterize etmeyi amaçlamışlardır [23]. Dil hareketinden kaynaklı glossokinetik potansiyel sinyalleri, EEG sinyalleri üzerinde bozulmalara ve potansiyel değişimine sebep olduğunu ve bunun araştırılması gerektiğini düşünmüşlerdir. Bu çalışmayı gerçekleştirmek için, dili diğer ağız dokularından izole etmek için üzerine elektriksel yük geçirmeyen plastik eldiven giydirilmiş, yüz ve kafa derisi üzerinden ölçümler almışlardır. Bulguları içinde dil hareketinin yalnızca EEG üzerinde bozulmalar oluşturmadığı aynı zamanda EEG potansiyeli oluşturabildiği üzerinedir. Dil hareketi mekanizmasına bağlı olarak dil ucunun negatif yüke sahip olduğunu ve damak gibi dokulara dokunarak bunun kafa derisi üzerinde yük azalmasına sebep olabileceğini belirtmişlerdir. Alternatif olarak, dil hareketlerinin ağız odasında akım iletim yollarının geometrisini yeniden düzenleyerek EEG'yi etkileyebileceğini belirtmişlerdir.

Nam, Y. ve ark. yaptıkları bir çalışmada glossokinetik potansiyeli üzerinden dilin ağız içindeki pozisyonunu takip ederek bir dil-makine arayüzü oluşturmuşlardır. 2010 yılında gerçekleştirilen bu çalışma literatürdeki glossokinetik potansiyel tabanlı

ilk dil-makine arayüzünü oluşturmaktadır [24]. İlgili çalışmada kafa derisi üzerine özel olarak yerleştirilen elektrotlar ile kafa derisi yarımkürelerinde doğrusal olarak oluşan potansiyel farkı sinyal olarak ölçerek sağ-sol olarak sınıflandırmışlardır. Sinyal işleme tekniklerinden temel bileşen analizi (PCA) kullanılmıştır. Çalışmada kursor kontrolü yapılmış ve dil pozisyonunun GKP sinyalleri üzerinden ayırt edilebildiği ortaya konulmuştur.

Yine Nam, Y. ve ark. 2012 yılında yaptıkları diğer bir çalışmada önceki çalışmalarına ek olarak çene üzerinden ölçtükleri EMG sinyallerini dur ve hareket et gibi değişim fonksiyonları için kullanmışlardır [13]. Çalışmada katılımcılar gerçek zamanlı elektrikli sandalye sürmüşlerdir ve 1-D kontrolü dil ve GKP üzerinden gerçekleştirmişlerdir. Çalışmalarına dil-dümeni (orijinal ismiyle “Tongue-Rudder”) adını vermişlerdir. Aynı çalışmada yüksek frekansları elemek için 4 Hz’lik alçak geçiren filtre kullanmışlardır. Katılımcılar dillerini yanak duvarlarına sürekli bir değişim içinde sağ-ön-sol olarak deędirmişlerdir. Böylece kafa derisi üzerinde oluşan sağ ve sol yarımkürelerdeki GKP sinyallerinin potansiyel farklarını alarak ağız içindeki dil pozisyonunu gösteren doğrusal bir sinyal elde etmişlerdir. Araştırmaya dört sağlıklı birey katılmış ve elektrikli sandalyeleri oluşturulan çeşitli parkurlarda dil ve çenelerini hareket ettirerek kullanmışlardır. PCA, Intertask Covariance ve Intersession Covariance isimli istatistiksel metotlar sınıflandırma işlemi için uygulanmıştır.

2014 yılında yapılan diğer bir çalışmada, Nam, Y. ve ark. 2-D kontrol için dil, çene ve göz hareketlerinden faydalanmışlardır [19]. Dil hareketine bağlı olarak ölçülen GKP sinyalleri ve göz hareketine bağlı olarak ölçülen EOG sinyalleri birer boyutlu kontrol oluşturularak toplamda iki boyutlu (2-D) kontrol kanalı oluşturmuşlardır. Çene hareketlerine bağlı olarak elde edilen EMG sinyali yine dur-hareket et gibi kalibrasyon kontrolü için kullanılmıştır. Çalışmada gerçek zamanlı bir insansı robot kontrolü yapılmıştır. GKP ve EOG sinyallerini karışmalara karşı doğru bir şekilde ayırt etmek için genelleştirilmiş Rayleigh yöntemi kullanılmıştır. Bununla birlikte sınıflandırma işlemi için SVM algoritmasından yararlanılmış ve %86,7 başarıya ulaşıldığı rapor edilmiştir. Araştırmacılar, 3 biyolojik sinyalin

kullanılmasından dolayı çalışmaya GOM-Yüzü (orijinal ismiyle “GOM-Face”) adını vermişlerdir.

Başka bir çalışmada, Nam, Y. ve ark. dilin konuşma ve seslerin çıkması ile ilgili ana artikülatorlerden birisi olduğunu belirtmiş ve buradan hareketle GKP ve fonetik sesler üzerine bir çalışma yapmışlardır [25]. Sonuçlar, diş, palato-alveolar ve palatal ünsüzlerin, frontal bölgede potansiyel azalmaya neden olduğunu ve oksipital bölgede potansiyel artışa neden olduğunu göstermiştir. Öte yandan, retro-ünsüzlerin telaffuz edilmesi esnasında frontal bölgede potansiyel artışa ve oksipital bölgede azalmaya neden olduğunu belirtmişlerdir. Bununla beraber, GKP' nin EEG üzerindeki bozulma etkilerinin yok edilmesinin, konuşma sinyali işlemede sinirbilim (Neuroscience) için yararlı olabileceğini belirtmişlerdir. Diğer faydaları açısından bu metodun beyin-bilgisayar arayüzü modelleri üzerinde gerçek dünya koşullarında uygulanabileceğini ve bu çalışma üzerinden yeni sessiz konuşma tanıma tekniği (Silent Speech Recognition) geliştirilebileceğini belirtmişlerdir. Aynı araştırmacılar 2016 senesi içinde diğer bir çalışmada önceki çalışmalarına atıfta bulunarak GKP sinyalinin, dil-makine arayüzü ve konuşma ile alakalı araştırmalarda faydaları üzerine bir derleme çalışması yapmışlardır [14].

Huo, X. ve ark. yaptıkları çalışmada donanımsal tabanlı dil-bilgisayar arayüzü modeli önermişlerdir [26]. Bu modelde dil üzerine sabit bir şekilde monte edilmiş küçük bir manyetik mıknatıs dil-izleyici olarak dil hareketlerini takip etmektedir. Dil hareketleri ile oluşan manyetik alan değişimleri, ağız bölgesinin dışındaki baş üstü setlerinde veya ağız içinde diş üzerine konulan ortodontik klipslerdeki manyetik sensör dizileri tarafından algılanır. Sensör çıkışları daha sonra taşınabilir bir bilgisayara kablosuz olarak iletildikten sonra işlenir ve farklı kullanıcı kontrol komutlarına çevrilir. Bu komutların, fare veya klavye işlevlerinin yerini alarak bir bilgisayara erişmek için kullanılabilceğini belirtmişlerdir. Ayrıca elektrikli tekerlekli sandalye, telefon veya diğer ekipmanları çalıştırmak için özelleştirilebildiklerini rapor etmişlerdir. Çalışmada altı komut seti için beyzbol kaskı prototipi geliştirilmiştir. Çalışmaya dil-sürücü sistemi adını vermişlerdir.

2007 ve 2008 senesi içinde yapılan diğer çalışmalarda Huo, X. ve ark. yine dil üzerine konulan manyetik dil-izleyici ve baş üstü sensörleri ile üç eksenli olarak dil hareketlerini takip etmişlerdir [27]-[29]. Elde edilen sinyaller kablosuz olarak bir bilgisayara aktarılmış ve altı komut seti için sırasıyla %99 ve %87'ye varan sınıflandırma başarısı elde etmişlerdir. Bilgi transfer oranı (ITR) yaklaşık olarak sırasıyla 150 bit/dk ve 130 bit/dk olarak bildirilmiştir. 2009 yılı içinde yapılan diğer bir çalışmada aynı araştırmacılar katılımcılara, çalışmalarında geliştirdikleri donanımsal dil-sürücü sistemi ile gerçek zamanlı elektrikli sandalye kullanmışlardır [30]. Çalışmaya 12 sağlıklı birey katılmış ve elleriyle kullandıkları sürenin yaklaşık 3 katı kadar bir sürede belirlenen parkuru dillerini kullanarak tamamladıklarını belirtmişlerdir. Çalışmaya dış baş seti olduğundan dolayı harici dil-sürücü sistemi (eTDS) adını vermişlerdir. Çalışmada Labview programında gerçek zamanlı kullanım için grafik tabanlı kullanıcı arayüzü de geliştirmişlerdir. Benzeri bir çalışmada, Yousefi, B. ve ark. standart klavye uygulaması için dil-sürücü tabanlı sistem geliştirmişler ve çalışmanın sonuçlarını Fitts kanunları ile değerlendirmişlerdir [31].

Huo, X. ve ark. 2012 senesi içinde yaptıkları yayında eTDS çalışmalarını derlemişlerdir. 6 sağlıklı ve 13 engelli insanın ITR sonuçları üzerinden sistemin gerçek zamanlı uygulamaları hakkındaki bilgileri bu çalışmada belirtmişlerdir [1]. eTDS çalışmasının geleneksel EEG tabanlı BCI sistemlerine göre yaklaşık iki kat kadar hızlı olduğunu rapor etmişlerdir. Yine aynı araştırmacılar 2013 yılı içinde geliştirdikleri eTDS sistemine konuşma kontrol sistemini eklemişler ve yeni sisteme çift modlu dil-sürücü sistemi (dTDS) adını vermişlerdir [32].

Huo, X. ve ark. yaptıkları diğer bir çalışmada ağız içi kablosuz diş klibini geliştirmişler ve dahili dil-sürücü sistemi adını (iTDS) vermişlerdir [33]. Geliştirilen sistem esnek bir baskı devre yapısı ile diş-klibine monte edilmiş manyetik sensörlerden oluşmaktadır. Dil üzerine yerleştirilen manyetik izleyici ile dil hareketleri izlenmiş ve 433 MHz, 915 MHz ve 2,42 GHz frekans bantlarında kablosuz veri iletim performanslarına bakılmıştır.

Gautham, K. ve ark. benzeri bir çalışma yapmış ve boşluk-etki sensörlerini dış-tutucu üzerine yerleştirmiş ve kablosuz bir sistem ile dil üzerindeki manyetik izleyici yardımıyla yardımcı cihazları kontrol eden iTDS sistemini ortaya koymuşlardır [34].

UnniKrishna Menon, K.A ve ark. geliştirdikleri kablosuz dil-sürücü sisteminde benzeri çalışmalarda olduğu gibi manyetik sensörler yerine optik sensörler kullanmış ve mikrodenetleyici ile oluşturdukları simülasyon arayüz ekranındaki yolu takip etmeyi başarmışlardır [35].

Sahadat, M.N ve ark. 2015 yılında yaptıkları bir çalışmada dil ve konuşma kontrolünün yanına baş kontrolü de ekleyip çok modlu dil-sürücü sistemini (mTDS) tanıtmışlardır. Katılımcılar zamana bağlı olarak fare ve klavye üzerinde uygulamalar yapmışlardır [36].

Ghovanloo, M. dil tarafından işletilen yardımcı teknolojiler üzerine derleme bir çalışma yapmıştır [16]. Bu çalışmada dil tabanlı arayüz sistemlerinin avantajlarından ve dilin, el ve parmaklar ile beyin korteksi üzerinde karmaşık bir yer işgal ettiğinden ve gelişmiş motor görevlerini yerine getirebildiğinden bahsetmişlerdir.

Ayala-Acevedo, A. ve ark. 2014 yılında yaptıkları çalışmada akıllı telefon uyumlu TDS uygulaması üzerinde yapay sinir ağı ve adaboost algoritmasının performansını ortaya koymuşlardır [37]. Ortalama sınıflandırma başarısının %92,64 olduğunu belirtmişlerdir.

Andreasen Struijk L.N.S 2006 senesi içinde yaptıkları bir çalışmada üst damak bölgesine yerleştirilen manyetik sensör grupları ile dil üzerine sabitledikleri kalıcı mıknatısı kullanarak, indüklenen dil-bilgisayar arayüzü (ITCI) modelini geliştirmişlerdir [38]. Basınç temelli dil makine arayüzlerine kıyasla indüklenen sensörlerin avantajının, yüksek sayıda sensöre sahip olmasının yanı sıra, aktivasyon için neredeyse hiç bir kuvvete ihtiyaç duyulmamış olmasını göstermişlerdir. Bu nedenle aktivasyon potansiyel olarak daha hızlı ve katılımcılar için daha az yorucu

olduğunu belirtmişlerdir. Ayrıca, ITCI'nin normal yeme ve konuşma ile ilgili dil-damak baskılarından etkilenmediğini rapor etmişlerdir.

Andreasen Struijk L.N.S ve ark. diğer bir çalışmada damak üzerine yerleştirilen klavye ile metin yazımı için ITCI sistemi gerçekleştirmişlerdir [15]. Ortalamada katılımcıların dakikada 15,5 karakter yazmayı başarabildiği ve sonuçlarının oldukça ümit verici olduğu bildirilmiştir.

Vaidyanathan, R. ve ark. 2004 senesi içinde yaptıkları çalışmada, kulak kanalında meydana gelen hava akışındaki değişiklikleri izleyerek dil hareketini tespit etmek ve kesin olarak tanımak için bir sinyal işleme stratejisi sunmuşlardır [39]. Ağız boşluğu içindeki dil hareketlerinin, kulak içinde harekete tepki olarak komut sinyalleri üretmek için işlenebilen benzersiz, ince basınç sinyalleri oluşturduğunu belirtmişlerdir. Bir kere tanındığında, söz konusu hareketler, bir bilgisayar ile iletişim ve mekanik aygıtların kontrol edilmesi gibi insan-makine arayüz uygulamalarında kullanılabilmesini öne sürmüşlerdir. İşlem stratejisi şöyledir; kulak içine yerleştirilmiş bir mikrofon kullanılarak basınç sinyali edinimi, dil hareketlerinden başka kaynaklardan kaynaklanan basınç değişimlerini reddetmek için bant geçiş filtre tasarımı, güç spektral yoğunluk analizi, çapraz-korelasyon yoluyla dalga formlarındaki başlangıç ve son nokta saptamasını içermektedir. Sinyal sınıflandırma işlemi için parametrik ve parametrik olmayan sınıflandırıcılar kullanılmıştır. Bunlar sırasıyla Gauss ve doğrusal olmayan dizilim sınıflandırıcılarıdır. Sistem, dört dil eylemi üzerinde test edilmiştir. Bunlar dilin, ağzın sol ve sağ köşelerine ve yine ağzın üst ve alt merkezine doğru dokunmasıdır. Gerçekleştirilen dil hareketlerinin ayrık olarak yapıldığı ve %97 oranında başarı elde edildiği bildirilmiştir. Aynı araştırmacılar aynı yıl yaptıkları benzeri bir çalışmada dil hareketleri ile robot kontrolü gerçekleştirmişlerdir [40].

Aynı araştırma ekibi 2006 yılında, önceki çalışmalarının kapsamını genişletmek ve farklı sınıflandırıcıların başarısını keşfetmek için dört katılımcının katıldığı bir çalışma gerçekleştirmişlerdir [41]. Çalışmada karar birleştirme algoritmasını kullanmışlar ve dört dil hareketi için ortalama sınıflandırma doğruluğu olarak %96

ve en yüksek başarı sonucu olarak %99 değerini elde etmişlerdir. Yine aynı sene içinde aynı araştırmacılar çift modlu arayüz çalışmasının sonuçlarını paylaşmışlardır [42]. Çalışmada dil ve ses sinyallerini aynı arayüz modeli içinde topladıklarını ve eller serbest (Hands-Free) insan-makine arayüzü (HMI) adını verdikleri sistem için kontrol ve iletişim kanalı oluşturduklarını belirtmişlerdir. Hava (Aural) ve ses sinyallerinin tanımlanması için HMM algoritmasından faydalandıklarını belirtmişlerdir. Dört katılımcı için dil-hava hareketi sonucu ortalama %98,41 olarak bulunmuştur. Yine dört katılımcıya sekiz kontrol kelimesi söylenmiş ve ortalama sınıflandırma sonucu olarak %95,87 bulunduğu rapor edilmiştir.

Vaidyanathan, R. ve ark. 2007 yılında diğer bir çalışmada dil-hava hareketi mantığını kullanarak 8 katılımcı ile karar füzyon sınıflandırma algoritmasını kullanmışlardır [43]. Geliştirilen konseptte, dil hareketlerine bağlı olarak kulak basıncı sinyallerini çıkarmak için enerji bazlı sinyal saptama ve segmentasyon, sinyallerdeki her deneme başarısını azaltmak için sinyal normalizasyonunu ve ortalama olarak çift yönlü çapraz korelasyon metotlarını kullanmışlardır. Ortalama başarı oranının %97 seviyesinde olduğunu belirtmişlerdir. Aynı araştırmacılar 2008 senesinde benzeri bir çalışmada, dalgacık dönüşümü (Wavelet Transform) yöntemini kullanarak sinyal üzerindeki gürültüleri gidermeyi amaçlamışlardır [44].

Mamun, K.A ve ark. çalışmalarında, dil hareketi kulak basıncı (TMEP) sinyallerini, engelli kişilere yönelik yardımcı insan makine arayüzlerinde kontrol komutları oluşturmak için kullanmıştır [45]. Bu çalışmanın amacının, hedeflenen bir hareketin kontrollünü içsel ve istemli olarak meydana gelen dil vasıtası ile oluşan fizyolojik sinyaller kullanılarak sınıflandırmak olduğunu belirtmişlerdir. Bölünmüş TMEP sinyallerinin özelliklerinin dalgacık paket dönüşümü (WPT) kullanılarak katsayı olarak çıkarıldığını ve çok katmanlı bir sinir ağı (MLNN) ile eğitilip test edildiğini rapor etmişlerdir. Ortalama sınıflandırma performansının altı kişi için %97,05 olarak gerçekleştiğini ortaya koymuşlardır. Aynı araştırmacı ve arkadaşları benzeri bir çalışmada Bayes sınıflandırıcı ile %98 gibi bir sonuç elde etmişlerdir [46].

Mace, M. ve ark. dil hareketi kulak basıncı (TMEP) sinyallerine dayanan bir yardımcı insan-makine arayüzü sisteminin gerçek zamanlı olarak uygulanmasını tanıtmışlardır. Bu çalışmada, araştırmacılar zaman alanı bilgisinden frekans özelliklerini çıkarmak için ayrık kosinüs dönüşümünü, tek değişkenli bir Gauss maksimum olabilirlik sınıfını, özellik seçimi ve özellik çıkarma için iki fazlı çapraz doğrulama prosedürünü kullanmaktadır. Düzlemsel bir tekerlekli sandalyeye yönelik simülasyon komutları vasıtasıyla sistemin, yardımcı robotik kontrol için kullanılabilceği bildirilmiştir ve %96,28 sınıflandırma başarısına ulaşılmıştır [47].

Gupta, L. ve ark. diğer bir çalışmada küçük örneklem büyüklükleri nedeniyle çok değişkenli sinyal klasmanlarının uygulanmasında sıklıkla karşılaşılan boyutsallık probleminin üstesinden gelmek için temel bileşen dönüşümü (PCT) ve ayrık kosinüs dönüşümü (DCT) özelliklerinin dönüşümü için bir strateji tanımlamışlardır. Ortaya çıkan PCT ve DCT-Gauss sinyal sınıflandırma stratejilerinin uygulamaları, tek kanallı dil hareketi kulak-basınç sinyalleri ve çok kanallı olaya ilişkin potansiyelleri (ERPs) sınıflandırarak gösterilmiştir. İki dönüşümün kombinasyonları ve dört özellik seçim kriteri arasında, maksimum büyüklük ve maksimum değişim seçim ölçütlerini kullanan PCT-Gauss sınıfları, iki sınıf sınıflandırma deneyi boyunca en iyi sınıflandırma doğruluğunu sağladığı rapor edilmiştir [48].

Dil hareketlerini izlemek ile ilgili dikkat çeken bir dizi çalışma Akgul, Y.S. ve ark. tarafından gerçekleştirilmiştir [49]-[53]. Konuşma ve yutkunma güçlüğü çeken ve bu konuda engelli olan insanların dil hareketlerini ultrason ile çekilmiş bir dizi dil hareketlerinden analiz eden çalışmayı ortaya koymuşlardır. Bu konuda görüntü işleme yöntemlerinden faydalandığını belirtmişlerdir.

Tang, H. ve ark. dil ile ilgili diğer bir çalışmada, ağızdan dokunma ara yüzü (OTI) geliştirmişlerdir [18]. Bu sistem dış mekanda seyrüseferde yönlendirici olarak görme engelli insanı yönlendirmek için dokunsal kanal boyunca yönlendirici ipuçları sağlamak üzere tasarlanmıştır. Sistem içindeki cihaz, dilin eşzamanlı çalışması için altta bir dokunuşla dokunmatik tuş takımı ve ağızın çatısına dokunsal sunum için üstte bir mikrofabiye elektro-kontrol'e sahip bir ağızlık olarak uygulanmıştır.

Deneysel bir sistem, kullanıcının bir bilgisayarla iletişim kurmasını ve ağızdan dokunma arayüzünün kullanılmasını sağlamıştır. Deneysel düzen esnasında yönlü işaretler kullanıcıya dört hareket yönüyle (sol, sağ, ileri ve geri) çizgi veya ok desenleri olarak sunulmuştur. Üst damak üzerindeki elektro-dokunma (Electrotactile) ve klavye sunumu dil ile uyarılarak, eşik ölçümü ve yönelme ipuçlarının belirlenmesi deneylerinde değerlendirilerek gerekli olan uyarımın ne kadar olduğunu belirlemişlerdir. Eşik hissi için 15 V civarında, rahat ve iyi algılanan uyarım için yaklaşık 25-30 V seviyelerinde bir uyarımın gerekli olduğunu belirtmişlerdir.

Caltenco, H.A ve ark. başka bir çalışmada, dil-bilgisayar arayüzleri için karakter aktivasyon zamanı tahmin modelinin geliştirilmesini araştırmışlardır [54]. Bu modelde, damak (Palatal) bölge çevresindeki dil seçiciliği görevleri için uygun olan Fitts yasasının değiştirilmesine dayanmaktadır. Model, indüklenen bir dil-bilgisayar arayüzü kullanılarak dil seçicilik deneylerinden elde edilen veriler ile eğitilmiş ve değerlendirilmiştir. Dil-ucu (ToT) seçiciliğini araştırmak suretiyle, ön ve orta damak bölgelerinin dilin ucuyla arka ve yan damak bölgelerine göre daha kolay ulaşılabilir olduğunu ifade etmişlerdir. Bu, ToT erişilebilirliğinin tüm hedefler için aynı olmadığını gösterir. Bütün bunlar hesaplanırken hareket genliği, hedef pozisyonu, aralarındaki etkileşimler, karakter belirsizliği ve hata düzeltme zamanının hesaba katıldığı belirtilmiştir. Çalışmanın sonuçlarının belirsiz dil bilgisayar arayüzü sistemleri için en uygun karakter düzenlemesi oluşturmak için kullanılabileceğinden ve böylece daha verimli dil-bilgisayar arayüzleri oluşturmak için faydalı olabileceğinden bahsetmişlerdir.

Caltenco H.A ve ark. 18 sağlıklı bireyin katıldığı başka bir araştırmada, standart Fitts yasası modeli kullanılarak öngörülen hedef konum ve hareket genişliğine göre ağız-ıçi (Intraoral) hedef seçim zamanını tahmin eden bir regresyon modeli oluşturmuştur [55]. 30 dakikalık üç günlük egzersiz seansında hız ve doğrulukta %30'luk bir iyileşme, dil kas sisteminin motor öğrenme yeteneklerini vurguladığını böylece dilin bilgisayar arayüzü teknolojilerini kullanmak için yararlı olduğuna dair daha fazla kanıt sağladığını belirtmişlerdir.

Caltenco H.A ve ark. dięer bir alıřmada indüklenen dil-kontrol sistemi (ITCS) tasarımı yapmıřlardır [56]. Bu sistemde, dil üzerindeki ferromanyetik dil izleyici, üst-damak üzerindeki indüklenen dil-kontrol sistemini kontrol etmek için kullanılmaktadır. Akıllı dil (Tonguewise) ismini verdikleri alıřmada klavye ve fare tipi ağız-ii sistem geliştirilmiřtir. Damak bölgesine konulan bu sistemde dilin ucuna baęlı sabit mıknatıs ile uyarımın yapılması saęlanmıřtır. Bu alıřmada bir eliřki olarak, karmařık sistemli yapıların hedef gruptan uzaklařtıęını, bununla beraber basit ve genel arayüz modellerinin ise bilgisayar etkileřiminde katılımcılar aısından yavař ve yorucu kontrol saęlayabildięini belirtmiřlerdir. Dil kontrol sistemi (TCS), 10 tuř takımı ve 8 ok yönlü fare-pedi olmak üzere iki ayrı sensör plakasına bölünmüřtür.

2013 yılında dięer bir alıřmada, Caltenco, H.A ve ark. ITCS tabanlı dil seimi ile hedef seim görevleri için görsel ve dokunsal ağız-ii sensörlerinin pozisyonunu geri bildirmek yöntemi ile yöntemin etkisini arařtırmıřlardır [57]. Görsel geribildirim, aktif ağız-ii hedefe karřılık gelen görsel bir göstergede alanın vurgulanmasıyla oluřturulmuřtur. 3. eęitim oturumunda, dakika başına 23,5 ve 15 ortalama hedef aktivasyonu seim elde edildięi bildirilmiřtir.

Enemark, M. ve ark. 2010 yılı içinde gerekleřtirdikleri bir alıřmada, indüklenen dil-kontrol sistemini geliřtirmiřtir [58]. Böylece gerek zamanlı elektrikli sandalye kullanımı gerekleřmiřtir. Yön kontrolü için 8 sensörü birleřtiren bulanık bir sistemin, tekerlekli sandalyede ok yönlü kontrol saęladıęını rapor etmiřlerdir.

Lontis, E.R. ve ark. indüklenen dil-kontrol sistemi (ITCS) tarafından saęlanan kablosuz bir alfabe klavyesi ve bir joyistik tipi fare alıřması yapmıřlardır [59]. Dil üzerinde tutturulmuř manyetik bir küçük izleyici mevcuttur. Bu sistem ile dakika başına doęru kelimeleri tanımlayarak sistemin performansı arařtırılmıřtır. İki katılımcı, sırasıyla iki ve üç ardışık güne, her günde iki seansa katıldıęı bildirilmiřtir. Maksimum dakika başına 2,94, 2,46 ve 2,06, 1,68 verimi, TCS klavyesi ile sırasıyla katılımcı-1 ve katılımcı-2 için kestirimci ve kestirimci olmayan klavye yazım teknięi ile elde edilmiřtir. Yine maksimum dakika başına kelime, katılımcı-1 ve katılımcı-2 için sırasıyla 2,09 ve 1,71 olarak TCS faresi ile elde edildięi belirtilmiřtir. Aynı

arařtırmacılar yine ITCS ile robot kol kontrolü yapmıřlardır [60]. Sonular, dil arayüzünün standart klavyeyle benzer bir řekilde 6 eksenli robot kolunu tamamen kontrol edebildiğini ve aynı sayıda başarılı manipölasyona ve standart klavyeye kıyasla %30'a varan görev süresinde ortalama bir artışa neden olabildiğini göstermektedir.

2011 yılında yapılan diđer bir arařtırmada, Takahashi, J. ve ark. boyun bölgesinin altına dil hareketlerini gözlemek için bir dizi elektrot koymuřlardır [61]. Dil hareketlerinin, elektrotlar tarafından ölçülen kas elektrik potansiyellerinin dağılımlarının merkez pozisyonuna göre belirlendiğini belirtmiřlerdir. alıřmanın sonularında sađ, sol, yukarı, ařađı, ileri, geri gibi altı hareket için %70'den yukarı sınıflandırma dođruluđu elde ettiklerinden bahsetmiřlerdir. alıřmaya 3 gönüllü katılmıřtır. Ayrıca Japonya'da iki milyondan fazla engelli insanın yařadığını ve felli hastaların popölasyonun fiziksel engelli kiřilerin %50'sini oluřturduđunu belirtmiřlerdir. Bununla beraber, el ile birlikte dilin, hareket kabiliyetinin en yüksek organ olduđunu ve omurilik yaralanmalarında dahi hareket kabiliyetini koruyabildiğini belirtmiřlerdir.

Diđer bir alıřmada Draghici, O. ve ark. ađız-pedi (MouthPad) isimli bir dil-bilgisayar arayüzü modeli geliřtirmiřlerdir [62]. Bu modelde, dilin konumunu ve hareketini bilgisayar ekranına yansıtarak komutların fare imleci hareketlerine çevrilmesi sađlanmıřtır. Sistem, üst-damađa yerleřtirilen bir ađız-ii elektrot dizisi ve hedef bilgisayarla iletiřim sađlayan bir yerleřik kontrol cihazı kullanmaktadır. Dilin konumu ve hareketi, dilin ucu ve elektrot dizisi arasındaki temas empedansı ölçülerek tespit edilir. Sistem, dil hareketlerinin, fare imleci hareketlerine dönüřtürölmesini desteklemek için kolaylıkla geniřletilebilecek bir bilgisayarın dokunmatik yüzeyine benzer bir řekilde tasarlanmıř ve bir bilgisayarın kontrol edilmesi amacıyla tıklamalar yapılarak uygulanmaktadır. Aynı arařtırmacılar 2014 yılında yaptıkları bařka bir alıřmada, ađız-pedi isimli alıřmalarının performansını, altı sađlıklı birey üzerinde ok yönlü bir nokta seme görevi kullanarak denemiřlerdir [63]. Elde edilen sonular gerek joyistiklerle neredeyse aynı olarak rapor edilmiřtir.

Nakatani, S. ve ark. önerdikleri sistemde, ağız boşluğundaki EMG sinyallerini ölçerek dil hareketlerini tahmin etmeye çalışmışlardır [64]. Sağlıklı bir katılımcı, dili dört yönde (ileri, geri, sola ve sağa) hareket ettirdiğinde dış-klibi üzerindeki dört ağız-içi EMG kanalı ölçülmüştür. Her EMG kanalı için frekans bantlarında sinyal gücü elde edilmiştir. Dil hareketlerini bu dört harekete ayırmak ve dinlenmek için en küçük kareler olasılıklı sınıflandırma (LSPC) kullanılmış ve %87,7'lik bir sınıflandırma başarısına ulaşılmıştır.

Johansen, D. ve ark. çalışmalarının amacının, robotik / protez el ve kollarını kontrol etmek için indüklenen dil kontrol sisteminin (ITCS) kullanımının fizibilitesini araştırmak olduğunu belirtmiştir [65]. Bu çalışmada, standart EMG sinyalleri ve ITCS'yi bir arada kullanarak robotik el için kontrol yöntemi sunulmuştur. İstenen işlevi etkinleştirmek için zaman ya da kavrama performans ölçütü olarak kullanılmıştır. İki kontrol şeması performansının karşılaştırılmasında istatistiksel olarak belirgin farklılıklar bulunmuştur. Ortalama olarak, ITCS kontrolü, EMG kontrol şemasından 1,15 sn daha hızlıdır ve aktivasyon süresinde %35,4'lük bir azalmaya karşılık geldiği belirtilmiştir. İncelemeler, ITCS kontrol yöntemi kullanılmasının, geleneksel bir EMG kontrol yöntemine kıyasla özel kavramaların veya fonksiyonların daha hızlı aktivasyonuna izin verebileceğini göstermektedir. Özellikle iki taraflı amputeler için, ITCS kontrol yönteminin protez kontrolü üzerinde belirgin bir etkiye sahip olabildiği gösterilmiştir.

Yang, H. ve ark. motor düşüncesi-hayali (MI) tabanlı beyin-bilgisayar arayüzü sistemlerinin rehabilitasyon amaçlı kullanılabileceğini belirtmişlerdir [66]. İlgili çalışmada disfaji rehabilitasyonu (Dysphagia Rehabilitation) için EEG sinyallerinden yutmanın motor görüntülerini saptayarak engelli bireyler için yeni bir yöntem önerilmektedir. Bununla beraber boyun altına yerleştirilen elektrotlar ile dil-hareketlerine bağlı olarak EMG sinyali ölçümleri alınmış ve EEG sinyalleri ile kıyaslaması yapılmıştır. Sınıflandırıcı olarak SVM kullanılmıştır. Literatürdeki diğer yöntemlere göre başarı oranı %8,02 artmıştır.

Sasaki, M. ve ark. istemli dil hareket sinyallerini, engelli arayüz çalışmalarında kullanmak üzere çene altına konulan dokuz EMG elektrotu kullanarak Suprahoid kas aktiviteleri üzerinden elde etmişlerdir [67]. Sınıflandırıcı olarak yapay sinir ağları kullanılmıştır ve %95 başarı oranı elde edilmiştir. Sasaki, M. ve ark. diğer bir çalışmada, Suprahoid kas aktivitelerinin gerçek zamanlı EMG ölçümünü istemli dil hareketleri esnasında almışlar ve yapay sinir ağları ile sınıflandırmışlardır [68]. RMS metodu özellik çıkarma işlemi için kullanılmıştır. 36 elektrot ile alınan ölçüm 100, 200, ve 300 örnekle özellik çıkarma işleminin ardından 108 özellikli veri kümesine dönüşmüştür. Daha sonra temel bileşen analizi (PCA) ile veri boyutu 10'a azaltılmıştır. Beş sağlıklı katılımcıdan 3 istemli dil hareketi esnasında ölçüm alındığı ve %97'ye varan sınıflandırma sonucunun elde edildiği bildirilmiştir.

Aynı araştırmacılar 2016 yılında yine EMG sinyallerine bağlı dil-arayüzünü geliştirmişlerdir [69]. Bu çalışmada yine Suprahoid kasları üzerinden altı istemli dil hareketi, kullanılan 22 elektrot ile EMG sinyali üzerinden ölçülmüştür. RMS ve Cepstrum katsayıları özellik çıkarmak için kullanılmış ve SVM algoritması ile örüntü tanıma işlemi gerçekleştirilmiştir. Çalışmaya beş sağlıklı katılımcı katılmış ve %95,1 oranında sınıflandırma başarısı görülmüştür. Bu çalışma EMG sinyallerinin çene altından ölçülmesinin, yutma, çiğneme veya konuşma gibi kullanıcı etkinliklerini engellemeyeceğini ve bu yüzden yardımcı cihazların kontrolü için istemli dil hareketleri sayısının ve performansının yeterli olduğunu belirtmişlerdir.

İlgili literatürde diğer önemli çalışmalar içinde, dil hareketi düşüncesi-hayali, diğer motor düşüncesi-hayali (MI) fonksiyonları ile beraber kullanılarak beyin-bilgisayar arayüzü BCI modelleri geliştirilmiştir. Obermaier, B. ve ark. bir çalışmada, bilgi transfer oranının (ITR) BCI'lardaki değişimini araştırmışlardır [70]. Bu çalışmada katılımcılardan sol el, sağ el, ayak, dil hareketi ve aritmetik operasyon düşünceleri esnasında ölçüm alınmış ve BCI'lar için sınıflandırma işlemi yapılmıştır. EEG sinyallerindeki örüntü bant güç değerlendirmesi ve HMM kullanılarak gerçekleştirilmiştir. Sınıflandırma işlemi ikili, üçlü, dördü ve beşli kombinasyonların sınıflandırmasını içermektedir ve ITR sonuçları buna bağlı olarak değerlendirilmiştir. Elde edilen bilgi transfer oranları, deneme başına 0,42 ila 0,81 bit arasında

değişmektedir ve bir BCI sistemi için farklı zihinsel görevlerin üst sınırının üç olduğunu ortaya koymaktadır.

Diğer bir çalışmada Arbabi, E. ve ark. sol küçük parmak ve dil ile iki sınıflı BCI modeli gerçekleştirmişlerdir [71]. Çalışmada BCI modeli içinde hangi zaman alanı özellik çıkarma metodunun daha iyi performans gösterdiği Bayes ve SVM algoritmaları kullanılarak araştırılmıştır. Böylece, her bir sınıflandırıcının en etkili özellik çıkarma işlemini kullanarak sırasıyla, %89,21 ve %91,01 sınıflandırma doğruluğu elde edilmiştir.

2007 yılında yapılan başka bir çalışmada, Dias, N.S. ve ark. sağ el, sol el, her iki ayak ve dil motor düşüncelerini BCI modeli için örüntülerini EEG sinyalleri üzerinden ayırt etmeye çalışmışlardır [72]. Adım-adım ayırmacı (Discriminant Stepwise) ve PCA-LDA tabanlı iki tip sınıflandırıcı denemişlerdir. 3 katılımcıdan 21 elektrot ile ölçüm alınmış ve adım-adım ayırmacı metodunun PCA-LDA tabanlı sınıflandırıcıdan daha iyi olduğu görülmüştür.

Miller, K.J. ve ark. elektrokortikografik (ECoG) dizilerini kullanan güncel BCI'ların, gerçek veya düşünsel-hayali motor hareketi ile ilişkili spesifik spektral bantlarının gücüne dayandığını belirtmişlerdir [73]. BCI modellerinde motor hareketler sırasında ECoG sinyallerinde spektral değişiklikler gözlemlendiğini ve klasik gamma bandının (30–70 Hz) davranış bozukluğu sergilediğini belirtmişlerdir. Bu gerçekliği dil ve el düşünsel hareketleri esnasında ölçerek, sınıflandırma doğruluğunun sınırlandırıldığını göstermişlerdir. Araştırmada dil ve el arasındaki iki sınıflı ayırt etme başarısında dil düşünsel hareketi-el düşünsel hareketini ayırt etmenin, dil düşünsel hareketi-dinlenme ve el düşünsel hareketi-dinlenme başarılarına göre yüksek olduğu görülmüştür.

Akıncı, B. ve ark. diğer bir çalışmada motor hareket düşünceleri-hayali EEG verilerinin sınıflandırılmasında sol el, sağ el, ayak ve dil hareket hayal durumlarını kullanmışlardır [74]. Sınıflandırmada yaygın mekansal modeller (CSP) yöntemi ve zamansal filtreler (Temporal Filters) kullanılmış ve sınıflandırmadaki doğruluğu

geliştirmek için 4-sınıf motor düşünceleri üzerinde ortak seyrek spektral mekansal modeller (CSSSP) yöntemi denenmiştir. Sonuç olarak %93,33'e varan sınıflandırma doğruluğu elde edilmiştir.

Diğer bir çalışmada, Xiao, D. ve ark. EEG sinyallerinin düşük sinyal-gürültü oranına sahip olduğunu bu sebeple enerji entropi (Energy Entropy) yöntemini kullanarak ön işleme gerçekleştirdiklerini belirtmişlerdir. Böylece Fisher sınıf ayırma kriteri ile dört motor düşünsel hareketini (sağ el, sol el, ayak ve dil) sınıflandırmışlardır [75]. Üç katılımcıdan elde ettikleri altı kombinasyonel tip veri kümesinin ortalama sınıflandırma doğruluğunu %85 olarak elde etmişlerdir. Aynı araştırmacılar 2010 yılında yaptıkları diğer bir çalışmada, yine dili içeren dört motor düşünsel-hayali hareket için ön işleme yöntemi olarak kör kaynak ayırma (BSS) kullanmışlardır [76]. Özellik çıkarma işlemi için Fisher uzaklık (Fisher Distance) yöntemini ve sınıflandırıcı olarak yapay sinir ağlarını ilgili veri setleri üzerinde uygulayarak ortalama başarıyı %80 olarak elde etmişlerdir.

Ming, D. ve ark. bir çalışmada, motor düşünsel hareketleri esnasında oluşan senkronizasyonda, olay ile ilgili uyumsuzluk (ERD) ve olayla ilişkili senkronizasyon (ERS) ile sonuçlanan akılsal görevlerin, genellikle beyin-bilgisayar arayüzü modellerinde incelendiğinden bahsetmişlerdir [77]. Bu çalışmada sol el, sağ el, ayak ve dilin motor düşünselleri tarafından uyarılan ERD / ERS yanıtını analiz edip sınıflandırdıklarını belirtmişlerdir. Sinyalleri filtrelemek için bağımsız bileşen analizi (ICA) yöntemini kullandıktan sonra özellik çıkarmak için PSD metodunu kullandıklarını belirtmişlerdir. SVM ile yapılan sınıflandırmada en yüksek sonuç %91,4 olarak elde edilmiştir.

Bao, X. ve ark. diğer bir çalışmada dört motor düşüncesi üzerinden biometrik kimlik tanıma sınıflandırması yapmışlardır [78]. Sağ el, sol el, ayak ve dil hareketi arasında en yüksek sonucu veren motor düşüncesinin dil olduğu görülmüştür. Enerji spektral yoğunluğu ve doğrusal kompleks değeri, EEG sinyalleri üzerinden özellik çıkarmada kullanılmıştır. Yapay sinir ağında en yüksek %90,6 doğruluk dil hareketi düşüncesi

ile bulunurken diğer motor fonksiyon düşünceleri %80 civarında doğruluk ile elde edilmiştir.

Johnson, A.N. ve ark. bir araştırmada, dil-sürücü sistemi içinde (TDS) dil ve el hareketlerinin beraber kullanılabilceği bir model önermişlerdir [79]. Bu modelde dil hareketlerinin dil üzerine konulan manyetik izleyici ve baş hizasına konulan sensörler ile takip edilebildiğini belirtmişlerdir. Çalışmanın amacının, eş zamanlı motor veya bilişsel görevlerin TDS teknolojisini kullanarak el ve dil arasındaki basit hareket kontrolünün çeşitli yönleri üzerindeki etkisini karşılaştırmak olduğunu belirtmişlerdir.

Tyler, M.E. ve ark. multipl skleroz (MS) hastalarındaki yürüme bozukluklarını azaltmak için yaptıkları çalışmada dil üzerinden uyararak için bir sistem geliştirmişlerdir [80]. Dil, kranial sinirler yoluyla beyne bağlandığından dili elektriksel olarak uyarmanın beyindeki plastisiteyi arttırabildiğinden bahsetmişlerdir. Bu sebeple kontrol grubu ve deney grubu olmak üzere yürüme güçlüğü çeken 12 MS hastası üzerinde 14 haftalık rehabilitasyon eğitimi yapılmıştır. Çalışmanın sonuçları dil tabanlı sinir uyarılmasının yürüme güçlüğü çeken MS hastalarını iyileştirdiğini göstermektedir.

Khorshidtalab, A. ve ark. BCI'lar için motor düşüncelerinin sınıflandırılmasının önemli olduğunu belirtmişlerdir. Bu sebeple sağ el, sol el, ayak ve dil hareket düşünce sinyallerini EEG üzerinden ölçüp sınıflandırdıklarından bahsetmişlerdir [81]. Çalışmada işlem karmaşıklığını azalttığı için zaman-alanı özellik çıkarma yöntemleri, SVM ile beraber kullanılmıştır. Bu özellik çıkarma işlemleri şunlardır; ortalama mutlak değer (MAV), maksimum tepe değeri (MPV), basit kare integral (SSI), Willison genliği (WA) ve dalga biçimi uzunluğu (WL). En yüksek başarı WA ve SVM yöntemleri ile %95,1 doğrulukta bulunurken, en düşük başarı WL ve SVM yöntemleri ile %31,67 doğrulukta elde edilmiştir.

Ghosh, P. ve ark. yaptıkları çalışmada temel amaçlarının, beynin bölümlerinin aktivasyonunu, grafik teorisi yardımıyla üç tipte motor düşünce görevini yerine

getirirken anlamak olduğunu belirtmişlerdir [82]. İnsan beyninin, özel fonksiyonlara ve farklı bölgelere sahip bir grafik ağı olarak düşünülebileceği ve bu bölgeler arasında sanal işlevsel bir bağlantının mevcut olduğunu belirtmişlerdir. Bu bölgelerin düğüm olarak kabul edildiği ve fonksiyonel bağlantıların, aralarındaki kenarlar olarak kabul edildiğini bildirmişlerdir. Bu işlevsel bağlantıların yoğunluğunun, belirli bir görevi yerine getirirken lobların aktivasyonuna bağlı olduğunu anlatmışlardır (örneğin motor düşünceleri, bilişsel görevler ve benzer şekilde). Grafiğin iki göstergesi, yani ağ yoğunluğu ve düğüm mukavemeti, tüm beyin loblarını kaplayan kişinin kafasına yerleştirilen 32 elektrot için hesaplanır ve daha yüksek yoğunluktaki düğümler olarak tanımlanır. Eğer bu gösterge değerlerinin her ikisi de karşılaştırılırsa, dil için güç bileşenlerinin temporal, frontal ve parietal lobların kuvvetinin merkezi bölgeden daha yüksek olduğunu kolaylıkla görülebildiğini göstermişlerdir.

Diğer bir çalışmada Gong, A. ve ark. motor düşünceleri görevleri tarafından ortaya konan beyin ağını istatistiksel analiz ve topolojik özelliklerin analizini kullanarak araştırmış ve 4-sınıf MI görevleri (sağ el, sol el, ayak ve dil hareketi) sırasında reaksiyon seviyesinde, reaksiyon süresinde ve aktive edilen hedefte önemli farklılıklar gözlemlemişlerdir [83]. Farklı görevler sırasında yürütme ve istirahat halleri arasındaki reaksiyon seviyesinde büyük bir fark olduğunu belirtmişlerdir. Sol el MI görevinin reaksiyon seviyesinin sağ el, ayak ve dil MI görevlerine kıyasla daha yüksek seviyede olduğunu gözlemlemişlerdir. Görevleri gerçekleştirmek için gereken tepki sürelerinin de farklı olduğunu belirtmişlerdir. Sol el ve sağ el MI görevleri sırasında, deneklerin beyin ağları derhal ve kuvvetle tepki gösterirken, ayaklar ve dil MI görevi sırasında bir gecikme olduğunu ortaya koymuşlardır.

Marjanovic, N. ve ark. konuşma güçlüğü çeken insanlar için damak üstüne konulan dil-dokunma arayüzü üzerindeki klavye ile iletişim kurmaya yarayan bir sistem geliştirmişlerdir [84]. Bu sistemde, dilin ucu ile harfler seçilir ve daha sonra kablosuz olarak aktarılan kelimeler ve cümleler sesli konuşma diline çevrilmektedir.

Park, H. ve ark. iTDS ile engelli insanların yaşamlarını kolaylaştırmak için bir arayüz çalışması geliştirmişlerdir [85]. Bu çalışmada iTDS, tek bir entegre sistemi (SoC) üzerinde tasarımı yapılmıştır. iTDS, dört köşesinde bulunan dört adet 3 eksenli manyetik sensör, ağızdaki manyetik alan varyasyonlarını okuyabilen uyumlu bir analog ön uç (AFE) özelliğine sahiptir.

Viseh, S. ve ark. eTDS arayüzü çalışmalarda sistemin başın üstüne yerleştirilmesinden dolayı denge ve sağlamlık yönüyle dışardaki kullanımlarda problemlere sahip olabildiğinden bahsetmiştir [86]. Bu sebeple geliştirdikleri sisteminin diş tutucusu şeklindeki iTDS yapısı üst dişlere sıkı bir şekilde yapışır ve sağlamlık sağlar. Bununla birlikte, iTDS'nin boyutları üzerinde daha fazla kısıtlama vardır, bu da batarya boyutunu sınırlandırır ve sonuç olarak, tek bir şarjla iki günlük uzun bir süre boyunca çalışacak şekilde güç tüketiminde önemli bir azalma olmasını gerektirir. Böylece bu çalışmada, sensörlerden sonra verici tarafındaki tüm sinyal işlemlerini gerçekleştiren TDS için ultra-güçlü bir yerel işlemci önerilmiştir. Artırılmış tasarım, alan programlanabilir kapı dizisi (FPGA) üzerinde uygulanmaktadır.

Literatür özetinde görüldüğü üzere dil hareketleri, dil-tabanlı makine arayüzü çalışmaları ile genel olarak dil üzerine ve ağız içi-çevresine yerleştirilen sırasıyla manyetik indükleyiciler, sensörler ve veri aktaran elektronik yapılar ile algılanmaktadır. Bu yaklaşıma ait çalışmaların en önemli avantajı yüksek doğruluk oranı ve çok modlu-boyutlu kontrol sistemlerini içerebilmesidir. Bu tip donanımsal çalışmalar doğruluk, veri aktarım oranı gibi sınıflandırmaya ait sonuçları yüksek çıkarmakla beraber, engelli bireyler için rahatsızlık verici, hijyenik olmayan ve hatta tıbbi operasyon gerektiren yaklaşımları ortaya koymaktadır. Literatürde karşılaşılan diğer önemli çalışmalar içinde dil-hareketi kulak basıncı öne çıkmaktadır. Bu yaklaşımda dil üzerinde veya ağız içinde herhangi bir elektronik ekipman bulunmamaktadır. Bununla beraber, dil hareket örüntüsünün kulak kanallarında oluşan basınç ile ölçülmesi sebebiyle kulak içine konulan basınç sensörlerinin engelli bireylerin dinleme ve işitme performanslarına olumsuz etki ettiği görülmektedir. Diğer bir grup çalışma içerisinde dil motor hareket düşüncesi, BCI çalışmalarıyla

beraber el ve ayak gibi uzuvların motor hareket düşünceleri ile kullanılmış ve çok modlu kontrol arayüz çalışmaları yapılmıştır. Bu yaklaşım geleneksel BCI çalışmaları ile benzer sorunlara sahip olmakla beraber sınıflandırma doğruluğu ve veri iletim transferi açısından donanımsal tabanlı ve kulak hava basıncı tabanlı dil-makine arayüzü çalışmalarından daha düşük performans sergilediği görülmüştür.


İlgili bu tez çalışması içerisinde sinyal işleme tekniklerinin ve makine öğrenmesi algoritmalarının başarısını araştırmak ve karşılaştırmak suretiyle glossokinetik potansiyel sinyallerinden faydalanarak doğal, güvenilir ve yüksek başarı sonuçlarına sahip 1-boyutlu kontrol için GKP tabanlı dil-makine arayüzü geliştirilmiştir ve ilgili literatüre katkıda bulunulmuştur. Tez çalışmasının ilk aşamasında SVM, LDA ve kNN algoritmalarının performansları, ortalama karesel kök (RMS), standart sapma (STD), varyans (VAR) ve ortalama değer (MV) özellik çıkarma yöntemlerini kullanarak elde edilmiştir [3]. Zaman alanındaki özellik çıkarma yöntemleri ile en iyi katılımcıda %99'a varan sınıflandırma başarısına SVM algoritması ile ulaşılmıştır. Tez çalışmasının ikinci aşamasında MLNN ve PNN yapay sinir ağları yöntemleri RMS ve güç spektral yoğunluğu (PSD) özellik çıkarma metotları ile beraber kullanılmıştır [9]. Zaman ve frekans alanındaki özellik çıkarma işlemlerinin ve yapay sinir ağları başarılarının elde edildiği bu çalışmada %97,25'a varan en iyi sonuç MLNN ve RMS ile elde edilmiştir. Bununla beraber tez çalışması içerisinde ortalama mutlak değer (MAV), maksimum tepe değeri (MPV) ve şekil faktörü (SF) özellik çıkarma metotları, temel bileşen analizi (PCA), bağımsız bileşen analizi (ICA) ve ayırık dalgacık dönüşümü (DWT) ön işleme yöntemleri ile beraber kullanılmıştır. Ayrıca konvolüsyonel sinir ağında bireysel ve ortalama sınıflandırma doğrulukları %97-%99 arasında elde edilmiştir. CNN mimarisi ile elde edilen bu yüksek başarı oranının, glossokinetik potansiyel tabanlı dil makine arayüzü tez çalışmasında oldukça önemli olduğu düşünülmektedir. Böylece engelli bireylerin yardımcı teknolojileri, GKP tabanlı TMI ile doğal, kullanımı kolay, hijyenik ve güvenilir olarak kontrol edebileceği ve çevresiyle daha sağlıklı iletişim kurarak yaşam standartlarını arttırabileceği düşünülmektedir.

BÖLÜM 2. İSTEMLİ DİL HAREKETİ VE GLOSSOKİNETİK POTANSİYEL SİNYALLERİ

Dil makine arayüzü (TMI), istemli dil aktivitelerinin harici cihazları veya bilgisayarları kontrol etmesini sağlayan bir donanım ve yazılım kombinasyonu olarak tanımlanır. Amaç, ağır engelli insanların hayatlarını olabildiğince düzenli bir şekilde yaşamasına yardımcı olmaktır. Bu amaçla geliştirilen yardımcı teknolojileri kontrol etmek ve dış dünya ile iletişim kurmak için birçok çalışma yapılmıştır. Bu tez çalışmasında 1-D kontrol için doğal, kullanımı kolay, güvenilir, başarı oranı yüksek ve engelli bireylere rahatsızlık vermeyen glossokinetik potansiyel tabanlı bir dil-makine arayüzü geliştirilmesi hedeflenmiştir. Bu doğrultuda makine öğrenmesi (ML) algoritmaları başta olmak üzere diğer sinyal işleme yöntemleri, glossokinetik potansiyel sinyallerini işlemede ve TMI modeli oluşturmada kullanılmıştır.


2.1. Glossokinetik Potansiyel Sinyal Oluşumu

Glossokinetik potansiyel (GKP) sinyalleri, dil ucunun ağız içindeki dokuya temasında kafa derisi üzerine yerleştirilen elektrotlarla ölçülebilen ve dil hareketlerini içeren elektriksel yanıtlardır. Bu tez çalışmasında, dil-makine arayüzünü geliştirmek için kafa derisi üzerinden ölçülen dil hareketlerini izlemeye yönelik uzamsal örüntüsünü (Spatial Patterns) incelediğimiz GKP'nin farklı bir yönü vurgulanmaktadır. Şekil 2.1.'de ağız içindeki dil yapısı görülmektedir.



Şekil 2.1. Ağız içindeki dil yapısının şematik gösterimi [14]

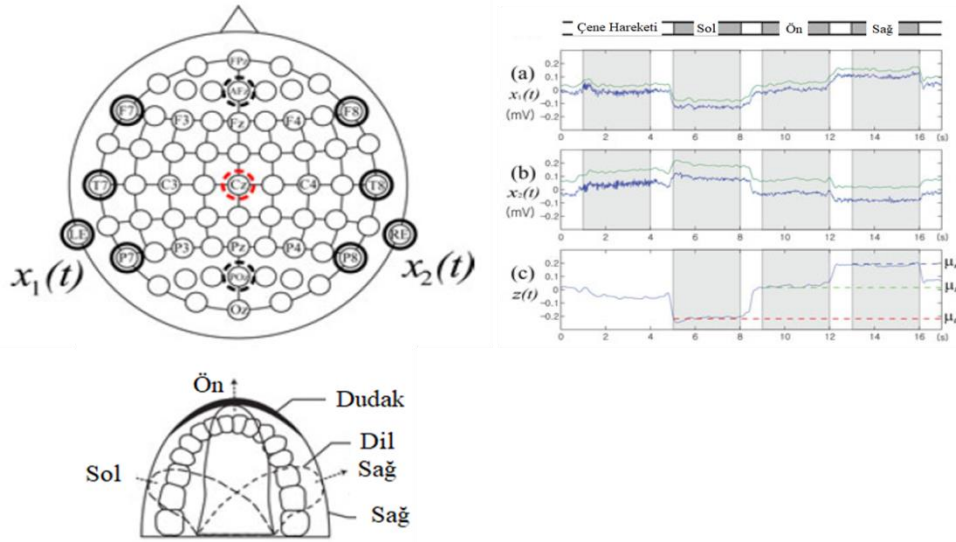
Dilin ucu, dil köküne göre negatif bir elektrik yüküne sahiptir. Bu nedenle dilin ucu, ağız içindeki dokulara temas ettiğinde, deşarj olayı, temas noktasına yakın potansiyel seviyeleri azaltır [3], [9], [13], [19]. Dil hareketlerini izlemek için önemli bir özellik olan temas pozisyonunun dil hareketine göre ters olarak tanımlanabileceği, dil hareket yönünün azalan GKP potansiyelinin uzamsal örüntülerini analiz ederek elde edilebildiği görülmektedir. Temas noktasından yayılan negatif elektrik alanı ve uyarılmış potansiyel temas noktasında maksimum düşüşü gösterirken, etkisi noktadan uzaklaştıkça azalır. Böylece, Şekil 2.2.'de görüldüğü üzere bir katılımcı EEG kaydı sırasında kendi dilini hareket ettirirse, üretilen elektrik alanı yüz cildine ve kafa derisine yayılmaktadır.



Şekil 2.2. Dil hareketine bağlı dil ucunun dokunması esnasında yüz ve kafa derisi üzerindeki potansiyel değişimin topografik gösterimi [23]

GKP sinyalleri, serebral olmayan (Noncerebral) bir bölgeden kaynaklandığından, beyin aktivitelerinin gözlemlenmesini engelleyebilir. Bundan dolayı, GKP, kayıt sırasında önlenmesi gereken veya ön işleme aşamasında aktif olarak çıkarılmış bir sinyal artefaktı olarak kabul edilmiştir. Bazı araştırmacılar dil hareketleri esnasında alınan kayıtlarda EEG sinyallerinin değiştiğini gözlemlemişlerdir. Böylece artefakt olarak görülen GKP için yeni bir uygulama alanı keşfetmişlerdir. Yani, dil, yanak duvarı ile temas halinde kalırken sol tarafa hareket ederse, sol yarımküredeki potansiyel seviyeler azalır ve sağ bölgedekiler artar ve bunun tersi de geçerlidir. Bu fenomen, dil üzerindeki yükün yarattığı elektrik alanıyla kolayca açıklanabilir. Negatif yüklü dil sol tarafa doğru hareket ederse, sol yarımküredeki elektrotların

potansiyelleri yavaş yavaş azalacak ve sağ yarımküredeki potansiyeller orantısal olarak artacaktır. Aynı araştırmacılar, bu fenomene dayanarak, ölçülen GKP seviyelerini dilin yatay konumuna göre analiz etmek ve yeni bir dil-makine arayüzü (TMI) uygulamak için doğrusal bir model geliştirmişlerdir [14]. Oluşturulan doğrusal modelde GKP sinyalini daha ayırt edici olarak elde etmek için kulak uçları üzerinden sinyal kaydı almışlardır. Dil, sağ-ön-sol veya tersi bir sıralamada yanak duvarlarına değdirilmek suretiyle GKP sinyal değişimi elde edilmiştir. Şekil 2.3.'te GKP sinyalini doğrusal olarak elde etmek için elektrot yerleşimi, dil hareket sıralaması ve doğrusal GKP sinyali oluşumu görülmektedir.



Şekil 2.3. Doğrusal GKP sinyali elde etmek için gerçekleştirilen elektrot yerleşimi, dil hareketi ve doğrusal sinyal gösterimi. $z(t)$ her iki elektrottaki ($x_1(t)$, $x_2(t)$) sinyalin farkı alınarak elde edilmiştir [13]


2.2. Glossokinetik Potansiyel Sinyalleri ve EEG İlişkisi

EEG'deki artefakt problemleri, kayıt sırasında aktif olarak ortadan kaldırılabildiği gibi off-line sinyaller üzerinde özel olarak oluşturulmuş uzamsal filtreler kullanılarak da gerçekleştirilebilir. Dilin ve ağızın kaba hareketlerinin, sıklıkla glossokinetik potansiyel olarak adlandırılan ve EEG potansiyelleri üzerine etki edebilen dil hareketlerinden kaynaklandığı belirtilmiştir. Bu nedenle GKP sinyallerinin yavaş dalga yanıtı olarak tanımlanabildiği görülmektedir. Dilin ucu, köke göre negatif elektrik yüküne sahiptir ve eğer dil, bir damak veya bir yanağa dokunursa, kafa derisinde saptanabilen önemli bir deşarj oluşturabilmektedir [14]. Bununla birlikte

Vanhatalo ve ark., iletim yolunun yeniden düzenlenmesinin, bir başka glossokinetik potansiyel kaynağı olabileceğini ileri sürmüşlerdir [23]. Dilin ucu, bir yanağa veya bir damağa değerse, toprak ile referans noktası arasında yeni bir akım yolu yaratılır ve daha sonra bu iletken değişiklik, EEG kanallarının değiştirilmiş potansiyeli olarak gözlemlenebilir. Deneysel verilere dayanarak kan-beyin bariyeri tarafından yönlendirilen ve beyinden dışarı çıkıp ağız çevresindeki kan akışına geri dönen sabit akımın bir modelini önermişlerdir. Böylece bu bulgular, dil hareketlerinin, küresel akım döngüsündeki iletken doku yollarının geometrisini değiştirerek EEG potansiyellerine neden olduğu fikriyle tutarlı olduğunu görmüşlerdir. Böylece yavaş EEG potansiyeli dil pozisyonunda küçük bir değişiklikte tutarlı bir şekilde ilişkiliyse, takip eden yavaş EEG potansiyellerinin, dil hareketlerinden kaynaklanan önemli bir bileşene sahip olabileceğini belirtmişlerdir.

Mevcut sonuçlar ayrıca dil hareket potansiyellerinin, tüm EEG sinyallerinin kortikal yüzeyden kaynaklandığını varsayan kortikal akım kaynağı tahminini etkileyebileceğini göstermektedir.

Vanhatalo ve ark. ayrıca GKP'nin, yük boşalmasını bloke etmek için dilin yüzeyini yalıtım suretiyle yok edilebileceğini Şekil 2.4.'te görüldüğü gibi bildirmişlerdir. GKP sinyalleri, öncelikle EEG analizi kapsamında incelenmiştir. Serebral olmayan bölgeden kaynaklandığından, beyin aktivitelerinin gözlenmesine müdahale edilebilir. GKP, EMG veya EOG'ye kıyasla daha az ilgi çekmiştir, çünkü GKP, EMG veya EOG'ye göre kolaylıkla düzenlenebilmektedir. İlk olarak, GKP, katılımcı tarafından bilinçli bir şekilde bastırılabilir. İstemsiz bir göz-küre hareketi veya gözün kırışması nedeniyle oluşan EOG sinyallerinden farklı olarak GKP, istemli bir dil hareketinden kaynaklanır. Dolayısıyla, katılımcı Parkinson hastalığı ve tümör bozukluğu gibi özel semptomlar göstermedikçe kolaylıkla dil ve buna bağlı olarak GKP sinyalleri düzenlenebilir [13].



Şekil 2.4. Dilin izole edilmesiyle GKP sinyalinin yüz ve kafa derisi üzerinde oluşmasının önlenmesine ait bir gösterim [23]

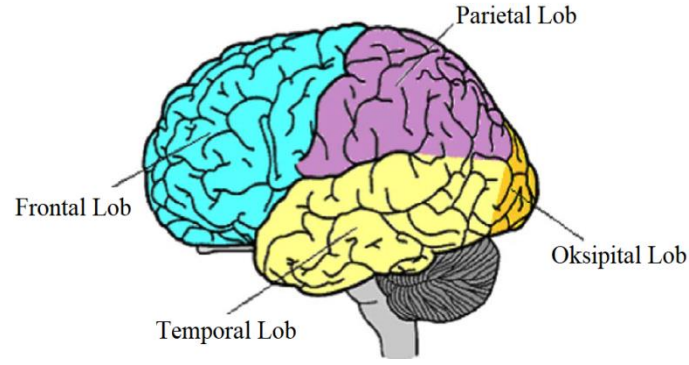
2.2.1. İstemli motor dil hareketine bağlı beyin aktivasyonu ile EEG ve GKP frekans bantları

Beyin, insan vücudunu ve işlevlerini kontrol etmek için birlikte çalışan bir dizi alt sistemden oluşmaktadır. Görme, dokunma, tat alma, duyma ve koku alma gibi işlevlerin değerlendirildiği beyin, dış ortamdan bilgi alabilir. Beynin vücut iç sistemlerinden aldığı bazı başka bilgiler de mevcuttur. Bu kompleks organ, alınan tüm bilgileri analiz edebilir ve eller, bacaklar, gözler, dil gibi vücut bölümlerini doğru bir şekilde kontrol edebilir. Beynin topografik haritalarına dayanarak, beyin bölümlerinin farklı bilişsel işlevlerle ilişkili olduğu keşfedilmiştir [87].

Beyin, genellikle serebral korteks ve subkortikal bölgeler olmak üzere iki ana bölüme ayrılabilir. Subkortikal bölgeler; kalp hızı, vücut ısısı, solunum, korku, öğrenme ve hafıza da dahil olmak üzere duygusal tepkiler gibi temel ve hayati fonksiyonları kontrol eder. Öte yandan, serebral korteks evrimsel açıdan daha yeni kabul edilir. Beynin en büyük ve en karmaşık kısmıdır. Bu bölge, duysal, motor işleme, dil hareketi, örüntü tanıma, planlama ve akıl yürütme gibi daha üst düzey işlevleri kontrol etmektedir. Böylece ilgili beyin bölgesine, BCI araştırmalarının önemli bir bölümü tarafından odaklanılmaktadır [88].

Serebral korteks, iki yarımküreye ayrılır, Şekil 2.5.'te gösterildiği gibi burada her yarımküre, dört lob'a ayrılır: Bunlar; frontal, parietal, oksipital ve temporal loblardır [88]. Parietal lob, heceleme, algılama, nesnelere manipüle etme ve mekansal farkındalık gibi çeşitli işlevlerden sorumludur. Temporal lobun temel işlevleri

şunlardır; konuşma, yüz tanıma, hafıza ve duyguları oluşturmaktır. Bir diğer lob, örgütlenme, planlama, sosyal beceriler, esnek düşünme, bilinçli hareket, problem çözme, dikkat, duygusal ve davranışsal kontrol ile bağlantılı olan Frontal lobdur. Oksipital lob ise, görsel uyaranların yorumlanmasıyla ilişkilidir.




Şekil 2.5. Beyin lobları gösterimi [88]

Sert bir iskelet yapısına sahip olmayan ve kompleks kaslar içeren dil, kranial sinirler ile doğrudan beyne bağlıdır [13], [89]. Bununla beraber konuşma, dikkat ve problem çözme gibi fonksiyonların, istemli dil hareketi esnasında oluşan motor ve zihinsel aktiviteler olması dolayısıyla frontal ve temporal lobların katkıda bulunabileceği düşünülebilir. Fakat dil hareketinin motor fonksiyon olması sebebiyle, sensorimotor korteks (Sensorimotor Cortex) adı verilen frontal lobun hemen arkasında temporal loba doğru uzanan bölge ile ilişkili olduğu literatürde geçmektedir [90].

MI-tabanlı BCI'larda saptanabilir ve güvenilir modeller üretmek için, kortikal alanların yeterince geniş olması gerektiği sonucuna varılmıştır, böylece elde edilen etkinlik yeterince belirgin olur. Beyin korteksi içinde el alanları, ayak alanları ve dil alanı nispeten büyüktür ve topografik olarak farklıdır [91].


Ritmik EEG aktiviteleri belirli frekans bantlarına bölünür. Bu bantların, kafa derisi üzerinde belirli, biyolojik olarak belirgin bir dağılımı olduğu kanıtlanmıştır. EEG frekans bantları altıya ayrılmıştır. Bunlar; delta (Δ), teta (Θ), alfa (α), mu (μ), beta (β), ve gama (γ) frekans bantlarıdır [88]. Delta (Δ), değişken bir genliğe sahiptir ve 1–4 Hz aralığındadır. Delta, derin uyku ve uyanıklık durumları ile ilişkili olan genlikteki en yüksek ve en yavaş dalga olarak görülmektedir. Teta (Θ), 20 μ V'tan

büyük ve 4–7 Hz aralığında olan bir genliğe sahiptir. Teta frekans bantı, çalışmayan anlarda, yaratıcı ilham, uyuşukluk ve derin meditasyon esnasında üretilir. Alfa (α), 8 ile 13 Hz arasında değişim gösteren bir dalgadır. Genellikle dinlenme, konsantrasyon ve bazen dikkat ile ilişkilidir. Mu (μ), motor kortekse göre kaydedilen genliğin maksimum olduğu alfa dalga frekans aralığında bulunur. Mu frekans bandı, motor nöronların çalıştığını gösterir. Beta (β) bandı, uyarı, düşünme, aktif konsantrasyon ile ilişkilidir ve 12 ile 30 Hz arasında oluşmaktadır. Son olarak, gama (γ), somatosensoriyel kortekste (Somatosensory Cortex) 30 Hz'den büyük bir frekansta gözlenir. Ayrıca, tanınan nesnelerin, seslerin veya dokunma duyularının kısa süreli bellek eşleştirmesi sırasında da oluşmaktadır. Delta ve teta frekanslarını içeren EEG sinyallerinin bir gösterimi Şekil 2.6.'da mevcuttur.



Şekil 2.6. Delta ve teta frekans bantlarını içeren EEG sinyalleri [88]

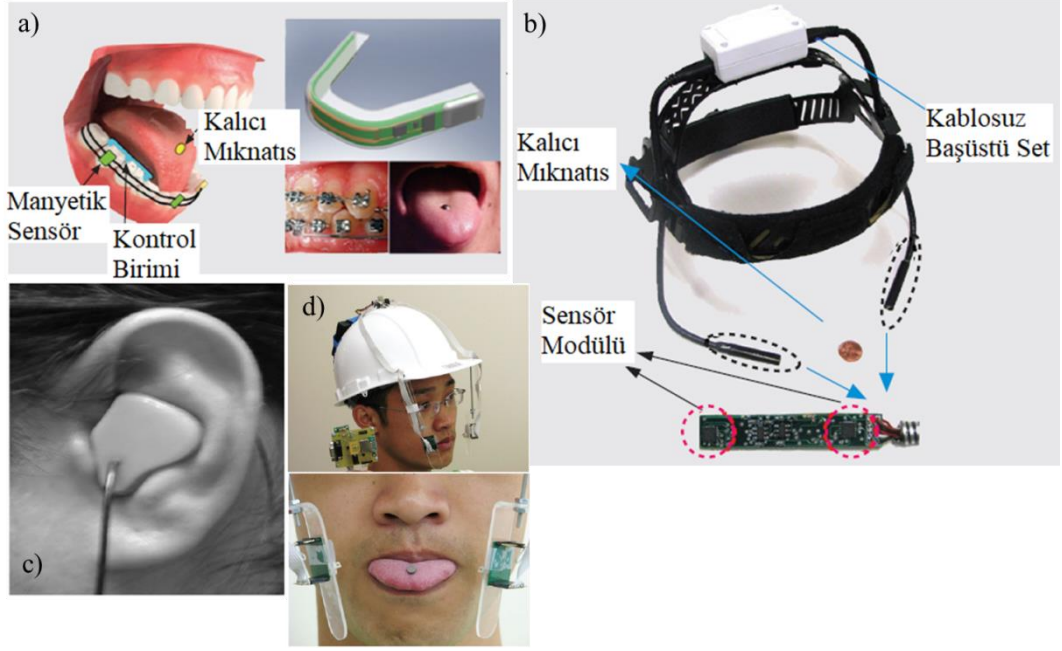
İstemli dil hareketiyle oluşan glossokinetik potansiyel sinyalleri genellikle düşük frekanslarda (delta ve teta bantları) görülmektedir. Dahası, dil hareketi ve doku teması ile oluşan GKP'nin örüntüsü olayla ilişkili potansiyel (ERP) ve yavaş kortikal potansiyel (SCP) gibi bilinen EEG sinyallerinden açıkça ayırt edilebilmektedir [13]. GKP'nin, çeşitli ritmik EEG aktivitelerinin aksine (örn., $\Delta \sim \gamma$ ritimleri) kalıcı DC potansiyel kayması vardır. Genel olarak, bu kayma 0,5 Hz kesme frekansına sahip bir yüksek geçiren filtre ile kolayca çıkarılabilir. Bunlara ek olarak, GKP'nin sahip olduğu genlik ölçeği birkaç 10 μ V aralığı içerisindeydir. Kafa derisi üzerinden ölçülen istemli dil hareketiyle üretilen GKP sinyallerinin voltaj farkı 25-80 μ V arasında değişmektedir [13]. ERP tabanlı EEG sinyali ise sadece 2 μ V ila 20 μ V arasında değişen genlik gösterir. Tez çalışması için kafa derisi üzerinden istemli dil hareketi esnasında ölçülen GKP sinyallerine ait örnek bir görüntü Şekil 2.7.'de görülmektedir.



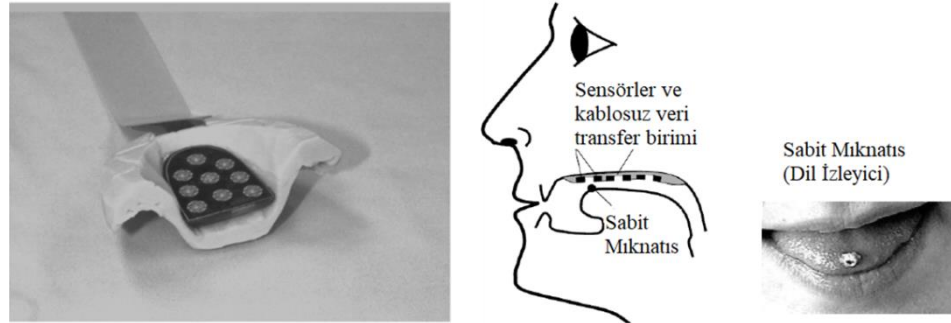
Şekil 2.7. Tez çalışması için yanak duvarına istemli ve ardışık hareketlerle dokunan dilin oluşturduğu GKP sinyallerinin, 6 sn boyunca kafa derisi üzerinden kaydedilen görüntüsü (Genlik: $\pm 80 \mu\text{V}$ civarında)

2.3. Dil-Makine Arayüzü ve Beyin-Bilgisayar Arayüzü Çalışmalarındaki Geleneksel Problemler

Literatürde var olan dil-makine arayüzü çalışmaları dil-sürücü sistemi (TDS), indüklenen dil-bilgisayar arayüzü (ITCI), ağız-dokunma arayüzü (OTI) sistemi ve dil hareketi kulak basıncı (TMEP) üzerine yoğunlaşmaktadır. Bu sistemlerden TDS ve ITCI sistemleri dil üzerine yerleştirilen kalıcı mıknatıs ve ağız içine veya başüstüne yerleştirilen manyetik sensör dizilerinden oluşmaktadır. OTI sistemlerinde ise dil ucu (ToT) ile damak (Palate) üstüne yerleştirilen kablosuz ağız-pedi veya klavyesi ile kontrol ve iletişim sağlanmaktadır. TMEP sistemlerinde ise dil hareketi esnasında oluşan kulak içindeki basınç değişimi sinyallerinin örüntüsü tanımlanarak yardımcı cihazları kontrol etmek mümkündür. Donanımsal dil makine arayüzü çalışmalarının en temel problemleri şunlardır: Ağız içinde ve dışında çeşitli elektronik ekipmanlar olduğu için engelli insanlar için rahatsız edicidir ve hijyenik değildir. Bununla beraber özellikle ağız içindeki veya kulak içindeki bu ekipmanlar engelli insanların yemek yeme, nefes alma, konuşma ve dinleme gibi gündelik fonksiyonları ve ihtiyaçları yerine getirmesinde sıkıntılar yaratabilmektedir. Donanımsal dil-makine arayüzü sistemlerine yönelik bazı çalışmalar Şekil 2.8.'de ve Şekil 2.9.'da gösterilmiştir.




Şekil 2.8.a) iTDS sistemine ait bir gösterim [1] b) eTDS sistemine ait bir gösterim [1] c) TMEP sistemine ait bir gösterim [43] d) TDS sistemine ait başka bir gösterim [27]



Şekil 2.9. a) OTI sistemine ait bir gösterim [18] b) ITCI sistemine ait bir gösterim [38]

Beyin bilgisayar arayüzü sistemleri, dil makine arayüzü sistemleri gibi engelli veya felçli insanların normal kas vücut hareketleri ile kontrol edemedikleri cihazları doğrudan beyin sinyalleri vasıtasıyla kullanmalarını sağlayan teknolojilerdir [88]. BCI'lar, protezlerin, robotların ve yardımcı teknolojilerin zihinsel niyetlerle kontrol edilebildiği sistemlerdir [91]. Sinyal elde etmede invazif (Invasive) ve invazif olmayan (Non-Invasive) türleri mevcuttur. Bununla beraber, zihinsel kontrol sinyalleri olarak EEG sinyalleri; görsel olarak uyarılmış potansiyeller (Visually Evoked Potentials), P300 sinyali, motor ve sensorimotor ritimleri (Motor and Sensorimotor Rhythms), motor hareket düşüncesi (Motor Imagery), bilinçsel görevler (Cognitive Tasks) ve yavaş kortikal potansiyel (Slow Cortical Potential)

olarak bilinmektedir [88]. BCI sistemine ait örnek bir görüntü Şekil 2.10.'da görülmektedir.



Şekil 2.10. BCI ve robotik kol kullanımına ait örnek bir gösterim [92]

Geleneksel BCI sistemleri, EEG sinyallerinin doğasından kaynaklanan bazı problemlere sahiptir. Bunlar EEG sinyallerinin doğrusal olmayan (Non-linearity), durağan olmayan (Non-stationarity) yapısından ve düşük sinyal-gürültü oranına (Signal-to-Noise Ratio) sahip olmasından kaynaklanmaktadır [88]. Bununla beraber, senkron BCI modellerinde her an için kontrol etme gereksinimi ve buna bağlı olarak ortaya çıkan kontrol kaybı (LoC) ve çok kanallı EEG ölçümlerinde ortaya çıkan özgürlük derecesi (DoF) problemleri gözlenmektedir [3]. Engelli katılımcılar için uzun eğitim zamanı (Training Time) ve sürekli yüksek bilişsel efora (Cognitive Effort) bağlı zihinsel yorgunluk problemleri de mevcuttur. Bununla beraber katılımcıdan-katılımcıya (Subject-to-Subject) veya çoklu-katılımcı (Inter-Subject) ve oturumdan-oturuma (Session-to-Session) veya çoklu-denemelerde (Inter-Trial) değişen sınıflandırma başarısı da BCI'lar için önemli sorunlar olarak belirtilmektedir [8], [9], [88].

2.4. Glossokinetik Potansiyel ve Dilin, Dil-Makine Arayüzü, Beyin-Bilgisayar Arayüzü Üzerine Katkıları ve Avantajları

Dil, motor kontrolü içeren yardımcı cihazların manipüle edilmesi için uygun bir organ olarak kabul edilir. Bunun nedenleri genel olarak aşağıdaki gibidir.

- a. Dil kraniyel sinirlerle doğrudan beyne bağlıdır ve beyne mesafesi nispeten kısadır [13].
- b. Dil genellikle omurilik yaralanmalarından ve daha birçok ciddi hasarlardan etkilenmeden kaçabilir ve çoğu nöromusküler dejeneratif bozukluğu (Neuromuscular Degenerative Disorder) olan kişilerin el-ayak gibi uzuvlarından daha yavaş etkilenir [13].
- c. Dil, karmaşık seslendirme ve yutma görevlerine uygun özel kaslardan oluşur, böylece çok az yorgunluk ile hızlı ve doğru bir şekilde hareket edebilir. Bu nedenle, bir dil tabanlı cihaz, dilin ağız boşluğu içinde serbestçe hareket etmesine izin verdiği sürece birkaç saat boyunca sürekli olarak kullanılabilir [1].
- d. Dil hareketleri, engelli insanlara kozmetik bir avantaj sağlayan ağız boşluğu tarafından gizlenebilir. Böylece engelli olmayan kişilerden farklı olarak görülmezler [1].
- e. Dil hareketleri sezgiseldir ve EEG tabanlı BCI'dan farklı olarak düşünme veya yüksek konsantrasyon gerektirmez. Böylece sürekli yüksek zihinsel efor ve buna bağlı olarak LoC ve DoF problemleri görülmez [9].
- f. Dil kaslarını kontrol eden motonöronlar, vücut pozisyonundaki değişikliklerle dilin vücut pozisyonununun refleksi olarak ayarlanmasına izin vererek zengin bir vestibüler girdi alırlar. Bu nedenle, dil ile çalışan cihazlar, tekerlekli sandalyede oturmak veya yatakta uzanmak gibi herhangi bir yerde ve herhangi bir pozisyonda rahatlıkla kullanılabilir [1].
- g. Dil hareketine bağlı sinyaller, beyin yüzeyinde implante edilmiş elektrot dizileri tarafından yakalanan motor korteksten sinirsel sinyaller (ECoG) kullanan bazı BCI'lerin aksine, kafa derisi açılmadan dil hareketine invazif olmayan erişimle kolayca elde edilebilir [1].

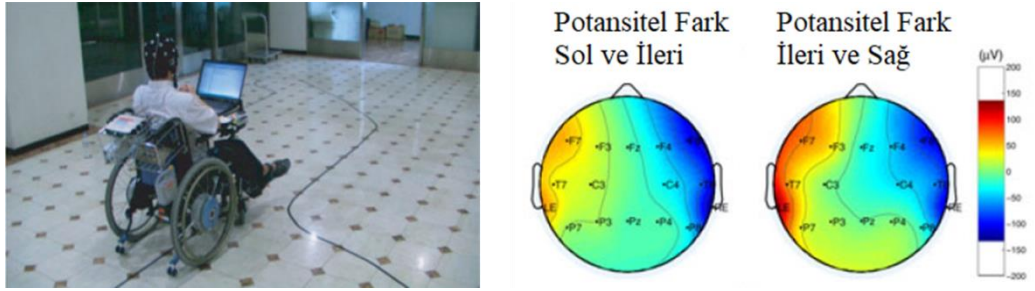
- h. Dil, duyu motor korteksinin önemli bir bölümüyle ilişkilidir ve bu konuda el ile karşılaştırılabilir. Somatik duyuusal korteks üzerinde bütün vücut ve alt uzuvlardan daha büyük bir haritalamaya sahip olduğu belirtilmiştir. Buna ek olarak kuvvet duyarlılığına ilişkin psikofiziksel çalışmalar, dil ucu gibi bazı oral yapıların parmak ucundan daha hassas olduğunu göstermiştir [18], [79]. Bu da dilin, AT'ler için hassas bir kontrol yapısı olduğunu gösterir [13].

TMI, ağız boşluğundaki dil hareketini algılar ve dilin herhangi bir şeye dokunması veya basmasını gerektirmeden bir dizi kullanıcı tanımlı komutlara dönüştürür. Bu komutlar daha sonra kullanıcıların ortamlarındaki çeşitli diğer cihazlarla iletişim kurması için kullanılabilir. Bu tez çalışmasında, GKP sinyalleri dil pozisyonunu tespit etmek ve doğal, güvenilir, performansı yüksek, kullanımı kolay bir dil-makine arayüzü geliştirmek için kullanılmıştır. GKP sinyallerinin TMI için katkıları ve diğer biyolojik sinyallere göre avantajları şunlardır:

- a. GKP istemli dil hareketleri ile oluşur ve istemsiz göz kırpmaları ile oluşan EOG ve istemsiz çene hareketleri ile oluşan EMG gibi sinyallerin aksine engelli kişi tarafından kolaylıkla bastırılabilir ve oluşturulabilir [13].
- b. GKP düşük frekanslarda oluşur, bu nedenle daha az bozulmaya neden olur ve basit bir yüksek geçişli filtre ile kolayca diğer frekanslardan ayrılabilir [13], [14].
- c. GKP düşük frekanslarda görüldüğünden EMG gibi EEG üzerinde bütün frekans bantlarında görülmez. EMG sinyali, üretildikten sonra, EEG analizini ciddi şekilde engeller ve bozar. Çünkü EMG, milivolt ölçeğinde tüm frekans bantlarını kirletir [13].
- d. GKP sinyalleri, EEG sinyallerinden olan ERP, VEP veya MI sinyallerinin genliğinden daha büyük bir genlik aralığında oluşur [13]. Bu da makine öğrenmesi algoritmalarının dil hareket yönüne bağlı olarak oluşan uzamsal örüntüyü daha kolay tanımasını sağlar. Sınıflandırma performansı artar.
- e. GKP sinyalleri düşük frekanslarda oluştuğundan ve doğrudan serebral bir sinyal olmadığı için alfa ve beta gibi zihinsel çaba gerektiren serebral sinyal

frekans bantları ile veya diğer motor hareket EEG sinyalleri ile daha az kesişim gösterirler [9].

- f. Yüz kaslarından elektromiyogram (EMG) gibi kas kasılmasıyla üretilen biyoelektrik sinyallerini veya göz hareket sinyallerini (EOG) kullanan AT'ler vardır. Bütün bu ölçümlerde, elektrotları yüze bağlamak can sıkıcı ve estetik açıdan rahatsız edici olabilir. Fakat geleneksel BCI sistemleri gibi kafa derisi üzerinden ölçülen GKP sinyalleri engelli insanlar için daha iyi bir serbestlik derecesi sunabilir [13].



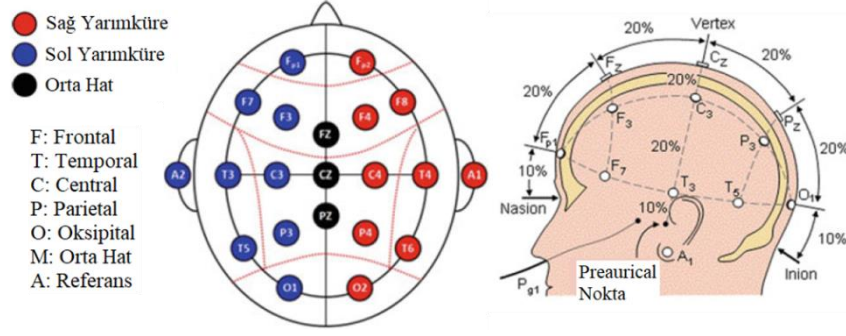
Şekil 2.11. Yanak duvarına değdirilen 1-boyutlu dil hareketiyle oluşan GKP potansiyel farkı ile elektrikli sandalye kullanımına ait örnek gösterim [13]

Dil hareketiyle 1-D elektrikli sandalye kullanımına ait örnek bir çalışma Şekil 2.11.'de gösterilmiştir. Dil, GKP sinyallerinin oluşturmasında yanak duvarlarına 6 sn'lik süre boyunca sağdan-sola ve soldan-sağa hareket ettirilmiştir.

2.5. EEG Ölçüm Düzeni, Elektrot Yerleşimi ve Elektrot Çeşitleri


Glossokinetik potansiyel sinyalleri, EEG ölçüm alan cihazlar ve ölçüm düzeni ile kafa derisi üzerinden alınmıştır. Bu sebeple EEG sinyal ölçüm düzeni tez çalışması içinde anlatılmıştır.

Uluslararası Klinik Nörofizyoloji Federasyonu (IFCN) tarafından geliştirilen 10-20 sistemi veya uluslararası 10-20 EEG ölçüm prosedürü sistemi, bir EEG testi veya deneyi sırasında kafa derisi elektrotlarının yerini belirlemek için kullanılır. 10-20 sistemi genellikle, Şekil 2.12.'de gösterildiği gibi kafa derisinin yüzeyinde yer alan 21 elektrot ile anlık EEG'yi kaydetmek için kullanılır.



Şekil 2.12. 10-20 EEG düzeni ve kafa derisi üzerine elektrot yerleşimi [93]

EEG sinyali, biri referans elektrot olan iki elektrotta ölçülür. Referans elektrot kaydı, diğer tüm elektrotlardaki elektriksel beyin potansiyelinin ölçüldüğü ve böylelikle kafa derisi bölgesinde varsayılan bir “inaktif” bölgeye yerleştirilmesi gereken bir elektrottur. Genel uygulamada referans elektrot, sol veya sağ kulak memesine veya her ikisine yerleştirilir [93]. Kafa derisi bölgesindeki mesafeleri ölçmek için nasion (burnun üstündeki delve, gözlerle aynı hizada) ve inion (kafatasının tabanında kemikli yumru başın arkasındaki orta hat) referans olarak alınır. Bu mesafeler hem ortogonal eksenler hem de kafa derisi alanının çevresi boyunca % 10 -% 20 -% 20 -% 20 -% 20 -% 10 oranında bölünmüştür [93].



Şekil 2.13. a) Altın elektrot gösterimi [94] b) Gümüş elektrot gösterimi [94]

EEG ölçüm elektrotları genellikle altın veya gümüş/gümüş klorür (Ag / AgCl) 'den yapılıdır [93]. Şekil 2.13. ve Şekil 2.14.'de sırasıyla elektrot ve EEG kepi ile ilgili örnekler gösterilmiştir.




Şekil 2.14. EEG kepi ve jel enjeksiyonu gösterimi [94]

2.5.1. Tez çalışması için gerçekleştirilen EEG üzerinden glossokinetik potansiyel sinyali ölçüm düzeni

Dil hareketine bağlı olarak yüz ve kafa derisi üzerinde oluşan glossokinetik potansiyel sinyalleri (yanıtları), EEG sinyallerini ölçen veri toplama cihazları kullanılarak EEG sinyalleri üzerinden ölçülebilmektedir [13], [19]. Tez çalışmasında GKP sinyallerinin ham verileri, 19 kanallı monopolar elektrotlar ile Micromed SAM32RFO EEG sinyal edinim sistemi kullanılarak toplanmıştır. Medcap elektrot kepi, kafa derisi üzerindeki sinyalleri ölçmek için 10-20 uluslararası elektrot yerleştirme sistemine göre kullanılmıştır. A2-A1 sırasıyla sağ ve sol kulak memesi referans noktası ve sol kaş üstü toprak olarak ayarlanmıştır. Ayrıca tüm empedanslar 10 k Ω 'ın altında tutulmuştur [3].

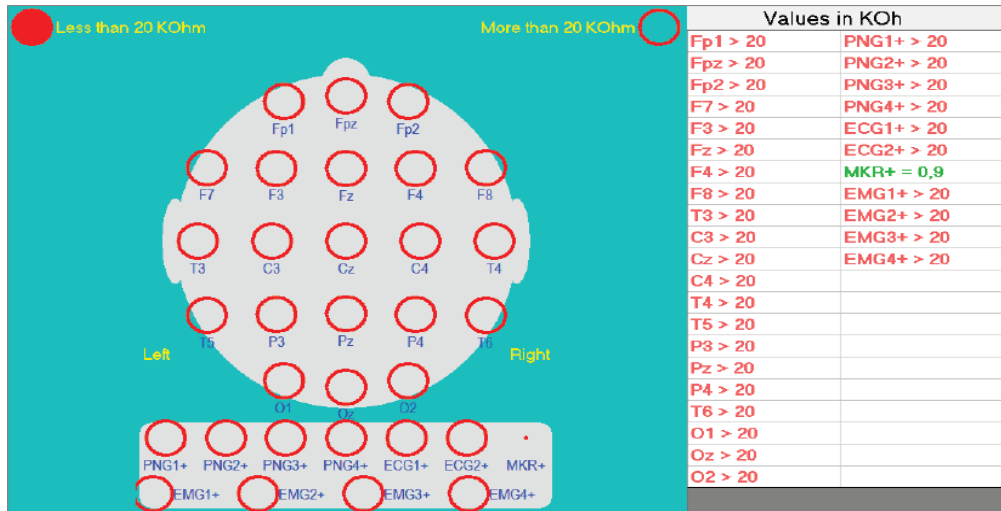
EEG ölçüm sistemi, 32 kanala sahip olan ölçüm yapabilen ve kayıt alabilen bir cihazdır. Tez çalışmasında kullanılan bu cihaz Şekil 2.15.'de gösterilmiştir.



Şekil 2.15. Tez çalışması içinde kullanılan EEG ölçüm cihazı gösterimi [87]

EEG ölçüm sistemi kuvvetlendirici katına ($1600 \mu\text{V}/\text{cm}$) sahiptir. Ayrıca, (f_c) kesim frekansı ($0,008\text{-}2000 \text{ Hz}$) arasında ayarlanabilmektedir. Şebeke gürültüsünü bastırmak için çentik filtre (50 Hz) ayarı mevcuttur. 2048 Hz maksimum örnekleme frekansına ve 16 bit çözünürlükte bir ADC yapısına sahiptir. Bununla beraber sistem, EEG kanalları için bipolar ve unipolar ölçüm modu seçeneği sunmaktadır [87].

Cihaz üzerinde uluslararası 10-20 ölçüm sistemine ait her elektrot için ayrı yuvalar ve kep bağlantı girişi için ayrı bir soket yuvası bulunmaktadır. Kullanılan elektrot jeli EEG kepi için üretilmiştir ve empedans ayarlamakta iletkenlik sağlamaktadır. EEG ölçüm sistemi içinde sunulan bu özellikler, Micromed firmasının ürettiği (System Plus Evaluation) arayüzü kullanılarak değiştirilebilmektedir [87]. Elektrot empedanslarının düzenlendiği program da bu arayüz içinde bulunmaktadır ve Şekil 2.16.'da görülmektedir.



Şekil 2.16. EEG ölçüm sistemi içerisinde empedans ayarlama arayüzü gösterimi [87]

Ölçüm alınan EEG sinyalleri seri haberleşme birimi ile bilgisayara aktarılmaktadır. Aktarılan bu sinyaller anlık olarak arayüz birimi üzerinde Şekil 2.17.'de görüldüğü üzere gözlenebilmektedir. Daha sonra bu sinyaller “edf” formatında (European Data Format) bilgisayara kaydedilmektedir. Bu noktada kaydedilen sinyallerin gerçek zamanlı olarak arayüz programından dışarı çıkmasına izin verilmemektedir [87]. Bu sebepten dolayı GKP tabanlı TMI çalışmasının gerçek zamanlı denemesi yapılamamıştır. Bununla beraber kaydedilen EEG sinyalleri ASCII formatına dönüştürülerek sinyal işleme teknikleri uygulanabilmektedir.



Şekil 2.17. EEG ölçüm sistemi içerisinde System Plus Evaluation arayüzü gösterimi [87]

Tez çalışması içinde kullanılan EEG kanal isimleri ve kanal numaraları, uluslararası 10-20 standartına uygun olarak kafa derisi üzerine Tablo 2.1.'de gösterildiği şekilde

yerleştirilmiştir. Çalışmada her bir kanal 1024 Hz'de örneklenmiş, 0,5-100 Hz'de süzölmüş ve 16 bit ile sayısallaştırılmıştır. Ayrıca, şebeke güröltüsünü ortadan kaldırmak için çentik filtresi 50 Hz'de uygulanmıştır. Daha sonra EEG sinyalleri üzerinden ölçölen dil hareket bilgisini içeren GKP sinyalleri, ham veri sinyalleri olarak bilgisayar ortamına aktarılmıştır.

Tablo 2.1. Tez çalışması içinde kullanılan EEG kanal isimleri ve numaraları

| Kanal Numarası | Kanal İsmi |
|----------------|------------|
| 1 | Fp2 |
| 2 | Fp1 |
| 3 | F7 |
| 4 | F3 |
| 5 | Fz |
| 6 | F4 |
| 7 | F8 |
| 8 | T3 |
| 9 | C3 |
| 10 | Cz |
| 11 | C4 |
| 12 | T4 |
| 13 | T5 |
| 14 | P3 |
| 15 | Pz |
| 16 | P4 |
| 17 | T6 |
| 18 | O1 |
| 19 | O2 |

2.6. Deneysel Düzen ve Glossokinetik Potansiyel Veri Toplama Adımları

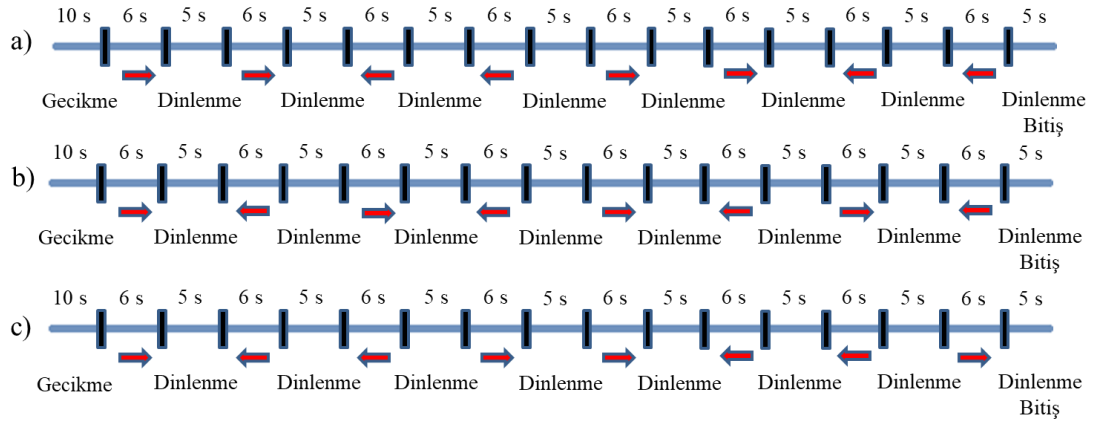
Tez çalışması içinde dil hareketine bağılı olarak üretilen glossokinetik potansiyel sinyalleri sonucu oluşın veri setleri, katılımcıların deneysel düzen aktiviteleri esnasında elde edilmiştir. Çalışmaya gönöllü olarak katılan katılımcılara ait demografik bilgiler Tablo 2.2.'de gösterilmiştir.

Tablo 2.2. Tez çalışması için gönüllü olan katılımcılara ait demografik bilgiler

| Katılımcılar | Cinsiyet | Yaş | Deneysel Düzen Numarası | Deneme Numarası |
|--------------|----------|-----|-------------------------|-----------------|
| Katılımcı-1 | K | 25 | 2 | 2 |
| Katılımcı-2 | E | 23 | 3 | 1 |
| Katılımcı-3 | E | 22 | 1 | 1 |
| Katılımcı-4 | K | 22 | 3 | 3 |
| Katılımcı-5 | E | 23 | 3 | 3 |
| Katılımcı-6 | E | 32 | 2 | 1 |
| Katılımcı-7 | E | 22 | 2 | 2 |
| Katılımcı-8 | E | 25 | 3 | 3 |
| Katılımcı-9 | E | 23 | 1 | 1 |
| Katılımcı-10 | E | 34 | 3 | 1 |

Tez çalışmasında kullanılan GKP sinyalleri ve buna bağlı veri setleri, yaşları 22-34 arasında değişen sekiz erkek ve iki kadın sağlıklı katılımcı olmak üzere toplamda on kişiden toplanmıştır. Kişilerin herhangi bir sinir sistemi rahatsızlığı yoktur ve katılımcıların böyle bir çalışmadaki ilk tecrübeleridir. Katılımcılar, Şekil 1.1.'de gösterildiği üzere, LCD monitörün karşısında ve yarım metre uzaklıkta rahat bir koltukta oturmuşlardır. Katılımcılardan deney süresince dil hareketi dışında hareket etmemeleri istenmiştir. Her bir katılımcı, her farklı deneysel düzende dört deneme (Trial) olmak üzere toplamda üç farklı deneysel düzen (Experimental Setup) ve buna bağlı olarak toplamda 12 deneme yapmıştır. Her bir kişinin en başarılı denemesi sinyal işleme için ham veri sinyali olarak seçilmiştir [3]. Her bir katılımcı için demografik bilgi, deney düzeneği ve deneme sayısı Tablo 2.2.'de gösterilmiştir. Bununla beraber deneme kayıtları esnasında, birkaç katılımcıda kayıtlar ilgili denemeler için kendilerinin istekleri üzerine yeniden alınmıştır.

Tez çalışması içinde katılımcılar Şekil 1.1.'de gösterildiği şekilde dil uçlarını sağ ve sol yanak duvarlarına ardışık ve ayırık hareketler ile değdirmek suretiyle GKP sinyalleri oluşturmuşlardır. Oluşan bu sinyal değişimleri kafa derisinden ve EEG sinyalleri üzerinden ölçülmüştür. Katılımcılar istemli dil hareketlerini Şekil 2.18.'de gösterildiği şekilde üç farklı deneysel düzenin akışına uygun olarak yerine getirmişlerdir.



Şekil 2.18. Deneysel düzen gösterimi a) 1. deneysel düzen b) 2. deneysel düzen c) 3. deneysel düzen

Her bir deneme için kayıt süresi 98 sn sürmüştür ve her bir deneme 10 sn gecikme ile başlamıştır. İstemli dil hareketleri ile sağ ve sol yanak duvarlarına dokunmak için geçen süre 6 sn iken, dinlenme süresi 5 sn olarak alınmıştır. Her denemede, 6 sn boyunca gerçekleştirdikleri dil hareketi sayısı dört sağa ve dört sola olmak üzere toplamda sekizdir. Katılımcıların 6 sn boyunca sağ veya sol yanak duvarına ayırık olarak 10-15 defa dokunmak suretiyle gerçekleştirdikleri dil hareketleri, yüz ve kafa derisi üzerinde glossokinetik potansiyel sinyalleri oluşturmaktadır. Katılımcılar, 5 sn dinlenme süresi boyunca hiçbir dil hareketi yapmaz ve dil öne doğru uzatılır. 6 sn boyunca her bir kanaldaki sayısallaştırılmış işaret, 1024 Hz örnekleme frekansı için (6×1024) örnek ile temsil edilmektedir.

BÖLÜM 3. SİNYAL İŞLEME METOTLARI VE MAKİNE ÖĞRENMESİ ALGORİTMALARI

Bio-sinyal kontrol sistemlerinin, vücut tabanlı mekanik sistemler (Body-Powered) gibi diğer kontrol sistemleri üzerindeki en önemli avantajı, kullanıcının isteklerini eller serbest (Hands-Free) olarak gerçekleştirebilmeleridir. Örneğin, bio-kontrol artık ticari fonksiyonel protezlerde mekanik vücutla çalışan sistemler için rekabetçi bir alternatiftir. Bu sistemler fonksiyonel olmakla beraber aynı zamanda kozmetik bir görünüm sağlamaktadır [4]. Tez çalışmasında, EEG sinyalleri üzerinden ölçülen ve deneysel düzen içinde istemli dil hareketleri sonucu oluşan glossokinetik potansiyel sinyaller sayısallaştırılarak ham veri sinyali olarak bilgisayar ortamına kaydedilmektedir. Sayısallaştırılan bu ham veri sinyallerinden anlamlı bilgiler çıkarmak ve yardımcı teknolojiler için kontrol ve iletişim komutları sağlamak için sinyal işleme teknikleri uygulanmaktadır [4]. Bu sinyal işleme teknikleri dil-makine arayüzüne, dil hareketine bağlı olarak üretilen GKP sinyallerini yakalama, alınan sinyalleri işleme, bunları sınıflandırma ve kontrol için bu sinyalleri kullanma açısından ilgili fonksiyonları kazandırır ve genel işlevlerini açıklar [3].


GKP sinyal işleme adımları Şekil 1.1.'de görüldüğü gibi şu adımlardan oluşmaktadır: Sinyal ön işleme, geleneksel makine öğrenmesi algoritmaları için özellik çıkarma ve boyut azaltma, konvolüsyonel sinir ağları için sinyalden görüntüye çevirme işlemi ve örüntü tanıma işlemi için (sınıflandırma) makine öğrenmesi algoritmalarının uygulanması.

3.1. Sinyal Ön İşleme Adımları, Filtreleme ve Normalizasyon

Ön işleme, bio-sinyal içine gömülmüş istenmeyen bileşenleri çıkarmak için gerçekleştirilir. İyi bir ön işleme, sinyal kalitesinde artışa neden olur ve bu da daha iyi özellik ayrışması ve sınıflandırma performansı ile sonuçlanır [93]. EEG sinyalleri

üzerinden alınan GKP sinyallerinin sinyal işleme ve sınıflandırma başarısının yüksek çıkması için, EEG sinyallerini etkileyen yüksek frekans ve bozucu etki içeren her türlü sinyalden arındırılmış olması beklenmektedir. EEG sinyali çoğunlukla iki tip gürültüye maruz kalır. İlk tip gürültü kaynakları AC güç hatları, aydınlatma ve çok sayıda elektronik ekipman (bilgisayar ekranı, televizyon, dizüstü bilgisayarlar ve cep telefonları) gibi harici, çevresel gürültü kaynaklarını içerir. İkinci tip gürültü kaynakları, vücut hareketlerine bağlı olarak üretilen diğer biyoelektrik potansiyeller (EMG, EOG ve ECG) veya cilt direnci etkilerine bağlı olarak çeşitli vücut aktivitelerinden ortaya çıkan fizyolojik bozucu etkilerdir [93].

İstemli dil hareketine bağlı olarak oluşan serebral olmayan GKP sinyalleri, EEG üzerinde düşük frekans bantlarında (delta ve teta bantları) ve EEG kaynaklı sinyal genliklerine göre yüksek genlikte oluşmaktadır. Bununla beraber GKP sinyalleri, EEG sinyalleri üzerinden alındığından dolayı her katılımcı için elde edilen ham veri sinyallerine öncelikle Matlab ortamında 10'uncu derece sonsuz dürtü yanıtı (IIR) Butterworth düşük geçiren filtre 40 Hz kesim (Cutoff) frekansında uygulanmıştır [3], [9]. Şekil 3.1.'de ham GKP sinyali ve filtrelenmiş GKP sinyaline ait örnek bir gösterim görülmektedir.



Şekil 3.1. Dil hareketine bağlı olarak üretilen Fp2 kanalına ait 6 sn'lik GKP ham veri sinyali ve filtre uygulanmış sinyal örnek gösterimi (Mavi Sinyal: Ham GKP sinyali, Kırmızı Sinyal: Filtrelenmiş GKP sinyali)

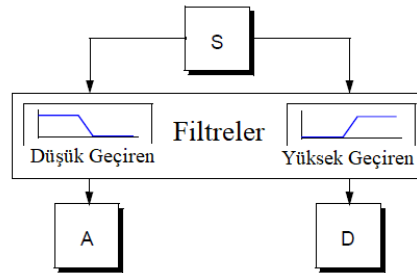
Daha sonra GKP sinyal yön bilgilerini içeren filtre uygulanmış ham veri sinyali Denklem 3.1'e göre (0-1) arasında normalize edilmiştir.

$$X_S^{norm} = \frac{X_S - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

X_S , veri kümesindeki "s" inci değeri gösterirken, X_{max} en yüksek değeri, X_{min} en düşük değeri ifade eder [95].

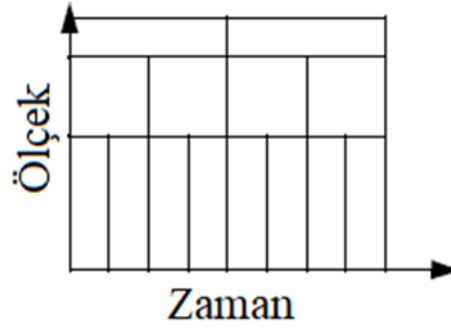
3.1.1. Ayrık dalgacık dönüşümü

Ayrık dalgacık dönüşümü (DWT), durağan olmayan sinyallerden gelen bilgileri analiz etmek ve çıkarmak için güçlü bir araç olarak ortaya çıkmıştır. DWT ayrıca çok çözünürlüklü analizler için uygundur. DWT yapısı gereği, giriş sinyalinin filtrelenmesi ve azaltılması için bir dizi işlemden oluşur. Yüksek frekanslı ve düşük frekanslı bileşenlerin ayrıştırılması işlemi, ölçekleme fonksiyonları ve dalgacık fonksiyonları yardımıyla Şekil 3.2.'de görüldüğü gibi düşük ve yüksek geçişli filtreler kullanılarak gerçekleştirilir [96], [97].



Şekil 3.2. Ayrık dalgacık dönüşümü ve filtre yapısı [98]
(S: Sinyal (Signal), A: Düşük frekanslı sinyal (Approximation), D: Yüksek frekanslı sinyal (Detail))

Dalgacık analizi, daha hassas düşük frekanslı bilgi istendiğinde uzun zaman aralıklarının kullanılmasına ve yüksek frekanslı bilgi istendiğinde daha kısa bölgelerin kullanılmasına izin verir. Şekil 3.3.'de gösterildiği gibi bunu yaparken dalgacık analizi değişken boyutlu pencereler sunar.




Şekil 3.3. Wavelet analizi ve zaman-ölçek alanı [98].

Bu tez çalışmasında, özellik çıkarımında ve sınıflandırma sonuçlarında daha iyi performans sonuçları elde etmek için, sinyal ön işleme adımı olarak, glossokinetik potansiyel sinyallerinin delta (1-4 Hz) ve teta (4-7 Hz) frekans bantlarının elde edilmesinde ayırık dalgacık dönüşümü tekniği uygulanmıştır. Bu uygulamada, 1024 Hz'lik bir örnekleme frekansıyla elde edilen ham veri sinyalleri için, 6. seviyedeki db10 (Daubechies) dalgacık tipi, GKP sinyallerinden delta ve teta frekans bantlarını çıkarmak için kullanılmıştır. DWT'ye ait ilgili matematiksel bağıntı Denklem 3.2'de görülmektedir.

$$DWT(a, b) = \frac{1}{\sqrt{a}} \sum_n x(n) \psi^* \left(\frac{n-b}{a} \right) \quad (3.2)$$

İlgili denklemde a ve b ifadeleri sırasıyla ölçü ve geçiş parametrelerini tanımlamaktadır [99]. Bununla beraber sürekli dalgacık dönüşümü (CWT) ve kısa zamanlı fourier dönüşümü (STFT), Şekil 3.4.'de görüldüğü gibi sinyallerin zaman-frekans analizini yapmaya imkan verir [99].



Şekil 3.4. Sürekli dalgacık dönüşümü ve zaman-frekans analizine ait örnek gösterim [87]

3.2. Özellik Çıkarma ve Sinyalden Görüntüye Çevirme İşlemi

Geleneksel sınıflandırıcılar için özellik çıkarma aşaması ham sinyal verilerini anlamlı bir özellik vektörüne (veri setlerine) dönüştürür [3], [4]. Genellikle sinyal işlemede bilgisayar arayüz tasarım yaklaşımını karakterize eden bu aşamadır. Bununla beraber doğru özellik çıkarma işlemi farklı sınıftaki kontrollerin daha iyi ayrıştırılması noktasında sınıflandırıcılar için zorluğu azaltır. Deneysel düzeneğin de sinyal örüntüsünün doğru bir şekilde ortaya çıkarılmasında, özellik çıkarma yöntemleri kadar önemli olduğunu belirtmek gerekir [93].

Özellik çıkarma için matematiksel işlemler zaman alanında, frekans alanında ve zaman-frekans alanında gerçekleştirilir. Zaman alanı özellikleri, sinyal genliğine göre işlenir ve sinyalin fiziksel yapısının tanımına izin vererek bio-sinyal enerjisini kapsar. Frekans alanı özellikleri, sinyali frekans düzleminde karakterize eder ve Fourier dönüşümü veya PSD kullanarak zaman alanındaki bio-sinyali frekans düzlemine taşır. Bununla beraber frekans alanı özellik çıkarma yöntemleri, dönüştürme işlemleri içerdiğinden zaman alanına göre daha fazla hesaplama yükü gerektirir [3]. Zaman-frekans özellik çıkarma yöntemleri, sinyali zaman ve frekans alanında aynı anda gösterir ve bu özellikler, spektrum gücünün zamanla nasıl değiştiğini tanımlar. Kısa zamanlı Fourier dönüşümü ve dalgacık dönüşümü en sık kullanılan zaman-frekans özellik çıkarma yöntemleridir [4]. Tez çalışması içerisinde, zaman alanı özellik çıkarma yöntemleri, frekans alanı özellik çıkarma yöntemlerine kıyasla, doğruluk ve hesaplama süresi açısından genel olarak daha yüksek performans gösterdiği için ağırlıklı olarak kullanılmıştır [5], [6], [9].

Son yıllarda örüntü tanımada en etkili derin öğrenme (DL) yöntemlerinden biri olan konvolüsyonel sinir ağı (CNN), bio-sinyal sınıflandırma uygulamalarında da oldukça iyi performans göstermektedir [100], [101], [102]. CNN, yapısı gereği görüntü işlemede sıkça kullanıldığından, istemli dil hareketi ile elde edilen bir boyutlu (1-D) zaman serisi glossokinetik potansiyel sinyalleri, iki boyutlu (2-D) griölçek zaman serisi sinyal görüntülerine dönüştürülmüştür.

3.2.1. Zaman alanında özellik çıkarma yöntemleri

Zaman alanı özellik çıkarma yöntemleri daha az hesaplama karmaşıklığından dolayı EEG gibi kaotik ve yüksek gürültü bağımlı sinyallerde sıkça kullanılmaktadır [81]. Tez çalışmasında EEG üzerinden ölçülen dil hareketine bağlı GKP sinyallerinden zaman alanında özellik çıkartmak için şu yöntemler kullanılmıştır; ortalama karesel kök (RMS), standart sapma (STD), varyans (VAR), ortalama değer (MV), ortalama mutlak değer (MAV), maksimum tepe değeri (MPV) ve şekil faktörü (SF) [3], [81], [103]. İlgili yöntemlerin matematiksel ifadeleri Tablo 3.1.'de gösterilmektedir.

Tablo 3.1. Zaman alanı özellik çıkarma yöntemleri ve matematiksel ifadeleri

| Yöntem | Matematiksel İfade | Denklem No |
|--------|----------------------------------------------------------------|------------|
| RMS | $\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i)^2}$ | (3.3) |
| STD | $\sigma_x = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}}$ | (3.4) |
| VAR | $\sigma_x^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ | (3.5) |
| MV | $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ | (3.6) |
| MAV | $\frac{1}{N} \sum_{i=1}^N x_i $ | (3.7) |
| MPV | $x_p = \max x(n) $ | (3.8) |
| SF | $\frac{x_{rms}}{\frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) }}$ | (3.9) |

Denklemlerde $X_i=1,2,3,\dots,n$ zaman serisi sinyallerini, n veri uzunluğunu ve \bar{X} ise dizideki verilerin ortalama değerini ifade eder.

3.2.2. Frekans alanında özellik çıkarma yöntemi

Dil hareketine bağlı olarak üretilen glossokinetik potansiyel sinyallerinin frekans alanında gösterimi ve veri setlerinden özellik çıkarma işlemi güç spektral yoğunluğu

(PSD) yöntemi ile gerçekleştirilmiştir. PSD zaman serisi sinyallerini frekans alanı veri dizilerine dönüştürür ve frekans bandındaki sinyal güç değişimini ortaya koyar. Başka bir ifade ile PSD, bir sinyalin frekansı üzerinden güç dağılımını tanımlayan bir işlemdir. İlgili yönteme ait matematiksel tanımlar aşağıdaki denklemlerde gösterilmiştir:

$$Px(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n)e^{-j2\pi fn} \right|^2 = \frac{1}{N} |X(f)|^2 \quad (3.10)$$

Denklem 3.10'da, $X(f)$ örnek veri dizisi $x(n)$ 'in Fourier dönüşümünü ifade ederken, N veri uzunluğunu tanımlar. PSD'nin bu formuna periodogram denmektedir. Welch metodu PSD'nin özel bir oluşumudur ve en sık kullanılan yapısıdır. Bu yaklaşım da ayrılmış ve üst üste binmiş veri bölütlerinden oluşur. Bu bölütler şu şekilde tanımlanır:

$$x_i(n) = x(n + iD) \quad n = 0, 1, \dots, M - 1 \quad (3.11)$$

$$i = 0, 1, \dots, L - 1$$

Denklem 3.11'de, n bölüt uzunluğunu ifade ederken, i veri bölütünü tanımlar. Ayrıca, iD , i 'inci dizinin başlangıç noktasıdır. $D = M$ olarak belirtilen bir koşul varsa, bölütler çakışmaz, fakat $D = M / 2$ olarak alınırsa veri bölütleri arasında %50 çakışma vardır. Daha sonra, PSD sonucunu belirlemek için her bir veri bölütüne pencere işlemi uygulanır. Değiştirilmiş periodogram aşağıdaki denklemde gösterildiği gibidir:

$$\bar{P}_X^{(i)}(f) = \frac{1}{MU} \left| \sum_{n=0}^{N-1} x(n)w(n)e^{-j2\pi fn} \right|^2 \quad (3.12)$$

Burada U , pencere fonksiyonu $w(n)$ 'de güç için normalleştirme faktörüdür ve formülasyon aşağıdaki gibi devam etmektedir:

$$U = \frac{1}{M} \sum_{n=0}^{N-1} w^2(n) \quad (3.13)$$

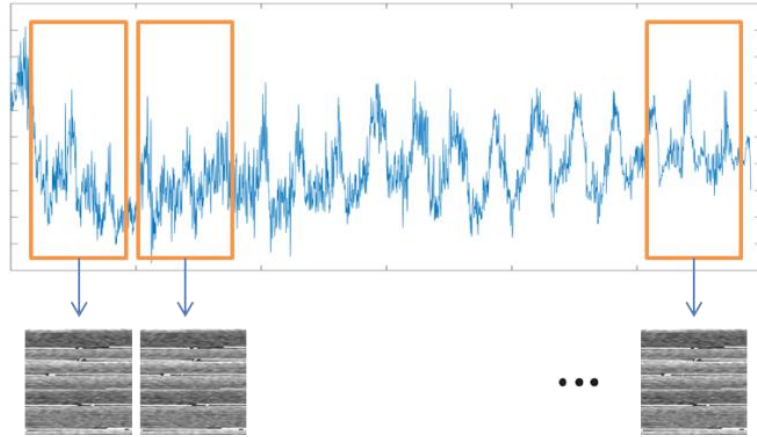
Tez çalışmasında veri seti örnekleri %50 çakışma ile sekiz segmente bölünmüş ve Hamming pencereleme kullanılmıştır. PSD ve Welch yöntemi için daha fazla teorik bilgi ilgili referanslarda bulunabilir [6], [104].

3.2.3. Sinyalden görüntüye çevirme işlemi

CNN mimarisinde sınıflandırma işlemi yapmak için GKP sinyallerinden 2-D zaman serisi sinyalleri olan sağ / sol dil hareket yön görüntüleri elde etmek gerekmektedir [101]. Sinyal-görüntü dönüştürme yönteminde, 1-D zaman serisi ham veri sinyalleri, Şekil 3.5.'de gösterildiği gibi 2-D zaman serisi sinyali olan griölçekli görüntülerde, görüntünün piksellerini oluşturur. $M \times M$ karesel piksel görüntü büyüklüğüne sahip olmak için ham veri sinyallerinden, M^2 uzunluğundaki veri dizisi ardışık bölütler olarak çıkarılır. Dönüşümün matematiksel ifadesi Denklem 3.14 'de gösterilmiştir.

$$P(j, k) = \text{round} \left\{ \frac{L((j-1) \times M + k) - \text{Min}(L)}{\text{Max}(L) - \text{Min}(L)} \times 255 \right\} \quad (3.14)$$

Denklem 3.14'de, $L(i)$, $i=1, \dots, M^2$ bölütlenen sinyallerin değerini ifade ederken, $P(j, k)$, $j=1, \dots, M$, $k=1, \dots, M$ değerini alır [100].



Şekil 3.5. GKP ham veri sinyaline ait bölütler ve $M \times M$ boyutunda görüntüler

3.2.4. Tez çalışması için elde edilen 1-D veri seti ve 2-D görüntü seti oluşumu

Deneysel düzen süresince katılımcıların yanak duvarlarına ardışık ve ayrı olarak değen istemli dil hareketleri esnasında EEG üzerinden ölçülen ve kaydedilen glossokinetik potansiyel sinyallerine ait 1-D ham veri sinyalleri, her katılımcı için $(6 \times 8 \times 1024) \times 19$ boyutundadır. 6 değeri, bir denemede çoklu temaslar için altı saniyelik süre anlamına gelirken, 8 değeri deney düzeneği dizilerinde gösterilen yanak duvarlarına doğru (4 sağ ve 4 sol) dil hareketlerinin toplam yön sayısını, 1024 örnekleme frekansını ve 19 kaydedilen kanal sayısını ifade eder. Elde edilen bu ham veri sinyaline filtreleme ve normalizasyon ön işleme adımları uygulandıktan sonra özellik vektörünü oluşturmak için özellik çıkarma işlemi uygulanmıştır. 1024 Hz frekansında örneklenen, filtrelenmiş ve normalize edilmiş bu ham veri sinyalinde, tüm EEG frekansları kapsandığından 100 ms'lik özellik çıkarma süresi seçilmiştir [3], [5]. Eğer 1 saniyelik veri kaydından $1024 / 100\text{ms} = 10$ birim (yaklaşık) elde edilirse, tek bir kanal özellik vektörü $(6 \times 8 \times 10) = 480$ (yaklaşık) veri uzunluğuna eşittir. Fakat, bazı katılımcılar deneysel düzen ve ölçüm esnasında tam olarak belirlenmiş zamanlarda oturumlarını başlatıp bitiremediklerinden dolayı, özellik vektörü uzunluğu 480 yerine 400 olarak belirlenmiştir. Böylece tüm kanallar göz önüne alındığında her katılımcı için ham veri seti uzunluğu 400×19 olarak alınmıştır. Tez çalışması içinde filtrelenmiş, normalize edilmiş ve özelliği çıkarılmış veri setine ham veri seti adı verilmiştir.

CNN, konvolüsyon alan yapısı gereği, geleneksel veya literatürdeki yeni ismiyle sığ sınıflandırma algoritmalarında olduğu gibi özellik çıkarma ve özellik seçme işlemlerine gerek duymamaktadır [105]. Bununla birlikte, CNN'nin temel dezavantajı, güçlü ve mükemmel sonuçlara sahip olmak için yüksek bir veri setine ihtiyaç duymasıdır. Bu tekniğin performansı örneklerin sayısının artırılmasıyla geliştirilebilir [106], [107]. Bu nedenle, her bir katılımcı için kaydedilen on iki deneme, Şekil 3.5'deki prosedürde gösterildiği gibi 2-D zaman serisi sinyal görüntülerini elde etmek için kullanılmıştır. Daha sonra, 1-D zaman serisi sinyallerinden 102×102 piksel boyutunda karesel görüntü oluşturmak için 100 ms çerçeve süresine karar verilmiştir. Bu nedenle, on dokuz kanal sinyalden oluşan her bir deneme, her yönde (sağ veya sol) 38 karesel görüntü üretebilir. Son olarak, her

katılımcıya ait on iki deneme, her bir yön / sınıf için $12 \times 38 = 456$ karesel görüntü sağlamayı başarmıştır. Daha sonra aynı prosedürde her bir katılımcı ve tek bir deneme için 11 kanal sinyale (frontal ve temporal bölge) ait sonuç bulunmuş ve 22 karesel görüntü elde edilmiştir. Bu nedenle, on iki denemede $12 \times 22 = 264$ görüntü, her yön için elde edilmiştir.

3.3. Boyut Azaltma ve Özellik Seçme Yöntemleri

Sinyal işlemede sınıflandırıcıların ve dolayısıyla arayüz sistemlerinin performansını ve hızını arttırmak için, özellik vektörü elde edildikten sonra gereksiz verileri ortadan kaldırarak özellik vektörünün boyutunu küçültmek gerekir [4], [108], [109]. Ortaya çıkan vektör, indirgenmiş özellik vektörü olarak adlandırılır. Yüksek boyutluluk, verileri işlemek için zaman ve alan gereksinimlerini artırır. Dahası, birçok alakasız ve / veya gereğinden fazla özelliğin varlığında, öğrenme yöntemleri aşırıya kaçmaya ve daha az yorumlanmaya eğilimlidir [93]. Boyut azaltımı için iki ana strateji vardır. Bunlardan ilki özellik yansıtma (projeksiyon) ve diğeri de özellik seçme yöntemleridir. Özellik yansıtma işlemi için en sık kullanılan yöntem temel bileşen analizi (PCA) iken, özellik seçme işlemi için bağımsız bileşen analizi (ICA) yöntemi kullanılmaktadır [4], [110].

3.3.1. Temel bileşen analizi yöntemi

Temel bileşen analizi yöntemi sinyal işlemede özellik vektörünün boyutunu azaltan projeksiyon tekniği olarak isimlendirilmektedir. PCA, temel bileşenler (PCs) olarak adlandırılan bir dizi yeni ortogonal özellik oluşturarak veri varyansını belirler. PCA, orijinal veri uzayında gereksiz özellik boyutlarının kaldırılmasını amaçlamaktadır [9], [111]. Böylece, boyutu azalan veri seti, makine öğrenmesi algoritmaları için hesaplamada kolaylık sağlar. PCA, yüksek boyutlu veri setlerini (X_t), kovaryans matrisinin (C) özdeğerlerini ve öz vektörlerini belirleyerek daha küçük boyutlu bir veri seti (S_t) haline dönüştürür. PCA ile ilgili denklemler şöyledir:

$$C(X) = \sum_{i=1}^N \frac{(X_i X_i^T)}{N} \quad (3.15)$$

$$\lambda_i u_i = C u_i, \quad i = 1, 2, 3 \dots m \quad (3.16)$$

Denklemlerde λ_i kovaryans matrisinde özdeğerleri tanımlarken, u_i ise aynı matrisin özvektörlerini tanımlar.

$$S_t(i) = u_i^T X_t, \quad i = 1, 2, 3 \dots m \quad (3.17)$$

Denklem 3.17'de, $S_t(i)$, veri seti (X_t)'nin temel bileşenlerini ifade eder [9], [87]. Tez çalışması içinde kullanılan PCA boyut azaltma yönteminde özelliği azaltılmış veri setinin, ham veri setini 10 temel bileşen ve 12 temel bileşen için %96 ile %99 aralığında temsil ettiği hesaplanmıştır.

3.3.2. Bağımsız bileşen analizi yöntemi

Bağımsız bileşen analizi (ICA), bağımsız bileşenler olarak adlandırılan gizli faktörleri ortaya çıkarmayı ve karşılıklı bağımsızlığı maksimize eden verilerin doğrusal projeksiyonlarını bulmayı amaçlayan bir tür istatistiksel tekniktir. Bağımsız bileşen analizi, optimum EEG kanallarını seçmek için kullanılabilir popüler bir kör kaynak ayırma (BSS) tekniğidir [108], [109]. ICA, EEG sinyallerini bağımsız beyin aktivitelerine ve arka projeksiyonunu kafa derisi haritalarının orijinal EEG kanallarına aktarma kabiliyetine sahiptir [108]. Bu açıdan EEG sinyalleri üzerinden ölçülen glossokinetik potansiyel sinyalleri için optimum kanalları seçerek özellik boyutunu azaltmada kullanılmış ve sonuçları PCA ile kıyas edilmiştir. Daha az EEG kanalı, daha taşınabilir ve kullanışlı arayüzler ve yardımcı teknolojiler anlamına gelir. Ayrıca ICA, gönüllü dil hareketleri sırasında beyin haritalama ve glossokinetik potansiyel yanıtlarının işleyişini anlamak için yararlı bir araç olabilir. ICA ile ilgili denklem şöyledir:

$$x_i(t) = a_{i1}s_1(t) + a_{i2}s_2(t) + \dots + a_{in}s_n(t) \quad i = 1, 2, \dots, n \quad (3.18)$$

Denklem 3.18'de, $x_i(t)$, n farklı ve rastgele deęişken katsayıya sahip doğrusal sinyal karışımını ve $s_n(t)$ saklanmış bileşenleri ifade eder [6]. ICA'ya ait matris gösterimindeki notasyon ise şöyle ifade edilmiştir:

$$\begin{bmatrix} x_1(t) \\ \vdots \\ x_n(t) \end{bmatrix} = A \begin{bmatrix} s_1(t) \\ \vdots \\ s_n(t) \end{bmatrix}, \quad A = [a_{i1}, a_{i2}, \dots, a_{in}] \quad (3.19)$$

Daha sonra;

$$x = As \quad (3.20)$$

Denklemleri ile gösterilebilir. ICA metodunun temel amacı saklı bileşenleri bulmak için rastgele deęişken katsayılarını (A) bulmaktır.

3.4. Makine Öğrenmesi Algoritmaları

Makine öğrenimi, örnek verileri veya geçmiş deneyimleri kullanarak bir performans ölçütünü optimize etmek için bilgisayarları programlamaktır. Makine öğrenmesi algoritmaları robotik, tıbbi teşhis, konuşma ve görüntü tanıma, biyometri, biyomedikal sinyal işleme ve örüntü tanıma alanlarında kullanılmaktadır [112].

Dil makine arayüzü (TMI), dil aktivitelerinin harici cihazları veya bilgisayarları kontrol etmesini sağlayan bir donanım ve yazılım kombinasyonu olarak tanımlanır. Amaç, engelli insanların hayatlarını olabildiğince düzenli ve kolay bir şekilde yaşamasına yardımcı olmaktır. Glossokinetik potansiyel tabanlı dil makine arayüzünün, ilgili yardımcı cihazları kontrol edebilmesi için sinyal işlemedeki son adım, bilgi içeren özellik vektörlerinin (veri setlerinin) doğru bir şekilde sınıflandırılmasıdır. Bu noktada BCI sistemlerinde olduğu gibi, GKP tabanlı TMI çalışmasının örüntü tanıma ve sınıflandırma işlemlerinde makine öğrenmesi algoritmaları kullanılmıştır [3], [9]. Tez çalışması içinde geleneksel makine öğrenmesi algoritmaları ile beraber son yıllarda sınıflandırma ve örüntü tanıma alanı başta olmak üzere birçok alanda yüksek performans gösteren derin öğrenme

metotlarından birisi olan konvolüsyonel sinir ağının GKP tabanlı TMI üzerindeki başarısı da araştırılmış ve sonuçları tez çalışması içine konulmuştur. Geleneksel makine öğrenmesi algoritmalarından ise yapay sinir ağı modellerinden MLNN-PNN, çekirdek tabanlı algoritmalarından SVM-LDA, karar ağaçları algoritmalarından Gini algoritması ve parametrik olmayan metotlardan kNN kullanılmıştır.

3.4.1. Performans değerlendirme kriterleri

Performans değerlendirme kriterleri, biyomedikal sinyal işleme üzerine uygulanan makine öğrenmesi algoritmalarını değerlendirmek için önemli parametrelerdir. GKP tabanlı TMI'nin performansını incelemek için doğruluk (ACC), özgülük (SPEC), duyarlılık (SENS) ve bilgi transfer oranı (ITR) değerlendirme parametreleri elde edilmiştir [9].

Geleneksel sınıflandırıcılarda sonuçların güvenilirliğini arttırmak için k-kat çapraz doğrulama tekniği (k-fold Cross Validation Technique) kullanılmış ve hesaplamalarda k=10 kat seçilmiştir. k-kat çapraz doğrulama, tutma tekniği (Hold-Out Technique) olarak adlandırılır. Bu teknikte sınıflandırma işleminden önce, veri seti rastgele olarak k alt veri setine bölünmüştür. Sonra her bir alt set, bir test seti olarak işlenirken, diğer (k-1) alt veri seti, eğitim seti oluşturmak için birleştirilir. k-kat çapraz doğrulama yönteminin temeli, örneklerin bölünmesiyle seçimin bağımsızlığına dayanmaktadır. Bu, elde edilen tahminin varyansını azaltarak tutma tekniğine sağlamlık sağlar. Diğer taraftan bu yöntem hesaplama yükünü arttırır [9], [113]. CNN için ise %50 eğitim-%50 test doğrulama tekniği kullanılmıştır. Sınıflandırma doğruluğunu bulmak için gerekli matematiksel denklemler şöyledir:

$$Doğruluk(TS) = \frac{\sum_{i=1}^{|TS|} Tahmin(n_i)}{|TS|}, \quad n_i \in TS \quad (3.21)$$

$$Tahmin(n) = \begin{cases} 1, & \text{eğer tahmin}(n) = cn \\ 0, & \text{diğer} \end{cases} \quad (3.22)$$

$$Sınıflandırma Doğruluğu (ML) = \frac{\sum_{i=1}^{|k|} doğruluk(TS_i)}{|k|} \quad (3.23)$$

Denklemlerde TS (Test Seti) sınıflandırılacak test verisini ifade ederken, cn test veri setindeki n . inci örneğin sınıfını, $Tahmin(n)$, n 'in sınıflandırma sonucunu ve k ise k çapraz doğrulama yöntemi ile makine öğrenmesi (ML) içindeki k sayısını ifade eder [9].

Doğruluk, duyarlılık ve özgüllük, alıcı işletim karakteristiği (ROC) analizinde kullanılan sınıflandırma ölçütleridir [9]. Doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN), belirtilen sınıflandırma ölçütleri için temel parametreleri oluşturmaktadır:

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.24)$$

$$Özgüllük = \frac{TN}{TN + FP} \quad (3.25)$$

Bilgi transfer oranı (ITR), EEG tabanlı BCI uygulamalarında kritik ve popüler bir değerlendirme parametresidir [70], [114]. ITR, EEG tabanlı heceleme sistemleri veya tekerlekli sandalyeler de dahil olmak üzere iletişim ve kontrol için her bir deneme başına veya zamana göre veri iletimi hakkında bilgi (bit veya karakter) sağlar [14]. Bu nedenle, tez çalışmasında, ITR'ye göre GKP tabanlı TMI'nın başarı oranı, elde edilen bütün veri seti işlemlerinde kullanılan önemli bir parametre sonucu olarak görülmektedir. ITR, Shannon ve Weaver'ın çalışmasından türetilmiştir ve B ile ifade edilmektedir [9]. ITR için gerekli matematiksel denklem şöyledir:

$$B = \log_2 N + P \log_2 P + (1 - P) \log_2 \frac{(1 - P)}{(N - 1)} \quad (3.26)$$

Denklem 3.26'da B , deneme başına bit sayısını tanımlar. N , farklı zihinsel görev türlerini veya sınıfı temsil ederken, P sınıflamanın doğruluk değerini gösterir. Bir arayüz sistemindeki çeşitli zihinsel görevlerin sayısının artması veya sınıf sayısının artması B 'deki artışa işaret eder. Alınan her bir karakterin tanıma doğruluğunun arttırılması da diğer yandan ITR'de bir iyileşme sağlar. Bununla birlikte, iletilen

verilerin (Δt_{ITR}) zaman maliyeti ile alınan doğru karakter verilerinin olasılığı arasında bir denge vardır [9].

3.4.2. Çok katmanlı sinir ağları

Yapay sinir ağları (ANN), beyinin bilgi işleme yeteneğinden esinlenerek geliştirilmiş bilgi işleme yapısına sahip bir algoritmadır. Böylece, yapay sinir ağları yeni bilgi öğrenebilir ve sahip olduğu modeli yeni bir probleme uyarlayabilir. Verilen bir problemi çözmek ve probleme özel olarak uygulamak için anahtar paradigma, nöronlar olarak adlandırılan birbirine bağlı unsurlardır [5], [6]. Doğrusal veya doğrusal olmayan transfer (aktivasyon) fonksiyonlarına sahip birçok yapay nörondan oluşan yapay sinir ağı, insan beyninin nöral yapısını taklit eder [9], [115].

Çok katmanlı sinir ağı (MLNN) örüntüyü tanımak için biyomedikal sinyal işlemede yaygın olarak kullanılan bir yapay sinir ağı türüdür. Bu algoritmayı kullanmanın ardındaki motivasyon, bir sistemin veya veri örneklerinin doğrusal olmayan davranışlarını yakalamak ve bunları tahmin etme yeteneğine sahip olmasıdır. MLNN'in yapısı, giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur [116]. MLNN, örüntüyü öğrenme ve genelleştirme yeteneğine sahiptir. İlk ve ikinci gizli katman çıktılarına ait denklemler sırasıyla 3.27 ve 3.28'de gösterilmektedir. Ayrıca çıkış katmanına ait denklem ise 3.29'da formülize edilmiştir:

$$\vec{X}^{ih1}(n) = \frac{1}{1 + \exp\left(W^{ih1}(n) * \vec{f}(n) + \vec{b}^{ih1}(n)\right)} \quad (3.27)$$


$$\vec{X}^{ih2}(n) = \frac{1}{1 + \exp\left(W^{ih2}(n) * \vec{X}^{ih1}(n) + \vec{b}^{ih2}(n)\right)} \quad (3.28)$$

$$\vec{Y}(n) = \frac{1}{1 + \exp\left(W^{ho}(n) * \vec{X}^{ih2}(n) + \vec{b}^{ho}(n)\right)} \quad (3.29)$$

Denklemlerde $W^{ih1}(n)$, giriş katmanından ilk gizli katmana giden ağırlıkları temsil ederken, $\vec{b}^{ih1}(n)$ birinci gizli katmandaki bayes değerlerini ifade eder. Benzer

şekilde, $W^{ih2}(n)$ birinci gizli katman ve ikinci gizli katman arasındaki ağırlık değerlerini gösterirken, $\vec{b}^{ih2}(n)$ ikinci gizli katmandaki bias değerlerini göstermektedir. Daha sonra, $W^{ho}(n)$ ikinci gizli katmandan çıkışa giden ağırlıkları tanımlarken, $\vec{b}^{ho}(n)$ çıkış katmanındaki biası göstermektedir. Bununla beraber $\vec{f}(n)$ özellik vektörünü, $\vec{Y}(n)$ sınıf indekslerini gösteren çıkışı, n ise eğitim örüntü indeksini ifade eder [9].

Bir nöronun çıkışı, ağırlıklandırılmış girişler ile bias değerinin toplamının bir fonksiyonu olarak ifade edilir. Çıkışı oluşturmak için, bir nöronun girişlerinin ağırlıklı toplamına bir aktivasyon fonksiyonu uygulanır. Genel olarak kullanılan aktivasyon fonksiyonunun örneği sigmoiddir. Bu tez çalışmasında ise MLNN için logaritmik sigmoid fonksiyonu kullanılmıştır. MLNN’de eğitim örneklerinin ağırlıklı sunulması, istenen sonuçlara daha iyi yaklaşılması amacıyla ağırlıkların değiştirilmesi eylemi olarak tanımlanmaktadır. MLNN yapısı Şekil 3.6.’da gösterilmiştir.



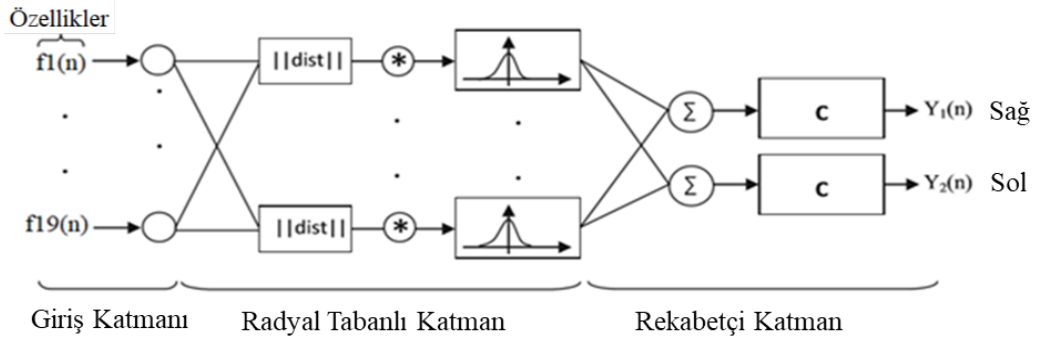
Şekil 3.6. Çok katmanlı sinir ağı yapısının gösterimi [9]

Bu çalışmada, sağ-sol yön için dil hareketleri tarafından üretilen GKP biyo-potansiyellerini sınıflandırmak için Levenberg Marquardt (LM) eğitim algoritması kullanılmıştır. Levenberg Marquardt, hata yüzeyindeki gradyan değişimini değerlendirmek için bir Hessian matrisi kullanır. Bu şekilde LM, yerel bir minimumda yakalanmama nedeniyle ikinci derece eğitim yöntemleri arasında çok hızlı ve verimli bir algoritmadır. Bu çalışmada, GKP tabanlı TMI’da sağ ve sol kararın sınıflandırılması için çok katmanlı yapay sinir ağına on dokuz kanallı özellik

vektörü giriş olarak sunulmuştur. MLNN yapısı içindeki en önemli sorunlardan biri, uygun gizli katman ve nöron sayısının belirlenmesidir [9]. Bu iş için belli bir matematiksel mutlak kural yoktur. Ağ olarak tanımlanan yapının optimal değeri, verilen görevi gerçekleştirebilecek ve genelleme yeteneğini en üst düzeye çıkarabilen en düşük gizli katman sayısına sahip olmasıdır. Ayrıca, ikinci mertebeden eğitim algoritması kullanan sinir ağı, sınıflandırmada birinci mertebeden eğitim yöntemlerine sahip ağlardan daha iyi bir yakınsamaya sahiptir. Bu sebeple, bu tez çalışmasında MLNN ağı, LM ile eğitilmiştir. Tez içinde kullanılan ağ yapısında iki gizli katmandaki nöron sayısı (20 nöron/ilk gizli katman ve 50 nöron/ikinci gizli katman), ortalama karesel hata (MSE) kriterine dayanan deneme ve hata kuralı kullanılarak belirlenmiştir. MLNN'de gizli katmandaki nöron sayısı sabit değerler olarak belirlenmiştir. Diğer durumda, gizli nöron sayısının rastgele seçimi, yetersiz öğrenme (Underfitting) veya aşırı öğrenme (Overfitting) sorunlarına neden olabilir. Bu sebeplerden dolayı, gizli nöron sayısının sabitlenmesi önemli ölçüde önemlidir [9].

3.4.3. Olasılıksal sinir ağları

Olasılıksal sinir ağları (PNN), radyal taban ve rekabet katmanları olarak adlandırılan iki orta katmana sahip bir tür ileri beslemeli ağ yapısına sahiptir. Donald Specht tarafından geliştirilmiş olan PNN, Gauss çekirdeklerini kullanarak olasılık yoğunluk fonksiyonunu tahmin eder ve Bayes karar diskriminant fonksiyonunu gerçekleştirir [5], [9]. Çan şeklinde bir aktivasyon fonksiyonu kullanan, mesafeye dayalı bir yapay sinir ağı olarak bilinir. Bu yöntem, doğrusal olmayan karar sınırlarını uygular ve Bayes optimal yaklaşımını kullanır [117]. PNN, tıbbi karar vericilere tanıdık bir süreç olan Bayes stratejisi nedeniyle biyomedikal kullanım için uygundur. Ayrıca, PNN'de geri yayılım algoritması kullanılmadığından, ağın tüm veri seti üzerinde eğitilmesi gerekli değildir. Böylece MLNN'e göre daha hızlı sınıflandırma işlemi yapılabilir [118], [119]. PNN ile ilgili örnek gösterim Şekil 3.7.'de görülmektedir.



Şekil 3.7. Olasılıksal sinir ağına ait örnek gösterim [9]

PNN radyal taban katmanında, ilk orta tabaka, giriş vektörü ile ağırlık matrisi arasındaki mesafeleri hesaplar ve ikinci orta tabaka (rekabet katmanı), maksimum doğruluk olasılığı ile sınıflandırmayı belirler. Tüm gizli üniteler, ünite bağlantı ağırlıkları vasıtasıyla ağ-gizli katman düğümlerine taşınan on dokuz boyutlu giriş vektörünü alır. Gizli katman bir dizi radyal temel fonksiyondan oluşur. j' inci gizli birim ile ilgili parametre vektörünün merkezi \vec{c}_j olarak isimlendirilir. Gizli katman düğümleri, merkez ve ağ giriş katmanı arasındaki Öklid mesafesini belirler. Daha sonra sonuçlar ağıdaki Gaussal olan radyal temelli fonksiyonlara taşınır [116]. PNN ile ilgili denklemler şöyledir:

$$X_j = \phi(\|\vec{f} - \vec{c}_j\| * b^{ih}) \quad (3.30)$$

$$\phi(x) = \exp(-x^2) \quad (3.31)$$

$$b^{ih} = 0.833/s \quad (3.32)$$

$$S_i = \sum_{j=1}^h W_{ji}^{ho} * X_j \quad (3.33)$$

$$Y_i = \begin{cases} 1, & \text{if } S_i \text{ is max of } \{S_1, S_2\} \\ 0, & \text{else} \end{cases} \quad (3.34)$$

Denklemlerde $i=1,2$ ve $j=1,2\dots h$. Y_i , i 'inci (sınıflandırma indeksi) çıkış olarak ifade edilir. \vec{f} , ondokuz boyutlu giriş vektörünü ifade ederken, W_{ji}^{ho} j 'inci gizli düğüm ile i 'inci çıkış düğümü arasındaki ağırlıkları göstermektedir. \vec{c}_j , j 'inci gizli vektör merkezini tanımlarken, s yayılma faktörü (Spread Factor) olarak bilinir ve sabit bir

sayıdır. b^{ih} radyal tabanlı katmanın bayes değerini ifade ederken, $\phi(\cdot)$ Gauss tabanlı radyal fonksiyonu göstermektedir [116].

Yayıma faktörü PNN için sınıflandırmada önemlidir. Bu nedenle, uygun bir değer genellikle verilere bağımlı olabilir [117]. Tez çalışması içinde, PNN' nin en iyi performansını sağlamak ve aktivasyon fonksiyonlarının yayılımının en uygun değerini bulmak için 0,01 basamak değeri ile (0,1-1) değerleri arasında yayılım faktörü araştırması yapılmıştır [9].

3.4.4. Destek vektör makinesi

Destek vektör makinesi, Corinna Cortes ve Vladimir Vapnik tarafından önerilen bir makine öğrenmesi algoritmasıdır [3]. SVM, bio-sinyal örüntülerini, özellikle EEG'yi sınıflandırmak için çok yaygın ve kullanışlı bir araçtır ve sınıflandırma algoritmaları içerisinde çekirdek tabanlı bir yöntemdir. SVM'de eğitim sürecinden sonra, ağırlık vektörü hesaplanır ve destek vektörleri olarak adlandırılır. Bunlar, belirsiz ve hatalı durumların meydana geldiği bilginin elde edilmesi için sınırlara (hiperdüzlem) yakın olan durumlardır. Böylece, hiperdüzlem sınıflandırma sürecinde karar için girdi boşluğunu ayırır. Hiperdüzlemden iki tarafa en yakın destek vektörlerine olan uzaklık marjın olarak adlandırılır [87], [112]. SVM, Şekil 3.8.'de gösterildiği gibi, genelleme için kenar boşluğu ve optimal ayıran hiperdüzlemi en üst düzeye çıkarmayı amaçlamaktadır. SVM ile ilgili temel denklemler şöyledir:

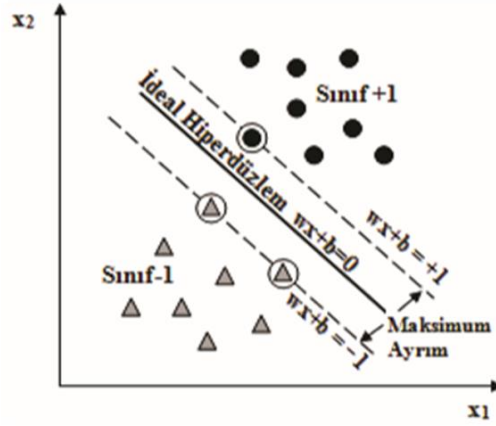
$$X\{t\} = \begin{cases} r^t = +1, & x^t \in C1 \\ r^t = -1, & x^t \in C2 \end{cases} \quad (3.35)$$

$$g(x) = \begin{cases} w^T x^t + w_0 \geq +1, & x^t \in C1 \\ w^T x^t + w_0 \leq -1, & x^t \in C2 \end{cases} \quad (3.36)$$

Denklemlerde, $X\{x^t, r^t\}$ eğitim kümesi olmak üzere, -1/+1 iki sınıf olarak etiketlenmiştir. İki sınıfı doğrusal olarak ayırmak için $g(x)$ hiperdüzlem olarak tanımlanır. w_0 hiperdüzlemin yerini hesaplarken, w oriyantasyonunu hesaplamakta kullanılır [3]. Böylece:

$$r^t(w^T x^t + w_0) \geq +1 \quad (3.37)$$

olur. SVM öğrenme oranı, başlatma ve yakınsama kontrolü gibi sezgisel parametreler kullanmaz [3].




Şekil 3.8. Destek vektör makinesi ve sınıflandırma örneği [87]

3.4.5. Doğrusal ayırım analizi

Doğrusal ayırım analizi (LDA), verilerin boyutunu azaltan bir tür projeksiyon tekniği sınıflandırıcısıdır. LDA, sınıflar arası mesafeyi maksimize etmeyi ve sınıf içi mesafeyi en aza indirmeyi amaçlamaktadır [3], [112]. $C1$ ve $C2$, örneklerin sınıfları olarak tanımlanırsa, LDA mümkün olduğunca maksimum ayrılabilirlik doğrultusunda uzamsal modeli ayırt etmek için projeksiyon yönünü (w) bulur [112]. Doğrusal ayırım analizi ile ilgili denklem şöyledir:

$$z = w^T x \quad (3.38)$$

Denklem 3.38'de x , w üzerine projeksiyon edilen örnekleri gösterir. LDA ile ilgili örnek gösterim Şekil 3.9.'da gösterilmektedir:



Şekil 3.9. LDA projeksiyon tekniği ile sınıflandırma için örnek bir gösterim [112]

LDA ile ilgili örnek gösterimde örnekler (x) için, m_1 ve m_2 projeksiyon edilmeden önce ve sonraki ortalama değerleri göstermektedir. $m_1 \in \mathcal{R}^d$ ve $m_2 \in \mathcal{R}^d$ olmak üzere m_1 ve m_2 de m_1 ve m_2 ile aynı ifadeleri tanımlar. Yine aynı şekil üzerinde, s_1^2 ve s_2^2 ortalamalar etrafındaki saçılmaları göstermektedir. Bununla beraber $X\{x^t, r^t\}$ örnek eğitim veri kümesi içinde x giriş ve r çıkış çiftleri olmak üzere diğer ilgili denklemler şöyle tanımlanmıştır:

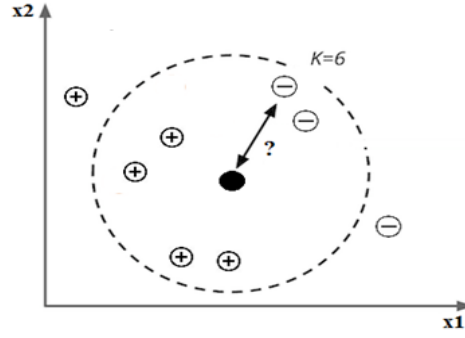
$$X\{t\} = \begin{cases} r^t = 1, & x^t \in C1 \\ r^t = 0, & x^t \in C2 \end{cases} \quad (3.39)$$

$$J(w) = \frac{w^T S_B w}{w^T S_W w} = \frac{|w^T (m_1 - m_2)|^2}{w^T S_W w} \quad (3.40)$$

Denklemlerde, $j(w)$ için S_B ve S_W sırasıyla sınıf içi ve sınıflar arası saçılımı göstermektedir [112].

3.4.6. En yakın k komşuluğu

kNN algoritması, girdi olarak sınıflandırılan veriyi girdinin en yakın k komşularından en çok örnek sınıfı olan sınıfa atar. Başka bir ifade ile tüm komşuların eşit oyu vardır ve k sayıdaki komşular arasında en fazla sayıda seçmene sahip olan sınıf seçilir. Yumuşatma parametresinin derecesi, kNN algoritması içinde k tarafından kontrol edilir. Böylece k, N'den (veri uzunluğu) küçük olmalıdır [112]. kNN ile ilgili gösterim Şekil 3.10.'da gösterilmiştir.



Şekil 3.10. İki sınıflı en yakın k komşuluğu algoritmasına ait örnek bir gösterim

kNN ile ilgili matematiksel ifadeler şöyledir:

$$d_1(x) \leq d_2(x) \leq \dots \leq d_N(x) \quad (3.41)$$

Denklem 3.41'de her örnek için a ve b arası mesafe öklid uzaklığı olarak tanımlanırsa; mesafeler, en yakın $d_1(x)$ mesafesi ve bir sonraki en yakın mesafe $d_2(x)$ ile artan sırada bulunur. Aşağıdaki denklemde; x^t , veri noktaları olarak tanımlanır ve t , örneklerin komşuluklarını ifade eder:

$$d_1(x) = \min_t |x - x^t| \quad (3.42)$$

Eğer i en yakın örneğin indeksini gösterirse:

$$i = \arg \min_t |x - x^t| \quad (3.43)$$


Böylece,

$$d_2(x) = \min_{j \neq i} |x - x^j| \quad (3.44)$$

Bu çalışmada, en iyi sonucu elde etmek için k değeri, 1'er adımlık değerler olarak 3 ile 25 arasında araştırılmıştır [3], [120]. Bununla beraber genel olarak optimum k değerlerinin 15-20 arasında olduğu gözlenmiştir [3].

3.4.7. Karar ağaçları

Karar ağaçları (DT), böl ve yönet stratejisini uygulayan kural tabanlı algoritmalarıdır. Bir modelin ağacını, bir dizi basit kurala dönüştürmek için verileri eğitim aşamasında bir model olarak yapılandıran parametrik olmayan yöntemlerdir. Ardından, yeni veri seti, iç karar düğümlerini ve sınıfları etiketlemek için terminal yaprakları oluşturarak, tekrarlı bölünmeler dizisi olarak tanımlanır [112], [121]. Karar ağacı yapısına ait örnek gösterim Şekil 3.11.'de gösterilmiştir.



Şekil 3.11. Veri seti ve ilgili karar ağacı ile sınıflandırma örnek gösterimi [112]

Bu çalışmada, ayrılma kriterlerini seçmek için Gini indeksli karar ağacı kullanılmıştır. Gini indeksi kullanan karar ağacı ile ilgili denklemler şöyledir:

$$Gini_{sol} = 1 - \sum_{i=1}^k \left(\frac{L_i}{|T_{sol}|} \right)^2 \quad (3.45)$$

$$Gini_{sağ} = 1 - \sum_{i=1}^k \left(\frac{R_i}{|T_{sağ}|} \right)^2 \quad (3.46)$$

k , veri kümesindeki toplam sınıf sayısıdır. T bir düğümdeki örnek sayısını, $|T_{sol}|$ sol daldaki örnek sayısını, $|T_{sağ}|$ sağ daldaki örnek sayısını, L_i sol daldaki i 'inci gruptaki örnek sayısını ve R_i sağ daldaki i 'inci gruptaki örnek sayısını tanımlar. İlgili özellik değerleri çiftler halinde gruplandırılır. Sol ve sağ ayırımlara karşılık gelen sınıf değerleri bu şekilde elde edilir. Daha sonra $Gini_{sol}$ ve $Gini_{sağ}$ değerleri, ilgili her bir özelliğin sol ve sağ bölümleri için hesaplanır:

$$Gini_j = \frac{1}{n} (|T_{sol}| \cdot Gini_{sol} + |T_{sağ}| \cdot Gini_{sağ}) \quad (3.47)$$

İlgili j özniteliği için hesaplanan *Gini* değerlerinin en küçüğü, bölünmenin bu öznitelikte gerçekleştirilmesi için seçilir. Bütün sınıflandırma işlem sonucu için her bir iç karar düğümü ve terminal yaprakları aracılığıyla işlem dizisi tekrarlanır [122].

3.4.8. Konvolüsyonel sinir ağları

Konvolüsyonel sinir ağı (CNN) görüntü işleme, bilgisayar görmesi, konuşma tanıma ve doğal dil işleme için son yıllarda geliştirilen makine öğrenmesi algoritmasıdır. Bununla beraber CNN, çok kanallı EEG sinyallerini işlemede aynı katılımcı için ve katılımcılar arası (Inter and Intra Subject) dikkate değer derecede değişkenliği olan zorlu veri kümelerinde oldukça iyi performans göstermektedir [123]. CNN mimarisi içerisinde, konvolüsyon katmanı (Convolutional Layer), havuzlama katmanı (Pooling Layer) ve tamamen bağlı katman (Fully Connected Layer) olmak üzere üç ana katman vardır [100], [106]. Konvolüsyon katmanı, görüntü tabanlı 2-D zaman serisi sinyallerinin pikselleri ile konvolüsyon işlemine girebilen matris formunda olan filtre yapılarına (Kernels) sahiptir. Konvolüsyon katmanları, görüntü üzerinde kenarlar, çizgiler ve köşeler gibi farklı özellikleri ortaya çıkarmayı amaçlamaktadır [105]. Konvolüsyon operatörü ile ilgili matematiksel denklem şöyledir:

$$y_k = \sum_{n=0}^{N-1} x_n h_{k-n} \quad (3.48)$$

Denklem 3.48’de x zaman serisi sinyallerini ifade ederken, h konvolüsyon matrisini ya da çekirdeği, N , x ‘in veri uzunluğunu, y ise özellik haritasını (Feature Map) veya çıkış vektörünü gösterir [106]. Havuzlama katmanı, özellik haritalarının boyutunu azaltmak için kullanılır ve aşağı örnekleme katmanı olarak adlandırılır. Bu nedenle, aşırı öğrenme ve hesaplama karmaşıklığı havuzlama katmanı ile hafifletilmiş olur. Tamamen bağlı katman ise verinin sınıfını belirler. Bu çalışmada iki farklı tür aktivasyon fonksiyonu kullanılmıştır. Bunlar: (1) Düzeltilmiş doğrusal aktivasyon birimi (Rectified Linear Activation Unit-ReLU) ve (2) Softmax’dır.

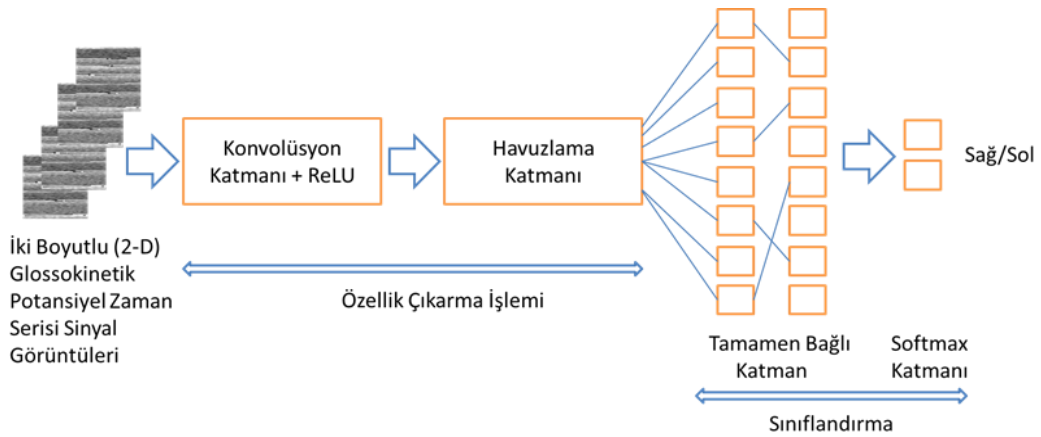
- (1) Düzeltilmiş doğrusal aktivasyon birimi: Her bir konvolüsyon katmanından sonra bir aktivasyon fonksiyonu uygulamak için yaygın bir uygulamadır. ReLU, ağ yapısına doğrusal olmayan bir durum sağlar [105], [106]. İlgili denklem şöyledir:

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x < 0 \end{cases} \quad (3.49)$$

- (2) Softmax: Bu fonksiyon k tane sayıda çıkış sınıfının olasılığını hesaplamak için kullanılır [106].

$$p_j = \frac{e^{x_j}}{\sum_1^k e^{x_k}} \quad j = 1, \dots, k \quad (3.50)$$

Denklem 3.50’de x (2-D zaman serisi sinyalleri için) ağın girişidir. Ağ üzerinde çıkışın değerleri 0-1 aralığındadır ve bunların olasılıksal toplamı 1 olarak kabul edilir. Tez çalışmasında kullanılan CNN mimarisi (Şekil 3.12.), çekirdek büyüklüğü 5 olan 5 ile 20 arasında değişen konvolüsyon katmanına sahiptir. Ayrıca, maksimum havuz katmanında çekirdek büyüklüğü 2 ve adım sayısı 4 ile 6 arasında seçilmekle beraber en iyi sınıflandırma performansına adım sayısı 5 ile ulaşılmıştır.



Şekil 3.12. Tez çalışması içinde kullanılan CNN mimarisi örnek gösterimi

BÖLÜM 4. ÇALIŞMANIN BULGULARI

Glossokinetik potansiyel tabanlı dil-makine arayüzünün sinyal işleme ve makine öğrenmesi algoritmalarına ait performans çıktıları bu bölümde gösterilmiştir. Tez çalışmasına ait sonuçlar, 10 katılımcı için ayrı ayrı bulunmuş ve ilgili veri setine ait tablolarda verilmiştir. Bulgular geleneksel sınıflandırıcılar için kullanılan özellik çıkarma metotları alt başlıkları altında gösterilmiştir. Konvolüsyonel sinir ağına ait sonuçlar da farklı alt başlık altında bölüm içinde verilmiştir. 10 katılımcı arasında her özellik çıkarma metodu için ham veri seti sonuçları içinde en yüksek sınıflandırma doğruluğunu elde eden katılımcı en başarılı katılımcı, en düşük sınıflandırma doğruluğunu elde eden katılımcı en başarısız katılımcı olarak adlandırılmıştır. Sonuçlar içinde kıyaslamalar yapılırken artış ve/veya azalış oranları yüzde ile ifade edilirken, kıyaslamalardaki artış ve/veya azalış değerleri puan olarak ifade edilmiştir.

4.1. Geleneksel Sınıflandırıcılar İçin Performans Değerleri

Geleneksel makine öğrenmesi algoritmaları içinde kullanılan özellik çıkarma metotları şöyle düzenlenmiştir; ortalama karesel kök (RMS), standart sapma (STD), varyans (VAR), ortalama değer (MV), ortalama mutlak değer (MAV), maksimum tepe değeri (MPV), şekil faktörü (SF) ve güç spektral yoğunluğu (PSD). Literatürde olduğu gibi tez çalışması sonuçları içinde de zaman alanı metotları arasında RMS, diğer özellik çıkarma metotlarına kıyasla 10 katılımcıya ait ortalama başarıda en yüksek sonucu ürettiği görülmüştür [3], [9]. Bundan dolayı RMS için oluşturulan bütün veri setlerine ait sonuçlar bağımsız bileşen analizi (ICA) dışında, diğer kullanılan ön işleme ve sınıflandırma yöntemlerinin tamamı için elde edilmiştir. Bununla beraber tez çalışması içinde kullanılan ML algoritmaları içinde çekirdek tabanlı algoritmalar (SVM ve LDA) ile elde edilen sonuçlar bütün özellik çıkarma ve veri setlerinin hepsinde ortak olarak bulunmuştur. Yine tez çalışması içerisinde tüm ML algoritmalarına ait sonuçların tamamı ham veri seti ve temel bileşen analizi veri

setlerinde ortak olarak bulunmuştur. Bağımsız bileşen analizi özellik azaltma yöntemine ait sonuç değerleri de, ortalama karesel kök, ortalama mutlak değer ve güç spektral yoğunluğu özellik çıkarma metotları için ilgili tablolarda ortaya konulmuştur. Tez çalışması içinde sunulan zaman-frekans skalası, frekans spektrumu ve periodogram grafiklerinde, en başarılı ve en başarısız katılımcının Fp2 kanalındaki ilk altı saniyelik sağ dil hareketine ait ham veri sinyali içindeki en uygun veri aralığı kullanılmıştır. Beyin haritalama gösterimleri için ise 6 sn'lik sağ ve sol dil hareketleri içindeki en uygun zaman aralığı seçilmiştir. Bununla beraber zaman-frekans skalası ve frekans spektrumu grafiğine ait genlik ölçeğinin belirli bir oranda farklı olduğu gözlenmiştir. Bundan dolayı zaman-frekans skalasında genlik grafiği yalnızca renk seviyesi ile ifade edilmiştir.

4.1.1. Ortalama karesel kök sonuçları

Zaman alanı özellik çıkarma yöntemlerinden birisi olan ortalama karesel kök (RMS) metoduna ait sonuçlar ilgili tablolarda verilmiştir. Her katılımcı ve bu katılımcıların ortalama sonuçları için doğruluk, duyarlılık, özgüllük ve bilgi transfer oranı elde edilmiştir. RMS metoduna ait sonuç tablolarında ve grafiksel sonuçlarda en başarılı ve en başarısız katılımcıya ait değerlendirmeler yapılmıştır.


Tablo 4.1. RMS ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|
| ACC | 77,02 | 97,01 | 75,28 | 80,69 | 91,18 | 93,01 | 87,06 | 72,53 | 90,48 | 96,05 | 86,03 | SVM |
| SPEC | 81,96 | 98,00 | 76,88 | 74,93 | 90,82 | 94,53 | 85,45 | 64,31 | 85,29 | 97,41 | 84,96 | |
| SENS | 70,27 | 96,05 | 73,76 | 88,23 | 91,49 | 93,21 | 88,66 | 83,04 | 97,53 | 94,25 | 87,65 | |
| ITR | 0,222 | 0,806 | 0,193 | 0,292 | 0,570 | 0,673 | 0,444 | 0,152 | 0,547 | 0,760 | 0,466 | |
| ACC | 78,00 | 97,01 | 78,24 | 80,20 | 90,04 | 95,45 | 86,34 | 73,30 | 77,03 | 96,00 | 85,16 | LDA |
| SPEC | 78,83 | 96,00 | 80,42 | 74,57 | 89,55 | 97,45 | 85,41 | 67,47 | 69,22 | 97,84 | 83,68 | |
| SENS | 76,88 | 97,97 | 74,81 | 88,25 | 90,52 | 92,38 | 87,28 | 80,93 | 87,66 | 93,47 | 87,02 | |
| ITR | 0,240 | 0,806 | 0,244 | 0,282 | 0,532 | 0,733 | 0,425 | 0,163 | 0,223 | 0,758 | 0,441 | |
| ACC | 72,35 | 96,07 | 73,01 | 72,10 | 86,07 | 92,56 | 82,58 | 73,68 | 77,48 | 94,45 | 82,04 | KNN |
| SPEC | 84,92 | 95,43 | 79,31 | 78,18 | 87,42 | 97,00 | 78,15 | 72,33 | 72,43 | 97,77 | 84,29 | |
| SENS | 55,63 | 96,74 | 64,89 | 63,34 | 84,46 | 85,95 | 87,64 | 75,39 | 84,21 | 89,99 | 78,82 | |
| ITR | 0,149 | 0,761 | 0,159 | 0,146 | 0,418 | 0,618 | 0,333 | 0,169 | 0,231 | 0,691 | 0,367 | |

Tablo 4.1. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 77,64 | 97,00 | 77,24 | 80,63 | 90,22 | 95,04 | 87,65 | 79,23 | 83,12 | 96,09 | 86,39 | |
| SPEC | 83,70 | 98,00 | 79,92 | 81,79 | 91,20 | 97,45 | 87,32 | 81,66 | 79,60 | 95,65 | 87,63 | MLNN |
| SENS | 68,79 | 95,53 | 73,42 | 78,45 | 86,68 | 90,83 | 88,16 | 75,21 | 85,28 | 95,00 | 83,74 | |
| ITR | 0,233 | 0,806 | 0,226 | 0,291 | 0,538 | 0,715 | 0,461 | 0,263 | 0,345 | 0,762 | 0,464 | |
| ACC | 73,03 | 95,29 | 72,19 | 75,09 | 87,18 | 95,01 | 84,03 | 80,42 | 79,61 | 94,02 | 83,59 | |
| SPEC | 90,75 | 96,00 | 89,25 | 75,31 | 88,26 | 96,63 | 82,64 | 77,77 | 74,00 | 97,83 | 86,84 | PNN |
| SENS | 49,80 | 94,66 | 49,92 | 74,54 | 85,17 | 92,55 | 85,62 | 83,80 | 87,23 | 88,68 | 79,20 | |
| ITR | 0,159 | 0,726 | 0,147 | 0,190 | 0,447 | 0,714 | 0,366 | 0,287 | 0,270 | 0,673 | 0,398 | |
| ACC | 70,35 | 94,23 | 72,20 | 72,72 | 84,11 | 93,02 | 82,06 | 76,73 | 77,25 | 92,12 | 81,48 | |
| SPEC | 77,06 | 93,00 | 77,79 | 78,32 | 86,61 | 94,91 | 82,19 | 76,72 | 80,07 | 91,88 | 83,85 | DT |
| SENS | 61,64 | 95,56 | 65,00 | 64,61 | 80,69 | 90,34 | 82,08 | 76,84 | 73,50 | 92,23 | 78,25 | |
| ITR | 0,123 | 0,682 | 0,147 | 0,155 | 0,368 | 0,635 | 0,321 | 0,217 | 0,226 | 0,602 | 0,348 | |

Tablo 4.1.'de ham veri setine ait ortalama karesel kök sonuçları görülmektedir. RMS metoduna ait bu sonuçlarda en iyi performans gösteren katılımcı-2 (SB2), %97,01 doğruluk oranına SVM ve LDA ile ulaştığı görülmektedir. Bununla beraber en düşük performans gösteren katılımcı-1 (SB1) için en düşük ve en yüksek doğruluk oranı (ACC) sırasıyla %70,35 (DT) ve %78 (LDA) olarak elde edilmiştir. 10 katılımcıya ait ortalama en yüksek doğruluk sonucu %86,39 ile çok katmanlı sinir ağında (MLNN) bulunurken, en düşük ortalama doğruluk sonucu %81,48 ile karar ağacında (DT) elde edilmiştir. En başarılı katılımcı ve en başarısız katılımcı arasında en yüksek sonuç değeri için 19,01 puan doğruluk oranı farkı elde edilirken, bu fark %19,59'luk doğruluk oranı artışına karşılık geldiği görülmektedir. Çekirdek tabanlı makine öğrenmesi algoritmalarından olan SVM (%86,03 ortalama) ve LDA (%85,16 ortalama) bireysel sonuçlarda (katılımcı-2 ve katılımcı-1) en yüksek sonuçları elde ettikleri gibi ortalama sonuçlar açısından da MLNN dışında en yüksek sonuçları üreten algoritmalar olarak görülmektedir. En başarılı ve en başarısız katılımcıya ait grafiksel sonuçlar Şekil 4.1.'de görülmektedir.



Şekil 4.1. Ortalama karesel kök ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.2. RMS ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 78,04 | 97,01 | 78,34 | 79,09 | 91,43 | 94,08 | 86,05 | 73,03 | 72,20 | 95,71 | 84,50 | SVM |
| SPEC | 86,80 | 97,50 | 79,07 | 81,36 | 92,84 | 95,78 | 85,04 | 70,99 | 64,93 | 97,83 | 85,21 | |
| SENS | 66,53 | 96,49 | 77,30 | 76,25 | 89,83 | 92,07 | 87,43 | 75,45 | 82,50 | 92,81 | 83,67 | |
| ITR | 0,241 | 0,806 | 0,246 | 0,260 | 0,578 | 0,676 | 0,417 | 0,159 | 0,147 | 0,745 | 0,428 | |
| ACC | 79,08 | 97,03 | 78,05 | 76,35 | 89,27 | 94,14 | 85,02 | 72,12 | 71,26 | 95,02 | 83,73 | LDA |
| SPEC | 79,19 | 96,00 | 80,42 | 72,30 | 89,51 | 95,80 | 82,29 | 67,33 | 59,67 | 97,39 | 81,99 | |
| SENS | 78,95 | 98,06 | 75,60 | 82,31 | 88,97 | 92,24 | 87,85 | 78,08 | 87,04 | 92,15 | 86,13 | |
| ITR | 0,260 | 0,807 | 0,241 | 0,211 | 0,508 | 0,678 | 0,391 | 0,146 | 0,135 | 0,715 | 0,409 | |
| ACC | 73,61 | 93,01 | 74,15 | 73,22 | 87,19 | 95,03 | 81,04 | 76,94 | 81,23 | 93,09 | 82,85 | KNN |
| SPEC | 86,30 | 91,96 | 86,39 | 76,07 | 87,14 | 96,04 | 78,30 | 75,00 | 79,71 | 97,64 | 85,46 | |
| SENS | 56,77 | 94,16 | 58,57 | 69,46 | 87,19 | 93,34 | 84,34 | 79,61 | 83,64 | 86,80 | 79,39 | |
| ITR | 0,167 | 0,635 | 0,176 | 0,162 | 0,448 | 0,715 | 0,299 | 0,221 | 0,303 | 0,637 | 0,376 | |
| ACC | 78,43 | 97,25 | 74,78 | 77,30 | 89,43 | 95,18 | 85,39 | 79,77 | 77,19 | 94,27 | 84,90 | MLNN |
| SPEC | 80,20 | 96,00 | 76,90 | 77,08 | 92,45 | 96,61 | 83,03 | 81,19 | 75,33 | 95,65 | 85,44 | |
| SENS | 75,19 | 98,00 | 70,89 | 75,42 | 84,31 | 91,36 | 86,45 | 77,47 | 79,50 | 91,37 | 83,00 | |
| ITR | 0,248 | 0,819 | 0,185 | 0,227 | 0,513 | 0,721 | 0,400 | 0,273 | 0,225 | 0,684 | 0,430 | |
| ACC | 73,54 | 96,02 | 73,56 | 74,46 | 87,01 | 95,30 | 84,59 | 78,27 | 84,07 | 94,12 | 84,09 | PNN |
| SPEC | 89,37 | 96,00 | 83,97 | 77,08 | 89,13 | 97,05 | 84,55 | 74,17 | 83,55 | 97,41 | 87,23 | |
| SENS | 52,83 | 96,07 | 60,25 | 70,74 | 83,48 | 92,98 | 84,80 | 83,66 | 84,70 | 89,67 | 79,92 | |
| ITR | 0,166 | 0,758 | 0,167 | 0,180 | 0,443 | 0,726 | 0,380 | 0,245 | 0,367 | 0,677 | 0,411 | |
| ACC | 74,41 | 93,03 | 74,06 | 73,13 | 86,26 | 92,26 | 82,26 | 76,26 | 77,05 | 92,30 | 82,10 | DT |
| SPEC | 80,59 | 92,00 | 80,93 | 77,07 | 87,88 | 92,84 | 82,23 | 76,30 | 77,50 | 95,24 | 84,26 | |
| SENS | 66,63 | 94,06 | 65,73 | 67,81 | 83,99 | 91,39 | 82,28 | 76,19 | 76,53 | 88,34 | 79,30 | |
| ITR | 0,180 | 0,635 | 0,174 | 0,160 | 0,423 | 0,607 | 0,326 | 0,209 | 0,223 | 0,609 | 0,355 | |

Tablo 4.2.'de temel bileşen analizi yöntemi ile azaltılmış ham veri seti için ortalama karesel kök özellik çıkarma metodu kullanılmış ve ilgili tablodaki sonuçlar elde edilmiştir. Her katılımcıya ait 19 kanalı içeren ham veri setinden 12 temel bileşen çıkarılmış ve veri seti (400×12) boyutuna indirgenmiştir. Tablo 4.2.'de görüldüğü üzere en iyi performans gösteren katılımcı-2 olmuştur. Bu katılımcı MLNN algoritması ile %97,25 doğruluk oranına ulaşırken, en düşük performans gösteren katılımcı-1, %79,08 doğruluk oranı sonucunu LDA ile elde etmiştir. 10 katılımcıya ait ortalama başarıda en iyi makine öğrenmesi algoritması MLNN (%84,90) olarak görülmektedir. PCA ile azaltılmış veri set üzerinde en başarılı ve en başarısız katılımcıya ait bireysel sonuçlarda en yüksek doğruluk oranının sırasıyla 0,24 ve 1,08 puan arttığı görülmektedir. Bununla beraber 10 katılımcıya ait ortalama en yüksek doğruluk oranının %86,39'dan %84,90'a azaldığı görülmektedir.

Tablo 4.3. RMS ve temel bileşen analizi veri seti sonuçları (400×10)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 76,89 | 97,25 | 76,61 | 75,17 | 89,08 | 96,01 | 85,18 | 77 | 79,01 | 96,07 | 84,83 | MLNN |
| SPEC | 81,07 | 97 | 79,98 | 79,67 | 88,3 | 96,23 | 84,05 | 81,25 | 75,74 | 96,54 | 85,98 | |
| SENS | 71,63 | 97,46 | 71,99 | 67,65 | 89,47 | 94,48 | 86,62 | 71,71 | 81,31 | 93,51 | 82,58 | |
| ITR | 0,220 | 0,818 | 0,215 | 0,191 | 0,503 | 0,758 | 0,395 | 0,222 | 0,259 | 0,761 | 0,434 | |
| ACC | 72,05 | 96,25 | 73,33 | 72,13 | 86,49 | 94,05 | 84,06 | 77,4 | 80,27 | 94,24 | 83,03 | PNN |
| SPEC | 89,9 | 96 | 80,85 | 77,54 | 89,15 | 96,21 | 82,68 | 76,26 | 80,96 | 97,45 | 86,70 | |
| SENS | 48,52 | 96,39 | 63,52 | 64,74 | 82,41 | 91,1 | 85,73 | 78,83 | 79,44 | 89,87 | 78,06 | |
| ITR | 0,145 | 0,769 | 0,163 | 0,146 | 0,429 | 0,674 | 0,367 | 0,229 | 0,283 | 0,682 | 0,389 | |

Tablo 4.3.'de temel bileşen analizi yöntemi ile boyutu azaltılmış veri setine (400×10) ait sonuç değerleri görülmektedir. İlgili tabloda MLNN ve PNN yapay sinir ağlarına ait sonuçlar gözlenmiştir. Görüldüğü üzere en başarılı katılımcıya ait doğruluk oranı %97,25 (MLNN) ile aynı kalırken, en başarısız katılımcıya ait doğruluk oranı %76,89'a (MLNN) düşmüştür. Ortalama doğruluk oranı başarısının ise 0,07 (%84,83-MLNN) puan düştüğü gözlenmiştir.

Tablo 4.4. RMS ve bağımsız bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 77,06 | 87,03 | 76,01 | 80,07 | 89,20 | 93,00 | 84,13 | 75,05 | 75,63 | 92,20 | 82,94 | |
| SPEC | 85,83 | 85,50 | 83,54 | 80,51 | 91,20 | 95,40 | 83,64 | 75,00 | 75,82 | 93,08 | 84,95 | SVM |
| SENS | 65,74 | 88,49 | 65,94 | 79,31 | 86,45 | 89,14 | 84,50 | 75,26 | 75,48 | 91,26 | 80,16 | |
| ITR | 0,223 | 0,443 | 0,205 | 0,279 | 0,506 | 0,634 | 0,369 | 0,189 | 0,199 | 0,605 | 0,365 | |
| ACC | 78,10 | 93,05 | 77,09 | 80,30 | 89,54 | 94,46 | 83,15 | 74,31 | 76,53 | 94,03 | 84,06 | |
| SPEC | 77,94 | 90,00 | 78,16 | 75,78 | 88,30 | 96,63 | 82,64 | 65,57 | 69,26 | 95,65 | 81,99 | LDA |
| SENS | 78,57 | 96,06 | 75,68 | 86,11 | 91,22 | 91,22 | 83,66 | 85,56 | 86,44 | 91,63 | 86,62 | |
| ITR | 0,242 | 0,636 | 0,224 | 0,284 | 0,517 | 0,691 | 0,346 | 0,178 | 0,214 | 0,674 | 0,400 | |

Tablo 4.4.'de bağımsız bileşen analizi yöntemi ile azaltılmış veri setine (400×12) ait sonuçlar görülmektedir. ICA yöntemi PCA yönteminin aksine boyut azaltmayı, temel bileşenleri hesaplayarak değil belirlenen bağımsız sayıda özelliği seçerek gerçekleştirmektedir. En başarılı katılımcı olan katılımcı-2 için en yüksek performans doğruluk değeri %93,05 (LDA) olarak hesaplanmıştır. Bununla beraber en başarısız katılımcı için görülen performans doğruluk değeri %78,10 (LDA) olarak elde edilmiştir. Ortalama doğruluk başarısı doğrusal ayırım analizi algoritması ile %84,06 olarak hesaplanmıştır. Görüldüğü üzere ICA yönteminde doğruluk oranı sonuç değerleri, PCA (400×12) veri setine göre en başarılı katılımcı için %4,31 oranında azalmıştır. Benzer şekilde ICA yöntemi sonuçlarında, en başarısız katılımcı ve ortalama doğruluk değeri için azalma miktarı %1,23 ve %0,98 olarak gözükmektedir.

Tablo 4.5. RMS ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|
| ACC | 76,03 | 96,01 | 74,11 | 61,29 | 83,08 | 93,79 | 85,08 | 61,27 | 67,04 | 92,03 | 78,97 | |
| SPEC | 87,25 | 96,00 | 83,58 | 96,52 | 87,90 | 95,38 | 81,73 | 93,72 | 59,75 | 93,91 | 87,57 | SVM |
| SENS | 61,55 | 95,99 | 62,14 | 12,99 | 75,95 | 91,71 | 88,77 | 20,02 | 76,88 | 89,42 | 67,54 | |
| ITR | 0,205 | 0,758 | 0,175 | 0,037 | 0,344 | 0,664 | 0,392 | 0,037 | 0,086 | 0,599 | 0,33 | |
| ACC | 76,35 | 96,05 | 74,68 | 61,11 | 81,26 | 94,11 | 85,15 | 58,04 | 65,80 | 91,02 | 78,36 | |
| SPEC | 77,45 | 94,50 | 76,42 | 55,36 | 82,43 | 94,96 | 81,60 | 69,21 | 54,49 | 92,63 | 77,91 | LDA |
| SENS | 74,95 | 97,55 | 72,68 | 68,79 | 79,60 | 92,76 | 89,32 | 43,85 | 81,14 | 88,40 | 78,90 | |
| ITR | 0,211 | 0,760 | 0,184 | 0,036 | 0,304 | 0,677 | 0,394 | 0,019 | 0,073 | 0,564 | 0,32 | |

Tablo 4.5. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 70,09 | 96,52 | 68,11 | 64,16 | 82,50 | 93,01 | 81,50 | 59,72 | 75,77 | 91,26 | 78,26 | kNN |
| SPEC | 85,77 | 96,00 | 87,25 | 73,26 | 87,20 | 94,59 | 80,62 | 72,86 | 74,96 | 92,93 | 84,54 | |
| SENS | 49,47 | 97,00 | 43,84 | 51,95 | 75,50 | 90,49 | 82,54 | 42,99 | 76,73 | 89,19 | 69,97 | |
| ITR | 0,120 | 0,782 | 0,097 | 0,059 | 0,331 | 0,634 | 0,309 | 0,027 | 0,201 | 0,572 | 0,31 | |
| ACC | 76,91 | 96,25 | 76,24 | 67,86 | 85,69 | 94,21 | 84,54 | 63,19 | 73,76 | 92,43 | 81,11 | MLNN |
| SPEC | 87,29 | 96,00 | 80,00 | 74,02 | 89,55 | 95,80 | 84,00 | 80,43 | 68,80 | 93,06 | 84,90 | |
| SENS | 62,28 | 96,10 | 71,42 | 59,04 | 78,90 | 91,96 | 84,69 | 40,97 | 79,68 | 90,47 | 75,55 | |
| ITR | 0,220 | 0,769 | 0,209 | 0,094 | 0,408 | 0,681 | 0,379 | 0,051 | 0,170 | 0,613 | 0,36 | |
| ACC | 71,27 | 96,28 | 70,08 | 65,37 | 82,26 | 93,24 | 82,04 | 64,27 | 78,10 | 91,20 | 79,41 | PNN |
| SPEC | 86,82 | 96,00 | 80,81 | 66,21 | 85,80 | 94,93 | 79,76 | 72,85 | 78,75 | 93,93 | 83,59 | |
| SENS | 50,35 | 96,61 | 56,22 | 64,17 | 77,15 | 90,82 | 83,99 | 53,27 | 77,05 | 87,19 | 73,68 | |
| ITR | 0,135 | 0,771 | 0,120 | 0,069 | 0,326 | 0,643 | 0,321 | 0,060 | 0,242 | 0,570 | 0,33 | |
| ACC | 66,05 | 94,00 | 67,76 | 61,55 | 81,14 | 93,92 | 79,17 | 66,01 | 72,20 | 89,00 | 77,08 | DT |
| SPEC | 68,79 | 95,00 | 74,11 | 67,46 | 82,45 | 95,38 | 82,14 | 74,05 | 77,46 | 89,57 | 80,64 | |
| SENS | 62,74 | 92,99 | 58,88 | 53,15 | 79,46 | 92,12 | 75,49 | 55,71 | 65,03 | 88,28 | 72,38 | |
| ITR | 0,076 | 0,673 | 0,093 | 0,039 | 0,302 | 0,669 | 0,262 | 0,075 | 0,147 | 0,500 | 0,28 | |

Tablo 4.5.'de frontal bölge elektrotlarına ait 7 kanalı içeren sinyal veri setinin sonuçları görülmektedir. Frontal bölge üzerinde belirlenen 7 kanal şöyledir; Fp1, Fp2, F7, F8, Fz, F3, ve F4. Görüldüğü üzere en başarılı katılımcıya (katılımcı-2) ait sınıflandırma doğruluğu kNN algoritması ile %96,52 olarak elde edilmiştir. En başarısız katılımcıya (katılımcı-1) ait sınıflandırma doğruluk oranı ise %76,91 (MLNN) olarak elde edilmiştir. Ham veri seti sonuçlarına (%97,01) göre katılımcı-2'ye ait en yüksek elde edilen doğruluk oranı değeri 0,49 puan kadar azalmıştır. Yine ham veri setine göre katılımcı-1'e ait elde edilen en yüksek doğruluk oranı değeri 1,09 puan kadar düştüğü gözlenmiştir. Bununla beraber 10 katılımcıya ait ortalama en yüksek doğruluk oranı %81,11 (MLNN) olarak bulunmuştur. Bu değer ham veri setinde ortalama en yüksek değerden 5,28 puan kadar az olduğu görülmektedir. Duyarlılık, özgüllük ve bilgi transfer oranı da yine doğruluk oranı değerine paralel şekilde değişmektedir.

Tablo 4.6. RMS ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 79,34 | 97,05 | 75,50 | 72,01 | 89,14 | 94,05 | 85,07 | 73,12 | 72,67 | 96,01 | 83,40 | |
| SPEC | 89,92 | 97,50 | 82,63 | 76,23 | 90,83 | 96,58 | 83,96 | 72,81 | 65,38 | 98,26 | 85,41 | SVM |
| SENS | 65,47 | 96,62 | 65,78 | 66,03 | 87,17 | 89,97 | 86,39 | 73,86 | 82,54 | 92,89 | 80,67 | |
| ITR | 0,265 | 0,808 | 0,197 | 0,145 | 0,504 | 0,675 | 0,392 | 0,160 | 0,154 | 0,758 | 0,406 | |
| ACC | 78,04 | 96,24 | 75,25 | 71,88 | 86,23 | 93,05 | 86,21 | 73,04 | 71,23 | 94,02 | 82,52 | |
| SPEC | 79,33 | 94,50 | 78,14 | 68,44 | 85,78 | 95,33 | 83,16 | 67,83 | 61,43 | 97,41 | 81,13 | LDA |
| SENS | 76,09 | 97,92 | 71,27 | 76,20 | 86,98 | 89,56 | 89,90 | 79,56 | 84,60 | 89,37 | 84,15 | |
| ITR | 0,241 | 0,769 | 0,193 | 0,143 | 0,422 | 0,636 | 0,421 | 0,159 | 0,134 | 0,673 | 0,379 | |
| ACC | 72,86 | 96,04 | 71,10 | 67,65 | 86,17 | 94,40 | 83,24 | 74,23 | 83,76 | 93,80 | 82,32 | |
| SPEC | 87,68 | 96,11 | 80,12 | 76,61 | 89,04 | 97,07 | 81,77 | 78,08 | 81,39 | 95,66 | 86,35 | KNN |
| SENS | 52,69 | 95,99 | 59,24 | 54,81 | 81,70 | 90,09 | 84,79 | 69,68 | 86,78 | 91,62 | 76,74 | |
| ITR | 0,157 | 0,759 | 0,133 | 0,092 | 0,420 | 0,689 | 0,348 | 0,177 | 0,360 | 0,665 | 0,380 | |
| ACC | 79,36 | 97,02 | 76,44 | 73,38 | 89,53 | 95,08 | 86,41 | 77,38 | 80,05 | 96,24 | 85,09 | |
| SPEC | 86,38 | 97,00 | 80,81 | 78,32 | 91,65 | 96,59 | 84,46 | 83,50 | 74,91 | 96,96 | 87,06 | MLNN |
| SENS | 70,03 | 97,02 | 69,77 | 66,67 | 85,12 | 93,08 | 88,88 | 68,53 | 86,21 | 95,42 | 82,07 | |
| ITR | 0,266 | 0,807 | 0,212 | 0,164 | 0,516 | 0,717 | 0,427 | 0,229 | 0,279 | 0,769 | 0,439 | |
| ACC | 73,22 | 95,26 | 74,55 | 70,02 | 87,12 | 94,17 | 83,01 | 77,42 | 83,02 | 94,70 | 83,25 | |
| SPEC | 90,81 | 94,50 | 84,84 | 70,60 | 88,71 | 97,48 | 77,45 | 77,19 | 80,58 | 96,11 | 85,83 | PNN |
| SENS | 49,84 | 96,10 | 61,08 | 69,58 | 85,02 | 89,77 | 89,11 | 77,57 | 86,31 | 93,05 | 79,74 | |
| ITR | 0,162 | 0,725 | 0,182 | 0,119 | 0,446 | 0,680 | 0,343 | 0,229 | 0,343 | 0,701 | 0,393 | |
| ACC | 71,19 | 94,50 | 71,32 | 67,14 | 84,15 | 92,09 | 80,08 | 74,28 | 78,24 | 93,04 | 80,60 | |
| SPEC | 78,40 | 96,00 | 75,08 | 70,53 | 89,13 | 93,64 | 80,26 | 78,04 | 84,00 | 93,04 | 83,81 | DT |
| SENS | 61,65 | 93,04 | 65,92 | 62,97 | 76,78 | 89,73 | 80,43 | 69,33 | 70,55 | 92,79 | 76,32 | |
| ITR | 0,134 | 0,693 | 0,135 | 0,087 | 0,369 | 0,601 | 0,280 | 0,178 | 0,244 | 0,636 | 0,336 | |

Tablo 4.6.'da görülen sonuçlar 11 kanal sinyal verilerini içeren frontal ve temporal bölge elektrotları için elde edilmiştir. Frontal ve temporal bölgeler üzerinde belirlenen 11 kanal şöyledir; Fp1, Fp2, F7, F8, Fz, F3, F4, T3, T4, T5 ve T6. Görüldüğü üzere en başarılı katılımcıya ait en yüksek sonuç değeri %97,05 (SVM) olarak elde edilirken, en başarısız katılımcıya ait en yüksek sonuç değeri %79,36 (MLNN) olarak bulunmuştur. Frontal ve temporal bölgeler için elde edilen bu değerler ham veri seti sonuçlarına göre sırasıyla, katılımcı-2 ve katılımcı-1 için 0,04 ve 1,36 puan kadar daha yüksektir. Yine ham veri setine kıyasla, ortalama en yüksek doğruluk oranı değeri 1,39 puan kadar düşüktür. 11 kanal veri seti ortalama sonuç

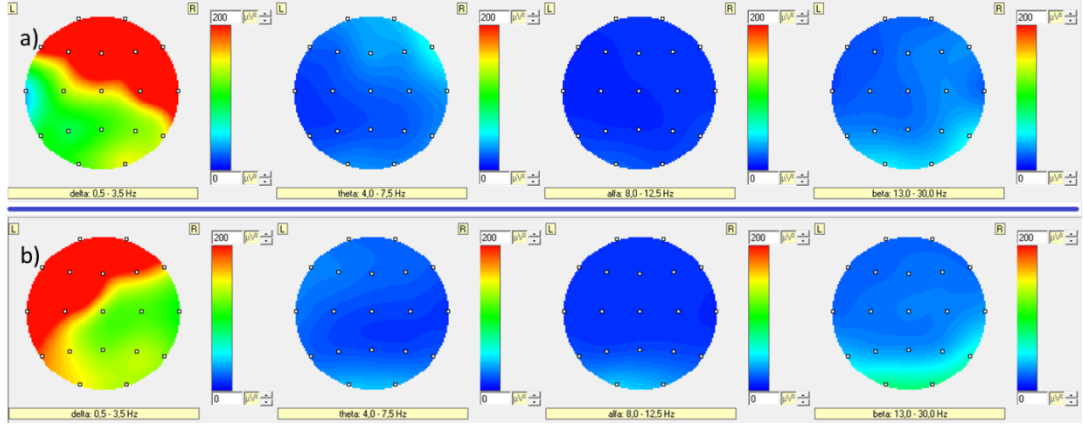
değerleri, 7 kanal veri seti ortalama sonuç değerlerine göre, bütün makine öğrenmesi algoritmaları için daha yüksek elde edildiği görülmektedir.

Tablo 4.7. RMS ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 80,39 | 97,01 | 75,35 | 77,07 | 91,47 | 96,04 | 86,68 | 73,08 | 77,22 | 97,01 | 85,13 | SVM |
| SPEC | 87,25 | 98,00 | 82,71 | 82,28 | 94,58 | 97,03 | 84,91 | 71,40 | 71,03 | 98,28 | 86,75 | |
| SENS | 71,16 | 96,02 | 65,99 | 70,13 | 86,76 | 94,72 | 88,46 | 75,42 | 85,66 | 95,04 | 82,94 | |
| ITR | 0,286 | 0,806 | 0,194 | 0,223 | 0,579 | 0,759 | 0,434 | 0,160 | 0,226 | 0,806 | 0,447 | |
| ACC | 77,46 | 97,04 | 77,12 | 75,13 | 92,00 | 96,22 | 87,07 | 71,13 | 76,04 | 97,03 | 84,62 | LDA |
| SPEC | 77,94 | 96,50 | 80,79 | 74,08 | 93,32 | 97,88 | 84,11 | 64,68 | 68,75 | 98,70 | 83,67 | |
| SENS | 76,63 | 97,57 | 71,68 | 76,88 | 90,25 | 93,63 | 90,72 | 79,39 | 86,03 | 94,81 | 85,76 | |
| ITR | 0,230 | 0,807 | 0,224 | 0,191 | 0,598 | 0,768 | 0,445 | 0,133 | 0,206 | 0,807 | 0,441 | |
| ACC | 72,20 | 95,96 | 68,76 | 67,28 | 87,48 | 95,14 | 82,16 | 75,38 | 79,84 | 93,01 | 81,72 | KNN |
| SPEC | 83,99 | 95,33 | 79,58 | 75,61 | 88,73 | 97,48 | 80,46 | 73,70 | 76,49 | 95,24 | 84,66 | |
| SENS | 56,34 | 96,59 | 54,82 | 55,44 | 85,66 | 91,83 | 84,04 | 77,54 | 84,83 | 89,82 | 77,69 | |
| ITR | 0,147 | 0,756 | 0,104 | 0,088 | 0,456 | 0,720 | 0,323 | 0,195 | 0,275 | 0,634 | 0,370 | |
| ACC | 79,41 | 97,49 | 75,58 | 74,62 | 91,23 | 96,04 | 84,36 | 78,11 | 82,23 | 96,73 | 85,58 | MLNN |
| SPEC | 84,57 | 98,00 | 82,33 | 80,04 | 92,46 | 97,05 | 84,87 | 82,61 | 80,04 | 96,99 | 87,90 | |
| SENS | 72,14 | 96,57 | 66,00 | 67,26 | 87,90 | 94,01 | 83,76 | 68,69 | 81,70 | 95,11 | 81,31 | |
| ITR | 0,266 | 0,831 | 0,198 | 0,183 | 0,571 | 0,760 | 0,374 | 0,242 | 0,325 | 0,792 | 0,454 | |
| ACC | 74,57 | 96,04 | 72,02 | 71,33 | 90,07 | 97,02 | 84,27 | 79,37 | 86,20 | 94,34 | 84,52 | PNN |
| SPEC | 84,17 | 95,50 | 83,60 | 74,55 | 90,76 | 99,58 | 82,60 | 79,43 | 84,02 | 96,97 | 87,12 | |
| SENS | 61,92 | 96,55 | 57,55 | 66,83 | 89,48 | 93,20 | 86,06 | 78,91 | 89,34 | 90,39 | 81,02 | |
| ITR | 0,182 | 0,760 | 0,145 | 0,136 | 0,533 | 0,807 | 0,372 | 0,266 | 0,421 | 0,686 | 0,431 | |
| ACC | 74,15 | 94,00 | 70,53 | 69,12 | 86,36 | 93,04 | 83,03 | 75,52 | 78,34 | 92,46 | 81,65 | DT |
| SPEC | 77,09 | 93,00 | 73,30 | 73,17 | 89,13 | 95,33 | 84,09 | 77,63 | 81,38 | 91,76 | 83,59 | |
| SENS | 70,28 | 95,04 | 66,89 | 63,81 | 82,03 | 89,52 | 82,21 | 72,75 | 73,84 | 92,85 | 78,92 | |
| ITR | 0,176 | 0,673 | 0,125 | 0,108 | 0,425 | 0,636 | 0,343 | 0,197 | 0,246 | 0,614 | 0,354 | |

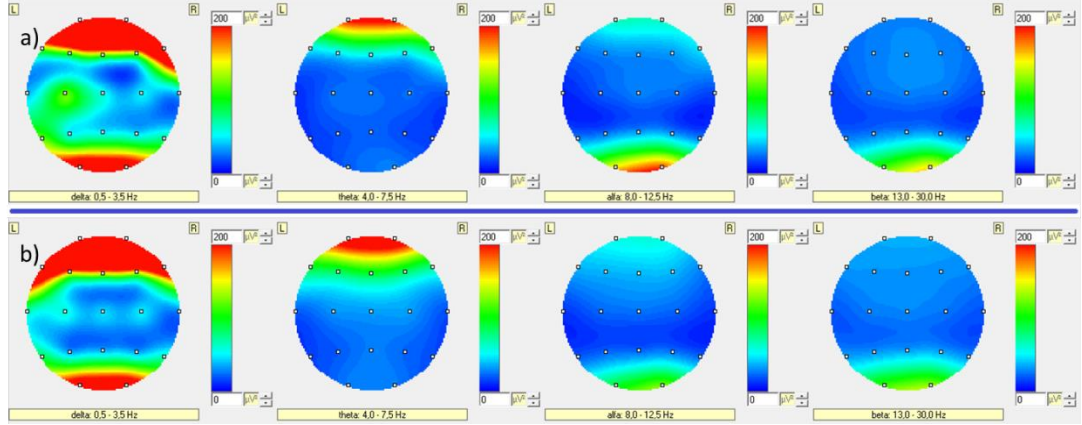
Tablo 4.7.'de görüldüğü üzere DWT ile delta ve teta frekans bantları çıkarılmış sinyaller üzerine RMS metodu uygulanmış ve sınıflandırma sonuç değerleri elde edilmiştir. Buna göre en başarılı ve en başarısız katılımcıya ait en yüksek doğruluk oranı değerleri sırasıyla %97,49 (MLNN) ve %80,39 (SVM) olarak elde edilmiştir. Her iki katılımcıya ait en yüksek doğruluk oranları için artış miktarı 0,48 (katılımcı-2) ve 2,39 (katılımcı-1) olarak görülmektedir. MLNN algoritması, ham

veri setinde olduğu gibi ortalama başarı en yüksek doğruluk değerini %85,58 ile elde etmiştir. DWT ile delta ve teta frekansları çıkarılan sinyale ait veri setindeki azalış miktarı ortalama başarı doğruluk oranı için 0,81 puandır.




Şekil 4.2.En başarılı katılımcıya (katılımcı-2) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.2.'de en başarılı katılımcıya ait beyin haritalama sonuçları gösterilmektedir. GKP sinyallerinin delta frekans bandında özellikle frontal ve temporal bölge üzerinde yoğunlaştığı görülmektedir. Bu sinyallerin frontal ve temporal bölge üzerinde yoğunlaşmasının sınıflandırma başarısı açısından önemli olduğu Tablo 4.5. ve Tablo 4.6.'da gözlenmiştir. Özellikle frontal ve temporal bölge sinyallerini temsil eden 11 kanal veri seti sonuçlarının (Tablo 4.6.), ham veri seti sonuçlarına (Tablo 4.1.) kıyasla en başarılı ve en başarısız katılımcı için daha yüksek sonuçlara sahip olduğu görülmüştür. Bununla beraber teta frekans bandındaki sinyal güç değişimi, alfa ve beta frekans bantlarında olduğu gibi neredeyse görülmemektedir. Beta frekans bandı içinde gözlenen oksipital bölge üzerinde zayıf bir sinyal güç değişimi mevcuttur. Bu durumun katılımcının deneysel düzen esnasında LCD monitöre bakarken görsel olarak uyarılmasından kaynaklandığı düşünülmektedir [9].




Şekil 4.3.En başarısız katılımcıya (katılımcı-1) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.3.'de en başarısız katılımcıya ait beyin haritalama sonuçları gösterilmektedir. Görüldüğü üzere delta frekans bandında frontal bölge üzerinde yoğunlaşan sinyal güç değişimleri en başarılı katılımcıda olduğu gibi temporal bölge (T3, T4, T5 ve T6 elektrotları) üzerinde oluşmamaktadır. Bununla beraber teta frekans bandı içinde Fp1 ve Fp2 frontal bölgesi üzerinde oluşum gösteren sinyal güç değişimleri mevcuttur. En başarısız katılımcı için sağ ve sol ayrımını net şekilde gösteren dil hareketlerine bağlı sinyal değişimleri beyin haritalama sonuçlarında görülmektedir. Dahası, delta frekans bandı içerisinde oksipital bölge üzerinde yoğunlaşan sinyal güç değişimleri mevcuttur. Bu değişimler en başarısız katılımcı için hedefe yönelik düşük motivasyon nedeniyle olabileceği gibi deneysel görevler sırasında yumuşak damağa veya diğer artikülatoörlere dokunulduğundan belirmiş olabilir. Deneysel düzen içindeki dil hareketlerinin ayırık ve olabildiğince hızlı olması gerekmektedir. Katılımcı-1'in bu görevleri yeterince iyi gerçekleştiremediği, böylece oluşan bu düşük performansın sınıflandırma algoritmalarına bağlı düşük doğruluk oranı değerleri oluşturduğu görülmektedir [9], [14].



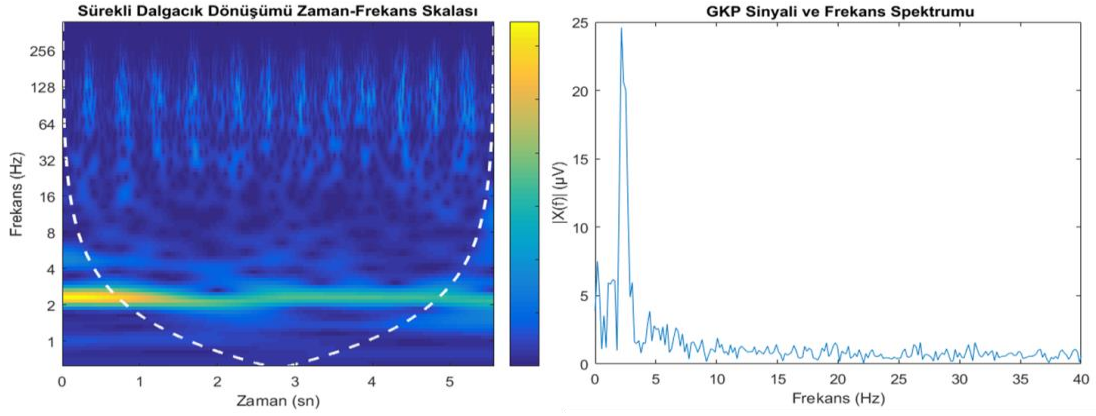
Şekil 4.4. En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil teması ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim

Şekil 4.4.'de en başarılı katılımcı için sağ dil hareketlerinin ortalama sinyal güçleri özellikle Fp2, Fp1, F8, T4 ve T6 kanallarına ait bölgelerde yüksek olduğu görülmüştür. Sağ dil hareketleri için en yüksek ortalama sinyal gücü ($1500 \mu V^2$ - $3000 \mu V^2$) aralığında F8 bölgesinde elde edilmiştir. Sol dil hareketlerine bağlı ortalama sinyal güçlerinin Fp2, Fp1, F3, F7, C3, T5 kanallarına ait bölgelerde yüksek olduğu gözlenmiştir. Sol dil hareketi için en yüksek ortalama sinyal gücü ($700 \mu V^2$ - $1200 \mu V^2$) aralığında Fp2, Fp1, F3, F7 bölgeler üzerinde elde edilmiştir. Katılımcı-2'nin sağ ve sol dil hareketlerine bağlı olarak kafa derisi üzerinde oluşan sinyal güçlerinin simetrik olmadığı gözlenmiştir. Bununla beraber her iki yönde (sağ ve sol) dördüncü altı saniyelik dil hareketlerine bağlı olarak oluşan ortalama sinyal güçleri, diğer altı saniyelik hareketlere kıyasla daha düşük oluşmuştur. Buna ek olarak sağ yanak duvarına dokunuşlarda daha yüksek bir ortalama sinyal gücü olduğu gözlenmiştir.

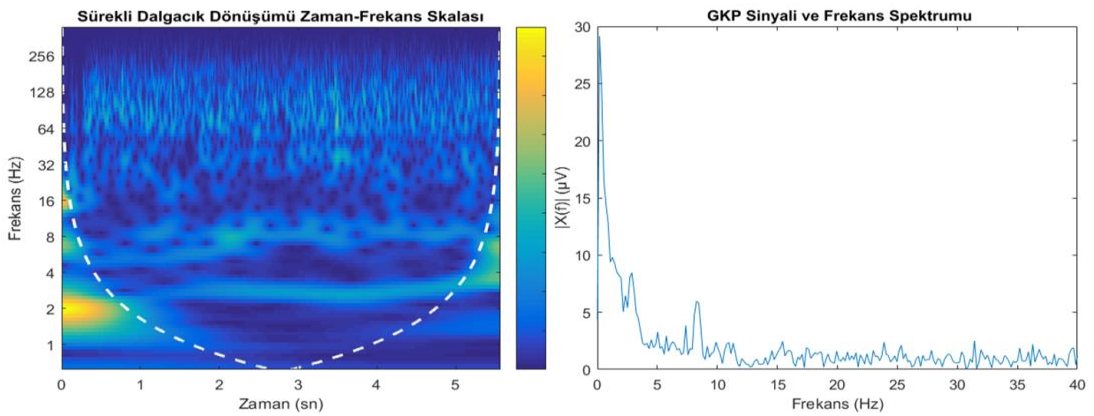


Şekil 4.5. En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil teması ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim

Şekil 4.5.'de en başarısız katılımcıya ait ortalama sinyal gücünün 19 kanal üzerindeki değişimi görülmektedir. Sağ ve sol dil hareketleri için sinyal kanalları üzerinde neredeyse simetrik olan ortalama sinyal güç değişimi görülmektedir. En yüksek ortalama sinyal güçlerinin her iki yön içinde Fp2 ve Fp1 kanallarına ait bölgelerde ($1000 \mu V^2$ - $4500 \mu V^2$) aralığında oluştuğu gözlenmiştir. Böylece beyin haritalama sonuçlarında görüldüğü gibi temporal bölgelerde ortalama sinyal güç değişimlerinin neredeyse oluşmadığı belirlenmiştir. Bununla beraber, katılımcı-1 için sol yanak duvarına dokunulması esnasında oluşan ortalama sinyal gücünün sağ yanak duvarına dokunulması esnasında oluşan ortalama sinyal gücünden daha fazla olduğu görülmektedir.




Şekil 4.6.En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)



Şekil 4.7.En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.6. ve Şekil 4.7.'de en başarılı ve en başarısız katılımcılara ait birinci altı saniyelik sağ dil hareketleri sonucunda oluşan GKP sinyallerinin sürekli dalgacık dönüşümü zaman-frekans skalası ve frekans spektrumları gösterilmektedir. Her iki grafiksel gösterimde de dil hareketine bağlı olarak oluşan GKP sinyallerinin 1-4 Hz delta frekans bandı içinde yüksek genlikte ($25 \mu\text{V}$ - $30 \mu\text{V}$) olduğu görülmektedir. Bununla beraber en başarısız katılımcı için teta ($4\text{-}7 \text{ Hz}$) frekans bandı içinde de önemli genlikte ($\geq 5 \mu\text{V}$) sinyal olduğu gözlemlenmiştir.



Şekil 4.8.En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.8.'de en başarılı ve en başarısız katılımcılar için birinci altı saniyelik sağ dil hareketleri esnasında oluşan GKP sinyallerinin periodogram grafikleri (spektral güç yoğunluğu) gösterilmektedir. Zaman-frekans skalası ve frekans spektrumunda görüldüğü üzere özellikle delta bandında yüksek bir sinyal gücü oluşmaktadır ($500 \mu\text{V}^2/\text{Hz}$ - $600 \mu\text{V}^2/\text{Hz}$). En başarısız katılımcı için ise teta frekans bandı içinde de belirli seviyede genliğe sahip sinyal gücü olduğu hesaplanmıştır ($\geq 50 \mu\text{V}^2/\text{Hz}$).

4.1.2. Standart sapma sonuçları


Standart sapma (STD) istatistiksel bir parametre olmasının yanı sıra sinyal üzerinden özellik çıkarma işlemi için kullanılan zaman alanı metotlarından birisidir. STD metoduna ait sonuç tablolarında ve grafiksel sonuçlarda en başarılı ve en başarısız katılımcıya ait değerlendirmeler yapılmıştır. İlgili sonuç değerleri şöyledir:

Tablo 4.8. STD ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|--------------|--------------|------|
| ACC | 72,45 | 85,22 | 78,01 | 78,12 | 72,28 | 91,17 | 69,65 | 84,27 | 72,37 | 90,27 | 79,38 | |
| SPEC | 71,32 | 82 | 72,94 | 71,38 | 69,04 | 89,82 | 68,68 | 84,84 | 64 | 90,04 | 76,41 | SVM |
| SENS | 74,09 | 88,5 | 84,58 | 87,03 | 77,07 | 93,17 | 71,53 | 83,51 | 83,56 | 90,25 | 83,33 | |
| ITR | 0,151 | 0,396 | 0,240 | 0,242 | 0,148 | 0,569 | 0,114 | 0,372 | 0,150 | 0,540 | 0,292 | |
| ACC | 73,29 | 83,44 | 78,00 | 76,38 | 73,18 | 91,13 | 70,35 | 84,81 | 73,08 | 91,21 | 79,49 | |
| SPEC | 74,45 | 76 | 74,25 | 69,66 | 68,66 | 93,62 | 70,32 | 89,29 | 70,53 | 91,76 | 77,85 | LDA |
| SENS | 72,15 | 90,85 | 82,61 | 85,49 | 79,55 | 87,65 | 69,87 | 79,27 | 76,22 | 90,86 | 81,45 | |
| ITR | 0,163 | 0,353 | 0,240 | 0,211 | 0,161 | 0,568 | 0,123 | 0,385 | 0,160 | 0,571 | 0,293 | |
| ACC | 66,13 | 78,07 | 74,17 | 67,02 | 69,58 | 88,13 | 62,03 | 74,13 | 62,13 | 83,13 | 72,45 | |
| SPEC | 82,09 | 70,07 | 78,79 | 73,88 | 76,93 | 93,94 | 63,29 | 78,17 | 62,36 | 90,55 | 77,01 | |
| SENS | 43,93 | 86,16 | 68,22 | 57,77 | 58,15 | 79,52 | 60,74 | 68,81 | 61,77 | 73,03 | 65,81 | |
| ITR | 0,076 | 0,241 | 0,176 | 0,085 | 0,114 | 0,475 | 0,042 | 0,175 | 0,043 | 0,345 | 0,177 | |
| ACC | 73,44 | 84,23 | 78,96 | 74,42 | 72,09 | 90,27 | 66,16 | 80,18 | 71,09 | 89,85 | 78,07 | MLNN |
| SPEC | 77,15 | 79,00 | 85,26 | 77,39 | 79,49 | 92,37 | 75,02 | 87,57 | 75,33 | 91,36 | 81,99 | |
| SENS | 69,01 | 87,88 | 70,44 | 70,28 | 60,70 | 86,81 | 55,40 | 69,85 | 65,52 | 87,71 | 72,36 | |
| ITR | 0,165 | 0,371 | 0,258 | 0,180 | 0,146 | 0,540 | 0,077 | 0,282 | 0,133 | 0,526 | 0,268 | |
| ACC | 66,02 | 80,04 | 76,06 | 69,56 | 72,45 | 89,26 | 64,46 | 75,07 | 64,09 | 84,05 | 74,11 | PNN |
| SPEC | 85,04 | 65,00 | 80,95 | 80,07 | 82,84 | 96,20 | 72,79 | 82,27 | 81,81 | 95,67 | 82,26 | |
| SENS | 41,23 | 95,07 | 70,10 | 55,36 | 56,99 | 79,13 | 55,16 | 66,54 | 40,15 | 68,13 | 62,79 | |
| ITR | 0,075 | 0,279 | 0,206 | 0,113 | 0,151 | 0,508 | 0,061 | 0,190 | 0,058 | 0,367 | 0,201 | |
| ACC | 71,12 | 80,52 | 74,13 | 71,57 | 70,05 | 90,17 | 67,64 | 79,25 | 67,29 | 85,46 | 75,72 | DT |
| SPEC | 75,42 | 81,00 | 76,42 | 74,49 | 73,68 | 91,20 | 67,64 | 83,95 | 69,71 | 87,39 | 78,09 | |
| SENS | 66,02 | 80,03 | 71,44 | 66,68 | 64,77 | 88,24 | 67,41 | 73,38 | 64,40 | 82,67 | 72,50 | |
| ITR | 0,133 | 0,289 | 0,175 | 0,139 | 0,119 | 0,536 | 0,092 | 0,263 | 0,088 | 0,402 | 0,224 | |

Tablo 4.8.'de standart sapma metodu ile özellik çıkarma işlemi uygulanmış ham veri setine ait makine öğrenmesi algoritmalarının sonuçları verilmiştir. Görüldüğü üzere en iyi performans gösteren birey katılımcı-10 (SB10) olarak belirlenmiştir. En düşük performans gösteren birey ise katılımcı-7 (SB7) olarak elde edilmiştir. Bu katılımcılara ait sınıflandırma doğruluk oranları, katılımcı-10 için %91,21 (LDA) iken katılımcı-7 için %70,35 (LDA) olarak hesaplanmıştır. Ortalama en yüksek sınıflandırma doğruluk oranı, katılımcı-7 ve katılımcı-10'da olduğu gibi doğrusal ayırım analizi (%79,49) ile elde edilmiştir. Bununla beraber, ortalama doğruluk oranları içinde LDA algoritmasından sonra en yüksek sonuç değeri üreten algoritma

SVM (%79,38) olarak hesaplanmıştır. STD'de ham veri seti sonuçlarına göre en başarılı ve en başarısız katılımcının performans değerleri Şekil 4.9.'da gösterilmiştir.



Şekil 4.9. Standart sapma ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.9. STD ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|--------------|--------------|------|
| ACC | 74,00 | 83,03 | 81,08 | 75,13 | 72,04 | 91,02 | 70,37 | 83,51 | 70,51 | 89,26 | 79,00 | SVM |
| SPEC | 81,96 | 77,00 | 81,28 | 76,61 | 77,43 | 92,39 | 70,97 | 88,44 | 75,74 | 91,74 | 81,36 | |
| SENS | 63,78 | 88,92 | 80,62 | 72,97 | 64,10 | 89,43 | 70,55 | 76,87 | 63,13 | 85,86 | 75,62 | |
| ITR | 0,173 | 0,343 | 0,300 | 0,191 | 0,145 | 0,564 | 0,123 | 0,354 | 0,125 | 0,508 | 0,283 | |
| ACC | 75,51 | 83,02 | 79,24 | 75,36 | 71,86 | 92,02 | 71,44 | 82,49 | 70,31 | 88,52 | 78,98 | LDA |
| SPEC | 77,47 | 76,50 | 73,72 | 70,14 | 66,54 | 94,49 | 69,94 | 87,92 | 68,35 | 90,04 | 77,51 | |
| SENS | 72,93 | 89,54 | 86,50 | 82,37 | 79,29 | 88,44 | 73,01 | 75,18 | 72,66 | 86,31 | 80,62 | |
| ITR | 0,197 | 0,343 | 0,263 | 0,194 | 0,143 | 0,598 | 0,137 | 0,331 | 0,123 | 0,486 | 0,281 | |
| ACC | 69,04 | 74,36 | 77,13 | 70,51 | 70,07 | 86,16 | 64,06 | 74,06 | 66,01 | 81,22 | 73,26 | kNN |
| SPEC | 86,87 | 69,22 | 80,83 | 74,44 | 79,79 | 93,19 | 67,58 | 87,94 | 66,51 | 89,60 | 79,60 | |
| SENS | 45,93 | 79,68 | 72,42 | 65,32 | 55,73 | 75,97 | 60,45 | 56,45 | 65,32 | 69,68 | 64,70 | |
| ITR | 0,107 | 0,179 | 0,224 | 0,125 | 0,120 | 0,420 | 0,058 | 0,174 | 0,075 | 0,303 | 0,179 | |
| ACC | 73,54 | 82,26 | 73,99 | 73,13 | 73,04 | 91,35 | 70,44 | 82,74 | 72,61 | 86,46 | 77,96 | MLNN |
| SPEC | 78,87 | 82,50 | 69,70 | 78,42 | 77,84 | 93,21 | 80,65 | 89,21 | 83,17 | 90,04 | 82,36 | |
| SENS | 66,24 | 81,77 | 79,46 | 65,40 | 65,51 | 87,37 | 57,83 | 73,80 | 58,93 | 80,27 | 71,66 | |
| ITR | 0,166 | 0,326 | 0,173 | 0,160 | 0,159 | 0,575 | 0,124 | 0,336 | 0,153 | 0,428 | 0,260 | |
| ACC | 67,51 | 79,07 | 76,06 | 66,45 | 72,11 | 88,31 | 62,74 | 75,15 | 63,73 | 84,29 | 73,54 | PNN |
| SPEC | 88,97 | 64,00 | 80,45 | 79,64 | 82,84 | 92,03 | 71,84 | 80,75 | 84,04 | 95,65 | 82,02 | |
| SENS | 39,27 | 94,26 | 70,10 | 48,57 | 56,04 | 82,87 | 52,50 | 68,12 | 36,08 | 68,33 | 61,61 | |
| ITR | 0,090 | 0,260 | 0,206 | 0,080 | 0,146 | 0,480 | 0,047 | 0,191 | 0,055 | 0,373 | 0,193 | |

Tablo 4.9. STD (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| ACC | 68,19 | 76,06 | 75,08 | 70,01 | 68,06 | 87,49 | 66,16 | 76,25 | 68,97 | 85,51 | 74,18 | DT |
| SPEC | 71,76 | 73,50 | 79,07 | 74,46 | 73,24 | 89,13 | 71,75 | 77,73 | 76,54 | 87,48 | 77,47 | |
| SENS | 64,03 | 78,72 | 69,96 | 63,19 | 60,09 | 85,35 | 59,78 | 74,34 | 58,96 | 82,44 | 69,69 | |
| ITR | 0,098 | 0,206 | 0,190 | 0,119 | 0,096 | 0,456 | 0,077 | 0,209 | 0,106 | 0,403 | 0,196 | |

Tablo 4.9.'da STD metodu ve temel bileşen analizi yöntemi uygulanmış veri setine ait makine öğrenme algoritmalarının sonuç değerleri görülmektedir. 12 temel bileşeni olan yeni veri setinde, veri temsil etme oranı diğer zaman alanı özellik çıkarma metotlarında olduğu gibi %96-%99 aralığındadır. En başarılı katılımcıya ait en yüksek doğruluk oranı (%89,26) SVM algoritması ile elde edilmiştir. En başarısız katılımcıya ait en yüksek doğruluk oranı ise LDA ile %71,44 olarak hesaplanmıştır. 10 katılımcıya ait ortalama doğruluk oranı %79 (SVM) olarak bulunmuştur. Bu değer ham veri seti ortalama en yüksek doğruluk oranından yalnızca 0,49 puan kadar azdır. En başarılı katılımcıda bu azalma oranı %2,13 iken, en başarısız katılımcıdaki artış oranı %1,54 olarak hesaplanmıştır.

Tablo 4.10. STD ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|--------------|--------------|-----|
| ACC | 72,22 | 85,26 | 75,10 | 62,49 | 67,06 | 91,09 | 70,17 | 70,17 | 70,02 | 87,02 | 75,06 | SVM |
| SPEC | 78,77 | 80,00 | 73,70 | 97,41 | 82,41 | 94,47 | 77,86 | 84,33 | 77,08 | 89,20 | 83,52 | |
| SENS | 63,99 | 90,68 | 77,33 | 14,49 | 44,50 | 86,56 | 61,23 | 52,42 | 60,04 | 83,82 | 63,51 | |
| ITR | 0,148 | 0,397 | 0,190 | 0,045 | 0,086 | 0,567 | 0,121 | 0,121 | 0,119 | 0,443 | 0,224 | |
| ACC | 73,24 | 85,02 | 74,12 | 63,00 | 67,02 | 90,27 | 69,18 | 72,03 | 66,48 | 88,03 | 74,84 | LDA |
| SPEC | 74,47 | 77,00 | 67,09 | 65,34 | 64,04 | 94,49 | 71,77 | 79,60 | 59,73 | 87,45 | 74,10 | |
| SENS | 71,51 | 93,08 | 82,92 | 60,06 | 72,12 | 84,15 | 66,29 | 62,42 | 75,75 | 88,91 | 75,72 | |
| ITR | 0,162 | 0,391 | 0,175 | 0,049 | 0,085 | 0,540 | 0,109 | 0,145 | 0,080 | 0,471 | 0,221 | |

Tablo 4.11. STD ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|--------------|-----|
| ACC | 74,37 | 85,02 | 77,06 | 66,12 | 72,02 | 90,19 | 69,05 | 83,27 | 70,25 | 88,06 | 77,54 | SVM |
| SPEC | 78,85 | 80,50 | 76,03 | 83,13 | 78,21 | 92,45 | 75,30 | 87,63 | 76,63 | 92,64 | 82,14 | |
| SENS | 68,35 | 89,40 | 78,49 | 43,54 | 62,71 | 86,95 | 62,73 | 77,73 | 61,33 | 81,77 | 71,30 | |
| ITR | 0,179 | 0,391 | 0,223 | 0,076 | 0,145 | 0,537 | 0,107 | 0,348 | 0,122 | 0,472 | 0,260 | |

Tablo 4.11. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|-------|-------|-----|
| ACC | 73,24 | 84,02 | 77,50 | 66,06 | 72,06 | 91,07 | 70,03 | 82,00 | 67,03 | 87,19 | 77,02 | |
| SPEC | 74,03 | 78,00 | 71,94 | 68,01 | 68,19 | 94,53 | 70,82 | 87,04 | 61,90 | 88,37 | 76,28 | LDA |
| SENS | 72,03 | 89,99 | 84,45 | 63,00 | 78,26 | 86,06 | 69,26 | 75,30 | 74,15 | 86,30 | 77,88 | |
| ITR | 0,162 | 0,366 | 0,231 | 0,076 | 0,145 | 0,566 | 0,119 | 0,320 | 0,085 | 0,448 | 0,252 | |

Tablo 4.10. ve Tablo 4.11.'de sırasıyla, 7-kanal (frontal) ve 11-kanal (frontal ve temporal bölge) veri setlerini içeren SVM ve LDA algoritmalarına ait sonuç değerleri görülmektedir. En başarılı katılımcıya ait en yüksek doğruluk değerleri %88,03 (LDA- 7 kanal veri seti) ve %88,06 (SVM- 11 kanal veri seti) olarak elde edilmiştir. En başarısız katılımcıya ait en yüksek doğruluk değerleri ise %70,17 (SVM- 7 kanal veri seti) ve %70,03 (LDA- 11 kanal veri seti) olarak hesaplanmıştır. Görüldüğü üzere 7 kanal ve 11 kanal veri seti sonuçları, her iki katılımcı için birbirlerine oldukça yakın bulunmuştur. Ortalama doğruluk oranı değerlerinde ise 11 kanal sonuçları SVM (%77,54) ve LDA (%77,02) algoritmalarının her ikisinde de daha yüksek gözlenmiştir. Ham veri seti için SVM ve LDA algoritmalarında ortalama doğruluk oranı değerleri, 11 kanal sonuçlarından sırasıyla %2,37 ve %3,20 oranında yüksek elde edilmiştir.

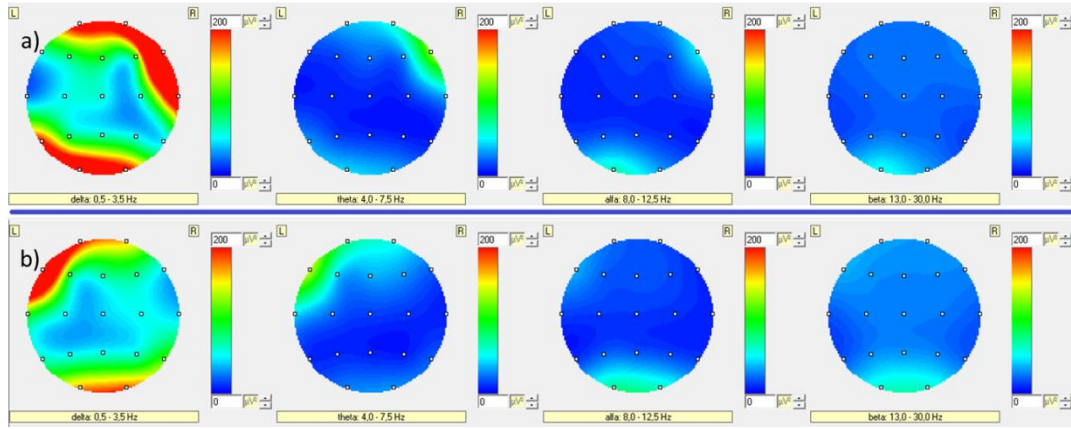
Tablo 4.12. STD ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|--------------|--------------|-----|
| ACC | 77,01 | 87,05 | 78,79 | 67,72 | 83,17 | 93,51 | 77,26 | 77,02 | 76,30 | 94,01 | 81,18 | |
| SPEC | 81,62 | 84,50 | 86,21 | 80,54 | 85,80 | 96,61 | 78,40 | 80,32 | 80,05 | 95,24 | 84,93 | SVM |
| SENS | 70,78 | 89,51 | 68,88 | 50,90 | 78,91 | 89,06 | 76,07 | 72,71 | 71,44 | 92,29 | 76,06 | |
| ITR | 0,222 | 0,444 | 0,254 | 0,093 | 0,346 | 0,653 | 0,227 | 0,222 | 0,210 | 0,673 | 0,334 | |
| ACC | 77,14 | 87,52 | 77,10 | 68,00 | 83,01 | 93,03 | 77,08 | 75,28 | 75,64 | 93,43 | 80,72 | |
| SPEC | 76,60 | 83,50 | 79,60 | 66,25 | 81,23 | 95,38 | 74,70 | 71,46 | 72,30 | 94,80 | 79,58 | |
| SENS | 77,78 | 91,58 | 73,85 | 70,21 | 85,21 | 89,58 | 79,73 | 80,07 | 80,39 | 91,33 | 81,97 | |
| ITR | 0,225 | 0,457 | 0,224 | 0,096 | 0,343 | 0,635 | 0,223 | 0,193 | 0,199 | 0,650 | 0,324 | |

Tablo 4.12.'de standart sapma metodu ve DWT yöntemi uygulanmış veri setine ait bir boyutlu dil hareketi sınıflandırma sonuçları gösterilmiştir. Glossokinetik potansiyel sinyallerinin özellikle delta ve teta frekans bantları içinde oluşmasından

dolayı, EEG üzerinden ölçülen GKP sinyallerinin diğer frekans bileşenlerinden kurtarılması sınıflandırma sonuçları açısından önem arz etmektedir. Görüldüğü üzere en başarılı katılımcıya ait sınıflandırma doğruluk oranı %94,01 (SVM) olarak elde edilmiştir. Bu değer standart sapma ham veri seti içindeki en başarılı katılımcıya ait en yüksek değerden 2,8 puan daha fazladır. En başarısız katılımcı için (%77,26-SVM) bu artış değeri ham veri setine göre 6,91 puandır. Tablo 4.12. için ortalama en yüksek sınıflandırma doğruluk oranı %81,18 (SVM) iken, bu değer ham veri setinden %2,12 kadar yüksek elde edilmiştir.

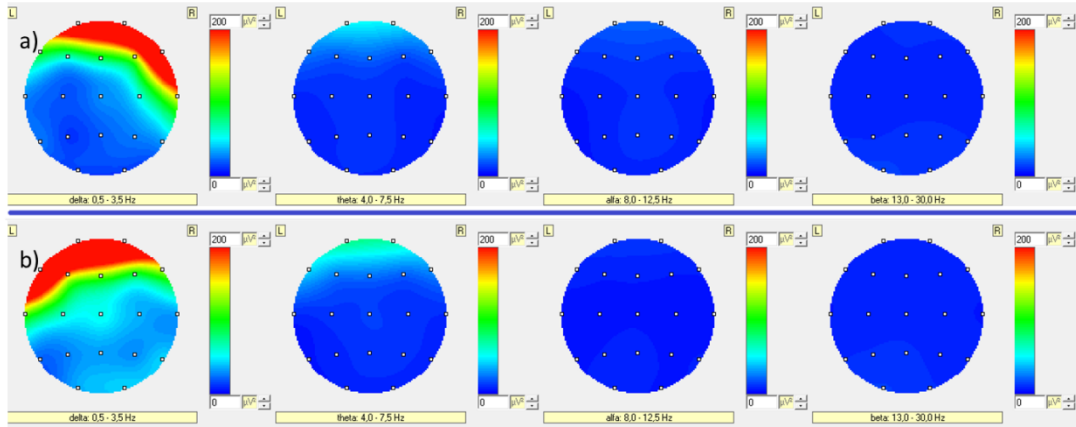
En başarılı katılımcı, en başarısız katılımcı ve ortalama sınıflandırma performansları için standart sapma özellik çıkarma metoduna ait hesaplanmış sınıflandırma sonuçlarının, ortalama karesel kök metoduna ait sınıflandırma başarılarından ilgili bütün veri setlerinde daha düşük olduğu görülmektedir. Böylece RMS'in, STD'ye kıyasla makine öğrenmesi algoritmalarının performansları açısından daha başarılı bir zaman alanı özellik çıkarma metodu olduğu söylenebilir.



Şekil 4.10. En başarılı katılımcıya (katılımcı-10) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

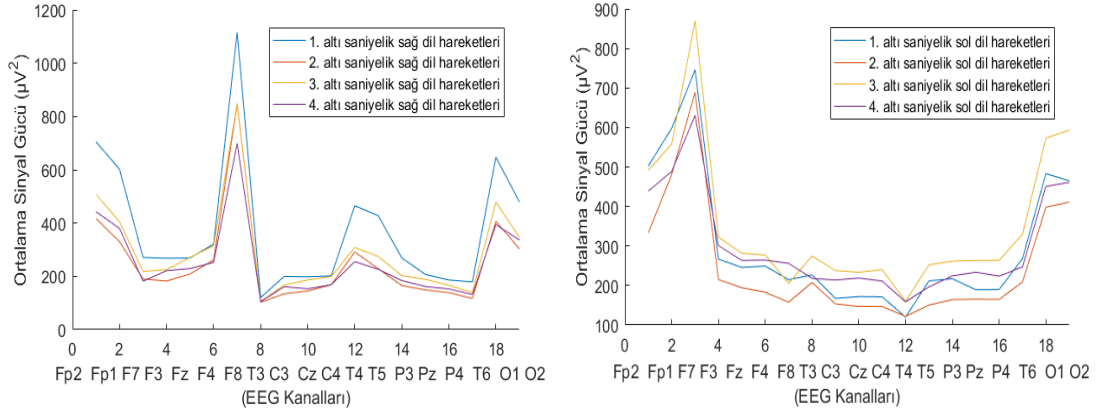
Şekil 4.10.'da görüldüğü üzere en başarılı katılımcının sağ ve sol dil hareketi ve dilin yanak duvarına ayırık dokunuşlarına bağlı olarak üretilen GKP sinyalleri, delta frekans bandı içerisinde yoğun bir sinyal gücü olarak görülmektedir. Fp1 elektrot bölgesinden başlayan sağ dil hareketine ait GKP sinyal gücü, T4 elektrot bölgesine kadar yüksek olarak görülmektedir. Sol dil hareketine ait GKP sinyal gücü, Fp2

elektrot bölgesinden T3 elektrot bölgesine kadar uzanmaktadır. Her iki yönelim için de arka-frontal (F3, Fz ve F4) ve merkez bölgelerde yüksek sinyal gücü oluşmadığı beyin haritalama sonuçlarında elde edilmiştir. Bununla beraber, teta frekans bandında her iki sınıflandırma yönü için Fp1 ve Fp2’de düşük değerlerde sinyal gücü olduğu görülmektedir. Görme uyarılmasına veya artikülasyon bir organ olan dilin o andaki konumuna bağlı olarak oksipital bölge üzerinde yoğun bir GKP sinyal gücü gözlenmektedir [14].



Şekil 4.11. En başarısız katılımcıya (katılımcı-7) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.11.’de en başarısız katılımcıya ait beyin haritalama sonuçları görülmektedir. İlgili katılımcı için GKP sinyallerine ait sinyal güçleri, sağ ve sol beyin kafa derisi üzerinde birbirine oldukça benzer uzamsal örüntüler oluşturmuştur. Delta frekans bandı içinde görülen yüksek sinyal güçleri frontal bölge üzerinden T3 ve T4 temporal bölge elektrotlarına kadar uzanmış, fakat ayırt edilebilir düzeyde temporal bölge üzerinde oluşmamıştır. En başarılı katılımcıya göre arka-frontal (F3, Fz ve F4) ve merkez bölgeler üzerinde oluşan sinyal güçleri beyin haritalaması üzerinde daha düzenli bir örüntü oluşturmuştur. Teta frekans bandı içinde ise en başarılı katılımcıdan daha düşük düzeyde sinyal gücünün Fp1 ve Fp2 elektrot bölgesi üzerinde olduğu gözlenmiştir. Katılımcı-7’de, alfa ve beta frekans bantları içinde, katılımcı-10’da olduğu gibi önemli bir sinyal gücü elde edilememiştir.

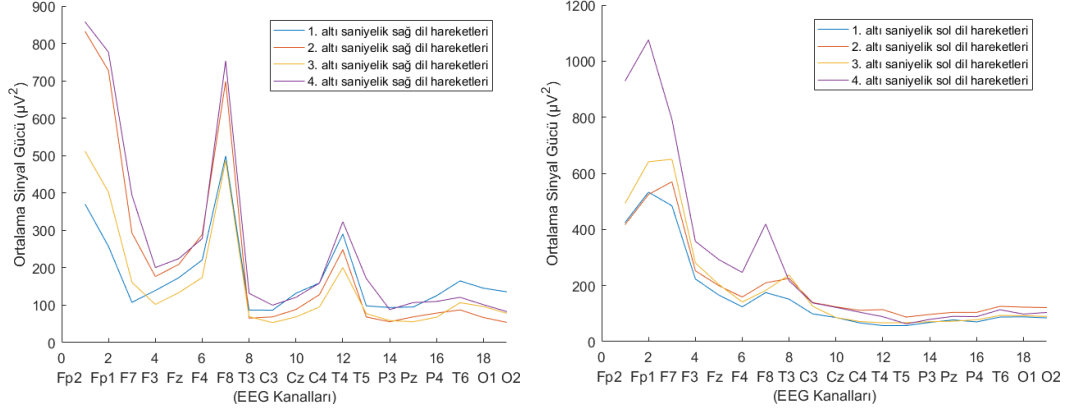


Şekil 4.12. En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temasları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim

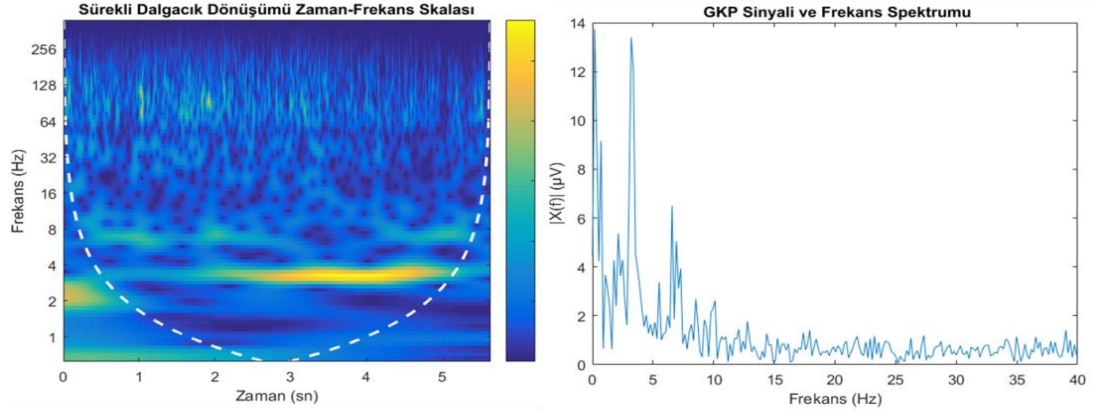
Şekil 4.12.'de en başarılı katılımcıya ait (katılımcı-10) ortalama sinyal gücü grafikleri verilmiştir. Görüldüğü üzere ortalama sinyal güç değişimleri sağ ve sol hareket ve dokunuşlarda EEG kanalları üzerinde simetrik olmayan bir örüntü oluşturmuştur. Sağa hareket ve dokunuşlar için, F8 frontal bölge üzerindeki kanallarda $600 \mu V^2$ - $1200 \mu V^2$ arasında ortalama sinyal gücü elde edilirken, T4 kanalında $200 \mu V^2$ - $600 \mu V^2$ ortalama sinyal gücü elde edilmiştir. Sola hareket ve dokunuşlar için ise, F7 frontal bölge üzerinde en yüksek ortalama sinyal gücü oluşurken ($600 \mu V^2$ - $900 \mu V^2$), Fp1 ve F3 bölgesinde $300 \mu V^2$ - $600 \mu V^2$ arasında ortalama sinyal gücü oluşmaktadır. En başarılı katılımcı için sağ hareket ve dokunuşlarda oluşan GKP sinyalinin ortalama gücünün sol hareket ve dokunuşlardan daha yüksek olduğu söylenebilir. Bununla beraber, her iki dil hareket ve dokunuş yönü için (sağ ve sol), temporal (T3, T4, T5, T6), merkez (C3, Cz, C4) ve parietal (P3, Pz, P4) bölge üzerindeki kanallardaki ortalama sinyal gücü değişimleri frontal bölgelere göre oldukça düşüktür. Yalnızca, O1 ve O2 bölgesinde, sağ ve sol hareket ve dokunuşlarda belirli bir ortalama sinyal gücü ($\geq 400 \mu V^2$) oluşmaktadır.

Şekil 4.13'de en başarısız katılımcıya ait ortalama sinyal gücü grafiği gösterilmiştir. Bu grafikte sağ ve sol dil hareket ve dokunuşları ile ortaya çıkan GKP sinyallerinin kafa derisine bağlı elektrot kanalları üzerinde neredeyse simetrik bir sinyal gücü oluşturması gözlenmiştir. En başarılı katılımcıda olduğu gibi Fp1 ve Fp2 frontal bölgelerde yüksek bir ortalama sinyal gücü ($300 \mu V^2$ - $1200 \mu V^2$) elde edilmiştir.

Bunun yanı sıra her iki yön için de, F8 bölgesi üzerindeki kanallarda yüksek ve ayırt edilebilir düzeyde ortalama sinyal güç değişimi görülmektedir.

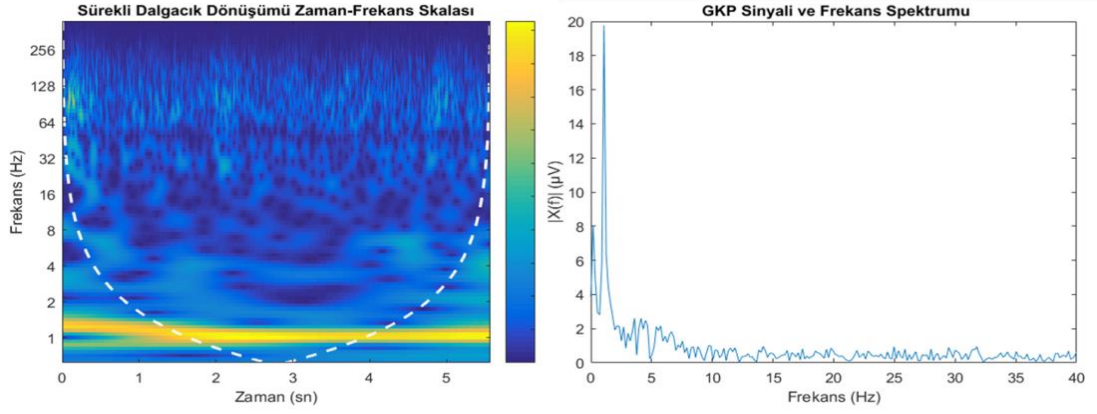


Şekil 4.13. En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaslari ile olusan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde deęişimini gösteren grafiksel gösterim




Şekil 4.14. En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.14. ve Şekil 4.15.'de en başarılı ve en başarısız katılımcının dil hareketi ve yanak duvarına dokunuşlarına bağlı olarak üretilen GKP sinyallerinin zaman-frekans skalası ve frekans spektrum grafikleri görülmektedir. En başarılı katılımcı için GKP sinyalleri, delta frekans bandı içinde 1-2 Hz civarında 14 μV genlikten yüksek üretilirken, 4 Hz civarında 13 μV ve 7-8 Hz arasında 6 μV genliğe kadar ulaşabilmektedir. En başarısız katılımcı için GKP sinyallerine ait frekans spektrumu, delta frekans bandı (1-4 Hz) içinde özellikle 1-2 Hz civarında 20 μV sinyal genliğine ulaştığı görülmektedir.



Şekil 4.15. En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)



Şekil 4.16. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.16.'da en başarılı ve en başarısız katılımcıya ait periodogram grafikleri gösterilmiştir. Zaman-frekans skalası ve frekans spektrumunda olduğu gibi özellikle delta frekans bandı içinde yüksek sinyal genliğine bağlı olarak ilgili frekanslarda yüksek sinyal güç yoğunluğu oluşturmuştur. En başarılı katılımcı için 3-4 Hz civarında $\leq 200 \mu V^2/Hz$ spektral güç yoğunluğu oluşurken, en başarısız katılımcı için aynı değerdeki spektral güç yoğunluğu 1-2 Hz arasında oluştuğu hesaplanmıştır.

4.1.3. Varyans sonuçları

Varyans (VAR), istatistik biliminde bir veri setindeki her veri değerinin o veri setindeki ortalama değer karelerinin ortalamasına eşit olan parametre olarak bilinir. Aynı zamanda standart sapmanın karesine eşittir [87]. Tez çalışması içinde VAR da,


STD gibi zaman alanında sinyal üzerinden özellik çıkarma işlemi için kullanılmıştır. Varyans metoduna ait sınıflandırma sonuçları şöyledir:

Tablo 4.13. VAR ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|--------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|--------------|------|
| ACC | 72,40 | 83,21 | 78,33 | 74,38 | 70,14 | 91,14 | 67,08 | 83,33 | 76,46 | 88,46 | 78,49 | SVM |
| SPEC | 70,08 | 73,00 | 72,47 | 62,37 | 63,15 | 87,30 | 66,28 | 90,18 | 66,68 | 89,15 | 74,07 | |
| SENS | 75,76 | 93,54 | 86,02 | 91,60 | 81,02 | 96,92 | 68,52 | 74,75 | 89,59 | 87,89 | 84,56 | |
| ITR | 0,150 | 0,347 | 0,246 | 0,179 | 0,120 | 0,568 | 0,086 | 0,350 | 0,213 | 0,484 | 0,274 | |
| ACC | 72,49 | 81,44 | 75,12 | 73,01 | 73,16 | 89,31 | 66,29 | 80,42 | 72,06 | 86,02 | 76,93 | LDA |
| SPEC | 74,82 | 74,00 | 69,86 | 65,45 | 73,64 | 92,83 | 68,07 | 89,23 | 69,31 | 91,76 | 76,90 | |
| SENS | 68,77 | 88,99 | 82,25 | 83,60 | 73,09 | 83,67 | 63,89 | 69,23 | 75,78 | 77,63 | 76,69 | |
| ITR | 0,151 | 0,308 | 0,191 | 0,159 | 0,161 | 0,509 | 0,078 | 0,287 | 0,145 | 0,416 | 0,240 | |
| ACC | 64,46 | 73,22 | 73,30 | 66,09 | 68,78 | 83,16 | 59,63 | 72,41 | 61,29 | 83,10 | 70,54 | kNN |
| SPEC | 82,43 | 63,67 | 78,78 | 72,94 | 75,94 | 92,64 | 60,55 | 80,43 | 66,77 | 90,18 | 76,43 | |
| SENS | 40,71 | 82,78 | 66,38 | 56,99 | 57,80 | 69,18 | 58,28 | 62,20 | 53,66 | 73,56 | 62,15 | |
| ITR | 0,061 | 0,162 | 0,163 | 0,076 | 0,104 | 0,346 | 0,027 | 0,150 | 0,037 | 0,345 | 0,147 | |
| ACC | 70,74 | 81,03 | 77,64 | 70,83 | 73,16 | 91,08 | 64,00 | 78,69 | 68,89 | 86,57 | 76,26 | MLNN |
| SPEC | 76,54 | 75,50 | 77,67 | 75,34 | 78,17 | 94,98 | 69,39 | 84,86 | 80,96 | 88,33 | 80,18 | |
| SENS | 63,32 | 85,02 | 76,51 | 62,79 | 64,72 | 83,27 | 58,00 | 68,56 | 49,34 | 83,74 | 69,53 | |
| ITR | 0,128 | 0,299 | 0,233 | 0,129 | 0,161 | 0,566 | 0,057 | 0,253 | 0,106 | 0,431 | 0,236 | |
| ACC | 57,02 | 70,65 | 73,36 | 62,71 | 65,03 | 84,01 | 53,51 | 71,71 | 64,15 | 84,47 | 68,66 | PNN |
| SPEC | 100,00 | 82,50 | 74,62 | 64,95 | 72,79 | 92,84 | 100,00 | 84,76 | 81,79 | 94,80 | 84,91 | |
| SENS | 0,00 | 58,74 | 71,83 | 60,30 | 53,78 | 70,91 | 0,00 | 54,97 | 39,51 | 70,02 | 48,01 | |
| ITR | 0,014 | 0,127 | 0,164 | 0,047 | 0,066 | 0,366 | 0,004 | 0,141 | 0,059 | 0,377 | 0,136 | |
| ACC | 68,39 | 79,98 | 74,72 | 71,36 | 69,53 | 88,19 | 63,83 | 77,61 | 68,00 | 85,06 | 74,67 | DT |
| SPEC | 71,38 | 78,00 | 76,44 | 75,33 | 74,89 | 92,01 | 67,14 | 79,92 | 77,08 | 88,30 | 78,05 | |
| SENS | 64,31 | 82,07 | 72,62 | 66,17 | 61,35 | 82,58 | 60,02 | 74,88 | 55,64 | 81,07 | 70,07 | |
| ITR | 0,100 | 0,278 | 0,184 | 0,136 | 0,113 | 0,476 | 0,056 | 0,233 | 0,096 | 0,392 | 0,206 | |

Tablo 4.13.'de ham veri seti için varyans özellik çıkarma metodu kullanılmış ve makine öğrenmesi algoritmaları için 10 katılımcıya ait sınıflandırma sonuçları elde edilmiştir. VAR metodu ve ham veri seti sonuçlarına göre en başarılı ve en başarısız katılımcı sırasıyla, katılımcı-6 ve katılımcı-7 olarak elde edilmiştir. Şekil 4.17.'de görüldüğü gibi katılımcı-6 için en yüksek sınıflandırma doğruluk oranı %91,14 (SVM) iken, katılımcı-7 için en yüksek doğruluk oranı değeri %67,08 (SVM) olarak

hesaplanmıştır. Ortalama doğruluk oranı ise SVM ile %78,49 olarak elde edilmiştir. Katılımcı-6 ve katılımcı-7 için en düşük hesaplanan doğruluk oranı ve ITR değerleri sırasıyla %83,16-0,346 (kNN) ve %53,51-0,004 (PNN) olarak bulunmuştur. Bununla beraber, VAR metodunun ham veri seti en yüksek sonuç değerleri için STD ve RMS metotlarından en başarılı katılımcı, en başarısız katılımcı ve 10 katılımcıya ait ortalama sonuçlarda daha düşük değerler ürettiği gözlenmiştir.



Şekil 4.17. Varyans ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.14. VAR ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|--------------|------|
| ACC | 72,01 | 82,20 | 80,03 | 75,22 | 71,48 | 91,22 | 67,01 | 82,27 | 71,53 | 86,05 | 77,90 | SVM |
| SPEC | 81,90 | 73,00 | 76,50 | 79,24 | 79,11 | 92,86 | 71,88 | 91,54 | 78,80 | 91,34 | 81,62 | |
| SENS | 58,79 | 91,48 | 84,75 | 69,35 | 61,17 | 88,73 | 61,53 | 70,28 | 61,82 | 79,14 | 72,70 | |
| ITR | 0,145 | 0,324 | 0,279 | 0,192 | 0,138 | 0,571 | 0,085 | 0,326 | 0,138 | 0,417 | 0,261 | |
| ACC | 73,81 | 82,15 | 76,17 | 71,29 | 69,08 | 89,03 | 67,28 | 77,14 | 71,10 | 86,04 | 76,31 | LDA |
| SPEC | 73,95 | 69,00 | 68,40 | 67,97 | 66,96 | 92,45 | 66,13 | 86,68 | 72,81 | 92,64 | 75,70 | |
| SENS | 73,90 | 95,19 | 86,36 | 75,33 | 72,46 | 84,60 | 68,69 | 64,94 | 68,34 | 76,92 | 76,67 | |
| ITR | 0,170 | 0,323 | 0,208 | 0,135 | 0,108 | 0,501 | 0,088 | 0,224 | 0,133 | 0,417 | 0,231 | |
| ACC | 68,92 | 71,05 | 73,04 | 69,51 | 68,02 | 81,31 | 62,01 | 69,48 | 65,76 | 78,10 | 70,72 | kNN |
| SPEC | 85,28 | 70,50 | 75,03 | 77,02 | 76,39 | 84,49 | 66,69 | 90,25 | 65,34 | 88,08 | 77,91 | |
| SENS | 46,97 | 71,82 | 70,69 | 59,09 | 55,34 | 76,50 | 56,63 | 42,94 | 66,60 | 64,12 | 61,07 | |
| ITR | 0,106 | 0,132 | 0,159 | 0,113 | 0,096 | 0,305 | 0,042 | 0,112 | 0,073 | 0,242 | 0,138 | |
| ACC | 70,13 | 79,33 | 78,14 | 71,79 | 72,27 | 90,49 | 66,09 | 78,76 | 67,35 | 84,11 | 75,85 | MLNN |
| SPEC | 78,81 | 74,00 | 75,95 | 76,18 | 77,81 | 94,08 | 69,78 | 88,91 | 82,75 | 87,45 | 80,57 | |
| SENS | 57,47 | 83,30 | 78,77 | 64,38 | 64,34 | 83,94 | 60,20 | 64,31 | 45,91 | 77,51 | 68,02 | |
| ITR | 0,120 | 0,265 | 0,242 | 0,142 | 0,148 | 0,547 | 0,076 | 0,254 | 0,089 | 0,368 | 0,225 | |

Tablo 4.14. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|
| ACC | 57,02 | 74,28 | 71,34 | 58,06 | 60,02 | 83,08 | 53,38 | 71,57 | 62,28 | 83,09 | 67,41 | PNN |
| SPEC | 100 | 59,00 | 72,00 | 100 | 100 | 85,27 | 100 | 85,26 | 91,36 | 95,27 | 88,82 | |
| SENS | 0,00 | 89,52 | 70,64 | 0,00 | 0,00 | 80,22 | 0,00 | 54,63 | 22,46 | 66,44 | 38,39 | |
| ITR | 0,014 | 0,178 | 0,136 | 0,019 | 0,029 | 0,344 | 0,003 | 0,139 | 0,044 | 0,344 | 0,125 | |
| ACC | 68,98 | 74,28 | 76,73 | 70,05 | 71,69 | 87,06 | 63,03 | 73,08 | 65,53 | 86,25 | 73,67 | DT |
| SPEC | 73,16 | 75,00 | 77,35 | 77,95 | 79,06 | 89,04 | 70,45 | 78,99 | 69,64 | 89,18 | 77,98 | |
| SENS | 63,56 | 73,68 | 75,71 | 59,55 | 60,61 | 83,69 | 54,49 | 65,58 | 60,20 | 82,72 | 67,98 | |
| ITR | 0,107 | 0,178 | 0,217 | 0,119 | 0,140 | 0,444 | 0,050 | 0,160 | 0,071 | 0,422 | 0,191 | |

Tablo 4.14.'de elde edilen sonuç değerlerinde PCA veri seti için VAR özellik çıkarma metodu kullanılmıştır. En başarılı katılımcı, en yüksek doğruluk oranını SVM (%91,22) ile elde ederken, en başarısız katılımcı bu değere LDA (%67,28) ile ulaşmıştır. 10 katılımcıya ait en yüksek sınıflandırma doğruluk oranını %77,90 ile SVM algoritması elde etmiştir. Buna ek olarak, kNN ve PNN, katılımcı-6 ve katılımcı-7 için sırasıyla %81,31 ve %53,38 en düşük doğruluk oranı değerlerini hesaplayan algoritma olarak görülmektedir. Ham veri seti sonuçlarına kıyasla Tablo 4.14'de, en başarılı katılımcı için doğruluk oranı artış değeri 0,08 puan olurken, en başarısız katılımcı için 0,2 puanlık artış miktarı gözlenmiştir.

Tablo 4.15. VAR ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|--------------|-----|
| ACC | 71,12 | 84,17 | 75,00 | 59,85 | 65,51 | 91,03 | 67,31 | 66,06 | 66,75 | 84,31 | 73,11 | SVM |
| SPEC | 87,19 | 75,50 | 68,40 | 99,57 | 91,61 | 95,82 | 92,92 | 88,02 | 65,40 | 95,65 | 86,01 | |
| SENS | 49,71 | 92,98 | 83,62 | 5,01 | 26,96 | 84,30 | 38,32 | 37,72 | 68,84 | 68,96 | 55,64 | |
| ITR | 0,133 | 0,370 | 0,189 | 0,028 | 0,071 | 0,565 | 0,088 | 0,076 | 0,083 | 0,373 | 0,197 | |
| ACC | 71,92 | 83,01 | 72,10 | 64,71 | 66,33 | 89,03 | 70,17 | 70,05 | 62,77 | 87,57 | 73,77 | LDA |
| SPEC | 75,89 | 72,50 | 60,59 | 70,53 | 66,12 | 96,25 | 75,17 | 82,11 | 50,62 | 96,96 | 74,67 | |
| SENS | 66,85 | 93,61 | 87,20 | 56,70 | 65,95 | 78,42 | 64,67 | 54,40 | 79,44 | 74,65 | 72,19 | |
| ITR | 0,144 | 0,342 | 0,146 | 0,063 | 0,078 | 0,501 | 0,121 | 0,119 | 0,048 | 0,458 | 0,202 | |

Tablo 4.16. VAR ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|--------------|-----|
| ACC | 71,42 | 83,00 | 76,10 | 62,10 | 71,93 | 89,04 | 66,40 | 81,06 | 66,43 | 87,13 | 75,46 | SVM |
| SPEC | 82,75 | 72,50 | 72,41 | 97,39 | 84,47 | 91,97 | 78,94 | 91,07 | 68,03 | 92,61 | 83,21 | |
| SENS | 56,34 | 93,57 | 80,84 | 14,06 | 52,89 | 84,81 | 52,42 | 68,55 | 64,82 | 79,48 | 64,78 | |
| ITR | 0,137 | 0,342 | 0,207 | 0,043 | 0,144 | 0,501 | 0,079 | 0,300 | 0,079 | 0,446 | 0,228 | |
| ACC | 72,05 | 82,03 | 75,04 | 62,26 | 73,46 | 89,47 | 67,10 | 78,25 | 65,11 | 86,13 | 75,09 | LDA |
| SPEC | 71,82 | 71,50 | 65,28 | 59,33 | 71,11 | 94,93 | 65,67 | 86,64 | 55,82 | 94,78 | 73,69 | |
| SENS | 72,11 | 92,36 | 87,82 | 66,05 | 77,06 | 81,58 | 68,58 | 67,63 | 77,66 | 74,18 | 76,50 | |
| ITR | 0,145 | 0,321 | 0,189 | 0,044 | 0,165 | 0,514 | 0,086 | 0,244 | 0,067 | 0,419 | 0,219 | |

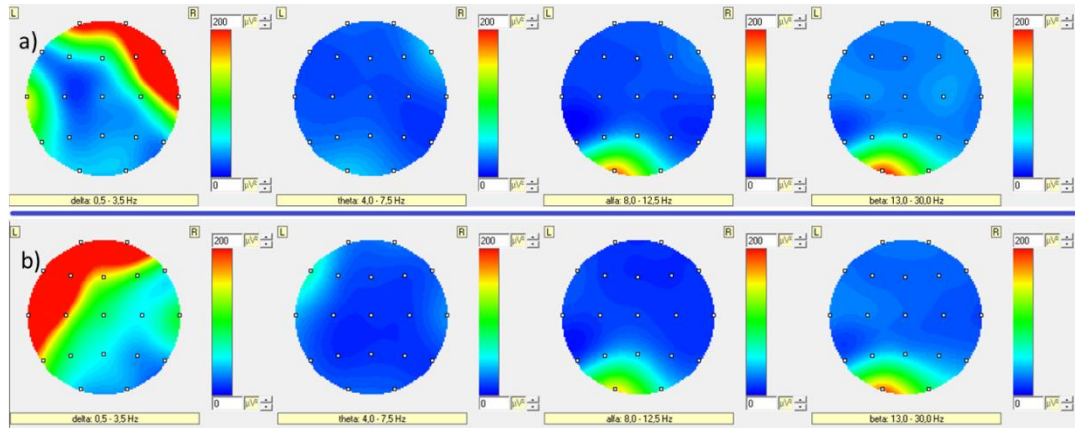
Tablo 4.15. ve Tablo 4.16.'da, 7 ve 11 kanal veri setleri üzerinde VAR metodu kullanılmış ve makine öğrenmesi algoritmalarına ait sınıflandırma sonuçları elde edilmiştir. En başarılı ve en başarısız katılımcı için 7 kanal veri setine ait sınıflandırma doğruluk oranı değerlerinin, 11 kanal veri setine göre sırasıyla %1,74 ve %4,57 oranında daha yüksek olduğu hesaplanmıştır. 10 katılımcıya ait sınıflandırma doğruluk oranı değeri 11 kanal veri setinde %75,46 (SVM) olarak elde edilmiştir. 7 kanal veri setinde ortalama doğruluk oranı değeri ise %73,77 (LDA) olarak belirlenmiştir. Bununla beraber 11 kanal veri setinde ortalama en yüksek doğruluk oranı değeri, ham veri seti ortalama en yüksek doğruluk oranı değerinden 3,03 puan daha düşük elde edilmiştir.

Tablo 4.17. VAR ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|--------------|-----|
| ACC | 73,03 | 84,22 | 76,65 | 69,44 | 81,19 | 91,06 | 73,00 | 73,04 | 71,00 | 92,20 | 78,48 | SVM |
| SPEC | 85,43 | 72,00 | 83,95 | 87,86 | 88,22 | 94,53 | 82,12 | 82,47 | 77,92 | 95,65 | 85,02 | |
| SENS | 56,94 | 96,39 | 67,61 | 44,15 | 70,61 | 86,52 | 62,31 | 61,31 | 61,26 | 87,74 | 69,49 | |
| ITR | 0,159 | 0,371 | 0,216 | 0,112 | 0,303 | 0,566 | 0,159 | 0,159 | 0,131 | 0,605 | 0,278 | |
| ACC | 71,09 | 84,71 | 76,40 | 68,02 | 80,23 | 91,37 | 71,11 | 72,85 | 73,40 | 91,11 | 78,03 | LDA |
| SPEC | 68,83 | 75,00 | 75,18 | 68,84 | 82,81 | 94,49 | 72,79 | 76,32 | 72,26 | 96,09 | 78,26 | |
| SENS | 74,46 | 94,44 | 78,18 | 67,52 | 76,86 | 86,29 | 69,14 | 67,98 | 75,38 | 84,55 | 77,48 | |
| ITR | 0,132 | 0,383 | 0,212 | 0,096 | 0,283 | 0,576 | 0,133 | 0,156 | 0,164 | 0,567 | 0,270 | |

Tablo 4.17.'de DWT yöntemi ile delta ve teta frekans bantları çıkarılan veri setinin VAR özellik çıkarma metodu uygulanarak elde edilen başarı değerleri görülmektedir.

En başarılı katılımcı için en yüksek doğruluk oranı değeri %91,37 (LDA) olarak hesaplanmıştır. En başarısız katılımcı için bu değer %73,00 (SVM) olarak elde edilmiştir. Görüldüğü üzere DWT ile alt frekans bantlarının (delta ve teta) elde edilmesi, VAR metodu uygulandıktan sonra sınıflandırma başarı oranlarını, en başarılı ve en başarısız katılımcı için sırasıyla 0,23 ve 5,92 puan kadar arttırmıştır. Ortalama sınıflandırma doğruluk değeri için ise DWT, LDA'da 1,1 puan arttırma başarısını sağlamıştır. SVM'de ise 0,01 puan kadar düşük ortalama doğruluk değeri sonucu üretilmiştir.

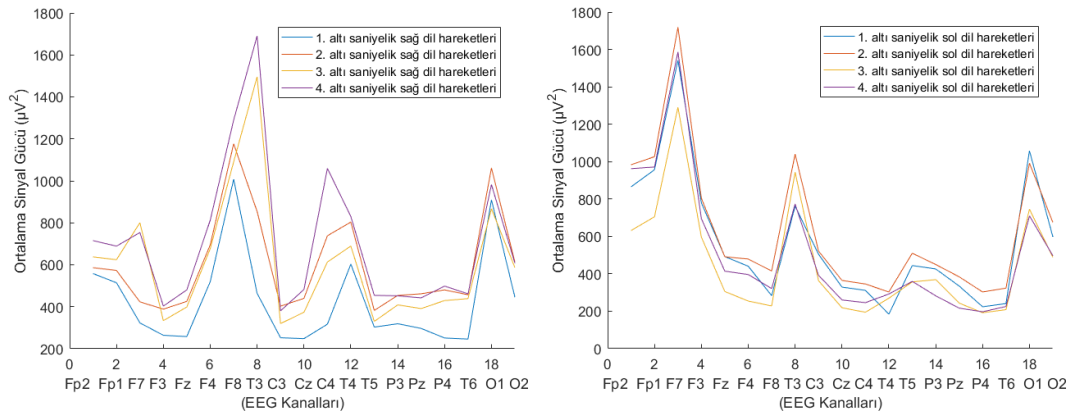


Şekil 4.18. En başarılı katılımcıya (katılımcı-6) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.18.'de en başarılı katılımcıya ait beyin haritalama sonuçları görülmektedir. Glossokinetik potansiyel sinyallerinin doğasından dolayı düşük frekanslarda görülen sinyal güç yoğunlukları, her iki yön için de, Fp1 ve Fp2 frontal bölgeden başlayarak T3 ve T4 bölgesini içine alacak şekilde temporal bölgeye kadar uzanmaktadır. Buna ek olarak sinyal güç yoğunluğunun sol dil hareketi ve dokunuşlarda T5 elektrot kanalına kadar genişlediği görülebilmektedir. Bununla beraber sağ ve sol beyin haritalama sonuçlarında arka-frontal (F3, Fz, F4) bölgede, merkez (C3, Cz, C4) bölgede ortalama seviyede sinyal gücü yoğunluğu fark edilmiştir. Ayrıca sol dil hareketi ve dokunuşlarda, parietal (P3, Pz) bölgede de ortalama seviyede sinyal gücü yoğunluğu oluşmaktadır. Teta frekans bandında her iki yön için de gözlenen çok düşük düzeyde sinyal güç yoğunluğu mevcuttur. En başarılı katılımcı için alfa ve beta frekanslarında oksipital bölgede özellikle O1 elektrot kanalı üzerinde yoğunluk kazanan sinyal gücünün, gözün LCD monitör karşısında sürekli uyarılmasından veya

dil ucunun (ToT) üst damağa veya diğer artikülatoörlere teması ile oluşması durumu mevcut olabilir [9], [14].

Şekil 4.11.'de en başarısız katılımcıya ait (katılımcı-7) beyin haritalama sonuçları görölmektedir. Katılımcı-7'ye ait beyin haritalama sonuçları için Şekil 4.11.'in hemen altında belirtilen çıkarımlara ek olarak, katılımcı-6 ile ilgili ilişkişel yorumlar ve farklar şöyledir: En başarılı katılımcı olan katılımcı-6'ya ait beyin haritalamasında sağ yarımkürede oluşan sinyal güç yoğunluğunun F4 ve T4 elektrot bölgesini de içeren şekilde örüntüye sahip olduđu görölmektedir. Yine sağ yarımkürede oluşan GKP sinyaline ait sinyal güç yoğunluğunun, katılımcı-7'de F4 ve T4 elektrot bölgesinde sınırda kaldığı ve ortalama seviyede bir sinyal güç yoğunluğuna sahip olduđu söylenebilir. Bununla beraber katılımcı-7 için sol yarımkürede, katılımcı-6'da gözlenen T3 ve T5 temporal elektrot bölgelerini bütünüyle içeren sinyal güç yoğunluđu oluşmamıştır.



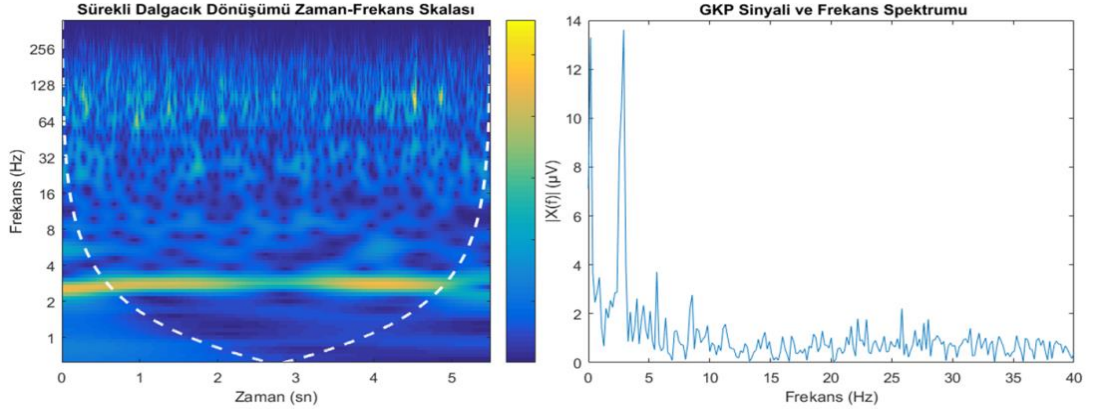
Şekil 4.19. En başarılı katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değışimini gösteren grafiksel gösterim

Şekil 4.19.'da en başarılı katılımcıya ait ortalama sinyal gücünün EEG elektrot kanallarına göre değışimi görölmektedir. Sağ dil hareketleri için F4, F8, T3 bölgeleri ile C4, T4 bölgelerine ait kanallarda diğör bölgelere ait kanallardan daha yüksek bir ortalama sinyal gücü elde edilmiştir. Özellikle dördüncü altı saniyelik sağ dil hareketine bağılı olarak üretilen GKP sinyal gücünün ortalama değışimine ait değışimin, diğör dil hareketlerinden daha yüksek olduđu ($\geq 1600 \mu V^2$) görölmektedir. Birinci, ikinci ve üçüncü sağ dil hareketine bağılı ortalama sinyal güçlerinin tepe noktaları


($400 \mu V^2$ - $1600 \mu V^2$) elde edilmiştir. Sol dil hareketlerinin ortalama sinyal güç değişimleri ise F7 bölgesinde ($1200 \mu V^2$ - $1800 \mu V^2$) en yüksek değerler aldığı görülebilmektedir. Yine Fp1, F3 bölgelerinde ($600 \mu V^2$ - $1000 \mu V^2$) değerler aldığı görülürken, T3 bölgesinde ($600 \mu V^2$ - $1000 \mu V^2$) seviyesinde ortalama sinyal gücü görülmektedir. Buna ek olarak sağ ve sol dil hareketleri için O1, O2 bölgesinde ($600 \mu V^2$ - $1000 \mu V^2$) değerler aralığında ortalama sinyal güçleri hesaplanmıştır.

Şekil 4.13.'de, en başarısız katılımcıya (katılımcı-7) ait ortalama sinyal gücü ve EEG kanalları üzerindeki değişim gösterilmiş ve değerlendirmeler ilgili şeklin alt tarafında belirtilmiştir. Buna ek olarak, varyans metodu sonuçları için en başarılı katılımcı (katılımcı-6) ile ortalama sinyal gücü grafiğine ait karşılaştırmalı değerlendirme şöyledir: En başarısız katılımcının ortalama sinyal gücü değişimi bütün altı saniyelik dil hareket sonuçları için her iki yönde neredeyse simetrik ve benzer çıkmaktadır. En başarılı katılımcı için bu değişimler her iki yön için birbirlerinden daha bağımsız ortaya çıkmıştır (Şekil 4.19.). Katılımcı-6'da sağ-sol dil hareketlerine ait ortalama sinyal güçlerinin, sağ dil hareketlerinde sağ bölgelerdeki kanallarda (F8, T4) daha yüksek çıktığı gözlenirken, sol dil hareketlerinde sol bölgelerdeki kanallarda (F7, T3) daha yüksek çıktığı belirlenmiştir.

Şekil 4.20.'de en başarılı katılımcıya ait GKP sinyallerinin zaman-frekans skalası ve frekans spektrumu gösterilmektedir. Görüldüğü üzere GKP sinyali delta frekans bandı içinde 6 sn süresinde 2-4 Hz arasında $12 \mu V$ - $14 \mu V$ aralığında yüksek bir genliğe sahiptir. Bununla beraber 4 Hz'den başlayan sinyalin 10 Hz'e kadar $2 \mu V$ - $4 \mu V$ aralığında genliğe sahip olduğu görülmektedir. Şekil 4.15.'de en başarısız katılımcıya ait eş değer grafikte GKP sinyalinin 1-2 Hz civarında $20 \mu V$ sinyal genliğine ulaştığı görülmektedir.



Şekil 4.20. En başarılı katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)



Şekil 4.21. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.21.'de en başarılı ve en başarısız katılımcıya ait dil hareketine bağlı olarak oluşan GKP sinyallerinin periodogram grafikleri gösterilmiştir. Görüldüğü üzere en başarısız katılımcıda oluşan spektral güç yoğunluğu 1-2 Hz aralığında $200 \mu V^2/Hz$ değerinde oluşurken, en başarılı katılımcıda 3-4 Hz aralığında $120 \mu V^2/Hz$ - $140 \mu V^2/Hz$ değerlerine ulaşmaktadır. Her iki katılımcıda da alfa ve beta frekans bantları içinde spektral güç yoğunluğu görülmemektedir.


4.1.4. Ortalama değer sonuçları

Sinyal işleme uygulamalarında zaman alanında en çok kullanılan özellik çıkarma metotlarından birisi olan ortalama değere (MV) ait tez sonuçları gösterilmiştir. Diğer özellik çıkarma metotlarında olduğu gibi en başarılı ve en başarısız katılımcıya ait sonuç değerleri ham veri seti sonuçlarına göre belirlenmiş ve ilgili çıkarımlar ortalama sınıflandırma başarıları ile birlikte bu katılımcılar ön plana alınarak yapılmıştır. Ortalama değer metoduna ait sonuç değerleri şöyledir:

Tablo 4.18. MV ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|-------|--------------|------|
| ACC | 74,90 | 84,29 | 73,96 | 69,35 | 88,94 | 94,03 | 84,22 | 84,33 | 90,49 | 89,43 | 83,39 | SVM |
| SPEC | 86,31 | 80,50 | 76,43 | 59,61 | 90,80 | 94,95 | 79,85 | 90,95 | 85,29 | 90,49 | 83,52 | |
| SENS | 60,57 | 88,07 | 70,84 | 81,69 | 86,57 | 92,96 | 89,17 | 76,04 | 97,52 | 88,18 | 83,16 | |
| ITR | 0,187 | 0,373 | 0,173 | 0,111 | 0,498 | 0,674 | 0,371 | 0,373 | 0,547 | 0,513 | 0,382 | |
| ACC | 54,44 | 54,04 | 54,23 | 53,05 | 51,27 | 63,13 | 56,16 | 63,06 | 62,80 | 51,63 | 56,38 | LDA |
| SPEC | 57,67 | 55,00 | 57,29 | 51,49 | 51,00 | 64,98 | 52,12 | 66,03 | 61,92 | 53,73 | 57,12 | |
| SENS | 50,32 | 53,12 | 50,18 | 54,95 | 51,88 | 60,45 | 60,51 | 59,27 | 64,03 | 48,71 | 55,34 | |
| ITR | 0,006 | 0,005 | 0,005 | 0,003 | 0,001 | 0,050 | 0,011 | 0,050 | 0,048 | 0,001 | 0,018 | |
| ACC | 67,27 | 82,02 | 64,33 | 64,20 | 86,13 | 87,11 | 80,07 | 67,41 | 79,19 | 87,01 | 76,47 | KNN |
| SPEC | 80,29 | 75,85 | 81,44 | 70,42 | 87,72 | 91,08 | 78,46 | 67,46 | 69,92 | 93,78 | 79,64 | |
| SENS | 50,50 | 88,25 | 42,22 | 54,93 | 83,73 | 81,11 | 81,96 | 67,27 | 91,38 | 77,82 | 71,92 | |
| ITR | 0,088 | 0,320 | 0,060 | 0,059 | 0,419 | 0,446 | 0,280 | 0,089 | 0,262 | 0,443 | 0,247 | |
| ACC | 72,52 | 84,00 | 71,30 | 68,31 | 88,35 | 93,93 | 83,68 | 76,87 | 86,26 | 89,52 | 81,47 | MLNN |
| SPEC | 78,36 | 80,00 | 80,99 | 74,08 | 90,36 | 94,53 | 84,87 | 77,79 | 83,97 | 94,40 | 83,93 | |
| SENS | 61,12 | 87,37 | 58,34 | 60,68 | 84,38 | 90,72 | 82,02 | 74,23 | 85,52 | 82,80 | 76,72 | |
| ITR | 0,152 | 0,366 | 0,135 | 0,099 | 0,481 | 0,670 | 0,358 | 0,220 | 0,422 | 0,516 | 0,342 | |
| ACC | 68,09 | 84,25 | 73,24 | 66,00 | 88,49 | 90,03 | 82,34 | 76,38 | 89,76 | 88,42 | 80,70 | PNN |
| SPEC | 81,86 | 73,00 | 77,77 | 67,54 | 90,83 | 92,81 | 80,71 | 72,65 | 88,75 | 96,11 | 82,20 | |
| SENS | 49,88 | 95,56 | 67,34 | 63,64 | 84,98 | 85,73 | 83,72 | 80,78 | 91,04 | 77,48 | 78,02 | |
| ITR | 0,097 | 0,372 | 0,162 | 0,075 | 0,485 | 0,532 | 0,327 | 0,211 | 0,524 | 0,483 | 0,327 | |
| ACC | 68,05 | 83,26 | 68,16 | 67,15 | 83,04 | 85,65 | 81,59 | 76,05 | 80,02 | 86,03 | 77,90 | DT |
| SPEC | 70,43 | 79,50 | 78,26 | 68,88 | 85,74 | 87,39 | 84,03 | 78,12 | 81,85 | 89,13 | 80,33 | |
| SENS | 64,92 | 87,02 | 55,16 | 64,29 | 78,81 | 82,80 | 79,17 | 73,19 | 77,65 | 81,73 | 74,47 | |
| ITR | 0,096 | 0,348 | 0,097 | 0,087 | 0,343 | 0,407 | 0,311 | 0,206 | 0,278 | 0,416 | 0,259 | |

Tablo 4.18.'de ortalama değer metoduna ait ham veri seti sonuçları ACC, SPEC, SENS ve ITR değerleri üzerinden gösterilmiştir. Görüldüğü üzere en başarılı katılımcı (%94,03-SVM) ve en başarısız katılımcı (%88,94-SVM) sırasıyla katılımcı-6 ve katılımcı-5 olarak elde edilmiştir (Şekil 4.22.). Destek vektör makinesi bireysel başarıda olduğu gibi 10 katılımcıya ait en yüksek sonuç değerini (%83,39) de sağlayan makine öğrenmesi algoritması olmuştur. Tez çalışmasında MV metodu ile beraber kullanılan SVM algoritmasında diğer özellik çıkarma metotlarında olduğu gibi SVM içinde doğrusal çekirdek yerine kuadratik çekirdek kullanılmıştır [3]. Bununla beraber çekirdek tabanlı LDA algoritmasında diğer metotlara ait sonuç değerlerinde olduğu gibi SVM'e yakın veya yüksek bir başarı değeri elde edilememiştir. Tablo 4.18.'de en düşük ortalama doğruluk oranı değeri %56,38 (LDA) olarak hesaplanmıştır. MV metodu ham veri seti (400×19) sonuçlarında RMS, STD ve VAR ham veri seti sonuçlarına kıyasla RMS metodundan sonra en yüksek başarı değerini elde etmiştir. Buna göre MV metodu, RMS metoduna kıyasla doğruluk oranı sonuçlarına göre en başarılı katılımcı için 2,98 puan, ortalama başarı için 3 puan kadar düşük değer oluşturmuştur. En başarısız katılımcı için ise MV, RMS'e kıyasla 10,94 puan kadar yüksek başarı sağlamıştır.



Şekil 4.22. Ortalama değer ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.19. MV ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| ACC | 57,03 | 52,29 | 59,16 | 58,10 | 60,06 | 62,08 | 62,19 | 64,62 | 63,46 | 59,02 | 59,80 |
| SPEC | 98,70 | 53,50 | 88,83 | 100 | 100 | 98,75 | 78,29 | 82,98 | 78,41 | 100 | 87,95 |
| SENS | 1,76 | 51,28 | 21,29 | 0,00 | 0,00 | 7,89 | 43,25 | 41,51 | 42,62 | 2,61 | 21,22 |
| ITR | 0,014 | 0,002 | 0,024 | 0,019 | 0,029 | 0,043 | 0,043 | 0,063 | 0,053 | 0,024 | 0,031 |

WAS

Tablo 4.19. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|-------|--------------|------|
| ACC | 54,02 | 52,03 | 56,21 | 51,49 | 50,73 | 59,28 | 56,57 | 63,29 | 64,35 | 50,02 | 55,80 | LDA |
| SPEC | 52,15 | 54,50 | 56,94 | 50,67 | 48,95 | 61,96 | 55,41 | 65,69 | 60,98 | 52,86 | 56,01 | |
| SENS | 56,88 | 49,57 | 54,57 | 52,77 | 53,86 | 55,13 | 57,46 | 59,89 | 69,26 | 46,38 | 55,58 | |
| ITR | 0,005 | 0,001 | 0,011 | 0,001 | 0,001 | 0,025 | 0,012 | 0,052 | 0,060 | 0,001 | 0,017 | |
| ACC | 69,08 | 81,33 | 70,45 | 67,39 | 81,03 | 90,98 | 82,04 | 76,79 | 89,06 | 80,60 | 78,88 | kNN |
| SPEC | 89,07 | 86,24 | 80,59 | 73,28 | 76,90 | 92,41 | 80,69 | 75,87 | 88,73 | 90,54 | 83,43 | |
| SENS | 42,34 | 76,45 | 57,76 | 59,02 | 87,31 | 88,79 | 83,67 | 77,87 | 89,76 | 66,78 | 72,97 | |
| ITR | 0,108 | 0,305 | 0,124 | 0,089 | 0,299 | 0,563 | 0,321 | 0,218 | 0,502 | 0,290 | 0,282 | |
| ACC | 70,88 | 84,89 | 73,55 | 69,10 | 85,38 | 89,54 | 82,46 | 75,48 | 86,20 | 87,45 | 80,49 | MLNN |
| SPEC | 80,22 | 85,00 | 82,15 | 78,30 | 88,24 | 90,27 | 82,14 | 77,29 | 83,93 | 90,47 | 83,80 | |
| SENS | 57,22 | 82,01 | 60,96 | 55,06 | 81,00 | 84,71 | 82,91 | 71,03 | 86,75 | 81,78 | 74,34 | |
| ITR | 0,130 | 0,387 | 0,167 | 0,108 | 0,400 | 0,517 | 0,330 | 0,196 | 0,421 | 0,455 | 0,311 | |
| ACC | 69,02 | 85,03 | 72,06 | 66,87 | 88,67 | 90,26 | 82,55 | 76,46 | 88,05 | 88,21 | 80,72 | PNN |
| SPEC | 84,68 | 75,00 | 82,23 | 66,68 | 92,86 | 94,96 | 81,13 | 74,58 | 86,99 | 96,12 | 83,53 | |
| SENS | 48,16 | 95,02 | 58,94 | 67,37 | 82,33 | 83,24 | 84,06 | 78,63 | 89,61 | 77,18 | 76,45 | |
| ITR | 0,107 | 0,391 | 0,145 | 0,084 | 0,490 | 0,539 | 0,332 | 0,213 | 0,472 | 0,477 | 0,325 | |
| ACC | 71,36 | 80,48 | 72,70 | 64,43 | 74,27 | 82,06 | 80,09 | 76,34 | 81,44 | 76,19 | 75,94 | DT |
| SPEC | 75,85 | 81,50 | 76,07 | 71,85 | 77,86 | 87,39 | 82,16 | 82,17 | 83,10 | 78,37 | 79,63 | |
| SENS | 65,75 | 79,36 | 68,39 | 54,07 | 68,07 | 74,24 | 77,41 | 68,87 | 79,32 | 72,98 | 70,84 | |
| ITR | 0,136 | 0,288 | 0,154 | 0,061 | 0,177 | 0,321 | 0,280 | 0,211 | 0,308 | 0,208 | 0,214 | |

Tablo 4.19.'da en başarılı katılımcının en yüksek elde ettiği doğruluk oranı değeri %90,98 (kNN) elde edilmiştir. En başarısız katılımcıya ve ortalama başarıya ait en yüksek doğruluk oranı değerleri sırasıyla %88,67 ve %80,72 ile PNN tarafından sağlanmıştır. Ham veri seti sonuç değerlerine göre MV ve PCA kombinasyonuna ait sonuçlar sırasıyla; katılımcı-6 ve katılımcı-5 için doğruluk oranı değeri 3,05 puan ve 0,27 puan azalış göstermiştir. 10 katılımcıya ait ortalama başarı değerinde ise doğruluk oranında 2,67 puan azalma hesaplanmıştır.

Tablo 4.20. MV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 57,22 | 59,04 | 59,00 | 58,12 | 60,01 | 59,41 | 62,12 | 60,12 | 58,00 | 58,04 | 59,11 | |
| SPEC | 100 | 57,50 | 99,57 | 100 | 100 | 100 | 98,59 | 98,64 | 100 | 100 | 95,43 | SVM |
| SENS | 0,00 | 61,11 | 6,30 | 0,00 | 0,00 | 0,00 | 20,28 | 11,17 | 0,00 | 0,00 | 9,89 | |
| ITR | 0,015 | 0,024 | 0,024 | 0,019 | 0,029 | 0,026 | 0,043 | 0,030 | 0,019 | 0,019 | 0,025 | |
| ACC | 56,30 | 52,02 | 55,31 | 50,42 | 47,75 | 58,10 | 51,12 | 56,08 | 58,02 | 47,20 | 53,23 | |
| SPEC | 56,88 | 51,00 | 57,83 | 45,96 | 49,40 | 61,16 | 50,71 | 57,23 | 53,66 | 50,63 | 53,45 | LDA |
| SENS | 55,69 | 52,73 | 52,18 | 56,60 | 45,09 | 53,17 | 51,30 | 54,85 | 63,49 | 42,17 | 52,73 | |
| ITR | 0,011 | 0,001 | 0,008 | 0,000 | 0,001 | 0,019 | 0,000 | 0,011 | 0,019 | 0,002 | 0,007 | |

Tablo 4.21. MV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

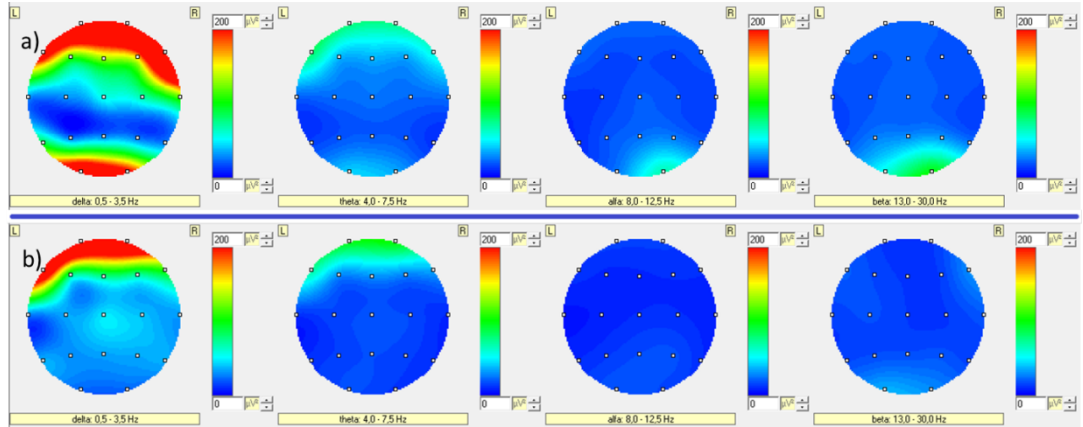
| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 57,18 | 55,52 | 59,34 | 58,04 | 60,18 | 60,02 | 62,10 | 65,19 | 59,14 | 58,06 | 59,48 | |
| SPEC | 99,09 | 43,50 | 94,66 | 100 | 100 | 100 | 94,33 | 84,35 | 97,86 | 100 | 91,38 | SVM |
| SENS | 2,00 | 67,32 | 13,65 | 0,00 | 0,00 | 1,25 | 25,29 | 40,99 | 6,36 | 0,00 | 15,69 | |
| ITR | 0,015 | 0,009 | 0,025 | 0,019 | 0,030 | 0,029 | 0,043 | 0,068 | 0,024 | 0,019 | 0,028 | |
| ACC | 56,45 | 51,23 | 55,01 | 52,01 | 49,21 | 60,43 | 54,50 | 61,06 | 55,11 | 50,29 | 54,53 | |
| SPEC | 56,48 | 50,00 | 53,40 | 51,56 | 49,80 | 58,22 | 55,93 | 59,82 | 52,39 | 55,85 | 54,35 | LDA |
| SENS | 56,27 | 52,43 | 56,98 | 52,70 | 48,97 | 63,96 | 52,64 | 62,35 | 58,95 | 42,34 | 54,76 | |
| ITR | 0,012 | 0,000 | 0,007 | 0,001 | 0,000 | 0,032 | 0,006 | 0,036 | 0,008 | 0,000 | 0,010 | |

Tablo 4.20. ve Tablo 4.21.'de 7 kanal ve 11 kanal veri setlerine ait MV metodu uygulanmış ve SVM ile LDA için sonuç değerleri elde edilmiştir. En başarılı katılımcıda 7 kanal ve 11 kanal veri setlerinde sırasıyla %59,41 ve %60,43 doğruluk oranı değerleri elde edilmiştir. En başarısız katılımcı için her iki veri setinde elde edilen değerler ise sırasıyla %60,01 ve %60,18 olarak görülmektedir. Ortalama başarıdaki doğruluk oranı artış değeri ise 0,37 ile SVM'de sağlanmıştır. Bununla beraber 11 kanal veri setinde en başarılı ve en başarısız katılımcıya ait ham veri setine kıyasla oldukça yüksek doğruluk oranı değeri azalması görülmektedir. Yine aynı veri seti karşılaştırmaları için (11 kanal ve ham veri seti) 10 katılımcıya ait ortalama başarı değerindeki doğruluk oranında ki azalma miktarı %36,74 olarak hesaplanmıştır.

Tablo 4.22. MV ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|--------------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 57,55 | 52,29 | 60,09 | 58,01 | 60,04 | 63,65 | 58,36 | 64,47 | 67,09 | 60,14 | 60,17 | |
| SPEC | 99,55 | 52,00 | 87,06 | 100 | 100 | 93,64 | 72,25 | 79,51 | 82,23 | 100 | 86,62 | SVM |
| SENS | 2,00 | 52,78 | 24,81 | 0,00 | 0,00 | 19,38 | 42,79 | 45,01 | 46,58 | 5,32 | 23,87 | |
| ITR | 0,017 | 0,002 | 0,030 | 0,019 | 0,029 | 0,054 | 0,020 | 0,061 | 0,086 | 0,030 | 0,035 | |
| ACC | 54,30 | 55,16 | 54,44 | 52,54 | 50,57 | 63,12 | 57,46 | 63,07 | 63,21 | 52,28 | 56,62 | |
| SPEC | 56,38 | 55,50 | 55,14 | 51,96 | 48,99 | 66,27 | 57,73 | 63,95 | 62,79 | 54,93 | 57,36 | |
| SENS | 51,76 | 55,21 | 53,26 | 53,32 | 53,20 | 58,90 | 57,08 | 62,02 | 63,80 | 49,07 | 55,76 | |
| ITR | 0,005 | 0,008 | 0,006 | 0,002 | 0,000 | 0,050 | 0,016 | 0,050 | 0,051 | 0,001 | 0,019 | |

Tablo 4.22.'de sınıflandırma performans değerleri açısından beklenenin aksine MV özellik çıkarma metodu 400×19 veri seti üzerinde bireysel ve ortalama başarı sonuçlarında oldukça düşük sonuçlar üretmiştir. En başarılı katılımcı için ham veri seti sonuçlarına göre doğruluk oranı değerinde azalma oranı %32,3, en başarısız katılımcı için doğruluk oranı değerinde azalma oranı %32,49 ve ortalama başarıda doğruluk oranı değerinde azalma oranı %27,84 olarak hesaplanmıştır.




Şekil 4.23. En başarısız katılımcıya (katılımcı-5) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.23.'de en başarısız katılımcıya ait beyin haritalama sonuçları görülmektedir. Sağ ve sol yarımkürede oluşan sinyal güç yoğunluğu delta frekans bandı içinde yer almakla beraber, her iki yön için de beta bandı frekansında ayırt edilebilir düzeyde sinyal güç yoğunluğu oluşmuştur. Sağ yarımkürede oluşan yüksek sinyal güç

yoğunluğu F7 bölgesinden başlayarak F8 bölgesini içine almaktadır. Bununla beraber yüksek sinyal güç yoğunluğunun arka-frontal bölgeyi (F3, Fz, F4) bütünüyle içermediği görülmektedir. Yine sağ yarımkürede orta seviyede sinyal güç yoğunluğunun T3, T4, T5 ve T6 temporal bölgeyle beraber P3, Pz, P4 parietal bölgede elde edildiği görülebilmektedir. Buna ek olarak, O1 ve O2 oksipital bölgeyi kapsayan yüksek sinyal güç yoğunluğu da gözlenmiştir. Sol dil hareket ve dokunuşlarına bağlı oluşan yüksek sinyal güç yoğunluğu sol yarımkürede Fp1, Fp2, F7 bölgelerinde oluşmaktadır. T3 ve T4 temporal bölgede ise orta seviyede sinyal güç yoğunluğu gözlenmiştir.

Şekil 4.18.'de en başarılı katılımcıya ait beyin haritalama örüntü sonuçları ve ilgili değerlendirmeler görülebilir. En başarılı (katılımcı-6) ve en başarısız (katılımcı-5) katılımcıya ait farklar şöyledir: En başarılı katılımcıda sağ ve sol yarımkürelerde T3 ve T4 temporal bölgelerinde görülen yüksek sinyal güç yoğunluğunun katılımcı-5 için oluşmadığı gözlenmektedir. Bununla beraber teta bandı içinde katılımcı-5'de orta seviyede oluşan sinyal güç yoğunluğunun katılımcı-6'da elde edilemediği görülmüştür.

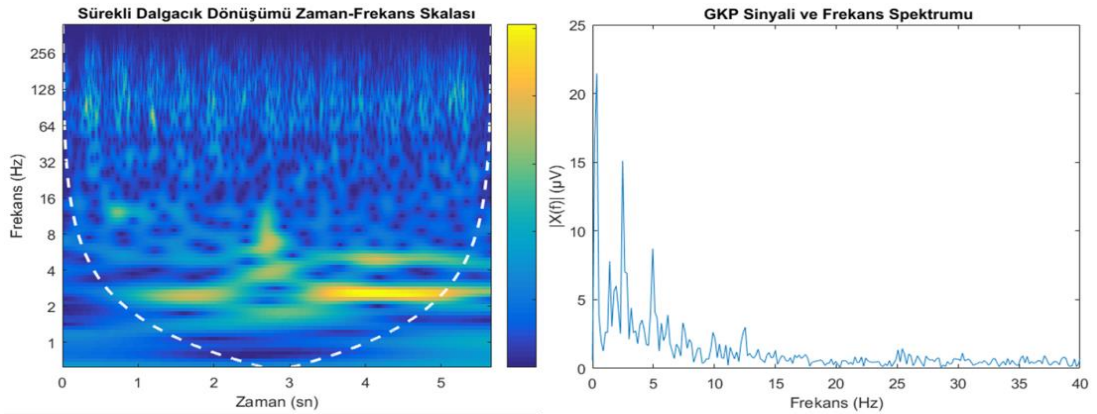


Şekil 4.24. En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaslari ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim

En başarısız katılımcıya ait ortalama sinyal gücü grafiği Şekil 4.24.'de gösterilmiştir. Sağ yarımküreye ait beyin haritalama sonuçlarında (Şekil 4.23.) da görüldüğü üzere; Fp2-Fp1 ($600 \mu V^2$ - $1400 \mu V^2$), F7 ($1000 \mu V^2$ - $1400 \mu V^2$), F8 ($400 \mu V^2$ - $600 \mu V^2$), T4-T5 ($400 \mu V^2$ - $600 \mu V^2$), P3-P4 ($400 \mu V^2$ - $800 \mu V^2$), T6 ($800 \mu V^2$), O1-O2 ($1400 \mu V^2$ -

1800 μV^2) kanallarına ait bölgelerde yüksek ve orta düzeyde ortalama sinyal gücü hesaplanmıştır. Sol dil hareketleri ve dokunuşları ile oluşan GKP sinyallerinin altı saniyelik hareketlerinde hesaplanan en yüksek ortalama sinyal gücünün (1200 μV^2), sağ dil hareketlerine ait en yüksek ortalama sinyal gücünden (1400 μV^2) daha az olduğu görülmektedir. Bununla beraber Fp2-Fp1 (600 μV^2 -1200 μV^2), F7-F3 (300 μV^2 -1000 μV^2), F8 (600 μV^2 -1000 μV^2), T5 (400 μV^2 -600 μV^2), P3-P4 (200 μV^2 -400 μV^2), O1-O2 (800 μV^2 -1200 μV^2) kanallarına ait bölgelerde yüksek ve orta düzeyde ortalama sinyal gücü elde edilmiştir.


Şekil 4.19.'da en başarılı katılımcıya (katılımcı-6) ait ortalama sinyal gücü grafiği gösterilmiştir. İlgili değerlendirmeler aynı şeklin altı tarafında belirtilmiştir. Katılımcı-6 ve katılımcı-5'e ait farklar ise şöyledir: En başarısız katılımcıda, en başarılı katılımcıda olduğunun aksine en yüksek ortalama sinyal güç değişimi sinyal kanalları üzerinde dil hareket yönüne göre ters oluşmuştur. Sağ dil hareket yönünde F7 bölgesinde ve sol dil hareketinde F8 bölgesinde en yüksek sinyal gücü oluşmaktadır. Bununla beraber katılımcı-6 için sağ dil hareketlerinde C4 ve T4, T5 üzerinde ortalama sinyal gücü değişimlerinin, aynı bölge için katılımcı-5'den daha ayırt edilebilir olduğu görülmektedir.



Şekil 4.25. En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.25.'de en başarısız katılımcının (katılımcı-5) dil hareketine ait GKP ham veri sinyalinin zaman-frekans skalası ve frekans spektrumu gösterilmiştir. Görüldüğü üzere GKP sinyali, delta bandı içinde 3-4 Hz arasında 15 μV genliğe, 5-6 Hz

civarında 8 μV genliğe ulaşmaktadır. Bununla beraber, teta frekans bandı (4-7 Hz) içinde oluşan GKP sinyal genliği $\geq 3 \mu\text{V}$ değerinde elde edilmiştir. En başarılı katılımcıya (katılımcı-6) ait zaman-frekans skalası ve frekans spektrumu Şekil 4.20'de gösterilmiştir. Her iki katılımcıya ait fark analizi şöyledir: En başarısız katılımcıda sinyal genliği 10 Hz'den sonraki frekanslarda gittikçe azalırken, en başarılı katılımcıda belirtilen frekanstan sonra oluşan sinyal genliği neredeyse sabittir ve 2 μV civarında görülmektedir.



Şekil 4.26. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.26.'de katılımcı-6 ve katılımcı-5'e ait periodogram grafikleri verilmiştir. En başarılı katılımcı için spektral güç yoğunluğu 3-4 Hz aralığında $\geq 120 \mu\text{V}^2/\text{Hz}$ değerine ulaşmaktadır. En başarısız katılımcıya ait spektral güç yoğunluğu ise 3-4 Hz aralığında en yüksek değerini ($100 \mu\text{V}^2/\text{Hz}$) elde ederken, 10 Hz'e kadar olan frekans bandı içinde $\leq 40 \mu\text{V}^2/\text{Hz}$ değerine erişmektedir.

4.1.5. Ortalama mutlak değer sonuçları


Tez çalışması içinde kullanılan özellik çıkarma metotlarından birisi de ortalama mutlak değerdir (MAV). Tez çalışmasında MAV metodu için delta ve teta frekans bantlarını glossokinetik potansiyel sinyallerinden çıkarmak amacıyla DWT yöntemi uygulanmış ek veri setleri şunlardır: PCA veri seti, ICA veri seti, 7 kanal-frontal bölge veri seti, 11 kanal-frontal ve temporal bölge veri seti. MAV metodu uygulanmış veri seti sonuçları şunlardır:

Tablo 4.23. MAV ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 77,07 | 97,03 | 77,14 | 79,05 | 91,12 | 94,23 | 85,39 | 74,22 | 78,00 | 96,02 | 84,93 | SVM |
| SPEC | 87,23 | 97,50 | 84,55 | 80,49 | 93,33 | 96,20 | 83,59 | 69,21 | 74,02 | 97,84 | 86,40 | |
| SENS | 63,35 | 96,52 | 67,51 | 76,95 | 87,79 | 91,48 | 87,38 | 80,73 | 83,30 | 93,58 | 82,86 | |
| ITR | 0,223 | 0,807 | 0,224 | 0,259 | 0,567 | 0,682 | 0,400 | 0,177 | 0,240 | 0,758 | 0,434 | |
| ACC | 75,13 | 96,02 | 77,21 | 77,44 | 91,06 | 95,01 | 86,29 | 72,17 | 76,02 | 96,01 | 84,24 | LDA |
| SPEC | 76,52 | 93,50 | 79,98 | 73,13 | 90,80 | 97,05 | 84,00 | 64,19 | 68,88 | 97,83 | 82,59 | |
| SENS | 73,63 | 98,52 | 73,44 | 83,84 | 91,67 | 92,04 | 88,93 | 82,22 | 85,85 | 93,51 | 86,37 | |
| ITR | 0,191 | 0,759 | 0,226 | 0,230 | 0,565 | 0,714 | 0,423 | 0,147 | 0,205 | 0,758 | 0,422 | |
| ACC | 69,17 | 95,01 | 69,00 | 70,05 | 86,19 | 94,08 | 81,49 | 74,37 | 79,01 | 92,15 | 81,05 | kNN |
| SPEC | 87,88 | 95,43 | 85,59 | 79,22 | 90,05 | 96,65 | 80,25 | 72,33 | 80,33 | 97,09 | 86,48 | |
| SENS | 44,85 | 94,55 | 46,98 | 57,49 | 80,69 | 90,75 | 82,91 | 76,72 | 77,33 | 85,41 | 73,77 | |
| ITR | 0,109 | 0,714 | 0,107 | 0,119 | 0,421 | 0,676 | 0,309 | 0,179 | 0,259 | 0,603 | 0,350 | |
| ACC | 74,65 | 96,50 | 77,10 | 75,96 | 90,17 | 94,21 | 83,41 | 77,19 | 79,25 | 95,77 | 84,42 | MLNN |
| SPEC | 82,75 | 97,00 | 80,95 | 74,89 | 91,23 | 95,80 | 83,98 | 81,76 | 76,61 | 96,56 | 86,15 | |
| SENS | 63,62 | 95,95 | 71,16 | 76,44 | 86,96 | 90,00 | 82,23 | 69,87 | 79,46 | 94,30 | 81,00 | |
| ITR | 0,183 | 0,781 | 0,224 | 0,204 | 0,537 | 0,681 | 0,352 | 0,225 | 0,263 | 0,747 | 0,420 | |
| ACC | 70,04 | 95,26 | 71,61 | 73,17 | 87,12 | 94,39 | 82,53 | 77,14 | 85,75 | 93,53 | 83,05 | PNN |
| SPEC | 90,77 | 95,00 | 84,47 | 75,76 | 88,71 | 96,58 | 78,79 | 71,84 | 83,95 | 98,26 | 86,41 | |
| SENS | 42,72 | 95,45 | 54,75 | 69,42 | 84,81 | 91,30 | 86,93 | 83,93 | 88,18 | 87,15 | 78,46 | |
| ITR | 0,119 | 0,725 | 0,139 | 0,161 | 0,446 | 0,688 | 0,332 | 0,224 | 0,409 | 0,654 | 0,390 | |
| ACC | 69,01 | 94,00 | 71,53 | 69,06 | 85,53 | 92,01 | 82,98 | 78,41 | 76,03 | 91,01 | 80,96 | DT |
| SPEC | 73,54 | 91,50 | 74,76 | 75,76 | 86,18 | 92,75 | 88,20 | 81,36 | 79,66 | 91,30 | 83,50 | |
| SENS | 62,69 | 96,40 | 67,38 | 59,47 | 84,61 | 91,07 | 76,70 | 74,48 | 71,51 | 90,31 | 77,46 | |
| ITR | 0,107 | 0,673 | 0,138 | 0,108 | 0,403 | 0,598 | 0,342 | 0,247 | 0,205 | 0,564 | 0,339 | |

Tablo 4.23.'de ham veri setine uygulanan ortalama mutlak değer sonuçları görülmektedir. Görüldüğü üzere en başarılı katılımcı ve en başarısız katılımcı sırasıyla katılımcı-2 ve katılımcı-3 olarak belirlenmiştir. En başarılı katılımcı için hesaplanan en yüksek sınıflandırma doğruluk oranı değeri %97,03 (SVM) olurken, en başarısız katılımcı için ulaşılan en yüksek doğruluk oranı değeri %77,21 (LDA) olarak bulunmuştur. Tablo 4.23.'de en düşük doğruluk oranı kNN ile katılımcı-3 sonuçları içinde %69,00 olarak gözlenmiştir. Bununla beraber, ortalama sınıflandırma başarı değerleri içinde SVM (%84,93) en iyi performans gösteren algoritma olarak görülmektedir. MAV metodu ile en başarılı katılımcı, en başarısız

katılımcı ve ortalama sınıflandırma başarısında ulaşılan en iyi sınıflandırma performanslarının diğer özellik çıkarma metodlarından daha iyi sonuçlar ürettiği görülebilmektedir. Bu duruma uymayan RMS ve MV’de en başarısız katılımcı sonuç değerleridir. MAV metodu için katılımcı-2 ve katılımcı-3’e ait makine öğrenmesi algoritmalarında hesaplanan performans değerleri Şekil 4.27.’de görülebilmektedir.



Şekil 4.27. Ortalama mutlak değer ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.24. MAV ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 77,03 | 97,01 | 77,16 | 76,39 | 91,04 | 95,24 | 85,31 | 69,05 | 72,01 | 95,07 | 83,53 | SVM |
| SPEC | 85,85 | 97,50 | 82,79 | 81,43 | 91,65 | 96,61 | 82,71 | 65,65 | 61,90 | 97,83 | 84,39 | |
| SENS | 65,55 | 96,43 | 69,89 | 69,41 | 89,94 | 93,13 | 88,09 | 73,06 | 85,74 | 91,50 | 82,27 | |
| ITR | 0,223 | 0,806 | 0,225 | 0,211 | 0,565 | 0,724 | 0,398 | 0,107 | 0,145 | 0,717 | 0,412 | |
| ACC | 77,26 | 95,00 | 79,07 | 75,18 | 89,16 | 94,04 | 84,70 | 69,02 | 71,00 | 94,04 | 82,85 | LDA |
| SPEC | 79,29 | 91,00 | 81,38 | 73,59 | 88,64 | 96,20 | 81,26 | 61,05 | 60,13 | 95,71 | 80,83 | |
| SENS | 74,41 | 99,02 | 76,57 | 77,33 | 90,02 | 91,17 | 88,65 | 78,94 | 86,01 | 91,48 | 85,36 | |
| ITR | 0,226 | 0,714 | 0,260 | 0,192 | 0,505 | 0,674 | 0,383 | 0,107 | 0,131 | 0,674 | 0,387 | |
| ACC | 72,08 | 92,06 | 73,26 | 72,66 | 85,11 | 93,01 | 81,44 | 73,29 | 82,05 | 91,54 | 81,65 | KNN |
| SPEC | 85,85 | 90,54 | 86,71 | 76,75 | 85,12 | 95,96 | 81,34 | 70,91 | 81,00 | 95,50 | 84,97 | |
| SENS | 53,52 | 93,49 | 55,97 | 67,33 | 85,02 | 88,65 | 81,55 | 75,63 | 83,27 | 86,33 | 77,07 | |
| ITR | 0,146 | 0,600 | 0,162 | 0,154 | 0,393 | 0,634 | 0,308 | 0,163 | 0,321 | 0,582 | 0,346 | |
| ACC | 76,14 | 96,22 | 76,55 | 77,14 | 89,15 | 94,44 | 84,77 | 76,29 | 77,93 | 95,27 | 84,39 | MLNN |
| SPEC | 81,01 | 97,00 | 78,72 | 81,78 | 90,40 | 96,18 | 86,30 | 81,62 | 74,40 | 95,22 | 86,26 | |
| SENS | 68,87 | 93,05 | 72,74 | 70,25 | 85,68 | 91,04 | 82,99 | 68,79 | 80,80 | 94,26 | 80,85 | |
| ITR | 0,207 | 0,768 | 0,214 | 0,224 | 0,505 | 0,690 | 0,384 | 0,210 | 0,239 | 0,725 | 0,417 | |

Tablo 4.24. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|
| ACC | 70,33 | 95,06 | 73,56 | 73,01 | 87,50 | 94,40 | 84,01 | 77,33 | 84,39 | 94,03 | 83,36 | PNN |
| SPEC | 90,34 | 95,00 | 84,80 | 77,92 | 89,11 | 97,46 | 83,01 | 72,37 | 81,85 | 97,39 | 86,93 | |
| SENS | 44,25 | 95,23 | 59,20 | 66,24 | 85,25 | 89,75 | 85,12 | 83,65 | 87,90 | 89,56 | 78,62 | |
| ITR | 0,123 | 0,716 | 0,167 | 0,159 | 0,457 | 0,689 | 0,366 | 0,228 | 0,375 | 0,674 | 0,395 | |
| ACC | 71,87 | 93,22 | 72,15 | 72,03 | 84,66 | 91,07 | 80,44 | 73,29 | 75,09 | 90,10 | 80,39 | DT |
| SPEC | 77,63 | 91,50 | 76,52 | 76,21 | 87,81 | 91,07 | 82,19 | 74,58 | 78,75 | 91,78 | 82,80 | |
| SENS | 64,86 | 94,88 | 65,88 | 65,68 | 79,45 | 91,17 | 78,28 | 71,88 | 70,11 | 87,88 | 77,01 | |
| ITR | 0,143 | 0,642 | 0,147 | 0,145 | 0,382 | 0,566 | 0,287 | 0,163 | 0,190 | 0,534 | 0,320 | |

Tablo 4.24.'de MAV ve PCA veri setine ait sınıflandırma başarıları görülmektedir. Buna göre, en başarılı katılımcı için en yüksek sınıflandırma doğruluk oranı %97,01 (SVM) olurken, en başarısız katılımcı için en yüksek sınıflandırma doğruluk oranı %79,07 (LDA) olmaktadır. Ortalama başarı için ise sınıflandırma doğruluk oranı %84,39 (MLNN) olarak hesaplanmıştır. PCA veri seti sonuçları (400×12), ham veri seti sonuçlarından (400×19) doğruluk oranı değerlerine göre; en başarılı katılımcıda ve 10 katılımcı için ortalama sınıflandırma sonuçlarında sırasıyla 0,02 puan ve 0,54 puan düşük elde edilmiştir. Buna ek olarak en başarısız katılımcıda ise 1,86 puan yüksek elde edilmiştir.

Tablo 4.25. MAV ve ayırık dalgacık dönüşümü uygulanmış, temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|----|
| ACC | 73,35 | 95,01 | 72,93 | 70,18 | 87,07 | 95,82 | 81,01 | 73,53 | 79,74 | 93,07 | 82,17 | KN |
| SPEC | 82,83 | 93,17 | 87,76 | 75,3 | 88,92 | 97,9 | 79,56 | 71,98 | 78,77 | 95,76 | 85,19 | |
| SENS | 60,53 | 96,85 | 53,92 | 62,26 | 83,83 | 93,12 | 82,26 | 75,76 | 81,43 | 89,43 | 77,94 | |
| ITR | 0,164 | 0,714 | 0,157 | 0,121 | 0,444 | 0,749 | 0,299 | 0,166 | 0,273 | 0,637 | 0,372 | |
| ACC | 73,17 | 95,01 | 71,21 | 69,47 | 88,02 | 91,03 | 82,08 | 75,41 | 78,06 | 90,37 | 81,38 | DT |
| SPEC | 77,96 | 94 | 77,79 | 77,43 | 89,11 | 91,11 | 82,6 | 78,04 | 79,66 | 93,04 | 84,07 | |
| SENS | 67,17 | 96,02 | 62,17 | 57,96 | 85,6 | 90,81 | 81,66 | 72,31 | 75,68 | 86,14 | 77,55 | |
| ITR | 0,161 | 0,714 | 0,134 | 0,112 | 0,471 | 0,565 | 0,322 | 0,195 | 0,241 | 0,543 | 0,346 | |

Tablo 4.25.'de ayırık dalgacık dönüşümü ile delta ve teta frekans bantları çıkarılmış veri setine ortalama mutlak değer özellik çıkarma metodu uygulanmıştır. Daha sonra PCA yöntemi ile 12 temel bileşene sahip veri setine dönüştürülmüş ve boyutu

azaltılmıştır. En başarılı katılımcıya ait en yüksek sonuç değeri %95,01 (DT) olarak hesaplanırken, en başarısız katılımcıya ait en yüksek sonuç değeri %72,93 (kNN) olarak belirlenmiştir. Ortalama sınıflandırma başarısı ise %82,17 (kNN) değerine sahiptir. Buna göre Tablo 4.24.'te en yüksek doğruluk oranı değerlerine kıyasla; katılımcı-2 için doğruluk oranı azalışı %2,06, katılımcı-3 için doğruluk oranı azalışı %7,76 ve ortalama başarı için doğruluk oranı azalışı %2,63 olarak görülmektedir.

Tablo 4.26. MAV ve bağımsız bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 77,01 | 96,28 | 77,29 | 79,23 | 90,00 | 93,06 | 85,25 | 74,03 | 77,33 | 94,01 | 84,35 | SVM |
| SPEC | 85,06 | 96,00 | 83,52 | 80,14 | 90,80 | 94,13 | 82,23 | 70,04 | 74,02 | 95,24 | 85,12 | |
| SENS | 66,41 | 96,39 | 68,79 | 78,65 | 88,78 | 91,68 | 88,53 | 79,01 | 82,21 | 92,19 | 83,26 | |
| ITR | 0,222 | 0,771 | 0,227 | 0,263 | 0,531 | 0,636 | 0,397 | 0,174 | 0,228 | 0,673 | 0,412 | |
| ACC | 76,13 | 93,05 | 78,45 | 77,42 | 88,82 | 94,22 | 87,01 | 73,44 | 75,53 | 95,51 | 83,96 | LDA |
| SPEC | 78,81 | 89,50 | 81,88 | 73,19 | 89,15 | 95,40 | 86,36 | 67,33 | 65,89 | 97,84 | 82,54 | |
| SENS | 72,14 | 96,64 | 74,47 | 83,01 | 88,34 | 92,41 | 87,65 | 81,19 | 89,00 | 92,42 | 85,73 | |
| ITR | 0,207 | 0,636 | 0,248 | 0,229 | 0,495 | 0,681 | 0,443 | 0,165 | 0,197 | 0,736 | 0,404 | |

Tablo 4.26.'da MAV ve ICA veri setine ait sınıflandırma sonuçları görülmektedir. Katılımcı-2 için bulunan en yüksek doğruluk oranı değeri %96,28 (SVM) iken, katılımcı-3 için bulunan en yüksek doğruluk oranı değeri %78,45 (LDA) olarak görülmektedir. 10 katılımcıya ait en yüksek ortalama doğruluk oranı değeri ise %84,35 (SVM) olarak elde edilmiştir. PCA sonuç değerlerine (Tablo 4.24.) kıyasla; katılımcı-2 için doğruluk oranı değerinde 0,73 puan, katılımcı-3 için 0,62 puan, ortalama başarı için 0,04 puan azalma görülmektedir.

Tablo 4.27. MAV ve ayırık dalgacık dönüşümü uygulanmış, bağımsız bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 72,33 | 91,51 | 73,32 | 72,58 | 85,21 | 91,33 | 78,52 | 76,22 | 80,23 | 89,26 | 81,05 | kNN |
| SPEC | 87,66 | 93,98 | 80,91 | 73,12 | 87,43 | 95,78 | 70,31 | 75,89 | 74,95 | 96,93 | 83,7 | |
| SENS | 52,27 | 89,06 | 64,49 | 71,84 | 81,93 | 84,97 | 87,97 | 76,64 | 87,63 | 78,81 | 77,56 | |
| ITR | 0,149 | 0,581 | 0,163 | 0,153 | 0,395 | 0,575 | 0,249 | 0,209 | 0,283 | 0,508 | 0,326 | |

Tablo 4.27. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| ACC | 72,13 | 88,13 | 71,65 | 71,2 | 82,04 | 87,22 | 79 | 75,47 | 77,54 | 83,19 | 78,76 | DT |
| SPEC | 74,43 | 89,5 | 76,5 | 74,89 | 85,82 | 89 | 79,68 | 79,55 | 81,34 | 85,27 | 81,6 | |
| SENS | 69,27 | 86,77 | 65,32 | 66,56 | 76,52 | 84,13 | 78,35 | 70,7 | 72,17 | 80,46 | 75,03 | |
| ITR | 0,146 | 0,474 | 0,14 | 0,134 | 0,321 | 0,449 | 0,258 | 0,196 | 0,231 | 0,347 | 0,27 | |

Tablo 4.27.'de sağlanan sonuçlar için veri setine öncelikle DWT yöntemi uygulanmış daha sonra MAV metodu ile özelliği çıkarılmıştır. Daha sonra ICA yöntemi ile 19 kanalı içeren veri seti 12 kanalı içeren veri seti boyutuna azaltılmış ve sınıflandırma işlemi gerçekleştirilmiştir. Görüldüğü üzere doğruluk oranı değerlerinde; katılımcı-2 için %91,51 (kNN), katılımcı-3 için %73,32 (kNN) ve 10 katılımcı ortalama başarısı için %81,05 (kNN) elde edilmiştir. Tablo 4.26.'ya kıyasla en yüksek doğruluk oranı değerleri; en başarılı katılımcı, en başarısız katılımcı ve ortalama başarı için azalmıştır.

Tablo 4.28. MAV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 75,05 | 95,23 | 72,02 | 59,37 | 82,26 | 93,1 | 85,11 | 61,07 | 67,09 | 92,01 | 78,23 | SVM |
| SPEC | 86,78 | 94,5 | 83,56 | 96,52 | 89,11 | 94,06 | 79,83 | 93,32 | 59,26 | 93,06 | 87 | |
| SENS | 59,87 | 95,91 | 57,44 | 9,5 | 72,61 | 91,48 | 91,12 | 19,89 | 77,64 | 90,81 | 66,63 | |
| ITR | 0,190 | 0,723 | 0,145 | 0,025 | 0,326 | 0,638 | 0,393 | 0,036 | 0,086 | 0,598 | 0,316 | |
| ACC | 75,16 | 95,02 | 74,08 | 60,24 | 82,02 | 93,05 | 85,3 | 57 | 66,03 | 91,03 | 77,89 | LDA |
| SPEC | 77,49 | 93,5 | 78,3 | 50,65 | 83,71 | 94,06 | 81,73 | 67,83 | 54,96 | 92,21 | 77,44 | |
| SENS | 72,18 | 96,52 | 68,6 | 74,35 | 79,76 | 91,45 | 89,36 | 43,17 | 81,06 | 89,44 | 78,59 | |
| ITR | 0,191 | 0,714 | 0,174 | 0,03 | 0,32 | 0,636 | 0,398 | 0,014 | 0,075 | 0,564 | 0,312 | |

Tablo 4.29. MAV ve ayırık dalgacık dönüşümü uygulanmış, 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 69,23 | 96,77 | 68,35 | 67,12 | 83,05 | 94,05 | 82,04 | 61,44 | 77,7 | 91,76 | 79,15 | kNN |
| SPEC | 82,14 | 97,25 | 88,36 | 73,17 | 84,64 | 94,47 | 79,27 | 75,72 | 77,48 | 93,06 | 84,56 | |
| SENS | 52,45 | 96,36 | 42,91 | 59,23 | 80,99 | 93,13 | 85,46 | 42,89 | 77,85 | 90,39 | 72,17 | |
| ITR | 0,11 | 0,794 | 0,099 | 0,086 | 0,344 | 0,675 | 0,321 | 0,038 | 0,234 | 0,589 | 0,329 | |

Tablo 4.29. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| ACC | 69,01 | 95,07 | 68,39 | 69,54 | 80,54 | 92,59 | 80,11 | 62,09 | 72,14 | 91,18 | 78,07 | DT |
| SPEC | 73,46 | 95 | 76,94 | 72,3 | 86,58 | 93,7 | 83,51 | 66,52 | 78,37 | 92,72 | 81,91 | |
| SENS | 62,19 | 95,21 | 57,57 | 66,26 | 71,48 | 91,02 | 76,32 | 56,48 | 63,7 | 88,84 | 72,91 | |
| ITR | 0,107 | 0,717 | 0,1 | 0,113 | 0,289 | 0,619 | 0,28 | 0,043 | 0,146 | 0,57 | 0,298 | |

Tablo 4.28. ve Tablo 4.29.'da görüldüğü üzere şu sonuçlar elde edilmiştir; en başarılı katılımcıda %95,23 (SVM) ve %96,77 (kNN), en başarısız katılımcıda %74,08 (LDA) ve %68,39 (DT), ortalama başarıda %78,23 (SVM) ve %79,15 (kNN).

Tablo 4.30. MAV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 79,14 | 97,05 | 75,27 | 72,03 | 88,29 | 94,29 | 86,02 | 70,06 | 74,07 | 96,01 | 83,22 | SVM |
| SPEC | 88,52 | 97,5 | 83,14 | 75,78 | 90,4 | 96,21 | 83,98 | 70,45 | 66,65 | 99,57 | 85,22 | |
| SENS | 67,08 | 96,54 | 64,95 | 66,52 | 85,14 | 91,42 | 88,23 | 69,65 | 84,13 | 91,11 | 80,48 | |
| ITR | 0,261 | 0,808 | 0,193 | 0,145 | 0,479 | 0,684 | 0,416 | 0,119 | 0,174 | 0,758 | 0,404 | |
| ACC | 76,08 | 96,25 | 76,2 | 72,06 | 88,03 | 94,26 | 87,16 | 71,06 | 72,07 | 94,02 | 82,72 | LDA |
| SPEC | 76,17 | 94 | 80,45 | 70,14 | 89,53 | 95,76 | 83,96 | 62,96 | 61,01 | 96,54 | 81,05 | |
| SENS | 76,11 | 98,55 | 70,19 | 74,12 | 85,64 | 91,87 | 90,88 | 81,66 | 87,14 | 90,49 | 84,66 | |
| ITR | 0,206 | 0,769 | 0,208 | 0,145 | 0,472 | 0,683 | 0,447 | 0,132 | 0,145 | 0,673 | 0,388 | |

Tablo 4.31. MAV ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 73,25 | 96,66 | 70,44 | 68,05 | 86,18 | 94,52 | 83,04 | 76,28 | 81,77 | 94,73 | 82,49 | kNN |
| SPEC | 85,33 | 96,67 | 81,4 | 74,91 | 86,7 | 97,46 | 81,33 | 78,14 | 82,25 | 94,78 | 85,9 | |
| SENS | 57,48 | 96,56 | 56,19 | 58,72 | 85,62 | 89,99 | 85,09 | 73,89 | 80,74 | 94,72 | 77,9 | |
| ITR | 0,162 | 0,789 | 0,124 | 0,096 | 0,42 | 0,694 | 0,343 | 0,21 | 0,315 | 0,702 | 0,386 | |
| ACC | 72,78 | 95,22 | 70,26 | 70,09 | 86,3 | 95,03 | 83,22 | 76,17 | 77,48 | 91,71 | 81,83 | DT |
| SPEC | 74,96 | 96 | 75,06 | 72,64 | 89,11 | 96,63 | 81,05 | 81,7 | 81,79 | 92,23 | 84,12 | |
| SENS | 69,51 | 94,59 | 63,73 | 66,95 | 81,8 | 92,76 | 85,67 | 68,8 | 71,53 | 91,27 | 78,66 | |
| ITR | 0,155 | 0,723 | 0,122 | 0,12 | 0,424 | 0,715 | 0,347 | 0,208 | 0,23 | 0,588 | 0,363 | |

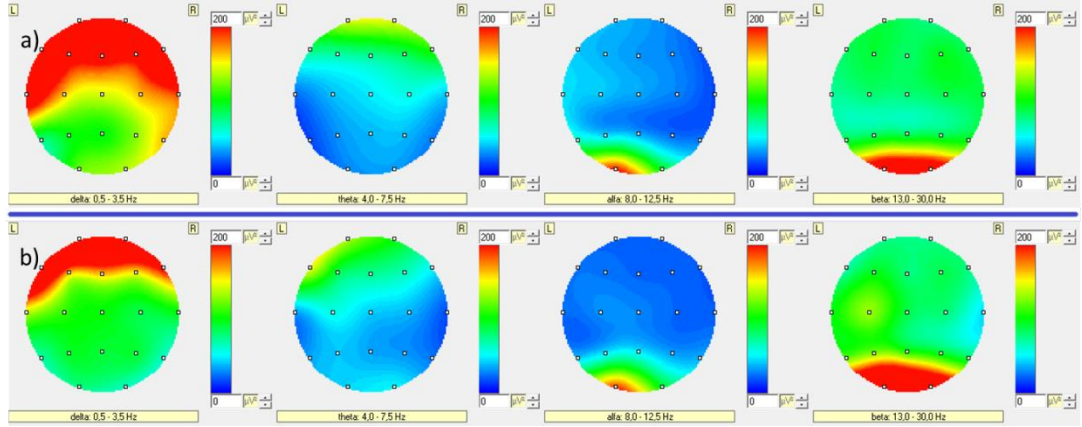
Tablo 4.30. ve Tablo 4.31.'de ilgili makine öğrenmesi sonuç değerleri sırasıyla şunlardır: Katılımcı-2 için %97,05 (SVM) ve %96,66 (kNN), katılımcı-3 için %76,2

(LDA) ve %70,44 (kNN), ortalama başarı için %83,22 (SVM) ve %82,49 (kNN) değerleri hesaplanmıştır. Ham veri seti sonuçlarına (Tablo 4.23.) kıyasla, 11 kanal veri seti sonuçları (Tablo 4.30) en başarılı katılımcıda 0,02 puan doğruluk oranı artışı sağlamıştır.

Tablo 4.32. MAV ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|--------------|-------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 79,21 | 97,27 | 74,20 | 74,09 | 91,07 | 96,04 | 84,34 | 72,06 | 76,04 | 96,04 | 84,04 | SVM |
| SPEC | 87,19 | 98,00 | 82,63 | 79,67 | 93,71 | 96,65 | 81,69 | 71,42 | 70,14 | 97,84 | 85,90 | |
| SENS | 68,56 | 96,53 | 63,59 | 66,50 | 87,08 | 95,27 | 87,52 | 72,81 | 84,17 | 93,66 | 81,57 | |
| ITR | 0,263 | 0,819 | 0,176 | 0,175 | 0,566 | 0,759 | 0,374 | 0,145 | 0,206 | 0,760 | 0,424 | |
| ACC | 76,08 | 97,26 | 75,31 | 74,04 | 91,07 | 95,26 | 85,64 | 71,02 | 75,23 | 96,21 | 83,71 | LDA |
| SPEC | 77,13 | 97,00 | 79,96 | 72,19 | 92,86 | 98,33 | 83,27 | 65,55 | 67,14 | 97,83 | 83,13 | |
| SENS | 75,13 | 97,59 | 69,38 | 76,69 | 89,19 | 90,73 | 88,54 | 77,87 | 86,09 | 93,89 | 84,51 | |
| ITR | 0,206 | 0,819 | 0,194 | 0,174 | 0,566 | 0,725 | 0,406 | 0,131 | 0,192 | 0,767 | 0,418 | |
| ACC | 70,27 | 96,02 | 67,20 | 68,32 | 87,01 | 94,30 | 83,02 | 73,07 | 80,98 | 92,50 | 81,27 | kNN |
| SPEC | 85,24 | 95,50 | 90,04 | 74,37 | 89,86 | 96,21 | 80,05 | 72,45 | 78,79 | 96,03 | 85,85 | |
| SENS | 50,44 | 96,55 | 37,78 | 60,19 | 83,22 | 91,35 | 86,27 | 73,76 | 84,05 | 87,58 | 75,12 | |
| ITR | 0,122 | 0,759 | 0,087 | 0,099 | 0,443 | 0,685 | 0,343 | 0,160 | 0,298 | 0,616 | 0,361 | |
| ACC | 71,17 | 94,27 | 70,27 | 71,09 | 88,06 | 93,21 | 83,01 | 75,66 | 77,7 | 91,04 | 81,55 | DT |
| SPEC | 76,17 | 94,5 | 74,15 | 75,29 | 91,23 | 93,28 | 84,48 | 77,65 | 79,62 | 91,78 | 83,82 | |
| SENS | 64,24 | 93,95 | 65,26 | 64,82 | 83,41 | 93,32 | 81,48 | 73,12 | 75,41 | 90,08 | 78,51 | |
| ITR | 0,133 | 0,684 | 0,122 | 0,132 | 0,472 | 0,642 | 0,342 | 0,199 | 0,234 | 0,565 | 0,353 | |

Tablo 4.32.'de veri seti üzerine DWT yöntemi uygulanmış ve glossokinetik potansiyel sinyalleri üzerinden 1-D hareket için sağ-sol sınıflandırmasına ait performans değerleri 10 katılımcı için elde edilmiştir. En başarılı katılımcı için %97,27 (SVM), en başarısız katılımcı için %75,31 (LDA) ve ortalama başarı için %84,04 (SVM) elde edilmiştir. Ham veri seti sonuçlarına kıyasla DWT yönteminin katılımcı-2'de 0,24 doğruluk oranı artışı sağladığı görülmektedir.

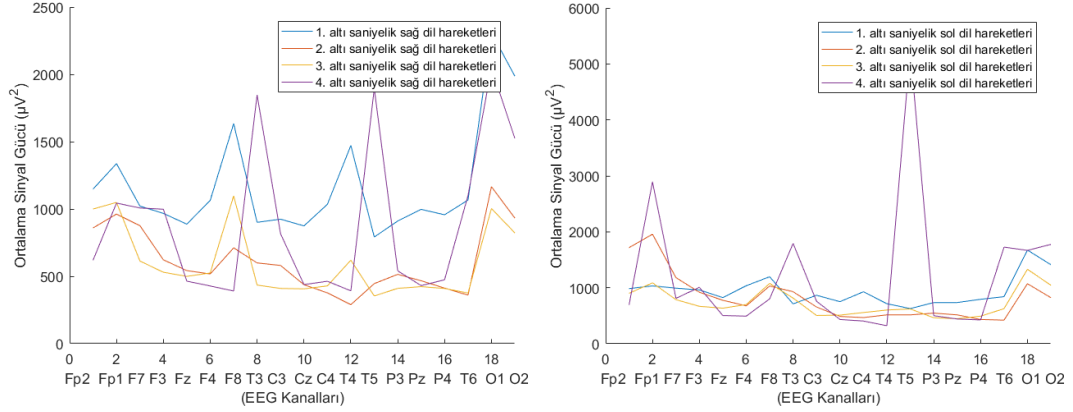


Şekil 4.28. En başarısız katılımcıya (katılımcı-3) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.28.'de görüldüğü üzere sağ yarımkürede delta frekans bandı içinde frontal (Fp1, Fp2), arka-frontal (F7, F3, Fz, F4, F8), merkez (C3, Cz, C4) ve temporal (T3, T4, T6) bölgelerde yüksek sinyal güç yoğunluğu görülmektedir. Sol yarımkürede oluşan yüksek sinyal güç yoğunluğu sağ yarımküreye göre daha az bölgede (frontal, arka-frontal ve T3) oluştuğu gözlenmiştir. Bununla beraber delta frekansında sağ ve sol yarımkürenin geri kalan bölgelerinde orta düzeyde sinyal güç yoğunluğu görülebilmektedir. Teta frekans bandında sağ ve sol yarımkürede frontal ve arka-frontal bölge üzerinde de orta düzeyde sinyal güç yoğunluğu elde edilmiştir. Buna ek en başarısız katılımcıda, zihinsel efor, düşünme ve odaklanma gerektiren işlerde ortaya çıkan beta frekans dalgaları sağ ve sol yarımkürede orta seviyede sinyal güç yoğunluğu oluşturduğu gözlenmiştir. Yine oksipital bölge (O1 ve O2) üzerinde yüksek sinyal güç yoğunluğu gözlenmiştir.

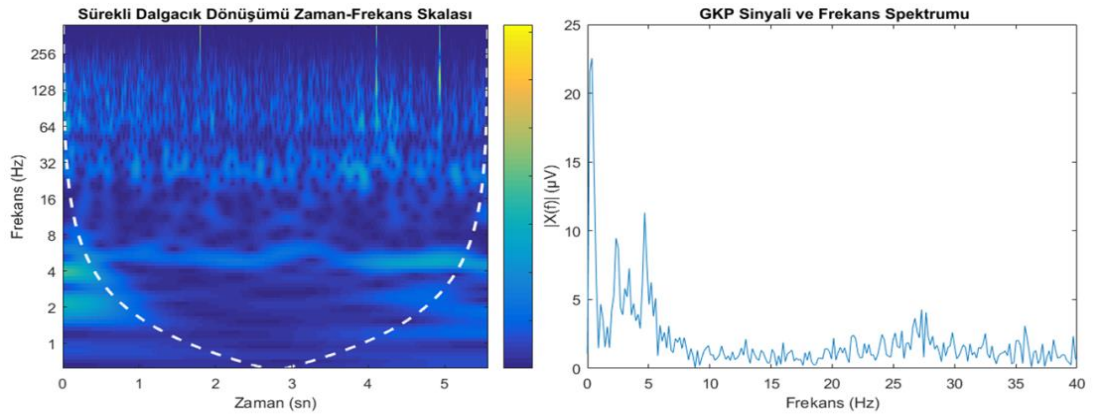
Şekil 4.2.'de en başarılı katılımcıya (katılımcı-2) ait beyin haritalama sonucu gösterilmiştir. En başarılı ve en başarısız katılımcıya ait beyin haritalama sonuçlarına ait farklar şöyledir: En başarılı katılımcıda delta frekansında yüksek sinyal güç yoğunlukları sağ ve sol yarımkürelerde simetrik olarak oluşmuştur. En başarısız katılımcıda (katılımcı-3) bu durum söz konusu değildir. Bununla beraber en başarılı katılımcıda, delta frekans bandı içinde, ilgili hareket yönünü gösteren temporal bölgelerde (T3, T4, T5, T6) sinyal güç yoğunlukları sağ ve sol yarımkürelerde net olarak oluştuğu gözlenmektedir. En başarısız katılımcıda bu durum net olarak ortaya

çıkamamıştır. Buna ek olarak, en başarısız katılımcı için beta frekans bandında orta düzeyde oluşan sinyal güç yoğunluğu en başarılı katılımcıda gözlenmemiştir.




Şekil 4.29. En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaslari ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde deęişimini gösteren grafiksel gösterim

En başarısız katılımcıya ait ortalama sinyal güç deęişimleri Şekil 4.29.'da görülmektedir. Beyin haritalama sonuçlarında da görüldüğü üzere sağ yarımkürede deęişim gösteren bölgeler şunlardır; frontal ($500 \mu V^2$ - $1500 \mu V^2$), arka-frontal ($500 \mu V^2$ - $1700 \mu V^2$), merkez ($500 \mu V^2$ - $1000 \mu V^2$), temporal ($500 \mu V^2$ - $2000 \mu V^2$), oksipital ($1000 \mu V^2$ - $2500 \mu V^2$). Sol yarımküredeki ortalama sinyal güç deęişimleri ise şöyledir; frontal ($1000 \mu V^2$ - $3000 \mu V^2$), arka-frontal ($\geq 1000 \mu V^2$), temporal ($\geq 1000 \mu V^2$), oksipital ($1000 \mu V^2$ - $2000 \mu V^2$). Bununla beraber, dördüncü altı saniyelik sağ ve sol dil hareketinin dięer hareketlere göre EEG kanalları üzerinde farklı bir örüntü oluşturduğu da görülmektedir.



Şekil 4.30. En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.30.'da en başarısız katılımcıya ait GKP sinyalinin zaman-frekans skalası ve frekans spektrumu gösterimi mevcuttur. Görüldüğü üzere GKP sinyali 1-2 Hz arasında $\geq 20 \mu\text{V}$ genlikte oluşmuş iken, 3-5 Hz arasında $5 \mu\text{V}$ - $10 \mu\text{V}$ genliğe sahiptir. Bununla beraber 5-10 Hz arasında $\leq 5 \mu\text{V}$ genlik değişimi gözlenmektedir. Zaman-frekans skalası üzerinde 2 Hz ve 4 Hz civarında genlik değişimi görülebilmektedir. En başarılı katılımcıya ait zaman-frekans skalası ve frekans spektrumu grafikleri ise Şekil 4.6.'da mevcuttur.



Şekil 4.31. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.31.'de en başarılı ve en başarısız katılımcıya ait spektral güç yoğunluklarını gösteren periodogram grafikleri verilmiştir. Görüldüğü üzere katılımcı-2 için 3-4 Hz arasında $\geq 500 \mu\text{V}^2/\text{Hz}$ spektral güç yoğunluğu oluşmakta iken, katılımcı-3 için 1-2 Hz arasında $\geq 100 \mu\text{V}^2/\text{Hz}$ en yüksek spektral güç yoğunluğuna ulaşılmıştır. Buna ek olarak, katılımcı-3 için 5 Hz'de $\geq 80 \mu\text{V}^2/\text{Hz}$ ve 25-30 Hz civarında (beta frekans bandı) $\leq 20 \mu\text{V}^2/\text{Hz}$ değerinde spektral güç yoğunluğu gözlenmiştir.

4.1.6. Maksimum tepe değeri sonuçları

Maksimum tepe değeri (MPV) metodu zaman alanı özellik çıkarma metotlarından biridir. Bu metotla ilgili tez çalışması içinde ham veri seti sonuçları, temel bileşen analizi veri seti sonuçları, 7 kanal-frontal veri seti sonuçları, 11 kanal-frontal ve temporal veri seti sonuçları ve ayrık dalgacık dönüşümü veri seti sonuçları


verilmektedir. İlgili sınıflandırma algoritmalarına ait elde edilen sonuç değerleri şunlardır:

Tablo 4.33. MPV ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 79 | 97,25 | 77,05 | 80,06 | 88,32 | 94,15 | 86,19 | 79,70 | 79,48 | 96,07 | 85,73 | SVM |
| SPEC | 84,6 | 97,5 | 80,45 | 80,56 | 91,25 | 96,63 | 84,52 | 78,52 | 78,32 | 97,39 | 86,97 | |
| SENS | 71,55 | 97,04 | 72,57 | 79,34 | 84,40 | 90,68 | 88,38 | 81,39 | 81,36 | 94,42 | 84,11 | |
| ITR | 0,259 | 0,819 | 0,223 | 0,279 | 0,480 | 0,678 | 0,421 | 0,272 | 0,268 | 0,761 | 0,446 | |
| ACC | 78,18 | 96,31 | 77,16 | 78,01 | 88,12 | 94,00 | 86,24 | 79,01 | 77,04 | 95,02 | 84,91 | LDA |
| SPEC | 77,57 | 96,00 | 77,31 | 72,70 | 87,84 | 95,34 | 84,98 | 78,08 | 70,62 | 96,54 | 83,70 | |
| SENS | 79,29 | 96,62 | 76,96 | 85,47 | 88,95 | 91,58 | 87,53 | 80,58 | 85,75 | 92,95 | 86,57 | |
| ITR | 0,243 | 0,772 | 0,225 | 0,240 | 0,474 | 0,673 | 0,422 | 0,259 | 0,223 | 0,714 | 0,424 | |
| ACC | 72,23 | 95,24 | 75,48 | 69,10 | 84,08 | 94,02 | 83,05 | 76,43 | 78,86 | 92,18 | 82,07 | kNN |
| SPEC | 85,06 | 94,59 | 79,49 | 74,19 | 84,97 | 95,76 | 80,30 | 79,52 | 76,20 | 96,43 | 84,65 | |
| SENS | 55,34 | 95,85 | 69,71 | 62,31 | 82,23 | 91,57 | 86,29 | 72,57 | 82,67 | 86,48 | 78,50 | |
| ITR | 0,148 | 0,724 | 0,196 | 0,108 | 0,368 | 0,673 | 0,344 | 0,212 | 0,256 | 0,604 | 0,363 | |
| ACC | 78,27 | 96,26 | 74,69 | 77,59 | 87,73 | 94,83 | 86,01 | 82,54 | 80,62 | 94,22 | 85,28 | MLNN |
| SPEC | 84,51 | 96,50 | 82,63 | 77,86 | 87,84 | 96,23 | 86,43 | 83,52 | 79,64 | 94,78 | 86,99 | |
| SENS | 68,68 | 95,97 | 63,90 | 75,39 | 87,46 | 92,04 | 85,12 | 79,62 | 81,29 | 93,46 | 82,29 | |
| ITR | 0,245 | 0,770 | 0,184 | 0,232 | 0,463 | 0,706 | 0,416 | 0,332 | 0,291 | 0,681 | 0,432 | |
| ACC | 74,41 | 95,27 | 76,68 | 73,70 | 85,04 | 94,01 | 83,62 | 82,27 | 81,22 | 94,47 | 84,07 | PNN |
| SPEC | 87,69 | 94,00 | 87,96 | 72,34 | 84,47 | 97,07 | 83,48 | 80,75 | 81,78 | 96,09 | 86,56 | |
| SENS | 57,20 | 96,59 | 62,23 | 75,46 | 85,92 | 89,55 | 83,71 | 84,34 | 80,39 | 92,49 | 80,79 | |
| ITR | 0,179 | 0,725 | 0,216 | 0,169 | 0,391 | 0,673 | 0,357 | 0,326 | 0,303 | 0,692 | 0,403 | |
| ACC | 74,19 | 94,24 | 75,23 | 71,67 | 85,84 | 92,20 | 81,84 | 79,63 | 78,02 | 91,22 | 82,41 | DT |
| SPEC | 77,83 | 94,00 | 78,22 | 77,05 | 88,30 | 92,07 | 81,69 | 83,42 | 77,93 | 91,39 | 84,19 | |
| SENS | 69,14 | 94,41 | 71,29 | 64,41 | 82,77 | 92,50 | 81,89 | 74,76 | 77,95 | 90,99 | 80,01 | |
| ITR | 0,176 | 0,682 | 0,192 | 0,140 | 0,412 | 0,605 | 0,316 | 0,271 | 0,240 | 0,571 | 0,361 | |

Tablo 4.33.'de maksimum tepe değerine ait ham veri seti sonuçları görülmektedir. En başarılı katılımcı (katılımcı-2) için elde edilen en yüksek doğruluk oranı değeri %97,25 (SVM) olurken, en başarısız katılımcı (katılımcı-4) için bulunan en yüksek ve en düşük doğruluk oranı değerleri sırasıyla %80,06 (SVM) ve %69,10 (kNN) olarak elde edilmiştir (Şekil 4.32.). 10 katılımcıya ait ortalama başarı için hesaplanan doğruluk oranı değeri %85,73 (SVM) olarak bulunmuştur. Ortalama başarıda MLNN (%85,28)'in, SVM'den sonra en iyi performansı gösteren algoritma olduğu

görülmektedir. MPV metodu ham veri seti sonuç değerlerine göre RMS metoduna kıyasla en başarılı ve en başarısız katılımcıya ait en yüksek doğruluk oranı değerlerinden sırasıyla 0,24 puan ve 2,06 puan daha iyi performans göstermiştir. Bununla beraber ortalama başarıda 0,66 puan daha az doğruluk oranı değeri elde etmiştir. MPV metodunun STD, VAR, MV, MAV metotlarına ait ham veri seti sınıflandırma performans değerlerinden en başarılı katılımcı, en başarısız katılımcı ve ortalama başarıda daha yüksek değerler elde ettiği görülmektedir. Bu duruma uymayan tek sonuç değeri MV metodu içinde en başarısız katılımcıya ait %88,94 doğruluk oranı değeridir.



Şekil 4.32. Maksimum tepe değeri ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.34. MPV ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 78,22 | 96,25 | 78,40 | 77,35 | 87,01 | 94,06 | 87,05 | 79,05 | 73,11 | 95,04 | 84,55 | SVM |
| SPEC | 84,55 | 95,00 | 82,55 | 76,65 | 88,73 | 96,21 | 84,09 | 79,45 | 72,32 | 96,96 | 85,65 | |
| SENS | 70,07 | 97,49 | 73,29 | 78,61 | 84,50 | 90,85 | 90,41 | 78,56 | 73,98 | 92,45 | 83,02 | |
| ITR | 0,244 | 0,769 | 0,247 | 0,228 | 0,443 | 0,675 | 0,444 | 0,259 | 0,160 | 0,715 | 0,418 | |
| ACC | 77,40 | 96,27 | 77,41 | 74,10 | 86,04 | 94,03 | 87,25 | 79,01 | 73,23 | 95,03 | 83,98 | LDA |
| SPEC | 77,19 | 94,50 | 76,92 | 70,54 | 84,93 | 94,49 | 84,50 | 77,19 | 62,32 | 95,72 | 81,83 | |
| SENS | 78,09 | 98,02 | 78,17 | 78,15 | 87,81 | 93,35 | 90,28 | 81,19 | 88,03 | 94,04 | 86,71 | |
| ITR | 0,229 | 0,770 | 0,229 | 0,175 | 0,417 | 0,674 | 0,450 | 0,259 | 0,162 | 0,715 | 0,408 | |
| ACC | 74,01 | 94,16 | 74,09 | 72,20 | 85,12 | 93,30 | 82,35 | 79,16 | 83,23 | 91,02 | 82,87 | KNN |
| SPEC | 79,16 | 92,07 | 85,14 | 72,30 | 86,05 | 97,80 | 83,00 | 81,21 | 82,30 | 96,24 | 85,53 | |
| SENS | 67,57 | 96,27 | 59,66 | 72,20 | 83,92 | 86,60 | 81,63 | 76,73 | 84,39 | 83,74 | 79,27 | |
| ITR | 0,173 | 0,679 | 0,175 | 0,147 | 0,393 | 0,646 | 0,328 | 0,262 | 0,348 | 0,564 | 0,371 | |

Tablo 4.34. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|------|
| ACC | 76,30 | 95,14 | 73,48 | 74,05 | 85,09 | 94,25 | 84,41 | 81,94 | 76,10 | 93,21 | 83,40 | |
| SPEC | 81,58 | 92,50 | 74,31 | 77,05 | 87,90 | 94,93 | 85,43 | 83,95 | 73,57 | 95,24 | 84,65 | MLNN |
| SENS | 69,84 | 94,97 | 71,75 | 67,74 | 80,60 | 91,97 | 82,91 | 77,29 | 78,50 | 90,19 | 80,58 | |
| ITR | 0,210 | 0,720 | 0,166 | 0,174 | 0,393 | 0,683 | 0,376 | 0,319 | 0,207 | 0,642 | 0,389 | |
| ACC | 74,06 | 95,25 | 76,08 | 72,08 | 85,10 | 93,60 | 84,78 | 82,06 | 79,31 | 94,06 | 83,64 | |
| SPEC | 86,36 | 94,00 | 89,35 | 76,23 | 88,26 | 96,61 | 84,03 | 81,17 | 78,80 | 95,67 | 87,05 | PNN |
| SENS | 58,06 | 96,46 | 58,93 | 66,98 | 80,56 | 89,39 | 85,67 | 82,87 | 80,12 | 91,63 | 79,07 | |
| ITR | 0,174 | 0,724 | 0,206 | 0,146 | 0,393 | 0,657 | 0,385 | 0,321 | 0,264 | 0,675 | 0,395 | |
| ACC | 73,20 | 91,01 | 74,75 | 72,28 | 84,65 | 91,06 | 81,05 | 79,66 | 75,60 | 90,48 | 81,37 | |
| SPEC | 78,02 | 92,50 | 76,05 | 78,41 | 87,48 | 92,41 | 80,74 | 81,72 | 82,23 | 90,89 | 84,04 | DT |
| SENS | 66,80 | 89,60 | 72,46 | 63,79 | 80,21 | 88,99 | 81,22 | 76,84 | 66,56 | 89,64 | 77,61 | |
| ITR | 0,161 | 0,564 | 0,185 | 0,148 | 0,382 | 0,566 | 0,299 | 0,271 | 0,198 | 0,546 | 0,332 | |

Tablo 4.34.'de MPV metodu ile özelliği çıkarılan veri seti üzerinde PCA boyut azaltma yöntemi uygulanmıştır. En başarılı ve en başarısız katılımcılar için en yüksek doğruluk oranı değerleri sırasıyla %96,27 (LDA) ve %77,35 (SVM) olarak hesaplanmıştır. Bununla beraber, SVM algoritması ortalama başarıda en yüksek doğruluk oranı değerini %84,55 olarak sağlamıştır. Ham veri seti sonuçlarına (Tablo 4.33.) kıyasla, katılımcı-2 için doğruluk oranı değeri %1,007 oranında azalmıştır. Benzer şekilde katılımcı-4' de doğruluk oranı değeri azalma oranı %3,38 iken ortalama başarıda %1,37 olarak elde edilmiştir.

Tablo 4.35. MPV ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 75,19 | 95,04 | 76,16 | 64,08 | 81,18 | 93,01 | 85,69 | 64,07 | 69,01 | 90,35 | 79,38 | |
| SPEC | 80,65 | 94,50 | 85,85 | 85,29 | 87,45 | 94,13 | 83,16 | 92,41 | 63,71 | 91,78 | 85,89 | SVM |
| SENS | 67,61 | 95,52 | 63,41 | 35,49 | 71,80 | 91,31 | 88,86 | 27,81 | 76,26 | 88,51 | 70,66 | |
| ITR | 0,192 | 0,715 | 0,208 | 0,058 | 0,302 | 0,635 | 0,408 | 0,058 | 0,107 | 0,542 | 0,32 | |
| ACC | 74,22 | 95,05 | 75,78 | 62,05 | 79,19 | 93,07 | 85,27 | 62,29 | 66,22 | 91,01 | 78,41 | |
| SPEC | 75,38 | 95,00 | 76,88 | 60,27 | 78,22 | 92,84 | 84,48 | 71,84 | 55,89 | 91,30 | 78,21 | LDA |
| SENS | 73,03 | 95,13 | 73,92 | 64,80 | 81,07 | 93,67 | 86,17 | 50,03 | 80,32 | 90,75 | 78,89 | |
| ITR | 0,177 | 0,716 | 0,201 | 0,042 | 0,262 | 0,637 | 0,397 | 0,044 | 0,077 | 0,564 | 0,31 | |

Tablo 4.36. MPV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 78,08 | 97,01 | 77,03 | 71,06 | 88,52 | 93,06 | 86,13 | 79,02 | 73,03 | 95,07 | 83,80 | SVM |
| SPEC | 85,53 | 98,00 | 81,88 | 80,13 | 91,25 | 94,47 | 83,12 | 76,28 | 67,54 | 96,11 | 85,43 | |
| SENS | 68,22 | 95,99 | 70,79 | 57,88 | 84,37 | 91,50 | 89,41 | 82,31 | 80,14 | 93,74 | 81,44 | |
| ITR | 0,241 | 0,806 | 0,223 | 0,132 | 0,486 | 0,636 | 0,419 | 0,259 | 0,159 | 0,716 | 0,408 | |
| ACC | 79,49 | 95,74 | 75,35 | 70,12 | 85,09 | 93,23 | 86,31 | 78,01 | 71,00 | 95,03 | 82,94 | LDA |
| SPEC | 79,33 | 95,50 | 74,78 | 66,21 | 83,68 | 94,57 | 83,59 | 76,44 | 61,47 | 95,67 | 81,12 | |
| SENS | 79,54 | 95,99 | 76,08 | 75,58 | 86,97 | 91,31 | 89,56 | 80,28 | 83,75 | 94,14 | 85,32 | |
| ITR | 0,268 | 0,746 | 0,194 | 0,120 | 0,392 | 0,643 | 0,424 | 0,240 | 0,131 | 0,715 | 0,387 | |

Tablo 4.37. MPV ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

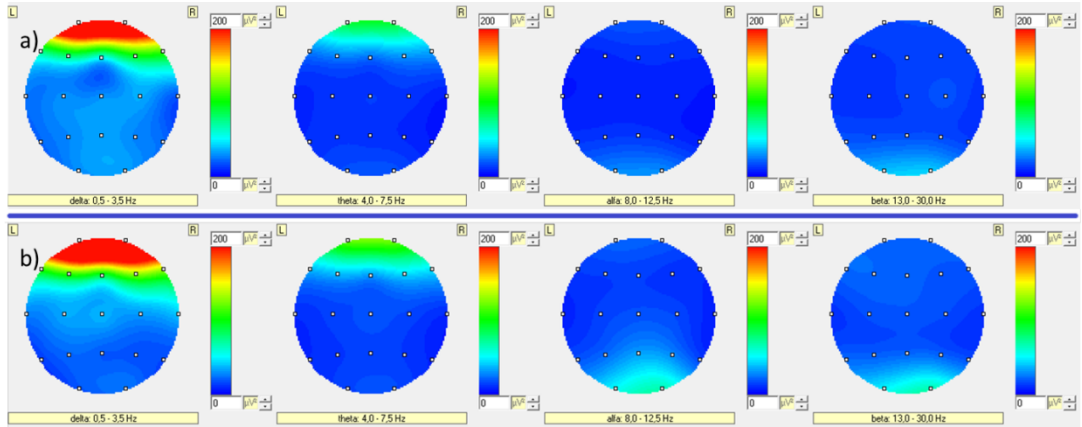
| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 81,19 | 98,02 | 78,3 | 70,12 | 92,01 | 95,00 | 88,31 | 72,27 | 75,30 | 96,44 | 84,70 | SVM |
| SPEC | 86,4 | 98,5 | 83,08 | 77,05 | 93,73 | 96,20 | 86,39 | 72,25 | 70,60 | 97,41 | 86,16 | |
| SENS | 74,01 | 97,57 | 72,33 | 60,75 | 89,73 | 93,21 | 90,64 | 72,21 | 81,76 | 95,14 | 82,74 | |
| ITR | 0,303 | 0,860 | 0,245 | 0,120 | 0,598 | 0,714 | 0,480 | 0,148 | 0,194 | 0,778 | 0,444 | |

Tablo 4.35. ve Tablo 4.36.'da 7 ve 11 kanal veri setlerine ait sonuç değerleri görülmektedir. En başarılı katılımcı için doğruluk oranı değerleri sırasıyla %95,05 (LDA) ve %97,01 (SVM) elde edilmiştir. En başarısız katılımcı için doğruluk oranı değerleri sırasıyla %64,08 (SVM) ve %71,06 (SVM) olarak hesaplanmıştır. Ortalama başarı için ise doğruluk oranı değerleri sırasıyla %79,38 (SVM) ve %83,80 (SVM) olarak bulunmuştur. Görüldüğü üzere ham veri setine kıyasla, 11 kanal veri seti sonuçlarında (Tablo 4.36.), katılımcı-2 için 0,24 puan, katılımcı-4 için 9 puan ve ortalama başarı için 1,93 puan daha düşük doğruluk oranı sonucu bulunmuştur. Bununla beraber Tablo 4.37.'de gösterilen sonuçlar için 11 kanal veri setine DWT yöntemi uygulanmış ve ilgili sınıflandırma sonuç değerleri elde edilmiştir. Buna göre, katılımcı-2 ve ortalama başarı için doğruluk oranı değerinde sırasıyla 1,01 puan ve 0,9 puan artış sağlanırken, katılımcı-4 için 0,94 puan azalma elde edilmiştir.

Tablo 4.38. MPV ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 81,12 | 98,01 | 79,52 | 76,32 | 93,02 | 96,07 | 89,05 | 73,23 | 79,19 | 97,02 | 86,25 | SVM |
| SPEC | 85,93 | 98,00 | 83,95 | 78,37 | 94,58 | 97,07 | 85,43 | 66,03 | 77,01 | 98,26 | 86,46 | |
| SENS | 74,82 | 98,00 | 73,80 | 73,62 | 89,84 | 94,62 | 93,00 | 82,56 | 82,03 | 95,34 | 85,76 | |
| ITR | 0,301 | 0,859 | 0,269 | 0,210 | 0,635 | 0,761 | 0,502 | 0,162 | 0,262 | 0,807 | 0,477 | |
| ACC | 80,04 | 98,27 | 80,92 | 76,20 | 92,16 | 96,34 | 89,00 | 73,01 | 71,02 | 97,02 | 85,40 | LDA |
| SPEC | 81,48 | 97,50 | 84,51 | 72,30 | 92,08 | 97,05 | 86,49 | 65,69 | 62,34 | 99,13 | 83,86 | |
| SENS | 78,09 | 99,05 | 76,43 | 81,45 | 92,50 | 95,43 | 91,94 | 82,48 | 83,04 | 94,22 | 87,46 | |
| ITR | 0,279 | 0,874 | 0,297 | 0,208 | 0,604 | 0,773 | 0,500 | 0,159 | 0,131 | 0,807 | 0,463 | |

Tablo 4.38.'de 19 kanallı özellik vektörüne sahip veri seti üzerinde delta ve teta frekansları bantları çıkarıldıktan sonra MPV özellik çıkarma metodu uygulanmış ve sınıflandırma sonuçları elde edilmiştir. Ham veri setine kıyasla (Tablo 4.33.), en başarılı katılımcıda ve ortalama başarıda en yüksek sınıflandırma sonuçları için %1,04 ve %0,60 doğruluk oranı artışı sağlanmıştır. En başarısız katılımcıda ise %4,67 azalma gözlenmiştir.

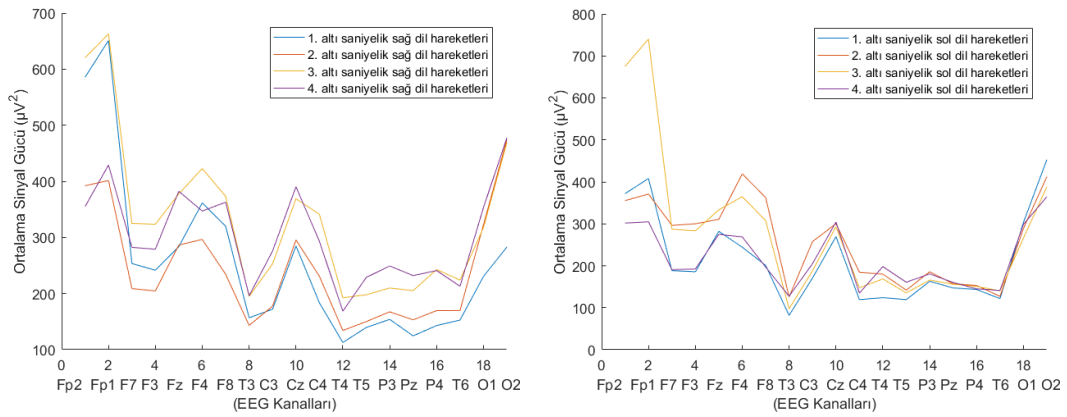


Şekil 4.33. En başarısız katılımcıya (katılımcı-4) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.33.'de en başarısız katılımcıya ait beyin haritalama sonucu gösterilmiştir. Görüldüğü üzere delta frekansında, sağ ve sol yarımkürede, frontal (Fp2, Fp1) bölge üzerinde yüksek sinyal güç yoğunluğu gözlenirken, arka-frontal (F7, F3, Fz, F4, F8) bölge üzerinde orta düzeyde sinyal güç yoğunluğu gözlenmektedir. Bununla beraber

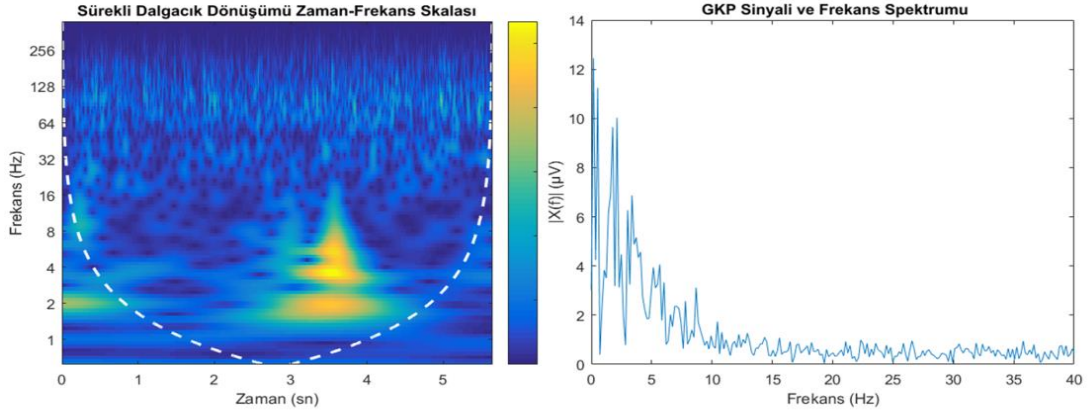
teta frekans bandı içinde frontal bölge üzerinde orta düzeyde sinyal güç yoğunluğu oluştuğu görülmektedir.

Şekil 4.2.'de en başarılı katılımcıya (katılımcı-2) ait beyin haritalama sonucu ve ilgili değerlendirmeler belirtilmiştir. Katılımcı-2 ve katılımcı-4 arasındaki farklar şöyledir: Katılımcı-2'de yüksek sinyal güç yoğunluğu sağ ve sol yarımküre üzerinde delta frekansında sağ veya sol yönü gösterecek şekilde temporal bölgelerde net olarak oluşmuştur. Aynı durumun katılımcı-4 için oluşmadığı görülmektedir.




Şekil 4.34. En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaları ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde değişimini gösteren grafiksel gösterim

Şekil 4.34.'de en başarısız katılımcıya ait EEG kanalları üzerindeki ortalama sinyal gücü değişimi görülmektedir. Beyin haritalama sonuçlarında da görüldüğü üzere (Şekil 4.33.), sağ dil hareketleri için; Fp2-Fp1 ($400 \mu V^2$ - $700 \mu V^2$) frontal bölge üzerinde, F4-F8 ($300 \mu V^2$ - $400 \mu V^2$) arka-frontal bölge üzerinde, Cz ($\leq 400 \mu V^2$) merkez bölge üzerinde sırasıyla yüksek ve orta düzeyde ortalama sinyal gücü değişimleri oluşmaktadır. Sol dil hareketleri için; Fp2-Fp1 ($300 \mu V^2$ - $700 \mu V^2$), F4-F8 ($200 \mu V^2$ - $400 \mu V^2$) ve Cz ($\leq 300 \mu V^2$) bölgeler üzerinde yüksek ve orta düzeyde ortalama sinyal gücü değişimleri görülmektedir. Bununla beraber, ortalama sinyal güç değişimlerinin EEG kanalları üzerinde simetrik bir form oluşturduğu gözlenmektedir. En başarılı katılımcıya (katılımcı-2) ait ortalama sinyal güç değişimi Şekil 4.4.'de mevcuttur.



Şekil 4.35. En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.35.'de en başarısız katılımcıya (katılımcı-4) ait frekans spektrumunda gözlemlendiği üzere 1-4 Hz arasında $4 \mu\text{V}$ - $12 \mu\text{V}$ arasında sinyal genliği oluşurken, 4-10 Hz arasında $\leq 4 \mu\text{V}$ genlik oluşmaktadır. Bununla beraber zaman-frekans skalasında görüldüğü gibi, üçüncü ve dördüncü saniyeler arasında frekans, delta ve teta bandından alfa ve beta bandına kaymıştır. Bu durum, katılımcının ritmik dil hareketleri ile beraber zihinsel düşünceler oluşturmaya başladığını da göstermektedir [87]. Şekil 4.6.'da en başarılı katılımcıya (katılımcı-2) ait zaman-frekans skalasında görüldüğü üzere 2-4 Hz arasında, altı saniye boyunca frekans kayması oluşmamıştır. Böylece katılımcı-2 ve katılımcı-4 arasındaki performans farkının yalnızca temporal bölge üzerinde oluşan sinyal güç yoğunluğundan kaynaklanmadığı söylenebilir. Bu sonucun oluşmasında katılımcı-2 için deneysel düzen esnasında herhangi bir zihinsel düşünceden uzak durulması da gösterilebilir [9].



Şekil 4.36. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

Şekil 4.36.'da her iki katılımcıya ait spektral güç yoğunluğu grafikleri görülmektedir. Görüldüğü üzere katılımcı-4 için 1-3 Hz arasında $\geq 70 \mu V^2/Hz$ değerinde en yüksek spektral güç yoğunluğuna ulaşılmıştır. Bununla beraber 4-10 Hz arasında $\leq 30 \mu V^2/Hz$ değerinde spektral güç yoğunluğu görülmektedir. Spektral güç yoğunlukları da frekans spektrumunda olduğu gibi en başarısız katılımcı için delta ve teta bandı içinde dağılmış bir oluşum gösterirken, en başarılı katılımcı için delta bandında, daha düşük ve dar frekans aralığında elde edilmiştir.

4.1.7. Şekil faktörü sonuçları

Özellik çıkarma metotlarından birisi olan şekil faktörü (SF), tez çalışması içinde kullanılmış ve makine öğrenmesi algoritmalarına ait sınıflandırma sonuç değerleri hesaplanmıştır. İlgili sonuç değerleri şöyledir:

Tablo 4.39. SF ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|------|
| ACC | 80,03 | 97,02 | 74,10 | 80,02 | 90,59 | 94,64 | 86,16 | 78,15 | 75,33 | 95,03 | 85,11 | SVM |
| SPEC | 86,78 | 97,50 | 82,23 | 82,23 | 90,78 | 96,63 | 85,93 | 77,59 | 75,80 | 95,69 | 87,12 | |
| SENS | 70,67 | 96,59 | 63,32 | 76,97 | 90,15 | 91,54 | 86,47 | 78,81 | 74,85 | 94,06 | 82,34 | |
| ITR | 0,279 | 0,806 | 0,175 | 0,279 | 0,550 | 0,699 | 0,420 | 0,243 | 0,194 | 0,715 | 0,436 | |
| ACC | 80,02 | 97,01 | 74,04 | 79,12 | 89,34 | 94,04 | 85,16 | 77,52 | 75,46 | 94,01 | 84,57 | LDA |
| SPEC | 81,07 | 96,50 | 76,58 | 77,03 | 87,88 | 95,34 | 83,07 | 74,53 | 71,01 | 96,09 | 83,91 | |
| SENS | 78,80 | 97,52 | 70,76 | 82,03 | 91,61 | 92,26 | 87,44 | 81,24 | 81,46 | 91,16 | 85,43 | |
| ITR | 0,278 | 0,806 | 0,174 | 0,261 | 0,511 | 0,674 | 0,394 | 0,231 | 0,196 | 0,673 | 0,420 | |
| ACC | 71,26 | 95,14 | 72,18 | 67,35 | 84,17 | 94,57 | 81,08 | 74,16 | 79,54 | 93,03 | 81,25 | KNN |
| SPEC | 87,08 | 94,71 | 88,35 | 72,39 | 84,83 | 95,80 | 79,54 | 74,93 | 76,21 | 96,52 | 85,03 | |
| SENS | 50,26 | 95,60 | 50,98 | 60,82 | 83,33 | 92,59 | 82,84 | 73,33 | 84,09 | 88,09 | 76,19 | |
| ITR | 0,135 | 0,720 | 0,147 | 0,089 | 0,370 | 0,696 | 0,300 | 0,176 | 0,269 | 0,635 | 0,354 | |
| ACC | 76,25 | 96,49 | 74,24 | 77,55 | 87,42 | 94,78 | 84,83 | 80,23 | 80,26 | 94,71 | 84,68 | MLNN |
| SPEC | 86,32 | 97,00 | 75,97 | 81,36 | 89,96 | 96,16 | 84,46 | 81,17 | 83,50 | 96,11 | 87,20 | |
| SENS | 63,12 | 95,47 | 72,31 | 71,63 | 82,81 | 92,77 | 85,18 | 77,62 | 75,41 | 92,77 | 80,91 | |
| ITR | 0,209 | 0,781 | 0,177 | 0,232 | 0,454 | 0,704 | 0,386 | 0,283 | 0,283 | 0,701 | 0,421 | |

Tablo 4.39. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|
| ACC | 73,24 | 95,04 | 70,08 | 70,24 | 82,52 | 94,38 | 82,18 | 78,26 | 85,22 | 95,26 | 82,64 | PNN |
| SPEC | 87,71 | 93,50 | 76,86 | 72,72 | 80,78 | 96,63 | 77,86 | 75,53 | 84,42 | 96,12 | 84,21 | |
| SENS | 53,89 | 96,57 | 61,79 | 66,80 | 84,91 | 90,78 | 87,13 | 81,75 | 86,64 | 94,19 | 80,45 | |
| ITR | 0,162 | 0,715 | 0,120 | 0,122 | 0,332 | 0,688 | 0,324 | 0,245 | 0,396 | 0,725 | 0,383 | |
| ACC | 75,11 | 92,03 | 70,06 | 71,13 | 83,28 | 93,06 | 82,26 | 77,70 | 74,15 | 91,48 | 81,02 | DT |
| SPEC | 77,94 | 92,00 | 72,00 | 72,32 | 85,29 | 94,13 | 82,10 | 82,06 | 78,79 | 90,94 | 82,76 | |
| SENS | 71,40 | 92,06 | 67,57 | 69,72 | 80,41 | 91,62 | 81,92 | 72,11 | 67,78 | 92,05 | 78,66 | |
| ITR | 0,190 | 0,599 | 0,119 | 0,133 | 0,349 | 0,636 | 0,326 | 0,234 | 0,175 | 0,580 | 0,334 | |

Tablo 4.39.'da en başarılı katılımcı (katılımcı-2) için en yüksek sınıflandırma doğruluk oranı %97,02 (SVM) olarak elde edilirken, en başarısız katılımcı (katılımcı-4) için en yüksek doğruluk oranı %80,02 (SVM) olarak hesaplanmıştır. 10 katılımcıya ait ortalama başarı oranı ise %85,11 (SVM) olarak bulunmuştur. Ortalama başarı için en yüksek ikinci ve üçüncü performansı gösteren makine öğrenmesi algoritmaları sırasıyla MLNN (%84,68) ve LDA (%84,57) olarak görülmektedir. Bununla beraber, SF diğer zaman alanı metotlarına kıyasla en başarılı katılımcıda ve ortalama başarıda sırasıyla (MAV, MPV) ve (RMS, MPV) metotları dışında diğer makine öğrenmesi algoritmalarından daha iyi performans gösterdiği görülmektedir.

Tablo 4.40. SF ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 79,05 | 96,00 | 73,08 | 75,05 | 87,35 | 94,22 | 86,23 | 76,27 | 75,12 | 95,05 | 83,74 | SVM |
| SPEC | 86,38 | 96,00 | 78,66 | 78,82 | 89,13 | 95,36 | 83,59 | 78,56 | 72,72 | 97,39 | 85,66 | |
| SENS | 69,38 | 96,00 | 65,92 | 69,07 | 84,43 | 92,50 | 89,20 | 73,35 | 78,43 | 91,84 | 81,01 | |
| ITR | 0,259 | 0,758 | 0,160 | 0,190 | 0,452 | 0,681 | 0,422 | 0,209 | 0,191 | 0,716 | 0,404 | |
| ACC | 79,17 | 96,01 | 73,05 | 75,02 | 86,21 | 94,54 | 86,05 | 78,12 | 73,29 | 95,06 | 83,65 | LDA |
| SPEC | 80,20 | 95,50 | 75,63 | 72,34 | 85,36 | 96,25 | 82,14 | 74,11 | 66,25 | 96,97 | 82,48 | |
| SENS | 77,67 | 96,59 | 69,55 | 78,66 | 86,89 | 91,98 | 90,08 | 82,97 | 83,07 | 92,54 | 85,00 | |
| ITR | 0,262 | 0,758 | 0,159 | 0,189 | 0,421 | 0,695 | 0,417 | 0,242 | 0,163 | 0,716 | 0,402 | |

Tablo 4.40. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|------|
| ACC | 78,05 | 95,04 | 72,17 | 71,02 | 86,45 | 94,02 | 81,09 | 80,80 | 82,43 | 92,11 | 83,32 | kNN |
| SPEC | 88,81 | 93,67 | 84,54 | 79,08 | 86,07 | 97,72 | 78,28 | 82,08 | 82,21 | 96,99 | 86,95 | |
| SENS | 63,69 | 96,43 | 56,22 | 60,25 | 86,98 | 88,39 | 84,75 | 78,97 | 82,75 | 85,10 | 78,35 | |
| ITR | 0,241 | 0,715 | 0,147 | 0,132 | 0,428 | 0,673 | 0,300 | 0,294 | 0,329 | 0,602 | 0,386 | |
| ACC | 76,29 | 96,25 | 73,35 | 73,17 | 85,35 | 95,07 | 84,48 | 80,21 | 77,13 | 94,18 | 83,55 | MLNN |
| SPEC | 79,82 | 94,50 | 70,69 | 76,67 | 87,43 | 96,21 | 83,98 | 80,89 | 80,87 | 94,38 | 84,54 | |
| SENS | 69,65 | 97,55 | 76,40 | 66,69 | 81,35 | 92,93 | 83,72 | 79,70 | 71,30 | 93,29 | 81,26 | |
| ITR | 0,210 | 0,769 | 0,164 | 0,161 | 0,399 | 0,717 | 0,377 | 0,282 | 0,224 | 0,680 | 0,398 | |
| ACC | 71,37 | 95,01 | 69,43 | 68,19 | 82,55 | 94,52 | 82,05 | 78,06 | 82,16 | 94,25 | 81,76 | PNN |
| SPEC | 86,34 | 94,00 | 74,58 | 71,94 | 82,41 | 96,67 | 78,94 | 74,92 | 83,59 | 96,11 | 83,95 | |
| SENS | 51,72 | 96,11 | 62,63 | 63,37 | 82,94 | 91,42 | 85,52 | 81,84 | 79,96 | 91,57 | 78,71 | |
| ITR | 0,136 | 0,714 | 0,112 | 0,098 | 0,332 | 0,693 | 0,321 | 0,241 | 0,323 | 0,683 | 0,365 | |
| ACC | 72,65 | 94,01 | 74,10 | 69,20 | 81,71 | 92,09 | 79,75 | 77,21 | 75,17 | 91,37 | 80,73 | DT |
| SPEC | 75,63 | 95,00 | 77,79 | 75,78 | 84,91 | 91,97 | 79,78 | 82,04 | 79,24 | 92,61 | 83,47 | |
| SENS | 68,41 | 93,03 | 69,09 | 60,06 | 76,94 | 92,00 | 79,65 | 70,99 | 69,66 | 89,76 | 76,96 | |
| ITR | 0,153 | 0,673 | 0,175 | 0,109 | 0,314 | 0,601 | 0,273 | 0,226 | 0,191 | 0,576 | 0,329 | |

Tablo 4.40.'da SF metodu ile özelliği çıkarılmış veri seti üzerine PCA yöntemi uygulanmış ve veri seti boyutu azaltılmıştır. Görüldüğü üzere en başarılı ve en başarısız katılımcı için PCA yöntemi, doğruluk oranı değerinde %0,79 ve %6,21 azalmaya sebep olmuştur. Bununla beraber ortalama başarıda en yüksek doğruluk oranı değerinde, ham veri seti sonucuna kıyasla %1,60 azalmaya meydana gelmiştir.

Tablo 4.41. SF ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 76,29 | 95,02 | 72,09 | 65,04 | 82,31 | 94,10 | 84,01 | 60,05 | 69,03 | 90,23 | 78,82 | SVM |
| SPEC | 83,70 | 94,00 | 81,42 | 82,70 | 89,13 | 95,72 | 82,19 | 83,56 | 67,07 | 90,43 | 84,99 | |
| SENS | 66,69 | 96,03 | 60,04 | 40,55 | 72,78 | 91,70 | 85,86 | 30,10 | 71,72 | 90,07 | 70,55 | |
| ITR | 0,210 | 0,715 | 0,146 | 0,066 | 0,327 | 0,676 | 0,366 | 0,029 | 0,107 | 0,538 | 0,318 | |
| ACC | 75,22 | 95,02 | 74,03 | 64,05 | 79,16 | 94,02 | 83,01 | 60,11 | 68,19 | 90,05 | 78,29 | LDA |
| SPEC | 76,26 | 95,50 | 74,72 | 60,22 | 79,09 | 94,95 | 82,19 | 64,31 | 62,81 | 88,37 | 77,84 | |
| SENS | 73,74 | 94,48 | 73,07 | 69,14 | 78,53 | 92,89 | 83,90 | 55,13 | 75,94 | 92,19 | 78,90 | |
| ITR | 0,192 | 0,714 | 0,174 | 0,058 | 0,262 | 0,673 | 0,342 | 0,030 | 0,098 | 0,533 | 0,308 | |

Tablo 4.42. SF ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 78,02 | 96,24 | 73,06 | 70,07 | 87,27 | 93,17 | 85,08 | 77,24 | 74,57 | 95,18 | 82,99 | SVM |
| SPEC | 83,36 | 97,50 | 78,08 | 79,22 | 89,11 | 95,40 | 82,73 | 79,45 | 71,79 | 96,97 | 85,36 | |
| SENS | 70,91 | 94,88 | 66,56 | 57,68 | 84,19 | 89,73 | 87,83 | 74,23 | 78,10 | 92,53 | 79,66 | |
| ITR | 0,240 | 0,769 | 0,159 | 0,120 | 0,450 | 0,641 | 0,392 | 0,226 | 0,182 | 0,721 | 0,390 | |
| ACC | 79,26 | 96,02 | 73,31 | 69,29 | 84,31 | 94,03 | 85,28 | 77,11 | 72,00 | 93,01 | 82,36 | LDA |
| SPEC | 79,86 | 95,50 | 74,80 | 64,89 | 81,20 | 95,38 | 83,07 | 72,85 | 65,78 | 94,35 | 80,77 | |
| SENS | 78,77 | 96,52 | 72,77 | 75,70 | 89,21 | 92,14 | 87,63 | 82,69 | 80,34 | 91,33 | 84,71 | |
| ITR | 0,263 | 0,759 | 0,163 | 0,110 | 0,373 | 0,674 | 0,397 | 0,224 | 0,145 | 0,635 | 0,374 | |

Tablo 4.43. SF ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 79,48 | 98,03 | 79,07 | 67,37 | 90,04 | 94,03 | 85,96 | 70,40 | 74,72 | 96,02 | 83,51 | SVM |
| SPEC | 84,07 | 98,5 | 83,93 | 77,55 | 92,08 | 95,38 | 83,48 | 71,03 | 75,29 | 96,11 | 85,74 | |
| SENS | 74,39 | 97,59 | 73,12 | 54,27 | 87,22 | 92,30 | 88,56 | 69,58 | 73,92 | 95,94 | 80,69 | |
| ITR | 0,268 | 0,86 | 0,26 | 0,089 | 0,532 | 0,674 | 0,415 | 0,124 | 0,184 | 0,758 | 0,416 | |

Tablo 4.41. ve Tablo 4.42.'de SF metodu için 7 ve 11 kanal veri seti sonuçları görülmektedir. En başarılı katılımcı için en yüksek doğruluk oranı değerleri 7 ve 11 kanal veri seti için sırasıyla %95,02 (SVM) ve %96,24 (SVM) olarak elde edilmiştir. En başarısız katılımcı için ise en yüksek doğruluk oranı değerleri %65,04 (SVM) ve %70,07 (SVM) olarak hesaplanmıştır. 11 kanal veri seti sonuçları, ham veri seti sınıflandırma sonuçlarına (Tablo 4.39.) kıyasla doğruluk oranı değerlerinde, 0,78 puan (katılımcı-2 için), 9,95 puan (katılımcı-4) ve 2,12 puan (ortalama başarı için) düşük olarak bulunmuştur. Buna ek olarak, SF metodu ve DWT yöntemi, 11 kanal veri seti sonuçlarında (Tablo 4.43.), SF ve 11 kanal veri seti sonuçlarına (Tablo 4.42.) göre, en başarılı katılımcı için 1,79 puan ve ortalama başarı için 0,52 puan daha yüksek doğruluk oranı sonucu ürettiği görülmektedir.

Tablo 4.44. SF ve ayrık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|--------------|-------|-------|-------|-------|-------|-------|--------------|-----|
| ACC | 79,32 | 98,00 | 78,02 | 73,83 | 91,24 | 96,01 | 86,16 | 73,26 | 78,01 | 97,05 | 85,09 | SVM |
| SPEC | 82,79 | 98,00 | 84,33 | 76,61 | 92,45 | 97,01 | 83,98 | 75,89 | 79,62 | 96,96 | 86,76 | |
| SENS | 74,54 | 97,99 | 69,69 | 69,68 | 89,08 | 94,80 | 88,66 | 70,21 | 75,75 | 97,16 | 82,76 | |
| ITR | 0,265 | 0,859 | 0,240 | 0,171 | 0,572 | 0,758 | 0,420 | 0,162 | 0,240 | 0,808 | 0,449 | |
| ACC | 79,15 | 97,01 | 77,11 | 72,10 | 90,12 | 96,07 | 87,47 | 72,28 | 78,11 | 97,05 | 84,65 | LDA |
| SPEC | 78,50 | 96,50 | 80,81 | 70,65 | 89,17 | 96,23 | 85,48 | 69,62 | 74,46 | 97,84 | 83,93 | |
| SENS | 80,03 | 97,54 | 72,31 | 74,31 | 92,30 | 95,82 | 89,68 | 75,95 | 82,75 | 95,84 | 85,65 | |
| ITR | 0,261 | 0,806 | 0,224 | 0,146 | 0,535 | 0,761 | 0,456 | 0,148 | 0,242 | 0,808 | 0,439 | |

Tablo 4.44.'de şekil faktörü metodu ve ayrık dalgacık dönüşümü yöntemi uygulanmış veri seti sonuç değerleri görülmektedir. En başarılı katılımcı için en yüksek sınıflandırma doğruluk oranı değeri %98 (SVM) olarak bulunurken, en başarısız katılımcı için bu değer %73,83 olarak elde edilmiştir. Bununla beraber en yüksek ortalama sınıflandırma başarısı doğruluk oranı %85,09 olarak hesaplanmıştır. Ham veri seti doğruluk oranı değerlerine kıyasla (Tablo 4.39.), en başarılı katılımcı için 0,98 puan artış sağlanırken, en başarısız katılımcı ve ortalama başarı için sırasıyla 6,19 puan ve 0,02 puan azalma elde edilmiştir.

Şekil faktörü özellik çıkarma metodu kullanılarak hesaplanan ham veri seti sınıflandırma sonuç değerlerine göre en başarılı katılımcı (katılımcı-2) ve en başarısız katılımcı (katılımcı-4) için ilgili grafikler şöyledir: Beyin haritalama sonuçları (Şekil 4.2. ve Şekil 4.33.), EEG kanalları üzerinde oluşan ortalama sinyal gücü grafiği (Şekil 4.4. ve Şekil 4.34.), sürekli dalgacık dönüşümü zaman-frekans skalası ve frekans spektrumu grafiği (Şekil 4.6. ve Şekil 4.35.) ve her iki katılımcıya ait spektral güç yoğunluğunu gösteren periodogram grafiği (Şekil 4.36.) gösterilmiştir. Belirtilen grafiklere ait değerlendirmeler ilgili grafiklere ait şekillerin alt kısmında ele alınmıştır.

4.1.8. Güç spektral yoğunluğu sonuçları


Frekans alanı özellik çıkarma metotlarından birisi olan güç spektral yoğunluğuna (PSD) ait makine öğrenmesi algoritmaları için sınıflandırma sonuç değerleri tez çalışması içinde verilmektedir. İlgili sonuç değerleri şöyledir:

Tablo 4.45. PSD ham veri seti sonuçları (400×19)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|------|
| ACC | 77,10 | 96,02 | 77,07 | 79,13 | 90,07 | 94,07 | 85,69 | 67,80 | 75,17 | 96,22 | 83,83 | SVM |
| SPEC | 86,40 | 96,00 | 82,71 | 73,55 | 92,45 | 97,03 | 80,22 | 85,77 | 62,77 | 99,13 | 85,60 | |
| SENS | 65,31 | 96,06 | 69,61 | 86,78 | 86,06 | 90,02 | 91,89 | 44,61 | 92,47 | 92,20 | 81,50 | |
| ITR | 0,224 | 0,758 | 0,223 | 0,261 | 0,533 | 0,675 | 0,408 | 0,094 | 0,191 | 0,768 | 0,414 | |
| ACC | 74,04 | 93,01 | 76,02 | 78,01 | 89,35 | 95,09 | 83,03 | 72,21 | 73,19 | 93,14 | 82,71 | LDA |
| SPEC | 72,23 | 88,50 | 76,98 | 71,47 | 91,21 | 97,46 | 76,60 | 63,32 | 59,73 | 97,83 | 79,53 | |
| SENS | 76,46 | 97,52 | 75,07 | 87,27 | 86,97 | 91,74 | 90,66 | 83,52 | 91,27 | 87,10 | 86,76 | |
| ITR | 0,174 | 0,634 | 0,205 | 0,240 | 0,511 | 0,717 | 0,343 | 0,147 | 0,161 | 0,640 | 0,377 | |
| ACC | 69,32 | 94,46 | 71,13 | 69,08 | 84,72 | 92,18 | 79,23 | 68,80 | 78,70 | 90,34 | 79,80 | kNN |
| SPEC | 83,96 | 94,67 | 80,38 | 76,55 | 88,29 | 96,63 | 77,58 | 67,00 | 75,82 | 96,09 | 83,69 | |
| SENS | 49,92 | 94,13 | 58,62 | 58,85 | 78,57 | 85,75 | 81,13 | 71,32 | 83,02 | 82,75 | 74,41 | |
| ITR | 0,111 | 0,691 | 0,133 | 0,108 | 0,383 | 0,604 | 0,263 | 0,105 | 0,253 | 0,542 | 0,319 | |
| ACC | 75,28 | 95,47 | 74,27 | 79,30 | 89,10 | 94,03 | 84,10 | 73,49 | 78,67 | 95,27 | 83,90 | MLNN |
| SPEC | 83,24 | 94,50 | 80,34 | 79,26 | 91,61 | 97,05 | 83,20 | 77,39 | 73,19 | 97,83 | 85,76 | |
| SENS | 64,18 | 95,99 | 66,82 | 78,93 | 83,19 | 89,96 | 84,50 | 67,02 | 85,35 | 90,74 | 80,67 | |
| ITR | 0,193 | 0,734 | 0,177 | 0,264 | 0,503 | 0,674 | 0,368 | 0,166 | 0,252 | 0,725 | 0,406 | |
| ACC | 70,11 | 91,27 | 71,26 | 70,23 | 85,06 | 91,05 | 83,44 | 74,35 | 81,19 | 92,02 | 81,00 | PNN |
| SPEC | 86,82 | 93,50 | 85,34 | 77,05 | 86,18 | 94,96 | 83,03 | 72,81 | 78,82 | 96,97 | 85,55 | |
| SENS | 48,26 | 89,08 | 52,96 | 60,91 | 83,38 | 85,57 | 84,12 | 76,40 | 84,62 | 85,32 | 75,06 | |
| ITR | 0,120 | 0,573 | 0,135 | 0,122 | 0,392 | 0,565 | 0,353 | 0,179 | 0,303 | 0,599 | 0,334 | |
| ACC | 68,00 | 93,24 | 72,12 | 72,19 | 85,29 | 92,16 | 81,18 | 76,03 | 76,52 | 91,03 | 80,78 | DT |
| SPEC | 73,16 | 93,50 | 75,08 | 77,93 | 87,46 | 93,30 | 81,65 | 80,30 | 78,77 | 91,76 | 83,29 | |
| SENS | 59,49 | 93,14 | 68,14 | 64,13 | 82,23 | 90,71 | 80,59 | 70,33 | 73,53 | 89,94 | 77,22 | |
| ITR | 0,096 | 0,643 | 0,146 | 0,147 | 0,398 | 0,604 | 0,302 | 0,206 | 0,214 | 0,565 | 0,332 | |

Tablo 4.45.'de PSD kullanılmış ham veri seti sonuç değerleri içinde en başarılı katılımcı (katılımcı-10) için en yüksek doğruluk oranı %96,22 (SVM) olarak hesaplanmıştır. En başarısız katılımcı (katılımcı-8) için en yüksek ve en düşük

doğruluk oranı değerleri sırasıyla %76,03 (DT) ve %67,80 (SVM) olarak elde edilmiştir. Bununla beraber, 10 katılımcı için bulunan en yüksek ve düşük ortalama başarı oranı değerleri sırasıyla %83,90 (MLNN) ve %79,80 (kNN) olarak hesaplanmıştır. Tez çalışması içinde kullanılan zaman alanı metotlarına ait ham veri seti sonuçlarına kıyasla; PSD metodu, RMS, MAV, MPV ve SF metotları ile elde edilen en başarılı katılımcı, en başarısız katılımcı ve ortalama başarı oranındaki en yüksek doğruluk oranı değerlerinden daha düşük sonuçlar sağlamıştır.



Şekil 4.37. Güç spektral yoğunluğu ve ham veri seti sonuçlarına göre en başarısız ve en başarılı katılımcıya ait sınıflandırma performans değerleri

Tablo 4.46. PSD ve temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|-----|
| ACC | 79,33 | 95,02 | 76,33 | 77,62 | 88,16 | 93,01 | 84,1 | 61,13 | 68,28 | 95,01 | 81,80 | SVM |
| SPEC | 86,78 | 95 | 86,26 | 79,2 | 90,82 | 96,56 | 77,47 | 87,53 | 55,43 | 97,84 | 85,29 | |
| SENS | 70,02 | 95,09 | 63,65 | 75,67 | 84,59 | 88,01 | 91,65 | 27,41 | 86,04 | 91,31 | 77,34 | |
| ITR | 0,265 | 0,715 | 0,21 | 0,233 | 0,475 | 0,634 | 0,368 | 0,036 | 0,099 | 0,714 | 0,375 | |
| ACC | 75,12 | 91,29 | 78,1 | 76,05 | 87,31 | 91,15 | 82,25 | 66,01 | 67,02 | 93,02 | 80,73 | LDA |
| SPEC | 71,25 | 85 | 80,51 | 73,19 | 89,51 | 93,7 | 69,94 | 69,8 | 48,53 | 96,96 | 77,84 | |
| SENS | 80,24 | 97,49 | 75,03 | 79,78 | 84,03 | 87,82 | 96,25 | 61,33 | 92,44 | 87,49 | 84,19 | |
| ITR | 0,191 | 0,573 | 0,242 | 0,206 | 0,451 | 0,568 | 0,325 | 0,075 | 0,085 | 0,635 | 0,335 | |
| ACC | 71,00 | 88,00 | 74,10 | 69,17 | 84,20 | 89,02 | 78,07 | 72,87 | 74,62 | 88,02 | 78,91 | kNN |
| SPEC | 80,31 | 85,52 | 82,59 | 72,20 | 83,95 | 94,97 | 76,15 | 73,24 | 72,75 | 95,85 | 81,75 | |
| SENS | 58,46 | 90,45 | 63,62 | 65,19 | 84,74 | 80,31 | 80,41 | 72,68 | 77,49 | 77,52 | 75,09 | |
| ITR | 0,131 | 0,471 | 0,175 | 0,109 | 0,370 | 0,501 | 0,241 | 0,157 | 0,183 | 0,471 | 0,281 | |

Tablo 4.46. (Devamı)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|-------|--------------|------|
| ACC | 76,06 | 93,37 | 76,90 | 76,25 | 87,32 | 93,11 | 83,65 | 71,28 | 78,33 | 94,40 | 83,07 | |
| SPEC | 84,25 | 91,50 | 78,26 | 78,37 | 90,80 | 94,13 | 84,48 | 78,12 | 72,28 | 97,39 | 84,96 | MLNN |
| SENS | 63,96 | 90,59 | 74,06 | 72,53 | 78,71 | 88,59 | 82,26 | 61,19 | 84,35 | 88,80 | 78,50 | |
| ITR | 0,206 | 0,648 | 0,220 | 0,209 | 0,451 | 0,638 | 0,357 | 0,135 | 0,246 | 0,689 | 0,380 | |
| ACC | 69,15 | 92,22 | 70,77 | 74,05 | 87,14 | 91,01 | 82,04 | 74,28 | 79,52 | 92,01 | 81,22 | |
| SPEC | 90,36 | 92,00 | 83,12 | 68,41 | 89,15 | 94,51 | 88,29 | 70,97 | 78,33 | 97,83 | 85,30 | PNN |
| SENS | 41,12 | 92,35 | 54,91 | 82,23 | 84,03 | 85,81 | 75,31 | 78,64 | 81,40 | 84,04 | 75,98 | |
| ITR | 0,109 | 0,606 | 0,128 | 0,174 | 0,446 | 0,564 | 0,321 | 0,178 | 0,269 | 0,598 | 0,339 | |
| ACC | 74,16 | 90,61 | 72,69 | 76,73 | 83,01 | 90,27 | 79,36 | 81,33 | 77,47 | 92,32 | 81,80 | |
| SPEC | 79,29 | 88,50 | 73,72 | 80,56 | 86,16 | 90,80 | 82,16 | 83,48 | 80,56 | 93,95 | 83,92 | DT |
| SENS | 67,64 | 92,58 | 71,24 | 70,92 | 78,16 | 89,52 | 76,59 | 78,49 | 73,11 | 90,58 | 78,88 | |
| ITR | 0,176 | 0,551 | 0,154 | 0,217 | 0,343 | 0,540 | 0,266 | 0,305 | 0,230 | 0,609 | 0,339 | |

Tablo 4.46.'da PSD metodu ve temel bileşen analizi yöntemi kullanılmış ham veri seti sınıflandırma sonuç değerleri görülmektedir. Buna göre; en başarılı ve en başarısız katılımcı için %95,01 (SVM) ve %81,33 (DT) ortalama doğruluk oranı değerleri elde edilmiştir. Bununla beraber ortalama başarı için en yüksek sınıflandırma doğruluk oranı değeri %83,07 (MLNN) olarak hesaplanmıştır. Ham veri setine (Tablo 4.45.) kıyasla en başarılı katılımcıda doğruluk oranı değeri için 1,21 puan azalma gözlenirken, en başarısız katılımcıda 5,3 puan artış sağlanmıştır. Ortalama başarıda doğruluk oranı için ise 0,83 azalma görülmektedir.

Tablo 4.47. PSD ve temel bileşen analizi veri seti sonuçları (400×10)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|------|
| ACC | 76,41 | 95,42 | 76,24 | 76,33 | 87,92 | 94,68 | 86,58 | 74,05 | 75,25 | 94,15 | 83,70 | |
| SPEC | 80,65 | 94 | 78,75 | 77,52 | 93,33 | 95,34 | 84,89 | 72,81 | 64,95 | 94,86 | 83,71 | MLNN |
| SENS | 68,52 | 95,92 | 72,38 | 71,6 | 80,29 | 91,4 | 85,43 | 74,96 | 86,37 | 90,98 | 81,79 | |
| ITR | 0,212 | 0,732 | 0,209 | 0,211 | 0,468 | 0,700 | 0,431 | 0,174 | 0,193 | 0,678 | 0,401 | |
| ACC | 70,43 | 91,75 | 72,08 | 69,91 | 85,15 | 91,22 | 83,3 | 74,08 | 76,08 | 91,08 | 80,51 | |
| SPEC | 91,21 | 91 | 80,08 | 72,7 | 88,7 | 95,38 | 79,96 | 71,05 | 74,93 | 96,11 | 84,11 | PNN |
| SENS | 43,13 | 92,54 | 61,14 | 66,09 | 79,46 | 85,29 | 86,25 | 78,07 | 77,9 | 84,22 | 75,41 | |
| ITR | 0,124 | 0,589 | 0,146 | 0,118 | 0,394 | 0,571 | 0,349 | 0,175 | 0,206 | 0,566 | 0,324 | |

Tablo 4.47.'de PSD metodu ve PCA yöntemi uygulanmış veri seti için sonuçlar gösterilmiştir. Tablo 4.46.'da 12 temel bileşen için elde edilen sınıflandırma sonuç değerleri 10 temel bileşen için MLNN ve PNN algoritmalarında elde edilmiştir. Buna göre; katılımcı-10 için en yüksek elde edilen doğruluk oranı değeri %94,15 (MLNN) olarak görülürken, katılımcı-8 için en yüksek elde edilen doğruluk oranı değeri %74,08 olarak gözlenmiştir.

Tablo 4.48. PSD ve ayrık dalgacık dönüşümü uygulanmış, temel bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|-------------|--------------|-----|
| ACC | 74,02 | 90,7 | 71,32 | 67,66 | 84,35 | 93,05 | 78,93 | 74,56 | 74,36 | 88,04 | 79,7 | KNN |
| SPEC | 86,2 | 87,5 | 80,85 | 73,1 | 84,83 | 95,36 | 79,64 | 77,25 | 74,87 | 95,22 | 83,48 | |
| SENS | 57,97 | 93,85 | 58,22 | 60,59 | 83,01 | 89,87 | 78,23 | 71,18 | 73,85 | 78,16 | 74,49 | |
| ITR | 0,174 | 0,553 | 0,135 | 0,092 | 0,374 | 0,636 | 0,257 | 0,182 | 0,179 | 0,472 | 0,305 | |
| ACC | 73,01 | 92,27 | 71,21 | 68,28 | 84,08 | 93,3 | 80,49 | 74,11 | 80,47 | 91,2 | 80,84 | DT |
| SPEC | 76,56 | 89,5 | 77,31 | 70,54 | 88,7 | 94,93 | 81,3 | 76,36 | 81,01 | 92,23 | 82,84 | |
| SENS | 68,63 | 94,93 | 63,53 | 65,21 | 77,14 | 91,01 | 79,51 | 71,35 | 79,58 | 89,62 | 78,05 | |
| ITR | 0,159 | 0,607 | 0,134 | 0,099 | 0,368 | 0,646 | 0,288 | 0,175 | 0,288 | 0,57 | 0,333 | |

Tablo 4.48.'de görülen sonuç değerleri için DWT yöntemi ile delta ve teta frekans bantları çıkarılmış veri seti üzerine PSD methodu ve PCA yöntemi uygulanmıştır. Tablo 4.46.'ya kıyasla, en başarılı ve en başarısız katılımcı için doğruluk oranı değerinde 3,81 puan ve 6,77 puan azalma görülmektedir. Ortalama başarı için elde edilen azalma değeri 2,23 (DT-%80,84) puan olarak gözlenmiştir.

Tablo 4.49. PSD ve bağımsız bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|-----|
| ACC | 76,89 | 95,24 | 77,02 | 80,24 | 88,17 | 94,59 | 83,15 | 73,01 | 76,05 | 95,77 | 84,01 | SVM |
| SPEC | 88,18 | 96 | 85,32 | 78,3 | 93,7 | 97,01 | 80,74 | 66,92 | 67,12 | 97,83 | 85,11 | |
| SENS | 62,21 | 94,39 | 66,19 | 83,4 | 80,3 | 91,19 | 85,97 | 80,97 | 88,33 | 93,17 | 82,61 | |
| ITR | 0,220 | 0,724 | 0,222 | 0,283 | 0,476 | 0,696 | 0,346 | 0,159 | 0,206 | 0,747 | 0,408 | |
| ACC | 75,15 | 92,5 | 76,05 | 78,65 | 89,12 | 93,27 | 82,38 | 73,05 | 73,18 | 93,19 | 82,65 | LDA |
| SPEC | 73,56 | 88,5 | 79,9 | 72,68 | 92,01 | 94,51 | 81,19 | 64,78 | 61,03 | 97,83 | 80,6 | |
| SENS | 76,66 | 96,52 | 70,63 | 86,19 | 84,74 | 91,5 | 83,39 | 83,52 | 89,76 | 86,61 | 84,95 | |
| ITR | 0,191 | 0,616 | 0,206 | 0,252 | 0,504 | 0,644 | 0,328 | 0,159 | 0,161 | 0,641 | 0,370 | |

Tablo 4.49.'da PSD methodu ve ICA yöntemi veri seti üzerine uygulanmış ve sınıflandırma sonuç değerleri elde edilmiştir. Buna göre; en başarılı ve en başarısız katılımcılarda sırasıyla %95,77 (SVM) ve %73,05 (LDA) değerleri elde edilmiştir. Bununla beraber, ortalama başarıda %84,01 (SVM) doğruluk oranı değeri görülmektedir. PCA ile 12 temel bileşen sonuçlarına kıyasla (Tablo 4.46.), en başarılı katılımcı ve ortalama başarı için sınıflandırma performansında sırasıyla 0,76 puan ve 0,94 puan doğruluk oranı artışı gözlenmiştir. En başarısız katılımcıda ise 8,28 puan azalma olduğu gözlenmiştir. Bağımsız bileşen analizi yöntemi ile optimize edilerek seçilen 12 bağımsız bileşen, PCA yöntemi ile boyutu azaltılan 12 temel bileşen sonuçlarına kıyasla; en yüksek ortalama başarının yanında SVM ve LDA ile üretilen ortalama başarı sonuçlarında da daha iyi performans gösterdiği görülmektedir.

Tablo 4.50. PSD ve ayrık dalgacık dönüşümü uygulanmış, bağımsız bileşen analizi veri seti sonuçları (400×12)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|-------------|-----|
| ACC | 72,09 | 87,35 | 69,04 | 69,24 | 83,04 | 89,28 | 75,48 | 75,37 | 78,96 | 87,19 | 78,7 | KNN |
| SPEC | 87,4 | 81,37 | 85,07 | 76,94 | 83,32 | 97,13 | 76,37 | 79,54 | 79,2 | 93,9 | 84,02 | |
| SENS | 51,74 | 93,34 | 48,43 | 59,13 | 83,11 | 77,41 | 74,58 | 70,16 | 78,16 | 77,91 | 71,4 | |
| ITR | 0,146 | 0,452 | 0,107 | 0,11 | 0,343 | 0,509 | 0,196 | 0,195 | 0,258 | 0,448 | 0,276 | |
| ACC | 71,21 | 84,24 | 70,01 | 72,41 | 80,25 | 86,34 | 76,75 | 76,28 | 78,25 | 83,05 | 77,88 | DT |
| SPEC | 74,03 | 85 | 72,87 | 77,05 | 84,98 | 87,34 | 77,38 | 79,03 | 80,09 | 86,11 | 80,39 | |
| SENS | 67,45 | 83,57 | 66,75 | 65,38 | 74,18 | 84,85 | 76,04 | 72,24 | 75,82 | 78,56 | 74,48 | |
| ITR | 0,134 | 0,372 | 0,119 | 0,15 | 0,283 | 0,425 | 0,218 | 0,21 | 0,244 | 0,343 | 0,25 | |

Tablo 4.50.'de görülen sınıflandırma sonuçlarında katılımcı-10 ve katılımcı-8 için elde edilen en yüksek doğruluk oranı değerleri DWT uygulanmadan önce hesaplanan ICA sonuç değerleri (Tablo 4.49.) ile kıyaslanmıştır. Buna göre bu değerler 8,58 puan düşük ve 3,23 puan yüksek elde edilmiştir. Ortalama başarıda, kNN (%78,7) doğruluk oranı değerinin, SVM (%84,01)'den daha düşük olduğu görülmektedir.

Tablo 4.51. PSD ve 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|------|
| ACC | 74,20 | 95,02 | 71,13 | 58,05 | 84,23 | 92,05 | 82,01 | 60,06 | 63,07 | 91,06 | 77,09 | |
| SPEC | 92,55 | 94,00 | 87,59 | 100 | 93,26 | 93,19 | 86,90 | 95,08 | 46,34 | 95,65 | 88,46 | SVM |
| SENS | 50,72 | 96,14 | 49,88 | 0,00 | 70,74 | 90,08 | 75,97 | 15,46 | 86,47 | 85,13 | 62,06 | |
| ITR | 0,176 | 0,714 | 0,133 | 0,019 | 0,371 | 0,600 | 0,320 | 0,029 | 0,050 | 0,566 | 0,298 | |
| ACC | 76,06 | 93,04 | 75,11 | 58,06 | 83,17 | 91,02 | 85,00 | 60,14 | 63,02 | 90,06 | 77,47 | |
| SPEC | 82,00 | 88,50 | 80,02 | 49,80 | 89,11 | 94,46 | 77,45 | 80,34 | 42,46 | 93,93 | 77,81 | LDA |
| SENS | 67,84 | 97,52 | 68,60 | 69,66 | 74,12 | 85,95 | 93,55 | 34,32 | 91,29 | 84,85 | 76,77 | |
| ITR | 0,206 | 0,636 | 0,191 | 0,019 | 0,346 | 0,564 | 0,390 | 0,030 | 0,050 | 0,533 | 0,297 | |
| ACC | 76,22 | 96,04 | 74,28 | 65,43 | 83,21 | 93,21 | 81,29 | 63,83 | 67,01 | 91,23 | 79,17 | |
| SPEC | 86,40 | 95,00 | 80,71 | 74,51 | 89,55 | 95,78 | 81,21 | 86,62 | 62,75 | 92,17 | 84,47 | MLNN |
| SENS | 61,99 | 97,05 | 64,26 | 53,69 | 72,66 | 87,88 | 80,58 | 33,90 | 72,48 | 88,14 | 71,26 | |
| ITR | 0,209 | 0,759 | 0,177 | 0,070 | 0,347 | 0,642 | 0,305 | 0,056 | 0,085 | 0,571 | 0,322 | |
| ACC | 72,21 | 94,48 | 69,43 | 63,18 | 80,03 | 93,33 | 80,18 | 61,80 | 76,56 | 90,09 | 78,13 | |
| SPEC | 86,80 | 93,00 | 84,03 | 74,86 | 82,45 | 95,33 | 78,85 | 93,75 | 71,88 | 94,78 | 85,57 | PNN |
| SENS | 53,11 | 95,99 | 50,63 | 47,22 | 76,68 | 90,44 | 81,99 | 21,00 | 82,97 | 83,15 | 68,32 | |
| ITR | 0,148 | 0,692 | 0,112 | 0,051 | 0,279 | 0,647 | 0,282 | 0,041 | 0,214 | 0,534 | 0,300 | |

Tablo 4.52. PSD ve ayrık dalgacık dönüşümü uygulanmış, 7 kanal-frontal bölge veri seti sonuçları (400×7)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|-----|
| ACC | 70,28 | 96,33 | 68,11 | 66,02 | 82,05 | 94,25 | 82,51 | 60,02 | 74,43 | 89,85 | 78,39 | |
| SPEC | 83,13 | 95,94 | 86,38 | 75,15 | 86,13 | 94,51 | 81,69 | 70,8 | 73,61 | 91,74 | 83,91 | KNN |
| SENS | 54,08 | 96,81 | 44,37 | 53,28 | 75,85 | 93,65 | 83,42 | 46,46 | 76,07 | 87,57 | 71,16 | |
| ITR | 0,122 | 0,773 | 0,097 | 0,075 | 0,321 | 0,683 | 0,331 | 0,029 | 0,18 | 0,526 | 0,314 | |
| ACC | 70,01 | 95,03 | 69,17 | 71,13 | 80,22 | 94,16 | 82,37 | 64,02 | 75,48 | 91,02 | 79,26 | |
| SPEC | 75,73 | 95,5 | 75,63 | 76,61 | 84,93 | 96,63 | 82,58 | 69,66 | 78,77 | 89,6 | 82,56 | DT |
| SENS | 62,4 | 94,46 | 61,29 | 63,65 | 73,5 | 90,81 | 82,06 | 57,04 | 71,24 | 92,81 | 74,93 | |
| ITR | 0,119 | 0,715 | 0,109 | 0,133 | 0,283 | 0,679 | 0,328 | 0,058 | 0,196 | 0,564 | 0,318 | |

Tablo 4.51. ve Tablo 4.52.'de 7 kanal-frontal bölge için oluşturulan veri setine PSD metodu ve PSD-DWT yöntemi uygulanmıştır. Elde edilen sınıflandırma sonuçları şöyledir: Ortalama başarı için hesaplanan en yüksek doğruluk oranı değerleri %79,17 (MLNN) ve %79,26 (DT) olarak elde edilmiştir.

Tablo 4.53. PSD ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|------|
| ACC | 79,46 | 95,02 | 72,41 | 71,20 | 89,06 | 93,22 | 84,25 | 62,20 | 70,01 | 94,01 | 81,08 | |
| SPEC | 89,33 | 95,00 | 87,61 | 72,30 | 92,90 | 96,20 | 75,17 | 91,92 | 54,09 | 96,96 | 85,15 | SVM |
| SENS | 66,57 | 94,94 | 53,43 | 70,03 | 83,08 | 88,12 | 94,59 | 24,19 | 91,86 | 89,81 | 75,66 | |
| ITR | 0,267 | 0,714 | 0,150 | 0,134 | 0,502 | 0,642 | 0,372 | 0,043 | 0,119 | 0,673 | 0,362 | |
| ACC | 76,30 | 92,00 | 77,04 | 69,12 | 87,23 | 92,05 | 83,04 | 69,40 | 68,03 | 92,08 | 80,63 | |
| SPEC | 75,36 | 87,50 | 82,67 | 64,06 | 89,55 | 95,76 | 72,32 | 71,01 | 50,69 | 97,39 | 78,63 | LDA |
| SENS | 77,30 | 96,37 | 70,49 | 76,12 | 83,59 | 86,95 | 95,44 | 67,38 | 91,52 | 84,75 | 82,99 | |
| ITR | 0,210 | 0,598 | 0,223 | 0,108 | 0,449 | 0,600 | 0,343 | 0,111 | 0,096 | 0,600 | 0,334 | |
| ACC | 76,11 | 95,05 | 76,53 | 71,31 | 88,28 | 93,38 | 85,19 | 73,23 | 73,14 | 94,84 | 82,71 | |
| SPEC | 88,14 | 94,50 | 81,88 | 78,39 | 89,95 | 95,82 | 82,64 | 67,06 | 68,79 | 97,43 | 84,46 | MLNN |
| SENS | 58,19 | 95,46 | 69,82 | 60,90 | 83,36 | 90,63 | 87,10 | 79,79 | 77,02 | 91,64 | 79,39 | |
| ITR | 0,207 | 0,716 | 0,214 | 0,135 | 0,479 | 0,649 | 0,395 | 0,162 | 0,161 | 0,707 | 0,382 | |
| ACC | 70,24 | 91,72 | 71,12 | 68,01 | 86,08 | 92,02 | 83,09 | 76,60 | 82,27 | 94,35 | 81,55 | |
| SPEC | 83,12 | 93,00 | 81,78 | 74,47 | 88,30 | 95,33 | 75,15 | 74,51 | 81,41 | 96,96 | 84,40 | PNN |
| SENS | 53,03 | 90,63 | 56,97 | 59,46 | 82,86 | 87,09 | 92,08 | 79,24 | 83,63 | 91,13 | 77,61 | |
| ITR | 0,122 | 0,588 | 0,133 | 0,096 | 0,418 | 0,599 | 0,345 | 0,215 | 0,326 | 0,687 | 0,353 | |

Tablo 4.54. PSD ve ayırık dalgacık dönüşümü uygulanmış, 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×11)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|-------------|-----|
| ACC | 73,07 | 96,3 | 69,3 | 66,4 | 86,29 | 94,32 | 82,11 | 74,4 | 80,7 | 91,13 | 81,4 | |
| SPEC | 84,36 | 95,82 | 88,7 | 73,86 | 87,22 | 96,2 | 81,17 | 75,08 | 80,94 | 92,63 | 85,6 | kNN |
| SENS | 58,38 | 96,78 | 44,37 | 56,54 | 85,37 | 91,8 | 82,98 | 73,65 | 80,43 | 88,92 | 75,92 | |
| ITR | 0,16 | 0,772 | 0,11 | 0,079 | 0,424 | 0,685 | 0,322 | 0,179 | 0,292 | 0,568 | 0,359 | |
| ACC | 74,42 | 93,29 | 71,05 | 68,57 | 85,31 | 95,01 | 83,05 | 75,25 | 76,02 | 91,01 | 81,3 | |
| SPEC | 79,7 | 91,5 | 78,68 | 73,61 | 90,34 | 95,36 | 80,8 | 79,39 | 78,35 | 91,3 | 83,9 | DT |
| SENS | 67,14 | 95,13 | 60,63 | 61,69 | 77,48 | 93,94 | 85,49 | 70,16 | 72,86 | 90,65 | 77,52 | |
| ITR | 0,18 | 0,645 | 0,132 | 0,102 | 0,398 | 0,714 | 0,343 | 0,193 | 0,205 | 0,564 | 0,348 | |

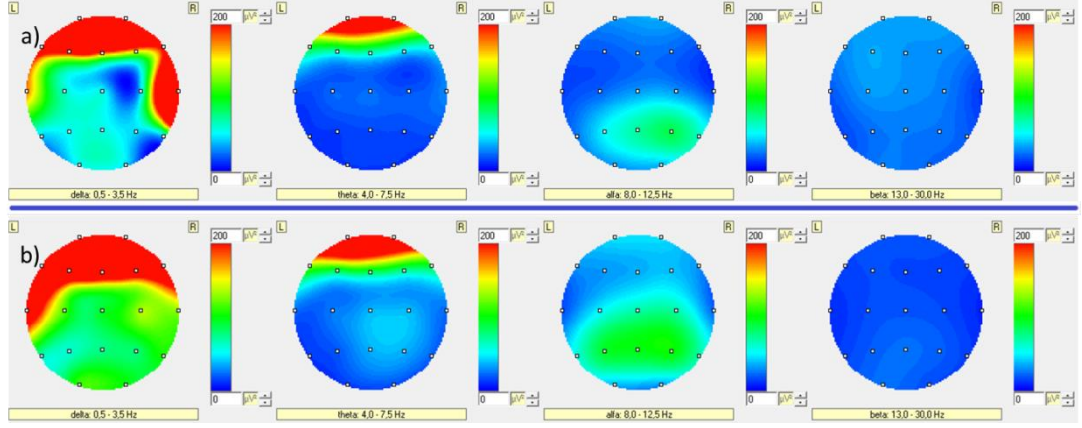
Tablo 4.53. ve Tablo 4.54.'de 11 kanal-frontal ve temporal bölge için oluşturulan veri setine PSD metodu ve PSD-DWT yöntemi uygulanmıştır. Elde edilen sınıflandırma sonuçları şöyledir: Ortalama başarı için hesaplanan en yüksek doğruluk oranı değerleri %82,71 (MLNN) ve %81,4 (kNN) olarak görülmektedir. Bununla beraber Tablo 4.53. ve Tablo 4.54.'de 11 kanal sonuç değerlerinde, ham veri setine kıyasla

(Tablo 4.45.) ortalama sınıflandırma başarısında %1,41 ve %2,97 azalma meydana geldiği gözlenmiştir.

Tablo 4.55. PSD ve ayırık dalgacık dönüşümü uygulanmış veri seti sonuçları (400×19)

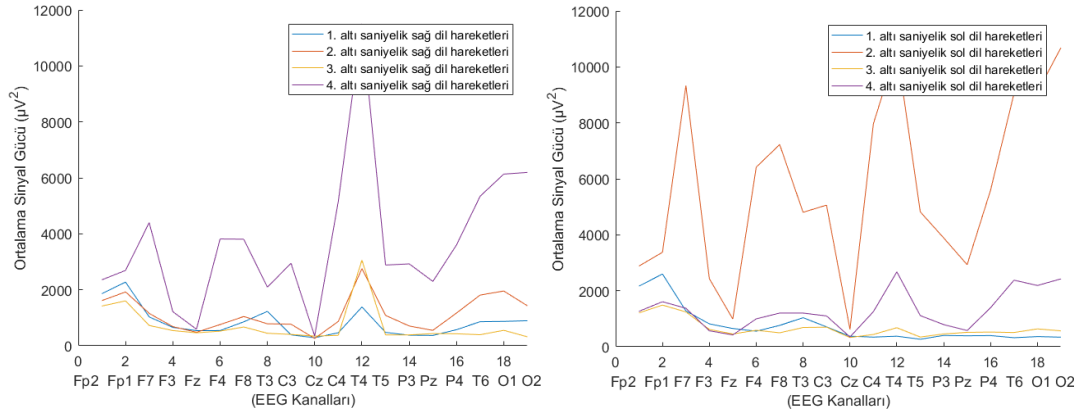
| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|-------|-------|-------|-------|--------------|-------|--------------|--------------|-----|
| ACC | 78,06 | 96,04 | 71,32 | 75,38 | 91,09 | 96,02 | 85,05 | 64,31 | 75,00 | 95,28 | 82,76 | SVM |
| SPEC | 89,92 | 96,00 | 88,87 | 77,08 | 93,28 | 97,07 | 80,74 | 89,68 | 60,13 | 98,26 | 87,10 | |
| SENS | 62,50 | 96,06 | 48,35 | 72,97 | 88,06 | 94,60 | 90,14 | 31,89 | 95,22 | 91,36 | 77,12 | |
| ITR | 0,241 | 0,759 | 0,136 | 0,195 | 0,567 | 0,759 | 0,391 | 0,060 | 0,189 | 0,726 | 0,402 | |
| ACC | 72,06 | 93,26 | 72,02 | 70,12 | 89,11 | 95,35 | 83,49 | 72,09 | 73,27 | 92,59 | 81,34 | LDA |
| SPEC | 70,38 | 90,00 | 80,47 | 66,63 | 92,07 | 97,90 | 76,95 | 62,49 | 58,88 | 97,39 | 79,32 | |
| SENS | 74,04 | 96,50 | 61,36 | 74,97 | 84,52 | 91,84 | 90,87 | 83,86 | 92,97 | 86,19 | 83,71 | |
| ITR | 0,145 | 0,644 | 0,145 | 0,120 | 0,504 | 0,729 | 0,354 | 0,146 | 0,162 | 0,619 | 0,357 | |
| ACC | 70,66 | 95,26 | 68,16 | 69,16 | 86,15 | 94,17 | 81,02 | 72,54 | 77,09 | 91,02 | 80,52 | KNN |
| SPEC | 82,64 | 95,44 | 89,85 | 77,76 | 89,39 | 97,05 | 81,29 | 73,22 | 75,33 | 95,22 | 85,72 | |
| SENS | 54,99 | 95,04 | 40,24 | 57,59 | 81,38 | 90,04 | 80,56 | 71,82 | 79,48 | 85,32 | 73,65 | |
| ITR | 0,127 | 0,725 | 0,097 | 0,109 | 0,420 | 0,679 | 0,299 | 0,152 | 0,224 | 0,564 | 0,340 | |
| ACC | 75,53 | 93,03 | 71,14 | 70,05 | 86,49 | 94,16 | 83,54 | 76,22 | 77,00 | 91,29 | 81,84 | DT |
| SPEC | 81,88 | 91,50 | 75,95 | 74,87 | 90,78 | 95,40 | 83,55 | 78,54 | 80,09 | 93,93 | 84,65 | |
| SENS | 66,97 | 94,57 | 65,18 | 63,58 | 80,11 | 92,48 | 83,35 | 73,51 | 72,71 | 87,88 | 78,03 | |
| ITR | 0,197 | 0,635 | 0,133 | 0,119 | 0,429 | 0,679 | 0,355 | 0,209 | 0,222 | 0,573 | 0,36 | |

Tablo 4.55.'de delta ve teta frekans bandı çıkarıldıktan sonra veri setine PSD metodu uygulanmış ve sınıflandırma sonuç değerleri elde edilmiştir. Buna göre; en başarılı ve en başarısız katılımcılar için %95,28 (SVM) ve %76,22 (DT) değerleri elde edilmiştir. Ortalama başarı için doğruluk oranı %82,76 (SVM) olarak hesaplanmıştır. Ham veri seti sonuç değerlerine kıyasla (Tablo 4.46.), DWT yönteminde en yüksek doğruluk oranları için en başarılı katılımcıda ve ortalama başarıda 0,94 puan ve 1,14 puan azalma meydana gelmiştir. En başarısız katılımcıda ise 0,19 puan artış sağlanmıştır.



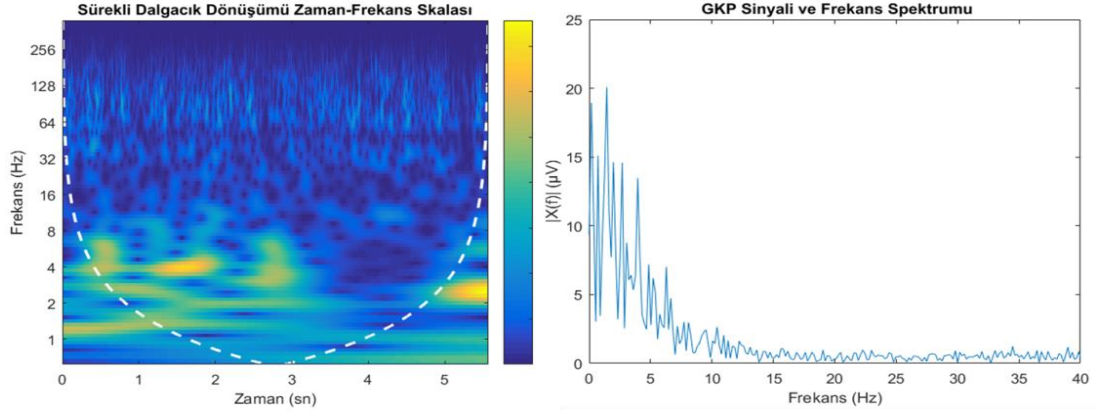
Şekil 4.38. En başarısız katılımcıya (katılımcı-8) ait beyin haritalama gösterimi a) Sağ yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi b) Sol yanak duvarına ardışık dil hareketleri ile dokunma esnasında frekans bantları üzerinde oluşan beyin haritalama gösterimi

Şekil 4.38.'de en başarısız katılımcıya ait beyin haritalama sonuçları görülmektedir. Sağ dil hareket yönü için delta frekans bandı içinde frontal ve arka-frontal bölge ile beraber T4 bölgesi üzerinde yüksek sinyal güç yoğunluğu gözlenmektedir. Yine aynı frekans bandı içinde sağ dil hareket yönü için merkez bölge (C3, Cz, C4) üzerinde orta düzeyde sinyal güç yoğunluğu görülmektedir. Sol dil hareket yönü için frontal bölge, arka-frontal bölge ve T3 bölgesi üzerinde yüksek sinyal güç yoğunluğu gözlenmiştir. Bununla beraber sol dil hareket yönü için delta frekansında orta düzeyde oluşan sinyal güç yoğunluğu merkez, parietal, T4, T5, T6 ve oksipital bölge üzerinde elde edilmiştir. Teta frekans bandı içinde sağ ve sol dil hareket yönü için frontal bölgede yüksek, arka-frontal bölgede orta düzeyde sinyal güç yoğunluğu görülmektedir. Buna ek olarak, sağ ve sol dil hareket yönü için alfa frekans bandında merkez, T5, T6 ve parietal bölge üzerinde orta düzeyde sinyal güç yoğunluğu elde edilmiştir. Düşünsel faaliyetlerin 6 sn boyunca veya kısmi zamanlı olarak oluşması katılımcı-8'de alfa frekansı içinde sinyal gücü oluşmasına sebep olduğu görülmektedir. En başarılı katılımcı (katılımcı-10) için beyin haritalama sonuçları Şekil 4.10.'da gösterilmektedir.




Şekil 4.39.En başarısız katılımcıya ait 6 sn boyunca sağ ve sol yanak duvarlarına dil temaslari ile oluşan sinyallerin ortalama sinyal gücü ve 19 kanal üzerinde deęişimini gösteren grafiksel gösterim

Şekil 4.39.'da en başarısız katılımcıya (katılımcı-8) ait ortalama sinyal gücü grafięi gösterilmiştir. Buna göre sağ dil hareket yönü içinde dördüncü altı saniyelik dil hareketleri ve sol dil hareket yönü içinde ise ikinci altı saniyelik dil hareketleri diğer altı saniyelik hareketlere göre EEG kanalları üzerinde farklı ve yüksek genliğe sahip bir örüntü oluşturmuştur. Katılımcının ritmik dil hareket ve dokunuşları yapmaktan uzak olması, bu durumun motivasyon eksikliğinden kaynaklandığı düşüncesini oluşturmaktadır. Beyin haritalama sonucunda (Şekil 4.38.) alfa frekans bandı üzerinde oluşan sinyal güç yoğunluęunun bu durumu teyit ettięi görülmektedir. Bununla beraber dördüncü altı saniyelik dil hareketleri hariç diğer sağ dil hareketleri için oluşan ortalama sinyal güçleri şöyledir: Fp2-Fp1 üzerinde $1500 \mu V^2$ - $2200 \mu V^2$, F7-F3-Fz-F4-F8 üzerinde $1000 \mu V^2$ - $2000 \mu V^2$, T4 üzerinde $500 \mu V^2$ - $3000 \mu V^2$ aralığında deęerler görülmektedir. İkinci altı saniyelik dil hareketleri hariç diğer sol dil hareketleri için oluşan ortalama sinyal güçleri şöyledir: Fp2-Fp1 üzerinde $1500 \mu V^2$ - $2200 \mu V^2$, F7-F3-Fz-F4-F8 üzerinde $1000 \mu V^2$ - $2000 \mu V^2$, T3 üzerinde $\leq 2000 \mu V^2$ aralığında deęerler hesaplanmıştır. En başarılı katılımcıya (katılımcı-10) ait ortalama sinyal gücü Şekil 4.12.'de gösterilmiştir. Buna göre katılımcı-8'de diğer başarısız katılımcılarda olduęu gibi sağ ve sol dil hareketleri için ortalama sinyal güç deęişimleri EEG kanalları üzerinde neredeyse simetrik olarak gözlenmiştir.



Şekil 4.40. En başarısız katılımcıya ait sürekli dalgacık dönüşümü zaman-frekans skalası (sol) ve glossokinetik potansiyel frekans spektrumu (sağ)

Şekil 4.40.'da en başarısız katılımcının (katılımcı-8), zaman-frekans skalasında ve frekans spektrumunda gözleendiği gibi 1-4 Hz (delta) ve 4-7 Hz (teta) frekanslarında ilk dört saniye içinde glossokinetik potansiyel sinyallerinin yüksek genlikte ($\leq 20 \mu\text{V}$) oluştuğu görülmektedir. Bununla beraber birinci ve ikinci saniyeler arasında alfa frekans bandı içinde (8-13 Hz) orta düzeyde genlik ($\leq 5 \mu\text{V}$) oluştuğu gözlenmiştir. En başarılı katılımcıya (katılımcı-10) ait zaman-frekans skalası ve frekans spektrumunda (Şekil 4.14.) görüldüğü gibi ritmik dil hareket ve dokunuşlarına bağlı üretilen GKP sinyalinin, delta frekans bandı içinde oluştuğu ve diğer frekans bantlarına dağılmadığı görülmüştür.



Şekil 4.41. En başarılı katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sol), en başarısız katılımcıya ait sağ dil hareketi esnasında oluşan GKP sinyali periodogram grafiği (sağ)

En başarılı katılımcıda dar frekans bandı içinde oluşum gösteren spektral güç yoğunluğu, en başarısız katılımcıda delta ve teta frekans bandında $\leq 120 \mu\text{V}^2/\text{Hz}$

oluşum göstermektedir (Şekil 4.41.). Bununla beraber, hesaplanan en yüksek spektral güç yoğunluğunun en başarılı katılımcıda yaklaşık iki kat yüksek olduğu gözlenmiştir.

4.1.9. Geleneksel sınıflandırıcılar için birleştirilmiş veri seti sonuçları

Tez çalışması içinde ortalama karesel kök (RMS), standart sapma (STD), varyans (VAR) ve ortalama değer (MV) özellik çıkarma yöntemleri için oluşturulmuş veri setleri aynı sınıf etiketlerini gösterecek şekilde birleştirilmiş ve makine öğrenmesi algoritmaları için sınıflandırma sonuç değerleri elde edilmiştir. Glossokinetik potansiyel tabanlı dil makine arayüzü çalışması içinde makine öğrenmesi sınıflandırma başarısını araştırmak ve arttırmak, engelli insanların arayüz modeli ile yardımcı teknolojileri daha güvenilir ve performansı yüksek bir şekilde kontrol etmesini sağlayabilir [9], [14]. Her özellik çıkarma metodu için 400×19 boyutunda veri seti oluşturulmuştur. Buna göre dört özellik çıkarma metodunda; ham veri seti için $(400 \times 19) \times 4$, 7 kanal-frontal bölge için $(400 \times 7) \times 4$, 11 kanal-frontal ve temporal bölge için $(400 \times 11) \times 4$ ve PCA yöntemi için 400×20 boyutunda veri setleri oluşturulmuş ve sınıflandırma başarı değerleri elde edilmiştir.

Tablo 4.56. RMS+STD+VAR+MV ham veri seti sonuçları (400×76)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|--------------|-------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 71,30 | 97,01 | 77,76 | 77,45 | 93,09 | 99,26 | 86,71 | 84,23 | 81,01 | 95,22 | 86,30 | SVM |
| SPEC | 75,75 | 97 | 79,07 | 78,8 | 94,15 | 99,17 | 84,85 | 86,6 | 80,49 | 96,11 | 87,20 | |
| SENS | 65,25 | 97,05 | 76,18 | 75,28 | 91,58 | 99,41 | 88,76 | 81,08 | 81,83 | 94,14 | 85,06 | |
| ITR | 0,135 | 0,806 | 0,235 | 0,230 | 0,638 | 0,937 | 0,435 | 0,371 | 0,299 | 0,723 | 0,481 | |
| ACC | 76 | 96,27 | 81,17 | 81,06 | 90,39 | 98,02 | 85,17 | 84,06 | 84,02 | 95,25 | 87,14 | LDA |
| SPEC | 79,29 | 96 | 83,12 | 79,64 | 90,36 | 99,17 | 82,66 | 86,98 | 88,30 | 96,54 | 88,21 | |
| SENS | 71,65 | 96,58 | 78,58 | 82,91 | 90,58 | 98,70 | 88,35 | 80,92 | 78,21 | 93,45 | 85,99 | |
| ITR | 0,205 | 0,770 | 0,302 | 0,300 | 0,544 | 0,920 | 0,394 | 0,367 | 0,366 | 0,724 | 0,489 | |
| ACC | 71,74 | 92,38 | 70,15 | 66,22 | 90,47 | 95,18 | 82,37 | 71,07 | 80,23 | 92,17 | 81,20 | KNN |
| SPEC | 84,23 | 88,78 | 84,4 | 73,30 | 92,74 | 96,43 | 79,53 | 71,98 | 72,73 | 96,38 | 84,05 | |
| SENS | 55,26 | 95,96 | 51,8 | 56,85 | 87,21 | 93,41 | 85,51 | 69,54 | 90,35 | 86,71 | 77,26 | |
| ITR | 0,141 | 0,611 | 0,121 | 0,077 | 0,546 | 0,721 | 0,328 | 0,132 | 0,283 | 0,604 | 0,356 | |

Tablo 4.56.'da en başarılı katılımcı (katılımcı-6) ve en başarısız katılımcı (katılımcı-4) için elde edilen en yüksek sınıflandırma doğruluk oranı değerleri sırasıyla %99,26 (SVM) ve 81,06 (LDA) olarak görülmektedir. Ortalama başarı için en yüksek doğruluk oranı %87,14 (LDA) olarak hesaplanmıştır. Birleştirilmiş veri seti sınıflandırma performansı RMS, STD, VAR, MV metotlarına ait ham veri seti sınıflandırma sonuçlarına kıyasla (MV'da en başarısız katılımcı hariç) daha yüksek sınıflandırma başarısı elde ettiği görülmektedir. Bununla beraber birleştirilmiş ham veri seti sonuçlarının MAV, MPV, SF ve PSD uygulanmış ham veri seti sonuçlarından da en başarılı katılımcı, en başarısız katılımcı ve ortalama başarı için yüksek olduğu görülmektedir. Buna ek olarak, 10 katılımcıya ait en yüksek ortalama başarı için birleştirilmiş ham veri seti doğruluk oranı sırasıyla; RMS'den 0,75 puan, STD'den 7,65 puan, VAR'dan 8,65 puan, MV'dan 3,75 puan, MAV'dan 2,31 puan, MPV'den 1,41 puan, SF'den 2,03 puan, PSD'den 3,24 puan daha yüksek elde edilmiştir.

Tablo 4.57. RMS+STD+VAR+MV ve temel bileşen analizi veri seti sonuçları (400×20)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|--------------|-------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 78,92 | 97,26 | 79,02 | 78,36 | 88,47 | 98,28 | 86,88 | 78,33 | 81,33 | 94,2 | 86,11 | SVM |
| SPEC | 80,2 | 97,5 | 77,83 | 77,01 | 88,32 | 98,73 | 84,5 | 77,21 | 80,07 | 95,22 | 85,66 | |
| SENS | 77,15 | 97,05 | 80,57 | 80,58 | 89,19 | 97,66 | 89,89 | 79,6 | 83,12 | 92,84 | 86,77 | |
| ITR | 0,257 | 0,819 | 0,259 | 0,247 | 0,484 | 0,875 | 0,439 | 0,246 | 0,305 | 0,681 | 0,461 | |
| ACC | 80,32 | 97,01 | 81,01 | 78,07 | 88,26 | 98 | 85,3 | 80,18 | 85,1 | 96,04 | 86,93 | LDA |
| SPEC | 82,43 | 95,5 | 78,24 | 76,65 | 86,18 | 97,88 | 81,32 | 82,98 | 75,29 | 98,7 | 85,52 | |
| SENS | 77,44 | 98,52 | 84,42 | 80,28 | 91,25 | 98,2 | 89,8 | 76,61 | 98,2 | 92,42 | 88,71 | |
| ITR | 0,285 | 0,806 | 0,299 | 0,241 | 0,478 | 0,859 | 0,398 | 0,282 | 0,393 | 0,760 | 0,480 | |
| ACC | 70,44 | 92,1 | 69,43 | 65,19 | 90,2 | 95,49 | 81,02 | 71,19 | 79,21 | 92,01 | 80,63 | KNN |
| SPEC | 82,88 | 88,74 | 83,29 | 72 | 93,32 | 96,35 | 78,79 | 70,99 | 72,08 | 96,09 | 83,45 | |
| SENS | 53,67 | 95,56 | 51,81 | 55,67 | 85,6 | 94,3 | 83,46 | 71,5 | 88,81 | 86,9 | 76,73 | |
| ITR | 0,124 | 0,602 | 0,112 | 0,068 | 0,537 | 0,735 | 0,299 | 0,134 | 0,263 | 0,598 | 0,347 | |

Tablo 4.57.'de görüldüğü üzere 76 kanallı özellik vektörü 20 temel bileşeni içeren özellik vektörüne PCA yöntemi kullanılarak azaltılmış ve sınıflandırma sonuç değerleri sağlanmıştır. En yüksek doğruluk oranı değerleri, katılımcı-6 için %98,28, katılımcı-4 için %78,36 ve ortalama başarı için %86,93 olarak hesaplanmıştır. Ham

veri setine kıyasla (Tablo 4.56.), en yüksek ortalama başarı doğruluk oranı %0,24 azalmıştır.

Tablo 4.58. RMS+STD+VAR+MV ve 7 kanal-frontal bölge veri seti sonuçları (400×28)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|--------------|-------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 78,15 | 97,03 | 77,49 | 68,66 | 84,8 | 98,03 | 86,25 | 70,68 | 75,16 | 92,27 | 82,85 | SVM |
| SPEC | 79,9 | 97,5 | 79,05 | 61,92 | 85,38 | 97,88 | 79,31 | 76,26 | 68,8 | 93,08 | 81,91 | |
| SENS | 75,71 | 96,54 | 75,53 | 77,87 | 84,04 | 98,23 | 94,19 | 63,36 | 83,71 | 90,9 | 84,01 | |
| ITR | 0,243 | 0,807 | 0,231 | 0,103 | 0,385 | 0,860 | 0,423 | 0,127 | 0,191 | 0,608 | 0,398 | |
| ACC | 78,15 | 95,02 | 78,1 | 68,03 | 84,35 | 97,24 | 87,04 | 71,02 | 74,01 | 92,03 | 82,50 | LDA |
| SPEC | 80,99 | 95 | 79,7 | 65,89 | 85,8 | 97,92 | 84,05 | 74,9 | 60,18 | 93,93 | 81,84 | |
| SENS | 74,76 | 95,06 | 76,1 | 70,64 | 82,4 | 96,44 | 90,29 | 65,7 | 92,94 | 89,57 | 83,39 | |
| ITR | 0,243 | 0,715 | 0,242 | 0,096 | 0,374 | 0,818 | 0,444 | 0,132 | 0,174 | 0,599 | 0,383 | |
| ACC | 70,54 | 93,24 | 67,07 | 64,90 | 82,5 | 93,34 | 81,42 | 61,60 | 73,49 | 91,23 | 77,93 | KNN |
| SPEC | 85,03 | 91,04 | 86,3 | 67,38 | 86,02 | 93,59 | 80,65 | 69,07 | 69,33 | 93,18 | 82,16 | |
| SENS | 51,32 | 95,31 | 42,48 | 61,74 | 77,23 | 92,98 | 82,39 | 51,86 | 79,25 | 88,44 | 72,30 | |
| ITR | 0,125 | 0,643 | 0,086 | 0,065 | 0,331 | 0,647 | 0,307 | 0,039 | 0,166 | 0,571 | 0,298 | |

Tablo 4.59. RMS+STD+VAR+MV ve 11 kanal-frontal ve temporal bölge veri seti sonuçları (400×44)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|-------|-------|--------------|-------|--------------|-------|-------|-------|-------|--------------|-----|
| ACC | 76,95 | 97,49 | 79,48 | 73,29 | 92,25 | 98,05 | 88,12 | 84,03 | 79,53 | 95,05 | 86,42 | SVM |
| SPEC | 78,48 | 97,5 | 78,68 | 69,71 | 93,71 | 98,32 | 84,94 | 84,37 | 79,18 | 96,09 | 86,10 | |
| SENS | 75,3 | 97,55 | 80,95 | 78,07 | 89,45 | 97,64 | 91,75 | 83,53 | 80,23 | 93,16 | 86,76 | |
| ITR | 0,221 | 0,831 | 0,268 | 0,163 | 0,607 | 0,861 | 0,474 | 0,366 | 0,269 | 0,716 | 0,478 | |
| ACC | 79 | 96,51 | 81,07 | 72,07 | 89,42 | 99,23 | 87,24 | 85,39 | 83,16 | 94,27 | 86,74 | LDA |
| SPEC | 81,09 | 96,5 | 79,98 | 73,53 | 89,93 | 99,57 | 84,52 | 85,24 | 76,99 | 96,16 | 86,35 | |
| SENS | 76,03 | 96,57 | 82,46 | 69,86 | 88,73 | 98,61 | 90,19 | 85,91 | 91,7 | 91,67 | 87,17 | |
| ITR | 0,259 | 0,782 | 0,300 | 0,146 | 0,513 | 0,935 | 0,449 | 0,400 | 0,346 | 0,683 | 0,481 | |
| ACC | 74,12 | 94,64 | 71,15 | 64,41 | 88,04 | 96,12 | 84,15 | 73,33 | 80,08 | 94,32 | 82,04 | KNN |
| SPEC | 87,18 | 92,37 | 84,03 | 66,55 | 87,85 | 97,08 | 81,6 | 72,32 | 72,27 | 97,18 | 83,84 | |
| SENS | 57,15 | 96,88 | 54,84 | 61,56 | 88,58 | 94,68 | 87,1 | 74,26 | 90,86 | 90,37 | 79,63 | |
| ITR | 0,175 | 0,698 | 0,133 | 0,061 | 0,472 | 0,763 | 0,369 | 0,163 | 0,280 | 0,686 | 0,380 | |

Tablo 4.58. ve Tablo 4.59.' da 7 kanal ve 11 kanal veri seti için hesaplanan 10 katılımcıya ait ortalama başarı sonuçlarında %82,85 (SVM) ve %86,74 (LDA) elde

edilmiştir. Ham veri seti sonuçlarına göre (Tablo 4.56.), 11 kanal veri setinde en yüksek doğruluk oranı için azalma değeri 0,4 puan olarak görülmektedir.

4.2. Konvolüsyonel Sinir Ağı İçin Sınıflandırma Performans Değerleri

Konvolüsyonel sinir ağına ait sınıflandırma performans değerleri tez çalışması içinde elde edilmiştir. Konvolüsyonel sinir ağı, glossokinetik potansiyel tabanlı dil makine arayüzünün performansını önemli ölçüde arttırmış, bireysel ve ortalama başarıda yüksek doğruluk oranı değerleri bulunmasını sağlamıştır. CNN’de ön işleme, özellik çıkarma, boyut indirgeme gibi sinyal işleme adımları gerekmemektedir. Buna karşılık eğitim verisi miktarında önemli ölçüde artışa ihtiyaç vardır. Bundan dolayı her katılımcı için kaydedilen 12 denemeye ait sinyaller görüntüye çevrilmiştir. Bu işlemde her katılımcı için 19 kanal ham veri sinyallerinden (1-D zaman serisi) her yön (sağ ve sol) için 456 adet olmak üzere toplamda 456×2 boyutunda karesel (2-D zaman serisi) ham görüntü seti elde edilmiştir. 11 kanal (frontal ve temporal bölge) ham veri sinyallerinden ise her yöne ait 264 adet karesel görüntü olmak üzere 264×2 boyutunda karesel görüntü seti oluşturulmuştur. Bununla beraber DWT yöntemi uygulanarak ham veri sinyallerinden delta ve teta frekans bantları çıkarıldıktan sonra oluşan sinyal üzerinden görüntüye çevirme işlemi yapılmıştır. Böylece her katılımcıya ait 456×2 karesel görüntü seti elde edilmiştir. Daha sonra delta ve teta frekans bandı çıkarılmış bu karesel görüntüler CNN’de ham görüntü seti sonucu ile kıyas edilmiştir. Hesaplanan sınıflandırma sonuç değerleri şunlardır:

Tablo 4.60. CNN için ham görüntü seti ve DWT uygulanmış görüntü seti sonuçları (456×2)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | |
|------|-------|--------------|-------|-------|--------|-------|-------|--------------|-------|-------|--------------|----------|
| ACC | 99,56 | 99,78 | 98,46 | 99,12 | 99,34 | 97,37 | 97,81 | 97,37 | 99,12 | 99,12 | 98,71 | HAM G.S. |
| SPEC | 99,12 | 99,56 | 99,12 | 99,56 | 99,56 | 98,68 | 97,81 | 95,61 | 99,12 | 100 | 98,82 | |
| SENS | 100 | 100 | 97,81 | 98,68 | 99,12 | 96,05 | 97,81 | 99,12 | 99,12 | 98,25 | 98,60 | |
| ITR | 0,959 | 0,977 | 0,886 | 0,927 | 0,943 | 0,824 | 0,847 | 0,824 | 0,927 | 0,927 | 0,904 | |
| ACC | 98,46 | 98,46 | 96,05 | 98,25 | 99,12 | 95,39 | 95,61 | 95,83 | 95,83 | 97,15 | 97,02 | DWT G.S. |
| SPEC | 99,12 | 99,12 | 96,93 | 98,68 | 100,00 | 96,49 | 98,68 | 95,18 | 96,93 | 96,93 | 97,81 | |
| SENS | 97,81 | 97,81 | 95,18 | 97,81 | 98,25 | 94,30 | 92,54 | 96,49 | 94,74 | 97,37 | 96,23 | |
| ITR | 0,886 | 0,886 | 0,760 | 0,873 | 0,927 | 0,730 | 0,740 | 0,750 | 0,750 | 0,813 | 0,811 | |

G.S. (Görüntü Seti)

Tablo 4.60.'da CNN için ham görüntü seti sonuçları ve DWT uygulanmış görüntü seti sonuçları görülmektedir. Buna göre, ham görüntü seti sonuçlarında, en başarılı katılımcı (katılımcı-2) için elde edilen doğruluk oranı %99,78 olarak gözlenmiştir. En başarısız katılımcı (katılımcı-8) ve 10 katılımcıya ait ortalama başarı doğruluk oranları ise %97,37 ve %98,71 olarak elde edilmiştir. Görüldüğü üzere CNN, ham görüntü seti için, geleneksel sınıflandırıcılara kıyasla hem bireysel hem de ortalama başarıda çok daha iyi performans göstermiştir. Geleneksel sınıflandırıcılarda da (RMS, MAV, MPV ve SF özellik çıkarma metotları) bireysel sınıflandırma performansı (en başarılı katılımcı) için %97'ye varan doğruluk oranları görülmüştür. Fakat ham görüntü seti sonuçlarında en başarısız katılımcılar için geleneksel sınıflandırıcılar ile %67-%88 aralığında bulunan doğruluk oranları, CNN için %97-%99 aralığında elde edilmiştir. Yine geleneksel sınıflandırıcılarda ham veri seti sonuçlarında 10 katılımcıya ait ortalama başarı %78-%86 aralığında doğruluk oranına sahip iken, CNN için ham görüntü seti doğruluk oranı %98,71 olarak hesaplanmıştır. Buna ek olarak CNN, birleştirilmiş ham veri seti sonuçlarına (Tablo 4.56.) kıyasla da daha yüksek sonuçlar üretmiştir.

DWT yöntemi uygulanmış görüntü setinde sınıflandırma performans değerleri; katılımcı-2 için %98,46, katılımcı-8 için %95,83 ve ortalama başarı için ise %97,02 olarak hesaplanmıştır. DWT uygulanmış görüntü setinde, ham görüntü seti sonuçlarına kıyasla daha az başarılı sonuçlar üretilmiştir. Bu durumda DWT'nin, 1-D zaman serisi sinyallerinde delta ve teta bandı çıkarılması esnasında var olan orijinal sinyale ait örüntüyü bozduğu söylenebilir. Böylece CNN'in, ham görüntü seti sinyallerinde daha iyi performans gösterdiği ve ön işleme yöntemlerine gereksinim duymadığı söylenebilir [111]. Geleneksel sınıflandırıcılarda performans artışı sağlayabilen DWT yöntemi CNN'de performans azalışına sebep olmuştur.

Tablo 4.61. CNN için 11 kanal-frontal ve temporal bölge görüntü seti sonuçları (264×2)

| | SB1 | SB2 | SB3 | SB4 | SB5 | SB6 | SB7 | SB8 | SB9 | SB10 | Ort. | 11 Kanal G.S. |
|------|-------|------------|-----|-----|-------|-------|-------|--------------|-------|------|--------------|---------------|
| ACC | 98,61 | 100 | 100 | 100 | 99,24 | 93,56 | 95,08 | 92,05 | 95,45 | 100 | 97,40 | |
| SPEC | 100 | 100 | 100 | 100 | 100 | 94,70 | 96,21 | 92,42 | 93,94 | 100 | 97,73 | |
| SENS | 97,22 | 100 | 100 | 100 | 98,48 | 92,42 | 93,94 | 91,67 | 96,97 | 100 | 97,07 | |
| ITR | 0,894 | 1 | 1 | 1 | 0,936 | 0,655 | 0,716 | 0,599 | 0,733 | 1 | 0,853 | |

G.S. (Görüntü Seti)

Tablo 4.61. 'de 11 kanal-frontal ve temporal bölge görüntü seti için CNN'de üretilen sınıflandırma sonuç değerleri görülmektedir. Buna göre, en başarılı katılımcı için %100 sınıflandırma doğruluğu elde edilmiştir. En başarısız katılımcı ve ortalama başarı için ise %92,05 ve %97,40 doğruluk oranları hesaplanmıştır. Ham görüntü setine kıyasla (Tablo 4.60.), 11 kanal görüntü setinde 10 katılımcı arasında 4 katılımcı için %100 doğruluk oranı elde edilmiştir. En başarısız katılımcı ve ortalama başarı için doğruluk oranları sırasıyla 5,32 puan ve 1,31 puan azaldığı görülmektedir.

4.3. Geleneksel Sınıflandırıcılar İçin Hesaplama Süreleri ve Saçılım Grafiği

Glossokinetik potansiyel tabanlı dil makine arayüzünün gerçek zamanlı kullanımında yüksek doğruluk oranı, güvenirlilik kavramlarının yanında sistemin hızı da önemli bir parametre olarak görülebilir [1], [9]. Bu noktada sinyal işleme adımlarının süresini gösteren değerler geleneksel makine öğrenmesi algoritmaları olan sınıflandırıcılar için tez çalışması içinde elde edilmiştir.

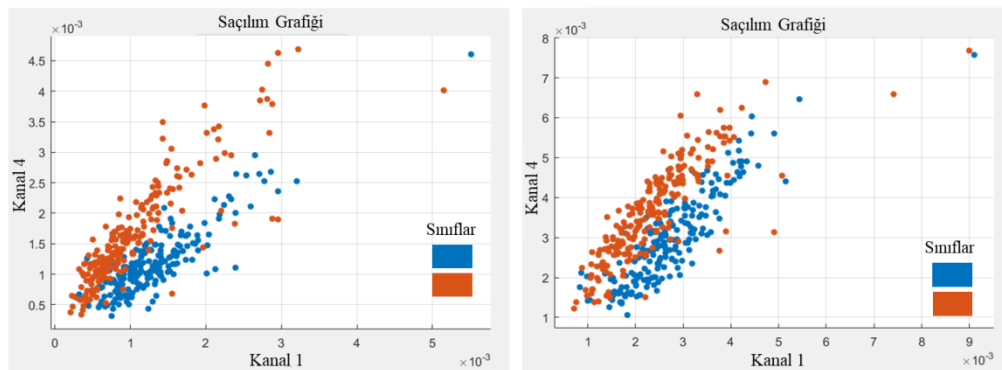
Tablo 4.62.'de geleneksel sınıflandırıcılar için hesaplama süreleri gösterilmektedir. Buna göre, RMS metodu için özellik çıkarma ve sınıflandırma süresi en az ve en fazla olan makine öğrenmesi algoritması, LDA (0,0016 sn) ve MLNN (0,1483 sn) olarak görülmektedir. PSD metodu için özellik çıkarma ve sınıflandırma süresi en az ve en fazla olan makine öğrenmesi algoritması, SVM (0,8936 sn) ve MLNN (1,1002 sn) olarak hesaplanmıştır. MAV metoduna ait özellik çıkarma ve sınıflandırma süresinin, DT (0,0014 sn) ile en kısa süreyi aldığı gözlenmiştir.

Tablo 4.62. Geleneksel sınıflandırıcılar için hesaplama süreleri (sn)

| | MLNN | PNN | LDA | SVM | DT | kNN | |
|------------|--------|--------|--------|--------|--------|--------|-----|
| Ö.Ç.Z. | 0,0836 | 0,0779 | 0,0547 | 0,0670 | 0,0725 | 0,0772 | RMS |
| S.Z. | 0,1463 | 0,0019 | 0,0002 | 0,0157 | 0,0337 | 0,0173 | |
| Ö.Ç.Z+S.Z. | 0,1483 | 0,0038 | 0,0016 | 0,0174 | 0,0356 | 0,0193 | |
| Ö.Ç.Z. | 37,92 | 38,22 | 36,72 | 35,70 | 37,40 | 38,02 | PSD |
| S.Z. | 0,1522 | 0,0017 | 0,0042 | 0,0011 | 0,0039 | 0,0019 | |
| Ö.Ç.Z+S.Z. | 1,1002 | 0,9572 | 0,9222 | 0,8936 | 0,9389 | 0,9524 | |
| Ö.Ç.Z+S.Z. | 0,3330 | 0,0214 | 0,0057 | 0,0028 | 0,0014 | 0,0021 | MAV |

Ö.Ç.Z. (Özellik Çıkarma Süreleri), S.Z. (Sınıflandırma Süreleri)

Tablo 4.62.'de hesaplama süresine ait sonuç değerleri, en başarılı katılımcılardan birisi olan katılımcı-2'nin ham veri seti kullanılarak bulunmuştur. Hesaplama sonuç değerleri, 1-kat çapraz doğrulama ile test örneklerinin ortalaması kullanılarak Matlab (lisans no: 834260) programında Intel Core I5-7200 U CPU (2,5 GHz), Windows 10, 64 bit ve 8 GB RAM'e sahip bir dizüstü bilgisayar üzerinde gerçekleştirilmiştir. CNN ile ilgili veri işleme sonuçları ise Matlab (lisans no: 40692431) programında Intel Core I7-6700 HQ CPU (2,6 GHz), Windows 10, 64 bit ve 16 GB RAM'e sahip bir dizüstü bilgisayar üzerinde gerçekleştirilmiştir.



Şekil 4.42. Katılımcı-2'ye ait MAV için ham veri seti üzerinden saçılım grafiği (sol), katılımcı-2'ye ait MPV için ham veri seti üzerinden saçılım grafiği (sağ) (Mavi: Sağ sınıfı, Turuncu: Sol sınıfı göstermektedir)

MAV ve MPV metotları için özellik çıkarma işleminden sonra oluşan ham veri seti üzerinden geleneksel sınıflandırma sonuçları içinde en başarılı katılımcılardan olan

katılımcı-2'ye ait saçılım grafiđi Şekil 4.42.'de gösterilmiştir. Görüldüğü üzere ham veri setine ait dağılım üzerinden kanal-1 ve kanal-4 için 1-D yön sınıflandırması (sağ ve sol) ayırt edilebilmektedir. Saçılım grafiđi üzerinde görülen ham veri seti üzerinde yalnızca normalizasyon işlemi uygulanmış ve filtreleme işlemi yapılmamıştır.

BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında engelli insanların yardımcı teknolojileri doğal, kullanımı kolay, güvenilir, yüksek performanslı ve hızlı bir şekilde kontrol etmesini sağlayabilecek glossokinetik potansiyel tabanlı dil makine arayüzü geliştirilmeye çalışılmıştır. Amaçlanan arayüz sistemi içinde ayırık dil hareket ve dokunuşlarına bağlı olarak üretilen glossokinetik potansiyel sinyali, kafa derisi üzerinden invazif olmayan EEG ölçüm sistemi kullanılarak alınmış ve sinyal işleme adımları ile 1-D yön kontrolü için sınıflandırma işlemi yapılmıştır. Sağ ve sol yanak duvarlarına dil ile ritmik ve seri hareketler vasıtasıyla dokunarak oluşan GKP sinyali, sinyal ön işleme, özellik çıkartma ve boyut azaltmanın ardından makine öğrenmesi algoritmaları olan sınıflandırıcılar ile sınıflandırılmış ve performans değerleri karşılaştırılarak ortaya konulmuştur (Şekil 1.1.).

Bilindiği üzere dil kompleks kas gruplarına sahip, hareketliyi yüksek, kozmetik açıdan avantajlı ve çok az yorulan bir organdır. Hipoglosal kranial sinirler vasıtasıyla doğrudan beyne bağlanması sebebiyle dil, genellikle omurilik yaralanmaları ve sinir-kas hastalıklarının çoğundan kaçabilmektedir. Böylece, yüksek seviyeli omurilik yaralanmaları olan engelli insanların bile dil kontrol yeteneklerini koruyabildikleri görülmektedir. Glossokinetik potansiyel yanıtları olarak da isimlendirilen glossokinetik potansiyel sinyalleri, EEG sinyalleri üzerinden de ölçülebilen, nadir olarak kullanımı literatürde görülen bir elektriksel sinyaldir ve EEG üzerindeki artefakt olarak da tanımlanabilmektedir. GKP sinyalleri, delta ve teta frekans bandı içinde EEG sinyallerine göre daha yüksek genlikte olduğundan, düşünsel frekans bantları (alfa ve beta) ile kesişimi olmamaktadır veya kesişimi çok az görülmektedir. Böylece GKP tabanlı TMI daha az odaklanma ve düşünsel efor gerektirdiğinden, dışardan gelen uyarılar veya içsel düşüncelerden EEG tabanlı BCI sistemlerinde olduğu kadar etkilenmediği görülmüştür. Bu nedenden ötürü kontrol performansının daha dayanıklı olması sağlanmıştır. Bu da GKP tabanlı TMI'nın engelli insanlara

yüksek performansın yanında güvenilir bir kontrol ve iletişim kanalı sunabilmesi demektir.

Bu tez çalışmasına 10 sağlıklı birey gönüllü olarak katılmıştır. Katılımcılardan, belirlenen deneysel düzenekler (Şekil 2.18.) içinde EEG ölçüm prosedürüne göre ölçümler alınmıştır. Bu kayıtlarda dil hareket ve yanak duvarlarına dokunuşları süresince kafa derisi üzerinde değişim gösteren glossokinetik potansiyel sinyallerine ait 1-D kontrol için uzamsal örüntü elde edilmiştir. 98 sn süren kayıtlar, deneme olarak isimlendirilmiş ve toplamda her bir katılımcı için 12 deneme kaydı alınmıştır. Böylece 6 sn'lik 4 sağ ve 4 sol dil hareketleri 5 sn'lik dinlenmeler ile kaydedilmiş ve 1024 Hz örnekleme frekansına göre sayısallaştırılmıştır. Her katılımcıya ait 19 kanallı ölçümde her deneme için özellik çıkarma işleminden sonra oluşan ham veri seti 400×19 boyutunda hesaplanmıştır.

7 kanal ve 11 kanal için oluşturulan veri setleri frontal ve frontal+temporal lob bölgelerini içeren elektrot kanalları için oluşturulmuş ve sınıflandırma sonuç değerleri elde edilmiştir. Modern beyin makine arayüzü tasarımında ve motor korteks bölgelerini aydınlatmak için yerel alan potansiyellerini (LFPs) ve kortika-masküler sinyallerini ölçmek önem arz etmektedir. Böylece bilgi sistem mühendisliği, istatistiksel sinyal işleme, makine öğrenmesi, kontrol teorisi ve bilgi teorisi gibi birçok araştırma alanının çoklu disiplin ile bir arada kullanılmasına gereksinim vardır [9], [124]. Bu açıdan frontal ve frontal+temporal lob bölgeleri ve GKP üzerinden ölçülebilen dil hareketlerinin sınıflandırma sonuç değerleri, modern beyin bilgisayar arayüzü veya dil makine arayüzü tasarımlarının yanında hesaplamalı sinirbilimine ait bilgiler de verebilir [3]. Frontal ve frontal+temporal loblara ait bölgelerde glossokinetik potansiyel sinyallerinin yoğun bir şekilde maruz kaldığı ve/veya bu bölgelerin dil hareket süreçlerine katkıda bulunduğu düşünülmektedir. Böylece bu bölgeleri içeren sinyal kanallarına ait sınıflandırma sonuç değerlerinin bütün kafa derisi üzerindeki sinyal kanallarına kıyasla kayda değer sonuçlar üretebildiği görülmüştür [3], [9], [23]. Özellikle frontal+temporal bölgeleri içeren 11 kanal veri setine ait ortalama başarı için en yüksek sınıflandırma doğruluk oranı değerlerinin 19 kanallı içeren ham veri setlerine oldukça yakın (1-3 puan arasında) sonuç değerleri

ürettiği gözlenmiştir. Frontal ve frontal+temporal bölgeler üzerinde oluşan yüksek sinyal güç yoğunlukları özellikle en başarılı katılımcılara ait beyin haritalama grafiklerinde de görülebilmektedir (Şekil 2.2., Şekil 2.10. ve Şekil 2.18.). Böylece glossokinetik potansiyel tabanlı dil makine arayüzü sistemi için kafa derisi üzerinde daha az sayıda elektrot kullanımı, önemli derece yüksek performans ve güvenirliliğin yanı sıra daha portatif, giyilebilir, kullanımı kolay ve hareket derecesi yüksek arayüz sistemlerinin geliştirilmesine imkan verebilir [8], [9].

Tez çalışması içinde beyin haritalama sonuçlarında beyin yarımküreleri üzerinde oluşan sinyal güç yoğunluklarının, dil hareket ve sağ-sol yanak duvarı dokunuş yönüne göre simetrik olarak oluştuğu gözlenmiştir (Şekil 2.2., Şekil 2.10. ve Şekil 2.18.). Dilin ucu, dil köküne göre negatif yüklü olduğundan yanak duvarlarına dokunuşları sırasında dokunma yüzeyinde potansiyel azalırken, diğer yüzey ve beyin yarımküresi üzerinde potansiyel artmaktadır. Böylece, Nam, Y. ve ark. yaptıkları çalışmalarda dil hareket ve dokunuşlarına bağlı olarak oluşan GKP sinyallerinin beyin yarımküresi üzerinde simetrik olmayan bir oluşum gösterdiklerini belirtmişlerdir [14]. Yine aynı çalışma grubunun fonetik sesler üzerine yaptıkları diğer bir çalışmada, retrofleks sesinin çıkartılması esnasında dilin oldukça büküldüğünü ve frontal bölge üzerinde yüksek bir sinyal güç değişimi oluşturduğunu belirtmişlerdir [25]. Böylece tez çalışması içinde deneme kayıtları süresince dilin, güçlü, hızlı, ritmik ve ayrık hareket ve yanak duvarı üzerine dokunuşlarının simetrik olmayan oluşumu bastırıldığı düşünülmektedir. Bununla beraber aynı çalışma grubu, GKP sinyallerinin simetrik olmayan durumunu ortaya çıkarmak için referans noktasını kafa derisinin merkezine alarak kulak üzerinden ölçüm almışlardır. Buna ek olarak dil, 6 sn'lik süre boyunca sağ-ön-sol gibi sürekli hareket ve tek dokunuşlar yaparak simetrik olmayan durumun oluşmasını sağlamışlardır. Fakat tez çalışması içinde 6 sn'lik süre boyunca aynı yöne ait aynı yanak duvarına birçok ayrık ve ritmik hareket ve dokunuşlar gerçekleştirilmiştir. Böylece yalnızca elektrot yerleşiminin değil aynı zamanda araştırmacıların yaptıkları deneysel düzenin de tez çalışması içinde kullanılan deneysel düzenden farklı olduğu görülmektedir. Tez çalışması içindeki bütün bu farkların beyin haritalama sonuçlarında simetrik bir durum yarattığı düşünülmektedir [3].

Beyin bilgisayar arayüzü çalışmalarında önemli problemlerden birisi de sistem performansının her zaman aynı olmaması ve çoklu-katılımcı, çoklu-deneme ve oturumlar arası farkların oluşmasıdır. Bu da sistemin dayanıksız veya güvenilir olmamasına sebep olmaktadır. Literatürde deneme artışı (Over-Trial) ve eğitim etkisi (Training Effect) diye isimlendirilen katılımcıların birçok deneme ve/veya eğitim yapmasının sınıflandırma performanslarını arttırdığı ve bu durumun motivasyon kadar önemli olduğu vurgulanmaktadır [3]. Her denemenin ve eğitimin katılımcının sınıflandırma performanslarını iyileştirecek şekilde beyin aktivitesini zorladığını belirtmişlerdir. Bu kavramlar aktarım öğrenmesi (transfer learning) olarak isimlendirilmiştir [8]. Benzer durumun tez çalışması esnasında da gözlemlendiği görülmektedir. Buna göre tez çalışması içinde her katılımcıya ait 12 deneme içinden en başarılı veri seti seçilmiş ve ilgili sonuç değerleri bu veri setlerine göre elde edilmiştir. Veri seti seçilmesi esnasında katılımcılar ve denemeler arası performans farklılıklarına ait durum Tablo 2.2.'de gösterilmiştir. Böylece katılımcı-3 ve katılımcı-9 hariç diğer sekiz katılımcı için seçilen veri setlerinin deneysel düzen-2 ve deneysel düzen-3 içinden seçildiği gözlenmiştir. Bu bulgular ışığında deneme artışının katılımcılar için olumlu performans etkisi yarattığı söylenebilir. Yine de GKP tabanlı TMI tez çalışmasının geleneksel EEG tabanlı BCI sistemlerine göre daha az eğitim zamanı gerektirdiği ve BCI sistemlerinin getirdiği yüksek bilinçsel efor gerektirmediği görülmüştür.

Çalışmanın sinyal işleme basamağına ait sınıflandırma işleminde geleneksel makine öğrenmesi algoritmalarından SVM, LDA, MLNN, PNN, kNN ve DT faydalanılmıştır. Bu sınıflandırma algoritmaları için zaman alanı özellik çıkarma metotlarından RMS, STD, VAR, MV, MAV, MPV ve SF kullanılmıştır. Buna ek olarak frekans alanı özellik çıkarma metotlarından PSD'ye ait sonuçlar da elde edilmiştir. Boyut azaltma yöntemlerinden PCA ve ICA için sınıflandırma işlemlerine ait sonuç değerleri de özellikle ham veri setine ait sınıflandırma başarıları ile kıyas edilmiştir. Bununla beraber, DWT yöntemi ile GKP sinyallerinin yoğun olarak oluştuğu delta ve teta frekans bantları kaydedilen ham veri sinyallerden ayrılmış ve sınıflandırma sonuç değerleri her özellik çıkarma metodu için hesaplanmıştır. Son yıllarda yüksek başarı oranlarına sahip makine öğrenmesi algoritmaları içinde derin

öğrenme metotlarından birisi olan CNN kullanılmış ve 1-D yön bilgisine ait sınıflandırma sonuç değerleri elde edilmiştir. Optimal makine öğrenmesi algoritmasını ve özellik çıkarma metodunu bulmak var olan sinyal işleme problemlerinin başında gelmektedir [8], [81]. Bu sebeple sonuçların yorumlanmasında ve grafiksel gösterimlerde her özellik çıkarma metodu için ham veri setindeki en başarılı katılımcı, en başarısız katılımcı ve 10 katılımcıya ait ortalama başarı değerlerine yer verilmiştir. Benzer şekilde CNN’de ham görüntü seti sonuç değerlerine göre en başarılı katılımcı, en başarısız katılımcı ve ortalama başarı değerleri dikkate alınarak değerlendirmeler yapılmıştır.

Sonuçların değerlendirilmesinde gözlenen önemli bir nokta en başarılı katılımcının yüksek motivasyona sahip olduğu ve dil hareket ve yanak duvarına dokunuşlarını ayırık, ritmik ve olabildiğince hızlı bir şekilde yaparken, en başarısız katılımcının deneysel düzene ve talimatlara yeterince odaklanmadığı, özellikle ayırık ve ritmik dil hareketlerini yeterince iyi yerine getiremedikleri gözlenmiştir. Böylece en başarısız katılımcılar için kabul edilebilir sonuçlar elde edildiği görülmüştür. Buna göre geleneksel makine öğrenmesi algoritmaları için; sekiz özellik çıkarma metodu arasında ham veri setine göre 10 katılımcıya ait ortalama başarıda en yüksek ve en düşük doğruluk oranı değerleri sırasıyla RMS’de %86,39 (MLNN) ve VAR’da %78,49 (SVM) olarak hesaplanmıştır. Bununla beraber çekirdek tabanlı makine öğrenmesi algoritmalarından olan SVM ve LDA, RMS ve PSD hariç altı özellik çıkarma metodunda en yüksek doğruluk oranı değerlerini elde etmişlerdir. Ham veri seti sınıflandırma sonuç değerleri arasında en yüksek doğruluk oranı değeri MPV’de %97,25 (SVM) olarak bulunmuştur. Yine ham veri seti sonuçlarına göre sekiz özellik çıkarma metodu içinde bütün katılımcılar arasında, katılımcı-2 dört kez en başarılı katılımcı olduğu gözlenmiştir. Katılımcı-6 ve katılımcı-10 ise ikişer kez en başarılı katılımcılar olarak bulunmuştur. Bununla beraber yine ham veri seti sonuçlarına göre sekiz özellik çıkarma metodu içinde bütün katılımcılar arasında katılımcı-4 ve katılımcı-7 ikişer kez en başarısız katılımcı olarak belirlenmiştir.

Tez çalışması içinde SVM ve LDA için RMS, MAV ve PSD’de hesaplanan aynı boyuttaki (400×12) temel bileşen analizi ve bağımsız bileşen analizine ait veri seti

sonuçlarında (Tablo 4.4., Tablo 4.26. ve Tablo 4.49.), ICA'nın PCA'dan doğruluk oranına göre ortalama başarıda 1-3 puan arası daha başarılı olduğu görülmektedir. Bu duruma uymayan yalnızca RMS'de SVM sonucu olduğu gözlenmektedir. Son yıllarda ICA, EEG tabanlı BCI sistemlerinde özellik azaltma ve kaynak komponentlerini ortaya çıkarmada yaygın bir şekilde kullanılmaktadır [87]. PCA normal dağılıma sahip veri setleri üzerinde faydalı olurken, ICA veri dağılımının normal dağılımdan uzaklaştığı veri setleri üzerinde sınıflandırma performanslarını arttırmaktadır. Böylece bu iki yöntemin uygulanmasının veri dağılımı hakkında da bilgi verdiği görülmektedir. EEG sinyalleri bütünüyle ne Gaussal olmayan (ICA) bir yapıya sahiptir ne de ilişkisel olmayan (PCA) bir yapıya sahiptir [125], [126]. Aynı durumun GKP sinyalleri içinde geçerli olduğu düşünülebilir. Böylece ICA ve PCA sınıflandırma sonuç değerlerinin birbirlerine oldukça yakın olduğu fakat ICA'nın özellikle başarısız katılımcılara ait veri setleri üzerinde boyut azaltma ve sınıflandırma performanslarında belirli bir seviyede daha iyi olduğu görülmüştür. Bu durumun sebebi olarak daha başarısız katılımcılara ait GKP sinyal verilerinin daha Gaussal olmayan bir veri dağılımına sahip olduğu ve yüksek oranda üst üste binmiş kortikal aktivelerin örüntülerinden kaynaklandığı söylenebilir [125].

GKP tabanlı TMI tez çalışmasında konvolüsyonel sinir ağına ait sınıflandırma performans değerlerinin geleneksel makine öğrenmesi algoritmalarına kıyasla oldukça yüksek olduğu görülmektedir (Tablo 4.60. ve Tablo 4.61.). Ham veri setine göre bireysel sınıflandırma performansları içinde dahi en başarısız katılımcılarda yüksek (%97-%99) sınıflandırma doğrulukları elde edilmesi ve CNN'in ön işleme, özellik çıkarma, boyut azaltma gibi sinyal işleme adımlarını gerektirmemesi GKP tabanlı TMI tez çalışması için oldukça önemlidir. Buna ek olarak sistemin her daim performansının aynı olmaması, çoklu-katılımcı, çoklu-deneme ve oturumlar arası farkların oluşması gibi problemlerin, CNN ile en aza indirgenmiş olacağı görülmektedir (10 katılımcı için ortalama doğruluk oranı %98,71). Böylece gerçek zamanlı uygulanabilecek gelecek çalışmalar için; engelli bireyler, yaşam kalitelerini arttıracak yardımcı teknolojileri CNN uygulanan GKP tabanlı TMI ile oldukça yüksek performansta yalnızca basit dil hareket ve dokunuşları vasıtasıyla rahatsızlık vermeyen, doğal ve güvenilir bir sistem ile 1-D olarak kontrol edebileceklerdir.

BCI çalışmalarında, ayırık düşünsel aktiviteler ve kısa süreli cevap zamanı, örüntü tanımada tatmin edici tanıma doğruluğu sağlayabilmektedir [127], [128]. Bu sebeple tez çalışması içinde dil makine arayüzü için, kısa süreli ve ayırık dil hareketleri gerçekleştirilmiştir. Uzun süren yüksek planlama zamanı ve esnek deneme sürelerinin BCI ve HMI çalışmalarında katılımcıların içsel düşüncelerini sonuç odaklı olarak düzenlemelerine izin verdiği ve bu durumun önemli katkılar sağlayabileceği belirtilmiştir [3]. Gelecek çalışmalarda bu kavramların kullanılabilmesi düşünülmektedir. Sonuç olarak GKP tabanlı TMI tez çalışmasında glossokinetik potansiyel sinyalleri üzerinden elde edilen 1-boyutlu kontrol örüntülerinin makine öğrenmesi algoritmalarına ve sinyal işleme yöntemlerine ait performans değerlerinin araştırılması yoluyla karşılaştırılması literatürdeki ilk çalışma olmuştur. Bununla beraber dilin kendisine ait avantajları ve GKP sinyaline ait özgün değerler, yüksek sınıflandırma performans değerleri ile yeni dil makine arayüzü ve beyin bilgisayar arayüzü yaklaşımlarını ortaya çıkarabileceği düşünülmektedir. Böylece bu tez çalışmasının, donanım tabanlı dil makine arayüzü çalışmalarının yanında geleneksel EEG tabanlı BCI sistemlerine de katkılar sunması ve/veya alternatif olması beklenmektedir.

KAYNAKLAR

- [1] Huo X., Ghovanloo M., Tongue drive: A wireless tongue-operated means for people with severe disabilities to communicate their intentions. *IEEE Commun. Mag.*, 50(10):128-135, 2012.
- [2] Jafari A., Buswell N., Ghovanloo M., Mohsenin T., A Low-Power Wearable Stand-Alone Tongue Drive System for People with Severe Disabilities. *IEEE Trans. Biomed. Circuits Syst.*, 12(1):58-67, 2018.
- [3] Gorur K., Bozkurt M.R., Bascil M.S., Temurtas F., Glossokinetic potential based tongue-machine interface for 1-D extraction. *Australas. Phys. Eng. Sci. Med.*, 41(2):379-391, 2018.
- [4] Rechy-Ramirez E.J., Hu H., Bio-signal based control in assistive robots: a survey. *Digit Commun. Networks*, 1(2):85-101, 2015.
- [5] Bascil M.S., Tesneli A.Y., Temurtas F., Multi-channel EEG signal feature extraction and pattern recognition on horizontal mental imagination task of 1-D cursor movement for brain computer interface. *Australas. Phys. Eng. Sci. Med.*, 38(2):229-239, 2015.
- [6] Bascil M.S., Tesneli A.Y., Temurtas F., Spectral feature extraction of EEG signals and pattern recognition during mental tasks of 2-D cursor movements for BCI using SVM and ANN. *Australas. Phys. Eng. Sci. Med.*, 39(3):665-676, 2016.
- [7] Saha S., Iftekhar K., Ahmed U., Evidence of Variabilities in EEG Dynamics During Motor Imagery-Based Multiclass Brain-Computer Interface. *IEEE Trans. NEURAL Syst. Rehabil. Eng.*, 26(2):371-382, 2018.
- [8] Jayaram V., Alamgir M., Altun Y., Grosse-wentrup M., Transfer Learning in Brain-Computer Interfaces. *IEEE Comput. Intell. Mag.*, 20-31, 2016.
- [9] Gorur K., Bozkurt M.R., Bascil M.S., Temurtas F., Glossokinetic potential based tongue-machine interface for 1-D extraction Using Neural Networks. *Biocybern. Biomed. Eng.*, 38(3):745-759, 2018.

- [10] Reuderink B., Poel M., Nijholt A., The Impact of Loss of Control on Movement BCIs. *IEEE Trans. NEURAL Syst. Rehabil. Eng.*,19(6):628-637, 2011.
- [11] Sketch S.M., Member S., Deo D.R., Menon J.P., Okamura A.M., Design and Experimental Evaluation of a Skin-Stretch Haptic Device for Improved Control of Brain-Computer Interfaces. In: *IEEE International Conference on Robotics and Automation (ICRA) Washington State Convention Center Seattle, Washington, May 26-30, 272-277, 2015.*
- [12] Mimche S., Ahn D., Kiani M., Elahi H., Murray K., Easley K., Sokoloff A., Ghovanloo M., Tongue implant for assistive technologies: Test of migration, tissue reactivity and impact on tongue function. *Arch Oral Biol.*, 71:1-9. 2016.
- [13] Nam Y., Zhao Q., Cichocki A., Choi S., Tongue-Rudder: A Glossokinetic-Potential-Based Tongue-Machine Interface. *IEEE Trans. Biomed. Eng.*, 59(1):290-299, 2012.
- [14] Nam Y., Koo B., Cichocki A., Choi S., Glossokinetic Potentials for a Tongue-Machine Interface. *IEEE Syst. Man., Cybern. Mag.*, 2(1):6-13, 2016.
- [15] Struijk L.N.S.A., Bentsen B., Gaihede M., Lontis E.R., Error-Free Text Typing Performance of an Inductive Intra-Oral Tongue Computer Interface for Severely Disabled Individuals. *IEEE Trans. NEURAL Syst. Rehabil. Eng.*, 25(11):2094-2104, 2017.
- [16] Ghovanloo M., Tongue Operated Assistive Technologies. In *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France August, 23-26, 4376-4379, 2007.*
- [17] Vuillerme N., Chenu O., Pinsault N., Fleury A., Demongeot J., Payan Y., Pressure sensor-based tongue-placed electrotactile biofeedback for balance improvement - Biomedical application to prevent pressure sores formation and falls. In: *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France, August, 23-26, 6113-6116, 2007.*
- [18] Tang H., Beebe D.J., An Oral Tactile Interface for Blind Navigation. *IEEE Trans. NEURAL Syst. Rehabil. Eng.*, 14(1):116-123, 2006.

- [19] Nam Y., Koo B., Cichocki A., Choi S., GOM-Face: GKP, EOG, and EMG-Based Multimodal Interface With Application to Humanoid Robot Control. *IEEE Trans. Biomed. Eng.*, 61(2):453-462, 2014.
- [20] Li J., Zhang Z., He H., Hierarchical Convolutional Neural Networks for EEG-Based Emotion Recognition. *Cogn. Comput.*, 10(2):368-380, 2018.
- [21] Klass, D., Bickford, R.G., Glossokinetic potentials appearing in the electroencephalogram. *Electroencephalogr. Clin. Neurophysiol.* 12, 239, 1960.
- [22] Jaffe, R., Brown, L., Tongue-movement artifacts in the electroencephalogram. *Clin. Electroencephalogr.* 14, 57-59, 1983.
- [23] Vanhatalo S., Voipio J., Dewaraja A., Holmes M.D., Miller J.W., Topography and elimination of slow EEG responses related to tongue movements. *Neuroimage*, 20:1419-1423, 2003.
- [24] Nam Y., Zhao Q., Cichocki A., Choi S., A Tongue-Machine Interface: Detection of Tongue Positions by Glossokinetic Potentials. *International Conference on Neural Information Processing Neural Information Processing. Models and Applications*, 34-41, 2010.
- [25] Nam Y., Koo B., Choi S., Language-Related Glossokinetic Potentials on Scalp. In: *IEEE International Conference on Systems, Man, and Cybernetics*, October 5-8, San Diego, CA, USA, 1063-1067, 2014.
- [26] Huo X., Wang J., Ghovanloo M., A Magnetic Wireless Tongue-Computer Interface. In: *Proceedings of the 3rd International IEEE EMBS Conference on Neural Engineering Kohala Coast, Hawaii, USA, May 2-5*, 322-326, 2007.
- [27] Huo X., Wang J., Ghovanloo M., A Wireless Tongue-Computer Interface Using Stereo Differential Magnetic Field Measurement. In: *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France, August*, 23-26, 5723-5726, 2007.
- [28] Huo X., Member S., Wang J., Member S., Ghovanloo M., A Magneto-Inductive Sensor Based Wireless Tongue-Computer Interface. *IEEE Trans. NEURAL Syst. Rehabil. Eng.*, 16(5):497-504, 2008.
- [29] Huo X., Wang J., Ghovanloo M., Wireless Control of Powered Wheelchairs with Tongue Motion Using Tongue Drive Assistive Technology. In: *30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, August 20-24*, 4199-4202, 2008.

- [30] Huo X., Member S., Ghovanloo M., Using Unconstrained Tongue Motion as an Alternative Control Mechanism for Wheeled Mobility. *IEEE Trans Biomed Eng.*, 56(6):1719-1726, 2009.
- [31] Yousefi B., Huo X., Ghovanloo M., Using Fitts's Law for Evaluating Tongue Drive System As a Pointing Device for Computer Access. In: 32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31 - September 4, 4403-4406, 2010.
- [32] Huo X., Park H., Kim J., Ghovanloo M., A Dual-Mode Human Computer Interface Combining Speech and Tongue Motion for People with Severe Disabilities. *IEEE Trans NEURAL Syst. Rehabil. Eng.*, 21(6):979-991, 2013.
- [33] Huo X., Jow U., Ghovanloo M., Radiation Characterization of an Intra-Oral Wireless Device at Multiple ISM Bands: 433 MHz, 915 MHz, and 2.42 GHz. In: 32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31 - September 4, 1425-1428, 2010.
- [34] Krishnamurthy G., Ghovanloo M., Tongue Drive: A Tongue Operated Magnetic Sensor Based Wireless Assistive Technology for People with Severe Disabilities. In: Proceedings of IEEE International Symposium on Circuits and Systems, 5551-5554, 2006.
- [35] Menon K.A.U., Jayaram R., Divya P., Wearable Wireless Tongue Controlled Assistive Device Using Optical Sensors. In: Tenth International Conference on Wireless and Optical Communications Networks (WOCN), 2013.
- [36] Sahadat M.N., Alreja A., Srikrishnan P., Ghovanloo M., A Multimodal Human Computer Interface Combining Head Movement, Speech and Tongue Motion for People with Severe Disabilities. In: IEEE Biomedical Circuits and Systems Conference (BioCAS), Atlanta, GA, USA, 2015.
- [37] Ayala-acevedo A., Ghovanloo M., Smartphone-Compatible Robust Classification Algorithm for the Tongue Drive System. In: IEEE Biomedical Circuits and Systems Conference (BioCAS) Proceedings, 3-6, 2014.
- [38] Struijk L.N.S.A., An Inductive Tongue Computer Interface for Control of Computers and Assistive Devices. *IEEE Trans. Biomed. Eng.*, 53(12):2594-2597, 2006.

- [39] Vaidyanathan R., Kook H., Gupta L., West J., Parametric and Non parametric Signal Analysis For Mapping Air Flow In the Ear-Canal to Tongue Movements: A New Strategy For Hands Free Human-Machine Interface. In: IEEE International Conference on Acoustics, Speech, and Signal Processing, 2-5, 2004.
- [40] Vaidyanathan R., Allen T.J., Quinn R.D., Tabib-azar M., Zarycki J., Levin J., Human-Machine Interface for Tele-Robotic Operation: Mapping of Tongue Movements Based on Aural Flow Monitoring. In: Proceedings of International Conference on Intelligent Robots and Systems, September 28-October 2, Sendai, Japan. 2004. p. 859-865, 2004.
- [41] Vaidyanathan R., Gupta L., Kook H., West J., A Decision Fusion Classification Architecture for Mapping of Tongue Movements Based on Aural Flow Monitoring. In: Proceedings of the IEEE International Conference on Robotics and Automation Orlando, Florida - May, 3610-3617, 2006.
- [42] Vaidyanathan R., Fargues M., Lin D., West J., A Dual-Mode Human-Machine Interface for Robotic Control based on Acoustic Sensitivity of the Aural Cavity. In: The First IEEE/RAS-EMBS International Conference on Biomedical Robotics and Biomechatronics, Pisa, Italy, 2006.
- [43] Vaidyanathan R., Chung B., Gupta L., Member S., Kook H., Kota S., West J.D., Tongue-Movement Communication and Control Concept for Hands-Free Human – Machine Interfaces. IEEE Trans. Syst. MAN, Cybern. A Syst. HUMANS, 37(4):533-546, 2007.
- [44] Vaidyanathan R., Wang S., Ieee M., Gupta L., Ieee M., A Wavelet Denoising Approach for Signal Action Isolation in the Ear Canal. In: 30th Annual International IEEE EMBS Conference Vancouver, British Columbia, Canada, August 20-24, 2677-2680, 2008.
- [45] Mamun K.A., Banik M., Mace M., Lutmen M.E., Vaidyanathan R., Wang S., Multi-layer Neural Network Classification of Tongue Movement Ear Pressure Signal for Human Machine Interface. In: 13th International Conference on Computer and Information Technology (ICCIT), Dhaka, Bangladesh, 2010.
- [46] Mamun K.A., Mace M., Lutmen M.E., Vaidyanathan R., Gupta L., Wang S., Multivariate Bayesian Classification of Tongue Movement Ear Pressure Signals Based on the Wavelet Packet Transform. In: IEEE International Workshop on Machine Learning for Signal Processing (MLSP 2010), August 29 – September 1, Kittilä, Finland, 208-213, 2010.

- [47] Mace M., Abdullah-al-mamun K., Vaidyanathan R., Wang S., Gupta L., Real-time Implementation of a Non-invasive Tongue-based Human-Robot Interface. In: IEEE/RSJ International Conference on Intelligent Robots and Systems, October 18-22, Taipei, Taiwan Real-time, 5486-5491, 2010.
- [48] Gupta L., Member S., Kota S., Member S., Murali S., Molfese D.L., Vaidyanathan R., A Feature Ranking Strategy to Facilitate Multivariate Signal Classification. IEEE Trans. Syst. MAN, Cybern. C. Appl. Rev., 40(1):98-108, 2010.
- [49] Kambhamettu C., Stone M., Automatic Motion Analysis of the Tongue Surface from Ultrasound Image Sequences. In: Proceedings of Biomedical Image Analysis Workshop, 126-132, 1998.
- [50] Kambhamettu C., Stone M., Analysis of The Tongue Surface Movement Using A Spatiotemporally Coherent Deformable Model. In: Proceedings Fourth IEEE Workshop on Applications of Computer Vision, 109-114, 1998.
- [51] Sinan Y., Chandra A., Stone M., Extraction and Tracking of the Tongue Surface from Ultrasound Image Sequences. In: Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1998.
- [52] Akgul Y.S., Kambhamettu C., Stone M., Automatic Extraction and Tracking of the Tongue Contours. IEEE Trans. Med. Imaging, 18(10):1035-1045, 1999.
- [53] Akgul Y.S., Kambhamettu C., Maureen S., A Task-Specific Contour Tracker for Ultrasound A Task-Specific Contour Tracker for Ultrasound. In Proceedings IEEE Workshop on Mathematical Methods in Biomedical Image Analysis. 2014.
- [54] Caltenco H.A., Member S., Lontis E.R., Struijk J.J., Lund M.E., Struijk L.N.S.A., Character Activation Time Character Activation Time Prediction Model for Tongue-Typing: Adaptation of Fitts's Law. In: 31st Annual International Conference of the IEEE EMBS Minneapolis, Minnesota, USA, September 2-6, 551-554, 2009.
- [55] Caltenco H.A., Lontis E.R., Boudreau S.A., Bentsen B., Struijk J., Struijk L.N.S.A., Tip of the Tongue Selectivity and Motor Learning in the Palatal Area. IEEE Trans. Biomed. Eng., 59(1):174-182, 2012.

- [56] Member S., Struijk L.N.S.A., TongueWise: Tongue-Computer Interface Software for People with Tetraplegia. In 32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31-September 4, 4534-4537, 2010.
- [57] Caltenco H.A., Lontis E.R., Bentsen B., Struijk L.N.S.A., Effects of sensory feedback in intra-oral target selection tasks with the tongue. *Disabil. Rehabil. Assist. Technol.*, 8(4):330-339, 2013.
- [58] Lund M.E., Ieee M., Christensen H.V., Caltenco H.A., Lontis E.R., Bentsen B., Struijk L.N.S.A., Inductive Tongue Control of Powered Wheelchairs. In 32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31 - September 4, 3361-3364, 2010.
- [59] Lontis E.R., Lund M.E., Christensen H.V., Bentsen B., Gaihede M., Caltenco H.A., Struijk L.N.S.A., Clinical Evaluation of Wireless Inductive Tongue Computer Interface for Control of Computers and Assistive Devices. In 32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31 - September 4, 3365-3368, 2010.
- [60] Struijk L.N.S.A., Lontis R., Comparison of Tongue Interface with Keyboard for Control of an Assistive Robotic Arm. In International Conference on Rehabilitation Robotics, QEII Centre, London, UK, July 17-20, 925-928, 2017.
- [61] Takahashi J., Suezawa S., Hasegawa Y., Sankai Y., Tongue Motion-based Operation of Support System for Paralyzed Patients. In IEEE International Conference on Rehabilitation Robotics Rehab. Week Zurich, ETH Zurich Science City, Switzerland, June 29 - July 1, 2011.
- [62] Draghici O., Batkin I., Bolic M., Chapman I., The MouthPad: a Tongue-Computer Interface. In IEEE International Symposium on Medical Measurements and Applications, 2013.
- [63] Draghici O., Batkin I., Bolic M., Chapman I., Performance Evaluation of the MouthPad. In IEEE International Symposium on Medical Measurements and Applications, 2014.
- [64] Nakatani S., Araki N., Konishi Y., Tongue-motion Classification Using Intraoral Electromyography for a Tongue – Computer Interface. In IEEE International Conference on Systems, Man, and Cybernetics Tongue-motion, 2349-2353, 2015.

- [65] Johansen D., Cipriani C., Member S., Popovi D.B., Struijk L.N.S.A., Control of a Robotic Hand Using a Tongue Control System - A Prosthesis Application. *IEEE Trans. Biomed. Eng.*, 63(7):1368-1376, 2016.
- [66] Yang H., Guan C., Ang K.K., Wang C.C., Phua K.S., Yu J., Dynamic Initiation and Dual-Tree Complex Wavelet Feature-based Classification of Motor Imagery of Swallow EEG Signals. In: *IEEE World Congress on Computational Intelligence*, June, 10-15, Brisbane, Australia., 10-15, 2012.
- [67] Sasaki M., Arakawa T., Nakayama A., Obinata G., Yamaguchi M., Estimation of Tongue Movement based on Suprahyoid Muscle Activity. In *International Symposium on Micro-Nano Mechatronics and Human Science*, 433–438, 2011.
- [68] Sasaki M., Onishi K., Arakawa T., Nakayama A., Stefanov D., Yamaguchi M., Real-Time Estimation of Tongue Movement based on Suprahyoid Muscle Activity. In: *35th Annual International Conference of the IEEE EMBS*, Osaka, Japan, 3 - 7 July, 4605-4608, 2013.
- [69] Sasaki M., Onishi K., Stefanov D., Kamata K., Nakayama A., Tongue interface based on surface EMG signals of suprahyoid muscles. *Robomech J.*, 3(9):2-11, 2016.
- [70] Obermaier B., Neuper C., Guger C., Pfurtscheller G., Information transfer rate in a five-classes brain-computer interface. *IEEE Trans. Neural Syst. Rehabil. Eng.*, 9(3):283-288, 2001.
- [71] Arbabi E., Shamsollahi M.B., Sameni R., Comparison between Effective Features Used for the Bayesian and the SVM Classifiers in BCI. In *IEEE Engineering in Medicine and Biology 27th Annual Conference*, 5365-5368, 2005.
- [72] Dias N.S., Kamrunnahar M., Mendes P.M., Schiff S.J., Correia J.H., Comparison of EEG pattern classification methods for brain-computer interfaces. In *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 2540-2543, 2007.
- [73] Miller K.J., Shenoy P., Nijs M Den, Sorensen L.B., Rao R.P.N., Ojemann J.G., Beyond the Gamma Band: The Role of High-Frequency Features in Movement Classification. *IEEE Trans. Biomed. Eng.*, 55(5):1634-1637, 2008.

- [74] Akıncı B., Gençer N.G., Classification of 4-class Motor Imagery EEG Data with Common Sparse Spectral Spatial Pattern Method. In 14th National Biomedical Engineering Meeting, 1-4, 2009.
- [75] Xiao D., Mu Z., Hu J., Classification of Motor Imagery EEG Signals Based on Energy Entropy. In International Symposium on Intelligent Ubiquitous Computing and Education, 61-64, 2009.
- [76] Xiao D.X.D, Hu J.H.J., Identification of Motor Imagery EEG Signal. In International Conference on Biomedical Engin. and Computer Science, 1-4, 2010.
- [77] Ming D., Sun C., Cheng L., Bai Y., Liu X., An X. ve ark., ICA-SVM combination algorithm for identification of motor imagery potentials. In IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 92-96, 2010.
- [78] Bao X., Wang J., Hu J., Method of individual identification based on electroencephalogram analysis. In International Conference on New Trends in Information and Service Science, 390-393, 2009.
- [79] Johnson A.N., Huo X., Ghovanloo M., Shinohara M., Dual-task motor performance with a tongue-operated assistive technology compared with hand operations. *J Neuroeng. Rehabil.*, 9(1):1-16, 2012.
- [80] Tyler M.E., Kaczmarek K.A., Rust K.L., Subbotin A.M., Skinner K.L., Danilov Y.P., Non-invasive neuromodulation to improve gait in chronic multiple sclerosis: A randomized double blind controlled pilot trial. *J. Neuroeng. Rehabil.*, 11(1):1-10, 2014.
- [81] Khorshidtalab A., Salami M.J.E., Hamed M., Evaluating the effectiveness of time-domain features for motor imagery movements using SVM. In International Conference on Computer and Communication Engineering, 909-913, 2012.
- [82] Ghosh P., Mazumder A., Bhattacharyya S., Tibarewala D.N., Hayashibe M., Functional Connectivity Analysis of Motor Imagery EEG signal for Brain-computer Interfacing Application. In International IEEE/EMBS Conference on Neural Engineering, 210-213, 2015.
- [83] Gong A., Liu J., Chen S., Fu Y., Time–Frequency Cross Mutual Information Analysis of the Brain Functional Networks Underlying Multiclass Motor Imagery. *J. Mot. Behav.*, 50(3):254-267, 2018.

- [84] Marjanovic N., Piccinini G., Kerr K., Esmailbeigi H., TongueToSpeech (TTS): Wearable wireless assistive device for augmented speech. In Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 3561-3563, 2017.
- [85] Park H., Kiani M., Lee H.M., Kim J., Block J., Gosselin B., et al. A wireless magnetoresistive sensing system for an intraoral tongue-computer interface. *IEEE Trans. Biomed. Circuits Syst.*, 6(6):571-585, 2012.
- [86] Viseh S., Ghovanloo M., Mohsenin T., Toward an Ultralow-Power Onboard Processor for Tongue Drive System. *IEEE Trans. Circuits Syst. II Express Briefs.*, 62(2):174-178, 2015.
- [87] Başçıl M.S., Beyinde Üretilen Yöne Bağlı EEG Sinyallerinin Öznitelik Çıkarımı Yardımıyla Sınıflandırılması. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 2015.
- [88] Ramadan R.A., Vasilakos A.V., Brain computer interface: control signals review. *Neurocomputing*, 223:26-44, 2016.
- [89] Iny D., Lundberg A., Levine W.S., Stone M., The dynamics and control of the tongue during speech. *Proc. Am. Control Conf.*, 1:246-251, 2001.
- [90] Anderson N.R., Wisneski K., Eisenman L., Moran D.W., Leuthardt E.C., Krusienski D.J., An offline evaluation of the autoregressive spectrum for electrocorticography. *IEEE Trans. Biomed. Eng.*, 56(3):913-916, 2009.
- [91] Hamed M., Salleh S.H, Noor A.M., Electroencephalographic Motor Imagery Brain Connectivity Analysis for BCI: A Review. *Neural Comput.*, 28:999-1041, 2016.
- [92] Lu C.W., Patil P.G., Chestek C.A., Current Challenges to the Clinical Translation of Brain Machine Interface Technology. *International Review of Neurobiology*, Elsevier Inc., 107:137-160, 2012.
- [93] Hassanien A.E., Azar A.T., *Brain Computer Interfaces: Current Trends and Applications*. Intelligent Systems Reference Library, Springer, Vol. 74, 2015.
- [94] *Biyomedikal Cihaz Teknolojileri-ELEKTROTLAR*, MEGEP (Mesleki Eğitim ve Öğretim Sisteminin Güçlendirilmesi Projesi), Ankara, 2007.
- [95] Yalçın N., Tezel G., Karakuzu C., Epilepsy diagnosis using artificial neural network learned by PSO. *Turkish J. Elec. Eng. Com. Sci.*, 23:421-432, 2015.

- [96] Desai K.D., Sankhe M.S., A Real-Time Fetal ECG Feature Extraction Using Multiscale Discrete Wavelet Transform. In International Conference on BioMedical Engineering and Informatics, 407-412, 2012.
- [97] Houssein E.H., Fahmy A.A., Hassanien A.E., Feature Extraction of Epilepsy EEG using Discrete Wavelet Transform. In Computer Engineering Conference, 12th International, 190-195, 2016.
- [98] Misiti M., Misiti Y., Oppenheim G., Poggi J.M., Wavelet Toolbox for Use with Matlab., Vol. 4, MathWorks. 2009.
- [99] Patel T.K., Panda P.C., Swain S.C., Mohanty S.K., A Fault Detection Technique in Transmission Line by Using Discrete Wavelet Transform. In Second International Conference on Electrical, Computer and Communication Technologies (ICECCT), 1-5, 2017.
- [100] Wen L., Li X., Gao L., Zhang Y., A New Convolutional Neural Network Based Data-Driven Fault Diagnosis Method. IEEE Trans. Ind. Electron., 65(7):5990-5998, 2018.
- [101] Cao Y., Guo Y., Yu H., Epileptic Seizure Auto-detection Using Deep Learning Method. In 4th International Conference on Systems and Informatics (ICSAI), 1076-1081, 2017.
- [102] Yang B., Duan K., Fan C., Hu C., Wang J., Automatic ocular artifacts removal in EEG using deep learning. Biomed. Signal Process Control, 43:148-158, 2018.
- [103] Gunes S., Dursun M., Polat K., Yosunkaya S., Sleep spindles recognition system based on time and frequency domain features. Expert Syst. Appl., 38(3):2455-2461, 2011.
- [104] Proakis J.G., Manolakis D.G., Digital signal processing. Vol. Third Edit., Prentice-Hall International, 2000.
- [105] Wang Z., Zhang Z., Gong X., Sun Y., Wang H., Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition. Concurr. Comput. Pr. Exper., 1-9, 2018, doi.org/10.1002/cpe.4413.
- [106] Acharya U.R., Lih S., Hagiwara Y., Hong J., Adeli H., Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. Comput. Biol. Med. 1-9, 2017.

- [107] Schirrmester R.T., Springenberg J.T., Dominique L., Fiederer J., Glasstetter M., Eggenberger K., et al., Deep Learning With Convolutional Neural Networks for EEG Decoding and Visualization. *Hum. Brain Mapp.*, 38:5391-5420, 2017.
- [108] Chai R., Naik G.R., Nguyen T.N., Ling S.H., Tran Y., Nguyen H.T., Selecting optimal EEG channels for mental tasks classification: An approach using ICA. In: *IEEE Congress on Evolutionary Computation (CEC)*, 1331-1335, 2016.
- [109] Vigário R., Särelä J, Jousmäki V., Hämmäläinen M., Oja E., Independent component approach to the analysis of EEG and MEG recordings. *IEEE Trans. Biomed. Eng.*, 47(5):589-593, 2000.
- [110] Mahajan K., Vargantwar M.R., Rajput S.M., Classification of EEG using PCA , ICA and Neural Network. *Int. J. Eng. Adv. Technol.*, 1(1):80-83, 2011.
- [111] Cilasun M.H., Yalçın H., A Deep Learning Approach to EEG based Epilepsy Seizure Determination. In *24th Signal Processing and Communication Application Conference (SIU)*, 2016.
- [112] Ethem A., *Introduction to Machine Learning*. Second Edi., 2010.
- [113] Sen B., Peker M., Novel approaches for automated epileptic diagnosis using FCBF selection and classification algorithms. *Turkish J. Electr. Eng. Comput Sci.*, 574(21):2092-2109, 2013.
- [114] Sengelmann M., Engel A.K., Maye A.. Maximizing Information Transfer in SSVEP Based Brain-Computer Interfaces. *IEEE Trans. Biomed. Eng.*, 64(2):381-394, 2017.
- [115] Shaft I., Ahmad J., Shah S.I., Kashif F.M., Impact of varying neurons and hidden layers in neural network architecture for a time frequency application. In *10th IEEE International Multitopic Conference (INMIC)*,188-193, 2006.
- [116] Temurtas H., Yumusak N., Temurtas F., A comparative study on diabetes disease diagnosis using neural networks. *Expert Syst. Appl.*, 36(4):8610-8615, 2009.
- [117] Inan G., Ubeyli E.D., Multiclass Support Vector Machines for EEG-Signals Classification. *IEEE Trans. Inf. Technol Biomed.*, 11(2):117-126, 2007.

- [118] Bao F.S., Lie D.Y., Zhang Y., A New Approach to Automated Epileptic Diagnosis Using EEG and Probabilistic Neural Network. In IEEE International Conference on Tools with Artificial Intelligence, 490-494, 2008.
- [119] Bao F.S., Gao J., Hu J., Lie D.Y.C., Zhang Y., Oommen K.J., Automated Epilepsy Diagnosis Using Interictal Scalp EEG. In 31st Annual International Conference of the IEEE EMBS Minneapolis, Minnesota, USA, 6603-6607, 2009.
- [120] Aydemir Ö., Kayıkçioğlu T., Investigation of the most appropriate mother wavelet for characterizing imaginary EEG signals used in BCI systems. Turkish J. Electr. Eng. Comput. Sci., 24:38-49, 2016.
- [121] Wang B., Wong C.M., Wan F., Mak P.U., Mak P.I., Vai M.I., Comparison of Different Classification Methods for EEG-Based Brain Computer Interfaces: A Case Study. In Proceedings of the IEEE International Conference on Information and Automation, 1416-1421, 2009.
- [122] Gorur K., Başçıl M.S., Bozkurt M.R., Temurtas F., Classification of Thyroid Data Using Decision Trees, kNN and SVM Methods. International Artificial Intelligence and Data Processing Symposium, 130-133, 2016.
- [123] Teo J., Hou C.L., Mountstephens J., Deep learning for EEG-Based preference classification. In the 2nd International Conference on Applied Science and Technology, 2017.
- [124] Chen X., He C., Wang Z.J., Member S., Mckeown M.J., An IC-PLS Framework for Group Corticomuscular Coupling Analysis. IEEE Trans. Biomed. Eng., 60(7):2022-2033, 2013.
- [125] Mckeown M.J., Saab R., Abu-gharbieh R., A Combined Independent Component Analysis (ICA)/ Empirical Mode Decomposition (EMD) Method to Infer Corticomuscular Coupling. In Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering, Arlington, Virginia, 5-8. 2005.
- [126] Li Y., Guan C., Qin J., Enhancing Feature Extraction with Sparse Component Analysis for Brain-Computer Interface. In Proceedings of the IEEE Engineering in Medicine and Biology, 27th Annual Conf. Shanghai, China, 5335-5338, 2005.

- [127] Jia Y., Xie J., Xu G., Li M., Zhang S., Luo A., Han X., A separated feature learning based DBN structure for classification of SSMVEP signals. 39th Ann. Int. Conf. of the IEEE Engin. in Medicine and Biology Society, 2017.

- [128] Dias N.S., Kamrunnahar M., Mendes P.M., Schiff S.J., Correia J.H., Customized Linear Discriminant Analysis for Brain-Computer Interfaces. 3rd International IEEE/EMBS Conference on Neural Engineering, 2007.

ÖZGEÇMİŞ

Kutlucan Görür, 13 Nisan 1985 yılında Adana'da dünyaya geldi. İlkokul, lise ve üniversite eğitimini bu şehirde tamamladı. 2003 senesinde Adana Anadolu Lisesi'nden mezun oldu. 2009 senesinde Çukurova Üniversitesi Elektrik Elektronik Mühendisliği'nden mezun olduktan sonra 2010 senesinde Bozok Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak akademik hayatına başladı. 2014 senesinde Bozok Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği yüksek lisans programından mezun olduktan sonra 2015 senesinde Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda doktora programına kayıt oldu. Halen Bozok Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak görev yapmaktadır.