

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE ENGELLİLERE
YÖNELİK EEG İŞARETLERİNİN SINIFLANDIRILMASI**

DOKTORA TEZİ

Ali Osman SELVİ

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**

Tez Danışmanı : Prof. Dr. Abdullah FERİKOĞLU

Ocak 2022

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE ENGELLİLERE
YÖNELİK EEG İŞARETLERİNİN SINIFLANDIRILMASI

DOKTORA TEZİ

Ali Osman SELVİ

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ

**Bu tez 18/01/2022 tarihinde aşağıdaki jüri tarafından
oybirliği/oyçokluğu ile kabul edilmiştir.**

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Prof.Dr. Osman ÇEREZCİ	BAŞARILI
Üye: Prof.Dr. Abdullah FERİKOĞLU	BAŞARILI
Üye: Prof.Dr. Cemil ÖZ	BAŞARILI
Üye: Prof.Dr. Hamdi Melih SARAOĞLU	BAŞARILI
Üye: Dr.Öğr.Üyesi Süleyman UZUN	BAŞARILI

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

Ali Osman SELVİ

18/01/2022

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 danışman hocam Prof.Dr. Abdullah FERİKOĞLU'na teşekkürlerimi sunarım.

Doktora sürecinde her zaman yanımda olan sevgili eşim Ayşegül SELVİ, hayatıma büyük değer katan oğlum Ali SELVİ ve kızım Ayçıl SELVİ'ye teşekkür ederim.

Benim bugünlere gelmemde en büyük pay sahibi olan babam Raşit SELVİ'ye, annem Emine SELVİ'ye ve abim Özder SELVİ'ye verdikleri maddi ve manevi desteklerinden dolayı teşekkür ederim.

Doktora sürecim boyunca desteklerini esirgemeyip bu süreç boyunca tecrübeleriyle katkı sağlayan kıymetli hocalarım Prof.Dr. Osman ÇEREZCİ'ye, Prof.Dr. Cemil ÖZ'e ve Doç.Dr. Derya GÜZEL ERDOĞAN'a, teşekkürlerimi sunarım.

Tez sürecim boyunca beraber çalıştığım desteklerini esirgemeyen kıymetli arkadaşlarım Doç.Dr. Emre DANDIL, Dr.Öğr.Üyesi Süleyman UZUN ve Dr.Öğr.Üyesi Cihan ŞAHİN'e manevi destekleri ile her zaman yanımda olan kıymetli abilerim Prof.Dr. Hasan YAMIK ve Öğr.Gör. Onur Yiğit ÖZGER'e, veri toplama sürecinde sabır ve anlayışla destek olan değerleri öğrenci ve arkadaşlarıma teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
KISALTMALAR	iv
SİMGELER	vi
TABLolar LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	viii
ÖZET.....	x
SUMMARY	xi

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

BEYNİN ÇALIŞMASI VE İZLEME YÖNTEMLERİ	6
2.1. Beynin Anatomik Yapısı	6
2.2. Beyin Aktivasyonunun Oluşması	7
2.3. Beyin Aktivesini İzleme Yöntemleri	10
2.3.1. Elektrokortikografi (ECoG)	10
2.3.2. Manyetoensefalografi (MEG)	11
2.3.3. Fonksiyonel manyetik rezonans görüntüleme (fMRG)	11
2.3.4. Fonksiyonel yakın kızılötesi spektroskopi (fYKS)	12
2.3.5. Elektroensefalografi (EEG).....	13
2.3.5.1. EEG işaretlerinin yapısı	14
2.3.5.2. EEG elektrot yerleşimi	15

BÖLÜM 3.

BEYNİN BİLGİSAYAR ARAYÜZÜ (BBA) SİSTEMLERİ	16
3.1. BBA Temel Yapısı	16
3.2. EEG Tabanlı BBA Kullanım Alanları	17
3.3. EEG Tabanlı BBA Uygulama Türleri	19
3.3.1. Olaya ilişkin salınımlar (OİS)	19
3.3.2. Olaya ilişkin potansiyeller (OİP)	20
3.3.2.1. Yavaş kortikal potansiyeller (YKP)	20
3.3.2.1.1. Görsel uyarılmış potansiyeller (GUP).....	20
3.3.2.1.2. P300 görsel uyarılmış potansiyeller	21

3.3.2.1.3. P300 uyarım çeşitleri.....	21
---------------------------------------	----

BÖLÜM 4.

P300 TABANLI BEYİN BİLGİSAYAR ARAYÜZÜ (BBA) TASARIMI.....	23
4.1. EEG Kayıt Cihazı	24
4.2. EEG Kanal Seçimi	25
4.3. Katılımcı Seçimi.....	26
4.4. P300 Potansiyelleri Uyarın Tasarımı.....	28
4.5. EEG Verilerinin Ön İşlenmesi	33
4.6. EEG İşareti Filtreleme.....	35
4.6.1. Butterworth filtre.....	36
4.7. Öznitelik Çıkarımı.....	37
4.7.1. Spektral entropi (SpEn) yöntemi.....	39
4.7.2. Anlık Frekans Bileşeni (AFB) yöntemi	42
4.7.3. Welch yöntemi	43
4.8. Öznitelik Birleştirme	45
4.9. Sınıflandırma.....	47
4.9.1. Çift yönlü uzun kısa süreli bellek ağı (ÇYUKSBA) sınıflandırıcı	47
4.9.2. Tek boyutlu evrişimsel sinir ağları (TBESA) sınıflandırıcı.....	49
4.9.3. Destek vektör makinası (DVM) sınıflandırıcı	51
4.10. Performans Metrikleri	53

BÖLÜM 5.

DENEYSEL SONUÇLAR.....	56
5.1. Çift Yönlü Uzun Kısa Süreli Bellek Ağı (ÇYUKSBA) Sınıflandırıcı Analiz Sonuçları.....	57
5.1.1. Öznitelik birleştirme sonuçları.....	57
5.1.2. Welch özniteliği sonuçları	61
5.2. Tek Boyutlu Evrişimsel Sinir Ağı (TBESA) Sınıflandırıcı Analiz Sonuçları.....	67
5.2.1. Öznitelik birleştirme sonuçları.....	67
5.2.2. Welch özniteliği sonuçları	71
5.3. DVM Sınıflandırıcı Ağı Analiz Sonuçları	76
5.3.1. Öznitelik birleştirme sonuçları.....	76
5.3.2. Welch özniteliği sonuçları	80
5.4. Kullanılan Sınıflandırıcıların Karşılaştırılması	84
5.5. Önerilen Yöntem ile Literatürün Karşılaştırılması.....	88

BÖLÜM 6. SONUÇ VE ÖNERİLER.....	92
--	-----------

KAYNAKLAR	96
------------------------	-----------

KISALTMALAR

AFB	: Anlık Frekans Bileşeni
ALDA	: Adımsal Lineer Diskriminant Analizi
ALS	: Amyotrofik Lateral Skleroz
AOK	: Aralıklı Otomatik Kodlayıcı
BBA	: Beyin Bilgisayar Arayüzü
BLDA	: Bayesien Lineer Diskriminant Analizi
BTO	: Bilgi Transfer Oranı
ÇYUKSBA	: Çift Yönlü Uzun Kısa Süreli Bellek Ağı
DDA	: Doğrusal Diskriminant Analizi
DDGUP	: Durağan Durum Görsel Uyarılmış Potansiyeller
DSİ	: Dijital Sinyal İşleme
DVM	: Destek Vektör Makinası
ECoG	: Elektrokortikografi
EEG	: Elektroensefalografi
ESA	: Evrimsel Sinir Ağı
fMRG	: Fonksiyonel Manyetik Rezonans Görüntüleme
fYKS	: Fonksiyonel Yakın Kızılötesi Spektroskopi
GSY	: Güç Spektral Yoğunluğu
GUP	: Görsel Uyarılmış Potansiyeller
KAOK	: Küme Aralıklı Otomatik Kodlayıcı
KKA	: Kanonik Korelasyon Analizi
KSFD	: Kısa Süreli Forier Dönüşümü
LDA	: Lineer Diskriminant Analizi
LH	: Lyme hastalığı
MEG	: Manyetoensefalografi
MS	: Multiple Skleroz
OİP	: Olaya İlişkin Potansiyeller

OİS	: Olaya ilişkin Salınımlar
OK	: Otomatik Kodlayıcı
SDC	: Sonsuz Dürtü Cevabı
SE	: Shannon Entropisi
SpEn	: Spektral Entropi
TBESA	: Tek Boyutlu Evrişimli Sinir Ağı
TSA	: Tekrarlayan Sinir Ağları
UKSB	: Uzun Kısa Süreli Bellek
YKP	: Yavaş Kortikal Potansiyeller



SİMGELER

a_k, b_k	: Filtre Katsayıları
X_j^l	: Özellik Haritası
$a(t)$	: İşaret Bileşeni Genliği
b	: Bias
$d(\bullet)$	: Alt Örnekleme Fonksiyonu
DN	: Doğru Negatif Sayısı
DP	: Doğru Pozitif Sayısı
f	: Frekans
$f(\bullet)$	: Aktivasyon Fonksiyonu
$g_i(t), f_i(t), q_i(t)$	: Uzun Kısa Süreli Bellek Kapı Fonksiyonları
N	: Uyarın Sayısı
P	: Ortalama Performans
$s(t)$	: Çok Bileşenli Sinyal
t	: Zaman
U	: Aktif Gizli Katman
$u(\bullet)$	: Örnekleme Fonksiyonu
W	: Bir Önceki Gizli Katman
$x(f)$	: İşaretin Fourier Dönüşümü
$x(t)$	: Nöron Girdisi
YN	: Yanlış Negatif Sayısı
YP	: Yanlış Pozitif Sayısı
$\delta(t)$	: Hata Terimi
σ	: Sigmoid Fonksiyon
$\phi(t)$	: İşaretin Anlık Fazı
φ	: Öğrenme Fonksiyonu
ω	: Hiperdüzlem Eşitlik Sınırı

TABLolar LİSTESİ

Tablo 2.1 : EEG frekans band aralıkları.....	14
Tablo 4.1 : DVM çekirdek fonksiyonları.....	53
Tablo 5.1 : Uyarıların sembolik gösterimi.	57
Tablo 5.2 : ÇYUKSBA öznitelik birleştirme eğitim verileri karmaşıklık matrisi.	58
Tablo 5.3 : ÇYUKSBA öznitelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.....	59
Tablo 5.4 : ÇYUKSBA öznitelik birleştirme test verileri karmaşıklık matrisi.....	60
Tablo 5.5 : ÇYUKSBA öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.....	61
Tablo 5.6 : ÇYUKSBA Welch özniteliği eğitim verileri karmaşıklık matrisi.....	63
Tablo 5.7 : ÇYUKSBA Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri.....	64
Tablo 5.8 : ÇYUKSBA Welch özniteliği test verileri karmaşıklık matrisi.....	65
Tablo 5.9 : ÇYUKSBA Welch özniteliği test verileri karmaşıklık matrisi metrikleri.....	66
Tablo 5.10 : TBESA öznitelik birleştirme eğitim verileri karmaşıklık matrisi.....	68
Tablo 5.11 : TBESA öznitelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.....	69
Tablo 5.12 : TBESA öznitelik birleştirme test verileri karmaşıklık matrisi.	70
Tablo 5.13 : TBESA öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.....	71
Tablo 5.14 : TBESA Welch özniteliği eğitim verileri karmaşıklık matrisi.	72
Tablo 5.15 : TBESA Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri.....	73
Tablo 5.16 : TBESA Welch özniteliği test verileri karmaşıklık matrisi.....	74
Tablo 5.17 : TBESA Welch özniteliği test verileri karmaşıklık matrisi metrikleri. ..	75
Tablo 5.18 : DVM öznitelik birleştirme eğitim verileri karmaşıklık matrisi.....	77
Tablo 5.19 : DVM öznitelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.....	77
Tablo 5.20 : DVM öznitelik birleştirme test verileri karmaşıklık matrisi.	79
Tablo 5.21 : DVM öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.....	79
Tablo 5.22 : DVM Welch özniteliği eğitim verileri karmaşıklık matrisi.....	81
Tablo 5.23 : DVM Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri. ..	82
Tablo 5.24 : DVM Welch özniteliği test verileri karmaşıklık matrisi.	83
Tablo 5.25 : DVM Welch özniteliği test verileri karmaşıklık matrisi metrikleri.....	83
Tablo 5.26 : Sınıflandırma başarımları.....	85
Tablo 5.27 : Sınıflandırma sonucu BTO değerleri.....	88
Tablo 5.28 : Sınıflandırma sonucu BTO değerleri.....	89

ŞEKİLLER LİSTESİ

Şekil 2.1 : Beynin bölümleri [19].....	7
Şekil 2.2 : Nöronun temsili yapısı.....	8
Şekil 2.3 : Aksiyon potansiyeli genlik değişimi.	9
Şekil 2.4 : Elektrokortikografi uygulaması [22].	10
Şekil 2.5 : Manyetoensefalografi uygulaması [23].	11
Şekil 2.6 : Fonksiyonel Manyetik Rezonans Görüntüleme uygulaması [26].	12
Şekil 2.7 : Fonksiyonel Yakın Kızılötesi Spektroskopi uygulaması [27].	12
Şekil 2.8 : BBA sistemlerinde tercih edilen taşınabilir örnek EEG cihazları [29].....	13
Şekil 2.9 : BBA sistemlerinde tercih edilen taşınabilir örnek EEG cihazları [29].....	15
Şekil 3.1 : Temel BBA sistemi yapısı.	16
Şekil 4.1 : P300 tabanlı Beyin Bilgisayar Arayüzü sistemi genel yapısı.	23
Şekil 4.2 : Emotiv EPOC+ EEG kayıt cihazı [49].	24
Şekil 4.3 : Xavier TestBench veri kayıt yazılım arayüzü.....	25
Şekil 4.4 : Uyarı sonucu kanal yoğunlukları.	26
Şekil 4.5 : Örnek EEG veri kayıt görüntüleri.....	27
Şekil 4.6 : P300 Görsel Uyarı Matrisi.	28
Şekil 4.7 : Görsel uyarı matrisinin sembolik tasarımı.	30
Şekil 4.8 : Veri kayıt protokolü.....	31
Şekil 4.9 : Doktor uyarısı için P300 sinyal örüntüsü.	31
Şekil 4.10 : Dört farklı sembol için sabit sırada oluşan P300 işaret örüntüleri.....	32
Şekil 4.11 : EEG işareti öteleme düzelme işlemi filtrenin Matlab kod söz dizimi.	34
Şekil 4.12 : EEG veri parçaları uyarı bölümleri.	34
Şekil 4.13 : Butterworth filtre genlik cevabı (dB).	37
Şekil 4.14 : Butterworth filtre faz cevabı.	37
Şekil 4.15 : Dört uyarı için güç spektrumu dağılımı örnek gösterimi.	41
Şekil 4.16 : Dört uyarı için SpEn özellikleri örnek gösterimi.	41
Şekil 4.17 : Dört uyarı için AFB özellikleri örnek gösterimi.	43
Şekil 4.18 : Welch özellikleri ortalanmış güç spektrumu tahminleri.	45
Şekil 4.19 : Örnek Doktor uyarısı için SpEn ve AFB özellikleri.....	46
Şekil 4.20 : Önerilen ÇYUKSBA mimarisi.	49
Şekil 4.21 : Önerilen TBESA mimarisi.....	51
Şekil 4.22 : Örnek DVM sınıflandırma işleminin grafiksel gösterimi.	52
Şekil 5.1 : Öznitelik birleştirme veri kümesi ÇYUKSBA eğitim grafiği.	57
Şekil 5.2 : ÇYUKSBA öznitelik birleştirme eğitim verileri sınıflandırma dağılımı..	59
Şekil 5.3 : ÇYUKSBA öznitelik birleştirme test verileri sınıflandırma dağılımı.	61
Şekil 5.4 : Welch özniteliği veri kümesi ÇYUKSBA eğitim grafiği.	62
Şekil 5.5 : ÇYUKSBA Welch özniteliği eğitim verileri sınıflandırma dağılımı.	64
Şekil 5.6 : ÇYUKSBA Welch özniteliği test verileri sınıflandırma dağılımı.	66
Şekil 5.7 : Öznitelik birleştirme veri kümesi TBESA eğitim grafiği.	67
Şekil 5.8 : TBESA öznitelik birleştirme eğitim verileri sınıflandırma dağılımı.	69
Şekil 5.9 : TBESA öznitelik birleştirme test verileri sınıflandırma dağılımı.....	71

Şekil 5.10 : Welch veri kümesi TBESA eğitim grafiği.....	72
Şekil 5.11 : TBESA Welch özniteliği eğitim verileri sınıflandırma dağılımı.....	74
Şekil 5.12 : TBESA Welch özniteliği test verileri sınıflandırma dağılımı.	76
Şekil 5.13 : DVM öznitelik birleştirme eğitim verileri sınıflandırma dağılımı.	78
Şekil 5.14 : DVM öznitelik birleştirme test verileri sınıflandırma dağılımı.	80
Şekil 5.15 : DVM Welch özniteliği eğitim verileri sınıflandırma dağılımı.	82
Şekil 5.16 : DVM Welch özniteliği test verileri sınıflandırma dağılımı.....	84
Şekil 5.17 : Eğitim veri kümesi sınıflandırma sonucu uyaran sınıfları arası dağılım.	86
Şekil 5.18 : Test veri kümesi sınıflandırma sonucu uyaran sınıfları arası dağılım. ...	87



MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE ENGELLİLERE YÖNELİK EEG İŞARETLERİNİN SINIFLANDIRILMASI

ÖZET

EEG cihazları kolay erişilebilirlik ve düşük maliyetleri sebebiyle Beyin Bilgisayar Arayüzü (BBA) sistemlerinde sıklıkla tercih edilmektedir. BBA sistemleri beyin fonksiyonlarını yitirmemiş ancak Amyotrofik Lateral Skleroz, Lyme Hastalığı, Multiple Skleroz, beyin sapı felci veya ciddi omurilik yaralanması gibi kronik nörolojik hastalıkları nedeniyle felç olan kişilerin düşünme ve odaklanma yeteneklerini kullanarak çevreleri ile iletişim kurmalarını sağlamak üzere tasarlanmaktadır. BBA sistemlerinin en önemli performas ölçütü yüksek sınıflandırma başarımı ve kullanıcıdan bilgisayar ortamına aktarılan dakikadaki bit oranı (Bilgi Transfer Oranı - BTO) ile ölçülmektedir. Performans ölçütlerinin başarımında, kullanılan uyaran paradigması, öznitelik çıkarım yöntemi ve sınıflandırıcı algoritması değişken oranlarda etkilidir. Tasarlanan BBA sistemlerinin bir çoğu çok sayıda uyaran ve tekrar yardımı ile yüksek oranda BTO performansı amaçlamaktadır. Bu dezavantajlı (engelli) bireylerin bu eğitim sürelerini başarılı tamamlamaları çok zordur. Bu tez çalışmasında, bireylerin temel gereksinimlerini temsil eden Doktor, Polis, İtfaiye ve Aile temalarını içerir Unity üzerinde hazırlanan 2x2 görsel uyarıcı matrisi katılımcılara gösterilmiştir. Emotiv EPOC+ cihazı ile toplanan EEG verilerinden 10 gönüllü katılımcının EEG verileri kullanılmıştır. Yüksek oranda BTO elde etmeye yönelik uyaranlar sabit sıra katılımcıya gösterilmiştir. Kayıt altına alınan EEG işaretlerinin işlenmesinde her bir uyaran bölümünde P300 işareti incelemesi yapmak yerine 4 uyaranı kapsayan işaretin tamamı bir bütün olarak incelenmiştir. Tasarlanan BBA sisteminin sınıflandırma başarımını arttırmaya yönelik Spektral Entropi ve Anlık Frekans Bileşeni özniteliklerine öznitelik birleştirme işlemi uygulanmıştır. Sonuçlar Welch öznitelik çıkarım yöntemi ile karşılaştırılmıştır. Bu tez çalışmasında tasarlanan BBA sistemi üzerinden elde edilen öznitelik verilerinin sınıflandırılması için Çift Yönlü Uzun Kısa Süreli Bellek Ağı (ÇYUKSBA) mimarisi önerilmiştir. Ayrıca önerilen sınıflandırma ağının başarımlarının kıyaslanmak için Tek Boyutlu Evrişimsel Sinir Ağları (TBESA) ve Destek Vektör Makinaları (DVM) ile de sınıflandırma işlemi gerçekleştirilmiştir. Sonuçlar analiz edildiğinde en yüksek sınıflandırma başarımına eğitim veri kümesi için %98.6, test veri kümesi için %96.9 olarak ÇYUKSBA'nın öznitelik birleştirme uygulanmış veriler ile ulaştığı görülmüştür. Tasarlanan BBA sistemi BTO performansı açısından incelendiğinde test veri kümesi için 40.4189 bit/dakika gibi yüksek bir değere ulaştığı görülmektedir. Elde edilen yüksek BTO değeri bu tez çalışmasında önerilen uyaran paradigması ve veri işleme tekniğinin engelli bireylere yönelik BBA çalışmalarına bir temel oluşturacağı ve katkı sunacağı öngörülmektedir.

Anahtar Kelimeler: Beyin Bilgisayar Arayüzü, EEG, P300, Öznitelik Birleştirme

CLASSIFICATION OF EEG SIGNALS FOR THE DISABLED WITH MACHINE LEARNING ALGORITHMS

SUMMARY

EEG devices are frequently preferred in Brain Computer Interface (BCI) systems due to their easy accessibility and low cost. BCI systems are designed to enable people who have not lost their brain functions, but who are paralyzed due to chronic neuromuscular diseases such as amyotrophic lateral sclerosis, Lyme disease, Multiple Sclerosis, brain stem paralysis or severe spinal cord injury, to communicate with their environment by using their thinking and focusing abilities. The most important performance criterion of BCI systems is measured by high classification performance and bit rate per minute (Information Transfer Rate - ITR) transferred from the user to the computer environment. The stimulus paradigm, feature extraction method and classifier algorithm used are effective at varying rates for the performance criteria. Many of the designed BCI systems aim at high ITR performance with the help of multiple stimuli and repetitions. It is very difficult for disadvantaged (disabled) individuals to successfully complete these training periods. In this thesis, the 2x2 visual stimulus matrix prepared on Unity, which includes the themes of Doctor, Police, Firefighter and Family, which represents the basic needs of individuals, is shown to the participants. EEG data of 10 volunteer participants were used from the EEG data collected with the Emotiv EPOC+ device. A fixed order of stimuli to achieve high ITR is shown to the participant. In the processing of the recorded EEG signals, instead of examining the P300 signal in each stimulus section, all the signals containing the 4 stimuli are examined completely. In order to increase the classification performance of the designed BCI system, feature fusion process is applied to Spectral Entropy and Instantaneous Frequency Component features. The results were compared with the Welch feature extraction method. In this thesis, Bidirectional Long Short Term Memory Network (Bi-LSTM) architecture, is proposed for the classification of feature data obtained through the designed BCI system. In addition, classification process was carried out with One-Dimensional Convolutional Neural Networks (1DCNN) and Support Vector Machines (SVM) to compare the performance of the proposed classification network. When the results are analyzed, it is seen that Bi-LSTM achieved the highest classification accuracy is achieved with 98.6% for the training dataset and 96.9% for the test dataset, with the data on which feature fusion is applied. When the designed BCI system is examined in terms of ITR performance, it is seen that it has reached a high value of 40.4189 bits/minute for the test dataset. It is predicted that the obtained high ITR value, the stimulus paradigm and data processing technique proposed in this thesis, could commence a basis and contribute to BCI studies for disabled individuals.

Keywords: Brain Computer Interface, EEG, P300, Feature Fusion

BÖLÜM 1. GİRİŞ

Elektroensefalografi (EEG) işaretleri kafatası üzerinden sensörler aracılığı ile alınan farklı genlik ve frekansa sahip beyin aktivasyon sinyalleridir. EEG işaretleri kullanılarak yapılan çalışmalarda EEG verisinin motor, duyu, görsel gibi birçok bilgiyi içerdiği gösterilmektedir [1]. EEG işaretlerini toplamak girişimsel olmayan bir yöntem olması sebebi ile bilimsel çalışmalarda sıklıkla tercih edilmektedir. Günümüzde teknolojik gelişmeler birçok alanda olduğu gibi EEG cihazlarında da gelişmelere yol açmıştır. Farklı sensör yapıları ve kablosuz bilgisayar bağlantısı bu gelişmelerin göze çarpanlarından bazılarıdır. EEG cihazları tıbbi uygulamalarda olduğu gibi biyomedikal uygulamalar geliştirilirken sıklıkla tercih sebebi olmaktadır. Kablosuz veri transferi ile EEG işaretlerinin bilgisayar ortamına gerçek zamanlı olarak aktarılması sağlanmaktadır. Mobil EEG cihazlarının kullanılmaya başlanması Beyin Bilgisayar Arayüzü (BBA) uygulamalarının önemli ölçüde artmasını sağlamıştır [2]. BBA sistemleri farklı uygulama alanları için tasarlanmaktadır. BBA sistemlerinin bir ölçümü beyin fonksiyonlarını yitirmemiş ancak Amyotrofik Lateral Skleroz (ALS), Lyme Hastalığı (LH), Multiple Skleroz (MS) beyin sapı felci veya ciddi omurilik yaralanması gibi kronik nöro-kas hastalıkları nedeniyle felç olan kişilerin çevreleri ile iletişim kurmalarını sağlamak üzere tasarlanmaktadır. Bu sistemler bireylerin düşünme ve odaklanma yeteneklerini kullanarak dış dünya ile iletişim kurmalarını sağlamaktadır. Bu sayede birey kafatası üzerinden alınan EEG sinyalleri ile dış ortamdaki çeşitli yazılım ve donanımları kontrol edebilmektedir [2,3].

Görsel uyaran içeren BBA sistemlerinde katılımcılardan görsel uyarının gösterileceği bir uyarı veya ekranı izlemeleri istenmektedir. EEG sinyalinde verilen görsel uyaran neticesinde oluşması beklenen ve gözlenen değişiklikler uyarılmış potansiyeller olarak adlandırılır [4]. Bu potansiyellerin bir çeşidi P300 olarak isimlendirilen işaretlerdir. P300 işaretleri ilk kez 1965 yılında Sutton ve ark. tarafından uyarının katılımcıya gösterildikten 300 milisaniye sonra oluşan pozitif defleksiyon sinyalleri olarak tanımlanmıştır [5]. Son yıllarda motor ve iletişim yeteneklerini kaybetmiş fakat beyin

fonksiyonlarını yitirmemiş bireylerin çevreleri ile iletişim kurmalarına yönelik birçok çalışma gerçekleştirilmektedir. Bu çalışmaların bir bölümü EEG içerisindeki P300 işaretlerini kullanarak yapılmaktadır. Bireylerden görsel uyaran sonucu elde edilen P300 işaretleri ile çevrelerindeki uygulama ve yazılımlarla ile iletişim kurmaları amaçlanmaktadır [6,7]. Bu çalışmaların büyük bir çoğunluğunda katılımcıya belirli sayıda satır ve sütun içeren, içerisinde alfanümerik karakterler bulunan matrisler gösterilmektedir. Kullanılan görsel uyaran matrisi P300 heceleme matrisleri olarak isimlendirilmektedir [8-15]. Farwell ve Donchin yaptıkları çalışmada katılımcıya 6 satır ve 6 sütun karakterlerden oluşan bir görsel uyaran matrisi göstermişlerdir. Çalışmada katılımcılardan ekrana yazmak istedikleri karaktere odaklanmaları istenmiştir. Lineer Diskriminant Analizi (LDA) kullanılan sınıflandırıcı ile P300 işaretleri sınıflandırılarak katılımcıların odaklandıkları karakterler ekrana yazdırılmıştır. Bu çalışmada kullanılan P300 heceleme matrisi sistemi oddball paradigması olarak adlandırılmıştır [8]. Çalışmalarda karakter sınıflandırma hızı ile dakikada bilgisayar ortamına aktarılan karakter sayısı da başarımlı ölçütü olarak verilmektedir. Gu ve ark. Farwell ve Donchin in çalışmalarına benzer bir çalışmada 4x10 bir heceleme matrisini oddball paradigması ile kullanmışlardır. Bayesien Lineer Diskriminant Analizi (BLDA) sınıflandırıcı kullandıkları çalışmalarında 40 karakterlik görsel uyarandan katılımcının odaklandığı karakteri ekrana yazdırmışlardır. Yaptıkları çalışma ile dakikada 9.07 karakter yazım performansını elde etmişlerdir [9].

Literatürde yapılan çalışmalarda siyah beyaz ekran ve geleneksel heceleme matrislerinden farklı olarak 2 ve 3 boyutlu görsel semboller kullanılarak yapılan P300 tabanlı BBA sistemleri de bulunmaktadır. Pérez ve ark. Doğrusal Diskriminant Analizi (DDA) kullandıkları çalışmalarında katılımcıya geleneksel P300 heceleme matrisinden farklı olarak resim uyaranları göstermişlerdir. Resim uyaranlarının verildiği sistemde P300 işaretlerinin sınıflandırılması ile bir robot kolun kontrolü gerçekleştirilmiştir [10]. P300 işaretleri kullanılarak gerçekleştirilen bir diğer çalışmada; Iturrate ve ark. Adımsal Lineer Diskriminant Analizini (ALDA) kullanılarak yaptıkları P300 tabanlı BBA çalışmasında görsel uyaranlar yardımı ile tekerlekli sandalye kontrolü gerçekleştirmişlerdir. Çalışmada görsel uyaran olarak kullanıcıya geleneksel P300 heceleme matrislerinden farklı olarak sanallaştırılmış ortam görüntüsüne ek renkli yön uyaranları verilmiştir. Geleneksel P300 sistemleri

veri toplama sürecinde uyarıların rasgele gösterimi ve kullanıcının buton benzeri donanımla odaklandığı uyarı ekranda belirlediğinde kayıt cihazına bir işaret gönderimi şeklinde çalışmaktadır.

Literatürde az sayıda olsa da farklı P300 paradigması öneren çalışmalarada rastlanmaktadır. He ve ark. çalışmalarında Destek Vektör Makinası (DVM) kullanarak yapmış oldukları P300 sınıflandırmasının bir bölümünde uyarıların sabit bir sıra ile katılımcıya göstermişlerdir. Sağlıklı bireyler üzerinde yaptıkları çevrimdışı çalışmada ortalama %92.7 başarımla elde etmişlerdir [12]. Salvaris ve ark. yapmış oldukları çalışmada geleneksel oddball paradigmasından farklı yeni bir paradigma olarak saat yönünde periyodik uyarı verme mekanizması sunmuşlardır. Yazarlar bu çalışmada geleneksel oddball paradigmayla alternatif bir yöntem olabileceğini ve Bilgi Transfer Oranı (BTO) değerinin artmasının sağlanabileceğini belirtmişlerdir [13]. BBA sistemlerinde sınıflandırma başarımlarını ve BTO performansını arttırmaya yönelik son yıllarda sıklıkla geleneksel P300 mekanizmasını ve sabit durum görsel uyarılmış potansiyelleri birlikte içeren hibrit yöntemler sunulmaktadır. Bu çalışmalarda katılımcıya P300 ve Durağan Durum Görsel Uyarılmış Potansiyeller (DDGUP) uyarıların aynı anda verilmektedir [14].

BBA sistemlerinde başarımları arttırmaya yönelik farklı öznelik çıkarım ve sınıflandırıcı seçim teknikleri uygulanmaktadır. Literatürde sıklıkla en yüksek sınıflandırma başarımlarını destekleyen öznelik çıkarımı ve sınıflandırıcı algoritması ilgili çalışmadaki BBA sistemi için önerilmektedir. Son yıllarda derin öğrenme algoritmalarının gelişmesi ile bu sınıflandırıcı algoritmalar diğer alanlarda olduğu gibi BBA sistemlerinde de kullanılmaya başlanmıştır. Aynı zamanda BBA sistemlerinde tek öznelik vektörlerini kullanmanın dışında birleştirilmiş öznelik vektörleri kullanılmaya başlanmıştır. Kundu ve Arı çalışmalarında P300 sinyallerinin sınıflandırılması için bir derin öğrenme yaklaşımı önermişlerdir. Çalışmada tek bir öznelik yerine Aralıklı Otomatik Kodlayıcı (AOK) ve Küme Aralıklı Otomatik Kodlayıcı (KAOK) dayalı iki farklı öznelik matrisinin bir araya getirilerek öznelik birleştirme yöntemini uygulamışlardır [15]. Literatürde P300 işaretlerinin sınıflandırılmasına yönelik az sayıda çalışma bulunmaktadır. Ditthapron ve ark. Uzun Kısa Süreli Bellek (UKSB) sınıflandırıcı kullanarak yapmış oldukları BBA çalışmasında %83.31 başarımla elde etmişlerdir [16].

Beyin fonksiyonlarını yitirmemiş ancak yatağa tamamen bağımlı dezavantajlı bireylerin temel ihtiyaçlarını karşılamak için P300 tabanlı BBA sistemleri çalışmalarına çok sayıda rastlanmaktadır. Bu sistemler literatürde sıklıkla Farwell ve Donchin tarafından önerilen oddball paradigmasını kullanmaktadır. Geleneksel P300 tabanlı sistemlerde EEG işaretleri rasgele sırada gösterilmekle birlikte her uyarın süresinde bağımsız olarak P300 veya P300 olmayan sinyaller olarak değerlendirilmektedir. Bu tür sistemlerin genellikle katılımcının diğer kişiyle veya donanımla metin bazlı bir ilişki kurması amaçlanmaktadır. Geleneksel sistemlerdeki çok sayıda uyarın gösterilmesi yorucu ve istenilen ihtiyacın odaklanılmasındaki sürenin uzamasına sebep olabilecektir. Literatürde uyarın sayısının fazla olması ile doğru orantılı olarak BTO performansının artışı belirtilmiştir. Uyarın sayısının çokluğu bu sebeple mümkün olan en fazla sayıda tercih edilmektedir. Ancak yatağa bağımlı dezavantajlı (engelli) bireylerin dış dünya ile metin bazlı iletişim kurmalarından ziyade bir harici donanım veya uygulamaya temel ihtiyaçları iletmek öncelik olduğu düşünülmektedir. Bu çalışmada belirtilen temel ihtiyaçlar, Doktor, Polis, İtfaiye ve Aile gibi acil durumlar için ulaşılması düşünülen odaklardır. Burada beklenen, kişinin gerekli uyarın bilgisini katılımcıyı yormadan en kısa sürede sisteme ilemesidir. Az sayıdaki uyarın düşük BTO performansını beraberinde getirmektedir. Bu sorunu aşmaya yönelik tez çalışmasında önerilen ve uygulanan uyarın sistemi ile tüm uyarınlar sabit sıra ile katılımcıya gösterilmiştir. Uyarınların tümünün sıra ile gösterilmesi zaman diliminde kayıt altına alınan EEG işaretinden P300 sinyalinin üretilmesi sonucunda farklı sinyal örüntüleri elde edilmesini sağlamıştır. Önerilen yöntem kayıt altına alınan EEG işaretlerini geleneksel yöntemden farklı olarak her uyarında ayrı P300 incelemesi yapmak yerine 4 uyarın için tek bir parça olarak incelemektedir. P300 işaretleri için ikili bir sınıflandırma yerine 4 uyarın için 4 farklı sinyal örüntüsü elde edilerek tekrar sayısı azaltılmış her bir uyarın odağı için beklenen süre düşürülmüştür. Bu sayede uyarın sayısı azlığı sebebiyle ortaya çıkan düşük BTO performansın artması sağlanmıştır.

Çalışmada; önerilen öznitelik birleştirme yöntemi ile yüksek sınıflandırma başarımı ve iyi bir BTO performansı elde edilmesi amaçlanmıştır. Bunun için P300 işaretlerinin özelliklerini en iyi ortaya çıkaran EEG işaretinin Spektral Entropi (SpEn) ve Anlık Frekans Bileşeni (AFB) tekniklerinden elde edilen özellikler birleştirilerek yeni bir öznitelik oluşturulmuştur. Bu tez ile önerilen P300 tabanlı BBA sistemi sınıflandırması

iin geleneksel P300 alıřmaların biroğunda kullanılan DVM algoritmaları ile son yıllarda etkin bir řekilde kullanılmaya bařlanan Tek Boyutlu Evriřimli Sinir Ağı (TBESA) ve ift Yönlü Uzun Kısa Süreli Bellek Ağı (YUKSBA) derin öğrenme algoritmaları kullanılmıřtır.

Ayrıca alıřmada; literatüre düşük uyaran sayısı ve az tekrar ile BTO'nın arttırılmasına yönelik yeni bir P300 paradigması önerilmiřtir. Bu yaklaşımın en iyi bařarım sonucunu elde edebilmesine yönelik öznitelik birleřtirme yöntemi ve derin öğrenme algoritmalarından yararlanılmıřtır. Elde edilen sonuçlara göre önerilen yöntem ile sabit sırada verilmiř dört uyaran için 10 katılımcıdan toplanan EEG verileri P300 tabanlı BBA olarak incelenmiřtir. Yapılan sınıflandırma sonuçlarına göre en yüksek bařarım %96,9 ile SpEn ve AFB özelliklerini içeren öznitelik birleřtirmenin YUKSBA ile sınıflandırılması ile elde edilmiřtir. Önerilen sistemin BTO deėeri dakikada 40,39 bit/dakika olarak elde edilmiřtir. Elde edilen yüksek BTO deėeri bu tez alıřmasında önerilen uyaran paradigması ve veri iřleme tekniğinin engelli bireylere yönelik BBA alıřmalarına bir temel oluřturacağı ve katkı sunacağı öngörülmektedir.

BÖLÜM 2. BEYNİN ÇALIŞMASI VE İZLEME YÖNTEMLERİ

2.1. Beynin Anatomik Yapısı

Sinir sistemi insan vücudunun kontrolünü sağlayan karmaşık bir yapıya sahip organizasyondur. Vücudun iç ve dış uyaranlarına cevap vererek ilgili sistem ve organların çalışmasını organize eder. Sinir sistemi iki bölüm olarak tanımlanmaktadır. Bu bölümler merkezi sinir sistemi ve çevresel sinir sistem olarak adlandırılır. Merkezi sinir sistemi beyin ve omurilikten oluşurken çevresel sinir sistemi merkezi sinir sistemini diğer tüm organlara bağlayan sinirlerden oluşmaktadır. Bu mekanizma içerisinde temel kontrol ve organizasyonu merkezi sinir sistemi içerisindeki beyin organı sağlamaktadır. Beyin yapısında gri ve beyaz madde olarak adlandırılan dokulardan oluşur. Gri madde nöron hücre gövdelerinden oluşurken beyaz madde sinir liflerinden oluşmaktadır [17].

Beyin kafatası boşluğunda yer almakta olup ortalama 1400 gram ağırlığa sahiptir. Beyin yapısında yaklaşık 100 milyar nöron içermekte olup toplam vücut ağırlığının %2 sini oluşturmaktadır. Yapısal olarak beyin sağ ve sol olmak üzere iki bölümden oluşmaktadır. Beyin fonksiyonel ve fizyolojik açıdan sınıflandırmak üzere farklı bölümler ile adlandırılmaktadır. Anatomik terminolojide beyin ön, yan, şakak, arka, limbik ve insular olmak üzere altı bölümde adlandırılmaktadır [18].

Ön (Frontal) Lob: Beynin en büyük lobu olan ön lob kafa tasının ön bölümünden üst orta bölümüne kadar uzanan bölgede yer almaktadır. Bu bölgede öğrenilmiş motor hareketleri, konuşma, duygusal tepkiler, planlama, koku algılama ve karar verme işlevleri gerçekleştirilmektedir [18].


Yan (Parietal) Lob: Beynin merkez sulkusundan arka bölümüne kadar uzanan bölümdür. Bu bölüm görsel ve duyuşsal algıların tetiklediği doğal motor ve kas hareketlerinin gerçekleştiği bölümdür [2,18].

Şakak (Temporal) Lob: Kafatası boşluğunun şakak bölümlerinde yer alan beyin bölümüdür. Bu bölüm duyma, işleme, analiz, hafıza, öğrenme, dil ve empati gibi çeşitli işlevlerle ilişkilidir [18].

Arka (Oksipital) Lob: Oksipital lob beynin arka bölümünde parietal lobdan beynin bitimine kadar uzanan beyin bölümüdür. Yapısı itibari ile beynin diğer bölümlerine göre daha yoğun ve karmaşık bir yapıya sahiptir. Birincil görsel alan olan arka lob görsel algı ve hafıza ilişkilendirmede büyük öneme sahiptir [2].

Limbik Lob: Limbik sistem beynin kafatası yüzeyinden uzakta amigdala ve hipokampusun hemen üstünde beyin sapı ile bağlantılı konumundadır. Limbik sistem 1998 yılında ayrı bir bölüm olarak nitelenmiştir. Amigdala ile olan bağlantıları sebebi ile duygusal bağlantılarla ilişkili işlevleri yerine getirmektedir. Aynı zamanda bu bölüm kısa süreli belleğin uzun süreli belleğe dönüştürülmesinde önemli bir role sahiptir. Limbik lob koku alma işlevini içeren sinirlere de sahiptir [18].

İnsular Lob: Beyin dış yüzeyinden uzak ön, yan ve şakak lobları tarafından örtülmüş bölümdür. İnsular bölüm tat alma, vücudun diğer organları ile ilgili çalışma ve duyu işlevlerini ile duyu ve biliş gibi birçok işlevi yerine getiren beyin bölümüdür [18]. Beyin bölümlerini gösterir görsel Şekil 2.1’de verilmiştir.




Şekil 2.1 : Beynin bölümleri [19].

2.2. Beyin Aktivasyonunun Oluşması

Beynin yapısını oluşturan hücreler nöron olarak adlandırılmaktadır. Nöronlar birbiri ile iletişim kurmak için karmaşık bir anatomik yapıya sahiptir. Nöronların genel yapısı Şekil 2.2.’de verilmiştir. Merkezde bir çekirdek içeren bir hücre gövdesi (soma)

bulunur. Hücre gövdesi etrafı dendrit adı verilen yapıyla çevrelenmiştir. Bu yapılar nöron hücresine girdi sağlamayı amaçlayan yapılardır. Dendrit den uzanan akson adı verilen yapılar diğer nöronlara bilgi iletimi için kullanılan terminal butonları (sinapslar) ile son bulur. Aksonlar iletim için miyelin kılıf ile çevrelenmiştir [20].




Şekil 2.2 : Nöronun temsili yapısı.

Nöronlar birbirlerine bilgi iletimi yaparken hücrelerindeki aksiyon potansiyelinden yararlanırlar. İnsan beynindeki bir nöronun dinlenme halindeyken hücre içi hücre dışına göre -75mV (mili volt) aksiyon potansiyeline sahiptir. Nöron hücresi içerisindeki iyonlar sadece hücre zarındaki gözenekler vasıtası ile dışarıya geçiş yapabilirler. Nöronların hücre zarında mikron karede bine yakın gözenek bulunmaktadır. Bu gözenekler hücre içi ve dışarısındaki iyon geçiş durumuna göre açılıp kapanabilmektedir. Bu gözenekler hücre içi ve dışı arasında yalnızca Na^+ , K^+ , Cl^- , veya Ca^{2+} iyonlarının geçişine duyarlıdır. Zar yarı geçirgen bir yapıya sahiptir ve dinlenme durumunda yalnızca K^+ iyonuna geçiş izni vermektedir. Dinlenme durumundayken hücre dışarısında Na^+ iyonu konsantrasyonu fazla iken hücre içerisinde K^+ iyon konsantrasyonu daha yüksektir. Hücre zarındaki gözenekler iyonla özgü geçirgenlik farklılıkları içermektedir. Hücre içerisindeki K^+ iyonlarının hücre dışarısındaki Na^+ iyonlarına göre bu gözeneklerden geçmesi daha kolaydır. Bu durum dinlenme halinde hücre içerisinde hücre dışarısında göre negatif olmasını sağlamaktadır.

Aksiyon potansiyeli, hücre merkezinden başlayarak akson boyunca akson terminallerine kadar ilerleyen bir voltaj değişimidir. Hücre zarı kanalları farklı uyarılma potansiyellerinde farklı iyonların geçişine izin vermektedir. Nöron hücre zarı uyarıldığında bir potansiyel hücre zarında ilerlemeye başlar. Na^+ kanallarının uyarılma seviyesi K^+ kanallarına göre daha düşük seviyededir. Bu sebeple hücre zarı

dışarısındaki Na^+ iyonları hücre içerisinde alınmaya başlanır. Bu işlem depolarizasyon olarak adlandırılmaktadır. Bu durumda hücre içerisindeki negatifliği hızla azalmaya başlarken hücre zarındaki Na^+ kanalları tamamıyla uyarılmış olmaktadır. Bu durum hücre zarı potansiyeli yaklaşık 20mv olana kadar devam eder. Oluşan pozitif potansiyel seviyesi Na^+ kanallarının kapanmasına sebep olmaktadır. Hücre zarı potansiyeli 20mv seviyelerine ulaştığında K^+ kanalları hücre içerisindeki K^+ iyonlarının hücre dışına geçişine izin vermektedir. Bu durum hücre zarı potansiyeli yaklaşık -75mV seviyelerine gelene kadar devam eder. Hücre zarı potansiyeli -75mV seviyelerine geldiğinde zarındaki K^+ kanalları tekrar kapanır. Bu olay repolarizasyon olarak adlandırılmaktadır. Hücre tekrar dinlenme potansiyeli seviyesine gelmiştir. Bir sonraki uyarılma durumuna kadar hücre içerisi negatifliğini korumaya devam eder. Bu süreç yaklaşık milisaniye seviyelerindedir. Depolarizasyon ve repolarizasyon sonucunda ortaya çıkan aksiyon potansiyeli oluşumunu gösterir temsili işaret Şekil 2.3’de verilmiştir.



Şekil 2.3 : Aksiyon potansiyeli genlik değişimi.


Nöronlar sinaps adı verilen terminaller aracılığı ile birbirleri ile iletişim kurarlar. Sinapslar aracılığı ile birbiri ile etkileşime giren nöronlar çok yakın bir temas halindedir [20]. Beyinde bilgiler nöronlarda oluşan aksiyon potansiyelleri akson ve dendrit uçlarındaki sinapslar yardımı ile bilgi iletimi sağlanmaktadır.

2.3. Beyin Aktivesini İzleme Yöntemleri

Beyin hücreleri olan nöron aktivitelerinin ölçülmesine yönelik farklı yöntemler önerilmektedir. Girişimsel ve girişimsel olmayan yöntemler olarak adlandırılan bu ölçüm tekniklerin farklı avantaj ve dezavantajları bulunmaktadır. Girişimsel yöntemler ağrı ve acı içerebilecek cerrahi işlem gerektiren yöntemlerken girişimsel olmayan yöntemler cerrahi bir operasyon gerektirmeyen ölçüm teknikleridir. BBA sistemlerinde geçmişten günümüze bu yöntemler kullanım amacına göre tercih sebebi olmaktadır. Bu yöntemlerden elektrokortikografi girişimsel bir yöntem iken manyetoensefalografi, fonksiyonel manyetik rezonans görüntüleme, fonksiyonel yakın kızılötesi spektroskopisi ve elektroensefalografi girişimsel olmayan yöntemler olarak sınıflandırılmaktadır.

2.3.1. Elektrokortikografi (ECoG)

Elektrokortikografi beynin en dıştaki zarının açılıp elektrotların korteks zarı üzerine yerleştirilerek istenilen bölgedeki aktivasyon işaretlerinin toplanmasına yönelik geliştirilmiş girişimsel tekniktir. Örnek bir elektrokortikografi yöntemi Şekil 2.4’de verilmiştir. Bu tekniğin en önemli avantajı kafatası ve kafa derisi gibi sinyali engelleyici etkenlerin devre dışı bırakılıp doğrudan korteks zar üzerinden sinyallerinin toplanmasıdır. Bu sayede elektrotların bulunduğu bölgeden alınan beyin işaretleri yüksek uzamsal çözünürlük ve yüksek işaret genliği ile elde edilebilmektedir. Direk korteks zar ile temas halinde olan elektrotlar dış girişimlerden daha yalın halde olan işareti algılayabilmektedir [21]. Belirli bir bölgeye elektrot yerleştirilmesi sonucu sadece ilgili bölgeden beyin sinyallerinin toplanması bu yöntemin en belirgin dezavantajdır.



Şekil 2.4 : Elektrokortikografi uygulaması [22].

2.3.2. Manyetoensefalografi (MEG)


Beyindeki elektriksel nöron aktivitesi manyetik bir alan oluşmasına sebep olmaktadır. Tesla seviyelerinde olan bu manyetik işaretler özel algılayıcılar tarafından toparlanabilmektedir. Manyetoensefalografi cihazları beynin manyetik aktivitesini izlemeye yönelik geliştirilmiş girişimsel olmayan cihazlardır. Şekil 2.5’de görülen manyetoensefalografi cihazları BBA sistemlerinde de araştırma konusu olmuştur ancak taşınabilirlik açısından esnek olmayan ve yüksek maliyetli cihazlar tercih sebebi olmamaktadır [21].



Şekil 2.5 : Manyetoensefalografi uygulaması [23].

2.3.3. Fonksiyonel manyetik rezonans görüntüleme (fMRG)

İnsan dokusundaki bulunan tüm atom çekirdekleri içsel bir manyetik momente ve dönüşe sahiptir. Bir manyetik rezonans görüntüleme (MRG) cihazına bu dokular yerleştirildiğinde hidrojen çekirdekleri ana manyetik alana paralel olarak hizalanır ve uygulanan alan kuvvetiyle orantılı frekansta dönmeye başlar. Farklı doku tipleri farklı dönüş frekanslarına sahip oldukları için medikal görüntülemelerde ayırt edici bir sinyal oluşumuna sebep olurlar. Fonksiyonel manyetik rezonans görüntüleme yapısal görüntülemekten ziyade beynin aktif bölümlerinin incelenmesini sağlamaktadır. Örnek bir fMRG cihazının görüntüsü Şekil 2.6’da verilmiştir. fMRG oksijenli ve oksijensiz kanın manyetik duyarlılığındaki farkın görüntülenmesi ile elde edilir. Beynin aktif olan nöronları faaliyetini gerçekleştirmek için oksijene ihtiyaç duymaktadır. Aktif olan nöronlarda oksijen fazlalığı fMRG yardımı ile beynin aktif bölümlerinin görüntülenmesini sağlamaktadır [24,25]. Bu yöntemin diğer yöntemlere göre uzaysal çözünürlüğünün yüksek olması bir avantajken cihazların büyük boyutlu ve yüksek maliyetli olması BBA sistemlerinde tercih edilmeme sebebi olmuştur [21].



Şekil 2.6 : Fonksiyonel Manyetik Rezonans Görüntüleme uygulaması [26].

2.3.4. Fonksiyonel yakın kızılötesi spektroskopisi (fYKS)

Yakın kızılötesi spektroskopisi yöntemi beynin yüzeyine yerleştirilen sensörler vasıtası ile beyin korteksindeki aktivasyonu optik görüntüleme tekniğidir. Beyin çalışma halinde hemodinamik değişimler meydana gelmektedir. Girişimsel olmayan bu yöntemde Şekil 2.7’de gösterildiği üzere kafatası üzerine yerleştirilen cihaz vasıtasıyla serebrum korteksine kızıl ötesi ve ultraviyole ışın demeti gönderilebilmektedir. Serebrum kortekse gönderilen ışın demeti Deoksihemoglobin değişimlerinden dolayı farklı dalga boyları ile geri yansımaktadır. Yansımadaki bu farklılıklar beynin nöronal aktivitesinin izlenmesini sağlamaktadır. Bu yöntem girişimlere açık olması sebebiyle çok tercih edilmemektedir. Ancak fMRG ile yapılamayan motor hareketlerinin bu cihazlar ile gerçekleştirilebiliyor olması en önemli avantajıdır. fYKS çok çeşitli alanlarda hala yapılmakla birlikte yaygın bir kullanıma henüz sahip değildir [24].



Şekil 2.7 : Fonksiyonel Yakın Kızılötesi Spektroskopisi uygulaması [27].

2.3.5. Elektroensefalografi (EEG)

Elektroensefalografiler beyin aktivasyonlarının gerçek zamanlı kayıt işlevini gerçekleştirmek üzere tasarlanmış cihazlardır. Beyin nöronlarının uyarılması sonucu ortaya çıkan aksiyon potansiyelleri beyin korteks zarı ve beyin dış zarında yansımaktadır. Noninvaziv bir yöntem olan EEG cihazları ile saçlı kafa derisi üzerine yerleştirilen elektrotlar vasıtası ile beyin işaretleri kayıt altına alınabilmektedir. İnsan beyni işaretleri ilk gözlemleri 1900'lü yılların başında yapılmaya başlandı. 1980'li yıllardaki teknolojik gelişmeler yardımıyla kayıt altına alınmaya başlanan EEG işaretleri 1990'lı yıllarda dijital ortamlarda gerçek zamanlı izleme ve değerlendirme işlemlerinde kullanılmaya başlandı.

Klinik olarak EEG cihazları günümüzde genellikle acil olarak kalp krizi vb. geçirilmiş bir rahatsızlık sonucu oluşabilecek epileptik durumların incelenmesi ile epileptik nöbetler, bilinç ve davranış bozuklukları, hastaların epilepsi ameliyatı uygunluğunu değerlendirmek ve çok sayıdaki nörolojik rahatsızlığın izlenimini yapmak amaçlı kullanılmaktadır. Son yıllarda yoğun bakım klinik uygulamalarında gerçek zamanlı EEG izlenimi kullanılmaktadır. Gerçek zamanlı EEG izlenimi ile hastanın epileptik nöbet izlenimi ve travmatik beyin hasarı hakkında bilgi sahibi olunabilmektedir. EEG cihazları günümüzde fMRG ve fYKS gibi fonksiyonel izleme cihazlarını yerini alacak çalışmalar içerisinde de sıklıkla kullanılmaktadır [28].



Şekil 2.8 : BBA sistemlerinde tercih edilen taşınabilir örnek EEG cihazları [29].

Teknolojik gelişmeler beraberinde birçok yenilikleri de beraberinde getirmektedir. Son yıllarda insanların yaşamlarını kolaylaştırmak ve bilgisayar ortamı ile etkileşimlerini arttırmak güncel çalışmalarda önemli ölçüde yer sahibidir. İnsanların düşüncelerini bilgisayar ortamına aktarmak uzun yıllardır merak konusu olmuştur. Bu

düşünce EEG cihazlarının tıbbi klinik araştırmalardan ziyade BBA uygulamalarında kullanılmaya başlanmasına sebep olmuştur [5]. EEG cihazlarının düşük maliyet, kolay erişim ve taşınabilir olmaları bu çalışmalarda en önemli tercih sebeplerindendir. Son yıllarda BBA sistemlerinde taşınabilir kablosuz bağlantıya sahip EEG cihazları tercih sebebi olmaktadır. Kullanılan EEG cihazlarına örnekler Şekil 2.8’de gösterilmiştir.

2.3.5.1. EEG işaretlerinin yapısı

Beyin faaliyetini gerçekleştirirken nöron aktivasyonları korteks tabakaya yansımaktadır. EEG işaretlerinin kafa derisi üzerinden elde edilmesinde etki eden birçok faktör olduğu bilinmektedir. Korteks tabakadaki aktivasyonlar kafa derisi üzerindeki EEG elektrotuna iletilirken arada kalan beyin omurilik sıvısı, kafa tası ve deri gibi doku dirençleri bu transferde önemli bir rol oynar. Beyin ile EEG elektrotu arasında kalan bu dokuların yaklaşık direnç etkileri hesaplanmaktadır. Beyin yapısından nöron olmayan glia hücreleri bulunmaktadır. Bu hücreler nöron aktivasyonun yansıtmaya yardımcı olarak EEG işaretlerinin elde edilmesine katkı sunmaktadırlar. EEG cihazı yapısındaki devreler yardımı ile nöronal aktivasyonun orijinaline en uygun biçimde elde edilmesi sağlanmaktadır.


EEG işaretleri özellikleri aktif nöronların sayısı ve uyarım çeşidine bağlı olarak değişmektedir. Sağlıklı bireylerde aktivasyonun çeşidine göre işaretlerin genliği 1-100 mikro volt arasında değişirken, frekansları band genişliği 0.1 – 70 Hz arasında değişmektedir. EEG cihazları beynin sadece büyük ve yüksek derecede senkronize alanlar üzerindeki elektriksel aktivitesi hakkında bilgi verebilmektedir [2]. EEG frekans band genişliği beş ana beyin dalgası ile sınıflandırılmaktadır. Bu frekans bantları Alfa (α), Theta (θ), Beta (β), Delta (δ) ve Gama (γ) olarak isimlendirilmektedir. Frekans band aralıkları Tablo 2.1’de verilmiştir [30].

Tablo 2.1 : EEG frekans band aralıkları.

Dalga Tipi	Frekans Bandı
Delta (δ)	0.5 – 4 Hz
Theta (θ)	4 – 7.5 Hz
Alfa (α),	8 – 13 Hz
Beta (β),	14 – 26 Hz
Gama (γ)	30 – 45 Hz

2.3.5.2. EEG elektrot yerleşimi

EEG cihazları için kabul edilmiş elektrot yerleşim standartları vardır. Bunlar 10 – 20, 10 – 10, 10 – 5 olarak adlandırılmaktadır. Bu standartlar EEG elektrotların kafatası üzerinde nerede konumlanacağı hakkında bilgi vermektedir. En yaygın kullanılan Elektrot yerleşim sistem 10 – 20 olarak adlandırılan sistemdir. Kafatası üzerindeki elektrot yerleşim bölgesi burun üzerindeki boşluktan (nasyon) başlayarak kafatasının arkasında ensenin üstündeki şiş bölgeye (inyon) kadar olan alanı kapsar. Bu alandaki 10 – 20 sistemi elektrotların yerleştiği kafatası üzerindeki bölümler arasında uzunluk oranı %20'dir. 10 – 20 standardında beynin kafatası yüzeyini kapsayan 5 ana bölüm ismi kullanılmaktadır. Bu bölümler Central (C), Frontal (F), Oksipital (O), Parietal (P) ve Temporal (T) olarak adlandırılmıştır. Beynin sol tarafında bulunan elektrotlar numaralandırılırken tek sayılar, sağ tarafında bulunan elektrotlar numaralandırılırken çift sayılar kullanılmaktadır. Her kafatası bölümünün merkezini sembolize eden elektrot z ile gösterilmektedir. Genellikle sol ve sağ kulak memesi altında A1 ve A2 olarak adlandırılan iki adet referans elektrotu bulunmaktadır. 10 – 20 elektrot yerleşim standardı Şekil 2.9'da verilmiştir [2,30].




Şekil 2.9 : BBA sistemlerinde tercih edilen taşınabilir örnek EEG cihazları [29]

BÖLÜM 3. BEYİN BİLGİSAYAR ARAYÜZÜ (BBA) SİSTEMLERİ

3.1. BBA Temel Yapısı

İnsan vücudunun merkezi kontrol birimi olan beyin konuşma, yürüme, okuma, koşma veya yemek yeme gibi öğrenilmiş birçok duyuşsal veya motor sinir sistemini kontrol ettiği gibi içgüdüsel olarak iç organlarımızın çalışması veya ağrı ve acı gibi durumlarda ortaya çıkan motor hareketlerinin kontrolünü sağlamaktadır. EEG üzerine uzun yıllardan beri yapılan çalışmalar sadece klinik olarak kısıtlı kalmamıştır. EEG işaretlerinin görüntülenmesinden bu yana beyin aktivasyonunun dış dünya ile iletişim kurmaya yönelik kullanılması birçok araştırmacının ilgisini çekmiştir. BBA sistemleri merkezi sinir sisteminin insan vücudu için oluşturduğu çıktıların dış dünya ile iletişimine yönelik kullanılmasını sağlamaya odaklanmıştır. Bu sistemler insan beynindeki istemli oluşturulmuş EEG işaretlerini kayıt altına alınan EEG işaretlerinden ayırt ederek bir çıktı üretmeyi amaçlamaktadır.



Şekil 3.1 : Temel BBA sistemi yapısı.

Temel bir BBA sistemi yapısı Şekil 3.1’de görülmektedir. BBA sistemlerinde katılımcıdan odaklanmasını istediği bir motor hareketi yapması beklenebildiği gibi bir uyarı takip etmesi de istenebilmektedir. Kullanım amacına yönelik planlanan bu aşama uygulamaya özgü farklılıklar içermektedir. Bireyin kafatası üzerine yerleştirilmiş bir EEG kayıt cihazı yardımı ile gerçek zamanlı beyin işaretleri bilgisayar ortamına aktarılmaktadır. Bu işaretler ham hali ile bir sistemi veya algoritmayı kontrol etmek için yeterli seviyede ve özellikte değildir. Öncelikle EEG cihazından alınan işaretler basit bir filtre yardımı ile istenmeyen sinyal bileşenlerinden temizlenir. Ham EEG verisi içerisinde kullanım amacına özgü özelliklerin çıkarılmasına yönelik öznel çıkarma teknikleri işarete uygulanır ve sınıflandırmaya hazır hale getirilir. BBA sistemlerinin son bölümü olan sınıflandırma en önemli adımlardan birisidir. Buradaki başarımlar sınıflandırma algoritmasının türüne ve uygunluğuna göre değişebildiği gibi EEG işaretinin toplanma kalitesi, gürültü temizleme performansı ve uygulamaya özgü en iyi öznel özelliklerin elde edilmesine bağlıdır. Sınıflandırma sonucu çıktıları tasarlanan sistemin hedefine yönelik bir uygulamanın çalıştırılması veya bir donanımın kontrol edilmesine yönelik kullanılmaktadır.

3.2. EEG Tabanlı BBA Kullanım Alanları

BBA sistemleri üzerine yapılan çalışmalara son yıllarda sıklıkla karşılaşılmaktadır. EEG işaretlerini kullanan bu sistemler günlük hayatta sağlıklı bireylerin bilgisayar ortamı ile etkileşimini sağlamaya yönelik dijital ortam ile iletişimi kurmak amaçlı kullanılmaktadır. Aynı zamanda bu sistemler ALS, LH, beyin veya omurilik yaralanması, beyin sapı hasarı, serebral palsi, MS vb. beyin fonksiyonlarını tamamıyla yitirmemiş ancak farklı iletişim ve motor hareketlerini kaybetmiş bireyler içinde araştırma konusu olmuş ve çalışmalar yapılmaktadır. EEG işaretlerinin farklı rahatsızlıklar yaşayan bireylerin tamamı için kullanılması mümkün olmamaktadır. Bu tarz sistemi kullanacak katılımcıların araştırılan EEG işareti özelliğini EEG kayıt cihazına yansıtabiliyor olması gerekmektedir [31].

BBA sistemleri üzerine yapılan çalışmalar büyük bir çoğunluğu bireylerin karakterler içeren bir uyarı matrisine odaklanmaları üzerine kurulmuştur. Bu çalışmalarda amaç iletişim becerisini yitirmiş bireylerin bilgisayar ortamına veya dolaylı yoldan karşı tarafa metinsel bir mesajı yazması veya sembolik bir işlemin gerçekleştirilmesine

yöneliktir. Çalışmaların bir diğer bölümü sadece bir uzvunu kaybetmiş bireylerin bir tekerlekli sandalye veya nöroprotezleri kontrol etmesine yönelik yapılmaktadır. Dijital teknolojilerinin gelişmesi ile BBA sistemler sadece bireye destek sistemleri olarak kullanılmanın yanında eğlence ve oyun sektörü ile eğitim gibi farklı alanlarda bireyin duygu durumu, düşünme yetisi gibi özelliklerinin bilgisayar ortamına aktarılarak analiz edilmesi veya kullanılmasına odaklanmaktadır. Bunlara ek olarak son yıllarda gerek karayolu taşıtı gerekse insansız hava araçlarının kullanımına yönelik çalışmalar yürütülmektedir [21,32].

Literatürde örnek çalışmalar incelendiğinde görsel uyaran ile bir aracın kontrolüne yönelik Rui ve ark. 8 kanalı bir EEG cihazı kullanarak yapmış oldukları çalışmada bir elektrikli tekerlekli sandalyeyi kontrol etmişlerdir. DDGUP kullandıkları çalışmalarında kullanıcıya LED bir panel tarafından uyarıcılar gösterilmiştir. Kanonik Korelasyon Analizi (KKA) yöntemi ile %93.9 başarımla elde etmişlerdir [33]. Bir diğer farklı uygulama olarak Shedeed ve ark. nöroprotez kullanımına yönelik yapmış oldukları çalışmada Emotive EPOC cihazının AF3, F7, F3 ve FC5 sensörlerini kullanarak 3 farklı kol hareketini EEG sinyallerini kullanarak %90 oranında sınıflandırma başarımla elde etmişlerdir. Uygulamada sınıflandırma algoritması olarak çok katmanlı algılayıcı yapay sinir ağı yapısı kullanılmıştır [34]. Duygusal analize yönelik Verkijika ve Wet yaptıkları çalışmada Emotive EPOC+ EEG cihazı verilerini kullanmaya yönelik geliştirilen bilgisayar yazılımı üzerinden çocukların basit düzeyden karmaşığa doğru matematiksel işlemleri yapmalarını istemişlerdir. Uygulama çocuklar tarafından kullanılırken EEG cihazı yardımı ile çocukların öğrenme sürecindeki kaygı duygularının takibi gerçekleştirilmektedir. Bu çalışmada çocukların duygusal durumuna göre soruların zorluk seviyesi değiştirilerek öğrenmenin tam olarak gerçekleştirilmesi amaçlanmıştır [35]. Beyin sinyallerinin bireyi tanımlayıcı bir özellik olarak kullanılmasına yönelik Al-Hudhud ve arkadaşları yapmış oldukları çalışmada biyometrik kimlik tanıma işlemi gerçekleştirmeyi amaç edinmişlerdir. Araştırmada insanların aynı uyarana düşünmesi sağlanarak beyin sinyalleri incelenmiştir. Araştırmacılar sinyal farklılıklarının yüzde bazında tutarlılıkları incelenerek bu yöntem için temel bir çalışma gerçekleştirmişlerdir [36]. Yapılan araştırmalar arasından dış ortamdaki bir aracın kontrolünün yapılmasına yönelik çalışmalara da sıklıkla rastlanmaktadır. Liu ve ark. yapmış oldukları çalışmada şantiye ortamındaki bir robotun beyin işaretleri ile kontrolünü amaçlamışlardır. DDGUP

kullandıkları çalışmalarında DVM ile yapmış oldukları sınıflandırmada %90 başarımla elde etmişlerdir [37]. Yapılan çalışmaların büyük bir bölümünü kullanıcıya bir ekran yardımı ile uyaranlar gösterilerek gerçekleştirilmektedir. Bu çalışmalarda bireye farklı karaktere sahip heceleme matrisleri gösterilmektedir. Shukla ve ark. yapmış oldukları çalışmada katılımcıya bir ev ortamında araçları kullanmaya yönelik bir matris yapısında görsel uyaran içeren sembolik karakterler göstermişlerdir. 16 kanallı bir EEG cihazı ile kayıt aldıkları EEG işaretlerinin öznel çıkarmında bağımsız bileşen analizi yöntemini sınıflandırılmasında ise Evrimsel Sinir Ağlarını (ESA) kullanmışlardır. Yapılan sınıflandırma sonucunda %90 başarımla ve 22.3 bit/dakika BTO performansı elde etmişlerdir [38].

3.3. EEG Tabanlı BBA Uygulama Türleri

EEG işaretleri BBA sistemlerinde kullanılırken farklı özelliklerinden yararlanılmaktadır. Beyin faaliyetlerini sürdürürken merkezi ve çevresel sinir sistemini kapsayan birçok nöral aktivasyon gerçekleştirir. Bunlar istemli ve istemsiz işaretler olarak EEG kayıtlarına yansımaktadır. Bu işaretlerin bir kısmı anlamlandırılabilir ve analiz edilebilir olarak değerlendirilmektedir. Analiz edilebilen bu sinyaller BBA sistemleri için kullanım konusu olmuştur. BBA sistemlerinde kullanılan bu EEG işaretleri olay ilişkili salınımlar ve olay ilişkili potansiyeller olarak sınıflandırılmaktadır.

3.3.1. Olaya ilişkin salınımlar (OİS)

Beynin çalışması sırasında farklı aktivasyon çeşitleri sinir yapısında kan akışındaki farklılıkları ortaya çıkarmaktadır. İnsan beyni işlevsel fonksiyonlarını milisaniyeler ölçeğinde sürekli değiştiren bir yapıya sahiptir. EEG'nin frekans yapısındaki zaman içindeki bu değişimler göreve özgü bir aktivasyon bileşeni ortaya çıkarabilmektedir. Beyin dinlenme durumunda yaklaşık 10 Hz frekans bandında bir işaret ritmi içermektedir. Bu ritimler 8 – 13 Hz aralığındaki alfa ritimleri içerisindeki mu ritimlerdir. Bu durağan durum olaya bağımlı desenkronizasyon olarak adlandırılmaktadır. Beyin dinlenme durumundan herhangi bir motor hareketi gerçekleştirmeye başladığında veya düşündüğünde EEG işaretlerindeki genlik değişimleri ile alfa içerisindeki mu ritimlerinde veya düşük beta ritimlerinde olaya bağımlı senkronizasyon işaretlerinin oluşmasına sebep olmaktadır [39,40].

Çalışmalarda bireylerin mu ve düşük beta ritimlerini kontrol edebilmesini öğrenebileceğine yönelik çalışmalar mevcuttur [41].

3.3.2. Olaya ilişkin potansiyeller (OİP)

Olay ilişkili potansiyeller (OİP) belirli bir olayın gerçekleşmesi veya uyarılma sonucu beyin tarafından üretilip kafa derisi üzerinden elde edilen EEG işaretleridir. OİP'ler kaydedilen EEG işaretleri içerisinde genellikle düşük genliklerde bulunmaktadır. EEG işaretinde uyaran zamanına ve sıklığına bağımlı olarak bir veya daha fazla OİP işaretleri ortaya çıkmaktadır. Bu işaretler uyarının verilışinden sonra elde edilen pozitif veya negatif oluşabilen genlik değışimlerdir. Verilen uyarını veya bir olayı takip eden ilk 150 milisaniye üzerinden kaydedilebilecek bileşenler dışsal etkiler tarafından ortaya çıkan işaretlerdir. Bu işaretler duyuşal sistemler tarafından alınan uyarıların EEG sinyalindeki yansımaları şeklindedir. Bunlar eksojen bileşenler olarak adlandırılır. Uzun gecikmeli sonrası elde edilen bileşenler ise bilişsel bilgi işleme gibi faaliyetlerin EEG işareti içerisindeki yansımalarıdır. Bunlar genellikle endojen bileşenler olarak adlandırılmaktadır. Endojen ve eksojen bileşenler BBA sistemlerinin tasarımında kullanılmaktadır. Ancak iki bileşen için tasarlanan sistemlerin tasarımı ve işletiminde farklılıklar mevcuttur [5].

3.3.2.1. Yavaş kortikal potansiyeller (YKP)

EEG içerisinde beynin olağan aktivitelerden kaynaklı ortaya yaklaşık 0.5 saniye sonra ortaya çıkıp birkaç saniye kadar devam eden EEG genlik işaretleridir. Negatif düzeydeki YKP zihinsel aktivite durumlarında ortaya çıkarken pozitif YKP'ler beynin dinlenmesi anında ortaya çıkmaktadır. YKP'ler günümüzde BBA uygulamaların bir bölümünde tercih edilmektedir. Bu işaretler ile bir bilgisayarın kontrolü veya oyun uygulamasının kontrolünün sağlandığı gibi dezavantajlı bireylerin iletişimi içinde kullanılmaktadır [21,39].

3.3.2.1.1. Görsel uyarılmış potansiyeller (GUP)

Görsel uyarılmış potansiyeller noninvaziv bir yöntem olan EEG cihazı yardımı ile görsel korteks üzerinden alınan işaretlerdir. Göz korteksinde oluşan aktivasyon ganglion hücreleri tarafından oluşan sinir demetleri yardımı ile beynin görsel

işlevlerini yerine getiren bölümüne iletilir. Buradaki görsel nöronların her uyaranda spesifik sunulan özelliklere uygun tepkiler verdiği düşünülmektedir [28]. GUP' leri kullanan BBA uygulamalarında katılımcıya gösterilen uyarının görsel korteksteki aktivasyon ve yansımalarına yönelik çalışmalar yapılmaktadır.

3.3.2.1.2. P300 görsel uyarılmış potansiyeller

P300 işaretleri belirli koşullar altından verilen uyarıcıdan yaklaşık 300 milisaniye sonra oluşan defleksiyon sinyalleridir. P300 işaretleri ilk olarak 1965 yılında Sutton ve ark. tarafından incelenmiştir. P300 uyarılmış potansiyelleri genellikle 300 milisaniye sürecinde oluşsa da bazen bu gecikme 250 ile 750 milisaniye değişkenlik gösterebileceği belirtilmiştir [5,43]. Uyarın öncesi EEG işaretlerine göre uyarın sonrası EEG işaretinin genliğinin belirli frekans aralığındaki değişimi olayla ilgili yanıtın göstergesidir. P300 işaretlerinin genliği yaşla birlikte azaldığını Yordanova çalışmasında göstermiştir. Uyarılmış P300 potansiyelleri için frekans yanıtı olaya ilgili bölgede her elektrotta belirgin bir şekilde görülmektedir. P300 uyarını verildikten sonra P300 işareti tek bir salınım ile incelenebilmektedir [44].

P300 tabanlı BBA sistemlerinde amaç kullanıcının odaklandığı sembolün doğru tahmin edilmesidir. Bilgisayar tarafından yapılan bu tahmin sürecini farklı öznel teknikleri ile desteklenmiş sınıflandırma algoritmaları yürütmektedir.

3.3.2.1.3. P300 uyarım çeşitleri

P300 işaretleri BBA sistemlerinde ilk olarak 1988 yılında Farwell ve Donchin tarafından kullanılmıştır. Yaptıkları bu çalışmada BBA sistemini kullanacak birey için bir heceleme matrisi önermişlerdir [8]. Genellikle P300 tabanlı BBA sistemlerinde Farwell ve Donchinin çalışmalarında önermiş olduğu oddball ismi verilen paradigma kullanılmaktadır. Bu sistemlerde kullanıcıya uyarın olarak verilecek bütün sembollerin olduğu siyah beyaz bir ekran gösterilmektedir. Sistemin çalışması ile uyarınlar satır ve sütun olarak rasgele yanarken katılımcıdan ekrana yazmak istediği karaktere odaklanması istenmektedir. Sistemin sınıflandırıcı bölümü bu süreçte kayıt altına alınan EEG işaretlerini P300 var ve P300 yok olarak incelemektedir. Oddball paradigmasında uyarınlar belirli tekrarlar ile kullanıcıya sunulmaktadır. Bir odak için geçen sürede kayıt altına alınan tekrar sayısındaki P300 işaretlerinin oluştuğu satır ve


sütun bilgileri birleştirilerek karakterin ekrana yazdırılması sağlanmaktadır. P300 tabanlı BBA üzerine yapılan çalışmaların en önemli bölümlerinden biri olan görsel uyaranlar bu sistemler için ayrı bir araştırma konusu olmuştur.

Kullanıcıya çok sayıda uyaran içeren ekran göstermek sistemlerin karmaşık bir görüntü sunmasına ekrana bakan kullanıcının yorulmasına ve odaklanma gücünün azalmasına sebep olabilmektedir. Bu sebeple literatürde uyaranların gruplandırılarak bölge bazlı uyaran matrislerinin tasarlandığı çalışmalar mevcuttur [45,46].

Görsel uyaran matrisi üzerine yapılan araştırmaların bir bölümü de kullanıcıya şekil ve resim içeren renkli görseller gösterilmesine yönelik yapılmıştır. Bu çalışmalar satır ve sütun uyaranı şeklinde kullanıcıya gösterildiği gibi birer birer kullanıcıya gösterilmektedir. Bu çalışmalarda çoğunlukla oddball paradigmasına uygun rasgele gösterim sunulmuştur [47,48]. Uyaranların teker teker kullanıcıya gösterildiği sistemlerin bir kısmında oddball paradigmasından farklı öneriler de sunulmuştur. Salvaris ve arkadaşları yapmış oldukları çalışmada kullanıcıya gösterilen uyaranları dairesel bir sıra ile ekrana yerleştirmişlerdir. Bu çalışmada uyaranlar saat yönünde sabit sıra ile kullanıcıya verilmiştir [13].

BÖLÜM 4. P300 TABANLI BEYİN BİLGİSAYAR ARAYÜZÜ (BBA) TASARIMI

Yapılan çalışmada, farklı bir uyarın gösterim yöntemi ile P300 tabanlı BBA sistemi gerçekleştirilmiştir. Önerilen sistemin bileşenlerin gösterir diyagram Şekil 4.1’de verilmiştir.



Şekil 4.1 : P300 tabanlı Beyin Bilgisayar Arayüzü sistemi genel yapısı.

Sistemin çalışmasında kullanılacak veri toplamaya katılan gönüllülere Unity platformunda hazırlanmış yeni bir paradigma öneren görsel uyarın animasyonu bilgisayar ekranı yardımı ile gösterilmiştir. Katılımcılardan verilen uyarın sonucu

toplanan P300 içeren beyin sinyalleri 14 kanallı mobil bir EEG cihazı tarafından toplanmıştır. Dijital ortama aktarılan EEG işaretleri sistem veya bireyin hareketlerinden kaynaklı bozucu etkilerin temizlenmesine yönelik bir ön işleme tabii tutulmuştur. Bozucu etkilerden arındırılmış EEG işaretlerinin özellikleri SpEn, AFB ve Welch yöntemi kullanılarak çıkartılmıştır. Ön işlenmiş EEG işaretlerinden çıkarılan SpEn ve AFB özelliklerine öznitelik birleştirme yöntemi uygulanmıştır. EEG işaretlerinden elde edilen öznitelik içeren veriler ÇYUKSBA, TBESA ve DVM yöntemleri kullanılarak sınıflandırılmıştır.

4.1. EEG Kayıt Cihazı

Bu tez çalışmasında EEG işaret kaydı gerçekleştirmek için Emotiv EPOC+ EEG kayıt cihazı kullanılmıştır. Emotiv EPOC+ cihazı 14 + 2 referans kanal ile AF3, AF4, F3, F4, FC5, FC6, F7, F8, T7, T8, P7, P8, O1, O2 noktalarından 128 ve 256 örnekleme frekansı ile kayıt yapılabilmektedir. EPOC+ cihazı usb bağlantı aracı yardımıyla kablosuz olarak bilgisayara bağlanabilmektedir. Cihaz jel yardımı ile çalışan sensörlerin aksine tuz bazlı sünger iletim parçaları kullanmaktadır. Bu sayede kullanılabilirlik açısından kolay ve kullanıcının sonrasında bir temizleme işlemi yapmasına gerek kalmamaktadır. Emotiv EPOC+ cihazının görüntüsü Şekil 4.2’de verilmiştir [49].



Şekil 4.2 : Emotiv EPOC+ EEG kayıt cihazı [49].

EPOC+ cihazlar jel bazlı EEG cihazlarına kıyasla sınırlı bir temas imkanı sunmaktadır. Kullanım esnasında sensörlerin işaret algılama kaliteleri düştüğünde sensörler ile kafa derisi arasında bulunan tuz bazlı süngerlerin ıslatılma ihtiyacı doğmaktadır. Cihaz beraberinde veri kaydetme ve bağlantı kalite kontrolü yapmayı sağlayan Xavier TestBench yazılımına sahiptir. Veri kayıt işlemine başlamadan önce bütün sensörlerin

en iyi kalitede temas yüzeyine sahip olunduklarından emin olduktan sonra veri kayıt işlemi gerçekleştirilmiştir. Veri kayıt esnasında sinyal kalitesi değişimlerinde katılımcılardan veri kayıt prosedürünün tekrarlama istenmiştir.

EEG işaretlerini kaydetme ve uyarın gösterimi için Intel i7 6700HQ 64 - bit işlemci, 24 GB RAM ve Windows 10 işletim sistemine sahip bilgisayar kullanılmıştır. Uyarın matrisi 22" bir monitör yardımı ile kullanıcıya gösterilmiştir. Katılımcıların veri kayıt ortamı dış gürültüden mümkün olduğunca izole seçilmiş ve veri kayıt sürecinde odada sadece kendileri ve kayıt sistemi bulunması sağlanmıştır. EEG işaretleri Xavier TestBench programı ile kayıt altına alınmıştır. Yazılımın arayüzü Şekil 4.3'de verilmiştir. Yazılım ile sensör temas kalitesi izlenebildiği gibi anlık EEG işaret değişimleri de gözlemlenebilmektedir. Bu çalışmada EEG işaretleri 128 bit örnekleme frekansı ile kayıt altına alınmıştır.




Şekil 4.3 : Xavier TestBench veri kayıt yazılım arayüzü.

4.2. EEG Kanal Seçimi

Bu tez çalışmasında Emotiv EPOC+ cihazı yardımı ile 14 kanaldan EEG kaydı alınmıştır. Tasarlanan sistemin hedef kitle düşünüldüğünde uygulanabilirliği için kompakt bir yapıda olması gereklidir. Bu düşünceden yola çıkarak mümkün olabilecek en az saydaki kanal sayısı ile işlem yapılması amaçlanmıştır. Görsel uyarınların EEG işaretleri içerisinde en uygun tepkilerinin parietal lob ve oksipital lob bölgesinde

alındığı bilinmektedir [5-50]. Matlab platformu üzerinde çalışan EEGLAB programı vasıtası kayıt altına P300 tabanlı BBA verilerinden bir örneğin güç spektral yoğunluk dağılımı Şekil 4.4’de verilmiştir.



Şekil 4.4 : Uyarı sonucu kanal yoğunlukları.

O1 ve O2 sensörlerinde gerçekleşen yoğunlukların yaklaşık aynı düzeyde olduğu görülmektedir. Bu tez çalışmasında P300 işaretlerinin incelenmesine yönelik O1 sensörü verileri kullanılmıştır.

4.3. Katılımcı Seçimi

Bu tez çalışmasında EEG veri kaydı için 20 gönüllü katılımcı çalışmaya dahil edilmiştir. Veri kayıt işlemine katılacak bireyler için;

- 18- 65 yaş arasında olmak.
- Çalışmaya katılmayı kabul etmek.
- Bilinen bir nörolojik veya psikiyatrik rahatsızlığı olmamak.
- Son 1 ay içerisinde kognitif fonksiyonları etkileyebilecek bir farmakolojik ajan almamış olmak.
- Test den önce kahve, çay, soda v.b. gibi kafein içeren içecekler almamış olmak.
- Bireyin saçlarında saç şekillendirici gibi bir kimyasal olmaması ve saçların temiz olması gerekmektedir.

katılımcı seçim kriterlerine riayet edilmiştir. Bu kriterleri sağlamayan bireyler çalışmaya dahil edilmemiştir.

EEG veri kayıt işlemi için Sakarya Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulundan 28.12.2016 tarih ve 04 sayılı etik kurul kararı ile onay alınmıştır. Veri kayıt işlemi öncesinde gönüllülerin bilgilendirilmiş gönüllü onam formunu okuması ve imzalaması istenmiştir. Deney sürecine katılmayı kabul eden bireylere deney süreci ve uyaran sistemi hakkında bilgiler verilerek bir örnek eğitim yapılmıştır.




Şekil 4.5 : Örnek EEG veri kayıt görüntüleri.

Katılımcılardan alınan EEG kayıtlarının bazılarında temas kalitesi ve cihazın örnekleme problemlerinden kaynaklı sorunlardan olduğu tespit edilmiştir. Yeni paradigma yaklaşımına yönelik yapılan deneysel çalışmalarda 10 gönüllünün sorunsuz olarak kayıt altına alınmış EEG işaretleri veri analiz aşamasında kullanılmıştır. Veri kayıt ve eğitim sürecini gösterir resimler Şekil 4.5’de verilmiştir.

4.4. P300 Potansiyelleri Uyaran Tasarımı

Bu tez çalışmasında katılımcılara gösterilmek üzere P300 görsel uyaran matrisi Unity üzerinde hazırlanmıştır. Tasarlanan P300 matrisi 2 satır ve 2 sütundan oluşmakta olup 4 uyaran içermektedir. Bir siyah arka plan üzerine yerleştirilen renkli görsellerden oluşan matris Şekil 4.6'de gösterilmektedir. Uyaran matrisi bireyin herhangi olası acil bir durumda iletişim kurması gerekli en temel 4 bileşeni içermektedir. Bu uyaranlar sırası ile Doktor, Polis, İtfaiye ve Aile temasını bireye göstermektedir.




Şekil 4.6 : P300 Görsel Uyaran Matrisi.

Bu çalışmada geleneksel P300 uyaran matrislerinden farklı bir uyaran matris paradigması önerilmiştir. BBA sistemlerinde uyaran matrisleri genellikle metinsel karakterler yazdırmaya yönelik tasarlanmış sistemlerdir [3,8]. Geleneksel sistemlerde alfanümerik karakterler katılımcıya uyaran olarak gösterilmektedir. Özellikle yatağa bağımlı bireylerde bu uyaran sayılarının fazla olması ve çok tekrarlı gösterim sistemlerin uyaran takibini zorlaştırmakla beraber odaklanan uyaranın kestirim süresinin uzamasına sebep olmaktadır. Metinsel iletişim yöntemleri için en iyi teknikler literatürde önerilmektedir. Ancak bireylerin temel ihtiyaçlarını iletmeye yönelik az sayıda uyaran içeren yüksek performanslı P300 sistemlerinin tasarımına ihtiyaç duyulduğu düşünülmektedir. Literatürde bu öneriyi destekler nitelikte çalışmalar yapılmaktadır [12,13].

Literatür incelendiğinde birçok uyaran sistemi tasarımı önerildiği görülmektedir. Bu sistemlerde değişmeyen temel mekanizma oddball paradigmasıdır. Oddball paradigmasında katılımcının ekranda rasgele verilen uyarılardan birine odaklanması istenmektedir. Farklı sayıda satır ve sütun içeren P300 heceleme matrisi sistemlerinde bütün karakterler siyah beyaz ekranda gri ölçekte verilmektedir. Uyaran sistem başladığında rasgele bir satır veya bir sütundaki bütün karakterler diğer karakterlerden farklı olarak daha parlak kullanıcıya gösterilmektedir. Her satır veya sütun uyarısından sonra bir uyaran arası geçiş süresi kadar sistem uyaran vermemektedir. Bu sırada sistem EEG işareti içerisinde uyaran arası geçiş süresi bitimine kadar bir P300 işareti varlığını değerlendirmektedir. Bu işlem tahmin başarımının yüksek olması için birçok kez tekrar edilmektedir. Belirlenen tekrar sayısına ulaşıldığında P300 işareti bulunan satır ve sütun bilgileri analiz edilerek odaklanılan karakterin ekrana yazılması sağlanmaktadır [8].

Bu sistemlerin en önemli dezavantajı başarımın yüksek elde edilebilmesi için uyarıların çok sayıda tekrar ile kullanıcıya verilmesidir. Bu durum BBA sisteminin katılımcının odaklandığı uyarıyı bilme süresinin uzamasına sebep olmaktadır.

Bu çalışmada geleneksel P300 oddball paradigmasından farklı olarak uyarılar sabit sıra ile katılımcıya gösterilmiştir. Bu önerinin amacı birçok uyarının rasgele tekrarlı verilerek P300 işaretinin hangi uyarıda daha çok meydana geldiğini hesaplamak yerine odaklanılan uyarının tek bir uyaran serisi ile P300 işaretinin hangi uyarıda oluştuğunun hesaplanmasıdır. Şekil 4.7’de verilen sembolik P300 görsel uyaran matrisinde, acil sağlık durumu ihtiyacını temsil eden bir doktor resmi (R1), herhangi bir güvenlik durumu ihtiyacını temsil eden bir polis resmi (R2), oluşabilecek bir yangın riski durumunda ihtiyacı temsil eden bir itfaiyeci resmi (R3) ve bunların dışında doğabilecek herhangi bir bakım ihtiyacı durumunda ulaşılması düşünülen aile resmi (R4) kullanılmıştır.




Şekil 4.7 : Görsel uyaran matrisinin sembolik tasarımı.

Sınıflandırma işleminde ağın eğitimi için kullanılacak P300 EEG işaretlerinin toparlanması için bir eğitim prosedürü belirlenmiştir. Bu prosedürde resimler önerilen paradigma uyarınca sıra ile R1, R2, R3 ve R4 olarak katılımcıya gösterilmiştir. Uyaran matrisi için animasyon başladığında katılımcılara 3 saniyelik bir geri sayım ekranı gösterilmektedir. Bu sayede katılımcıların animasyonun başlamasına kendilerini hazırlaması hedeflenmiştir. Geri sayım ekranının ardından 5.6 saniyelik siyah bir ekran gelmektedir. Bu süre zarfında katılımcıların durağan durum EEG işaretlerinin kaydedilmesi amaçlanırken aynı zamanda EEG işaretlerinin işlenmesinde uyaran öncesi referans bir bölümün bulunması hedeflenmiştir.


Durağan durum olarak belirlenen 5.6 saniyelik siyah ekranın ardında bütün uyaranlar ekranda 2 saniye süre ile gösterilmektedir. Katılımcının ekranda hangi uyaranların olduğunu görmesi ve hafızasında yer edinmesi amaçlanmıştır. Bu süre zarfından katılımcının odaklanması istenilen resmin etrafında yeşil bir çerçeve gösterilmektedir. Katılımcılara bir sonraki yeşil çerçeveli uyaran gelene kadar kendilerine gösterilen yeşil çerçeve ile verilmiş uyarı odak seçmeleri belirtilmiştir. Bu ekrandan sonra katılımcılardan sabit sıra ile gelecek uyaranlardan odak olarak belirtilen uyarı takip etmesi istenmiştir. Uyaranların teker teker gösterilmesinden hemen önce bütün semboller ekrandan kaybolmakta ve 600ms'lik bir siyah ekran gösterimi yapılmaktadır. Bu siyah ekran EEG işaretinin her bir resim serisinin gösterimine denk gelen bölümünün ayırımında kullanılmak üzere gösterilmiştir. Uyaranlar ekranda 200ms kalırken bir sonraki uyaran verilene kadar gösterilen siyah ekranın süresi 300ms'dir.

Eğitim prosedüründe her bir uyarı için 16 tekrar yapılmıştır. Bir uyarı için 16 tekrar tamamlandığında resimlerin hepsi tekrar ekranda belirmekte ve bir sonraki odaklanılacak uyarının etrafı yeşil çerçeve ile gösterilmektedir. 4 uyarı için bu prosedür tamamlandığında tasarlanan senaryo için EEG veri kaydı tamamlanmış olmaktadır. Bu prosedür 10 katılımcıya uygulanmış ve her katılımcı için 64 adet P300 işareti içeren EEG verisi elde edilmektedir. Prosedürün zaman bölümlenmesini sembolik gösterimi Şekil 4.8’de verilmiştir. Her bir katılımcı için veri kayıt süresi 3 dakika 5 saniye sürmektedir.




Şekil 4.8 : Veri kayıt protokolü.

Tasarlanan uyarı sistemi ile elde edilen veriler incelendiğinde odak uyarısının verildiği zaman diliminde P300 işaretinin oluştuğu gözlemlenmektedir. Katılımcıdan Doktor uyarısına odaklanması istenildiğinde oluşan P300 işareti içerir EEG veri parçası Şekil 4.9’da verilmiştir.



Şekil 4.9 : Doktor uyarısı için P300 sinyal örüntüsü.

Uyaran ve uyaran arası geçiş süreleri şekilde zaman düzlemi üzerinde bölümler olarak gösterilmiştir. EEG işaretlerinin ön işlemesi aşamasında bütün uyaranların sıra ile gösterilmesinden hemen önce verilen 600ms'lik siyah ekran referans alınmaktadır. EEG işaretleri veri işleme bölümünde kullanılmadan önce bu referans bölümden başlayarak 4 uyarandan en sonuncusu olan Aile uyarınının bitimine kadar parçalara ayrılır. Geleneksel yöntemde bu işlem her uyaran verildiğinde ayrı olarak yapılmaktadır. Elde edilen işaret örüntüsü 4 uyaran tamamı için geçen süredeki EEG verisini kapsamaktadır. Bu işaret örüntüsü içerisinde her uyaran; 200ms uyarının ekranda kalma süresi ve 300ms uyaran arası geçiş süresi olmak üzere 500ms'lik bir bölümde bulunmaktadır. 4 uyarının tamamını içerir bu işaret örüntüsü toplamda 2sn'lik bir zaman dilimini kapsamaktadır. Uyaran sıralamasında Doktor uyarını ilk uyaran olduğu için işaretin yaklaşık 300ms sonrasında pozitif seviyede bir genlik olduğu gözlemlenmektedir. Diğer uyaranların verildiği işaretin diğer bölümlerinde anlamlı bir genlik değişimi söz konusu olmamıştır.



Şekil 4.10 : Dört farklı sembol için sabit sırada oluşan P300 işaret örüntüleri.

Katılımcılar diğer uyarılardan herhangi birine odaklandığında P300 genlik değişimi EEG işareti içerisinde ilgili uyarının verildiği bölgede oluşmaktadır. Dört uyarının ardışık sabit sıra ile verilmesi her uyarıyı temsil eden bölgede oluşan P300 işareti 4 farklı işaret örüntüsü oluşmasına sebep olmaktadır.

Şekil 4.10'da her uyarı için oluşan P300 içeren farklı işaret örüntüleri görülmektedir. Doktor uyarısı için yaklaşık 300ms de oluşan P300 işareti Polis uyarısı için yaklaşık 700ms de, İtfaiyesi uyarısı için yaklaşık 1200ms de ve Aile uyarısı için ise yaklaşık 1700ms zaman bölümlerinde oluştuğu görülmektedir.

Tasarlanan uyarı sistemi ile çoklu tekrarlar ile P300 işareti var ve yok kıyası yapmak yerine farklı işaret örüntülerinin sınıflandırması sınıflandırma başarımları ve BTO performansına katkıda bulunacağı değerlendirilmiştir.

4.5. EEG Verilerinin Ön İşlenmesi

Emotiv EPOC+ cihazı yapısı itibarı ile veri kayıt işlemini gerçekleştirirken Analog Dijital Çevirici çıkışı işaretsiz öteleme işlemine tabii tutulmaktadır. Bu sayede 14 kanal EEG işaretlerinin hepsinin uygulama arayüzünde tek bir sayfada gösterilmesi sağlanmaktadır. Bu öteleme yaklaşık 4200 μV seviyelerindedir. EEG işaretlerinin öznitelik çıkarma ve sınıflandırma işlemi gerçekleştirilmeden önce sıfır seviyesine tekrar geri çekilmesi gerekmektedir.

Taban kayması probleminin düzeltilmesi için iki yöntem önerilmektedir. Bu dönüşüm için basit olarak verinin ortalamasının veriden çıkartılması çözüm olacağı gibi, 0,16 Hz 1. Mertebeden yüksek geçiren bir filtre yardımı ile ötelemenin çıkartılması bir diğer yardımcı bir çözüm olmaktadır. Gerçek zamanlı veri üzerinde öteleme işlemini daha verimli çıkartmanın başka bir yolu sonsuz impuls cevabına sahip bir filtre kullanmaktır. Bu filtreyi kullanmak bellek kullanımı açısından çok verimli olmasa da farklı veri grubu uygulamaları için filtre zaman sabitinin değiştirilmesi kolaylık sağlamaktadır. Filtreye ait sözde kod Şekil 4.11'de verilmiştir [49].

Algotirma 1: İşaret öteleme düzeltmesi için MATLAB kod bloğu

Result: EEGveri

Başla :

EEG_D, Satır Sütun Boyutlarını Ham EEG Verisinden oku

Örnekleme oranı Rate SR = 128

EEGveri isminde sıfır matrisi oluştur

EEG_Data matrisini kopyalayarak back_eeg matrisini oluştur

for $r1 = 1$ to *Satır Boyutu* **do**

for $r = 2$ to *Satır Boyutu* **do**

 İşlem gerçekleştir ;

 (back_eeg(r1) * (SR-1) + EEG_D / SR); den back_eeg(r1) i hesapla


 EEG_D(r) - back_eeg(r1); den EEGdata(r1) i hesapla

end

end

Şekil 4.11 : EEG işareti öteleme düzelme işlemi filtrenin Matlab kod sözdizimi.

Deney protokolü katılımcıya uygulandıktan ve öteleme farkının düzeltilmesinden sonra kayıt altına alınan EEG işareti deney prosedürün başında verilen hazırlık zamanı ve uyaranların bir arada gösterildiği bölümlerden ayrılmaktadır. Elde edilen sadece uyaranları içeren P300 paradigmasına uygun EEG işaretleri her bir uyaran için parçalara ayrılmıştır. Uyaranları verilirken katılımcılardan EEG verisi üzerinde bir işaretleme işlemi yapmaları talep edilmediği için uyaranların öncesinde verilen 600ms'lik referans boşluğu işaretin bölünmesinde kullanılmıştır. Parçalara ayırma işlemini gösterir zamanlama çizelgesi şekil 4.12'de verilmiştir. Verinin ayrılmasında geçen süre 4 uyaran ve 4 uyaran arası geçiş süresi için toplam 2000ms'dir. Bu sınıflandırmaya uygulanacak 2000ms'lik EEG işaret parçaları 256 örnek içermektedir.



Şekil 4.12 : EEG veri parçaları uyaran bölümleri.

4.6. EEG İşareti Filtreleme

EEG işaretleri kayıt altına alınması esnasında beyin sinyallerine birçok gürültü karışmaktadır. EEG işareti içerisindeki bu gürültü bileşeni artefakt olarak isimlendirilmektedir. Artefaktlar insan vücudunun doğası gereği oluşan aktiviteler sonucu oluşan işaretler olduğu gibi sistem dışı kaynaklardan gelen sebeplerden kaynaklı da olabilmektedir. Bu bozucu etkiler fizyolojik kaynaklı olan ve fizyolojik kaynaklı olmayan etkiler olarak adlandırılmaktadır. Fizyolojik sebepli artefaktlar göz kırpması veya hareketi, motor hareketleri ve kalp atışı vb. ile ilgili etkiler olabilmektedir. Fizyolojik olmayan dış kaynaklı artefaktlar ise ortam gürültüsü, güç hattı gürültüsü ve elektromanyetik parazitler gibi örneklendirilir. Fizyolojik olmayan artefaktlar sınırları net çizilmiş deneysel protokol düzenleri ve basit lineer filtrelemeler ile EEG içerisindeki beyin işaretlerinden ayırt edilebilmektedir. Aynı zamanda veri kayıt ortamının dış bozucu etkilerden yalıtılmış bir ortam olarak tasarlanması (örneğin faraday kafesi) tercih edilebilmektedir. Fizyolojik olmayan artefaktlara oranla fizyolojik artefaktların EEG işareti içerisinde çıkarılması veya azaltılması daha zordur. Bu artefaktların işaret içerisinde çıkartılması için gelişmiş filtreleme, yöntem ve tekniklerin kullanılması gereklidir [51,52].

BBA sistemleri tasarım amaçları uyarınca dış ortamdan bağımsız çalışacak sistemler değildirler. Bu sebeple dış ortam girişimlerine büyük ölçüde açık durumdadırlar. Bunlara ek olarak fizyolojik artefaktlar daima EEG işaretinin içerisinde bulunmaktadır. Literatürde yapılan BBA çalışmaların çoğunluğu dış gürültülerden yalıtılmış laboratuvar ortamlarında gerçekleştirilmektedir [53]. Aynı zamanda katılımcılar veri kayıt süresinde sistemi kısa süreli kullandıkları için normal olandan daha az fizyolojik artefakt üretebilmektedirler. Bu sebeple BBA sistemleri için EEG işareti içerisindeki bozucu etkilerin çıkartılması sistemin performansı için büyük önem arz etmektedir.

Çalışmada fizyolojik ve fizyolojik olmayan artefaktların EEG işaretleri içerisinde çıkarılmasına yönelik Sonsuz Dürtü Cevabı (SDC) filtre çeşidi olan Butterworth filtresi kullanılmıştır.

4.6.1. Butterworth filtre


Biyomedikal sistem tasarımlarında Dijital Sinyal İşleme (DSİ) sıklıkla tercih edilen yöntemlerden birisidir. Sistem içerisindeki analog filtreler yardımı ile net bir şekilde belirginlik gösteren gürültü bileşenleri dijital işaretin içerisinde temizlenebilmektedir. Ancak yine de dijital ortama aktarılan işaret içerisinde birçok artefakt bulunmaktadır. DSİ'nin en önemli adımlarında biri de bu bozucu etkilerin dijital filtreler yardımı ile asıl sinyalden ayrılmasıdır. Dijital filtrelerin bir çeşidi olan SDC filtreleri analog filtrelerle benzerliği sebebi ile keskin frekans cevabına sahiptir. Bu özellik SDC filtrelerinin biyomedikal sinyal işleme uygulamalarında tercih sebebi olmasına neden olmuştur [54].

SDC filtreler Sonlu Dürtü Cevabı filtreler gibi doğrusal filtre olmalarına rağmen tekrarlı yapıdadırlar, bu nedenle son M tane örneğin yanı sıra son P tane filtrelemeden de yararlanırlar. Bu sayede, SDC filtreler daha az katsayı ile işlem yaparlar. SDC filtrelerden Butterworth, Tchebychev veya Eliptik filtreler EEG sinyal analizinde sıklıkla kullanılırlar [55-57].


SDC filtresinin matematiksel fonksiyonu Denklem 4.1'de verilmiştir. Dijital filtre fonksiyonu tekrarlanan çarpma ve toplama şeklinde çalışmaktadır. Buradaki a_k ve b_k filtre katsayılarını, $x(n)$ ve $y(n)$ giriş ve çıkış sinyal dizilerini temsil etmektedir. M ve P ise aynı zamanda filtrenin derecesini göstermektedir. Basit filtrelemenin yeterli olması sebebi ile bu iki katsayı eşit olarak kullanılmıştır [58]. Denklemdaki a_k ve b_k arasındaki ilişki SDC filtresinin önceki çıkış ve mevcut girişten oluştuğunu göstermektedir [54].

$$y(n) = \sum_{k=0}^M a_k x(n-k) + \sum_{k=1}^P b_k y(n-k) \quad (4.1)$$

Yapılan çalışmada bozucu etkileri EEG verisinden çıkartmak için MATLAB ortamında hazırlanan yazılım yardımıyla 3 dereceden 5 Hz ile 15 Hz arası band geçiren Butterworth filtre kullanılmıştır. Kullanılan Butterworth filtrenin Genlik (dB) cevabı Şekil 4.13'de verilmiştir. Sinyalin genlik cevabı çıkış sinyalindeki frekansların genliğinin giriş sinyalindeki frekansların genliğine oranını vermektedir. Filtrenin faz cevabı Şekil 4.14'de verilmiştir. Sinyalin faz cevabı giriş frekansının çıkış faz cevabını vermektedir.



Şekil 4.13 : Butterworth filtre genlik cevabı (dB).



Şekil 4.14 : Butterworth filtre faz cevabı.

4.7. Öznitelik Çıkarımı

EEG işaretlerinin ön işleme adımından sonra ham EEG işaretlerinden tasarlanan BBA sistemine uygun özelliklerin çıkarılması gerekmektedir. Öznitelik çıkarma işlemi ile EEG işaretlerindeki gürültü ve diğer gereksiz bilgilerin işaret içerisinden çıkartılarak katılımcıya verilen uyaran çeşidine uygun işaret özellikleri belirlenerek uygun özelliklerin elde edilmesi amaçlanmaktadır [59]. Literatürde uygulamaya özgü EEG işaretinin farklı özellikleri üzerine çalışmalar yapılmaktadır. Çalışmalarda genellikle amaç mümkün olabilen en az sayıda özellik ile en iyi başarıyı elde edebilmektir. Literatürde çalışılan öznitelik çıkarım yöntemleri dört kategoride incelenmektedir. Bu yöntemler;

• *Derin Öğrenme Tabanlı Özellikler:* Geleneksel öznitelik çıkarım tekniklerinden farklı olarak derin öğrenme tabanlı öznitelik çıkarım yöntemleri işaretin doğrusal olmayan özelliklerinin de çıkarılmasına yardımcı olmaktadır. Geleneksel yöntemler araştırmacının bilgisine dayalı ve işaretin temel özelliklerinden çıkarım yapmayı sağlamaktadır. Bu dezavantajı ortadan kaldırmaya yönelik son yıllarda derin öğrenme tabanlı otomatik öznitelik çıkarım teknikleri kullanılmaya başlanmıştır. Derin öğrenme yöntemleri yardımı ile herhangi bir manuel işlem yapılmaksızın işaretlerin farklı üst düzey özelliklerin elde edilmesini sağlamaktadır. Derin öğrenme yöntemleri eğitim verileri için mevcut sınıf etiketine dayalı olarak öznitelik çıkarım modelini hazırlar. Derin öğrenme algoritmaları ayırt edici algoritmalar ve öğrenme aktarımı algoritmaları olarak iki bölüme ayrılmaktadır. Bu ayırt edici algoritmalar yardımı ile doğrusal olmayan dönüşüm, olasılıksal tahmin mekanizması ve sınıflandırma yolu ile ayırt edici özellikler elde edilir. Bu modellerde öznitelik çıkarımı ve sınıflandırma tek bir adımda gerçekleştirilmektedir [60]. Ayırt edici mimarilere örnek olarak temel olarak derin sinir ağları [61], Tekrarlayan Sinir Ağları (TSA) [62] ve Evrimsel Sinir Ağları (ESA) [63] verilebilir. Öğrenme aktarımı algoritmaları eğitim verilerinin çok sayıda olma ihtiyacını gidermeye yönelik geliştirilmiştir. Otomatik Kodlayıcı (OK) [64], Düzenlenmiş Boltzman Makinesi [65], Derin Düşünme Ağları [66] ve UKSB ağı [67] öğrenme aktarımı algoritmalarından en çok tercih edilenlerdir. BBA sisteminin performansını arttırmaya yönelik kullanılan bu yöntemler yüksek performanslı bilgisayarlara ihtiyaç duymaktadır [60].

• *Frekans Alanı Özellikler:* EEG işaretleri içerisinde çeşitli frekans bileşenleri ve frekans ritimleri bulunmaktadır. BBA uygulamalarında katılımcıya verilen uyaran türüne göre farklı zihinsel veya bilişsel tepkiler oluşmaktadır. Bu tepkiler EEG işareti içerisinde farklı ritimlerin oluşmasına sebep olmaktadır. Genellikle işaretin güç spektral yoğunluğu ve dar bant frekans özelliği frekans alanı özelliklerinde tercih edilmektedir. Güç spektral yoğunluk farklı frekanslar üzerindeki güç dağılım bilgisinin elde edilmesini sağlamaktadır.

• *Zamansal Özellikler:* EEG işaretlerin zamansal değişimleri uygulamalarda öznitelik olarak kullanılmaktadır. En verimli zamansal özellik EEG işaretinin zaman alanındaki genliğidir. P300 tabanlı BBA uygulamalarında karakter tanıma için sıklıkla kullanılmaktadır. Zamansal özellikler sadece sinyalin genliği hakkında bilgi barındırmaktadır. Frekans değişimi hakkında bilgi vermemektedir.

- *Zaman – Frekans Alanı Özellikler:* EEG işaretlerinin BBA sistemlerinde kullanılmasında zamansal ve frekans alanı özelliklerinin birlikte kullanımı başarımlı olumlu yönde etkilemektedir. EEG işaretlerine Kısa Süreli Fourier Dönüşümü (KSFD) ve Dalgacık Dönüşümü (DD) gibi yöntemler uygulanarak zamansal ve frekans alanı özelliklerini birlikte barındıracak özellikler çıkarımını mümkündür. Ancak gerek zaman gerekse frekans alanı özelliklerinin çıkarımı hesaplaması bu özelliklerin tek başına çıkarılmasına göre daha karmaşık bir hesaplama gerektirir.

Bu çalışmada SpEn, AFB ve Welch öz nitelik çıkarım tekniklerinden elde edilen özellikler kullanılmıştır. P300 özneliğini daha iyi ortaya çıkarabileceği düşünülen SpEn ve AFB özelliklerine özellik birleştirme işlemi uygulanmıştır.

4.7.1. Spektral entropi (SpEn) yöntemi

Spektral Entropi (SpEn) farklı frekanslardaki güç dağılımını ve genlik bileşenlerini kullanan Shannon Entropisi (SE) teorisinin normalleştirilmesine dayanmaktadır [68]. SpEn'nin biyolojik zaman serisi işaretlerinin önemli doğrusal olmayan özelliklerini sunmak için faydalı olduğu öne sürülmüştür [69]. Spektral özellikler işaretin frekans özelliklerinde farklı sinyal enerjisi dağılımlarına sahip sinyal sınıfları arasında ayırım yapmak için kullanılmaktadır. Spektral entropi hesabı için öncelikle güç dağılımı normalize edilmektedir. Normalize edilen değerler ile işaretin içerisindeki frekanslardaki güç olasılık dağılımı elde edilir [70].

$x[n]$, $n=1, \dots, N$ olan N örnekleli ayrık bir zaman sinyali için $X[m]$, $m=1, \dots, M$ noktalı ayrık fourier dönüşümdür. $x[n]$ sinyalinin SpEn'sini elde etmek için ilk olarak güç spektrumu Denklem 4.2'deki gibi hesaplanmaktadır.

$$[m] = |X[m]|^2; m = 1, \dots, M \quad (4.2)$$

Güç spektrumu hesaplanan işaretin daha sonra $P(m)$ olasılık dağılımı hesaplanmaktadır. Olasılık dağılımının hesaplaması Denklem 4.3'de verilmektedir.

$$P(m) = \frac{S[m]}{\sum_{k=1}^M S[k]}; m = 1, \dots, M \quad (4.3)$$

Olasılık dağılımının hesaplanması sonrasında SE tekniğine göre işaretin güç SpEn'si Denklem 4.4 de verildiği şekilde ifade edilmektedir.

$$H_x = \sum_{k=1}^M P(k) \log_2 \left(\frac{1}{P(k)} \right) \quad (4.4)$$

İşaret içerisindeki beyaz gürültü tek bir güç spektrumuna sahiptir. Bu sebeple maksimum SE hesaplanmaktadır. Maksimum SE $\log_2(M)$ logaritmik hesaplaması ile elde edilmektedir. Bu sebeple normalleştirilmiş SpEn Denklem 4.5'de ifade edildiği şekilde hesaplanmaktadır.

$$H_x^{nm} = \frac{\sum_{k=1}^M P(k) \log_2 \left(\frac{1}{P(k)} \right)}{\log_2(M)} \quad (4.5)$$

$x[n]$ işaretinin zaman – frekans SpEn'sini elde etmek için ilk zaman – frekans spektrogramında $X[n, f]$, $n=1, \dots, N_1$, $f=1, \dots, F_1$ hesaplanır. Buradaki N_1 ve F_1 değerleri spektrogramın sayı zaman veya frekans çözünürlüğüne bağlıdır. Bu hesaplama sonucundan olasılık dağılımı $P(n, f)$ Denklem 4.6'da verildiği şekilde hesaplanmaktadır.


$$P(n, f) = \frac{X[n, f]}{\sum_{j=1}^{F_1} X[n, j]}; n = 1, \dots, N_1; f = 1, \dots, F_1 \quad (4.6)$$

$P(n, f)$ olasılık dağılımı hesaplamasından sonra n örneğindeki anlık SpEn hesaplaması Denklem 4.7 de verilmiştir [71].


$$H(n) = \sum_{j=1}^{F_1} P(n, j) \log_2 \left(\frac{1}{P(n, j)} \right); n = 1, \dots, N_1 \quad (4.7)$$

EEG işaretleri içerisinde bulunan P300 işaretleri enerji değişimi farklılığı oluşturması sebebi ile tez çalışmasında sınıflandırmayı destekleyici olarak SpEn öznitelik çıkarım tekniği olarak tercih edilmiştir. Görsel uyarılmış potansiyel işaretlerinin genlik potansiyeline sahip olması işaretin SpEn'sinin özelliğinin ayırt edici bir özellik olarak kullanımı literatürdeki daha önce yapılan çalışmalarda gösterilmiştir [72-74].

Tez çalışmasında kullanılan paradigma uyarınca uyanların hepsinin bir defa gösterildiği EEG işaretlerinin 2000 ms lik 256 örnek içeren verileri üzerine SpEn yöntemi uygulanmıştır.



Şekil 4.15 : Dört uyarı için güç spektrumu dağılımı örnek gösterimi.



Şekil 4.16 : Dört uyarı için SpEn özellikleri örnek gösterimi.

Katılımcının odaklanması istediği Doktor, Polis, İtfaiye ve Aile uyarıları için elde edilen örnek güç spektrum dağılımları Şekil 4.15’de verilmiştir. SpEn özellikleri elde edilmiş her bir uyarı için öznitelik verilerinin grafiksel gösterimi Şekil 4.16’da verilmiştir.

4.7.2. Anlık Frekans Bileşeni (AFB) yöntemi

İşaret işleme ve ayrıştırma tabanlı sistemler EEG işaretlerinin çok bileşenli genlik ve frekans modülasyonlu sinyaller olarak modellenenbilmesinden yararlanmaktadır. Bu nedenle sınıflandırma başarımını arttıracak ayırt edici özelliklerin EEG sinyalleri içerisinde çıkarılabileceği bir ön işleme adımı uygulanmaktadır. EEG işareti içerisinde çıkarılan ayırt edici özelliklerden birisi de anlık frekans bileşenidir [75].

AFB; radar, telekomünikasyon, sonar, biyomedikal ve diğerleri gibi durağan olmayan gerçek hayat sinyallerinin analizi için önemli bir parametredir [76,77]. Genlik ve frekans modülasyonu gösterimi kullanılarak durağan olmayan işaretler Denklem 4.8’deki gibi modellenenbilmektedir [76].


$$s(t) = \sum_{k=1}^M s_k(t) = \sum_{k=1}^M a_k(t) \cos(\phi_k(t)) \quad (4.8)$$

$s(t)$ çok bileşenli bir işaret ise; M sinyal bileşenlerinin sayısıdır. $a_k(t)$ ise k sırasındaki işaret bileşeninin genliğini temsil etmektedir. $\phi_k(t)$ ise işaret anlık fazını vermektedir. Bir $a_k(t)$ düşük frekanslı işaretin $\cos(\phi_k(t))$ yüksek frekanslı bileşen üstünde örtüşme yapmadığı tahmin edilmektedir. Bir işaretin AFB işaretin anlık fazının zamana göre türevi olarak tanımlanmaktadır. AFB anlık fazın türevi olarak hesaplanması Denklem 4.9’da verilmiştir [76].

$$f_k(t) = \frac{d}{dt} \phi_k(t) \quad (4.9)$$

EEG üzerine yapılan çalışmalarda istenen frekans bileşenlerin seçimini sağlamaya yönelik AFB kullanılmaktadır [78]. EEG işaret işleme üzerine yapılan çalışmalarda alfa bant genliği ve anlık frekans bileşenin birbirinden bağımsız olduğu varsayılmaktadır. Matematik ve dinamik teorideki çalışmalar bu varsayımın beyin gibi karmaşık sistemlerde aşırı basitleştirme olabileceğini düşünmektedir. Ancak çok karmaşık bir yapıya sahip olan beynin aktivasyonları EEG işaretlerinin içerisine aynı karmaşıklık

ile yansımaktadır. Birbiri ile ilişkili nöronlardan oluşan beynin karmaşık yapısının herhangi bir uyarana karşı oluşan kortikal yanıtların genliği ve anlık frekans arasındaki etkileşimin olabileceği belirtilmiştir [79]. Bu ilişkiden yola çıkarak tez çalışmasında SpEn özelliğini destekleyici nitelikte AFB özelliği kullanılmak üzere tercih edilmiştir. Şekil 4.17’de Doktor, Polis, İtfaiye ve Aile uyarıları için elde edilen anlık frekans özellikleri örnek olarak gösterilmektedir.



Şekil 4.17 : Dört uyararı için AFB özellikleri örnek gösterimi.

4.7.3. Welch yöntemi

Welch yöntemi belirli bir frekans aralığında bir sinyalin ortalama gücünün hesaplanmasına yönelik kullanılmaktadır. EEG verileri için yaygın olarak tercih edilmektedir. Bir EEG işaretinin güç yoğunluğunu belirlemek için kullanılan bu yöntemin temeli fourier dönüşümüne dayanmaktadır. Bu yöntemde belirli parçalara bölünmüş EEG işaretleri üzerine Hızlı Fourier Dönüşümü (HFD) uygulanarak

spektrum belirlenmektedir. Belirlenen spektrumun ortalamasının alınması ile işaretin Güç Spektral Yoğunluğu (GSY) hesaplanmaktadır [80,81].

Sonlu N uzunluğundaki bir x_m EEG işareti için GSY değerleri Denklem 4.10'da verildiği gibi işaretin ayrık fourier dönüşümünün mutlak değerinin karesi olan periodogram yardımıyla ölçülür.

$$P_{xx}(f) = \frac{1}{N} |x(f)|^2 \quad (4.10)$$

Buradaki f işaretin bir parçasının frekansına karşılık gelmektedir. $x(f)$ ise işaretin fourier dönüşümüdür. Bir periodogram asimptotik olarak güçlü olmayan güç spektrumunun tahminini vermektedir. Welch yönteminde N uzunluğundaki bir işaret M uzunluğundaki K adet üstü üste binen parçalara ayrılır. i 'ninci parça için örnek hesaplama Denklem 4.11'de verilmiştir.

$$x_i(n) = x(n + iD) \quad (4.11)$$

Buradaki $n=0, \dots, N-1$, $i=0, \dots, K-1$ ve D ise sıradaki üste bindirilen parçayı temsil etmektedir. Bu hesaplama için kullanılan pencerelenmiş parça periodogramı Denklem 4.12'de verilmiştir.

$$P_{xx}^i(f) = \frac{1}{MU} \left| \sum_{n=0}^{N-1} w(n) x_i(n) e^{-j2\pi f n} \right|^2 \quad (4.12)$$


$w(n)$ ve U pencere işlevini ve gücünü hesaplayan pencere fonksiyonu Denklem 4.13'de verilmiştir.

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (4.13)$$

Son olarak K periodogramlarının ortalaması Denklem 4.14'de verildiği gibi alınarak Welch güç spektrumu hesaplanır [82].

$$P_{XX}^W = \frac{1}{K} \sum_{i=0}^{K-1} P_{xx}^i(f) \quad (4.14)$$

Tez çalışmasında önerilen paradigma üzerinden hazırlanmış verilerin Doktor, Polis, İtfaiye ve Aile uyarıları için elde edilen örnek Welch özellikleri ortalananmış güç spektrumu tahminleri Şekil 4.18’de verilmiştir.




Şekil 4.18 : Welch özellikleri ortalananmış güç spektrumu tahminleri.

4.8. Öznitelik Birleştirme

EEG işaretleri frekans alanında, zaman alanında, zaman – frekans alanında ve uzaysal alanda farklı bilgiler içermektedir. EEG işaretlerinin sınıflandırılmasında tek bir özelliğin kullanılması diğer özelliklerden yoksun kalınmasına sebep olmaktadır. Bu durum sınıflandırma başarımını olumsuz etkilemektedir [83]. Son yıllarda literatürde yapılan çalışmalarda EEG işaretlerinin sınıflandırılmasına yönelik tek bir özellik kullanmak yerine birden fazla özelliğin birleştirilmesi yöntemi kullanılmakta ve yeni teknikler önerilmektedir [84-86].

Bu çalışmada birbirini destekleyen özelliklerden SpEn ve AFB özelliklerine özellik birleştirme yöntemi uygulanmıştır. Özellik birleştirme yöntemi ile P300 tabanlı BBA sistemindeki EEG işaretlerini sınıflandırma başarımının yükseltilmesi amaçlanmıştır. Her iki özellik çıkarımına uygulanan ön işlenmiş, filtrelenmiş ve paradigmaya uygun parçalanmış 1x256 veri içeren EEG işaretleri ile yeni öznitelik vektörleri elde edilmiştir. Elde edilen öznitelik vektörleri her bir özellik için 1x29 veri içermektedir. Aynı ayır elde edilmiş öznitelik vektörleri 2x29 tek bir veri matrisi olarak birleştirilmiştir.

Örnek bir Doktor uyarısı için SpEn ve AFB özelliklerinin birlikte gösterimi Şekil 4.19'da verilmiştir.



Şekil 4.19 : Örnek Doktor uyarısı için SpEn ve AFB özellikleri.

4.9. Sınıflandırma

BBA sistemlerinde sisteme özgü özellikleri temsil eden işaretlerin ayrımının yapılabilmesi için sınıflandırma işlemine gereksinim duyulmaktadır. Biyomedikal işaretlerin sınıflandırılmasına yönelik günümüze kadar çok sayıda sınıflandırma tekniği kullanılmıştır. Sınıflandırma algoritmalarının yetenekleri geliştikçe performans başarımları doğru orantılı olarak artmaktadır. EEG işaretlerinin sınıflandırılmasına yönelik yapılan çalışmalarda son birkaç yıla kadar sıklıkla Bağımsız Bileşen Analizi, DVM, LDA gibi geleneksel yöntemler tercih edilmiştir. Son yıllarda görüntü işleme uygulamalarında sıklıkla kullanılmaya başlanan derin öğrenme algoritmaları EEG işaretlerinin sınıflandırılmasına yönelik kullanılmaktadır. Çalışmada öznitelik birleştirme yöntemi ve welch yöntemi ile elde edilen veriler TBESA, ÇYUKSBA ve DVM ile sınıflandırılmıştır.

4.9.1. Çift yönlü uzun kısa süreli bellek ağı (ÇYUKSBA) sınıflandırıcı

UKSB kendi kendine geri beslemeden tekrarlayan dizilerin kapasitesini tahmin edebilen Tekrarlayan Sinir Ağlarının TSA bir türüdür. UKSB yapısında her TSA düğümü düzensiz dizi üretebilen dahili hafızaya sahip olmasına rağmen TSA için eğim (gradient) probleminin ortadan kalkması veya büyümesi bu ağlar için sorun teşkil eder. Bu gibi problemleri ortadan kaldırmak için TSA hücresinin içine 3 kapı eklenerek UKSB ağı geliştirilmiştir [87].

Bu 3 kapı $g_i(t)$ giriş kapısı, $f_i(t)$ ihmal kapısı ve $q_i(t)$ çıkış kapısıdır. Ek olarak giriş kapıları hücreye giren yeni bilgi akışını kontrol eder. İhmal kapısı ise verinin hücrede saklanıp saklanmayacağına karar verirken çıkış kapısı ise çıkış üretildiği zaman devreye girer. Her kapının temelinde bir durum birimi vardır. $s_i(t)$. $g_i(t)$, $f_i(t)$, $h_i(t)$ ve $q_i(t)$ denklemleri aşağıda verilmiştir.

$$g_i^{(t)} = \sigma(b_i^g + \sum_j U_{i,j}^g x_j^{(t)} + \sum_j W_i^g h_j^{(t-1)}) \quad (4.15)$$

$$f_i^{(t)} = \sigma(b_i^f + \sum_j U_{i,j}^f x_j^{(t)} + \sum_j W_i^f h_j^{(t-1)}) \quad (4.16)$$

$$s_i^{(t)} = f_i^{(t)} s_i^{(t-1)} + g_i^{(t)} \sigma(b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} h_j^{(t-1)}) \quad (4.17)$$

$$h_i^{(t)} = \tanh(s_i^{(t)}) q_i^{(t)} \quad (4.18)$$

$$q_i^{(t)} = \sigma(b_i^0 + \sum_j U_{i,j}^0 x_j^{(t)} + \sum_j W_{i,j}^0 h_j^{(t-1)}) \quad (4.19)$$

Burada U aktif gizli katmandaki girişleri birbirine bağlayan ağırlık matrisi, W bir önceki gizli katman ile aktif gizli katmanı birbirine bağlayan ağırlık matrisidir. b bias olup U , W ve b 'nin alt simgesi olan i filtre numarasını gösterir. $x(t)$ ise aktif giriş vektörü ve $h_i(t)$ aktif gizli katmandır. Buradaki i bağlı hücreyi gösterir t her hücredeki zaman adımıdır. σ UKSB biriminde kapı gibi davranan sigmoid fonksiyonudur [16].

UKSB geçici bağlantılar kurmak için çalıştığı sürece bir dahili bellek hücresi kullanır. Bu dahili bellek hücresi UKSB yapısının en önemli birimidir. UKSB modülü aynı zamanda bir dizi özdeş zamanlama modülü içermektedir. Her modülün içerisinde TSA'daki eğim problemini ortadan kaldırmaya yönelik eklenmiş kapılar bulunmaktadır. Bu kapı yapılarının varlığından dolayı UKSB mimarisi her durumda ayrı ayrı etkilemektedir. Ağ bilgilerin seçici olarak geçmesini sağlamak için kapılarda aktivasyon fonksiyonu olarak 0 ve 1 arasındaki sigmoid fonksiyonunu kullanır. UKSB yapısındaki kapılarda sigmoid fonksiyon çıkışı 1 iken tüm bilgiler geçer sigmoid fonksiyonun çıkışı 0 iken bir bilgi geçişi olmamaktadır.


UKSB mimarisi tek yönlü bir iletim yapısına sahiptir ve sadece önceki bilgileri dikkate almaktadır. Bu mimari yapısı sebebiyle UKSB sonraki bilgileri dikkate almamaktadır. ÇYUKSBA hem önceki hem de sonraki bilgileri dikkate almaktadır. Buradaki temel prensip iki UKSB ağının zıt zamanlamalarla birbirine bağlanmasıdır. İleri UKSB giriş bilgilerinden önceki verilerin dikkate alınmasını sağlarken geriye doğru olan UKSB sonraki bilgilerin dikkate alınmasını sağlamaktadır. Gizli durum H_t ÇYUKSBA'nın t zamandaki ileri $\vec{h}_t$ ve geri $\overleftarrow{h}_t$ bilgilerini içermektedir. Bu yaklaşımın matematiksel ifadesi aşağıdaki denklemlerde verilmiştir [88,89].

$$\vec{h}_t = \overrightarrow{LSTM}(h_{t-1}, x_t, c_{t-1}), t \in [1, T] \quad (4.20)$$

$$\overleftarrow{h}_t = \overleftarrow{LSTM}(h_{t+1}, c_{t+1}), t \in [T, 1] \quad (4.21)$$

$$H_t = [\vec{h_t}, \overleftarrow{h_t}] \quad (4.22)$$

Çalışmada önerilen ÇYUKSBA mimarisi Şekil 4.20’de görüldüğü gibi altı katmandan oluşacak şekilde tasarlanmıştır. Öncelikle, 1x2 boyutunda 29 çekirdek girişi ilk katman olarak, NxMx29 blok şeklinde sıra giriş katmanı ise ikinci katman olarak yerleştirilmiştir. Üçüncü katman ise ağın çıkışını belirlemek ve sonraki katmanları ağa uygun hale getirmek için 1x2 bir ÇYUKSBA bloğundan oluşmaktadır. Dördüncü katmana yerleştirilen bir tam bağlantılı katman ile, ÇYUKSBA katmanı ve ağın çıkışına en uygun filtreleri aktarmak için kullanılan bir softmax katmanı ile birbirine bağlanmıştır. Son aşamada ise, bir sınıflandırma katmanı ile, dört farklı uyarının uygun bir şekilde sınıflandırılması sağlanmıştır.



Şekil 4.20 : Önerilen ÇYUKSBA mimarisi.

4.9.2. Tek boyutlu evrimsel sinir ağları (TBESA) sınıflandırıcı

Evrimsel Sinir Ağları (ESA) yerel bağlantı ve ağırlık paylaşımı yöntemlerini kullanan çok katmanlı bir algılayıcı sinir ağıdır. Ağırlıkların sayısı ağın optimize edilmesini kolaylaştırırken modelin karmaşıklığını azaltmak uyum riskinin azaltılmasını sağlamaktadır. Genel olarak ESA görüntüler gibi iki boyutlu veriler için kullanılmaktadır. Ancak literatürde tek boyutlu EEG işaretlerini sınıflandırmaya yönelik ESA ağı mimarisinin uygunlaştırılarak kullanımına son yıllarda sıklıkla rastlanmaktadır [90-92].

ESA ağları temel olarak giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Giriş katmanı bir boyutlu veya iki boyutlu verileri işleyebilmektedir.

Gizli katman evrişimsel katmanlardan, havuz katmanlarından ve tam bağlantılı katmanlardan oluşmaktadır. Evrişimli katman girdi verisinden özellik çıkarmaktadır. Havuz katmanı evrişimli katmandan aldığı özellikleri alarak özellik seçimi ve bilgi filtrelemesini gerçekleştirmektedir. Tam bağlantılı katman ise ileri beslemeli sinir ağındaki gizli katman gibi çalışarak çok boyutlu verileri vektörlere genişleterek bir sonraki katmana aktarma görevini gerçekleştirmektedir. ESA ağının çıktı katmanı ise softmax fonksiyonu veya lojistik fonksiyonu kullanarak sınıflandırma sonuçlarını ağın çıktısına iletmektedir. ESA ağlarının evrişim katmanı hesaplama ifadesi Denklem 4.23’de verilmiştir [93].

$$X_j^l = f \left(\sum_{i \in M_j} X_i^{l-1} * K_{ij}^{l-1} + b_j^l \right) \quad (4.23)$$

Denklemdeki X_j^l j sıradaki özellik haritası l sıradaki katman için M_j seçilen giriş özelliği kümesini temsil eder. K_{ij}^l evrişimli katmanın çekirdek fonksiyonunu temsil etmektedir. $f(\bullet)$ aktivasyon fonksiyonunu ve b_j^l ofset parametresini temsil etmektedir.

Özellik haritasındaki l sıradaki katmanın j ’ ninci hata işareti hesaplama Denklem 4.24’de verilmiştir. Denklemdeki ω_j^{l+1} $l+1$ sıradaki katmanın j ’ ninci özellik haritası ağırlığını temsil etmektedir. ip_j^l l sıradaki katmanın j ninci giriş değerini temsil etmektedir. $f(\bullet)$ aktivasyon fonksiyonunun kısmi türevini, $u(\bullet)$ ise örnekleme fonksiyonunu temsil etmektedir.

$$\delta_j^l = \omega_j^{l+1} \left(f'(ip_j^l) \cdot u(\delta_j^{l+1}) \right) \quad (4.24)$$

Evrişim çekirdeğinin ağırlık gradyan fonksiyonu Denklem 4.25’de verilmiştir.

$$\frac{\partial G}{\partial K_{ij}^l} = \sum_{u,v} (\delta_j^l)_{uv} (d_i^{l-1})_{uv} \quad (4.25)$$


Denklemdeki d_i^{l-1} , $l+1$ sıradaki katmanın i ’ ninci özellik haritası bloğunu temsil etmektedir. d_i^{l-1} evrişim işlevi sürecinde K_{ij}^l evrişim çekirdek fonksiyonu ile çarpılmaktadır. (u, v) evrişimli özellik haritasının konumunu temsil etmektedir. Havuzlama katmanı için hesaplama formülü Denklem 4.26’da verilmiştir.

$$X_j^l = f(\omega_j^l d(X_i^{l-1}) + b_j^l t) \quad (4.26)$$

Denklemdaki $d(\bullet)$ alt örnekleme fonksiyonunu temsil etmektedir. Havuzlama katmanının gradyan fonksiyonu Denklem 4.25'dekine benzer şekilde hesaplanmaktadır. ESA'nın belirli bir zamandaki ağırlık güncelleme ifadesi Denklem 27'de verilmiştir. Buradaki zaman t den $t+1$ e geçişi ifade etmektedir. φ öğrenme oranını temsil ederken, $\delta(t)$ hata terimini, $x(t)$ ise nöronun girdisini temsil etmektedir.

$$W(t + 1) = W(t) + \varphi \delta(t) x(t) \quad (4.27)$$

ESA verilerden basit örüntülerin tanımlayarak gelişmiş katmanlarda karmaşık örüntüler elde etmektedir. TBESA ağırları ile bir boyutlu işaretlerin analizi ve sınıflandırılmasında işaretlerin kısa bölümlerinde etkili özelliklerin elde edilmesiyle iyi bir performans başarmı sunmaktadır [93]. Önerilen TBESA mimarisi Şekil 4.21'de verilmiştir. Kullanılan TBESA mimarisi, 1x2 boyutunda 29 çekirdek girişi ilk katman olarak, NxMx16 blok şeklinde TBESA katmanı ise ikinci katman olarak yerleştirilmiştir. Üçüncü katman ise ağırlık eğitimindeki negatif değerlerin eğitimi olumsuz etkilemesinin önüne geçmek adına sigmoid fonksiyon içeren ReLu katmanından oluşmaktadır. Dördüncü katman olarak 128 çekirdekli girişi olan tab bağlantılı katman kullanılmıştır. Dördüncü katman olarak 64 çekirdekli girişi katmana uygulanan veriler en uygun filtreleri aktarmak için kullanılan bir softmax katmanı ile sınıflandırma katmanına bağlanmıştır. Son aşamada sınıflandırma katmanı ile, dört farklı uyarının uygun bir şekilde sınıflandırılması sağlanmıştır.




Şekil 4.21 : Önerilen TBESA mimarisi.

4.9.3. Destek vektör makinası (DVM) sınıflandırıcı

DVM çok sınıflı veri kümelerini sınıflandırmak için genişletilebilen bir ikili sınıflandırıcıdır. Literatürde EEG ve P300 tabanlı BBA sistemlerinin sınıflandırılmasında sıklıkla tercih edilmektedir [12,94]. DVM algoritması sezgiler üzerinde çalışır ve sınıfları ayıran bir karar sınırı oluşturarak verileri sınıflandırır. Bu

karar sınırına hiperdüzlem adı verilmektedir [95]. DVM sınıflandırma yöntemi öğrenme sürecinde eğitim verilerini kullanan denetimli makine öğrenme yöntemlerini kullanmaktadır. DVM sınıflandırıcı girişine uygulanan verileri aralarındaki maksimum mesafeye göre hiperdüzlem üzerinde iki alt alana bölerek hiperdüzlemi bulmaya çalışır. Hiperdüzlem ile veri arasındaki mesafeye kenar boşluğu denilmektedir. Hiperdüzleme en yakın veriler destek vektör verileri olarak adlandırılmaktadır. Veriler iki alt bölüme ayrıldığı için veri kümesi üzerinden iki destek vektör kümesi elde edilmektedir. Elde edilen destek vektör kümeleri pozitif ve negatif destek vektörler olarak adlandırılmaktadır [96]. Örnek bir DVM sınıflandırma işleminin grafiksel gösterimi Şekil 4.22’de verilmiştir.



Şekil 4.22 : Örnek DVM sınıflandırma işleminin grafiksel gösterimi.

Örnek olarak A ve B sınıfı için sınırlar sırasıyla Denklem 28 ve Denklem 4.29’da tanımlanmıştır.

$$\omega \cdot x + b = 1, \omega \in R^N, b \in R \quad (4.28)$$

$$\omega \cdot x + b = -1, \omega \in R^N, b \in R \quad (4.29)$$

Denklemlerdeki ω sınırı tanımlamaktadır. X giriş vektörü ve b ise sabit bir eşik değeridir. Kenar sınırlarının ortasına çizilen hiperdüzlemin tanımı Denklem 4.30’da verilmiştir.

$$\omega \cdot x + b = 0 \quad (4.30)$$

Denklem 4.31’de verilen karar fonksiyonu $f(x)$ veri noktasının A veya B noktasında olduğunu göstermektedir.

$$f(x) = \text{sign}(x \cdot \omega + b) \quad (4.31)$$

Veriler doğrusal olarak ayrılamazlar ise daha büyük bir boyuta eşlenerek ayrılabilir hale getirilirler. Bu sayede veriler doğrusal olarak ayrılabilir hale gelmektedir. Ekstra boyutta oluşturulan verilerin arasındaki karar sınırı matematiksel fonksiyonlar yardımı ile orijinal alt boyuta yansıtılabilmektedir. Bu süreç doğrusal olmayan sınıflandırma kategorisine girmektedir. DVM doğrusal olmayan bu durumlar için çekirdek fonksiyonlarını kullanmaktadır. Çekirdek fonksiyonu K , vektörleri orijinal uzaydan özellik uzayına eşleyen bir fonksiyondur. Çekirdek fonksiyonuna giren orijinal uzay vektörleri (X_i, X_j) Denklem 4.32’de gösterildiği gibi çıkış vektörlerinin nokta çarpımı ile hesaplanmaktadır [93].

$$K(X_i, X_j) = \phi(X_i) \cdot \phi(X_j) \quad (4.32)$$

DVM sınıflandırıcıda kullanılan çekirdek fonksiyonları Tablo 4.1’de verilmiştir [95].

Tablo 4.1 : DVM çekirdek fonksiyonları.

DVM Çekirdek Fonksiyonları	
Doğrusal Çekirdek	$K(X_i, X_j) = X_i \cdot X_j$
Polinomal Çekirdek	$K(X_i, X_j) = (\gamma X_i \cdot X_j + C)^d$
Gauss Çekirdek	$K(X_i, X_j) = \exp\left(-\frac{\ X_i - X_j\ ^2}{\gamma}\right)$
Gaus RBF Çekirdek	$K(X_i, X_j) = \exp\left(-\gamma \ X_i - X_j\ ^2\right)$
Sigmoid Çekirdek	$K(X_i, X_j) = \tanh(\gamma X_i^T \cdot X_j + C)$

4.10. Performans Metrikleri

P300 tabanlı BBA sistemlerinin performans değerlendirmesi sistemin sınıflandırma doğruluğu ve BTO değeri üzerinden yapılmaktadır. Çok sınıflı uyaran sistemi içeren BBA sistemlerinde sınıflandırma sonuçları karmaşıklık matrisi ile gösterilmektedir. Sınıflandırma sonucu elde edilen karmaşıklık matrisi ile tasarlanan sistemin avantaj ve dezavantajları etkili bir şekilde değerlendirilebilmektedir. Karmaşıklık matrisleri sınıflandırıcı girişine verilen veri kümelerinin sınıflandırma sonucundaki dağılımlarını göstermektedir. Karmaşıklık matrisi incelenirken veri kümesi içerisinde, doğru pozitif

sınıflandırılmış örnekler (DP) değerini, doğru negatif sınıflandırılmış örnekler (DN) değerini, sınıflandırıcının doğru negatif olarak sınıflandırması gereken örneği pozitif olarak sınıflandırması yanlış pozitif (YP) değerini ve sınıflandırıcının pozitif olarak sınıflandırması gereken örneği negatif sınıflandırması sonucu yanlış negatif (YN) değerini ifade etmektedir. Karmaşıklık matrisinde veri kümeleri arasındaki dağılımlar ile sistemin başarımını analiz etmeye yönelik metrikler hesaplanmaktadır. Bu metrikler doğruluk, keskinlik, hassasiyet (geri çağırma) ve F1 skorudur [97,98].

Doğruluk: Sistemin sınıflandırma sonucunda doğru sınıflandırılmış örneklerin oranını vermektedir. Doğruluk metriği formülü Denklem 4.33’de verilmiştir.

$$Doğruluk = 100 * \frac{DP + DN}{DP + DN + YP + YN} \quad (4.33)$$

Keskinlik: Sistemin sınıflandırma sonucunda bir veri kümesindeki tahminlerin ne kadarının gerçekten pozitif olduğu bilgisini vermektedir. Keskinlik metriği formülü Denklem 4.34’de verilmiştir.

$$Keskinlik = \frac{DP}{DP + YP} \quad (4.34)$$

Hassasiyet (Geri Çağırma): Sistemin sınıflandırma sonucunda sınıflandırılmış tüm pozitiflerin hangi oranda doğru olarak pozitif olduğu bilgisini vermektedir. Hassasiyet metriği formülü Denklem 4.35’de verilmiştir.

$$Hassasiyet = \frac{DP}{DP + DN} \quad (4.35)$$

F1 Skoru: Keskinlik ve Hassasiyet metriklerinin tek bir değer olarak gösterilmesini sağlamaktadır. F1 skoru bu iki metriğin harmonik ortalamasıdır. F1 skorunun formülü Denklem 4.36’da verilmiştir.

$$F1 = 2 * \frac{Keskinlik * Hassasiyet}{Keskinlik + Hassasiyet} \quad (4.36)$$

BTO değeri bir BBA sisteminde katılımcı ile bilgisayar arasındaki iletişimin performansını değerlendirmek en etkili ölçümlerden biridir. BTO değeri sistemin doğruluğuna, bir uyarıyı tanımak için geçen süreye ve sistemdeki uyarıların sayısına

bağlıdır. BTO değerinin hesaplanmasında kullanılan formül Denklem 4.37 ve Denklem 4.38’de verilmiştir.

$$B = \log_2 N + P \log_2 P + (1 - P) \log_2 \left[\frac{1 - P}{N - 1} \right] \quad (4.37)$$

$$BTO = Bx \frac{60}{t} \quad (4.38)$$

burada N uyaran sayısıdır, P ortalama performanstır ve t her seçim için zamanı gösterir [99].



BÖLÜM 5. DENEYSEL SONUÇLAR

Çalışmasında önerilen paradigma ile tasarlanan P300 tabanlı BBA sistemiyle kayıt altına EEG işaretlerine SpEn ve AFB öznitelik çıkarım teknikleri uygulanmış, elde edilen özellikler öznitelik birleştirme yöntemi ile birleştirilmiştir. Öznitelik birleştirme yönteminin sınıflandırma performansına etkisini görmek üzere veri kümesine ayrı olarak welch öznitelik yöntemi uygulanmıştır. P300 Tabanlı BBA sistemi için tasarlanan paradigma ile kayıt altına alınmış verilerden üretilmiş öznitelik verileri ÇYUKSBA, TBESA ve DVM sınıflandırma yöntemleri ile sınıflandırılmıştır. Uyarı odaklanma tespiti doğruluk performansı ve bilgi transfer oranı yardımıyla önerilen sistemin performans analizi yapılmıştır.

P300 tabanlı BBA sistemlerinin tasarlanmasında en önemli noktalardan biri sınıflandırma algoritmasının başarımıdır. Sınıflandırma algoritmalarından en iyi performansı almak uyaran paradigmasına, öznitelik çıkarım tekniğine ve sınıflandırıcının mimarisine bağlı olduğu gibi ağırlık eğitimi için kullanılan veri kümesinin büyüklüğü ile de ilişkilidir. P300 tabanlı sistemler için ağırlık eğitimi için büyük miktarda veri toplamak sistemin en büyük sorunlarından biridir. Bu sorunu çözmeye yönelik son yıllarda sınıflandırma algoritmalarına uygulanan veri kümeleri üzerinde veri artırım teknikleri uygulanmaya başlanmıştır. Katılımcılardan toplanmış verilere 10 kat veri artırım işlemi uygulanmıştır. Veri artırımı sonucu 4 uyarının her biri için 1600 adet olan toplamda 6400 P300 işareti veri kümesini oluşturmaktadır. Bu verilerin %90'ı eğitim %10'u test için rasgele yöntem ile ayrılmıştır. Eğitim verisi kümesi toplam 5760 P300 işareti içeren örnekten oluşurken test veri kümesi 640 adet P300 işareti içeren örnekten oluşmaktadır. Eğitim ve Test verileri kümelerindeki uyaran dağılımı eşit orandadır.

Katılımcılara gösterilen Doktor, Polis, İtfaiye ve Aile uyarılarını sınıflandırma sonuçlarında Tablo 5.1'de verildiği şekilde sembolik olarak gösterilmiştir.


Tablo 5.1 : Uyarıların sembolik gösterimi.

Uyarı Adı	Sembolik Gösterimi
Aile	A
Doktor	D
İtfaiye	İ
Polis	P

5.1. Çift Yönlü Uzun Kısa Süreli Bellek Ağı (ÇYUKSBA) Sınıflandırıcı Analiz Sonuçları

5.1.1. Öznetelik birleştirme sonuçları

Sınıflandırma için kullanılan ÇYUKSBA sınıflandırıcı ile yapılan çalışmalarda en iyi sonuçların elde edildiği ağı öğrenme fonksiyonu olarak “adam” kullanılmıştır. Kullanılan ağı öğrenme oranı 0.2, bırakma oranı %20 olarak kullanılmıştır. Öznetelik birleştirme veri kümesi ÇYUKSBA eğitim grafiği Şekil 5.1'de verilmiştir. Elde edilen eğitim başarımına her bir epok da 38 iterasyon olmak üzere toplamda 76 iterasyonda ulaşılmıştır.



Şekil 5.1 : Öznetelik birleştirme veri kümesi ÇYUKSBA eğitim grafiği.

SpEn ve AFB özelliklerine öznitelik birleştirme tekniği uygulanarak çıkarılan öznitelik verileri ÇYUKSBA ile eğitim veri kümesi sınıflandırma sonuçları Tablo 5.2'deki karmaşıklık matrisinde verilmiştir. Karmaşık matrisindeki dört çapraz hücre ağ tarafından doğru sınıflandırmış örnek sayılarını vermektedir. Aile, Doktor ve Polis uyarıları için 1440 örneğin tamamı doğru bir şekilde sınıflandırılmıştır. Ancak İtfaiye uyararı için 1440 örneğin 1360 adeti doğru olarak sınıflandırılırken 80 adeti hatalı olarak polis uyararı olarak sınıflandırılmıştır. Bu hatalı örnekler İtfaiye uyararı veri kümesinin %5.6'sını temsil etmektedir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %98.6'sı doğru, %1.4'ü hatalı olarak sınıflandırılmıştır.

Tablo 5.2 : ÇYUKSBA öznitelik birleştirme eğitim verileri karmaşıklık matrisi.

Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1440	0	0	0	100% 0%
	D	0	1440	0	0	100% 0%
	İ	0	0	1360	0	100% 0%
	P	0	0	80	1440	94.7% 5.3%
Doğruluk		100%	100%	94.4%	100%	98.6%
Hata		0%	0%	5.6%	0%	1.4%
		A	D	İ	P	
		Hedef Sınıf				


Öznitelik birleştirme yöntemi kullanılarak oluşturulan öznitelik verileri ÇYUKSBA eğitimi sonucunda karmaşıklık matrisinden elde edilen her bir uyararı için hesaplanmış metrikler Tablo 5.3'de verilmiştir. Aile, Doktor ve Polis uyarıları için keskinlik değeri istenen en yüksek değeri olan 1 olarak elde edilmiştir. İtfaiye uyararındaki hatalı sınıflandırma örneklerinden dolayı bu uyararı veri kümesinin keskinlik değeri 0.9444 olarak elde edilmiştir. Hassasiyet metrikleri incelendiğinde, Polis uyararı veri kümesinin hassasiyeti 0.94737 olarak hesaplanmıştır. İtfaiye uyararı veri kümesinin 80 örneğinin Polis uyararı olarak hatalı sınıflandırılması bu uyararı veri kümesinin hassasiyet değerinin düşmesine ve 0.94737 olarak hesaplanmasına sebep olmuştur. Diğer uyararı veri kümeleri

için istenen en yüksek seviyede hassasiyet değeri 1 olarak hesaplanmıştır. Hesaplanan metriklerin F1 skoru incelendiğinde İtfaiye ve Polis uyararı veri kümelerindeki hatalı sınıflandırmalar sebebiyle İtfaiye uyararı F1 skoru 0.97143, Polis uyararı F1 skoru 0.97297 olarak hesaplanmıştır. Doktor ve Aile için ise bu skor en yüksek değer olan 1 olarak hesaplanmıştır.

Tablo 5.3 : ÇYUKSBA öznelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	1	1
Doktor	1	1	1
İtfaiye	0.9444	1	0.97143
Polis	1	0.94737	0.97297

Öznelik birleştirme uygulanmış veriler için eğitim veri seti ÇYUKSBA sınıflandırma sonucunda uyaran veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.2’de verilmiştir.



Şekil 5.2 : ÇYUKSBA öznelik birleştirme eğitim verileri sınıflandırma dağılımı.

ÇYUKSBA yöntemi ile eğitilmiş ağa uygulanan 640 P300 işareti içeren test veri kümesinin sınıflandırma sonuçları Tablo 5.4’deki karmaşıklık matrisinde verilmiştir. Sınıflandırma sonuçlarına göre Doktor ve Aile uyararı veri kümeleri %100 başarımla sınıflandırılırken İtfaiye uyararı veri kümesi 20 adet örneği Polis uyararı veri kümesi

olarak hatalı sınıflandırılmıştır. Polis uyararı veri kümesindeki 20 hatalı örnek verinin %12.5'ini temsil etmektedir. 160 örneğin 140'ı doğru sınıflandırılan İtfaiye uyararı veri kümesi için sınıflandırma başarımı %87.5 olarak elde edilmiştir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %96.9'u doğru, %3.1'i hatalı olarak sınıflandırılmıştır.

Tablo 5.4 : ÇYUKSBA öznelitik birleştirme test verileri karmaşıklık matrisi.


Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	160	0	0	0	100% 0%
	D	0	160	0	0	100% 0%
	İ	0	0	140	0	100% 0%
	P	0	0	20	160	88.9% 11.1%
	Doğruluk	100%	100%	87.5%	100%	96.9%
	Hata	0%	0%	12.5%	0%	3.1%
		A	D	İ	P	
		Hedef Sınıf				

Eğitim veri kümesi ile ÇYUKSBA ile eğitilmiş ağa uygulanan test veri kümesi karmaşıklık matrisinden elde edilen her bir uyararı için ayrı olarak hesaplanmış metrikler Tablo 5.5'de verilmiştir. Aile, Doktor ve Polis uyararı veri kümeleri için keskinlik değeri istenen en yüksek değeri olan 1 olarak hesaplanmıştır. İtfaiye uyararı veri kümesindeki 20 örneğin hatalı sınıflandırmasından dolayı bu uyararı veri kümesinin keskinlik değeri 0.875 olarak elde edilmiştir. İtfaiye uyararı 20 örneğinin Polis uyararı veri kümesinde hatalı sınıflandırılması bu uyararı kümesinin hassasiyet değerinin 0.88889 olarak hesaplanmasında etkili olmuştur. Diğer uyararı veri kümeleri için istenen en yüksek seviyede hassasiyet değeri 1 olarak hesaplanmıştır. Hesaplanan metriklerin F1 skoru incelendiğinde İtfaiye ve Polis uyararı veri kümelerindeki hatalı sınıflandırmalar sonucunda İtfaiye uyararı F1 skoru 0.9333, Polis uyararı F1 skoru 0.94118 olarak hesaplanmıştır. Doktor ve Aile için ise bu skor 1 olarak hesaplanmıştır.

Tablo 5.5 : ÇYUKSBA öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	1	1
Doktor	1	1	1
İtfaiye	0.875	1	0.9333
Polis	1	0.88889	0.94118


Eğitilmiş ÇYUKSBA’na uygulanan test veriler için uyaran veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.3’de verilmiştir.



Şekil 5.3 : ÇYUKSBA öznitelik birleştirme test verileri sınıflandırma dağılımı.

5.1.2. Welch özniteliği sonuçları

Welch özellikleri çıkarılmış veri kümesinin sınıflandırılmasında kullanılan ÇYUKSBA’nın öğrenme fonksiyonu, öğrenme oranı ve bırakma oranı öznitelik birleştirmede kullanılan parametreler ile aynı seçilmiştir. Welch veri kümesi ÇYUKSBA eğitim grafiği Şekil 5.4’de verilmiştir. Elde edilen eğitim başarımına her bir epok da 38 iterasyon olmak üzere toplamda 570 iterasyonda ulaşılmıştır.



Şekil 5.4 : Welch özniteliği veri kümesi ÇYUKSBA eğitim grafiği.

Önerilen paradigmanın P300 tabanlı BBA uygulamalarında genellikle tercih edilen Welch yöntemi ile elde edilmiş öznitelik verileri ÇYUKSBA ile eğitilmiştir. Eğitim sonuçlarını gösterir sonuçlar Tablo 5.6'daki karmaşıklık matrisinde gösterilmektedir. Eğitim verileri sonuçları incelendiğinde ağ girişine uygulanan sınıflandırma verilerinden sadece Aile uyararı veri kümesinin tamamı doğru olarak sınıflandırılmıştır. Doktor uyararı veri kümesindeki örneklerden 100'ü Polis uyararı veri kümesinde, 80'i Aile uyararı veri kümesinde ve 80'i İtfaiye uyararı veri kümesinde hatalı olarak sınıflandırılırken 1180 adet Doktor uyararı örneği doğru olarak sınıflandırılabilmiştir. 260 adet hatalı sınıflandırılmış Doktor veri kümesi örneği bu uyararı örneklerinin %18.1'lik bölümünü temsil etmektedir. İtfaiye uyararı veri kümesinden 80 örnek Polis uyararı veri kümesinde hatalı sınıflandırılmıştır. Bu hatalı örnekler İtfaiye uyararı veri kümesinin %5.6'sını temsil etmektedir. Polis uyararı veri kümesindeki 100 örnek Aile uyararı veri kümesinde hatalı olarak sınıflandırılmıştır. Hatalı sınıflandırılmış 100 örnek Polis uyararı veri kümesinin %6.9'luk bölümünü temsil etmektedir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %92.4'ü doğru, %7.6'sı hatalı olarak sınıflandırılmıştır.

Tablo 5.6 : ÇYUKSBA Welch özniteliği eğitim verileri karmaşıklık matrisi.

Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1440	80	0	100	88.9% 11.1%
	D	0	1180	0	0	100% 0%
	İ	0	80	1360	0	94.4% 5.6%
	P	0	100	80	1340	88.2% 11.8%
	Doğruluk	100%	81.9%	94.4%	93.1%	92.4%
	Hata	0%	18.1%	5.6%	6.9%	7.6%
		A	D	İ	P	
		Hedef Sınıf				


Welch yöntemi kullanılarak oluşturulan öznitelik verileri ÇYUKSBA eğitimi sonucunda karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.7’de verilmiştir. Aile uyararı veri kümesi için keskinlik değeri istenen en yüksek değer olan 1 olarak elde edilmiştir. Doktor, İtfaiye ve Polis örneğindeki hatalı sınıflandırma örneklerinden dolayı keskinlik değerleri Doktor uyararı için 0.81944, İtfaiye uyararı için 0.94444 ve Polis uyararı için 0.93056 olarak hesaplanmıştır. Hassasiyet metrikleri incelendiğinde, Doktor uyararı veri kümesinde sınıflandırılmış hatalı örnek olmaması sebebi ile hassasiyet metriği 1 olarak elde edilmiştir. Aile uyararı veri kümesi olarak hatalı sınıflandırılan 80 Doktor uyararı örneği ve 100 Polis uyararı örneği bu uyarar için hassasiyet değerinin düşmesine sebep olmuştur. Hatalı sınıflandırmalar sonucu Aile uyararı için hassasiyet değeri 0.88889 olarak hesaplanmıştır. Doktor uyararı veri kümesinin 80 örneğinin İtfaiye uyararı veri kümesi olarak hatalı sınıflandırılması sonucu İtfaiye uyararı hassasiyet değerinin 0.94444 hesaplanmasına sebep olmuştur. Polis uyararı veri kümesi olarak hatalı sınıflandırılmış 100 Doktor uyararı örneği ve 80 İtfaiye uyararı örneği Polis uyararı veri kümesinin hassasiyet değerinin 0.88158 olarak hesaplanmasına sebep olmuştur. Polis uyararı ve aile uyararındaki hatalı sınıflandırma sayısı aynı olmasına rağmen Aile uyararı örneklerinin tamamının doğru sınıflandırılmış olması daha iyi bir hassasiyet değerinin elde edilmesini sağlamıştır. F1 skorları incelendiğinde en iyi skorun 0.94444 ile İtfaiye uyararı

örneklerinin sahip olduğu görülmektedir. F1 skoru, Doktor uyarani veri kümesi için 0.90076, İtfaiye uyarani veri kümesi için 0.94444 ve Polis uyarani veri kümesi için 0.90541 olarak hesaplanmıştır.

Tablo 5.7 : ÇYUKSBA Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri.

Uyarani Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.88889	0.94118
Doktor	0.81944	1	0.90076
İtfaiye	0.94444	0.94444	0.94444
Polis	0.93056	0.88158	0.90541

Welch özniteliği uygulanmış veriler için eğitim veri seti ÇYUKSBA sınıflandırma sonucunda uyarani veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.5’de verilmiştir.



Şekil 5.5 : ÇYUKSBA Welch özniteliği eğitim verileri sınıflandırma dağılımı.

ÇYUKSBA yöntemi ile eğitilmiş ağa uygulanan Welch yöntemi ile elde edilmiş 640 P300 işareti içeren test veri kümesinin sınıflandırma sonuçları Tablo 5.8’deki karmaşıklık matrisinde verilmiştir. Sınıflandırma sonuçlarına göre Aile ve Polis uyarani veri kümelerinin tamamı doğru sınıflandırılırken Doktor uyarani 40 örneğinden 20 örneğinin Aile, 20 örneğinin ise İtfaiye uyarani veri kümesinde hatalı olarak sınıflandırıldığı görülmektedir. Doktor uyarani veri kümesindeki 40 hatalı sınıflandırma bu veri kümesinin

%25 'ini temsil etmektedir. İtfaiye uyarani veri kümesindeki 20 örneğin Polis uyarani veri kümesinde hatalı olarak sınıflandırıldığı görülmektedir. Hatalı sınıflandırılmış 20 İtfaiye uyarani veri kümesi örneği bu uyarandaki verilerin tamamının %12.5'ini temsil etmektedir. Tüm uyarani veri kümeleri için sınıflandırma sonuncunda tahminlerin %90.6'sı doğru, %9.4'ü hatalı olarak sınıflandırılmıştır.

Tablo 5.8 : ÇYUKSBA Welch özneliği test verileri karmaşıklık matrisi.

Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	160	20	0	0	88.9% 11.1%
	D	0	120	0	0	100% 0%
	İ	0	20	140	0	87.5% 12.5%
	P	0	0	20	160	88.9% 11.1%
	Doğruluk	100%	75%	87.5%	100%	90.6%
	Hata	0%	25%	12.5%	0%	9.4%
		A	D	İ	P	
		Hedef Sınıf				


Eğitim veri kümesi ile ÇYUKSBA eğitilmiş ağına uygulanan welch özellikleri içerir test veri kümesi sınıflandırma sonucu karmaşıklık matrisinden elde edilen metrikler Tablo 5.9'da verilmiştir. Aile ve Polis uyarani veri kümelerinin tamamı doğru sınıflandırıldığı için keskinlik değeri istenen en yüksek değer olan 1 olarak hesaplanmıştır. İtfaiye uyarani veri kümesindeki hatalı sınıflandırılmış 20 Doktor uyarani örnekleri sebebiyle ile bu uyarani keskinlik değeri 0.875 olarak hesaplanmıştır. Doktor uyarani veri kümesindeki örneklerden sadece 120 örnek doğru sınıflandırıldığı için keskinlik metriği 0.75 olarak hesaplanmıştır. Sınıflandırma sonucu karmaşıklık matrisinin hassasiyet metrikleri incelendiğinde Doktor uyarani veri kümesinde sınıflandırılmış diğer kümelerden hatalı bir örnek olmadığı için hassasiyet değeri 1 olarak hesaplanmıştır. Aile ve Polis uyarani veri kümelerinde 20 adet farklı uyarani örneklerinin hatalı sınıflandırılması sonucu bu uyarani veri kümelerinin hassasiyet metriği 0.88889 olarak hesaplanmıştır. İtfaiye uyarani veri kümesindeki 160 örneğin 140'ının doğru sınıflandırılması ve 20 doktor örneğinin

hatalı olarak bu grupta sınıflandırılması İtfaiye uyarını için hassasiyet metriğinin 0.875 olarak hesap edilmesine sebep olmuştur. F1 skorları incelendiğinde 0.94118 değeri ile Aile ve Polis uyarını veri kümeleri en yüksek skora sahiptir. İtfaiye uyarını ver kümesi için F1 skoru 0.875 hesaplanırken Doktor uyarını veri kümesinin F1 skoru 0.875 ile en düşük değere sahip olmuştur.

Tablo 5.9 : ÇYUKSBA Welch özneliği test verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.88889	0.94118
Doktor	0.75	1	0.85714
İtfaiye	0.875	0.875	0.875
Polis	1	0.88889	0.94118

Welch özneliği uygulanmış veriler için test veri seti ÇYUKSBA sınıflandırma sonucunda uyarın veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.6'de verilmiştir.




Şekil 5.6 : ÇYUKSBA Welch özneliği test verileri sınıflandırma dağılımı.

5.2. Tek Boyutlu Evrimsel Sinir Ağı (TBESA) Sınıflandırıcı Analiz Sonuçları

5.2.1. Öznitelik birleştirme sonuçları

Sınıflandırma için kullanılan TBESA sınıflandırıcı ile yapılan çalışmalarda en iyi sonuçların elde edildiği ağı öğrenme fonksiyonu olarak “sgdm” kullanılmıştır. Kullanılan ağı öğrenme oranı 0.2 kullanılmıştır. Öznitelik birleştirme veri kümesi TBESA ağı eğitim grafiği Şekil 5.7’de verilmiştir. Elde edilen eğitim başarımına her bir epok da 96 iterasyon olmak üzere toplamda 288 iterasyonda ulaşılmıştır.



Şekil 5.7 : Öznitelik birleştirme veri kümesi TBESA eğitim grafiği.

Öznitelik birleştirme tekniği uygulanarak çıkarılan öznitelik verileri eğitim veri seti için TBESA sınıflandırma sonuçları Tablo 5.10’daki karmaşıklık matrisinde verilmiştir. Aile ve Doktor uyararı veri kümeleri için 1440 örneğin tamamı doğru bir şekilde sınıflandırılmıştır. Ancak İtfaiye uyararı veri kümesi 1440 örneğinden 1340 adeti doğru olarak sınıflandırılırken 100 örnek Aile uyararı veri kümesi olarak hatalı sınıflandırılmıştır. Bu hatalı örnekler İtfaiye uyararı veri kümesinin %6.9’unu temsil etmektedir. Polis uyararı veri kümesindeki 1440 örneğin 1380 adeti doğru olarak sınıflandırılırken 60 örnek Doktor uyararı veri kümesinde hatalı olarak sınıflandırılmıştır. Polis uyararı veri kümesindeki 60 hatalı örnek bu uyararı veri kümesinin %4.2’sini temsil

etmektedir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %97.2'si doğru, %2.8'i hatalı olarak sınıflandırılmıştır.

Tablo 5.10 : TBESA öznelik birleştirme eğitim verileri karmaşıklık matrisi.

Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1440	0	100	0	93.5% 6.5%
	D	0	1440	0	60	96.0% 4.0%
	İ	0	0	1340	0	100% 0%
	P	0	0	0	1380	100% 0%
	Doğruluk	100%	100%	93.1%	95.8%	97.2%
	Hata	0.0%	0.0%	6.9%	4.2%	2.8%
		A	D	İ	P	
		Hedef Sınıf				


Öznelik birleştirme yöntemi kullanılarak elde edilen eğitim veri setinin TBESA eğitimi sonucunda karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.11'de verilmiştir. Aile ve Doktor uyararı veri kümelerindeki 1440 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyararların keskinlik metrikleri 1 olarak hesaplanmıştır. Polis uyararı veri kümesinde 60 örneğin hatalı sınıflandırılması sonucu bu uyararın keskinlik metrik değeri 0.95833 olarak hesaplanmıştır. İtfaiye uyararı veri kümesindeki hatalı sınıflandırılan 100 örnek sonucu 0.93056 keskinlik metrik değeri ile dört uyararı arasındaki en düşük değere sahiptir. İtfaiye ve Polis uyararı veri kümelerinin hassasiyet metriği bu uyararı sınıflarında hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Polis uyararı örneklerinden 60 tanesinin Doktor uyararı sınıfında tahmin edilmesi sonucu Doktor uyararı hassasiyet değeri 0.96 bulunmuştur. İtfaiye uyararı örneklerinden 100 tanesinin Aile uyararı veri kümesinde sınıflandırılması Aile uyararı hassasiyet değerinin 0.93506 ile en düşük olarak hesaplanmasına sebep olmuştur. F1 skorları incelendiğinde en yüksek F1 skoruna 0.97959 ile Doktor uyararı veri kümesi sahiptir. Diğer uyararı veri kümelerinin F1

skorları sırası ile Polis uyararı için 0.97872, Aile uyararı için 0.96644 ve İtfaiye uyararı için 0.96403 olarak hesaplanmıştır.

Tablo 5.11 : TBESA öznitelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.93506	0.96644
Doktor	1	0.96	0.97959
İtfaiye	0.93056	1	0.96403
Polis	0.95833	1	0.97872

Öznitelik birleştirme yöntemi uygulanmış verilerin eğitim veri seti için TBESA sınıflandırma sonucunda uyaran veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.8’de verilmiştir.



Şekil 5.8 : TBESA öznitelik birleştirme eğitim verileri sınıflandırma dağılımı.

TBESA eğitilmiş ağına uygulanan 640 P300 işareti içeren test veri kümesinin sınıflandırma sonuçları karmaşıklık matrisi Tablo 5.12’de verilmiştir. Sınıflandırma sonuçlarına göre Aile ve İtfaiye uyaran veri kümeleri %100 başarımla sınıflandırılırken Doktor uyararı veri kümesinden 10 örnek Polis uyararı veri kümesinde hatalı sınıflandırılmıştır. Hatalı sınıflandırılan 10 örnek Doktor veri kümesinin %6.2’sini temsil etmektedir. Polis uyararı veri kümesinden 20 örnek hatalı olarak Aile uyararı olarak sınıflandırılmıştır. Hatalı sınıflandırılan 20 örnek Polis uyararı veri kümesinin %12.5’ini

temsil etmektedir. Tüm uyarıcı veri kümeleri için sınıflandırma sonucunda tahminlerin %95.3'ü doğru, %4.7'i hatalı olarak sınıflandırılmıştır.

Tablo 5.12 : TBESA öznelik birleştirme test verileri karmaşıklık matrisi.

Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	160	0	0	20	88.9% 11.1%
	D	0	150	0	0	100.0% 0.0%
	İ	0	0	160	0	100% 0%
	P	0	10	0	140	93.3% 6.7%
	Doğruluk	100%	93.8%	100%	87.5%	95.3%
	Hata	0.0%	6.2%	0.0%	12.5%	4.7%
		A	D	İ	P	
		Hedef Sınıf				


TBESA eğitilmiş ağına uygulanan test veri kümesi sınıflandırma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.13'de verilmiştir. Aile ve İtfaiye uyarıcı veri kümelerindeki 160 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyarıcıların keskinlik metrikleri 1 olarak hesaplanmıştır. Doktor uyarıcı veri kümesindeki hatalı 10 örnek sınıflandırması sonucu bu veri kümesinin keskinlik değeri 0.9375 olarak hesaplanmıştır. Polis uyarıcı veri kümesi 20 hatalı örnek sınıflandırma sonucunda 0.875 keskinlik metriği değeri ile dört uyarıcı arasındaki en düşük değere sahiptir. Doktor ve İtfaiye uyarıcı veri kümeleri hassasiyet metriği bu uyarıcı sınıflarında hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Doktor uyarıcı veri kümesindeki 10 örneğin Polis uyarıcı veri kümesinde sınıflandırılması sonucu Polis uyarıcı veri kümesi hassasiyet değeri 0.93333 hesaplanmıştır. Polis uyarıcı örneklerinden 20 tanesinin Aile uyarıcı veri kümesinde sınıflandırılması Aile uyarıcı veri kümesinin hassasiyet değerinin 0.88889 ile en düşük olarak hesaplanmasına sebep olmuştur. F1 skorları incelendiğinde en yüksek F1 skoruna 1 ile İtfaiye uyarıcı veri kümesi sahiptir. Diğer uyarıcı veri kümeleri F1 skorları sırası ile

Doktor uyararı için 0.96774, Aile uyararı için 0.94118 ve İtfaiye uyararı için 0.90323 olarak hesaplanmıştır.

Tablo 5.13 : TBESA öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.88889	0.94118
Doktor	0.9375	1	0.96774
İtfaiye	1	1	1
Polis	0.875	0.93333	0.90323


Öznitelik birleştirme yöntemi uygulanmış verilerin test veri seti için TBESA sınıflandırma sonucunda uyaran veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.9’da verilmiştir.



Şekil 5.9 : TBESA öznitelik birleştirme test verileri sınıflandırma dağılımı.

5.2.2. Welch özniteliği sonuçları

Welch özellikleri çıkarılmış veri kümesinin sınıflandırılmasında kullanılan TBESA’nın öğrenme fonksiyonu ve öğrenme oranı öznitelik birleştirmede kullanılan parametreler ile aynı seçilmiştir. Welch veri kümesi TBESA eğitim grafiği Şekil 5.10’da verilmiştir. Elde edilen eğitim başarımına her bir epok da 115 iterasyon olmak üzere toplamda 19550 iterasyonda ulaşılmıştır.



Şekil 5.10 : Welch veri kümesi TBESA eğitim grafiği.

Tablo 5.14 : TBESA Welch özneteliği eğitim verileri karmaşıklık matrisi.

Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1260	0	0	0	100% 0%
	D	0	1440	0	100	93.5% 6.5%
	İ	180	0	1440	0	88.9% 11.1%
	P	0	0	0	1340	100% 0%
	Doğruluk	87.5%	100%	100%	93.1%	95.1%
	Hata	12.5%	0.0%	0.0%	6.9%	4.9%
		A	D	İ	P	
Hedef Sınıf						

Welch yöntemi ile elde edilmiş veri setinin TBESA eğitim sonuçları Tablo 5.14'deki karmaşıklık matrisinde gösterilmektedir. Karmaşıklık matrisi incelendiğinde ağ girişine uygulanan sınıflandırma verilerinden Doktor ve İtfaiye uyararı veri kümelerinin 1440 örneğinin tamamı doğru olarak sınıflandırılmıştır. Aile uyararı veri kümesindeki


örneklerden 180'i İtfaiye uyararı veri kümesinde hatalı olarak sınıflandırılmıştır. Aile uyararı veri kümesindeki hatalı sınıflandırılmış örnekler Aile veri kümesinin %12.5'ini temsil etmektedir. Polis uyararı veri kümesi sınıflandırma sonucu incelendiğinde bu veri kümesinin %6.9'unu temsil eden 100 örnek Doktor uyararı olarak hatalı sınıflandırılmıştır. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %95.1'i doğru, %4.9'u hatalı olarak sınıflandırılmıştır.

Welch özelliklerini içeren eğitim veri setinin TBESA ile sınıflandırılma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.15'de verilmiştir. Doktor ve İtfaiye uyararı veri kümelerindeki 1440 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyararların keskinlik metrikleri 1 olarak hesaplanmıştır. Polis uyararı veri kümesindeki 100 örneğin hatalı sınıflandırılması sonucu bu veri kümesinin keskinlik metrik değeri 0.93056 olarak hesaplanmıştır. Aile uyararı veri kümesi 180 örneğin hatalı sınıflandırılması sonucunda 0.875 keskinlik metriği değeri ile dört uyararı arasındaki en düşük değere sahiptir. Aile ve Polis uyararı veri kümelerinin hassasiyet metriği bu uyararı sınıflarında hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Polis uyararı veri kümesinden 100 örneğin hatalı olarak Doktor uyararı veri kümesinde tahmin edilmesi sonucu Doktor uyararı hassasiyet değeri 0.93506 hesaplanmıştır. Aile uyararı veri kümesindeki 180 örneğin İtfaiye uyararı veri kümesinde hatalı sınıflandırılması sonucu İtfaiye uyararı hassasiyet değeri 0.88889 değeri ile en düşük olarak hesaplanmasına sebep olmuştur. F1 skorları incelendiğinde en yüksek F1 skoruna 0.96644 ile Doktor uyararı veri kümesi sahiptir. Diğer uyararı veri kümeleri F1 skorları sırası ile Polis uyararı için 0.96403, İtfaiye uyararı için 0.94118 ve Aile uyararı için 0.93333 olarak hesaplanmıştır.

Tablo 5.15 : TBESA Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri.

Uyararı Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	0.875	1	0.93333
Doktor	1	0.93506	0.96644
İtfaiye	1	0.88889	0.94118
Polis	0.93056	1	0.96403

Welch yöntemi uygulanmış verilerin eğitim veri seti için TBESA sınıflandırma sonucunda uyarın veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.11’de verilmiştir.



Şekil 5.11 : TBESA Welch özniteliği eğitim verileri sınıflandırma dağılımı.

Tablo 5.16 : TBESA Welch özniteliği test verileri karmaşıklık matrisi.

Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	D	İ	P		
	160	0	0	0	100%	0%
	0	160	0	40	80.0%	20.0%
	0	0	160	0	100%	0%
Doğruluk	0	0	0	120	100%	0%
	100%	100%	100%	75.5%	93.8%	
	0.0%	0.0%	0.0%	25.0%	6.3%	
	A	D	İ	P		
Hedef Sınıf						


TBESA ile eğitilmiş ağa uygulanan Welch özelliği içeren 640 test veri kümesinin sınıflandırma sonuçları karmaşıklık matrisi Tablo 5.16'da verilmiştir. Sınıflandırma sonuçlarına göre Aile, Doktor ve İtfaiye uyararı veri kümeleri örneklerinin tamamı doğru sınıflandırılırken Polis uyararı veri kümesi 40 örneğinin Doktor uyararı olarak hatalı sınıflandırılmıştır. Hatalı sınıflandırılan 40 örnek Polis uyararı veri kümesinin %25'ini temsil etmektedir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %93.8'i doğru, %6.3'ü hatalı olarak sınıflandırılmıştır.

TBESA eğitilmiş ağına uygulanan test veri kümesi sınıflandırma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.17'de verilmiştir. Aile, Doktor ve İtfaiye uyararı veri kümelerindeki 160 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyararların keskinlik metrikleri 1 olarak hesaplanmıştır. Polis uyararı veri setindeki 40 örneğin hatalı sınıflandırması sonucu Polis uyararı keskinlik değeri 0.75 olarak hesaplanmıştır. Aile, İtfaiye ve Polis uyararları hassasiyet metriği bu uyararı veri kümelerinde hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Polis uyararı veri kümesinden 40 örneğin Doktor uyararı veri kümesinde tahmin edilmesi sonucu Polis uyararı hassasiyet değeri 0.8 hesaplanmıştır. F1 skorları incelendiğinde en yüksek F1 skoruna 1 ile 0.75 ile Aile ve İtfaiye uyararı veri kümeleri sahiptir. Diğer uyararı veri kümelerinin F1 skorları sırası ile Doktor uyararı için 0.88889, Polis uyararı için 0.85714 olarak hesaplanmıştır.

Tablo 5.17 : TBESA Welch özneliği test verileri karmaşıklık matrisi metrikleri.

Uyararı Sembölü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	1	1
Doktor	1	0.8	0.88889
İtfaiye	1	1	1
Polis	0.75	1	0.85714

Welch yöntemi uygulanmış test veri seti için TBESA sınıflandırma sonucunda uyararı veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.12'de verilmiştir.



Şekil 5.12 : TBESA Welch özniteliği test verileri sınıflandırma dağılımı.

5.3. DVM Sınıflandırıcı Ağı Analiz Sonuçları

Sınıflandırma için kullanılan DVM algoritmasında çekirdek fonksiyonu olarak Gaussian çekirdek fonksiyonu kullanılmıştır. Standart normalizasyon işlevi kullanılan yapıda çekirdek ölçekleme değeri 33 dür.

5.3.1. Öznitelik birleştirme sonuçları

Öznitelik birleştirme tekniği uygulanarak çıkarılan öznitelik verileri eğitim veri seti için DVM sınıflandırma sonuçları Tablo 5.18'deki karmaşıklık matrisinde verilmiştir. İtfaiye ve Doktor uyarı veri kümeleri için 1440 örneğin tamamı doğru bir şekilde sınıflandırılmıştır. Aile uyarı veri kümesinin 1440 örneğinden 1360 adeti doğru olarak sınıflandırılırken 80 adeti İtfaiye uyarı olarak hatalı sınıflandırılmıştır. Bu hatalı örnekler İtfaiye uyarı veri kümesinin %5.6'sını temsil etmektedir. Benze şekilde Doktor uyarı veri kümesi 1440 örneğin 1360 adeti doğru sınıflandırılırken 80 adeti Polis uyarı olarak hatalı sınıflandırılmıştır. Doktor uyarısındaki hatalı sınıflandırmış 80 örnek bu veri kümesinin %5.6'sını temsil etmektedir. Tüm uyarı veri kümeleri için sınıflandırma sonucunda tahminlerin %97.2'si doğru, %2.8'i hatalı olarak sınıflandırılmıştır.

Tablo 5.18 : DVM öznitelik birleştirme eğitim verileri karmaşıklık matrisi.

Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1360	0	0	0	100% 0%
	D	0	1360	0	0	100% 0%
	İ	80	0	1440	0	94.7% 5.3%
	P	0	80	0	1440	94.7% 5.3%
	Doğruluk	94.4%	94.4%	100%	100%	97.2%
	Hata	5.6%	5.6%	0.0%	0.0%	2.8%
		A	D	İ	P	
		Hedef Sınıf				

Öznitelik birleştirme yöntemi kullanılarak elde edilen veri setinin DVM eğitimi sonucunda karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.19’da verilmiştir.


Tablo 5.19 : DVM öznitelik birleştirme eğitim verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	0.94444	1	0.97143
Doktor	0.94444	1	0.97143
İtfaiye	1	0.94737	0.97297
Polis	1	0.94737	0.97297

İtfaiye ve Polis uyararı veri kümelerindeki 1440 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyararların keskinlik metrikleri 1 olarak hesaplanmıştır. Aile ve Doktor uyararı veri kümelerinin ikisinde de hatalı 80 örnek sınıflandırması sonucu keskinlik metrik değeri bu uyararı veri kümeleri için 0.94444 olarak hesaplanmıştır. Aile ve Doktor uyararı veri kümeleri hassasiyet metriği bu uyararı veri kümelerinde diğer sınıflardan gelen hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Aile uyararı veri kümesinden 80 örneğin hatalı olarak İtfaiye uyararı olarak sınıflandırılması sonucu İtfaiye uyararı hassasiyet metriği 0.94737,

Doktor uyararı veri kümesinden 80 örneğin hatalı olarak Polis uyararı olarak sınıflandırılması sonucu Polis uyararı hassasiyet metriği 0.94737 olarak hesaplanmıştır. F1 skorları incelendiğinde aynı sayıda iki farklı veri kümesi arasında hatalı sınıflandırma sonucu İtfaiye ve Polis uyararı veri kümeleri F1 skoru 0.97297 hesaplanırken Aile ve Doktor uyararı veri kümeleri F1 skoru 0.97143 olarak hesaplanmıştır.

Öznitelik birleştirme yöntemi uygulanmış verilerin eğitim veri seti için DVM sınıflandırma sonucunda uyararı veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.13’de verilmiştir.



Şekil 5.13 : DVM öznitelik birleştirme eğitim verileri sınıflandırma dağılımı.

DVM yöntemi ile eğitilmiş ağa uygulanan 640 P300 işareti içeren test veri kümesinin sınıflandırma sonuçları karmaşıklık matrisi Tablo 5.20’de verilmiştir. Sınıflandırma sonuçlarına göre İtfaiye ve Polis uyararı veri kümeleri %100 başarımla sınıflandırılmıştır. Aile uyararı veri kümesinden 20 örnek İtfaiye uyararı olarak hatalı sınıflandırılmıştır. Hatalı sınıflandırılan 20 örnek Aile uyararı veri kümesinin %12.5’ini temsil etmektedir. Doktor uyararı veri kümesi 20 örnek Polis uyararı veri kümesi olarak hatalı sınıflandırılmıştır. Hatalı sınıflandırılan 20 örnek Doktor uyararı veri kümesinin %12.5’ini temsil etmektedir. Tüm uyararı veri kümeleri için sınıflandırma sonucunda tahminlerin %93.8’i doğru, %6.2’si hatalı olarak sınıflandırılmıştır.

Tablo 5.20 : DVM öznitelik birleştirme test verileri karmaşıklık matrisi.

Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	140	0	0	0	100% 0%
	D	0	140	0	0	100% 0%
	İ	20	0	160	0	88.9% 11.1%
	P	0	20	0	160	88.9% 11.1%
	Doğruluk	87.5%	87.5%	100%	100%	93.8%
	Hata	12.5%	12.5%	0.0%	0.0%	6.2%
		A	D	İ	P	
		Hedef Sınıf				

DVM eğitilmiş ağına uygulanan test veri kümesi sınıflandırma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.21’de verilmiştir.


Tablo 5.21 : DVM öznitelik birleştirme test verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	0.875	1	0.93333
Doktor	0.875	1	0.93333
İtfaiye	1	0.88889	0.94148
Polis	1	0.88889	0.94148

İtfaiye ve Polis uyararı veri kümelerindeki 160 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyarıların keskinlik metrikleri 1 olarak hesaplanmıştır. Aile uyararı veri kümesinden 20 örneğin hatalı olarak İtfaiye uyararı veri kümesinde sınıflandırılması sonucu Aile uyararı keskinlik metriği 0.875, Doktor uyararı veri kümesinden 20 örneğin hatalı olarak Polis uyararı veri kümesinde sınıflandırılması sonucu Doktor uyararı keskinlik metriği 0.875 olarak hesaplanmıştır. Aile ve Doktor uyarıları hassasiyet metriği bu uyarı sınıflarında diğer sınıflardan gelen hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak

hesaplanmıştır. Aile uyarani veri kümesinden 20 örneğin hatalı olarak İtfaiye uyarani veri kümesinde sınıflandırılması sonucu İtfaiye uyarani hassasiyet metriği 0.88889, Doktor uyarani veri kümesinden 20 örneğin hatalı olarak Polis uyarani veri kümesinde sınıflandırılması sonucu Polis uyarani hassasiyet metriği 0.88889 olarak hesaplanmıştır. F1 skorları incelendiğinde aynı sayıda iki farklı veri kümesi arasında hatalı sınıflandırma sonucu İtfaiye ve Polis uyarani F1 skoru 0.94118 hesaplanırken Aile ve Doktor uyarani F1 skoru 0.93333 olarak hesaplanmıştır.

Öznitelik birleştirme yöntemi uygulanmış verilerin test veri seti için DVM sınıflandırma sonucunda uyarani veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.14’de verilmiştir.



Şekil 5.14 : DVM öznitelik birleştirme test verileri sınıflandırma dağılımı.

5.3.2. Welch özniteliği sonuçları

Welch yöntemi ile elde edilen öznitelik verileri eğitim veri seti için DVM sınıflandırma sonuçları Tablo 5.22’deki karmaşıklık matrisinde verilmiştir. Aile ve İtfaiye uyarani veri kümeleri için 1440 örneğin tamamı doğru bir şekilde sınıflandırılmıştır. Doktor uyarani veri kümesi 1440 örneğinden 1280 adeti doğru olarak sınıflandırılırken 160 adeti Aile uyarani olarak hatalı sınıflandırılmıştır. Bu hatalı örnekler Doktor uyarani veri kümesinin %11.1’ini temsil etmektedir. Polis uyarani veri kümesindeki 1440 örneğin 1340 adeti doğru sınıflandırılırken 100 adeti Doktor uyarani olarak hatalı sınıflandırılmıştır. Polis uyaraniındaki hatalı sınıflandırma bu veri kümesinin %6.9’unu temsil etmektedir. Tüm

uyaran veri kümeleri için sınıflandırma sonucunda tahminlerin %95.5'i doğru, %4.5'i hatalı olarak sınıflandırılmıştır.

Tablo 5.22 : DVM Welch öz niteliği eğitim verileri karmaşıklık matrisi.


Eğitim Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	1440	160	0	0	90% 10%
	D	0	1280	0	100	92.8% 7.2%
	İ	0	0	1440	0	100% 0%
	P	0	0	0	1340	100% 0%
	Doğruluk	100%	88.9%	100%	93.1%	95.5%
	Hata	0.0%	11.1%	0.0%	6.9%	4.5%
		A	D	İ	P	
		Hedef Sınıf				

Welch özelliklerini içeren eğitim veri setinin DVM ile sınıflandırılma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.23'de verilmiştir. Aile ve İtfaiye uyarani veri kümelerindeki 1440 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyaraların keskinlik metrikleri 1 olarak hesaplanmıştır. Polis uyarani veri kümesinde 100 örneğin hatalı sınıflandırması sonucu Polis uyarani keskinlik metrik değeri 0.93056 olarak hesaplanmıştır. Doktor uyarani veri kümesi 160 hatalı sınıflandırma sonucunda 0.88889 keskinlik metrik değeri ile dört uyarani arasındaki en düşük değere sahiptir. İtfaiye ve Polis uyarani veri kümelerinin hassasiyet metriği bu uyarani veri kümelerinde hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değeri olan 1 olarak hesaplanmıştır. Polis uyarani veri kümesinden 100 örneğin hatalı olarak Doktor uyarani veri kümesinde sınıflandırılması sonucu Doktor uyarani hassasiyet değeri 0.92754 hesaplanmıştır. Doktor uyarani veri kümesinden 160 örneğin hatalı olarak Aile uyarani veri kümesinde sınıflandırılması, Aile uyarani hassasiyet değerinin 0.9 ile en düşük değeri olarak hesaplanmasına sebep olmuştur. F1 skorları incelendiğinde en yüksek F1 skoruna 1 ile İtfaiye uyarani sahiptir. Diğer uyaraniların F1 skorları sırası ile Polis uyarani için 0.96403, Aile uyarani için 0.94737 ve Doktor uyarani için 0.9078 olarak hesaplanmıştır.

Tablo 5.23 : DVM Welch özniteliği eğitim verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.9	0.94737
Doktor	0.88889	0.92754	0.9078
İtfaiye	1	1	1
Polis	0.93056	1	0.96403

Welch yöntemi uygulanmış eğitim veri seti için DVM sınıflandırma sonucunda uyaran veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.15’de verilmiştir.



Şekil 5.15 : DVM Welch özniteliği eğitim verileri sınıflandırma dağılımı.

DVM yöntemi ile eğitilmiş ağa uygulanan 640 P300 işareti içeren test veri kümesinin sınıflandırma sonuçları Tablo 5.24’deki karmaşıklık matrisinde verilmiştir. Aile, İtfaiye ve Polis uyaran veri kümeleri için 160 örneğin tamamı doğru olarak sınıflandırılmıştır. Doktor uyaran veri kümesi 160 örneğinden 120 adeti doğru olarak sınıflandırılırken 40 adeti Aile uyarını olarak hatalı sınıflandırılmıştır. Bu hatalı örnekler Doktor uyarını veri kümesinin %25’ini temsil etmektedir. Tüm uyaran veri kümeleri için sınıflandırma sonucunda tahminlerin %93.8’i doğru, %6.2’si hatalı olarak sınıflandırılmıştır.

Tablo 5.24 : DVM Welch öz niteliği test verileri karmaşıklık matrisi.

Test Doğruluğu Karmaşıklık Matrisi						
Çıkış Sınıfı	A	160	40	0	0	80.0% 20.0%
	D	0	120	0	0	100% 0%
	İ	0	0	160	0	100% 0%
	P	0	0	0	160	100% 0%
	Doğruluk	100%	75%	100%	100%	93.8%
	Hata	0.0%	25.0%	0.0%	0.0%	6.2%
		A	D	İ	P	
		Hedef Sınıf				

Welch özelliklerini içeren test veri setinin DVM ile sınıflandırılma sonucu karmaşıklık matrisinden hesaplanmış metrikler Tablo 5.25’de verilmiştir.


Tablo 5.25 : DVM Welch öz niteliği test verileri karmaşıklık matrisi metrikleri.

Uyaran Sembolü	Keskinlik	Geri Çağırma / Hassasiyet	F1 Skoru
Aile	1	0.8	0.88889
Doktor	0.75	1	0.85714
İtfaiye	1	1	1
Polis	1	1	1

Aile, İtfaiye ve Polis uyararı veri kümelerindeki 160 örneğin tamamının doğru olarak sınıflandırılması sonucu bu uyarıların keskinlik metrikleri 1 olarak hesaplanmıştır. Doktor uyararı veri kümesindeki 40 örneğin hatalı sınıflandırılması sonucu bu uyarının keskinlik değeri 0.75 olarak hesaplanmıştır. Doktor, İtfaiye ve Polis uyararı veri kümeleri hassasiyet metriği bu uyarı veri kümelerinde hatalı sınıflandırılmış hiçbir örnek olmaması sebebi ile en yüksek değer olan 1 olarak hesaplanmıştır. Doktor uyararı veri kümesinden 40 örneğin hatalı olarak Aile uyararı veri kümesinde sınıflandırılması sonucu Aile uyararı veri kümesinin hassasiyet değeri 0.8 hesaplanmıştır. F1 skorları

incelendiğinde en yüksek F1 skoruna 1 ile İtfaiye ve Polis uyararı veri kümeleri sahiptir. Diğer uyarıların F1 skorları sırası ile Aile uyararı için 0.88889 ve Doktor uyararı için 0.85714 olarak hesaplanmıştır.

Welch yöntemi uygulanmış test veri seti için DVM sınıflandırma sonucunda uyararı veri kümeleri arasındaki doğru ve hatalı sınıflandırma dağılımı Şekil 5.16’da verilmiştir.



Şekil 5.16 : DVM Welch özneliği test verileri sınıflandırma dağılımı.

5.4. Kullanılan Sınıflandırıcıların Karşılaştırılması


Öznitelik birleştirme ve Welch yöntemleri uygulanarak elde edilmiş P300 Tabanlı BBA sistemi EEG verileri ÇYUKSBA, TBESA ve DVM sınıflandırma algoritmaları ile sınıflandırılmıştır. Sınıflandırma sonuçları başarımlarının kıyaslamasını gösterir sonuçlar Tablo 5.26’da verilmiştir. Elde edilen sonuçlara göre eğitim veri setinde en yüksek başarımları %98.6 ile SpEn ve AFB özellikleri içeren öznitelik birleştirme yöntemi ile ÇYUKSBA sınıflandırıcı algoritması elde etmiştir. TBESA ve DVM algoritmalarının aynı veri kümesindeki başarımları %97.2 olarak elde edilmiştir. Aynı sınıflandırıcı algoritmaların eğitim veri seti Welch özellik verisi sınıflandırma başarımları ÇYUKSBA için %92.4, TBESA için %95.1 ve DVM için %95.5 olarak elde edilmiştir. Welch özelliği ile öznitelikleri çıkarılmış EEG verilerinin eğitim veri kümesi için başarımları önerilen öznitelik birleştirme yönteminin başarımlarından düşük olarak elde edilmiştir.

Eğitim veri kümesi ile eğitimi tamamlanmış ÇYUKSBA, TBESA ve DVM ağlarına uygulanan test veri kümesinin genel başarımlarına göre en yüksek başarımları %96.9


ile SpEn ve AFB özellikleri içeren öznitelik birleştirme yöntemi ile ÇYUKSBA sınıflandırıcı algoritması elde etmiştir. TBESA algoritmasının aynı veri kümesindeki başarımı %95.3, DVM algoritmasının başarımı %93.8 olarak elde edilmiştir. Aynı sınıflandırıcı algoritmalarının Welch özellikleri kullanılarak eğitilmiş ağlarına uygulanan test veri kümelerinin başarımları değerlendirildiğinde, ÇYUKSBA için %90.6, TBESA ve DVM için %93.8 olarak elde edilmiştir. Welch özelliği ile öznitelikleri çıkarılmış EEG verilerinin başarımları eğitim veri kümesinde olduğu gibi test veri kümesinde de önerilen öznitelik birleştirme yönteminin başarımlarından düşük olarak elde edilmiştir.

Tablo 5.26 : Sınıflandırma başarımları.

Sınıflandırma Türü	Öznitelik Türü	Veri Kümesi	Sınıflandırma Başarımı (%)	Sınıflandırma Hatası (%)
ÇYUKSBA	SpEn + AFB	Eğitim	98.6	1.4
		Test	96.9	3.1
	Welch	Eğitim	92.4	7.6
		Test	90.6	9.4
TBESA	SpEn + AFB	Eğitim	97.2	2.8
		Test	95.3	4.7
	Welch	Eğitim	95.1	4.9
		Test	93.8	6.3
DVM	SpEn + AFB	Eğitim	97.2	2.8
		Test	93.8	6.2
	Welch	Eğitim	95.5	4.5
		Test	93.8	6.2



Şekil 5.17 : Eğitim veri kümesi sınıflandırma sonucu uyaran sınıfları arası dağılım.



Şekil 5.18 : Test veri kümesi sınıflandırma sonucu uyaran sınıfları arası dağılım.

Eğitim veri seti için sınıflandırma sonuçlarının uyarıcı sınıfları arasında dağılımlarını gösterir grafik Şekil 5.17’de, test veri seti için sınıflandırma sonuçlarının uyarıcı sınıfları arasında dağılımını gösterir grafik Şekil 5.18’de verilmiştir. Grafiklerdeki turuncu barlar hatalı sınıflandırılmış örnekleri temsil ederken mavi barlar doğru sınıflandırılmış örnekleri temsil etmektedir.

Önerilen paradigma ile tasarlanan P300 tabanlı BBA sisteminin sınıflandırma sonuçlarına dayalı hesap edilmiş BTO sonuçları Tablo 5.27’de verilmiştir. BTO değerleri hesaplandığında eğitim ve test veri kümeleri için en yüksek değer SpEn ve AFB özellik birleşim yöntemi ile elde edilmiş verilerin ÇYUKSBA ile sınıflandırılması sonucu elde edilmiştir. Eğitim veri kümesi için BTO değeri 43.1893 bit/dakika olurken test veri seti için 40.4189 olarak elde edilmiştir.

Tablo 5.27 : Sınıflandırma sonucu BTO değerleri.

Sınıflandırma Yöntemi	Öznitelik Türü	Veri Kümesi	Ortalama BTO (bpm)
ÇYUKSBA	SpEn+AFB	Eğitim	43.1893
		Test	40.4189
	Welch	Eğitim	34.4219
		Test	32.3384
TBESA	SpEn+AFB	Eğitim	40.8775
		Test	38.1229
	Welch	Eğitim	37.8508
		Test	36.1477
DVM	SpEn+AFB	Eğitim	40.8775
		Test	36.1477
	Welch	Eğitim	38.3980
		Test	36.1477

5.5. Önerilen Yöntem ile Literatürün Karşılaştırılması

Literatürde P300 tabanlı BBA sistemleri üzerine daha önce yapılmış çalışmalar farklı veri kümeleri, öznitelik çıkarım teknikleri ve sınıflandırma yöntemlerinin kullanılması nedeniyle karşılaştırmak zor olsa da ÇYUKSBA, TBESA ve DVM sınıflandırma algoritmaları ile son yıllarda yapılmış çalışmalar Tablo 5.28’de verilmiştir.

Tablo 5.28 : Sınıflandırma sonucu BTO değerleri.

Yazarlar	Yıl	Sınıflandırma Yöntemi	Öznitelik Çıkarım Yöntemi	Veri Seti	Uyaran Sayısı	Katılımcı Sayısı	Bilgi Transfer Oranı (%)	Başarım Oranı (%)
Salvaris v.d. [13]	2012	DVM	Kanal Bazlı Ortalama	Kendi veri setleri	8	8	33	90
He v.d. [12]	2017	DVM	Alt Örnekleme	Kendi veri setleri	4	8	-	92.7
Kuo v.d. [100]	2018	DDGUP destekli DVM	CCA Tabanlı Uzamsal Filtre	Kendi veri setleri	4	5	27.9	90.25
Kundu ve Ari [84]	2019	DVM	Aralıklı Otomatik Kodlayıcı	BCI competition Iib	36	-	~45	95.5
Kshirsagar ve Londhe [92]	2019	TBESA	Yığıt Otomatik Kodlayıcı	Kendi veri setleri	64	10	20.58	88.22
Ditthapron v.d. [16]	2019	UKSB-ESA	Otokodlayıcı	BCI competition Iib	36	-	-	80.11
Oralhan [101]	2020	DVM	Belirtilmemiş	Kendi veri setleri	9	4	6.81	83.78
Kundu ve Ari [15]	2020	YSA	Yığıt Otomatik Kodlayıcı	BCI competition Iib	36	-	~15	98
Oralhan [102]	2020	3BESA	Butterworth ve Alt Örnekleme	BCI competition III - II	36	2	5.53	94.22
Lee v.d. [103]	2020	DVM	Aşırı Örnekleme	Kendi veri setleri	6	44	8.82	87.27
Shukla v.d. [104]	2020	ESA	Bağımsız Bileşen Analizi	Kendi veri setleri	6	9	46.45	93.22
Zhang ve Fu [105]	2020	ÇYUKSBA	Belirtilmemiş	BCI competition Iib	36	-	-	80.06
Lee v.d. [106]	2020	ESA	Ortak Ortalama Referans	Kendi veri setleri	36	55	-	89.22
Shukla v.d. [38]	2021	TBESA	Ayrık Dalgacık Dönüşümü	Kendi veri setleri	6	9	22.33	90
Abibullaev ve Zollanvari [67]	2021	UKSB	İşaretçi ve Band Geçiren Filtre	Kendi veri setleri	36	10	-	79.10
Çalışmada Önerilen Yöntem	2021	ÇYUKSBA	Spektral Entropi ve Anlık Frekans Bileşeni	Kendi veri setimiz	4	10	40.4189	96,9

Katılımcı sayıları incelendiğinde çalışmaların birçoğunda 10 ve altında gönüllünün çalışmalara dahil edildiği görülmektedir. BBA sistemlerinin sınıflandırma bölümünde sıklıkla DVM algoritmaları tercih edilmektedir. Son yıllarda DVM kullanarak yapılan P300 tabanlı BBA sınıflandırma başarımları incelendiğinde en yüksek başarıımı Kundu ve Ari yapmış oldukları çalışmada %95.5 ile elde etmişlerdir. DVM ile yapılan çalışmalar incelendiğinde BTO performansı açısından en yüksek değer aynı çalışma ile yaklaşık 45 bit/dakika olarak hesaplanmıştır. Bu yüksek BTO değerini 36 uyaran sayısı ile elde etmişlerdir.

Son yıllarda derin öğrenme algoritmaları görüntü işleme uygulamalarının yanı sıra işaret işleme uygulamalarında da araştırma konusu olmuştur. Sınıflandırıcı ağ mimarilerinin dahili yapısındaki çalışma yöntemine uygun öznitelik çıkarma işlevi tercih edilmedeki en önemli etkenlerden birisidir. Derin öğrenme algoritması ile sınıflandırma çalışması yapılan alanlardan biri de P300 içeren BBA sistemleridir. Tablo incelendiğinde genellikle ESA tabanlı ve TSA tabanlı sınıflandırma algoritmalarının sıklıkla tercih edildiği görülmektedir. Derin öğrenme yaklaşımının P300 içeren BBA uygulamalarında yeni tercih edilmesi sebebi ile mevcut uygulamalar bir temel çalışma niteliğindedir. P300 tabanlı BBA sistemleri üzerinde son yıllarda yapılan ESA tabanlı sınıflandırma çalışmaları incelendiğinde; Oralhan, Butterworth filtreleme ve alt örnekleme öznitelik tekniği kullandığı çalışmasında 3 Boyutlu Evrişimsel sinir Ağı (3BESA) ile %94.22 başarımla elde etmiştir. Çalışmada BTO değeri 6.81 bit/dakika olarak hesaplanmıştır. TSA tabanlı derin öğrenme algoritmalarının P300 tabanlı BBA uygulamaları incelendiğinde genellikle UKSB mimarisinin tercih sebebi olduğu görülmektedir. UKSB sınıflandırma mimarisi kullanan çalışmalar incelendiğinde Ditthapron ve arkadaşları açık erişimli bir veri kümesi kullanarak yapmış oldukları çalışmada %80.11 sınıflandırma başarımla elde etmişlerdir. Çalışmada BTO değeri hesaplanmamıştır. UKSB mimarisini kullanan bir diğer çalışma ise Abibullaev ve Zollanvari nin kendi veri kümelerini oluşturarak yapmış oldukları çalışmadır. Bu çalışmada sınıflandırma başarımla %79.10 olarak elde edilmiştir. Abibullaev ve Zollanvari çalışmalarında BTO değeri hesaplaması yapmamışlardır. Literatür incelendiğinde Zhang ve Fu yapmış oldukları çalışmada P300 içeren EEG işaretlerinde insanların yaşadığı depresyonun etkisini ÇYUKSBA ile sınıflandırmışlardır. Kullanılan ÇYUKSBA mimarisi %80.6 başarımla ulaşmıştır. Çalışma P300 tabanlı bir BBA uygulaması olmaması sebebi ile BTO hesaplaması yapılmadığı görülmektedir.

Bu tez çalışmasında uygulanan sınıflandırma tekniklerinde en yüksek başarımlar %96.9 ile ÇYUKSBA ile elde edilmiştir. Literatürdeki P300 tabanlı BBA uygulamaları ile kıyaslandığında ortalamanın çok üstünde bir başarımlar elde edilmiştir. DVM, ESA ve TSA tabanlı sınıflandırıcı kullanan uygulamaların BTO performansı açısından literatür incelendiğinde 40.4189 bit/dakika gibi ortalamanın üstüne bir değer elde edildiği görülmektedir. Shukla ve arkadaşları yapmış oldukları çalışmada 46.45 bit/dakika gibi yüksek bir değer elde etmişlerdir. BTO hesaplamasında anlatıldığı üzere uyaran sayısı ve sınıflandırma başarımlarının artması ile doğru orantılı olarak BTO performansının arttığı bilinmektedir. Shukla ve arkadaşlarının yapmış olduğu çalışmadaki BTO performansına 6 uyaran ile ulaşmışlardır. Kuo ve arkadaşları sabit uyarılmış potansiyeller ile P300 potansiyellerini hibrit kullandıkları sistemde DVM sınıflandırma sonucunda 4 uyaran ile en yüksek 27.9 bit/dakika BTO değeri elde etmişlerdir. Aynı uyaran sayısına sahip iki sonuç kıyaslandığında bu tez çalışmasında elde edilen 40.4189 bit/dakika BTO değeri önerilen paradigma ve analiz yönteminin başarıma etkisini göstermektedir.

BÖLÜM 6. SONUÇ VE ÖNERİLER

BBA sistemleri üzerine yapılan çalışmaların sayısı gün geçtikçe artmaktadır. Çalışmaların bir bölümü çevresi ile iletişim yeteneği bulunmayan bireylerin çevreleri ile iletişim kurmalarına yönelik olarak gerçekleştirilmektedir. Gerçekleştirilen çalışmaların başka bir bölümü bir veya daha fazla uzvunu kaybetmiş bireylerin belirli bir protezi veya aracı kontrol etmeleri üzerine odaklanmıştır. Son yıllarda BBA çalışmalarının ihtiyaç sahipleri bireylerin bir araç veya bir cihazı kontrolünden ziyade insanların beyin işaretleri yardımı ile oyun, multimedya ve sanal gerçeklik gibi uygulamalar ile eğlence dünyasında da kullanılmaya başlandığı görülmektedir. Gerçekleştirilen uygulamaların birçoğunda zaman ilerledikçe bireylere gösterilen uyaran sayısında da artış olduğu gözlemlenmektedir. Uyaran sayısının fazla olması ile BBA sistemlerinin en önemli performans kriteri olan BTO değerinin de artması amaçlanmaktadır. Bu sayede bireylerin bilgisayar ortamına aktarabildikleri bilgi boyutunun da artması sağlanmaktadır. P300 heceleme sistemleri için dakikadaki bilgi aktarımı en önemli kriterdir ancak boyun bölgesi altını kullanamayan ve iletişim yeteneğini yitirmiş bireyler için asıl önemli olan temel ihtiyaç durumlarını karşı tarafa iletebilmeleridir. Çok sayıda uyaran içeren sistemlerin sistemi kullanan kişinin odaklanma güçlüğü çekmesine, yorucu bir eğitim sürecinin oluşmasına ve istenilen ihtiyacın karşı tarafa aktarılmasında hatalar oluşacağına sebep olabileceği düşünülmektedir. Yapılan çalışmalarda genellikle eğitim veri toplama sürecinde katılımcı bir uyarana odaklandığında bir buton benzeri donanım ile bilgisayara bir işaret göndermesi de istenmektedir. Boyun altı felçli bireylerin bu eğitim sürelerini başarılı tamamlamaları çok zordur. P300 EEG işaretleri yapısı önemli derecede kişisel farklılıklar içermemektedir. Bu düşünceden yola çıkarak temel gereksinimlerini iletme ihtiyacı duyan bireyler dolaylı yararlanıcı kitle olarak seçilmiş ve bu bireylere yönelik gelecekte yapılacak çalışmalara temel oluşturacak sağlıklı gönüllülerden alınan veriler kullanılarak az sayıda uyaran ile BBA sistemi tasarımı hedeflenmiştir. Bu sebeple veri kayıt aşamasında önerilen paradigmada eğitim verisi kayıt işlemi sırasında bir işaretçi

donanım kullanmaktan kaçınılmış ve yazılımsal olarak katılımcının hangi uyarana odaklanılması istendiği önceden bildirilmiştir. BBA sistemlerinin en önemli iki ölçütü olan sınıflandırma başarımı ve BTO performansında kayıt cihazının performansı, uyaran paradigması, uygulanan öznitelik tekniği ve sınıflandırıcının mimarisi değişken oranlarda etkilidir. Bu tez çalışmasında BBA sistemi başarımını etkileyen uyaran paradigması, uygulanan öznitelik tekniği ve sınıflandırıcı mimarisi üzerinde öneriler sunulmuştur.

BBA sistemlerinde BTO performansının artırılmasına yönelik yeni bir uyaran paradigması önerilmiştir. P300 tabanlı BBA sistemlerinin tasarımları uzun yıllardır Farvell ve Donchin tarafından önerilmiş oddball paradigması üzerine kurgulanmaktadır. Oddball paradigması uyaranların rasgele verildiği BBA sistemi ile kayıt altına alınmış EEG işaret pencerelerinde P300 işaretini ikili olarak var veya yok niteliğinde aramaktadır. Sistem çalışmasında sınıflandırma sonucunda en sık P300 işaretine karşılık gelen uyarı odaklanılan uyaran olarak değerlendirmektedir. Tasarlanan sistemlerin çoğunda sınıflandırma sonucunda yüksek başarımın elde edilmesi uyaran verilme sıklığının artırılması ile sağlanmaktadır. Çok sayıda sembol içeren uyaran matrisleri için tekrarlar göz ardı edilecek seviyede BTO performansına etki etmektedir. Oddball paradigmasını kullanan az sayıda uyaran içeren sistemler için bu durum BTO performansı açısından büyük dezavantaj oluşturmaktadır. Bu dezavantajı ortadan kaldırmaya yönelik önerilen uyaran paradigmasında uyaranlar sabit sıra ile katılımcıya gösterilmiştir. Veri işleme sürecinde uyaranlardan önce verilen siyah ekran referans kabul edilmiş veri bu referansa göre veri pencerelenmiştir. Referans noktasından ayrılan her bir EEG verisi 4 uyarı içeren EEG işaretlerini kapsamaktadır. Bu sayede 4 farklı uyaran için işaretin farklı zaman bölgelerinde P300 işareti oluşturulması amaçlanmış ve her uyaran için farklı işaret örüntüsü elde edilmiştir. Bu tasarım ile odağın tespiti için çok sayıda uyaran tekrarının azaltılması amaçlanmıştır. BTO etkileyen kriterlerden olan uyaran sayısının azalmasındaki dezavantaj tekrar sayısının azaltılması ile ortadan kaldırılmaya çalışılmıştır.

BBA sistemlerinin en önemli performans kriteri sınıflandırma başarımı kayıt altına alınan EEG işaretlerinin filtrelenmesi ve P300 işaret özelliğini en iyi ortaya çıkaracak öznitelik çıkarım tekniğinin uygulanmasına bağlı olduğu gibi sınıflandırma işlemini gerçekleştirecek yöntemin performansına da bağlıdır. Tasarlanan sistemde EEG verileri Emotiv EPOC+ cihazı ile kayıt altına alınmıştır. Sistemin kullanılabilirliğe uygun olması

açısından tek kanal olarak O1 sensörü verileri tercih edilmiştir. Elde edilen EEG işaretlerinin Butterworth filtreleme ile yöntemi ile gürültülerden arındırma ve taban kayması problemleri giderilmiştir. Sınıflandırmada en iyi başarıyı elde edebilmek için P300 işaretini mümkün olan en iyi şekilde temsil edecek bir veri kümesi elde etmek önemlidir. Bu amaçla kayıt altına alınan EEG işaretlerinin en iyi P300 özelliğini gösterebilmesine yönelik işaretin SpEn ve AFB özellikleri çıkartılarak öznelik birleştirme tekniği uygulanmıştır. Öznelik birleştirme yönteminin performansa etkisini gözlemlemek adına literatürde sıklıkla kullanılan EEG işareti öznelik çıkarım tekniklerinden Welch tekniği ile de kayıt altına alınan EEG işaretlerinin öznelikleri çıkarılmıştır. Sınıflandırmada en iyi başarıyı elde etmeye yönelik son yıllarda işaret işleme uygulamalarında sıklıkla kullanılan derin öğrenme algoritmalarından ÇYUKSBA ve TBESA tercih edilmiştir. Önerilen derin öğrenme mimarilerinin başarılarını karşılaştırmaya yönelik EEG işaretlerinin sınıflandırılmasında sıklıkla tercih edilen DVM algoritması ayır bir sınıflandırıcı olarak kullanılmıştır.

Tasarlanan deneysel mekanizma üzerinde yapılan çalışmalardan elde edilen sonuçlar incelendiğinde, ÇYUKSBA sınıflandırıcının gelişmiş yapısı ile eğitim veri kümesinde %98,6, test veri kümesinde %96,9 gibi yüksek bir başarı oranı ile TBESA ve DVM sınıflandırıcılarından daha iyi sonuç elde ettiği görülmektedir. Sistem BTO açısından incelendiğinde eğitim veri setinde 43.1893, test veri setinde 40.4189 gibi yüksek değer hesaplanmıştır. Elde edilen sonuçlara göre az sayıda uyaran içeren P300 tabanlı BBA sistemleri için yüksek seviyede başarı ve BTO performansı sağlayan P300 tabanlı BBA sistemi tasarlanmıştır.

Sistemin BBA sistemlerinin en önemli bileşenlerinden olan EEG kayıt cihazlarının performansı sistemin genel performansını doğrudan etkilemektedir. Çalışmada, kablosuz özelliğe sahip tuz bazlı sünger temaslı sensörler kullanan EMOTİV EPOC+ cihazı kullanılmıştır. Kullanılan cihazda sensörler ile kafatası derisi arasındaki tuz bazlı süngerler belirli bir zaman sonra kuruması ve temasının azalması bazı kanallarda veri kaybına sebep olmaktadır. Cihaz taşınabilirlik açısından kablosuz tasarlanmıştır ancak zaman zaman bu haberleşme yöntemi hatalarından kaynaklı örnekleme frekansında kayıplar olduğu tespit edilmiştir. Bu sebeple çalışma boyunca farklı paradigmlar ile 20 katılımcıdan EEG veri kaydı gerçekleştirilmiştir ancak EEG cihazının belirtilen kısıtlarından dolayı sadece 10 katılımcının EEG verileri çalışmada kullanılmıştır. Eğitim

veri seti için çok sayıda katılımcı, iyi kalitede temas sağlayan çok kanallı bir EEG cihazı ve bir işaretçinin kullanılmasının sistemin sınıflandırma başarımını olumlu etkileyeceği düşünülmektedir.

Önerilen paradigma az sayıda uyaran için yüksek performans değerleri elde etmiştir. Önerilen paradigmada uyaranların tamamı gösterilmektedir ve her bir uyaran işaretinde diğer uyaranların verildiği sürelerdeki EEG işaretleri de bulunmaktadır. Uyaran sayısının fazla olması ile katılımcının farklı uyaranlara odaklanabileceği riski ortaya çıkabileceği düşünülmektedir. Aynı zamanda sabit sırada verilen uyaranların tamamının gösterilmesi veri kayıt sürelerinin uzamasına sebep olabilecektir. Bu durumun BTO performansı açısından dezavantaj oluşturabileceği düşünülmektedir.

Engelli bireylere yönelik ileride yapılabilecek BBA sistemlerine bir temel oluşturacak nitelikte yapılan bu çalışmada hedef kitlenin ellerini kullanamayacağı olasılığından yola çıkarak bir işaretçi donanım kullanılmamıştır. Bir işaretçinin kullanılmasının sistemin başarımlarını olumlu etkileyebileceği düşünülmektedir.

KAYNAKLAR

- [1] Wolpaw, J. R., Birbaumer, N., Mcfarland, D. J., Pfurtscheller, G., ve Vaughan, T. M. (2002). Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767-791. doi:10.1016/s1388-2457(02)00057-3
- [2] Abdulkader, S. N., Atia, A., ve Mostafa, M.-S. M. (2015). Brain computer interfacing: Applications and challenges. *Egyptian Informatics Journal*, 16(2), 213-230. doi:10.1016/j.eij.2015.06.002
- [3] Sellers, E. W., Ryan, D. B., ve Hauser, C. K. (2014). Noninvasive brain-computer interface enables communication after brainstem stroke. *Science translational medicine*, 6(257), 257re7-257re7. doi: 10.1126/scitranslmed.3007801
- [4] Beveridge, R., Wilson, S., Callaghan, M., ve Coyle, D. (2019). Neurogaming With Motion-Onset Visual Evoked Potentials (mVEPs): Adults Versus Teenagers. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(4), 572-581. doi:10.1109/tnsre.2019.2904260
- [5] Wolpaw, J. R., ve Wolpaw, E. W. (2012). Brain-computer interfaces: something new under the sun. *Brain-computer interfaces: principles and practice*. New York: Oxford Üniv. Basım
- [6] Saevarsson, S., Kristjánsson, Á., Bach, M., ve Heinrich, S. P. (2012). P300 in neglect. *Clinical Neurophysiology*, 123(3), 496-506. doi:10.1016/j.clinph.2011.07.028
- [7] Sambeth, A., Maes, J. H. R., ve Brankačk, J. (2004). With long intervals, inter-stimulus interval is the critical determinant of the human P300 amplitude. *Neuroscience Letters*, 359(3), 143-146. doi:10.1016/j.neulet.2004.01.064
- [8] Farwell, L. A., ve Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, 70(6), 510-523. doi:10.1016/0013-4694(88)90149-6
- [9] Gu, Z., Chen, Z., Zhang, J., Zhang, X., ve Yu, Z. L. (2019). An Online Interactive Paradigm for P300 Brain–Computer Interface Speller. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(2), 152-161. doi:10.1109/tnsre.2019.2892967
- [10] Perez Vidal, A. F., Oliver Salazar, M. A., ve Salas Lopez, G. (2016). Development of a Brain-Computer Interface Based on Visual Stimuli for the Movement of a

- Robot Joints. Ieee Latin America Transactions, 14(2), 477-484. doi:10.1109/tla.2016.7437182
- [11] Iturrate, I., Antelis, J. M., Kubler, A., ve Minguez, J. (2009). A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. IEEE Transactions on Robotics, 25(3), 614-627. doi:10.1109/tro.2009.2020347
- [12] He, S., Zhang, R., Wang, Q., Chen, Y., Yang, T., Feng, Z., . . . Li, Y. (2017). A P300-Based Threshold-Free Brain Switch and Its Application in Wheelchair Control. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25(6), 715-725. doi:10.1109/tnsre.2016.2591012
- [13] Salvaris, M., Cinel, C., Citi, L., ve Poli, R. (2012). Novel Protocols for P300-Based Brain-Computer Interfaces. Ieee Transactions on Neural Systems and Rehabilitation Engineering, 20(1), 8-17. doi:10.1109/tnsre.2011.2174463
- [14] Wang, M., Daly, I., Allison, B. Z., Jin, J., Zhang, Y., Chen, L., ve Wang, X. (2015). A new hybrid BCI paradigm based on P300 and SSVEP. Journal of Neuroscience Methods, 244, 16-25. doi:10.1016/j.jneumeth.2014.06.003
- [15] Kundu, S., ve Ari, S. (2020). A Deep Learning Architecture for P300 Detection with Brain-Computer Interface Application. IRBM, 41(1), 31-38. doi:10.1016/j.irbm.2019.08.001
- [16] Dittaporn, A., Banluesombatkul, N., Ketrat, S., Chuangsuwanich, E., ve Wilaiprasitporn, T. (2019). Universal Joint Feature Extraction for P300 EEG Classification Using Multi-Task Autoencoder. IEEE Access, 7, 68415-68428. doi:10.1109/access.2019.2919143
- [17] Watson, Craig. Basic Human Neuroanatomy: A Clinically Oriented Atlas (6. bs.). Lulu.com, 2012.
- [18] Borden, N. M., Forseen, S. E., ve Stefan, C. (2015). Imaging Anatomy of the Human Brain: A Comprehensive Atlas Including Adjacent Structures. New York: Springer Publishing Company.
- [19] Url-1 <<https://www.dana.org/wp-content/uploads/2019/08/anatomy-function-brain-areas-basics-large.jpg>>, erişim tarihi 17.12.2021.
- [20] Dubin, M. W. (2013). How the brain works. Massachusettes: John Wiley ve Sons.
- [21] Oralhan, Z. (2016). Durağan Hal Görsel Uyarı Tabanlı Beyin Bilgisayar Arayüzü İçin Optimum Uyarı Özelliklerinin Belirlenmesi Ve Gerçeklenmesi. Doktora Tezi, Erciyes Üniversitesi, Kayseri.
- [22] Miller, K. J., Hermes, D., ve Staff, N. P. (2020). The current state of electrocorticography-based brain-computer interfaces. Neurosurgical Focus, 49(1), E2. doi:10.3171/2020.4.focus20185
- [23] Gross, J. (2019). Magnetoencephalography in Cognitive Neuroscience: A Primer. Neuron, 104(2), 189-204. doi:10.1016/j.neuron.2019.07.001

- [24] Scarapicchia, V., Brown, C., Mayo, C., ve Gawryluk, J. R. (2017). Functional magnetic resonance imaging and functional near-infrared spectroscopy: insights from combined recording studies. *Frontiers in human neuroscience*, 11, 419. doi:10.3389/fnhum.2017.00419
- [25] Buxton, R. B. (2009). *Introduction to functional magnetic resonance imaging: principles and techniques*. New York: Cambridge Üniv. Basım.
- [26] Menon, S., Zhu, J., Goyal, D., ve Khatib, O. (2017, 2017-07-01). Haptic fMRI: Reliability and performance of electromagnetic haptic interfaces for motion and force neuroimaging experiments. Paper presented at the 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) içinde (ss. 3930-3935). doi: 10.1109/EMBC.2017.8037716.
- [27] Quaresima, V., ve Ferrari, M. (2019). Functional Near-Infrared Spectroscopy (fNIRS) for Assessing Cerebral Cortex Function During Human Behavior in Natural/Social Situations: A Concise Review. *Organizational Research Methods*, 22(1), 46-68. doi:10.1177/1094428116658959
- [28] Schomer, D. L., ve Da Silva, F. L. (2012). *Niedermeyer's electroencephalography: Basic principles, clinical applications, and related fields*. Lippincott Williams ve Wilkins. New York: Oxford Üniv. Basım. doi: 10.1093/med/9780190228484.001.0001
- [29] Vasiljevic, G. A. M., ve De Miranda, L. C. (2020). Brain–Computer Interface Games Based on Consumer-Grade EEG Devices: A Systematic Literature Review. *International Journal of Human–Computer Interaction*, 36(2), 105-142. doi:10.1080/10447318.2019.1612213
- [30] Sanei, S., ve Chambers, J. A. (2013). *EEG signal processing*. Massachusettes: John Wiley ve Sons.
- [31] Antonietti, A., Balachandran, P., Hossaini, A., Hu, Y., ve Valeriani, D. (2021). The BCI Glossary: a first proposal for a community review. *Brain-Computer Interfaces*, 8(3), 42-53. doi:10.1080/2326263x.2021.1969789
- [32] Shih, J. J., Krusienski, D. J., ve Wolpaw, J. R. (2012). Brain-Computer Interfaces in Medicine. *Mayo Clinic Proceedings*, 87(3), 268-279. doi:10.1016/j.mayocp.2011.12.008
- [33] Na, R., Hu, C., Sun, Y., Wang, S., Zhang, S., Han, M., . . . Zheng, D. (2021). An embedded lightweight SSVEP-BCI electric wheelchair with hybrid stimulator. *Digital Signal Processing*, 116, 103101. doi:10.1016/j.dsp.2021.103101
- [34] Shedeed, H. A., Issa, M. F., ve El-Sayed, S. M. (2013, 2013-11-01). Brain EEG signal processing for controlling a robotic arm. Paper presented at the 2013 8th International Conference on Computer Engineering & Systems (ICCES). (ss. 152 – 157)

- [35] Verkijika, S. F., ve De Wet, L. (2015). Using a brain-computer interface (BCI) in reducing math anxiety: Evidence from South Africa. *Computers & Education*, 81, 113-122. doi: 10.1016/j.compedu.2014.10.002
- [36] Al-Hudhud, G., Alzamel, M. A., Alattas, E., ve Alwabil, A. (2014). Using brain signals patterns for biometric identity verification systems. *Computers in Human Behavior*, 31, 224-229. doi: 10.1016/j.chb.2013.09.018
- [37] Liu, Y., Habibnezhad, M., ve Jebelli, H. (2021). Brain-computer interface for hands-free teleoperation of construction robots. *Automation in Construction*, 123, 103523. doi:10.1016/j.autcon.2020.103523
- [38] Shukla, P. K., Chaurasiya, R. K., ve Verma, S. (2021). Performance improvement of P300-based home appliances control classification using convolution neural network. *Biomedical Signal Processing and Control*, 63, 102220. doi: 10.1016/j.compedu.2014.10.002
- [39] Sözer, A.T. (2017). Durağan Hal Görsel Uyarılmış Potansiyel Temelli Beyin Bilgisayar Arayüzü Tasarımı Ve Uygulaması. Doktora Tezi, Karabük Üniversitesi, Karabük.
- [40] Pfurtscheller, G., Stancák, A., ve Neuper, C. (1996). Event-related synchronization (ERS) in the alpha band — an electrophysiological correlate of cortical idling: A review. *International Journal of Psychophysiology*, 24(1-2), 39-46. doi:10.1016/s0167-8760(96)00066-9
- [41] Koo, B., Lee, H.-G., Nam, Y., Kang, H., Koh, C. S., Shin, H.-C., ve Choi, S. (2015). A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery. *Journal of Neuroscience Methods*, 244, 26-32. doi:10.1016/j.jneumeth.2014.04.016
- [42] Herrmann, C. S., ve Knight, R. T. (2001). Mechanisms of human attention: event-related potentials and oscillations. *Neuroscience & Biobehavioral Reviews*, 25(6), 465-476. doi:10.1016/s0149-7634(01)00027-6
- [43] Duncan, C. C., Barry, R. J., Connolly, J. F., Fischer, C., Michie, P. T., Näätänen, R., . . . Van Petten, C. (2009). Event-related potentials in clinical research: Guidelines for eliciting, recording, and quantifying mismatch negativity, P300, and N400. *Clinical Neurophysiology*, 120(11), 1883-1908. doi:10.1016/j.clinph.2009.07.045
- [44] Yordanova, J., ve Kolev, V. (1997). Developmental changes in the event-related EEG theta response and P300. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, 104(5), 418-430. doi:10.1016/s0168-5597(97)00054-3
- [45] Fazel-Rezai, R. (Editör). (2011). Recent advances in brain-computer interface systems. Rijeka: InTech
- [46] Oralhan, Z. (2019). A New Paradigm for Region-Based P300 Speller in Brain Computer Interface. *IEEE Access*, 7, 106618-106627. doi:10.1109/access.2019.2933049

- [47] Aydin, E. A., Bay, O. F., ve Guler, I. (2018). P300-Based Asynchronous Brain Computer Interface for Environmental Control System. *IEEE Journal of Biomedical and Health Informatics*, 22(3), 653-663. doi:10.1109/jbhi.2017.2690801
- [48] Rathi, N., Singla, R., ve Tiwari, S. (2021). A novel approach for designing authentication system using a picture based P300 speller. *Cognitive Neurodynamics*, 15(5), 805-824. doi:10.1007/s11571-021-09664-3
- [49] Url-2<<https://www.crossroadsacademy.org/crossroads/wp-content/uploads/2016/05/Test-Bench-Manual-.pdf>>, erişim tarihi 22.12.2021.
- [50] Santopetro, N. J., Brush, C. J., Burani, K., Bruchnak, A., ve Hajcak, G. (2021). Doors P300 moderates the relationship between reward positivity and current depression status in adults. *Journal of Affective Disorders*, 294, 776-785. doi:10.1016/j.jad.2021.07.091
- [51] Mumtaz, W., Rasheed, S., ve Irfan, A. (2021). Review of challenges associated with the EEG artifact removal methods. *Biomedical Signal Processing and Control*, 68, 102741. doi:10.1016/j.bspc.2021.102741
- [52] Jiang, X., Bian, G.-B., ve Tian, Z. (2019). Removal of Artifacts from EEG Signals: A Review. *Sensors*, 19(5), 987. doi:10.3390/s19050987
- [53] Minguillon, J., Lopez-Gordo, M. A., ve Pelayo, F. (2017). Trends in EEG-BCI for daily-life: Requirements for artifact removal. *Biomedical Signal Processing and Control*, 31, 407-418. doi:10.1016/j.bspc.2016.09.005
- [54] Agrawal, N., Kumar, A., Bajaj, V., ve Singh, G. K. (2021). Design of digital IIR filter: A research survey. *Applied Acoustics*, 172, 107669. doi:10.1016/j.apacoust.2020.107669
- [55] Majumdar, K. K., ve Vardhan, P. (2011). Automatic Seizure Detection in ECoG by Differential Operator and Windowed Variance. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(4), 356-365. doi:10.1109/tnsre.2011.2157525
- [56] Martinez, P., Bakardjian, H., ve Cichocki, A. (2007). Fully online multicommand brain-computer interface with visual neurofeedback using SSVEP paradigm. *Computational intelligence and neuroscience*, 2007. (1-9) doi:10.1155/2007/94561
- [57] Dornhege, G., Blankertz, B., Curio, G., ve Muller, K.-R. (2004). Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms. *IEEE Transactions on Biomedical Engineering*, 51(6), 993-1002. doi:10.1109/tbme.2004.827088
- [58] Basiri M, M. A., ve Sk, N. M. (2015). Configurable Folded IIR Filter Design. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 62(12), 1144-1148. doi:10.1109/tcsii.2015.2468917

- [59] Amini, Z., Abootalebi, V., ve Sadeghi, M. T. (2013). Comparison of Performance of Different Feature Extraction Methods in Detection of P300. *Biocybernetics and Biomedical Engineering*, 33(1), 3-20. doi:10.1016/s0208-5216(13)70052-4
- [60] Kundu, S., ve Ari, S. (2021). Brain-Computer Interface Speller System for Alternative Communication: A Review. *IRBM*. doi:10.1016/j.irbm.2021.07.001
- [61] Chiarelli, A. M., Croce, P., Merla, A., ve Zappasodi, F. (2018). Deep learning for hybrid EEG-fNIRS brain-computer interface: application to motor imagery classification. *Journal of neural engineering*, 15(3), 036028.
- [62] Tsiouris, K. M., Pezoulas, V. C., Zervakis, M., Konitsiotis, S., Koutsouris, D. D., ve Fotiadis, D. I. (2018). A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in Biology and Medicine*, 99, 24-37. doi:10.1016/j.compbiomed.2018.05.019
- [63] Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., ve Lance, B. J. (2018). EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering*, 15(5), 056013.
- [64] Gao, W., Guan, J.-A., Gao, J., ve Zhou, D. (2015). Multi-ganglion ANN based feature learning with application to P300-BCI signal classification. *Biomedical Signal Processing and Control*, 18, 127-137. doi:10.1016/j.bspc.2014.12.007
- [65] Li, J., Yu, Z. L., Gu, Z., Wu, W., Li, Y., ve Jin, L. (2018). A Hybrid Network for ERP Detection and Analysis Based on Restricted Boltzmann Machine. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(3), 563-572. doi:10.1109/tnsre.2018.2803066
- [66] Lu, N., Li, T., Ren, X., ve Miao, H. (2017). A Deep Learning Scheme for Motor Imagery Classification based on Restricted Boltzmann Machines. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(6), 566-576. doi:10.1109/tnsre.2016.2601240
- [67] Abibullaev, B., ve Zollanvari, A. (2021). A Systematic Deep Learning Model Selection for P300-Based Brain-Computer Interfaces. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1-13. doi:10.1109/tsmc.2021.3051136
- [68] Acharya, U. R., Fujita, H., Sudarshan, V. K., Bhat, S., ve Koh, J. E. W. (2015). Application of entropies for automated diagnosis of epilepsy using EEG signals: A review. *Knowledge-Based Systems*, 88, 85-96. doi:10.1016/j.knosys.2015.08.004
- [69] Khan, N. A., Ali, S., ve Choi, K. (2021). An instantaneous frequency and group delay based feature for classifying EEG signals. *Biomedical Signal Processing and Control*, 67, 102562. doi:10.1016/j.bspc.2021.102562
- [70] Asgharzadeh-Bonab, A., Amirani, M. C., ve Mehri, A. (2020). Spectral entropy and deep convolutional neural network for ECG beat classification. *Biocybernetics and Biomedical Engineering*, 40(2), 691-700. doi:10.1016/j.bbe.2020.02.004

- [71] Boashash, B., Azemi, G., ve O'Toole, J. M. (2013). Time-Frequency Processing of Nonstationary Signals: Advanced TFD Design to Aid Diagnosis with Highlights from Medical Applications. *IEEE Signal Processing Magazine*, 30(6), 108-119. doi:10.1109/msp.2013.2265914
- [72] Dodia, S., Edla, D. R., Bablani, A., Ramesh, D., ve Kuppili, V. (2019). An efficient EEG based deceit identification test using wavelet packet transform and linear discriminant analysis. *Journal of Neuroscience Methods*, 314, 31-40. doi:10.1016/j.jneumeth.2019.01.007
- [73] Chang, W., Wang, H., Hua, C., Wang, Q., ve Yuan, Y. (2019). Comparison of different functional connectives based on EEG during concealed information test. *Biomedical Signal Processing and Control*, 49, 149-159. doi:10.1016/j.bspc.2018.12.008
- [74] Roy, G., Bhoi, A. K., ve Bhaumik, S. (2021). A Comparative Approach for MI-Based EEG Signals Classification Using Energy, Power and Entropy. *IRBM*. doi:10.1016/j.irbm.2021.02.008
- [75] Khan, N. A., Ali, S., ve Choi, K. (2021). An instantaneous frequency and group delay based feature for classifying EEG signals. *Biomedical Signal Processing and Control*, 67, 102562. doi:10.1016/j.bspc.2021.102562
- [76] Khan, N. A., ve Boashash, B. (2016). Multi-component instantaneous frequency estimation using locally adaptive directional time frequency distributions. *International Journal of Adaptive Control and Signal Processing*, 30(3), 429-442. doi:10.1002/acs.2583
- [77] Zhang, Y., Chen, W., Lin, C.-L., Pei, Z., Chen, J., ve Chen, Z. (2021). Boosting-LDA algorithm with multi-domain feature fusion for motor imagery EEG decoding. *Biomedical Signal Processing and Control*, 70, 102983. doi:10.1016/j.bspc.2021.102983
- [78] Taran, S., ve Bajaj, V. (2019). Emotion recognition from single-channel EEG signals using a two-stage correlation and instantaneous frequency-based filtering method. *Computer Methods and Programs in Biomedicine*, 173, 157-165. doi:10.1016/j.cmpb.2019.03.015
- [79] Nelli, S., Itthipuripat, S., Srinivasan, R., ve Serences, J. T. (2017). Fluctuations in instantaneous frequency predict alpha amplitude during visual perception. *Nature Communications*, 8(1). doi:10.1038/s41467-017-02176-x
- [80] Landau, O., Cohen, A., Gordon, S., ve Nissim, N. (2020). Mind your privacy: Privacy leakage through BCI applications using machine learning methods. *Knowledge-Based Systems*, 198, 105932. doi:10.1016/j.knosys.2020.105932
- [81] Alkan, A., ve Yilmaz, A. S. (2007). Frequency domain analysis of power system transients using Welch and Yule-Walker AR methods. *Energy Conversion and Management*, 48(7), 2129-2135. doi:10.1016/j.enconman.2006.12.017

- [82] Gupta, A., Agrawal, R. K., Kirar, J. S., Andreu-Perez, J., Ding, W.-P., Lin, C.-T., ve Prasad, M. (2021). On the Utility of Power Spectral Techniques With Feature Selection Techniques for Effective Mental Task Classification in Noninvasive BCI. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 51(5), 3080-3092. doi:10.1109/tsmc.2019.2917599
- [83] Zhang, Y., Chen, W., Lin, C.-L., Pei, Z., Chen, J., ve Chen, Z. (2021). Boosting-LDA algriothm with multi-domain feature fusion for motor imagery EEG decoding. *Biomedical Signal Processing and Control*, 70, 102983. doi:10.1016/j.bspc.2021.102983
- [84] Kundu, S., ve Ari, S. (2019). P300 based character recognition using sparse autoencoder with ensemble of SVMs. *Biocybernetics and Biomedical Engineering*, 39(4), 956-966. doi:10.1016/j.bbe.2019.08.001
- [85] Hu, L., Xie, J., Pan, C., Wu, X., ve Hu, D. (2021). Multi-feature fusion method based on WOSF and MSE for four-class MI EEG identification. *Biomedical Signal Processing and Control*, 69, 102907. doi:10.1016/j.bspc.2021.102907
- [86] Al-Qazzaz, N. K., Alyasseri, Z. A. A., Abdulkareem, K. H., Ali, N. S., Al-Mhiqani, M. N., ve Guger, C. (2021). EEG feature fusion for motor imagery: A new robust framework towards stroke patients rehabilitation. *Computers in Biology and Medicine*, 137, 104799. doi:10.1016/j.compbimed.2021.104799
- [87] Hochreiter, S., ve Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. doi: 10.1162/neco.1997.9.8.1735
- [88] Wang, S., Wang, X., Wang, S., ve Wang, D. (2019). Bi-directional long short-term memory method based on attention mechanism and rolling update for short-term load forecasting. *International Journal of Electrical Power & Energy Systems*, 109, 470-479. doi:10.1016/j.ijepes.2019.02.022
- [89] Hu, X., Yuan, S., Xu, F., Leng, Y., Yuan, K., ve Yuan, Q. (2020). Scalp EEG classification using deep Bi-LSTM network for seizure detection. *Computers in Biology and Medicine*, 124, 103919. doi:10.1016/j.compbimed.2020.103919
- [90] Gao, B., Zhou, J., Yang, Y., Chi, J., ve Yuan, Q. (2022). Generative adversarial network and convolutional neural network-based EEG imbalanced classification model for seizure detection. *Biocybernetics and Biomedical Engineering*, 42(1), 1-15. doi:10.1016/j.bbe.2021.11.002
- [91] Amin, S. U., Alsulaiman, M., Muhammad, G., Bencherif, M. A., ve Hossain, M. S. (2019). Multilevel Weighted Feature Fusion Using Convolutional Neural Networks for EEG Motor Imagery Classification. *IEEE Access*, 7, 18940-18950. doi:10.1109/access.2019.2895688
- [92] Kshirsagar, G. B., ve Londhe, N. D. (2019). Improving Performance of Devanagari Script Input-Based P300 Speller Using Deep Learning. *Ieee Transactions on Biomedical Engineering*, 66(11), 2992-3005. doi:10.1109/tbme.2018.2875024

- [93] Xu, Z., Zhao, J., Yu, Y., ve Zeng, H. (2020). Improved 1D-CNNs for behavior recognition using wearable sensor network. *Computer Communications*, 151, 165-171. doi:10.1016/j.comcom.2020.01.012
- [94] Delgado, J. M. C., Achanccaray, D., Villota, E. R., ve Chevallier, S. (2020). Riemann-Based Algorithms Assessment for Single- and Multiple-Trial P300 Classification in Non-Optimal Environments. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(12), 2754-2761. doi:10.1109/tnsre.2020.3043418
- [95] Jha, R. K., ve Swami, P. D. (2021). Fault diagnosis and severity analysis of rolling bearings using vibration image texture enhancement and multiclass support vector machines. *Applied Acoustics*, 182, 108243. doi:10.1016/j.apacoust.2021.108243
- [96] Nakagawa, S., Hochin, T., Nomiya, H., Nakanishi, H., ve Shoji, M. (2021). Prediction of unusual plasma discharge by using Support Vector Machine. *Fusion Engineering and Design*, 167, 112360. doi:10.1016/j.fusengdes.2021.112360
- [97] Zou, S., Qiu, T., Huang, P., Bai, X., ve Liu, C. (2020). Constructing Multi-scale Entropy Based on the Empirical Mode Decomposition(EMD) and its Application in Recognizing Driving Fatigue. *Journal of Neuroscience Methods*, 341, 108691. doi:10.1016/j.jneumeth.2020.108691
- [98] Liu, X., Xie, Q., Lv, J., Huang, H., ve Wang, W. (2021). P300 event-related potential detection using one-dimensional convolutional capsule networks. *Expert Systems with Applications*, 174, 114701. doi:10.1016/j.eswa.2021.114701
- [99] Liu, M., Wu, W., Gu, Z., Yu, Z., Qi, F., ve Li, Y. (2018). Deep learning based on Batch Normalization for P300 signal detection. *Neurocomputing*, 275, 288-297. doi:10.1016/j.neucom.2017.08.039
- [100] Kuo, C. H., Chen, H. H., Chou, H. C., Chen, P. N., & Kuo, Y. C. (2018). Wireless stimulus-on-device design for novel P300 hybrid brain-computer interface applications. *Computational intelligence and neuroscience*, (1-13). doi: 10.1155/2018/2301804
- [101] Oralhan, Z. (2019). P300 ve DHGUP Tabanlı Hibrid BBA Hecceleyicisi için Yeni bir Yaklaşım. *European Journal of Science and Technology*, 1392-1398. doi:10.31590/ejosat.671521
- [102] Oralhan, Z. (2020). 3D Input Convolutional Neural Networks for P300 Signal Detection. *IEEE Access*, 8, 19521-19529. doi:10.1109/access.2020.2968360
- [103] Lee, T., Kim, M., ve Kim, S.-P. (2020). Improvement of P300-Based Brain-Computer Interfaces for Home Appliances Control by Data Balancing Techniques. *Sensors*, 20(19), 5576. doi:10.3390/s20195576
- [104] Shukla, P., Chaurasiya, R., ve Verma, S. (2020). Brain-computer interface-based single trial P300 detection for home environment application. *Electronics Letters*, 56(25), 1392-1395. doi:10.1049/el.2020.2488

- [105] Zhang, Y., ve Fu, Z. (2020). The study of EEG Recognition of Depression on Bi-LSTM based on ERP P300. E3S Web of Conferences, 185, 02007. doi:10.1051/e3sconf/202018502007
- [106] Lee, J., Won, K., Kwon, M., Jun, S. C., ve Ahn, M. (2020). CNN With Large Data Achieves True Zero-Training in Online P300 Brain-Computer Interface. Ieee Access, 8, 74385-74400. doi:10.1109/access.2020.29880579

